



Fundamentos de Redes Neurais Profundas

Palavras-Chave: Redes neurais profundas, aprendizado de máquina, *deep learning*.

Autores:

João Paulo Christofolletti - FEEC

Prof. Dr. Romis Ribeiro de Faissol Attux (orientador/a) - FEEC

INTRODUÇÃO:

Redes neurais são estruturas de processamento da informação inspiradas pelo funcionamento do sistema nervoso humano. Seu estudo teve seu início com o trabalho de McCulloch e Pitts, e elas têm recebido destaque desde então graças a seu excelente desempenho em tarefas como reconhecimento de imagens, reconhecimento de fala e processamento de linguagem natural. Diante disto, o objetivo deste projeto é a realização de um estudo sobre a temática de redes neurais profundas a partir de uma perspectiva de aprendizado de máquina.

METODOLOGIA:

Inicialmente, houve um foco maior na formação básica em aprendizado de máquina. Assim, o projeto se iniciou com um estudo sobre fundamentos da teoria da probabilidade e da teoria da informação, que teve por base os primeiros capítulos das notas de aula do curso de pós-graduação “Aprendizado de Máquina” [1].

Em seguida, ainda utilizando essas notas de aula, passou-se a um estudo sobre as temáticas de regressão e classificação. Em seguida, foi possível adentrar a teoria de redes neurais e de redes neurais profundas, sendo o livro [2] usado como referência de apoio. Ao longo do estudo, foram realizadas reuniões semanais entre aluno e o orientador para discussão e suporte em dúvidas.

Para complementar o estudo, passou-se a uma implementação no âmbito de um problema prático. Escolheu-se um conjunto de dados [3] que aborda a análise de eficiência energética de 12 formas de construção diferentes, as quais diferem em relação a: 1. capacidade relativa; 2. área de superfície; 3. área de parede; 4. área do telhado; 5. altura geral; 6. orientação; 7. área de vidraça e 8. distribuição da área de vidraça. Essas construções foram simuladas no Autodesk Ecotect Analysis, levando a um total de 768 formas de construção. Em suma, o conjunto contém 8 parâmetros de entrada e duas saídas.

Para finalizar o estudo dirigido, foi proposta uma nova implementação de classificação, a qual teve por base um conjunto de dados sintético com duas dimensões de entrada e duas classes. O conjunto tinha 10.000 amostras, e os rótulos foram definidos como +1 e -1.

Com esses dados foi feita, primeiramente, uma regressão logística baseada na entropia cruzada como função custo e uma regressão linear utilizando o critério de quadrados mínimos. Posteriormente, foi criada

uma rede densa do tipo perceptron de múltiplas camadas (MLP) com duas camadas intermediárias. As camadas intermediárias tinham a função logística como função de ativação, enquanto a camada de saída se manteve linear. O método de treinamento desta rede se deu através do algoritmo de gradiente / backpropagation. O MATLAB foi utilizado como ferramenta computacional para a realização destas implementações.

Por fim, realizamos um teste baseado numa aplicação prática de reconhecimento de imagens. Optamos por utilizar o clássico conjunto de dados MNIST, que é composto de 70 mil imagens rotuladas de dígitos escritos à mão [4]. Para a implementação, consideramos importante fazer uso de um framework em Python, e utilizamos a biblioteca TensorFlow juntamente com o Keras [5]. Escolhemos uma rede neural MLP com quatro camadas ocultas, sendo a função de ativação *relu* utilizada para essas camadas e a função *softmax* para a camada de saída. A entropia cruzada foi utilizada como função custo e o método do gradiente como otimizador.

RESULTADOS E DISCUSSÃO:

Optamos enfocar, nesta seção, os resultados do experimento com a base MNIST, por se tratar do problema mais próximo de uma aplicação prática. Utilizando a rede descrita na seção anterior e a abordagem de treinamento baseada no gradiente, obtivemos uma acurácia de 97,8%, compatível com os resultados reportados em [4]. A Fig. 1 ilustra a atuação da rede: apresenta-se uma seleção aleatória de dígitos, com a indicação da classe escolhida pela rede e o grau de confiança gerado pela função softmax.

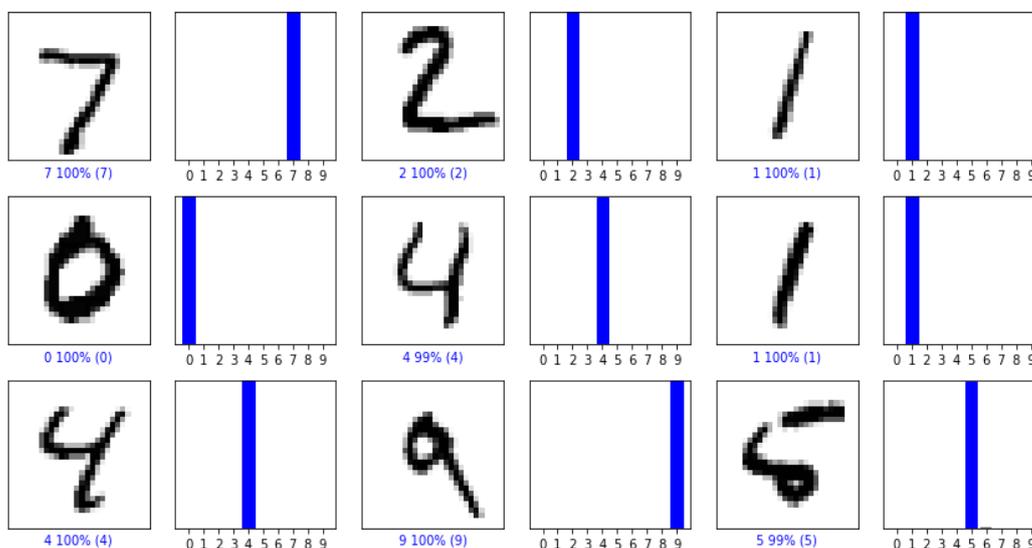


Figura 1 – Dígitos, Classificação da Rede e Grau de Confiança

CONCLUSÕES

Neste trabalho, apresentamos os resultados do projeto, partindo do estudo teórico realizado e chegando à implementação de uma rede neural no âmbito de uma aplicação prática. Foram obtidos resultados condizentes com o esperado, e, ademais, todo o esforço permitiu que o aluno construísse uma formação sólida na área. Com esse conhecimento, realizaremos um segundo ano de iniciação científica no qual buscaremos contribuições originais na detecção de COVID-19 a partir de imagens de raios-X.

BIBLIOGRAFIA

- [1] L. Boccatto, R. Attux, *Notas de Aula do Curso IA048 – Aprendizado de Máquina*, 2020.
- [2] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016.
- [3] D. Dua, C. Graff, *UCI Machine Learning Repository*, University of California - Irvine, [<http://archive.ics.uci.edu/ml/datasets/Energy+efficiency#>], 2019.
- [4] Y. LeCun, C. Cortes, C. J. C. Burges, The MNIST Database of Handwritten Digits, <http://yann.lecun.com/exdb/mnist/>, 2021.
- [5] A. Géron, *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*, Editora Alta Books, 2019.