

COMPARAÇÃO ENTRE MODELOS RESNET NA CLASSIFICAÇÃO DE DÍGITOS MANUSCRITOS

Renan Marcili Lemons¹; Rafael Duarte dos Santos²; Ruhan Avila da Conceição³

¹Universidade Federal de Pelotas – rmlemons@inf.ufpel.edu.br

²Universidade Federal de Pelotas – rrdsantos@inf.ufpel.edu.br

³Instituto Federal Sul-rio-grandense – ruhanconceicao@ifsul.edu.br

1. INTRODUÇÃO

A inteligência artificial tem se popularizado cada vez mais nas últimas décadas, sendo cada vez mais utilizada nos mais diversos setores, desde assistentes pessoais, a indústria de transporte e até na área da saúde (OUR WORLD IN DATA, 2023). Um dos grandes motivos responsáveis por essa evolução rápida é o aprendizado profundo (*deep learning*), sendo uma subárea do aprendizado de máquina, que trabalha a ideia de algoritmos que possibilitem ao computador aprender diretamente a partir dos dados, sem a necessidade de uma programação específica para cada uma das tarefas.

De acordo com Raschka (2017), existem três principais tipos de aprendizado de máquina:

- Aprendizado supervisionado: o modelo é treinado usando dados rotulados, ou seja, tanto as entradas quanto as saídas corretas são fornecidas. O objetivo é aprender uma função que mapeia as entradas e as saídas levando em conta os dados fornecidos durante o treinamento. Geralmente utilizados em tarefas de classificação.
- Aprendizado não supervisionado: onde o modelo é treinado sem os dados rotulados, então, neste caso o objetivo é que o modelo aprenda a identificar padrões ou estruturas, sem necessidade de descobrir uma saída correta.
- Aprendizado por reforço: este tipo de aprendizado envolve um agente que vai aprendendo a tomar decisões ao interagir por meio de tentativa e erro, sendo recompensado ou penalizado por cada ação tomada, reforçando as ações corretas através de uma recompensa, ou atenuando ações incorretas por meio de penalidades. Ele busca sempre maximizar a recompensa acumulada.

Redes neurais são uma classe de algoritmos de aprendizado de máquina que buscam simular o funcionamento do cérebro humano, visando reconhecer padrões complexos nos dados fornecidos. O tamanho das redes neurais podem variar de apenas um neurônio (perceptron) até centenas de camadas, onde surge o termo aprendizado profundo (*deep learning*). Devido a capacidade de aprendizado elevado das redes neurais, somado ao fato do crescimento do poder computacional e da quantidade de dados disponíveis atualmente, o aprendizado profundo tem se tornado a técnica principal para tarefas como o reconhecimento de imagem, processamento de linguagem natural, sendo capaz até mesmo de superar o desempenho humano em algumas tarefas (GOODFELLOW; BENGIO; COURVILLE, 2016).

As redes neurais convolucionais (*Convolutional Neural Networks* - CNNs) são uma classe especial de redes neurais profundas focadas principalmente para

o processamento de dados tipicamente organizados em matrizes, como imagem e vídeo. Este tipo de rede busca extrair características hierárquicas dos dados para permitir a identificação de padrões em imagens. (RUN.AI, 2024).

Dentre os diversos algoritmos de classificação de imagens baseados em CNNs, destacam-se as ResNets, cuja nomenclatura vem de redes residuais, que foram introduzidas no artigo Deep Residual Learning for Image Recognition, que tratam de uma nova forma de treinar redes profundas, sendo mais fácil e eficiente treinar uma rede se ela aprender a ajustar “resíduos” em vez de tentar aprender uma nova função completa do zero (HE et al., 2016). A ResNet possui diversos tamanhos de camadas, variando de 18 até 152, onde o maior número de camadas é indicado para tarefas de classificação mais complexas. Tendo isto em vista, este trabalho visa comparar os modelos *ResNet* 18, *ResNet* 34 e *ResNet* 50 em termos de eficiência de classificação e tempo de execução na classificação de dígitos numéricos sobre o dataset MNIST (LECUN; CORTES; BURGESS, 1998).

2. METODOLOGIA

Para a implementação e execução dos modelos foi escolhida a linguagem de programação Python, devido a popularidade da mesma, o que acaba por fornecer uma grande quantidade de material online disponível sobre a mesma. Para o desenvolvimento do trabalho específico no que tange às redes neurais, a biblioteca escolhida foi a PyTorch, pois ela já possui a implementação de funções e ferramentas para o desenvolvimento do trabalho, facilitando o processo de treinamento dos modelos escolhidos.

A execução dos modelos realizou-se através de ambientes de computação na nuvem. Utilizando o Google Colab, aproveitando o acelerador de hardware GPU-T4 para acelerar o treinamento das redes. Devido ao Google Colab ter um limite de uso, alternativamente, utilizou-se o *Kaggle*, utilizando a configuração de GPU T4x2 no treinamento das redes. É importante salientar que embora o ambiente de execução do Kaggle disponibilize duas GPUs simultaneamente, apenas uma foi utilizada nas tarefas de treino e inferência.

O dataset utilizado no treinamento e nos testes dos modelos foi o *MNIST*, que é um dataset de imagens sobre números escritos à mão, contendo cerca de 70.000 imagens. O objetivo deste trabalho é avaliar a eficácia de três modelos de *ResNet* na classificação destas imagens, considerando também o custo de execução e as diferenças entre os modelos.

Os seguintes hiperparâmetros foram definidos:

- *Batch Size*: é referente ao número de exemplos de treinamento processados antes de atualizar os parâmetros do modelo. Foi utilizado um batch size de 512.
- *Learning Rate*: responsável por definir a velocidade que o modelo ajusta seus parâmetros durante o treinamento. Foi utilizado um learning rate fixo de 0.0001
- *Epochs*: é o número de vezes que o modelo passa por todo conjunto de dados de treinamento. Foi utilizado um número de trinta Epochs em cada treinamento.

O processo de treinamento das redes neurais foi realizado da seguinte maneira: primeiramente, cada uma das *ResNet* foi obtida com os pesos

pré-treinados, alterando-se apenas a última camada totalmente conectada (fully connected - FC). Durante o treinamento, os pesos de todas as camadas convolucionais foram congelados, ou seja, o gradiente descendente foi aplicado apenas na camada de saída FC, sem atualização dos pesos nas demais camadas.

3. RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados os resultados dos treinamentos das arquiteturas *ResNet 18*, *ResNet 34* e *ResNet 50*, sobre o *dataset MNIST*, para a tarefa de classificação de dígitos manuscritos. Os três modelos foram treinados por trinta épocas, com um *learning rate* fixo de 0,0001 e um *batch size* de 512. Os resultados são apresentados na Tabela 1.

Tabela 1 - Resultados obtidos a partir modelos testados

	ResNet18	ResNet34	ResNet50
Loss 1ª Epoch	2,2074	2,0676	1,8783
Loss 30ª Epoch	0,2100	0,2483	0,2490
Acurácia Conjunto de Teste Fino	95,03%	93,53%	92,88%
Acurácia Conjunto de Teste	94,78%	93,50%	93,42%
Tempo de Execução	3736 segundos	4748 segundos	7002 segundos

Como mostra a tabela com os resultados obtidos, o modelo *ResNet 18*, para a classificação sobre o *dataset MNIST* se mostrou mais eficiente, seja no parâmetro de acurácia, quanto no tempo de execução. As possíveis razões para uma rede neural mais simples ter obtido um desempenho melhor comparado a redes com mais camadas, podem ser a simplicidade da tarefa. Como o *dataset MNIST* contém imagens de dígitos manuscritos com baixa resolução (28x28 pixels) e apenas dez classes (de 0 a 9), as características necessárias para diferenciar os números são relativamente simples e podem ser aprendidas com menos camadas de convolução.

Outra possibilidade é o *overfitting*, pois redes mais profundas têm uma quantidade significativamente maior de parâmetros, o que pode levar esses modelos a se ajustar demais aos dados de treinamento, reduzindo a capacidade de generalização no conjunto de testes. Como dito anteriormente o *dataset MNIST* é pequeno a *ResNet 34* e *ResNet 50* podem ter apresentado um *overfitting*, o que justificaria o modelo *ResNet 18* ter obtido um melhor desempenho nos testes.

4. CONCLUSÕES

Os testes realizados para o desenvolvimento deste trabalho mostraram que a *ResNet* 18 apesar de ser um modelo de rede neural mais simples se mostrou mais eficiente em uma tarefa relativamente simples no campo de classificação de imagens, o que mostra que a complexidade da rede não resulta necessariamente em um desempenho melhor. Portanto, a escolha da arquitetura da rede neural deve considerar a complexidade da tarefa que deseja ser realizada, levando em conta o equilíbrio entre o desempenho e a eficiência computacional. O desenvolvimento deste trabalho mostrou-se uma importante tarefa para a aprendizagem no treinamento e desenvolvimento de redes neurais sobre a arquitetura *ResNet*. Para trabalhos futuros, espera-se avaliar o desempenho dessas redes em *datasets* mais complexos, ou também o desempenho das mesmas ao aplicar a quantização nesses modelos, analisando os impactos causados sobre o desempenho e eficiência computacional dos mesmos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep Residual Learning for Image Recognition. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**, Las Vegas, v.770, n.778, p.770-778, 2016.

OUR WORLD IN DATA. **The brief history of artificial intelligence: the world has changed fast—what might be next?** 2023. Online. Disponível em: <https://ourworldindata.org/ai>. Acessado em: 19 set. 2024.

RASCHKA, Sebastian. **Python Machine Learning**. 2. ed. Birmingham: Packt Publishing, 2017. 622 p.

RUN.AI. **Deep Convolutional Neural Networks**. 2023 Online. Disponível em: <https://www.run.ai/guides/deep-learning-for-computer-vision/deep-convolutional-neural-networks>. Acessado em: 22 set. 2024.

LECUN, Y.; CORTES, C.; BURGESS, C. J. C. **The MNIST Database of Handwritten Digits**. 1998. Acessado em 18 set. 2024. Disponível em: <http://yann.lecun.com/exdb/mnist/>