

Utilização de redes neurais artificiais como estratégia para o reconhecimento de emoções

Mayara de L. S. Meotti¹,
Cristiano A. Künas,² Edson L. Padoin¹

¹Universidade Reg. do Noroeste do Estado do Rio G. do Sul (UNIJUI) - Brasil

²Universidade Federal do Rio Grande do Sul (UFRGS) - Brasil

mayara.meotti@sou.unijui.edu.br, cakunas@inf.ufrgs.br

padoin@unijui.edu.br

Resumo. *A inteligência artificial vem sendo aplicada e ganhando espaço em diferentes áreas. No presente trabalho foi utilizado RNA para analisar opiniões de usuários na rede social twitter. Com o objetivo de melhorar a precisão dos resultados, uma rede neural recorrente do tipo LSTM foi desenvolvida e executada em GPUs com o dataset público. Os resultados experimentais mostraram um índice de até 50% de acertos quanto à classificação das emoções, utilizando a estratégia do TensorFlow com redução da quantidade de epochs.*

1. Introdução

Os avanços tecnológicos possibilitam que os usuários recuperem ou armazenem dados em grandes quantidades, porém a forma de organizá-los é complexa para um sistema computacional. Nesse contexto, cresce a importância da criação de novas maneiras para acessar e manipular esse grande volume de informações. Para isso, redes neurais artificiais (RNA) têm sido utilizadas e treinadas, a fim de processar dados disponíveis e aplicá-los nas mais variadas funções, como no reconhecimento de fala e na tradução automática.

Almejando aumentar a precisão dos resultados, a RNA utiliza algoritmos e cálculos pré-definidos, exigindo processadores cada vez mais potentes para os sistemas. Nesse contexto, a adoção de novas estratégias de processamento têm sido utilizadas para atender tal demanda [Kunas et al. 2023]. Microprocessadores especializados em processamento gráfico, como GPUs, podem ser empregados para reduzir o tempo de treinamento das redes e, consequentemente, amenizar o processador da máquina. No entanto, é necessário escolher cuidadosamente o tipo de RNA escolhida, bem como o sistema a ser utilizado para que a estratégia adotada seja bem sucedida.

Este trabalho está assim organizado. Na Seção 2 são destacados trabalhos relacionados que foram importantes para a elaboração deste. Seguindo, na Seção 3 será abordado definições e conhecimentos acerca das redes neurais. Na sequência são destacadas a metodologia bem como os resultados obtidos. Por fim, são abordadas as conclusões e ideias de futuros trabalhos.

2. Trabalhos Relacionados

Muitas pesquisas têm sido desenvolvidas, bem como avanços publicados sobre Inteligência Artificial (IA) e Machine Learning (ML).

O estudo de Batta Mahesh sobre ML define e aborda a importância do aprendizado de máquina quando não se pode interpretar os dados após visualizados. Também destaca a importância de indústrias aplicarem este tipo de aprendizado em virtude de grandes conjuntos de dados disponíveis [Mahesh 2020].

Künas apresenta um estudo sobre a utilização de RNA aplicados no Reconhecimento de Sentimentos em Textos. Utilizando uma base de dados acerca de *feedbacks* para treinamento da rede neural, a solução proposta consegue resultados com precisão de acertos de entre 87% e 89% no reconhecimento de sentimentos em textos [Kunas et al. 2021]

Neste trabalho, foi utilizada uma abordagem similar ao desenvolvido por Kunas. O nosso trabalho propõe o desenvolvimento de uma Rede Neural Artificial paralela com o objetivo de analisar sentenças por meio de uma RNN do tipo Long Short-Term Memory (LSTM) modificada. Para o treinamento e a análise de sentimentos foi utilizado um *dataset* composto por centenas de *reviews* expostos na rede social *twitter* referentes a opiniões dos usuários acerca de variados gêneros de filmes. A partir desta etapa, foi realizada a classificação das informações e o problema pode ser considerado do tipo classificatório binário.

3. Rede Neural Recorrente (RNN)

RNN é uma das categorias de RNA onde as conexões entre os seus nós podem criar um ciclo. Desta forma a saída de alguns nós pode afetar a entrada dos nós subsequentes aos mesmos nós. Esta organização permite que seja analisado o comportamento dinâmico de forma temporal[Wang et al. 2020].

Por outro lado, o surgimento das redes sociais favoreceu a difusão de opiniões de usuários acerca de assuntos compartilhados no meio, com isso se cria a necessidade de usar a tradução de máquina para interpretá-las corretamente. Nesse contexto, o presente trabalho pretende desenvolver uma RNA para analisar sentenças da rede social *twitter*.

Para o treinamento e a análise de sentimentos foi desenvolvido um protótipo em duas etapas. A fim de alcançar um maior índice de acurácia possível, inicialmente, foi selecionado um conjunto de dados positivo e negativo e utilizado no treinamento. Em seguida, foi realizado o treinamento utilizando a RNR do tipo LSTM desenvolvida. Este modelo foi utilizado devido ao fato da mesma possuir uma memória interna que possibilita o armazenamento das classificações anteriores por um determinado período de tempo. Por fim, o paralelismo da RNA pode vir a ser utilizado reconhecendo sentimentos e analisando-os nos testes.

4. 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 divisão 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].

5. Resultados

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 pertencem ao grupo 1 na classificação binária. Na Figura 1 são apresentados os resultados obtidos no primeiro teste relacionando *Cross-Entropy* e a quantidade de *Epochs*.

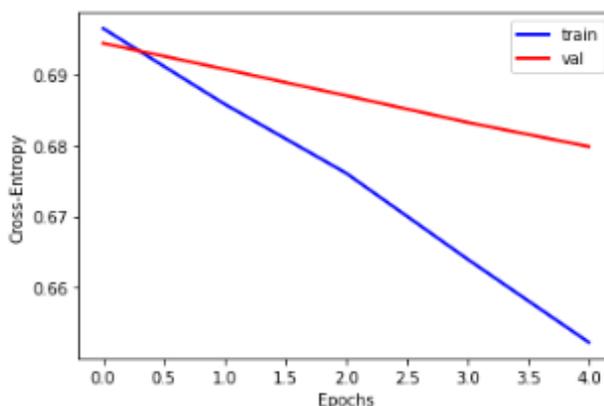


Figura 1. Comparativo entre Cross-Entropy e Epochs

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. Também pode ser observado que tanto a curva de validação quanto a curva de treinamento diminui inversamente proporcional às *Epochs*.

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

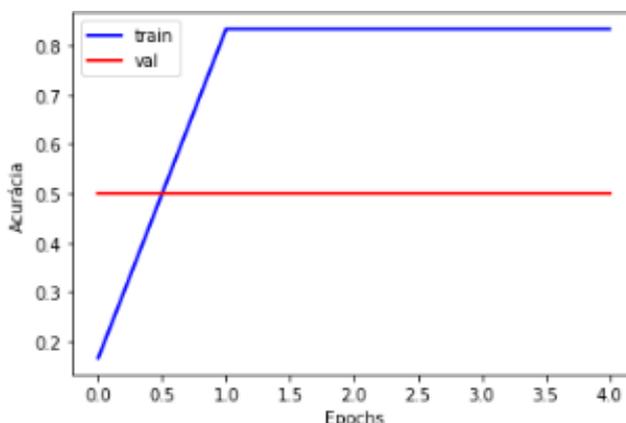


Figura 2. Comparativo entre Acurácia e Epochs

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.

6. Considerações Finais e Trabalhos Futuros

Neste artigo, foram apresentados os resultados dos testes desenvolvidos a partir da criação de 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.

7. Agradecimentos

Este trabalho vem sendo desenvolvido 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. Os autores agradecem ao E+I por disponibilizar recursos para o desenvolvimento da pesquisa e da execução dos testes deste artigo.

Referências

- 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.