Fundamentos de Redes Neurais Profundas

Palavras-Chave: Aprendizado de Máquina, Redes Neurais, Classificação de imagens

Autores:

Matheus Felipe Cavalcante Cunha, RA 250456 - FEM

Prof. Dr. Romis R. F. Attux (Orientador), DCA - FEEC

INTRODUÇÃO

O aprendizado profundo (*deep learning*) é uma área do aprendizado de máquina que tem ganhado destaque nas últimas décadas, principalmente por sua característica de conseguir lidar com grandes volumes de dados e conseguir encontrar e extrair padrões complexos. As redes neurais são soluções eficazes para diversos problemas como tradução automática, processamento de voz, previsão de séries temporais, e também em análise de imagens, que será o principal objeto de estudo dessa pesquisa.

O projeto teve como objetivo fornecer uma base sólida nos fundamentos de aprendizado de máquina e de redes neurais profundas, abordando tanto conceitos teóricos quanto a aplicação prática. Nele, foram abordados a resolução de problemas de predição de séries temporais, classificação binária com regressão logística, classificação binária com MLP (do inglês *multilayer perceptron*) e reconhecimento de imagens da base de dados MNIST com MLP e CNN (do inglês *convolutional neural network*). Por fim, foi desenvolvida uma CNN para análise de imagens médicas, inspirada na dissertação de Bassi [1], focando na detecção de padrões relevantes em exames de tórax. As abordagens adotadas serão detalhadas ao longo deste resumo.

Os algoritmos desenvolvidos nesse projeto foram implementados utilizando a linguagem de programação Python, utilizando diversas bibliotecas, sendo as principais Pandas, Matplotlib, Scikit-Learn, TensorFlow e Keras.

METODOLOGIA

No início do projeto, foi realizado um estudo dirigido com base no material do curso de pós-graduação IA048 – Aprendizado de Máquina, ministrado pelo orientador e pelo Prof. Levy Boccato [2]. Durante o estudo, foi apresentado ao aluno os seguintes conteúdos: teoria da probabilidade, teoria de informação, regressão linear, classificação linear, KNN, redes neurais MLP e CNN.

Além disso, os problemas resolvidos foram extraídos do mesmo material do curso [2], com exceção do problema final de classificação de imagens médicas, cuja base de dados foi extraída do Kaggle [3].

Tanto o estudo quanto a resolução dos problemas foram acompanhados de reuniões periódicas com o orientador para discussões e esclarecimento de dúvidas.

RESULTADOS E DISCUSSÃO

Classificação binária com MLP:

Foi apresentado ao aluno um conjunto de dados com informações clinicas de mulheres com idade superior a 21 anos de origem indígena (Pima) na região de Phoenix, Arizona, EUA. Cada amostra contém 8 atributos. A última coluna é binária, sendo '1' caso a mulher possua diabetes e '0' caso não possua diabetes.

Nesse exercício, percebeu-se que havia um desbalanceamento na classe a ser predita, tendo 500 mulheres que não possuíam diabetes e 268 mulheres que possuíam diabetes. Tal problema foi resolvido incluindo esse atributo no argumento *stratify* da função *train_test_split*.

Novamente, foram utilizadas a linguagem de programação Python e as bibliotecas Pandas, Matplotlib, Scikit-Learn, Seaborn, além das bibliotecas Keras e TensorFlow. Várias redes foram treinadas a fim de encontrar os melhores hiperparâmetros para a MLP. A seguir, na Figura 1, estão apresentadas métricas da rede com melhor acurácia no conjunto de validação.

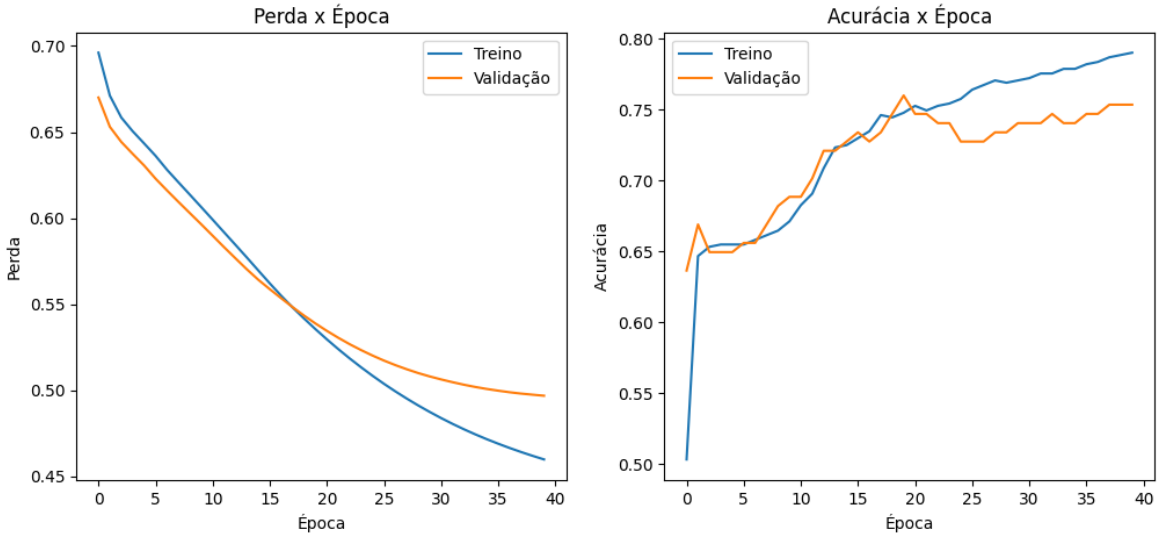

Figura 1: Gráficos mostrando as métricas perda e acurácia ao longo das épocas da MLP.

Reconhecimento de imagens com MLP e CNN:

Nesse exercício, foi explorada a base de dados MNIST, que contém 160.000 imagens de dígitos numéricos manuscritos com dimensão 28x28, sendo 60.000 delas para treinamento e 100.000 para testes, esta é uma base de dados clássica para estudar sobre classificação multiclasse.

Como ferramentas, foram usadas a linguagem de programação Python e as bibliotecas Numpy, Matplotlib, Tensorflow, Keras e Scikit-Learn. Foram treinados algoritmos de MLP e CNN, que atingiram, respectivamente, 97,67% e 98,87% de acurácia. Abaixo, as Figuras 2 e 3 mostram exemplos de 4 padrões classificados corretamente e 4 padrões classificados erroneamente nas redes treinadas.

Figura 2: Exemplos de classificação com MLP

Figura 3: Exemplos de classificação com CNN

Reconhecimento de imagens médicas com CNN:

A base de dados utilizada foi a NIH Chest X-ray [3], em que estão presentes mais de 100 mil imagens de raios-X da região torácica, rotuladas com o respectivo diagnóstico do paciente, presente em um arquivo .csv auxiliar. Primeiramente, foi realizada uma análise exploratória dos dados, a fim de entender mais sobre a base de dados, descobrindo por exemplo a quantidade de ocorrência de cada doença e também a distribuição amostral de pessoas por idade e gênero, o que pode ser observado nas Figuras 4 e 5.

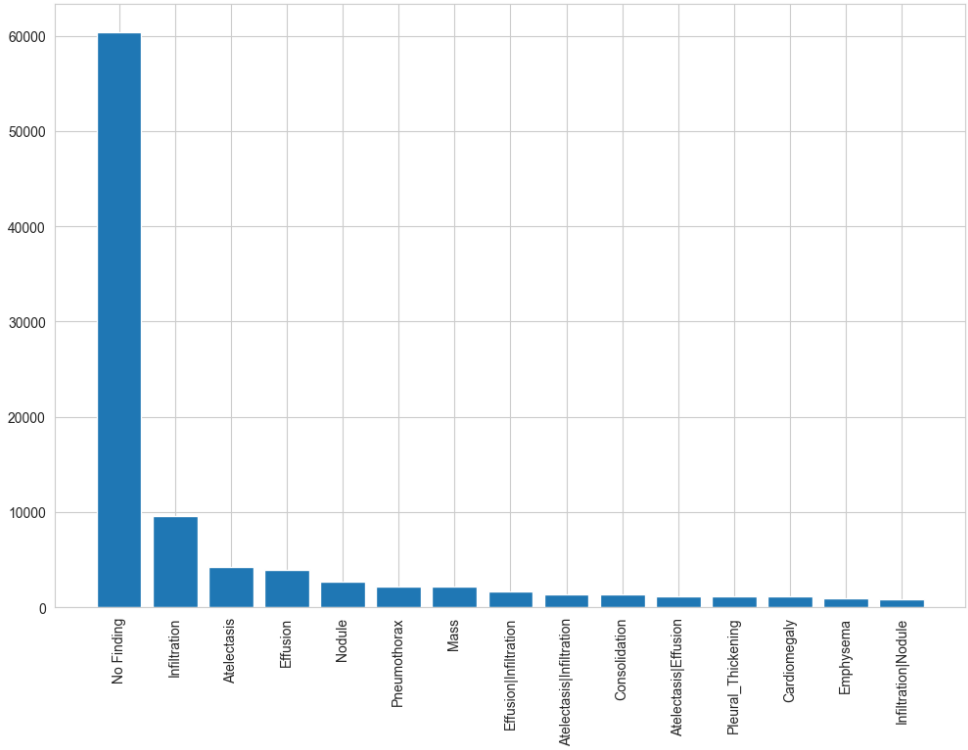

Figura 4: Quantidade de diagnósticos por doença

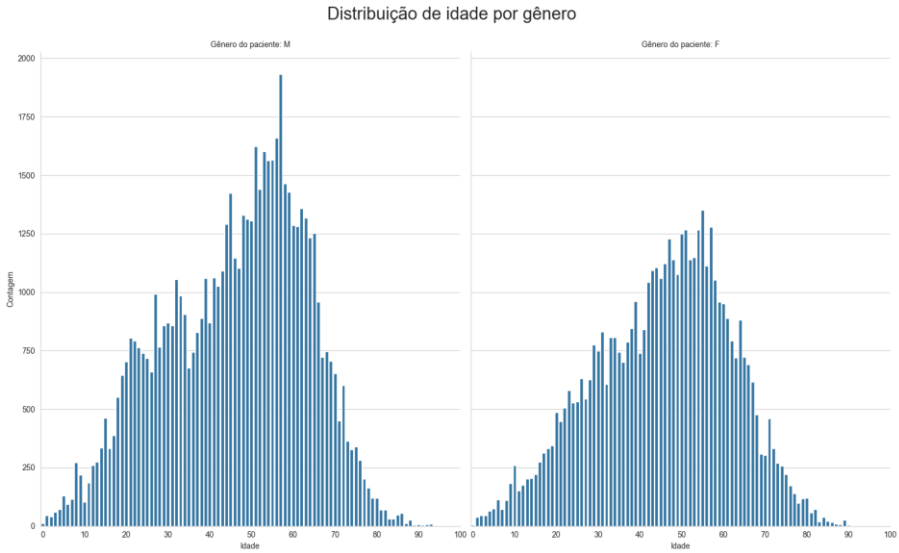

Figura 5: Distribuição das amostras por idade e por gênero

Depois da análise dos dados, foi modelada uma rede neural convolucional (CNN) simples, baseada na MobileNet, sem pesos pré-treinados, adaptada para classificação *multilabel* com ativação sigmoide na saída. O modelo foi compilado com o otimizador Adam, função de perda *binary crossentropy* e as métricas *binary accuracy* e *mean absolute error*.

Primeiramente, realizou-se um treino rápido, com 5 épocas e 100 passos por época, e foram obtidas as curvas ROC para as classes presentes na Figura 6, assim como as métricas de treino *binary accuracy* de 0,8735 e *mean absolute error* de 0,1954. Em seguida, realizou-se o treinamento de forma mais robusta, com 15 épocas e 150 passos por época, e foram obtidas as métricas de treino de binary accuracy de 0,8771 e mean absolute error de 0,1910, bem como as curvas ROC da Figura 7.

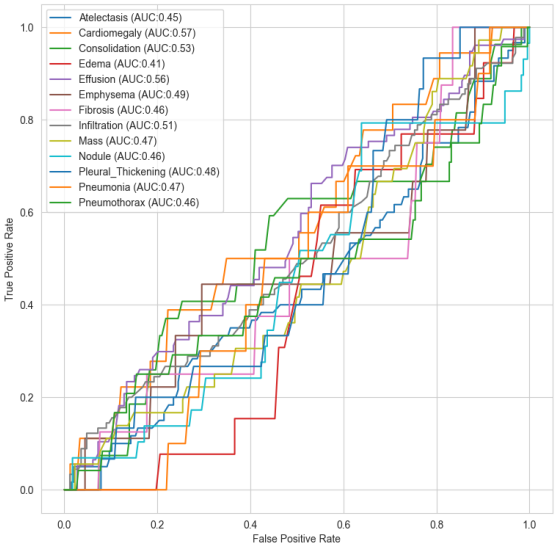

Figura 6: Curvas ROC para a CNN simples

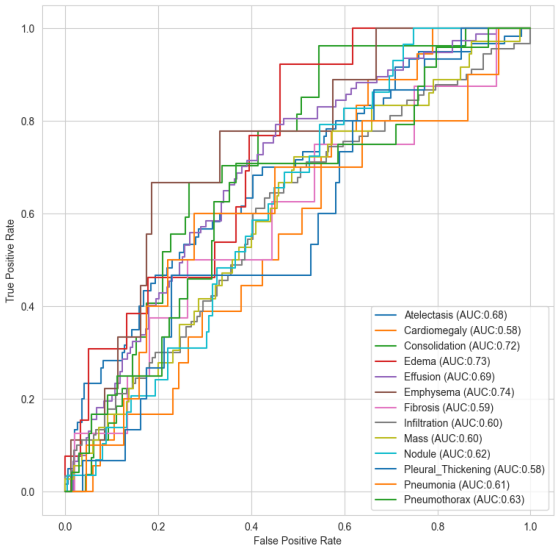

Figura 7: Curvas ROC para a CNN robusta

Na Figura 8, estão presentes algumas imagens e seus respectivos diagnósticos reais e a probabilidade prevista pelo modelo mais robusto.

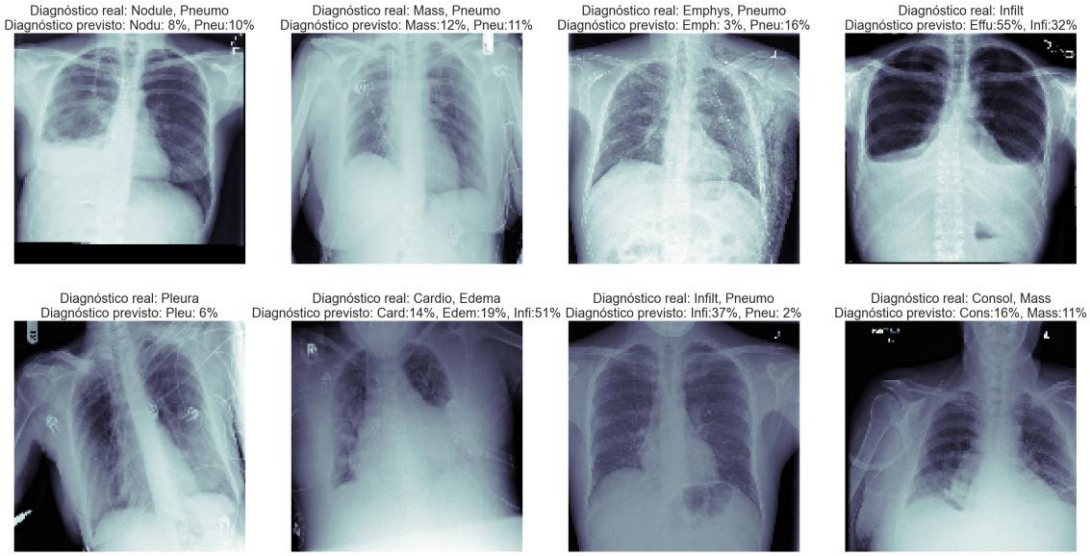

Figura 8: Exemplo de diagnósticos reais e probabilidades calculadas pela rede neural

CONCLUSÕES

O projeto permitiu a exploração dos fundamentos teóricos e práticos do aprendizado de máquina e das redes neurais profundas, mostrando a importância e eficácia dessas ferramentas em resolução de problemas complexos. O estudo destacou a importância da escolha do modelo para cada tipo de problema, uma vez que diferentes modelos apresentam comportamentos distintos conforme a aplicação.

No contexto da aplicação de redes neurais convolucionais em visão computacional, buscou-se detectar padrões em imagens médicas por meio de aprendizado supervisionado. Os resultados obtidos demonstraram a efetividade da abordagem, reforçando a relevância das redes neurais como ferramenta de apoio em tarefas complexas como a detecção automatizada de doenças em exames de imagem, ao mesmo tempo em que ressaltaram a necessidade de cautela na interpretação dos resultados, uma vez que os modelos não devem ser considerados infalíveis.

BIBLIOGRAFIA

[1] P. R. A. S. Bassi, A study of deep neural networks for image recognition in BCIs and COVID-19 detection, 2021.

[2] L. Boccato, R. R. F. Attux, Notas de Aula do Curso IA048 – Aprendizado de Máquina, FEEC/UNICAMP, 2020.

[3] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, R. M. Summers, ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases, IEEE CVPR, pp. 3462–3471, 2017. Disponível em: <https://www.kaggle.com/datasets/nih-chest-xrays/data>. Acesso em: jul. 2025.

[4] I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016.

[5] A. Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd ed., O'Reilly Media, 2019.