



DESENVOLVIMENTO DE UM SISTEMA DE ORDENAÇÃO DE DADOS NUMÉRICOS UTILIZANDO REDES NEURAIS E COMPARAÇÃO COM ALGORITMOS TRADICIONAIS

SILVA, Lorrana Barbosa¹; SOTOMAYOR, Nilo Mauricio²

RESUMO

O presente trabalho explora o campo da Inteligência Artificial (IA), com foco nas Redes Neurais Artificiais (RNAs), para o desenvolvimento de um sistema de ordenação de dados numéricos. As RNAs, inspiradas no funcionamento do cérebro humano, são aplicadas em diversas tarefas, como aprendizado, reconhecimento de padrões e classificação. O estudo aborda desde o Perceptron Simples, eficiente em problemas linearmente separáveis, até o Perceptron de Múltiplas Camadas (MLP), que resolve problemas não lineares complexos, como o XOR. O projeto consistiu no desenvolvimento e avaliação de um sistema de ordenação numérica baseado em RNAs, implementado em Python. O desempenho do sistema foi comparado com algoritmos de ordenação clássicos, como o QuickSort. Os resultados indicam que a rede neural é capaz de ordenar pequenas listas de números, mas sua generalização para sequências maiores é limitada pelo alto custo computacional em comparação com os métodos tradicionais. O foco principal do trabalho foi o estudo teórico, matemático e computacional dos modelos Perceptron Simples e MLP, abrangendo temas como funções de ativação, retropropagação do erro e capacidade de generalização. Essa investigação aprofundada proporcionou uma base sólida de conhecimento, que culminou na criação de um e-book educacional. O e-book visa disseminar os fundamentos do aprendizado supervisionado e a implementação de redes neurais artificiais.

Palavras-chave: Inteligência Artificial. RNAs. Perceptron. Aprendizado Supervisionado. Ordenação Numérica.

I. INTRODUÇÃO/JUSTIFICATIVA

O Plano desenvolvido insere-se no contexto da pesquisa em Inteligência Artificial (IA) aplicada à ordenação de dados numéricos, integrando fundamentos teóricos e experimentação prática com Redes Neurais Artificiais (RNAs). A

¹ Bolsista do Programa de Iniciação Científica (PIBIC). Universidade Federal do Norte do Tocantins (UFNT), Centro de Ciências Integradas (CCI). e-mail: lorrana.silva@ufnt.edu.br.

² Orientador do Programa de Iniciação Científica (PIBIC). Universidade Federal do Norte do Tocantins (UFNT), Centro de Ciências Integradas (CCI). e-mail: nilo.sotomayor@ufnt.edu.br.

investigação situa-se na área de Ciências Exatas e da Terra, com ênfase em IA e Matemática Aplicada, voltando-se ao estudo de modelos computacionais de aprendizado supervisionado e suas limitações práticas.

A IA é um campo interdisciplinar em constante avanço, cujo objetivo é desenvolver sistemas capazes de executar tarefas que tradicionalmente exigiriam inteligência humana. De acordo com Russell e Norvig (2004), a área estuda agentes inteligentes capazes de perceber o ambiente e agir sobre ele, utilizando técnicas como aprendizado de máquina e redes neurais. Estas, segundo Haykin (2001), são modelos inspirados no cérebro humano, compostos por neurônios artificiais interconectados que processam informações de forma paralela e adaptativa. Dentre os modelos históricos, destacam-se o Perceptron, proposto por Frank Rosenblatt (1958), capaz de aprender classificações lineares, e o Perceptron Multicamadas (MLP), que estendeu essa capacidade para problemas não lineares, como o XOR.

Neste trabalho, desenvolveu-se e avaliou-se um sistema de ordenação numérica baseado em RNAs, comparando seu desempenho com algoritmos clássicos, como o QuickSort. Embora a rede tenha conseguido ordenar pequenas listas, observou-se alto custo computacional para sequências maiores. O trabalho de pesquisa concentrou-se também no estudo teórico do Perceptron e do MLP, abordando tópicos como funções de ativação, retropropagação e generalização. As atividades realizadas contribuíram para o domínio conceitual e técnico em redes neurais, unindo estudo teórico, experimentação prática e produção de material educacional, reafirmando a relevância formativa e científica do projeto.

II. BASE TEÓRICA

A fundamentação teórica desta pesquisa foi construída principalmente com base na obra “Redes neurais: Princípios e prática” (Haykin, 2001), que forneceu suporte matemático essencial para o entendimento das Redes Neurais Artificiais (RNAs), em especial dos modelos Perceptron Simples e Perceptron Multicamadas (MLP).

Complementarmente, adotou-se a abordagem conceitual de Russell e Norvig (2004), em “Artificial Intelligence: A Modern Approach”, para a compreensão da Inteligência Artificial como ciência dos agentes inteligentes. Também foram consultados trabalhos, como os de Frank Rosenblatt (1958), criador do Perceptron, e

de Minsky e Papert (1969), que discutiram suas limitações, contribuindo para uma reflexão crítica sobre separabilidade linear e aprendizado supervisionado.

A revisão bibliográfica incluiu, ainda, livros e artigos científicos sobre modelagem matemática de RNAs, funções de ativação, retropropagação do erro e algoritmos clássicos de ordenação. Esses referenciais não apenas embasaram teoricamente o estudo, como também orientaram a construção da metodologia experimental em Python, permitindo a análise comparativa entre o desempenho das redes neurais e os métodos tradicionais de ordenação.

III. OBJETIVOS

Geral

Investigar o funcionamento das redes neurais artificiais no contexto da ordenação de dados numéricos, aprofundando os fundamentos teóricos e computacionais do Perceptron como modelo básico de aprendizado supervisionado.

Específicos:

- Compreender os princípios do aprendizado supervisionado e sua relação com a modelagem matemática de neurônios artificiais;
- Estudar o modelo de Perceptron como base conceitual para o aprendizado de máquina, explorando sua formulação matemática, processo de treinamento e limitações;
- Implementar, em linguagem Python, um modelo simples de Perceptron para tarefas básicas de classificação e ordenação numérica;
- Analisar os resultados obtidos quanto à capacidade de generalização e eficiência do modelo, em comparação conceitual com algoritmos clássicos de ordenação;
- Produzir um produto educacional (livro) que sistematiza o conhecimento adquirido, explicando de forma didática os fundamentos matemáticos, lógicos e computacionais do aprendizado supervisionado, com foco no Perceptron e sua aplicação introdutória à inteligência artificial.

IV. METODOLOGIA

A pesquisa, de caráter experimental e exploratório, foi realizada no Laboratório de Pesquisa em Materiais para Aplicações em Dispositivos Eletrônicos (LABMADE) da Universidade Federal do Norte do Tocantins (UFNT). Teve como foco compreender, de forma gradual e estruturada, os fundamentos teóricos e práticos do aprendizado supervisionado e das redes neurais artificiais. Antes de aplicar esses modelos em tarefas de ordenação numérica, foi necessário dominar conceitos essenciais de inteligência artificial, aprendizado de máquina e modelagem computacional inspirada no funcionamento do cérebro humano.

IV.1 Estudo dos fundamentos da aprendizagem supervisionada e redes neurais

Como parte do processo metodológico, elaborou-se um e-book que sintetiza e organiza o percurso de aprendizado, funcionando tanto como registro da experiência formativa quanto como recurso didático. O material apresenta uma progressão didática que conduz o leitor da definição de inteligência aos princípios do aprendizado supervisionado, abordando generalização, transferência de conhecimento e robustez adaptativa que são aspectos fundamentais à inteligência biológica e artificial. Os conceitos são explicados de forma acessível e rigorosa, conectando fundamentos filosóficos e formulações computacionais, e mostrando a inteligência artificial como uma formalização matemática de processos cognitivos de adaptação, previsão e decisão.

IV.2 Descrição do Código e Funcionamento da Rede Neural para Ordenação Numérica

O código implementa uma rede neural do tipo Perceptron Multicamadas (MLP) para a ordenação de sequências numéricas, a rede utiliza aprendizado supervisionado por mapeamento indireto prevendo posições relativas em vez de ordenar diretamente os valores, o que permite reconstruir a sequência ordenada. Os dados de treinamento são pares entrada-saída, compostos por sequências de três números e seus respectivos índices ordenados. Por exemplo, para a sequência [3,2,1], a saída é [2,1,0]. As Entradas e saídas são normalizadas no intervalo [0,1], garantindo estabilidade e convergência no treinamento.

A arquitetura da rede possui três camadas totalmente conectadas: duas ocultas com 10 neurônios (ReLU) e uma de saída com 3 neurônios (linear). O modelo utiliza o otimizador Adam e a função de perda MSE, sendo treinado por 500 épocas sobre

os dados normalizados. Durante a predição, a rede gera três valores contínuos que representam posições relativas. A função `argsort` é aplicada a esses valores para determinar a ordem crescente, reorganizando a sequência original. Essa abordagem mostra como redes neurais podem aprender padrões complexos de reorganização, embora com custo computacional maior que os algoritmos clássicos de ordenação.

IV.3 Implementação do Algoritmo de Ordenação Quicksort em Python

O algoritmo Quicksort é amplamente reconhecido por sua eficiência na ordenação de dados, baseando-se na estratégia de divisão e conquista. Ele particiona recursivamente o vetor em subconjuntos menores até que todos os elementos estejam em ordem. Na implementação em Python, o processo inicia verificando se o vetor possui um ou nenhum elemento (caso base); caso contrário, escolhe-se um pivô central, que divide o conjunto em três partes: elementos menores, iguais e maiores.

O procedimento é então reaplicado recursivamente aos subconjuntos, e os resultados são concatenados, formando a sequência final ordenada. O uso de compreensões de lista torna o código mais legível e elimina estruturas de repetição explícitas.

Nos testes realizados, o Quicksort foi aplicado aos mesmos vetores usados nos experimentos com redes neurais, permitindo comparar um método determinístico clássico com um baseado em aprendizado de máquina. O algoritmo apresentou resultados precisos e consistentes, com complexidade média $O(n \log n)$, sendo eficiente mesmo para grandes volumes de dados. Diferentemente das redes neurais, que exigem treinamento e produzem resultados aproximados, o Quicksort é exato e independente de dados de treino, servindo como referência de desempenho e robustez nas tarefas de ordenação numérica.

Os experimentos desenvolvidos com a rede neural e o algoritmo QuickSort fundamentaram a análise comparativa apresentada na seção seguinte.

V. RESULTADOS E DISCUSSÃO

Os algoritmos clássicos de ordenação, como o Quicksort, foram projetados especificamente para resolver o problema da ordenação de forma determinística e eficiente. Eles apresentam um custo computacional bem definido e previsível, geralmente expresso em termos da complexidade assintótica. No caso do Quicksort, o custo médio de execução é da ordem de $O(n \log n)$, o que significa que o tempo

necessário para ordenar cresce quase linearmente com o número de elementos, tornando-o muito eficiente para aplicações práticas. Além disso, o Quicksort é um algoritmo in-place, isto é, não requer memória adicional proporcional ao tamanho dos dados, utilizando apenas um espaço auxiliar mínimo para a recursão. Essa característica o torna extremamente leve em termos de uso de recursos computacionais e apropriado para sistemas com restrições de memória e processamento.

Por outro lado, as redes neurais artificiais não foram concebidas originalmente para executar tarefas determinísticas como a ordenação direta de números, mas sim para aprender padrões complexos a partir de dados. Quando aplicadas a essa tarefa, o custo computacional torna-se significativamente maior devido ao processo de treinamento, que envolve a multiplicação de matrizes de grandes dimensões e o ajuste iterativo de milhares ou milhões de parâmetros. O treinamento de uma rede neural apresenta uma complexidade que depende tanto do número de amostras de entrada quanto da profundidade e da quantidade de neurônios da rede. Em termos gerais, o custo cresce de forma aproximadamente proporcional a $O(n \times p \times e)$, onde n representa o número de amostras de treinamento, p o número de parâmetros (pesos e bias) da rede e e é o número de épocas de treinamento. Assim, mesmo para conjuntos pequenos, o esforço computacional total tende a ser várias ordens de magnitude superior ao exigido por algoritmos tradicionais de ordenação.

Além disso, enquanto o Quicksort realiza cada ordenação de forma independente e com custo previsível, as redes neurais exigem uma fase inicial de aprendizado que pode ser extremamente custosa, mas que permite, em contrapartida, reutilizar o modelo para novas entradas. Mesmo assim, o custo de inferência — isto é, o tempo necessário para aplicar a rede já treinada a um novo conjunto de dados — continua sendo superior ao de um algoritmo de ordenação clássico, especialmente em problemas de pequena escala. Outro aspecto importante é a precisão: o Quicksort fornece sempre o resultado correto e completo, enquanto uma rede neural apenas aproxima a função de ordenação com base no treinamento, podendo apresentar desvios ou inconsistências em entradas não vistas anteriormente.

Em resumo, os algoritmos clássicos de ordenação são altamente otimizados para resolver um problema específico com o mínimo custo computacional e total previsibilidade, enquanto as redes neurais consomem muito mais recursos de processamento e memória para alcançar um resultado semelhante, ainda que de

forma aproximada. O uso de uma RNA para ordenar dados só se justificaria em contextos experimentais ou em sistemas híbridos, nos quais a ordenação faz parte de uma tarefa mais ampla de aprendizado e reconhecimento de padrões. Portanto, em termos estritos de custo computacional e eficiência, os algoritmos clássicos de ordenação permanecem incomparavelmente superiores às redes neurais para esta finalidade.

VI. CONCLUSÃO/CONSIDERAÇÕES FINAIS

A experiência desenvolvida neste projeto permitiu compreender, de forma teórica e prática, o funcionamento das Redes Neurais Artificiais, com ênfase no Perceptron e no Perceptron Multicamadas (MLP). O estudo consolidou conhecimentos sobre aprendizado supervisionado, funções de ativação e retropropagação do erro, além de evidenciar as limitações das RNAs na tarefa de ordenação numérica. O impacto principal desta pesquisa foi a elaboração de um e-book sobre o tema, demonstrando o amadurecimento acadêmico e a capacidade de transformar o aprendizado em produção de conhecimento. A vivência proporcionou uma formação mais sólida na área de Inteligência Artificial, reforçando a importância da iniciação científica como instrumento de integração entre ensino, pesquisa e extensão.

VII. REFERÊNCIAS

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. ed. Nova Jersey: Prentice Hall, 2001. p. 27-382.

MINSKY, Marvin; PAPERT, Seymour. **Perceptrons: a introduction to computational geometry**. Cambridge: MIT Press, 1969. P. 117- 268.

ROSENBLATT, Frank. The Perceptron: a perceiving and recognizing automaton. Report 85-460-1. Buffalo, New York: **Cornell Aeronautical Laboratory**.1958. p.1-58.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 4. ed. Global Edition. Harlow, UK: Pearson Education Limited, 2022. p.54.

TEGMARK, Max. **Vida 3.0: O ser humano na era da inteligência artificial**. São Paulo: Benvirá-Saraiva, 2019. p.32 - 45.

VIII. AGRADECIMENTOS

Agradeço ao CNPq pela bolsa de Iniciação Científica, que possibilitou esta pesquisa e minha formação acadêmica, e ao Prof. Dr. Nilo Mauricio Sotomayor pelas orientações e contribuições fundamentais ao desenvolvimento do trabalho.