

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO RECONHECIMENTO DE EMOÇÕES¹

Mayara de Lourdes Schreiber Meotti², Edson Luiz Padoin³

¹ Trabalho realizado com apoio do programa PIBEX/UNIJUI e MCTIC/CNPq projeto Universal 18/2021 sob número 406182/2021-3 e Universal 28/2018 sob número 436339/2018-8.

² Mayara de Lourdes Schreiber Meotti, estudante do 6º semestre do curso de Engenharia de Software.

³ Professor dos cursos de Ciência da Computação e Engenharia de Software.

INTRODUÇÃO

Os avanços tecnológicos possibilitaram que grandes quantidades de dados passem a ser processados e armazenados. No entanto, a organização desses dados representa um desafio complexo para os sistemas computacionais. Nesse contexto, surge a necessidade de criar abordagens inovadoras para que seja possível o acesso bem como a manipulação desse enorme volume de informações. As redes neurais artificiais (RNAs) têm surgido como solução, treinadas para processar esses dados da melhor forma e aplicá-los nas mais variadas funções, desde o reconhecimento de fala até a tradução automática.

Essa busca por maior precisão nos resultados impulsionou o desenvolvimento de algoritmos e cálculos pré-definidos nas RNAs, tornando essencial o uso de processadores cada vez mais poderosos nesses sistemas. Nesse contexto, estratégias de processamento inovadoras têm sido adotadas para atender a essa demanda em constante crescimento (Kunas et al., 2023).

Uma abordagem estratégica tem sido empregar microprocessadores especializados em processamento gráfico, como as GPUs, para a redução significativa do tempo de treinamento das RNAs, amenizando a carga dos processadores principais das máquinas. No entanto, a escolha da arquitetura da RNA e do sistema a ser empregado é de extrema importância para que a estratégia seja bem sucedida.

Este trabalho está assim organizado. Na Seção 2 é destacada a metodologia usada para a elaboração deste. Seguindo, na Seção 3 será discutido os resultados obtidos. Por fim, são abordadas as conclusões.

METODOLOGIA

Para a implementação do código foi utilizado o ambiente de desenvolvimento do Google Colab. Definiu-se a extensão Tensor Flow com GPU do Colab para a realização dos testes do algoritmo desenvolvido. Este que foi implementado na linguagem de programação Python com as bibliotecas Keras e Tensor Flow. Diferentes sentenças foram expostas e analisadas com o software para a realização de testes de análise de emoções. A solução primeiramente faz uma análise de um texto inicial, *review* e, posteriormente, identifica se a sentença possui um caráter **positivo** ou **negativo**.

Para que a estratégia seja bem sucedida, o algoritmo desenvolvido carrega os dados selecionados e os prepara para o treinamento, o que é de extrema importância para remover caracteres especiais que não possuem valor para o significado do texto. Em seguida, esses dados são divididos em duas partes, uma para treinamento e outra para validação, na qual foi utilizado uma proporção de 75/25.


Para esta etapa foi utilizado o *Scikit-learn*, este que é um pacote de aprendizado de máquina de código aberto e abrangente para Python. Ele foi escolhido devido aos vários métodos de aprendizado disponíveis além de suas implementações otimizadas [Hao and Ho 2019].

RESULTADOS E DISCUSSÃO

Cross-Entropy ou entropia cruzada é considerada uma métrica clássica que torna possível calcular o custo associado ao resultado de predição do modelo em questão, por meio do valor de p , a fim de definir a probabilidade da instância pertencer ao grupo 1 na classificação binária. Na Figura 1 são apresentados os resultados obtidos no primeiro teste relacionando *Cross-Entropy* com a quantidade de *Epochs*.

Analisando os resultados apresentados no gráfico da Figura 1, percebe-se que conforme é aumentado o número de *Epochs* treinadas o valor de *Cross-Entropy* diminui. Este resultado, demonstra uma tendência positiva, pois mostra que o modelo está aperfeiçoando a capacidade de treinamento tanto na validação quanto no treinamento. Também é possível analisar que as curvas se encontram próximas umas das outras, porém conforme o número das *Epochs* aumenta, o espaçamento entre elas também. Tal comportamento pode indicar um início de *overfitting*.

Figura 1: Comparativo entre Cross-Entropy e Epochs.




Fonte: Reprodução autoral.

Em um segundo teste foi analisada a relação entre *Epochs* e *Acurácia* conforme ilustrado na Figura 2.

Observando os resultados alcançados, é possível perceber que a curva de treinamento aumenta até alcançar acurácia igual a 0,8 em *Epoch* igual a 10, sendo que após se mantém constante até o final dos testes. Esse aumento de acurácia ocorre ao alimentar a rede com mais exemplos de treinamento, pois o modelo necessita se ajustar aos padrões e tendências presentes nos dados. Também é observado que a curva de validação apresenta comportamento constante com acurácia igual a 0,5, ou seja uma porcentagem de 50% de acertos do modelo, o que indica que a acurácia na validação não melhora conforme o número de *epochs* aumenta.

Figura 2: Comparativo entre Acurácia e Epochs.



Fonte: Reprodução autoral.

CONSIDERAÇÕES FINAIS

Neste artigo, foram apresentados os resultados dos testes desenvolvidos a partir da criação de uma RNA para analisar sentenças da rede social *Twitter*. Almejando traduzir e classificar sentenças com alto índice de acerto foi proposto uma estratégia paralela que faz uso do TensorFlow com GPU que apresentou redução na quantidade de batches e, ainda obteve um índice mediano de acertos na classificação. Embora seja um trabalho inicial adotando uma maneira eficiente de treinamento, é necessário avaliar os custos computacionais para o uso dessa abordagem.

Resultados experimentais usando diferentes bibliotecas e sistemas resultaram em um baixo índice de classificação e tempos. Como futuros trabalhos, pretende-se aprimorar o algoritmo utilizado um *dataset* maior para treinamento almejando aumentar a sua acurácia, bem como implementá-lo em sistemas com TPUs. Também pretende-se desenvolver uma versão para reconhecimento de emoções a partir da fala e da *face ID* para ser utilizada no Robot humanoide NAO V6 disponível no laboratório.

Palavras-chave: Redes neurais. RNA. Emoções. Aprendizado de máquina.

REFERÊNCIAS BIBLIOGRÁFICAS

Hao, J. and Ho, T. K. 2019. **Machine learning made easy: a review of scikit-learn package in python programming language.** Journal of Educational and Behavioral Statistics, 44(3):348–361.

Kunas, C. A., Heck, L., and Padoin, E. L. 2021. **Desempenho de modelos de redes neurais recorrentes para análise de sentimentos.** In XXI Escola Regional de Alto Desempenho (ERAD), pages 1–4, Joinville, SC. SBC.

Kunas, C. A., Padoin, E. L., and Navaux, P. O. A. 2023. **Accelerating deep learning model training on cloud tensor processing unit.** In International Conference on Cloud Computing and Services Science (CLOSER), pages 1–8, Prague, Czech Republic. Springer.

Mahesh, B. 2020. **Machine learning algorithms - a review.** In International Journal of Science and Research (IJSR), pages 1–6, Uttar Pradesh, India. Springer.

Wang, X., Zhao, Y., and Pourpanah, F. 2020. **Recent advances in deep learning.** International Journal of Machine Learning and Cybernetics, 11:747–750.