



**UNIVERSIDADE FEDERAL DO OESTE DO PARÁ – UFOPA
INSTITUTO DE ENGENHARIA E GEOCIÊNCIAS – IEG
BACHARELADO INTERDISCIPLINAR EM CIÊNCIA E TECNOLOGIA**

CÉLIA YASMIN SOUSA PEREIRA

**COMPARAÇÃO DE MODELOS DE REDES NEURAS CONVOLUCIONAIS COM
TRANSFER LEARNING PARA A CLASSIFICAÇÃO DE IMAGENS**

SANTARÉM

2024

CÉLIA YASMIN SOUSA PEREIRA

**COMPARAÇÃO DE MODELOS DE REDES NEURAS CONVOLUCIONAIS COM
TRANSFER LEARNING PARA A CLASSIFICAÇÃO DE IMAGENS**

Trabalho de Conclusão de Curso apresentado ao Bacharelado Interdisciplinar em Ciência e Tecnologia para obtenção do grau de Bacharel em Ciência e Tecnologia na Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências.

Orientador: Anderson Alvarenga de Moura Meneses

SANTARÉM

2024



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO OESTE DO PARÁ
INSTITUTO DE ENGENHARIA E GEOCIÊNCIAS**



AD REFERENDUM Nº 9 / 2024 - IEG (11.01.09)

Nº do Protocolo: 23204.014149/2024-61

Santarém-PA, 28 de outubro de 2024.

O presidente do Colegiado de Cursos do Programa de Ciência e Tecnologia* do Instituto de Engenharia e Geociências (IEG) da Universidade Federal do Oeste do Pará (Ufopa), no uso de suas atribuições legais, e considerando:

O atendimento ao princípio da continuidade e eficiência administrativa do serviço público, para que essa decisão produza efeitos de forma tempestiva na vigência prevista;

Considerando o Regimento de TCC dos cursos do Programa de Ciência e Tecnologia, em conformidade com o Projeto Pedagógico do Curso (PPC) de Bacharelado Interdisciplinar em Ciência e Tecnologia;

Considerando que o trabalho "COMPARAÇÃO DE MODELOS DE REDES NEURAIS CONVOLUCIONAIS COM TRANSFER LEARNING PARA A CLASSIFICAÇÃO DE IMAGENS" foi publicado por meio digital no XXVI Encontro Nacional de Modelagem Computacional e Encontro de Ciência e Tecnologia dos Materiais, realizado no período de 25 a 27 de outubro de 2023.

MANIFESTA-SE, ad referendum:

1) Pela aprovação do Trabalho de Conclusão de Curso "COMPARAÇÃO DE MODELOS DE REDES NEURAIS CONVOLUCIONAIS COM TRANSFER LEARNING PARA A CLASSIFICAÇÃO DE IMAGENS" da aluna CÉLIA YASMIN SOUSA PEREIRA - 2021004284, na modalidade Publicação em Evento Científico, com orientação do docente ANDERSON ALVARENGA DE MOURA MENESES, vinculado ao período 2024.1.

2) Pela atribuição da nota 7,0 ao TCC supracitado.

Observação: A nota para TCC na modalidade de publicação em evento científico é definida pelo Regimento de TCC do Programa de Ciência e Tecnologia. Para pleitear uma nota maior o aluno deve solicitar a composição de uma banca de avaliação para a realização de uma avaliação pública. A discente não realizou a solicitação.

* Bacharelado Interdisciplinar em Ciência e Tecnologia, Bacharelado em Engenharia Física e Bacharelado em Engenharia Mecânica

(Assinado digitalmente em 28/10/2024 16:08)

UBIRAEELSON DE LIMA RUELA
COORDENADOR DE CURSO - TITULAR
IEG (11.01.09)
Matrícula: 2060289

Visualize o documento original em <https://sipac.ufopa.edu.br/public/documentos/index.jsp> informando seu número: **9**, ano: **2024**, tipo: **AD REFERENDUM**, data de emissão: **28/10/2024** e o código de verificação: **a650d5d52c**

**Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema Integrado de Bibliotecas – SIBI/ UFOPA**

- P436c Pereira, Célia Yasmin Sousa
Comparação de modelos de redes neurais convolucionais com transfer learning para a classificação de imagens./ Célia Yasmin Sousa Pereira. – Santarém, 2024.
13 p.: il.
Inclui bibliografias.
- Orientador: Anderson Alvarenga de Moura Meneses.
Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências, Bacharelado Interdisciplinar em Ciência e Tecnologia.
1. Redes Neurais Convolucionais. 2. Machine Learning. 3. Transfer Learning. 4. Modelos Pré-Treinados. I. Meneses, Anderson Alvarenga de Moura, *orient.* II. Título.
- CDD: 23 ed. 621.38456

RESUMO

O presente trabalho aborda o desenvolvimento e aplicação de modelos pré-treinados para o reconhecimento de imagens de diferentes datasets, onde foram aplicados modelos de Redes Neurais Convolucionais (CNN, do inglês Convolutional Neural Network) a partir do Aprendizado de Transferência (TL, do inglês Transfer Learning). Desse modo, surgiu a perspectiva de utilizar um modelo já treinado como ponto de partida para a resolução de um outro problema relacionado. Em vista disso, o objetivo principal do projeto voltou-se para o destaque na aplicação dos modelos pré-treinados para grandes conjuntos de dados e a comparação entre os dois modelos escolhidos para o projeto, os quais são: ResNet50 e InceptionV3. A pesquisa evoluiu para o estudo e comparação entre dois modelos pré-treinados, ResNet50 e InceptionV3. Como resultado, o modelo pré-treinado ResNet50 obteve resultado superior ao modelo InceptionV3 (com acurácias médias 0.8856 e 0.8363, respectivamente), aplicado o teste não-paramétrico de Kruskal-Wallis, atestou-se que há diferença estatisticamente significativa entre os resultados dos modelos.

Palavras-chave: Redes Neurais Convolucionais; Machine Learning; Transfer Learning; Modelos Pré-Treinados.



COMPARAÇÃO DE MODELOS DE REDES NEURAIAS CONVOLUCIONAIS COM TRANSFER LEARNING PARA A CLASSIFICAÇÃO DE IMAGENS

Célia Yasmin Sousa Pereira¹ – celia.pereira@discente.ufopa.edu.br

Yana dos Santos Pereira¹ – yana.pereira@discente.ufopa.edu.br

Anderson Alvarenga de Moura Meneses^{1,2} – anderson.meneses@ufopa.edu.br

¹ Laboratório de Inteligência Computacional – Universidade Federal do Oeste do Pará - Santarém, PA, Brasil

² Universidade Federal do Oeste do Pará, Programa de Pós-Graduação em Sociedade, Natureza e Desenvolvimento – Santarém, PA, Brasil

Resumo: O presente trabalho aborda o desenvolvimento e aplicação de modelos pré-treinados para o reconhecimento de imagens de diferentes datasets, onde foram aplicados modelos de Redes Neurais Convolucionais (CNN, do inglês Convolutional Neural Network) a partir do Aprendizado de Transferência (TL, do inglês Transfer Learning). Desse modo, surgiu a perspectiva de utilizar um modelo já treinado como ponto de partida para a resolução de um outro problema relacionado. Em vista disso, o objetivo principal do projeto voltou-se para o destaque na aplicação dos modelos pré-treinados para grandes conjuntos de dados e a comparação entre os dois modelos escolhidos para o projeto, os quais são: ResNet50 e InceptionV3. A pesquisa evoluiu para o estudo e comparação entre dois modelos pré-treinados, ResNet50 e InceptionV3. Como resultado, o modelo pré-treinado ResNet50 obteve resultado superior ao modelo InceptionV3 (com acurácias médias 0.8856 e 0.8363, respectivamente), aplicado o teste não-paramétrico de Kruskal-Wallis, atestou-se que há diferença estatisticamente significativa entre os resultados dos modelos.

Palavras-chave: Redes Neurais Convolucionais; Machine Learning; Transfer Learning; Modelos Pré-Treinados;

1. INTRODUÇÃO

Redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos constituídos de unidades simples, os nodos ou neurônios, que computam funções matemáticas (especialmente não-lineares). As RNAs apresentam-se como ferramentas estatísticas capazes de armazenar conhecimentos a partir de exemplos, e vem sendo aplicadas em problemas de ajuste de funções, reconhecimento de padrões, modelos de previsão e outras aplicações em diversas áreas do conhecimento humano. Segundo Fiorin (2011), “a principal razão para sua ampla gama de aplicações reside na capacidade de generalização, auto-organização, e processamento temporal que possibilita a resolução de diferentes problemas complexidades”.

Por meio de algoritmos, as RNAs são capazes de reconhecer padrões e, assim, baseado no funcionamento do cérebro humano, podem adaptar-se a mudanças para aprender com os

erros e tomar decisões a partir da aprendizagem, com um aprimoramento contínuo, a fim de enfrentar situações complexas. Dessa maneira, surgiu a perspectiva de utilizar um modelo já treinado como ponto de partida para a resolução de um outro problema relacionado.

Para iniciar os trabalhos de pesquisa, foram necessários referenciais teóricos, estudos relacionados ao uso da linguagem Python de programação para aplicações em Deep Learning, assim como pesquisas sobre as ferramentas do Machine Learning e dos fundamentos do processamento de imagens através de técnicas que têm como objetivo a extração da informação nela contida (Gonzalez e Woods, 2008), em busca na melhoria de informação visual para interpretação humana ou para aplicações em âmbito específico (Pacheco, 2013). Em seguida, já com o entendimento de todo esse aparato teórico, foi realizada a busca dos modelos pré-treinados e o estudo profundo de cada um, desde os parâmetros para o funcionamento dos modelos até as métricas de comparação. Posteriormente, foi fundamental aprender os pontos semelhantes e distintos de cada modelo, como por exemplo, parâmetros de funcionamento, quantidade de camadas, tudo isso com o intuito de comparar os resultados obtidos da maneira mais eficaz possível.

2. TRABALHOS RELACIONADOS

Moura e Meneses (2021) aplicaram a rede U-Net na segmentação de imagens de tomografia computadorizada do coração e compararam o seu desempenho com a métrica Coeficiente de Similaridade de Dice, que mede a superposição entre as imagens segmentadas pelo algoritmo e as imagens de referência segmentadas manualmente. Os autores chegaram a conclusão, a partir de testes estatísticos, que não houve diferença significativa entre os modelos de acordo com a variação de alguns hiperparâmetros tais como *feature maps* e otimizadores e, portanto, todos os resultados foram satisfatórios em comparação a outros resultados obtidos em competições de segmentação.

Paiva et al. (2022) utilizaram a microscopia Síncrotron, empregando a rede U-Net em imagens contendo amostras do cristalino da rã *Thoropa miliaris* com contraste para avaliar métodos de segmentação de imagens automáticas e semiautomáticas. As imagens contidas na base de dados apresentavam contraste de fase baseada em propagação (XSPCT). As avaliações foram realizadas a partir da quantificação de volume e também do Coeficiente de Similaridade de Dados (DSC). Os métodos utilizados para a forma semiautomática foram Interpolação e Bacia Hidrográfica, já para a segmentação automática, o método escolhido foi através do uso da arquitetura U-Net. Ao final do trabalho, os autores compararam os 3 métodos utilizados e obtiveram um DSC médio global de 97,02% para o método da Interpolação, 95,41% para Bacia Hidrográfica e 89,29% utilizando a arquitetura U-Net e apesar do método 3 ter tido o menor valor médio de DSC, ele foi o mais eficiente em relação a tempo de treinamento, pois os métodos 1 e 2 necessitaram 01:30 horas para o treinamento enquanto o método 3 levou somente alguns segundos, desta forma, todos os resultados foram satisfatórios, porém a arquitetura U-Net teve seu desempenho comprometido por conta irregularidade nas bordas das imagens do cristalino da rã.

Almeida (2021) usou o Transfer Learning e Redes Neurais Convolucionais para a classificação de imagens e reconhecimento de objetos no âmbito da perícia criminal. Dentre esses objetos, encontravam-se imagens de documentos, armas, carros, pessoas, entre outros. Os autores concluíram que o modelo criado a partir das Redes Neurais Convolucionais obteve um valor de acurácia de 98% na classificação de imagens que continham documentos e não documentos. E por meio dos resultados com a integração do software Autopsy, constatou-se o

potencial prático do projeto para a realização de pesquisas envolvendo classificações de imagens e detecções de objetos no âmbito da perícia criminal.

3. REFERENCIAL TEÓRICO

Nesta seção apresentaremos os principais conceitos que compõem este trabalho.

3.1. Inteligência Artificial

Para Russell e Norvig (2010), “O campo da IA busca o entendimento da inteligência e a construção de entidades inteligentes. Para os autores, há duas idéias fundamentais sobre inteligência: a capacidade de aprendizagem e a manifestação de ‘comportamento inteligente’”. Nessa direção, os autores descrevem isso a partir de quatro categorias de definições para a inteligência artificial: sistemas que agem como seres humanos, sistemas que pensam como seres humanos, sistemas que pensam racionalmente e sistemas que agem racionalmente. Os sistemas que agem como seres humanos são caracterizados por apresentarem comportamento similar ao dos seres humanos. Nesse caso a máquina deve portar algumas capacidades específicas para manifestar tal comportamento humano, tais como: processamento de linguagem natural; representação de conhecimento; argumentação automatizada, e o aprendizado de máquina, que permite que essas máquinas possam se adaptar a novas circunstâncias e superar o conhecimento atual (Russell; Norvig, 2020).

3.2. Machine Learning

O Aprendizado de máquina é um campo da ciência que apresenta a evolução dos sistemas de reconhecimento de padrões, permitindo aos computadores desenvolver o aprendizado a partir dos erros e fazer previsões (Koenigkam, 2019).

Dessa maneira, o aprendizado de Máquina é uma área da Inteligência Artificial que tem como objetivo o desenvolvimento de sistemas capazes de desempenhar o aprendizado a partir de dados. Através da investigação de problemas anteriores, a fim de serem capazes de realizar a tomada de decisões (Monard; Baranauskas, 2003).

3.3. Redes Neurais Convolucionais

As Redes Neurais Convolucionais (RNC) ou Convolutional Neural Networks (CNN) foram desenvolvidas para trabalhar com entradas no formato de grid, imagens bidimensionais. Nesse tipo de entrada são verificadas as dependências espaciais, em que regiões adjacentes frequentemente possuem cores similares em seus pixels. Apesar de sua crescente popularidade por trabalhar com arquivos de imagem, as CNN também são muito empregadas em dados espaciais, temporais e espaço-temporais (Almeida, 2020).

3.4. Transfer Learning

Transfer learning pode ser definido como uma técnica em que um modelo já treinado que foi usado para resolver um problema específico é utilizado novamente para a solução de um novo problema relacionado ao primeiro. Por exemplo, no reconhecimento de imagens, geralmente tem-se as primeiras camadas de uma rede responsáveis por detectar características genéricas, ao passo que as últimas camadas serão capazes de detectar os traços mais específicos (Almeida, 2020).

3.5. ResNet50

ResNet50 é um modelo muito usado para a classificação de imagens em categorias. Ele possui mais de 23 milhões de parâmetros a serem treinados. É uma rede neural artificial de renome. Ela se monta a partir de construções obtidas e baseadas nas células da pirâmide do córtex cerebral. É uma rede neural profunda possuindo 50 camadas. Portanto, detém uma ampla variedade de recursos de vários objetos já apreendida e consiste em uma convolução e um bloco de identidade para cada estágio com três camadas de convolução em cada bloco (Bhuma, 2022).

3.6. InceptionV3

InceptionV3 é um modelo convolucional que contém 48 camadas de profundidade. Esse modelo é um dos mais famosos e utilizados no ramo de transferência de aprendizado. É uma rede neural convolucional que busca auxiliar na análise de imagens e na detecção de objetos, sendo desenvolvida inicialmente como um módulo para o GoogLeNet. É a terceira edição da Inception Convolutional Neural Network do Google. Possui uma arquitetura onde seus neurônios são organizados em camadas, onde cada camada executa diferentes transformações nos dados de entrada, e ela é formada por mini-modelos de redes (Ferreira, 2018).

4. MATERIAIS E MÉTODOS

A Figura 1 mostra as etapas metodológicas do projeto.

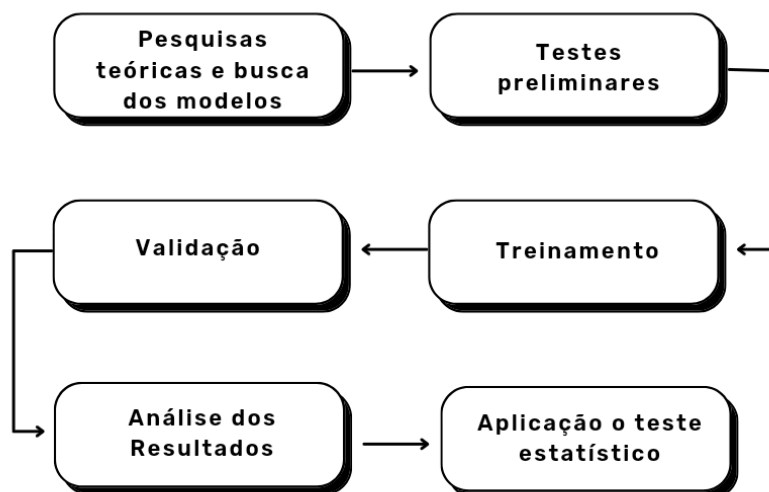


Figura 1: Fluxograma da realização do projeto

As ferramentas utilizadas para implementação da rede neural foram Python na versão 3.9.12, a ferramenta de ciência de dados Anaconda 3, versão 23.1.0. e as bibliotecas foram Keras com TensorFlow na versão 2.8, Numpy para as operações matemáticas, a biblioteca PIL (Python Imaging Library) que é voltada para a manipulação de imagens e Matplotlib para a plotagem gráfica das imagens e do desempenho dos modelos. Todos os treinamentos foram feitos com 20 épocas e salvos em arquivo HDF5. Logo após, foram feitas comparações

estatísticas e a partir disso houve a aplicação do teste não paramétrico de Kruskal-Wallis. Ao final, com todas as etapas concluídas, obteve-se as tabelas comparativas, os boxplots e as métricas de comparação estatística. As implementações foram baseadas no código disponível na página

4.1. Dataset

O dataset Flowers utilizado nas implementações foi baixado por meio do web site ImageNet (www.image-net.org) e contém 3.670 imagens divididas em 5 classes distintas, que são: Roses, Sunflowers, Dandelions, Tulips e Daisy. Todas as imagens possuíam padrões distintos e consistentes.



Figura 2: Imagens presentes no Dataset Flowers

4.2. Equipamento

O equipamento usado para o treinamento e predição foi o GPU NVIDIA GeForce RTX 2080 Ti, que possui memória da GPU de 0.7/27.0 GB e CPU com placa Intel(R) Core(TM) i5-7400 de 3.00GHz e 32.0 GB de memória RAM. O Sistema Operacional utilizado foi Windows 10 Home, versão: 22H2, juntamente com o pacote de dados Anaconda 3, na versão 23.1.0.

4.3. Métricas comparativas

A métrica comparativa usada para os dois modelos foi a acurácia, essa que é uma medida amplamente utilizada na classificação e se trata das medidas de acerto pelas medidas totais, que é dada por:

$$\text{Acurácia} = \frac{\text{Previsões Corretas}}{\text{Total de Previsões}}$$

Também foram avaliados os valores de precisão e perda das 20 épocas de cada treinamento, média, mediana, desvio padrão, valor mínimo e valor máximo retirados da acurácia de todos os 10 treinamentos.

A precisão é o grau de variação de resultados de uma medição e pode ser expressa como desvio padrão relativo (DPR) ou coeficiente de variação (CV%), segundo a fórmula:

$$DPR = RSD = CV\% = \frac{S}{\text{média} \times 100}$$

Em que, S é o desvio padrão e média, a concentração média determinada.

4.4. Teste estatístico

O teste estatístico de Kruskal-Wallis foi aplicado aos resultados da validação (dados da Tabela 1), para atestar se havia diferença estatisticamente significativa ou não. O teste de Kruskal-Wallis é um método não paramétrico utilizado para comparar três ou mais populações. Ele é usado para testar a hipótese nula de que todas as populações possuem funções de distribuição iguais contra a hipótese alternativa de que ao menos duas das populações possuem funções de distribuição diferentes. Se o valor-p $\leq 0,05$, então a hipótese nula pode ser rejeitada (Almeida, 2022).

5. RESULTADOS E DISCUSSÃO

Os resultados obtidos ao fim do projeto com os dois modelos pré-treinados ResNet50 e InceptionV3 se encontram nas Tabelas 1 e 2, respectivamente, assim como as execuções e valores de acurácia demonstrados graficamente na Figura 3. Na Tabela 1 estão os valores de 10 execuções de cada modelo, e na Tabela 2 estão os valores de média, mediana, desvio padrão, valor máximo e valor mínimo com 20 épocas cada que foram feitas no treinamento e validação.

Tabela 1: Valores das execuções para os experimentos realizados

Execuções	ResNet50	InceptionV3
1	0.8828	0.8120
2	0.8910	0.8488
3	0.8815	0.8569
4	0.8842	0.8556
5	0.8815	0.8065
6	0.8883	0.8011
7	0.8842	0.8569
8	0.8896	0.8134
9	0.8869	0.8215
10	0.8869	0.8801

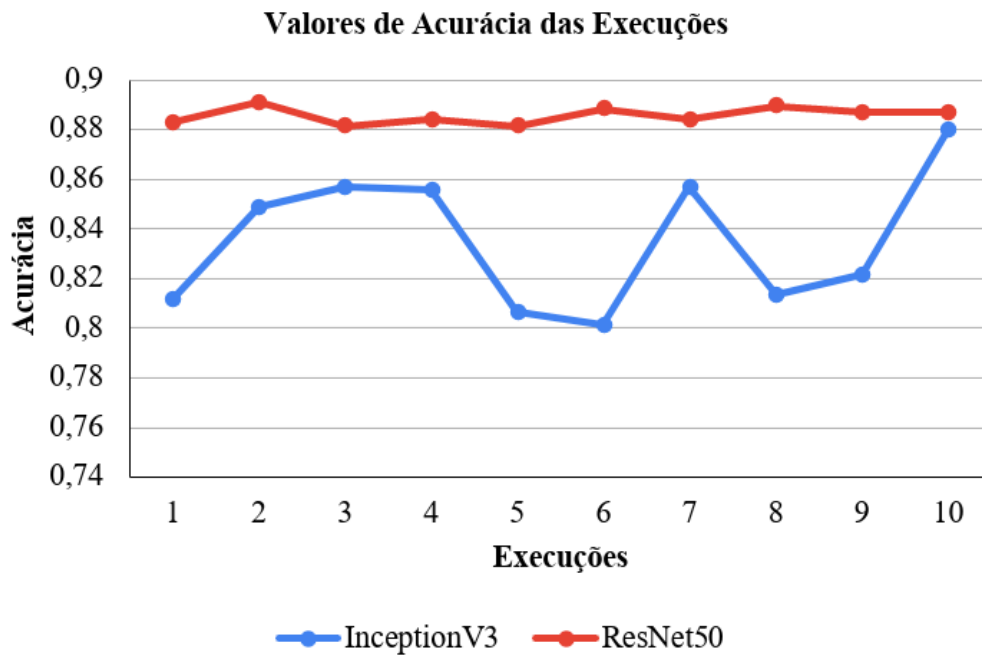


Figura 3: Gráfico execuções versus acurácia

Tabela 2: Resultados estatísticos da Validação

	ResNet50	InceptionV 3
Média	0.8856	0.8363
Mediana	0.8849	0.8038
Desvio Padrão	0.0031	0.0259
Valor Máximo	0.8910	0.8801
Valor Mínimo	0.8815	0.8011

Com os valores dos resultados contidos na tabela, foi realizado o teste estatístico de Kruskal-Wallis para verificar a diferença estatística dos modelos ResNet50 e InceptionV3 a partir dos 10 valores de acurácia obtidos. O resultado desse teste ($H = 14.33$ e $p\text{-valor} \approx 0.0002$) mostrou que houve uma diferença estatisticamente significativa.

Na Figura 4, os boxplots apresentam graficamente a distribuição dos valores de acurácia por modelo, mostrando que todos os valores da rede Resnet50 (em vermelho) concentram-se acima de 0,88 indicando que o modelo pré-treinado ResNet50 tem o melhor desempenho, confirmado pelo teste estatístico de Kruskal-Wallis.

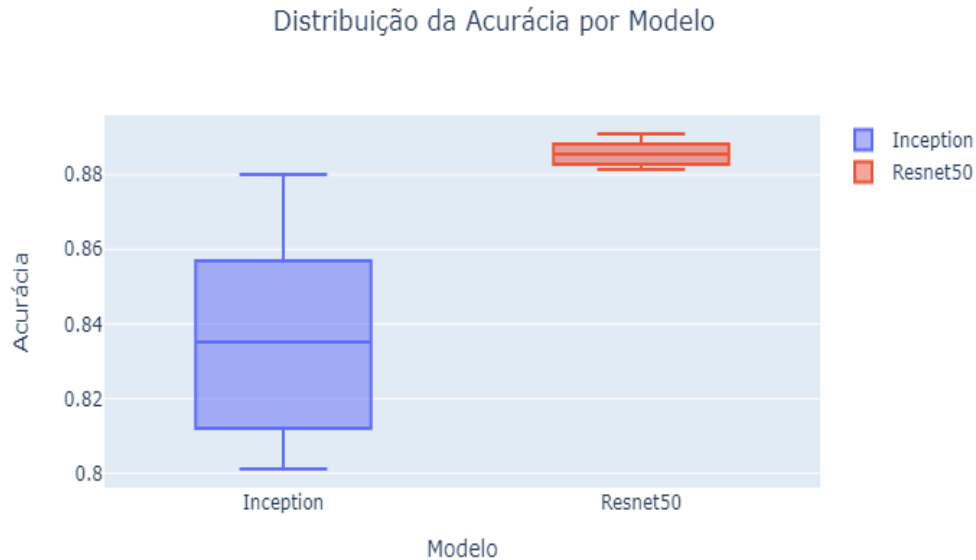


Figura 4: Boxplots de distribuição de acurácia para cada modelo

6. CONCLUSÃO

Neste trabalho, os modelos de redes neurais convolucionais pré-treinados ResNet50 e InceptionV3 foram usados para classificação de imagens a fim de avaliar a acurácia, com a comparação de desempenho utilizando-se uma base de dados que possui 3.670 imagens, que foram subdivididas para treinamento e validação. A partir disso, foi realizada a comparação estatística entre eles com o teste estatístico de Kruskal-Wallis. As predições realizadas pelos modelos apresentaram resultados satisfatórios em relação às métricas aplicadas aos valores obtidos.

Desta forma, foi comprovado o alto desempenho de ambos os modelos na classificação de imagens, sendo o ResNet50 superior, de acordo com o teste estatístico realizado. Além disto, obteve-se um menor desvio nos valores de acurácia da ResNet50, todos acima de 0,88, enquanto no modelo InceptionV3 notam-se resultados menores e uma variação maior.

Este trabalho avaliou o desempenho dos modelos pré-treinados ResNet50 e InceptionV3 para classificação de imagens, com o intuito de auxiliar na execução de futuros projetos com uso do Transfer Learning, a fim de ampliar o conhecimento e as aplicações práticas na área de Machine Learning aplicado ao Processamento Digital de Imagens.

Reconhecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC) pelo apoio financeiro.

REFERÊNCIAS

Almeida, D. C. (2022). Utilização dos testes estatísticos Kruskal-Wallis e Mann-Whitney para avaliação de sistemas de solos reforçados com geotêxteis. Acesso em: <https://doi.org/10.1590/1517-7076-RMAT-2021-45351>

Almeida, J. R. (2021). Transfer learning e convolutional neural networks para a classificação de imagens e reconhecimento de objetos no âmbito da perícia criminal.

Acesso em: <https://repositorio.unb.br/handle/10482/40286>

Bhuma, C. M. (2022). Classificação de textura de vírus de imagens TEM usando fusão de momentos Chebyshev e recursos Resnet50.

Acesso em: <https://doi.org/10.1590/1678-4324-2022210636>

Cuttle, J. A. T. (2018). Utilização de redes convolucionais profundas para estimativa de ângulos de pose de fâcies obtidas através do kinect.

Acesso em: <https://repositorio.ufsc.br/handle/123456789/192158>

Ferreira, J. M. da S. (2018). Classificação dos estágios do sono utilizando análise espectral e redes neurais convolutivas.

Acesso em:

<https://1library.org/document/y8gjp4g5-manayra-ferreira-classifica%C3%A7%C3%A3o-est%C3%A1gios-utilizando-an%C3%A1lise-espectral-convolutivas.html#fulltext-content>

Fiorin, D. V. (2011). Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares.

Acesso em: <https://doi.org/10.1590/S1806-11172011000100009>

Husain, M. A. S. Al (2022). Detecção precoce de câncer de mama com base térmica usando o início V3, Inception V4 e Inception modificado MV4.

Acesso em: <https://doi.org/10.1007/s00521-021-06372-1>

Indolia, S. et al. (2018). Compreensão conceitual da rede neural convolucional - uma abordagem de aprendizado profundo.

Acesso em: <https://doi.org/10.1016/j.procs.2018.05.069>

Koenigkam-Santos M., Ferreira-Júnior J. R., Wada D. T., Tenório A. P. M., Nogueira-Barbosa M. H., Azevedo-Marques P. M. A. (2019). Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão.

Acesso em: <http://dx.doi.org/10.1590/0100-3984.2019.0049>

Monard, M. C.; Baranauskas, J. A. Conceitos sobre aprendizado de máquina. Sistemas inteligentes-Fundamentos e aplicações, v. 1, n. 1, p. 32, 2003.

Moura, M. e Meneses, A. A. M. (2021) “Avaliação dos parâmetros da rede neural convolucional Unet para segmentação de imagens de TC do coração”. Disponível nos anais do XXIV Encontro Nacional de Modelagem Computacional (ENMC).

Pacheco, E. F. (2013). Processamento de estruturas tridimensionais de Medicina Nuclear na modalidade PET.

Acesso em: <http://dx.doi.org/10.4322/rbeb.2013.005>

Paiva et al. (2022). Avaliação de desempenho de métodos de segmentação para avaliação do cristalino da rã *Thoropa miliaris* a partir de imagens de micro-TC de contraste de fase baseadas em síncrotron.

Acesso em: <https://doi.org/10.1016/j.ejmp.2021.12.013>

Pereira, Y., Meneses, A., Silva, D. and Barroso, R. (2022). Latin American Journal of Computing. Segmentação de imagens de tomografia computadorizada pulmonar usando U-net.

Russell, S. J.; Norvig, P. Artificial intelligence: a modern approach. 3 Ed. Upper Saddle River: Pearson Education Limited. 2010.

Russell, S.; Norvig, P.. Artificial intelligence: a modern approach. 4 Ed. Pearson Education Limited, 2020.

COMPARISON OF CONVOLUTIONAL NEURAL NETWORK MODELS WITH TRANSFER LEARNING FOR IMAGE CLASSIFICATION

The present work deals with the development and application of pre-trained models for image recognition from different datasets, where Convolutional Neural Network (CNN) models were applied from Transfer Learning (TL). Transfer Learning). Thus, the perspective of using an already trained model as a starting point for solving another related problem arose. In view of this, the main objective of the project focused on the application of pre-trained models to large data sets and the comparison between the two models chosen for the project, which are: ResNet50 and InceptionV3. The research evolved into the study and comparison between two pre-trained models, ResNet50 and InceptionV3. As a result, the pre-trained ResNet50 model obtained a better result than the InceptionV3 model (with average accuracies of 0.8856 and 0.8363, respectively), applied the Kruskal-Wallis non-parametric test, it was attested that there is a statistically significant difference between the results of the models.