


**PENSAMENTO COMPUTACIONAL NO ENSINO MÉDIO: UMA SEQUÊNCIA DIDÁTICA
SOBRE INTELIGÊNCIA ARTIFICIAL E REDES NEURAIS ARTIFICIAIS**

**COMPUTATIONAL THINKING IN HIGH SCHOOL: A TEACHING SEQUENCE ON
ARTIFICIAL INTELLIGENCE AND ARTIFICIAL NEURAL NETWORKS**

**PENSAMIENTO COMPUTACIONAL EN LA EDUCACIÓN SECUNDARIA: UNA
SECUENCIA DE ENSEÑANZA SOBRE INTELIGENCIA ARTIFICIAL Y REDES
NEURONALES ARTIFICIALES**

 <https://doi.org/10.56238/arev7n10-228>

Data de submissão: 23/09/2025

Data de publicação: 23/10/2025

Inês Maria Maia Pinto de Guadalupe

Mestre em Matemática

Instituição: Universidade Federal de São João del-Rei

E-mail: inesmaiguadalupe@gmail.com

Juan Carlos Zavaleta Aguilar

Doutor em Matemática Aplicada

Instituição: Universidade Federal de São João del-Rei

E-mail: jaguilar@ufsj.edu.br

RESUMO

Este trabalho visa a integração da modelagem matemática (MM) e das redes neurais artificiais (RNA) no ensino médio (EM) com o objetivo da promoção do pensamento computacional (PCO). A proposta de ensino foi aplicada em uma turma do 3º ano de uma escola pública de tempo integral, por meio de uma sequência didática envolvendo onze aulas. Nestas aulas, os alunos exploraram conceitos de RNA, vinculados ao conteúdo matemático e alinhados às diretrizes da Base Nacional Comum Curricular (BNCC). Utilizou-se uma metodologia mista, que combinou abordagens qualitativas e quantitativas; questionários iniciais avaliaram o conhecimento prévio e o interesse dos estudantes, enquanto atividades práticas e discussões interativas, como comparações entre neurônios biológicos e artificiais e o uso de programação no Google Colab, enriqueceram a experiência de aprendizado. A linguagem de programação Python facilitou a aplicação dos conceitos de RNA, como funções de ativação, ajuste de pesos e reconhecimento de padrões. Observou-se o desenvolvimento do PCO, especialmente nas habilidades de decomposição e abstração à medida que os alunos acompanhavam a aplicação de algoritmos simples para a estruturação de problemas matemáticos e computacionais. Embora houvesse inicialmente receio quanto ao uso de funções na composição de RNA, os estudantes acabaram compreendendo a simplicidade lógica desses conceitos, o que aumentou o engajamento nas atividades práticas. Conclui-se que a sequência didática foi eficaz em introduzir os alunos ao campo das RNA, promovendo conexões entre conceitos matemáticos e tecnológicos e despertando o interesse pelo mundo da programação e suas aplicações na resolução de problemas contextualizados. Com o devido ajuste no tempo de cada etapa e um foco maior em atividades práticas, essa abordagem tem grande potencial para aproximar os estudantes das novas tecnologias e fortalecer o desenvolvimento do PCO.

Palavras-chave: Redes Neurais Artificiais. Modelagem Matemática. Pensamento Computacional. Ensino Médio. Perceptron de Camada Única. Programação na Linguagem Python.

ABSTRACT

This work aims to integrate mathematical modeling (MM) and artificial neural networks (ANN) into secondary education (SE) with the goal of promoting computational thinking (PCO). The teaching proposal was implemented in a third-grade class at a full-time public school, through a teaching sequence involving eleven lessons. In these lessons, students explored ANN concepts linked to mathematical content and aligned with the guidelines of the National Common Curricular Base (BNCC). A mixed methodology was used, combining qualitative and quantitative approaches. Initial questionnaires assessed students' prior knowledge and interest, while hands-on activities and interactive discussions, such as comparisons between biological and artificial neurons and the use of Google Colab programming, enriched the learning experience. The Python programming language facilitated the application of ANN concepts, such as activation functions, weight adjustment, and pattern recognition. The development of the PCO was observed, particularly in decomposition and abstraction skills, as students followed the application of simple algorithms to structure mathematical and computational problems. Although initially apprehensive about using functions in ANN composition, students eventually understood the logical simplicity of these concepts, which increased their engagement in practical activities. The conclusion is that the teaching sequence was effective in introducing students to the field of ANNs, fostering connections between mathematical and technological concepts and sparking interest in the world of programming and its applications in solving contextualized problems. With appropriate adjustments to the timing of each stage and a greater focus on practical activities, this approach has great potential to introduce students to new technologies and strengthen the development of the PCO.

Keywords: Artificial Neural Networks. Mathematical Modeling. Computational Thinking. High School. Single-Layer Perceptron. Python Programming.

RESUMEN

Este trabajo busca integrar el modelado matemático (MM) y las redes neuronales artificiales (RNA) en la educación secundaria (ES) con el objetivo de promover el pensamiento computacional (PCO). La propuesta didáctica se implementó en una clase de tercer grado en una escuela pública de tiempo completo, a través de una secuencia de enseñanza de once lecciones. En estas lecciones, los estudiantes exploraron conceptos de RNA vinculados al contenido matemático y alineados con las directrices de la Base Curricular Común Nacional (BNCC). Se utilizó una metodología mixta, combinando enfoques cualitativos y cuantitativos. Los cuestionarios iniciales evaluaron el conocimiento previo y el interés de los estudiantes, mientras que las actividades prácticas y las discusiones interactivas, como las comparaciones entre neuronas biológicas y artificiales y el uso de la programación de Google Colab, enriquecieron la experiencia de aprendizaje. El lenguaje de programación Python facilitó la aplicación de conceptos de RNA, como funciones de activación, ajuste de peso y reconocimiento de patrones. Se observó el desarrollo del PCO, particularmente en las habilidades de descomposición y abstracción, a medida que los estudiantes siguieron la aplicación de algoritmos simples para estructurar problemas matemáticos y computacionales. Aunque inicialmente existía cierta aprensión por el uso de funciones en la composición de RNA, los estudiantes finalmente comprendieron la simplicidad lógica de estos conceptos, lo que incrementó su participación en actividades prácticas. La conclusión es que la secuencia didáctica fue eficaz para introducir a los estudiantes en el campo de las RNA, fomentando las conexiones entre conceptos matemáticos y tecnológicos y despertando el interés por el mundo de la programación y sus aplicaciones para la resolución de problemas contextualizados. Con ajustes adecuados en la duración de cada etapa y un mayor enfoque en las actividades prácticas, este enfoque tiene un gran potencial para introducir a los estudiantes a nuevas tecnologías y fortalecer el desarrollo del PCO.

Palabras clave: Redes Neuronales Artificiales. Modelado Matemático. Pensamiento Computacional. Bachillerato. Perceptrón de una Sola Capa. Programación en Python.

1 INTRODUÇÃO

A educação matemática desempenha um papel fundamental na formação dos estudantes, desenvolvendo habilidades analíticas, lógicas e críticas essenciais para enfrentar desafios tanto nas carreiras acadêmicas quanto na vida cotidiana. No entanto, o ensino tradicional muitas vezes parece abstrato, repetitivo e distante da realidade, o que pode desmotivar e dificultar a compreensão desta disciplina.

No Brasil, a educação enfrenta desafios significativos, especialmente em termos de qualidade e equidade. Avaliações externas, como o Sistema de Avaliação da Educação Básica (SAEB), destacam fragilidades, como a evasão escolar e o baixo desempenho em

Matemática, como evidenciado. Dados do Censo Escolar de 2023 indicam um aumento preocupante na taxa de evasão escolar, como evidenciado pelo INEP, enquanto os resultados do Programa Internacional de Avaliação de Estudantes (PISA) mostram que a maioria dos estudantes brasileiros não alcança o nível mínimo de proficiência em matemática.

Diante desse cenário, é imperativo que os professores desta importante área do conhecimento repensem suas práticas profissionais. Nesse sentido, a MM surge como uma abordagem pedagógica importante, aproximando a matemática do mundo real e tornando-a mais acessível e relevante para os estudantes.

Este trabalho propõe a aplicação de uma sequência didática em uma turma do 3º ano do EM da Escola Estadual Coronel Xavier Chaves (EECXC). O objetivo é integrar a MM e as RNAs no contexto do PCO, visando também facilitar a compreensão da Inteligência Artificial (IA), a partir de uma perspectiva matemática. A escolha da EECXC se justifica pelo perfil de seus alunos, que refletem a realidade da educação pública brasileira, e pelo interesse da instituição em promover inovações pedagógicas no ensino de matemática, buscando, de forma efetiva, melhorar as práticas nos Itinerários Formativos (IF) do Novo Ensino Médio (NEM).

A opção por este tema é motivada pela crescente relevância das RNA e a importância dos fundamentos matemáticos na compreensão da IA e do aprendizado de máquina. Essas redes, inspiradas no funcionamento do cérebro humano, oferecem uma abordagem eficaz para resolver problemas complexos.

Oliveira e Silva (2022) apontam que a introdução dos conceitos de RNA no currículo de matemática do EM não só torna a disciplina mais relevante para o mundo atual, mas também prepara os estudantes para futuras oportunidades. No entanto, para que essa abordagem seja implementada de forma eficaz, é essencial contar com professores bem capacitados e motivados.

A sequência didática proposta, contempla atividades e recursos práticos para os professores que atuam nos IF do NEM, abordando conectivos lógicos como AND, OR e XOR e demonstrando a construção de uma RNA para prever resultados em situações simples. A proposta inclui o uso da linguagem de programação Python para implementar computacionalmente esses conceitos, proporcionando uma compreensão teórico-prática das RNA.

Na literatura especializada podem ser encontrados diversos trabalhos relacionados com os temas tratados nesse trabalho, entre eles destacam-se os trabalhos de Furtado (2019), que apresenta uma abordagem prática para sala de aula envolvendo RNA e outras pesquisas relevantes como "Redes Neurais no Ensino Básico", da Sociedade Brasileira de Matemática, que explora o uso de redes neurais como recurso pedagógico inovador para o ensino básico, oferecendo formação continuada para professores.

Outro estudo realizado por Coelle, Rodrigues e Silva (2022), descreve estratégias para introduzir conceitos de RNA aos alunos do EM de forma acessível, utilizando conceitos matemáticos básicos. Ainda, o trabalho de Costa e Junior (2014), propõe o uso de RNA para despertar o interesse dos estudantes pela matemática, destacando seu potencial pedagógico.

Essas contribuições teóricas e práticas enriqueceram a elaboração da sequência didática proposta neste trabalho, fornecendo as bases para sua implementação. Nesse contexto, ao explorar a conexão entre MM e RNA na educação matemática, inserindo o PCO no EM este trabalho busca investigar também como o PCO, por meio do conhecimento das RNA, pode contribuir para o ensino de matemática e suas tecnologias, desenvolvendo competências e habilidades previstas na BNCC.

2 REFERENCIAIS TEÓRICOS

2.1 MODELAGEM MATEMÁTICA

A MM é uma abordagem pedagógica que visa ensinar matemática por meio de sua aplicação em contextos do cotidiano no âmbito da educação básica. Segundo Burak (2010), esta metodologia teve origem na década de 80, a partir de estudos que objetivavam uma melhoria do ensino de matemática.

O trabalho de Burak aborda a incorporação da MM na prática de ensino, destacando a importância de identificar situações práticas, coletar dados relevantes, traduzir problemas para o contexto matemático, criar e resolver modelos, analisar resultados, refletir criticamente sobre os modelos e comunicar os resultados de forma clara e organizada.

De acordo com Bassanezi (2002), o ensino da matemática nas escolas é conduzido de forma descolada da realidade e do processo histórico de sua construção, o qual fica evidenciado na seguinte observação:

O desenvolvimento de novas teorias matemáticas e suas apresentações como algo acabado e completo acabaram conduzindo seu ensino nas escolas de maneira desvinculada da realidade, e mesmo do processo histórico de construção da matemática. Assim é que um teorema é ensinado, seguindo o seguinte esquema: “enunciado – demonstração – aplicação”, quando de fato o que poderia ser feito é sua construção na ordem inversa, isto é, sua motivação, a formulação de hipóteses, a validação e novos questionamentos, e finalmente seu enunciado. Estaríamos assim reinventando o resultado juntamente com os alunos, seguindo o processo da modelagem e conjugando verdadeiramente o binômio ensino-aprendizagem (Bassanezi, 2022, p. 36).

Dessa forma, ao apresentar um problema real ou contextualizado, a solução desse problema deve promover a motivação de buscar a solução de forma individual, coletiva ou orientada. Nesse entendimento, devemos incorporar a MM na prática de ensino de várias maneiras, a partir de diferentes abordagens, mas seguindo alguns procedimentos, conforme aponta Pereira (2023):

- Identificando um problema do mundo real que envolva situações práticas e que possam ser resolvidos usando conceitos matemáticos específicos. Isso ajuda os estudantes a ver a aplicação prática da matemática em suas vidas.
- Coletando dados relevantes para o problema. Isso pode incluir atividades de pesquisa, experimentação ou análise de conjuntos de dados existentes.
- Traduzindo um problema do mundo real para o contexto matemático, identificando as variáveis envolvidas e as relações entre elas, podendo fazer suposições ou simplificações para tornar o problema mais acessível. Isso envolve traduzir a linguagem do problema para a linguagem matemática.
- Criando modelos matemáticos que representem o problema ou seja, as relações entre as variáveis identificadas. Isso pode envolver o uso de equações, inequações, sistemas de equações, funções, tabelas, gráficos, etc.
- Resolvendo equações ou manipulando as representações matemáticas criadas para encontrar uma solução para o problema. Isso pode envolver o uso de cálculos matemáticos, software de simulação ou outras ferramentas computacionais.
- Analisando os resultados do MMO. Isso significa interpretar as soluções em termos do problema original e verificar se os resultados fazem sentido na situação do mundo real. Discutir se a solução é aplicável ao problema original e quais são as implicações práticas das descobertas.

- Fazendo uma reflexão crítica sobre os modelos criados; considerando a validade de suas suposições, a precisão dos dados coletados e a relevância de suas soluções.
- Comunicando os resultados de forma clara e organizada, explicando o problema, o MMO desenvolvido, os métodos utilizados e as instruções apresentadas, por meio de relatórios, apresentações ou modelos visuais.

Dessa forma, a MM frequentemente envolve habilidades multidisciplinares, pois o processo de modelagem exige a integração de conhecimentos de diversas áreas, como a pesquisa científica, o uso de tecnologias, e a comunicação de resultados. Além disso, os estudantes podem se beneficiar ao trabalhar em equipe, combinando diferentes perspectivas para criar modelos mais abrangentes e eficazes. Assim, a MM se revela uma ferramenta versátil, útil em diversas disciplinas e áreas, ajudando a desenvolver habilidades essenciais, como pensamento crítico, resolução de problemas e comunicação matemática.

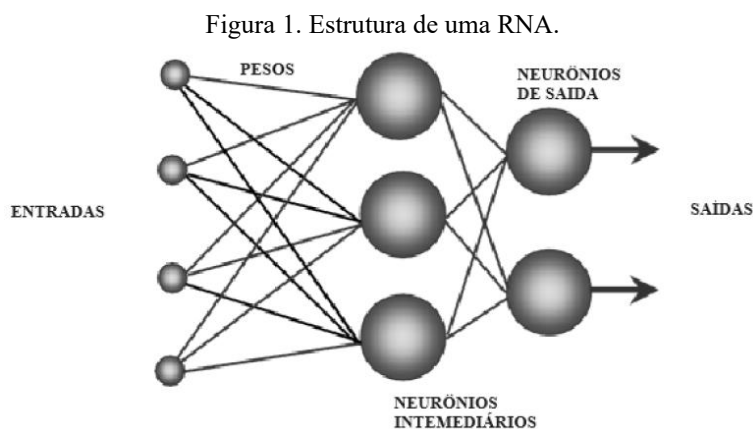
2.2 INTELIGÊNCIA ARTIFICIAL E REDES NEURAIS ARTIFICIAIS

A IA se refere à simulação de processos de inteligência humana em sistemas computacionais, permitindo que máquinas executem funções cognitivas como aprendizado, raciocínio, identificação de padrões, resolução de problemas e interpretação da linguagem natural. Essas capacidades possibilitam que os sistemas realizem tarefas complexas de forma semelhante ao raciocínio humano, como apontado por Haykin (2001). Este campo é interdisciplinar, combinando ciência da computação, matemática, estatística, engenharia e ciências cognitivas.

Os principais campos da IA abrangem diversas áreas interconectadas e com aplicações variadas. Segundo Russell e Norvig (2016), esses campos incluem: aprendizado de máquina, que permite a criação de sistemas capazes de melhorar seu desempenho com base em dados; RNA e aprendizado profundo, focados em simular o funcionamento do cérebro humano para resolver problemas complexos; visão computacional, para a análise de imagens e vídeos; processamento de linguagem natural, que envolve a interpretação e geração de linguagem humana; robótica, dedicada à construção de agentes físicos autônomos; e inteligência artificial generalizada, que busca desenvolver sistemas com capacidades cognitivas comparáveis às humanas.

Nesse contexto, as RNA são estruturas matemáticas inspiradas no funcionamento do cérebro humano, compostas por unidades chamadas neurônios artificiais, nós ou perceptrons, organizadas em camadas. Esse conceito foi introduzido por Frank Rosenblatt na década de 1950, com o desenvolvimento do perceptron, que visava simular o comportamento de um neurônio biológico.

Através da Figura 1, pode-se observar as três principais camadas de uma rede neural: entrada, camadas ocultas e saída.



Fonte: Furtado, 2019, p. 11.

O funcionamento de uma rede neural envolve também três etapas principais: propagação para frente (propagação direta), cálculo do erro e retropropagação. Durante a fase de propagação para frente, os dados de entrada são passados pela rede, camada por camada, até a camada de saída.

Após a combinação linear das entradas, seguida por uma função de ativação, cada entrada é multiplicada pelo seu respectivo peso, e esses produtos são somados, resultando na aplicação do somatório ponderado.

Conforme descrito por Haykin (2001), os pesos iniciais de uma rede neural são definidos aleatoriamente, com valores geralmente entre -1 e 1. Durante o treinamento da rede, esses pesos são ajustados iterativamente com o objetivo de minimizar o erro nas saídas. Esse processo de ajuste dos pesos, realizado através de algoritmos de aprendizado, como o gradiente descendente, é chamado de treinamento da rede.

Segundo Haykin (2001), uma rede neural pode ser vista como uma máquina adaptativa, onde todos os neurônios artificiais são maciçamente interligados:

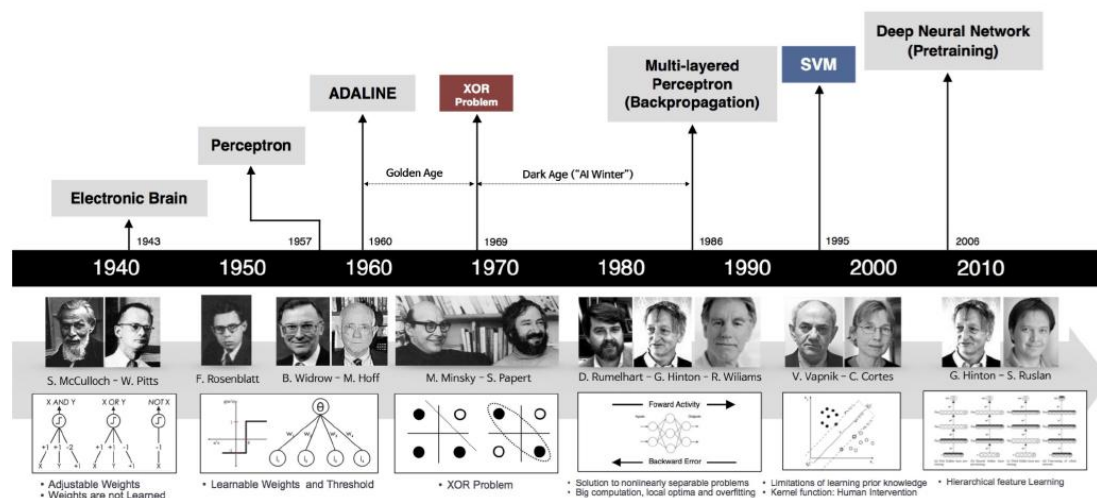
Uma rede neural é um processador maciçamente paralelo distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos: 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (Haykin, 2001, p. 28).

A aprendizagem de uma RNA significa que ela se torna capaz de apresentar saídas adequadas a partir de novas entradas, ou seja, de dados que não estavam presentes durante o seu processo de

treinamento. Isso implica que a rede ajusta seus pesos para minimizar os erros na saída, permitindo assim generalizar o conhecimento adquirido para novas situações.

As RNA modernas são alicerçadas em princípios matemáticos sólidos, como álgebra linear, cálculo diferencial e otimização numérica. A pesquisa em RNA continua a explorar métodos avançados, arquiteturas complexas e aplicações em diversos setores. Entretanto, as RNA vem sendo desenvolvidas desde 1940, como ilustrada na Figura 2.

Figura 2. Marcos no desenvolvimento das RNA.




Fonte: Data Science Academy.

2.3 O PERCEPTRON DE CAMADA ÚNICA

O perceptron de camada única é uma representação computacional simplificada de um neurônio. É um componente fundamental de muitos algoritmos de aprendizado de máquina e funciona como um modelo de RNA (Figura 1) de uma única camada, usado principalmente para tarefas de classificação linear.

Para ilustrar a relação entre os neurônios biológicos e os perceptrons, apresenta-se a Figura 3.

Figura 3. Comparação entre neurônio biológico e neurônio artificial.

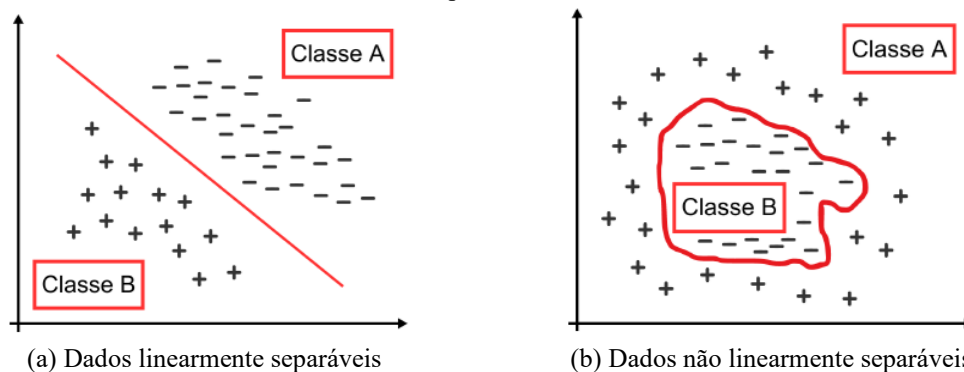


Fonte: Adaptado de Naranjo, 2014, p. 68.

A Figura 3 ilustra, à esquerda, um neurônio biológico, destacando suas principais partes: os dendritos, o corpo celular e o axônio. Esta imagem evidencia a complexidade do sistema nervoso humano e a interação dos neurônios no processamento e transmissão de informações. À direita, apresenta um neurônio artificial, ou perceptron. Este modelo simplificado serve como bloco de construção fundamental para redes neurais artificiais, capturando a essência do neurônio biológico de forma computacional, o que possibilita sua aplicação em algoritmos de aprendizado de máquina.

Segundo Silva, Spatti e Flauzino (2010), o perceptron funciona como um classificador capaz de separar padrões em classes, desde que estas sejam linearmente separáveis. No contexto do aprendizado de máquina, os dados são considerados linearmente separáveis se for possível traçar uma fronteira de decisão que separe duas classes de dados. Na Figura 4, ilustra-se dados que são linearmente separáveis 4-(a) e os que não são 4-(b), respectivamente.


Figura 4. Dados linearmente separáveis e não linearmente separáveis.



Fonte: Adaptado de Furtado (2019), p. 48 e 49.

O perceptron utiliza entradas ponderadas e uma função de ativação para produzir saídas binárias. Na Figura 5, pode-se observar uma representação desse neurônio artificial.

Figura 5. Representação do perceptron.



Fonte: Adaptado de Deep Learning Book Brasil (2025).

Segundo Furtado (2019), para que uma função matemática possa ser utilizada como função de ativação em uma rede neural artificial, é necessário que duas condições sejam satisfeitas: a função deve ser contínua e os limites da função no infinito devem ser finitos. A continuidade da função assegura que pequenas variações nas entradas resultem em pequenas variações nas saídas, o que é essencial para a estabilidade e a convergência dos algoritmos de treinamento. Além disso, a exigência de limites finitos evita que os valores das ativações se tornem infinitos, o que poderia causar instabilidades numéricas e comprometer o treinamento da rede neural.

Funções que são frequentemente utilizadas como funções de ativação são degrau unitário, ReLU, sigmoide, TanH, entre outras.

Na Figura 5 é ilustrado o funcionamento básico de um perceptron de camada única: variáveis de entradas (x_1, x_2, \dots, x_n) são ponderadas por pesos correspondentes (w_1, w_2, \dots, w_n), refletindo a importância de cada entrada. Cada entrada é multiplicada por seu peso e, em seguida, os produtos dessas multiplicações são somados, formando assim uma soma ponderada ($\sum_{i=1}^n x_i w_i$). Esse valor

somado é então ajustado por um parâmetro adicional conhecido como viés, b , com o propósito de deslocar a soma ($\sum_{i=1}^n x_i w_i + b$), permitindo que a rede ajuste a saída mesmo quando todas as entradas são zero. Após essa soma ajustada, a função de ativação (f) é aplicada, $f(\sum_{i=1}^n x_i w_i + b)$. A função de ativação determina o valor final da saída do neurônio $\hat{y} = f(\sum_{i=1}^n x_i w_i + b)$. Por último, é comparado, através do erro E , a solução conhecida \bar{y} e a calculada \hat{y} , $E = \bar{y} - \hat{y}$.

Em resumo, um perceptron é um algoritmo simples que aprende a tomar decisões com base nas entradas que recebe, ajustando seus pesos e viés para minimizar os erros e melhorar sua eficiência ao longo do tempo. Ele forma uma base para redes neurais mais complexas usadas em problemas de aprendizado de máquina. Todavia, eles são usados para resolver uma variedade de problemas de aprendizado de máquina, incluindo classificação, reconhecimento de padrões, entre outras aplicações específicas.

2.4 O PENSAMENTO COMPUTACIONAL NA BNCC

Para Wing (2016), o PCO é uma habilidade cognitiva que envolve a capacidade de resolver problemas de forma lógica e algorítmica, muitas vezes fazendo uso de conceitos e técnicas da ciência da computação. Segundo a autora, esse pensamento envolve habilidades de resolução de problemas, raciocínio lógico e a capacidade de entender e aplicar conceitos computacionais em diversas situações, não se limitando ao contexto da programação. Wing afirma ainda que o PCO é uma habilidade fundamental para todos, não somente para cientistas da computação e defende que além da leitura, escrita e a aritmética, deveríamos incluir o PCO como habilidade analítica de todas as crianças.

A BNCC é um documento normativo que “define o conjunto orgânico e progressivo de aprendizagens essenciais que todos os alunos devem desenvolver ao longo das etapas e modalidades da Educação Básica” (BNCC, 2018).

A BNCC propõe que os estudantes utilizem tecnologias, como calculadoras e planilhas eletrônicas, desde os primeiros anos do Ensino Fundamental. Essa abordagem visa garantir que, ao chegar aos anos finais, os alunos estejam preparados para desenvolver o PCO através da interpretação e elaboração de algoritmos, incluindo aqueles representados por fluxogramas.

Embora a BNCC não defina o ensino do PCO como uma disciplina isolada, ela integra seus princípios e habilidades em diversas áreas curriculares. No EM, as competências específicas de matemática e suas tecnologias enfatizam:

Investigar e estabelecer conjecturas a respeito de diferentes conceitos e propriedades matemáticas, empregando estratégias e recursos, como observação de padrões, experimentações e diferentes tecnologias, identificando a necessidade, ou não, de uma

demonstração cada vez mais formal na validação das referidas conjecturas (BNCC, 2018, p. 531).

Dessa forma, o documento enfatiza o desenvolvimento de habilidades cognitivas, como raciocínio lógico, abstração, solução de problemas e criatividade, que são componentes essenciais do PCO. Além disso, valoriza a colaboração, o trabalho em equipe e a resolução de conflitos, habilidades socioemocionais importantes para o desenvolvimento do PCO.

Segundo Costa, Sila e Oliveira (2021), a MM e a PCO utilizam abstração e simplificação para modelar situações complexas de forma estruturada, enquanto Wing (2016) destaca o PCO como uma habilidade essencial que transcende a programação.

Em síntese, tanto a MM quanto o PCO estão profundamente associados à resolução de problemas complexos. A MM permite compreender e modelar problemas de maneira abstrata, enquanto o PCO desenvolve o raciocínio estruturado e as habilidades práticas necessárias para implementar soluções eficientes.

2.5 OS ITINERÁRIOS FORMATIVOS

O conceito de IF surgiu como parte da implementação de novas propostas pedagógicas no Brasil, especialmente com a introdução da BNCC no EM. Segundo Silva (2028), o IF visa personalizar e diversificar a formação dos alunos, oferecendo trajetórias de aprendizado mais flexíveis e alinhadas aos seus interesses e habilidades.

A Lei nº 13.415/2017 aborda o IF especificamente no artigo 36, que trata da reorganização do currículo do EM. De acordo com essa lei, o currículo do EM deve ser estruturado para garantir tanto a formação comum quanto a formação específica, por meio dos IF. Esses itinerários permitem que o estudante se aprofunde em áreas do conhecimento ou em campos relacionados às suas aspirações profissionais.

Os principais objetivos do IF é promover uma educação mais integrada, interdisciplinar e focada no desenvolvimento das competências e habilidades dos alunos. Dessa forma, esse modelo de ensino busca atender às necessidades individuais de aprendizagem, estimulando a autonomia dos estudantes e oferecendo oportunidades para que se envolvam em áreas de conhecimento específicas. Além disso, pretende-se que o itinerário formativo contribua para o desenvolvimento de habilidades essenciais, como o pensamento crítico, a resolução de problemas complexos e a aplicação prática do conhecimento adquirido.

Entretanto, Almeida (2024), ao analisar os desafios enfrentados na implementação dos IF no NEM brasileiro, mostra que:

... a submissão dos itinerários formativos aos interesses do mercado de trabalho levanta preocupações sobre a formação dos jovens brasileiros, enfatizando a preparação para um mercado precário e flexível em detrimento de uma educação sólida e abrangente. A falta de avaliação adequada das necessidades dos estudantes e a ausência de integração entre as etapas da educação básica contribuem para a fragmentação do sistema educacional e para a perpetuação das desigualdades existentes (Almeida, 2024, p. 42).

Os itinerários formativos abrangem diversas áreas, tais como Linguagens e suas Tecnologias, Matemática e suas Tecnologias, Ciências da Natureza e suas Tecnologias, Ciências Humanas e Sociais Aplicadas, além da Formação Técnica e Profissional.

Dentro desses itinerários, há a possibilidade de oferecer cursos, disciplinas e atividades destinadas a aprofundar os conhecimentos em áreas específicas, proporcionando, assim, uma formação mais especializada.

No contexto da MM e RNA é possível aplicar uma proposta de sequência didática que envolva esses temas e que seja orientada para o desenvolvimento do PCO. A ideia é integrar essas áreas de forma a estimular o raciocínio lógico e a criatividade dos alunos, ao mesmo tempo em que se abordam conceitos matemáticos e computacionais essenciais.

A MM, ao ser aplicada ao estudo de RNA, permite que os estudantes compreendam como algoritmos complexos podem ser formulados e solucionados de maneira estruturada.

Em consequência, a sequência didática proposta deve incluir atividades práticas, estudos de caso e desafios de programação, proporcionando uma experiência de aprendizado que desenvolva tanto as habilidades teóricas quanto as práticas necessárias para a resolução de problemas no contexto tecnológico atual.

3 SEQUÊNCIA DIDÁTICA PARA O ENSINO DO PERCEPTRON NO ENSINO MÉDIO

Com base no referencial teórico apresentado, este capítulo apresenta uma abordagem didática para integrar o uso de RNA às aulas do IF, destinadas a uma turma do EM. Tais aulas integram os IF sugeridos para o NEM, os quais têm como objetivo principal a flexibilização e diversificação do ensino.

Devido a que o IF possibilita uma formação mais especializada, sugere-se a escolha do itinerário formativo Tecnologias e Inovação, ou, outro equivalente, justificando sua escolha pelo interesse em aplicar a MM e desenvolver o PCO no EM, por meio da elaboração didática de uma RNA.

Para tanto, recomenda-se a implementação da rede neural perceptron, devido à sua simplicidade quando restrito a um número mínimo de neurônios. Essa escolha possibilita uma demonstração prática das iterações da rede, permitindo que os alunos compreendam o processo de forma manual, o que facilita a abstração da complexidade dos algoritmos subjacentes às RNA. Tal abordagem foca na

compreensão dos fundamentos antes de explorar estruturas mais complexas, como as redes multicamadas.

Outra justificativa para abordar o perceptron no EM é que as ferramentas matemáticas utilizadas na MM dessa RNA, como diferentes tipos de funções de ativação, compreensão da separabilidade de dados, somatórias, sequências e operações matriciais básicas, estão alinhadas às habilidades propostas pela BNCC para essa etapa da educação básica.

Além disso, o estudo do perceptron estimula o desenvolvimento do PCO ao integrar conceitos de lógica, abstração e análise de dados, promovendo a solução de problemas complexos e a aplicação prática de conhecimentos matemáticos e computacionais.

Considerando os conhecimentos básicos dos estudantes sobre o sistema nervoso, funções e conectivos lógicos, é necessária uma revisão dos conceitos fundamentais necessários para se compreender os princípios do perceptron. Essa revisão deve incluir os fundamentos matemáticos essenciais e o entendimento básico sobre o funcionamento dos neurônios, que servirão como base para abordar os aspectos tecnológicos relacionados à IA.

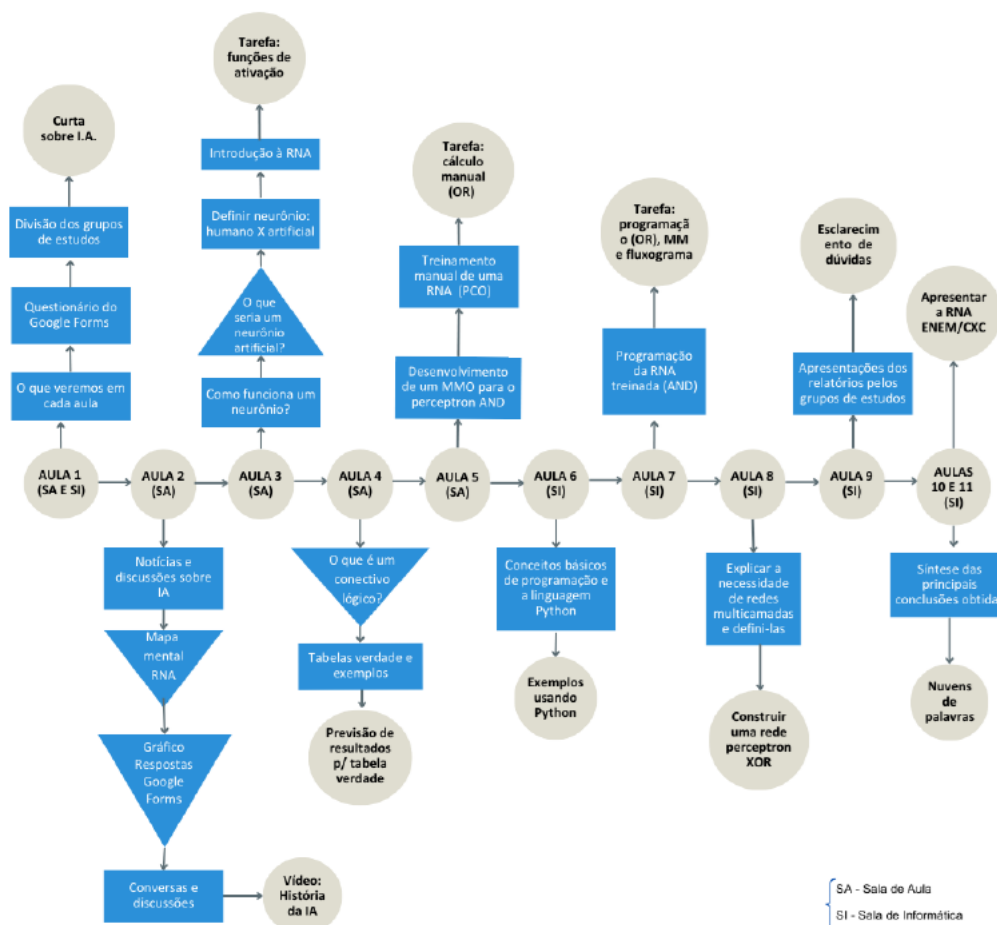
No entanto, é importante destacar que cada turma possui características únicas, e, portanto, a necessidade de revisão pode variar. Em alguns casos, a retomada desses conceitos pode demandar mais tempo, enquanto em outros, pode ser abordada de forma mais sucinta.

Assim, o planejamento da sequência didática deve ser cuidadosamente ajustado para garantir que os alunos adquiram a base necessária, permitindo uma aplicação eficaz dos conteúdos e o bom andamento das atividades subsequentes.

3.1 PROGRAMAÇÃO DE AULAS NA SEQUÊNCIA DIDÁTICA PROPOSTA

O conteúdo e planejamento de aulas pode ser ilustrado através da Figura 6. O conteúdo das aulas, bem como detalhamentos de temas, questionários, tarefas, códigos, entre outros, podem ser encontrados no livro dos autores Guadalupe e Aguilar (2025).

Figura 6. Planejamento das aulas da sequência didática.



Fonte: Elaborado pela autora.

Esta proposta didática propõe um conjunto de, no mínimo, 10 aulas ao longo de três meses, contemplando uma aula semanal. As aulas devem ser realizadas alternando entre o ambiente da sala de aula e o laboratório de informática, priorizando atividades práticas e o uso de recursos tecnológicos, como retroprojetores, computadores e internet, para enriquecer as dinâmicas.

Na primeira aula, sugere-se apresentar conceitos fundamentais relacionados à IA e avaliar o conhecimento prévio dos alunos. Nas aulas seguintes, introduzir a teoria sobre RNA e os princípios básicos de programação. Para isso, utilize situações-problema que possibilitem a criação e análise de redes perceptron, promovendo discussões que ajudem a aprofundar a compreensão dos conceitos.

Sugere-se também organizar os alunos em equipes, incentivando-os a desenvolver soluções para os desafios propostos. Oriente cada equipe a apresentar suas abordagens, destacando as estratégias utilizadas e os conceitos matemáticos aplicados.

O principal objetivo desta sequência didática é oferecer aos estudantes uma introdução aos conceitos fundamentais de IA e RNA, conectando esses tópicos à prática pedagógica. As atividades

planejadas buscam desenvolver o PCO e habilidades matemáticas, além de estimular a resolução colaborativa de problemas.

Ao final da sequência, os alunos devem ser capazes de compreender os conceitos básicos da IA e sentir-se motivados a explorar mais profundamente essa área dinâmica e transformadora. Para alcançar esses objetivos, integre atividades práticas e promova discussões em grupo, garantindo uma aprendizagem interativa e significativa, conectada aos desafios do mundo atual.

Essa abordagem equilibra teoria e prática, com ênfase no desenvolvimento de habilidades aplicadas por meio de atividades realizadas no laboratório de informática.

4 APLICAÇÃO DA SEQUÊNCIA DIDÁTICA

A sequência didática foi implementada na turma do 3º ano da EECXC, que é a única turma em tempo integral da instituição no ano de 2024 e a única escola de nível médio do município.

A turma é composta por 25 adolescentes com idades entre 16 e 18 anos, e a escolha dessa turma fundamenta-se na maturidade esperada desses estudantes, que se encontram em uma fase de crescente interesse pelo mercado de trabalho e reconhecem a importância da computação e da programação. Além disso, esses jovens demonstram entusiasmo pelo uso das tecnologias, impulsionados tanto pela curiosidade quanto pela oportunidade de explorar o tema na redação do ENEM 2024.

A seguir apresenta-se o relato de experiência da autora deste trabalho na aplicação da sequência didática.

4.1 PRIMEIRA AULA - 16 DE AGOSTO DE 2024

A primeira aula da sequência didática contou com a presença de 20 dos 25 alunos matriculados e teve como objetivo introduzir conceitos fundamentais de IA e suas aplicações em diversas áreas do conhecimento. Após apresentar os objetivos e a sequência das aulas (Figura 5), percebi grande interesse dos alunos, embora o conhecimento prévio sobre o tema fosse quase inexistente.

Durante a conversa, surgiram percepções variadas: uma aluna associou a IA a “robôs que destruiriam o mundo”, o que gerou uma reflexão sobre estereótipos; outra mencionou ter feito um curso de Python, e seis alunos — integrantes do grupo de assistência tecnológica da escola — mostraram entusiasmo especial, pois já atuam na manutenção de equipamentos.

Os alunos deveriam responder um questionário no *Google Forms* (Apêndice B de Guadalupe e Aguilar, 2025), mas, devido a falhas na internet e à indisponibilidade do laboratório, o link foi enviado via WhatsApp para preenchimento posterior. Assim, a curta de 5 minutos planejada foi adiada.

Expliquei que, a partir do terceiro encontro, as atividades seriam em grupo. Apesar da fragmentação inicial da turma, formaram-se cinco equipes de três a sete integrantes, conforme suas preferências. Para encerrar, pedi que pesquisassem notícias recentes sobre IA para discussão na próxima aula. Essa primeira experiência permitiu não apenas introduzir o tema, mas também estimular reflexões sobre as percepções e experiências tecnológicas dos alunos.

4.2 SEGUNDA AULA - 23 DE AGOSTO DE 2024

A segunda aula contou com a presença de 13 estudantes (52% da turma) e teve como foco a discussão de notícias sobre IA e a introdução ao conceito de RNA. Apenas dois alunos trouxeram notícias — uma sobre um cão-robô que anda na Lua e outra sobre o uso de IA na medicina — o que iniciou um debate sobre o avanço tecnológico e seus impactos. Parte da turma demonstrou entusiasmo, enquanto outros permaneceram mais reservados, indicando timidez ou falta de engajamento.

Após a leitura das notícias, assistimos ao vídeo “O que é IA”, que apresenta de forma acessível os usos positivos e negativos da tecnologia. A partir dele, discutimos o uso ético da IA abordando temas como campanhas eleitorais, deepfakes e desinformação.

Em seguida, apresentei os resultados do questionário aplicado via Google Forms. Quatro alunos não responderam, possivelmente por falta de interesse ou dificuldade de acesso à internet, já que muitos vivem na zona rural. As respostas mostraram que, embora a maioria afirme ter alguma noção sobre IA, apenas 28,6% compreendem seu funcionamento. Cerca de 90,5% nunca ouviram falar de RNA, mas mais de 90% demonstraram interesse em aprender mais.

Aproveitei os dados para introduzir o conceito de RNA e explicar que ela é um dos campos da IA. Mostrei a Figura 7, com os principais campos de estudo, e comparei um neurônio biológico a um neurônio artificial para facilitar a compreensão. Ressaltei que, nas próximas aulas, estudaremos o funcionamento das redes neurais e o papel da matemática nesse processo.

Figura 7. Campos de estudo da IA.



Fonte: Elaborado pela autora.

A aula despertou curiosidade, especialmente entre os meninos, mas ainda é preciso incentivar maior participação das meninas e dos alunos mais tímidos. O vídeo “História da IA” ficou como tarefa para o horário de almoço, conforme sugestão da turma.

4.3 TERCEIRA AULA: 30 DE AGOSTO DE 2024

A terceira aula novamente apresentou baixa frequência de alunos, o que pode afetar a compreensão de conceitos fundamentais, como os neurônios artificiais e suas aplicações. Conversando com outros professores, constatei que essa ausência recorrente ocorre em todas as turmas do ensino médio, resultado da insatisfação dos estudantes com o regime de tempo integral, que os mantém na escola por nove horas diárias.

Iniciei a aula lembrando que o neurônio artificial é uma simplificação do neurônio humano e utilizei imagens para ilustrar suas partes principais — dendritos, núcleo e axônio — explicando suas funções e simulando uma sinapse para demonstrar a transmissão dos impulsos nervosos. Destacou-se que as redes neurais artificiais foram inspiradas nesse funcionamento biológico, o que ajuda os alunos a compreenderem a relevância do tema.

Em seguida, apresentei a Figura 3, comparando o neurônio biológico com o neurônio artificial e definindo seus elementos: entradas, pesos, somatório, função de ativação e saída. Expliquei como cada componente contribui para o processamento da informação dentro da rede.

Depois, introduzi o conceito de funções de ativação — degrau, sigmoide e ReLU — explicando-as de forma matemática e visual por meio de slides. Inicialmente, alguns alunos demonstraram preocupação com o uso de funções, mas, após exemplos simples e comparações, mostraram-se mais confiantes.

Concluí a aula explicando que, no próximo encontro, estudaríamos o perceptron, o modelo mais simples de neurônio artificial, essencial para compreender redes mais complexas. Como atividade, os alunos receberam uma tarefa prática de cálculos envolvendo as três funções de ativação, disponível no Apêndice E do livro de Guadalupe e Aguilar (2025), com o objetivo de aplicar os conceitos estudados e compreender o impacto de cada função na saída do neurônio artificial.

4.4 QUARTA AULA - 04 DE SETEMBRO DE 2024

Na quarta aula, houve um avanço significativo na participação dos alunos. A mudança de horário para o primeiro período da tarde, resultado de uma troca com a professora de Tecnologia e Inovação que também leciona Filosofia com a mesma turma, contribuiu para melhorar a frequência, que até então era um desafio.

Com a turma completa, retomei os conceitos essenciais sobre o perceptron, reforçando que ele representa um neurônio artificial simplificado. Utilizei novamente a Figura 3 para explicar o fluxo de dados, das entradas à saída gerada pela função de ativação, e revisamos os gráficos das três funções estudadas anteriormente. Ao solicitar a entrega da tarefa prática, percebi que nenhum grupo havia concluído o trabalho, então sugeri que se reunissem nos intervalos para completá-lo, incentivando a colaboração e o aprendizado coletivo.

Avançando no conteúdo, expliquei que o perceptron é aplicável apenas a problemas linearmente separáveis e apresentei exemplos visuais com os conectivos lógicos AND e XOR. Utilizei o exemplo “quero café” e “quero leite”, resultando em “quero café com leite”, para facilitar a compreensão das combinações lógicas.

Reforcei a importância da tabela-verdade como base do raciocínio lógico, destacando sua utilidade em diversas áreas e em provas de concursos. Em seguida, mostrei que as entradas de um neurônio artificial são codificadas numericamente, atribuindo 1 para verdadeiro e 0 para falso. Aplicamos essa codificação no estudo do conectivo AND, relacionando-o ao funcionamento de uma rede perceptron.

Encerramos a aula com a previsão de aprofundar o estudo sobre o perceptron na próxima semana, consolidando o aprendizado sobre lógica e redes neurais.

4.5 QUINTA AULA - 11 DE SETEMBRO DE 2024

Na quinta aula, o objetivo foi demonstrar manualmente o funcionamento de uma rede perceptron usando o conectivo lógico AND. Expliquei que a rede seria treinada para retornar verdadeiro apenas quando todas as entradas fossem verdadeiras, reforçando a codificação padrão (1

para verdadeiro, 0 para falso). Inicialmente, sugeri pesos nulos e bias -1, destacando que, em redes mais complexas, valores de pesos idênticos podem causar problemas de simetria, mas para esta rede simplificada isso facilita o entendimento.

Utilizei uma taxa de aprendizagem de 0,4, explicando seu papel no ajuste de pesos e bias a cada discrepância entre a saída da rede e a saída esperada. Aplicamos os primeiros pares de entradas, somando produtos dos pesos pelas entradas, adicionando o bias e passando pela função de ativação degrau para determinar a saída. Quando houve erro, mostrei como reajustar pesos e bias com base na regra Delta.

Percebi que alguns alunos se dispersaram, demonstrando preferência por avançar diretamente para a programação. Reforcei a importância de compreender o processo manual para identificar pontos passíveis de automação, preparando-os para o uso do Python nas próximas aulas.

Planejei uma atividade prática em grupos para criar um perceptron para o conectivo OR, deixando instruções para reflexão e preparação da próxima aula. Observei que a primeira tarefa ainda não havia sido entregue e que os alunos não registravam anotações, dificultando o acompanhamento. Além disso, distrações como avaliações de outras disciplinas reduziram o engajamento.

Para otimizar futuras aulas, sugiro focar apenas nas atualizações de pesos e bias quando houver erro, intercalando explicações teóricas com visualizações gráficas, destacando correções significativas e antecipando a utilização de simulações digitais para acelerar o processo, mantendo o equilíbrio entre teoria e prática.

4.6 SEXTA AULA - 18 DE SETEMBRO DE 2024

Nesta aula, precisei retomar e resumir a explicação dada na aula anterior, quando utilizei um quadro para relembrar os conceitos estudados, pois nenhum dos alunos fez registros durante a última aula. Neste momento, eu tinha em mão uma síntese do processo de construção de uma RNA perceptron AND, impressa para cada um dos estudantes. Essa base era essencial para que pudessem avançar para a programação desta RNA.

Com quase todos os estudantes presentes, organizei-os em grupos para que, sob minha supervisão, iniciassem a resolução da atividade sobre o conectivo OR, a partir da análise da RNA do conectivo AND.

Entretanto, percebi novamente que os grupos enfrentaram dificuldades em manter o foco. Eles não se concentravam para ler o material de apoio que preparei para complementar o planejamento inicial, mostrando ainda uma grande dependência da minha orientação. A dispersão foi evidente, com

muitos estudantes distraídos, preocupados com a prova de biologia que teriam na aula seguinte. Infelizmente, a aula se mostrou pouco produtiva, repetindo o cenário da aula anterior.

Concluí a aula recomendando que, ao menos, lessem o material de apoio e tentassem realizar a atividade proposta. De acordo com o planejamento inicial, essa sexta aula já seria realizada no laboratório de informática para darmos início à programação, mas essa etapa precisou ser adiada para o próximo encontro.

4.7 SÉTIMA AULA - 25 DE SETEMBRO DE 2024

Na aula de hoje, trabalhei com os alunos os conceitos básicos de Python no Google Colab, com o objetivo principal de que compreendessem o conceito de perceptron e sua aplicação como modelo de neurônio artificial.

Iniciei projetando no quadro alguns códigos simples que deveriam ser reproduzidos no Colab, explicando passo a passo os comandos essenciais de Python conforme o planejamento inicial. A turma pôde acompanhar e replicar os códigos no ambiente, fazendo pequenas alterações, executando-os e observando como essas mudanças influenciavam os resultados. Essa abordagem prática reforçou o entendimento sobre entradas, saídas e a função de ativação.

Fiquei satisfeita ao ver alguns estudantes modificando outras variáveis, explorando além do sugerido e analisando as novas saídas apresentadas. Isso mostrou que, por meio da programação, eles poderiam adquirir uma compreensão sólida do funcionamento de uma RNA.

Para concluir a explicação, introduzi o conceito de função de ativação e programei três delas: degrau, sigmoide e ReLU. Projetei novamente os códigos no quadro e os enviei pelo WhatsApp para que os alunos pudessem dedicar mais tempo a explorar cada função. Posteriormente, projetei novamente os gráficos destas funções que comprovavam os resultados apresentados pela programação.

Pedi que executassem os scripts e observassem o comportamento de cada função de ativação. A tarefa inicial, proposta na terceira aula, envolvia calcular essas funções manualmente; agora, na sétima aula, os alunos repetiriam o cálculo utilizando a programação em Python. Como o cálculo manual não foi realizado anteriormente, sugeri que comparassem os resultados obtidos com os valores da tarefa e experimentassem ajustar os parâmetros para observar diferentes saídas. Assim, puderam perceber a simplicidade da execução programada e visualizar os resultados em gráficos projetados, discutindo as diferenças entre as funções.

A atividade foi bem recebida pela turma, que demonstrou grande envolvimento ao longo da aula, participando ativamente, testando o código e propondo suas próprias variações. Ao final, o interesse e o progresso dos alunos em relação aos conceitos abordados foram evidentes. Na próxima

aula, concluiremos nossas observações sobre as funções de ativação na construção de uma rede perceptron e daremos continuidade a outros conceitos essenciais para a programação da rede perceptron AND.

Durante toda a aula, mantive o foco no entendimento da lógica de programação, retomando sempre os conceitos fundamentais da construção de uma rede neural e preparando a turma para o entendimento completo da programação da RNA perceptron AND.

4.8 OITAVA AULA - 2 DE OUTUBRO DE 2024

Nesta aula, concentrei-me no entendimento da lógica de programação por trás do perceptron, destacando a importância de cada linha de código. À medida que os alunos executavam os programas e faziam ajustes, discutimos as implicações de suas modificações e como elas influenciavam o funcionamento da rede neural.

No entanto, observei que muitos estudantes se perdiam em seus códigos devido a pequenos erros, como uma indentação incorreta, a seleção inadequada de um símbolo ao

copiar, ou até mesmo um espaço extra que impedia o Colab de executar os comandos corretamente para a construção do perceptron AND. Esses problemas consumiram boa parte do tempo, não consegui avançar até o ponto em que pretendia introduzir a necessidade de redes multicamadas.

Por outro lado, no contato direto com os alunos, percebi um grande interesse em entender como tudo funciona na programação. Eles se surpreendiam com o impacto que pequenos detalhes tinham no resultado esperado. Aproveitei essa oportunidade para esclarecer a diferença e complementaridade entre programação e inteligência artificial, retomando o conceito de aprendizagem da rede. Também expliquei que, em redes mais complexas, são usadas múltiplas funções de ativação e que o objetivo final é que a rede seja capaz de tomar decisões, de forma "autônoma".

Esta aula corresponde ao planejamento da Aula 7, que incluía a Tarefa 7, descrita no Apêndice K do livro dos autores Guadalupe e Aguilar (2025). No entanto, como nenhuma das tarefas anteriores foi realizada em casa, a Tarefa 7, planejada como uma atividade complementar destinada a reforçar os conceitos de programação e RNA, não pode ser executada, pois não tínhamos tempo disponível para executá-la em sala de aula.

4.9 NONA AULA - 9 DE OUTUBRO DE 2024

Iniciamos a aula retomando o uso do Colab para revisar os códigos da rede perceptron AND e observar as saídas após duas iterações que permitiriam a convergência da rede. Reforcei a importância

do planejamento antes da programação: definir claramente o objetivo, considerar as melhores abordagens e tomar decisões fundamentadas.

Compartilhei com eles meu próprio processo de escolha de pesos e bias para o cálculo manual. Expliquei que foi um trabalho experimental, no qual testei diferentes configurações, mantendo o bias fixo em algumas tentativas, avaliando a taxa de aprendizagem ideal para acelerar o processo e ainda garantir um bom resultado. Dada a natureza manual do trabalho, optei por valores de pesos e bias aleatórios para simplificar e agilizar o processo.

Mostrei que, para adaptar o exemplo da rede AND e programar a rede perceptron OR, é preciso apenas considerar as diferenças lógicas entre esses conectivos e analisar a separabilidade dos dados. Juntos, revisamos esses pontos, fizemos as alterações necessárias nas saídas esperadas, executamos o código e discutimos os novos resultados.

Aproveitamos para esclarecer a tarefa solicitada na quinta aula: a construção manual do perceptron OR com base no perceptron AND.

De acordo com o planejamento inicial, esta nona aula seria dedicada às apresentações dos resultados dos trabalhos em grupo. No entanto, esta parte do planejamento não se concretizou como esperado, o que dificultou a avaliação do aprendizado dos estudantes, uma vez que não desenvolveram as atividades propostas.

4.10 DÉCIMA AULA - 23 DE OUTUBRO DE 2024

Nesta aula, o objetivo foi introduzir a estrutura de uma rede neural multicamadas. Começamos revisitando o conceito de uma RNA que resolve o problema do XOR, cujos dados de entrada não são linearmente separáveis, como vimos anteriormente.

O objetivo foi demonstrar aos estudantes que um perceptron de camada única tem, de fato, as limitações já mencionadas, sendo capaz de lidar apenas com dados linearmente separáveis. Em contraste, uma rede neural multicamadas é capaz de superar essas limitações, resolvendo problemas complexos que os métodos tradicionais de programação não conseguem abordar de forma eficaz.

Em continuidade, introduzi um exemplo prático de rede neural construída com dados históricos do INEP, especificamente de estudantes da nossa escola desde 2009. Mostrei a planilha do Excel com os dados consolidados: 348 linhas e 436 colunas, correspondentes às variáveis de entrada da rede.

Observei a reação dos estudantes, alguns demonstraram surpresa e até receio com o tamanho e complexidade da base de dados — o que talvez os tenha ajudado a perceber a importância da programação para esse tipo de análise. Também lhes apresentei o dicionário de variáveis do ENEM

2022, e discutimos as variáveis não quantitativas e como elas poderiam ser transformadas e utilizadas na programação.

Expliquei que, ao explorar essa grande tabela, poderíamos identificar informações específicas, como a maior e a menor nota, médias, valores modais e medianos, o que despertou bastante curiosidade na turma. No entanto, alguns alunos expressaram preocupação com a dificuldade de incluir seus próprios dados na rede e obter uma previsão preliminar de suas notas no ENEM.

Esclareci que, embora esse processo seja viável com programação, ele demanda tempo, especialmente devido à quantidade de variáveis envolvidas. Propus que, para facilitar, experimentassem construir uma rede neural com um número reduzido de variáveis, selecionando as mais relevantes. Comentei, no entanto, que uma rede tende a produzir melhores resultados quando treinada com uma maior diversidade de variáveis.

Introduzi os conceitos de dados para treinamento e dados para teste, destacando que a rede, conforme programada, oferece um bom grau de confiabilidade nas previsões. Porém, ressalté a importância de uma análise especializada para validar os resultados, considerando que meu objetivo foi apenas contextualizar o uso de tecnologias avançadas em nossa prática de aula.

Os estudantes mostraram grande curiosidade em relação à programação da rede, embora inicialmente tenham ficado intimidados com a quantidade de códigos. Eles ficaram eufóricos ao vislumbrar a possibilidade de prever resultados de provas, como as do ENEM, antes mesmo de realizá-las. Os mais otimistas se empolgaram com a ideia dessas previsões, enquanto outros, que se sentiram desmotivados desde o início da sequência didática, consideraram o conteúdo muito complexo.

Reforcei, mais uma vez, que este era apenas o primeiro contato deles com programação e redes neurais e que, com a continuidade dos estudos, esses conceitos certamente se tornariam mais familiares e práticos, sendo assimilados com mais naturalidade.

Finalizei explicando que, no próximo e último encontro, faríamos uma revisão rápida dos principais tópicos abordados, sintetizando tudo o que discutimos ao longo das aulas.

4.11 AULA 11 - 30 DE OUTUBRO DE 2024

Nesta última aula da sequência didática, iniciei abrindo espaço para que os alunos compartilhassem suas percepções e experiências ao longo deste IF em Tecnologia e Inovação. De modo geral, eles expressaram que, embora considerem o tema interessante e necessário, também o veem como muito complexo e desafiador.

Alguns até afirmaram não ter afinidade com esses estudos. Aproveitei para relatar minha própria trajetória, lembrando-lhes que, no início, também encontrei dificuldades em programação e no

entendimento de redes neurais — uma área que, em um primeiro momento, parecia distante e inatingível para mim. Ressaltei, porém, a importância de persistirmos: a tecnologia avança rapidamente e, embora o aprendizado demande esforço, é uma habilidade essencial para nos mantermos atualizados.

Em seguida, compartilhei um link que elabora uma ‘nuvem de palavras’ e pedi que resumissem suas experiências em três palavras, incluindo emoções, aprendizados e desafios enfrentados ao longo do curso. Com as palavras escolhidas, construímos juntos a nuvem de palavras, que projetei no quadro.

Ao ler algumas delas, confesso que senti um leve desapontamento ao ver expressões como "não gosto", "cansativo", "confuso", "sono". Porém, senti também satisfação ao notar que as palavras "interessante", "difícil", foram as que mais se destacaram, indicando que, apesar dos desafios, a turma reconheceu o valor do aprendizado, como é possível observar a partir da Figura 7.

Para concluir, reafirmei que este foi apenas o primeiro contato com uma área nova e desafiadora, e que é natural encontrar obstáculos. Encorajei-os a continuar explorando, mantendo a curiosidade e a disposição para o aprendizado, pois a jornada tecnológica é longa, mas gratificante. Finalizamos com uma breve revisão das principais etapas que percorremos juntos, reforçando a importância do esforço contínuo e da resiliência em um campo que oferece inúmeras oportunidades para quem se dispõe a aprender.

Figura 7. Percepções dos alunos sobre a sequência didática aplicada.



Fonte: Elaborada pela autora.

5 CONSIDERAÇÕES FINAIS

A proposta de integrar a MM e as RNA no EM, com o objetivo de desenvolver o PCO, mostrou-se desafiadora e promissora ao mesmo tempo. A sequência didática, implementada ao longo de onze

aulas, permitiu que os alunos do 3º ano da EECXC tenham um primeiro contato com conceitos fundamentais de IA e RNA, conectando-os ao conteúdo matemático e tecnológico de forma teórica e prática.

Uma das maiores contribuições da matemática para esse trabalho foi a modelagem das funções de ativação, que proporcionou uma melhor compreensão do funcionamento das redes neurais.

Quando os alunos observaram o processo manual de construção da RNA, eles não apenas repetiram cálculos, mas também buscaram padrões, permitindo de forma natural o desenvolvimento do PCO. Esse processo os preparou para a próxima etapa: a programação das redes neurais, uma vez que entender as repetições e padrões é um caminho direto para a implementação algorítmica.

Ensinar conceitos complexos, como redes neurais e programação, para alunos de EM é desafiador, e suas dificuldades já eram esperadas. Isso, por si só, é uma contribuição importante ao campo da educação, pois revela o que funciona e o que ainda precisa ser ajustado para abordar temas complexos em contextos escolares.

Desde a primeira aula, ficou claro que os estudantes tinham pouco ou nenhum conhecimento prévio sobre IA e RNA, o que era esperado. No entanto, eles demonstraram interesse em estudar esses conceitos. Vídeos, diagramas e exemplos comparativos entre neurônios biológicos e artificiais foram fundamentais para facilitar a compreensão de termos técnicos como neurônio, funções de ativação e perceptron.

Contudo, a falta de uma base sólida ou mesmo interesse em matemática causou, em diversos momentos, uma certa insegurança entre os alunos, dificultando a participação ativa. Essa lacuna impactou diretamente a compreensão de conceitos mais avançados, como a aplicação das funções de ativação e o reajuste de pesos nas redes neurais, tornando o ritmo de aprendizado mais lento. Por outro lado, a curiosidade em relação à IA gerou interesse natural pela discussão, apesar de alguns tópicos apresentarem maior dificuldade de compreensão.

Diante da percepção de que alguns estudantes tiveram dificuldade em compreender conceitos fundamentais das RNA é importante ressaltar que a matemática utilizada nas atividades foi bastante simples e poderia ser aplicada em qualquer turma do EM, do primeiro ao terceiro ano. Os cálculos envolvidos foram acessíveis e compatíveis com o nível de ensino, sendo planejados de modo a não sobrecarregar os alunos com fórmulas complexas.

A dificuldade, portanto, não esteve na complexidade matemática, mas na aceitação e familiaridade com a disciplina. Isso evidencia a necessidade de um maior investimento na construção de uma base matemática consistente ao longo do ensino básico, de forma a garantir que os alunos

estejam mais preparados para enfrentar desafios que envolvam aplicações tecnológicas, como RNA. Uma possibilidade é a introdução do PCO desde o ensino fundamental, como já configurado na BNCC.

Momentos de entusiasmo foram especialmente evidentes entre os alunos que fazem parte da equipe de assistência tecnológica da escola, que se engajaram com mais facilidade nas discussões. No entanto, a não adesão às tarefas externas indicou a necessidade de repensar as estratégias de incentivo e avaliação. Fatores como o acesso limitado à internet e a falta de tempo para atividades complementares sugerem que a adaptação ao contexto dos alunos, especialmente aqueles da zona rural, poderia melhorar o engajamento.

A coleta de dados, por meio de questionários sobre o conhecimento prévio e o interesse dos alunos, gerou informações valiosas. A pesquisa revelou que a maioria dos estudantes nunca havia ouvido falar de redes neurais artificiais, mas demonstrou curiosidade em aprender mais sobre o tema. As respostas à pergunta: Você faz uso da inteligência artificial no seu dia a dia? Conte-me quando ou como, destacaram uma clara insegurança quanto ao entendimento desse tópico tão atual, revelando o quanto ele ainda é pouco compreendido. Esse resultado reforça a necessidade de continuar explorando o tema em sala de aula, contextualizando seu uso prático e ético, e evidenciando sua importância no cotidiano e no cenário global.

Outro desafio observado foi a tendência dos alunos em priorizar disciplinas que exigem avaliação formal, o que afetou diretamente o engajamento com a sequência didática. Em alguns momentos, metade da turma estava concentrada em cadernos de química ou biologia, preocupada com as avaliações dessas disciplinas.

Isso levanta questionamentos sobre a adequação dos IF para a aplicação dessa sequência didática, já que muitos alunos concentram seus esforços nas matérias que consideram mais importantes para sua aprovação. Esse cenário reforça a necessidade de repensar o ambiente e o contexto em que a sequência didática é aplicada.

Além disso, foi necessário ajustar os horários de aula com a turma para aumentar a frequência dos alunos. Após conversar com outros professores e supervisores, percebi que a baixa frequência é um problema recorrente no NEM. Muitos alunos recebem autorização familiar para sair mais cedo ou faltam às aulas sem justificativa, devido à dificuldade de se adaptarem à carga horária exigida. Isso destaca a importância de encontrar soluções que equilibrem as exigências curriculares com a realidade dos estudantes, para que o aprendizado ocorra de maneira eficaz e motivadora.

A integração de temas inovadores, como IA e RNA, ao conteúdo de matemática e tecnologia desperta o interesse dos estudantes e os conecta a questões contemporâneas, preparando-os para desafios futuros, tanto acadêmicos quanto profissionais. Apesar das dificuldades, a sequência didática

foi uma oportunidade para os alunos exercitarem a resiliência, que é fundamental para o aprendizado em áreas técnicas.

Por fim, as considerações para o aprimoramento deste projeto incluem o fortalecimento das estratégias de participação e engajamento dos alunos, o ajuste das atividades práticas para garantir maior adesão e a continuidade do uso de recursos visuais e analogias que facilitem a compreensão dos conceitos técnicos.

Para os alunos do ensino integral, uma alternativa seria incluir aulas específicas para o desenvolvimento de atividades em grupo, que nesta sequência foram designadas como tarefas para casa. Outra possibilidade seria eliminar as tarefas manuais e, após a demonstração do processo manual, focar diretamente na programação, solicitando que todos os cálculos e experimentos fossem realizados no Google Colab.

No entanto, para que isso fosse eficaz, os estudantes precisariam primeiro identificar claramente os padrões de repetição que possibilitariam a programação da rede. Além disso, a introdução de quizzes como forma de avaliação ao longo da sequência pode incentivar a reflexão e a busca pelo conhecimento, substituindo as atividades escritas que os alunos não aceitam bem. Essas estratégias, porém, demandariam mais tempo e mais aulas, o que infelizmente não se encaixou no cronograma disponível.

Outra possibilidade para fomentar a participação dos alunos nas atividades próprias desta sequência é através de projetos, em que os alunos que gostariam de trilhar o ensino superior em áreas relacionadas a matemática aplicada ou ciências da computação, sejam escolhidos.

Finalmente, com esse trabalho, os autores esperam ter contribuído e incentivado a abordagem das RNA desde o EM, em vista que esse conhecimento está impactando os ambientes de trabalho, de ensino, gestão, entre outros, de maneira crescente e desafiadora.

REFERÊNCIAS

ALMEIDA, R. S. d. et al. Itinerários formativos no novo ensino médio e os desafios para a educação no Brasil. *IOSR Journal of Humanities and Social Science (IOSR-JHSS)*, v. 29, n. 3, Series 4, p. 37–42, 2024. Disponível em: <<https://doi.org/10.9790/0837-2903043742>>.

BASSANEZI, R. C. *Ensino-aprendizagem com modelagem matemática: uma nova estratégia*. São Paulo: Unicamp, 2002.

BRASIL. Lei nº 13.415, de 16 de fevereiro de 2017. <http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2017/lei/113415.htm>.

BURAK, D. Modelagem matemática sob um olhar de educação matemática e suas implicações para a construção do conhecimento matemático em sala de aula. *Revista de Modelagem na Educação Matemática*, v. 1, n. 1, p. 10–27, 2010. Disponível em: <<https://mid-educacao.curitiba.pr.gov.br/2017/10/pdf/00156542.pdf>>.

COLLE, J. E.; RODRIGUES, W. M.; SILVA, W. R. da. Redes neurais artificiais: ideias básicas no ensino médio. *Brazilian Journal of Development*, v. 8, n. 3, p. 21795–21810, 2022. Disponível em: <<https://doi.org/10.34117/bjdv8n3-399>>.

COSTA, A.O; JUNIOR, E. F. Utilização das Redes Neurais Artificiais com Estímulo ao Aprendizado de Matemática. *Enciclopédia Biosfera*. v.10, n. 9, p. 2567-2580, 2014. <https://www.researchgate.net/publication/319162808_UTILIZACAO_DE_REDES_NEURAIIS_ARTIFICIAIS_COMO_ESTIMULO_AO_APRENDIZADO_DE_MATEMATICA>.

Data Science Academy. Uma breve história das redes neurais artificiais. Disponível em: <<https://www.deeplearningbook.com.br/uma-breve-historia-das-redes-neuraisartificiais/>>.

Deep Learning Book Brasil. Função de Ativação. 2025. Disponível em: <<https://www.deeplearningbook.com.br/funcao-de-ativacao/>>.

FURTADO, M. I. V. *Redes neurais artificiais: uma abordagem para sala de aula*. Ponta Grossa, PR: Atena Editora, 2019.

GUADALUPE, M. I; AGUILAR, J, C. *Inteligência Artificial no Ensino Médio: Desenvolvendo o Pensamento Computacional através da Rede Neural Perceptron*. São José dos Pinhais: Editora Seven, 2025.

HAYKIN, S. *Redes neurais: princípios e prática*. Porto Alegre: Editora Bookman, 2001.

Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. *Publicados resultados preliminares do Censo Escolar 2023*. 2023. Disponível em: <<https://www.gov.br/inep/pt-br/assuntos/noticias/censo-escolar/publicadosresultados-preliminares-do-censo-escolar-2023>>.

Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. *Divulgados os resultados do PISA 2022*. 2023. Disponível em: <<https://www.gov.br/inep/pt-br/assuntos/noticias/acoes-internacionais/divulgados-os-resultados-do-pisa-2022>>.

Ministério da Educação. Base Nacional Comum Curricular: Ensino Médio - Matemática. 2018. Disponível em: <<http://basenacionalcomum.mec.gov.br/>>.

NARANJO, J. F. L. Inteligência computacional aplicada na geração de respostas impulsivas bi-auriculares e em aurilização de salas. Dissertação (Mestrado) — Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2014.

OLIVEIRA, C. R.; SILVA, M. L. A inteligência artificial no ensino: personalização e acessibilidade para o século xxi. Cadernos Uninter de Práticas Educativas, v. 10, n. 2, p. 45–56, jul 2022. Disponível em: <<https://www.cadernosuninter.com/index.php/intersaberes/article/view/2964/2145>>.

PEREIRA, L. E. Contribuições da modelagem matemática para o desenvolvimento de habilidades de resolução de problemas no ensino médio. 2023. Disponível em: <<https://www.btdt.ueg.br/handle/tede/1462>>.

RUSSELL, S.; NORVIG, P. Inteligência Artificial: Uma Abordagem Moderna. 3. ed. Rio de Janeiro: Campus Elsevier, 2016. Tradução da obra original Artificial Intelligence: A Modern Approach.

Sociedade Brasileira de Matemática. Redes neurais no ensino básico. 2022. Disponível em: <https://pmo.sbm.org.br/wp-content/uploads/sites/5/sites/5/2022/09/art32_vol10_SBM_PMO_2022.pdf>.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Editora Artliber, 2010.

SILVA, E. F. Itinerários formativos no novo ensino médio: maiores oportunidades ou aligeiramento da formação? Projeção e Docência, v. 15, n. 1, p. e1524DO08, 2018. Disponível em: <<https://projecaociencia.com.br/index.php/Projecao3/article/view/2389>>.

WING, J. Pensamento computacional: um conjunto de atitudes e habilidades que todos, não só cientistas da computação, ficaram ansiosos para aprender e usar. Revista Brasileira de Ensino de Ciência e Tecnologia, v. 9, n. 2, 2016.