

# Desenvolvimento de um Objeto de Aprendizagem Digital para o Ensino de Redes Neurais Artificiais

Ângelo Magno de Jesus<sup>1</sup>, Hugo de Melo Teodoro<sup>1</sup>

<sup>1</sup>Instituto Federal de Minas Gerais - *campus* Ouro Branco

angelo.jesus@ifmg.edu.br, hugomteodorol@gmail.com

**Abstract.** *Despite the countless applications of Machine Learning in society, teaching its concepts to students may not be a simple and trivial task. This study presents the IAprender Digital Educational Object aimed at teaching Artificial Neural Networks (ANNs) to high school and undergraduate students. Through the artifact, students can apply and explore ANN concepts by visualizing its internal functioning in an interactive way and analyzing a practical application related to their daily lives in a playful way. Finally, the artifact was evaluated by students in a survey applied after an expository class. The results demonstrated that the proposed system is promising to fulfill its goal.*

**Resumo.** *Apesar das inúmeras aplicações da Aprendizagem de Máquina na sociedade, ensinar seus conceitos para estudantes pode não ser uma tarefa simples e trivial. Este estudo apresenta o Objeto Educacional Digital IAprender voltado para o ensino de Redes Neurais Artificiais (RNAs) para estudantes de ensino médio e superior. Por meio do artefato, estudantes podem aplicar e explorar conceitos de RNA visualizando seu funcionamento interno de forma interativa e analisando uma aplicação prática relacionada com o seu dia-a-dia de forma lúdica. Por fim, o artefato foi avaliado por estudantes em um questionário aplicado após uma aula expositiva. Os resultados demonstraram que o sistema proposto é promissor para cumprir seu objetivo.*

## 1. Introdução

Os produtos e aplicações técnicas da Ciência da Computação estão amplamente presentes no cotidiano das pessoas. Em especial, a aplicação de Aprendizagem de Máquina ou *Machine Learning* (ML), subcampo da Inteligência Artificial (IA), está cada vez mais presente nos aplicativos de dispositivos móveis, nas redes sociais, nos videogames, na produção industrial, nos veículos automatizados e em muitas outras tecnologias presentes na sociedade. Esta presença impacta diretamente a forma como as pessoas irão conduzir suas vidas [Senac 2024]. Neste sentido, o divulgador científico Carl Sagan defendia a ideia de que se tem uma sociedade altamente dependente de Ciência e Tecnologia, mas em que quase ninguém entende o que é Ciência e Tecnologia [Sagan 2011]. No entanto, o ensino de conceitos de IA pode não ser uma atividade simples e trivial, mesmo em cursos superiores. Os Referenciais de Formação da SBC [Calsavara et al. 2017] para Ciência da Computação inserem a disciplina de Inteligência Artificial como parte do eixo de resolução de problemas complexos. Além disso, técnicas de ML podem envolver aplicações interdisciplinares de conceitos científicos e matemáticos.

Dado o problema de se ensinar conceitos de ML, este artigo tem como objetivo propor o desenvolvimento do Objeto Educacional Digital IAprender. O artefato foca no ensino de conceitos de Redes Neurais Artificiais (RNAs), do tipo *Multi Layers*

*Perceptrons*, de uma forma lúdica e interativa. O objetivo do software é ensinar o modelo matemático, modo de funcionamento da estrutura interna e arquitetura de RNAs por meio de experiências interativas relacionadas a um exemplo prático do dia-a-dia. O público alvo principal do sistema consiste em estudantes do último ano do ensino médio, para realização de atividades de desenvolvimento do Pensamento Computacional [Barr e Stephenson 2011], e estudantes iniciais de cursos superiores de Ciência da Computação e outras ciências consideradas como exatas. O objeto de aprendizagem foi validado com um grupo de estudantes e demonstrou ser uma ferramenta promissora para introduzir conceitos de RNAs e ML.

## **2. Fundamentação Teórica**

### **2.1. Ensino de Inteligência Artificial e Aprendizado de Máquina**

Nadzinski et al. (2022) relatam que há uma crescente importância do ensino de temas como Aprendizado de Máquina e Inteligência Artificial em diferentes níveis de ensino. No entanto, é preciso observar que o ensino de conceitos de ML pode ser um desafio, mesmo no ensino superior, dado a própria complexidade subjacente a este campo de estudo. Isto pode ser evidenciado devido à própria definição da disciplina que se trata de uma sub-área da Inteligência Artificial que se concentra em estudar algoritmos que permitem que computadores aprendam. Neste sentido, um algoritmo de ML deve receber um conjunto de dados e inferir informações sobre as propriedades destes dados possibilitando que ele faça previsões sobre outros dados que ele pode encontrar no futuro [Segaran 2008]. Isto pode envolver a utilização de diferentes técnicas que envolvem variados conceitos da matemática, estatística e biologia além do próprio campo de Projeto e Análise de Algoritmos da Ciência da Computação. No contexto do ensino superior, os Referenciais de Formação da SBC para Ciência da Computação [Calsavara et al. 2017] recomendam que o ensino de Ciência da Computação, incluindo Inteligência Artificial, deve ser centrado no aluno, envolvendo metodologias ativas de aprendizagem quando aplicável. O professor deve apresentar as aplicações dos conceitos teóricos e deve atuar como um mediador estimulando a competição, a comunicação, provocando a realização de trabalho em equipe, motivando os alunos para os estudos e orientando o raciocínio.


Marques et al. (2020) relatam que apesar da tradição do ensino de Aprendizado de Máquina se dar nos cursos superiores, é possível observar um recente movimento de inclusão desse tema também na educação básica ao redor do mundo. Neste sentido, os autores apresentam um mapeamento sistemático sobre o ensino de Aprendizado de Máquina na Educação Básica. Conforme os pesquisadores, Muitas Unidades Instrucionais (UIs) abordam o tópico de redes neurais de forma teórica e/ou por meio de aplicações práticas. Entretanto, algumas UIs apenas focam em promover um entendimento genérico dos mecanismos sobre o tema e suas aplicações. Também segundo os autores, a maioria das abordagens envolve o ensino de apenas um algoritmo de Aprendizado de Máquina apresentando um exemplo, uma demonstração ou atividades práticas. De forma geral, as UIs usam seus esforços para demonstrar a aplicação de ML na prática, apresentando vários exemplos para obter a atenção dos estudantes [Marques et al. 2020]. Ainda no contexto do ensino básico, Sanusi et al. (2023) conduziram uma revisão sistemática da literatura com o objetivo de

entender o ensino e aprendizado de ML na educação K12. Em suas conclusões, os autores relatam que mais recursos de ensino de ML são necessários para a educação básica e ambientes informais; que mais estudos precisam ser realizados sobre como a ML pode ser integrada em outros domínios que vão além da computação; que a maioria dos estudos se concentra em questões pedagógicas, sendo frágeis no que diz respeito a programas de desenvolvimento profissional de professores; e que mais evidências de implicações sociais e éticas devem ser consideradas em pesquisas futuras.

## 2.2. Aprendizado de Máquina com Redes Neurais Artificiais

O conceito de Aprendizado de Máquina e Redes Neurais é extremamente amplo, portanto neste artigo serão descritos apenas os conceitos que poderão contextualizar o desenvolvimento e aplicação do Objeto de Aprendizagem Digital proposto. As RNAs são técnicas de Aprendizagem de Máquina geralmente utilizadas para classificação de dados. Como o nome sugere, esta técnica é inspirada no funcionamento das células denominadas neurônios presentes no sistema nervoso de seres vivos.

O modelo de RNA desenvolvido foi baseado na descrição da técnica apresentada por Floriano e Nolfi (2000). A Figura 1 ilustra uma abstração de uma RNA do tipo *Feedforward* que se trata de uma estrutura dividida em camadas.



**Figura 1. modelo de uma RNA conforme Floriano e Nolfi (2000)**

Esta abstração em específico diz respeito a um modelo de três camadas. A camada inferior abriga as unidades de entrada de tamanho  $m$ :  $\{x_1, x_2, \dots, x_m\}$ , a camada central diz respeito às unidades ocultas de tamanho  $n$ :  $\{h_1, h_2, \dots, h_n\}$ , e a camada de saída engloba as unidades de saída de tamanho  $p$ :  $\{y_1, y_2, \dots, y_p\}$ . Além disso, as unidades de entrada estão conectadas com as unidades ocultas por meio das arestas ponderadas  $\{v_{1,1}, v_{1,2}, \dots, v_{n,m}\}$  e as unidades ocultas estão conectadas com as unidades de saída por meio das arestas ponderadas  $\{w_{1,1}, w_{1,2}, \dots, w_{p,n}\}$ .

Conforme um padrão de entrada  $u$ , a classificação pode ser realizada pela seguinte forma:

Dado um vetor de entrada  $\{x_1, x_2, \dots, x_k\}$ , calcular os valores das unidades ocultas pela equação:

$$h_j^u = f\left(\sum_{k=1}^m v_{j,k} x_k^u\right)$$

Sendo  $f$  a função de ativação da RNA. Desta forma,  $f$  pode ser uma função linear, escada (binária) ou senóide.

Computar os valores das unidades de saída:

$$y_i^u = f\left(\sum_{j=1}^n w_{i,j} h_j^u\right)$$

O resultado da classificação será dado pelos valores calculados na camada de saída.

O treinamento da rede pode ser realizado pela técnica de retropropagação (*back-propagation*). Este algoritmo calcula a contribuição de erro nas unidades ocultas transmitindo o erro delta das unidades de saída de volta para as unidades ocultas através das conexões ponderadas. Neste sentido, dado um padrão de treinamento  $s$  (que também representa uma entrada  $u$ ), realizar a atribuição:

$$x_k^u = s_k^u$$

Calcular  $h_j^u$  e  $y_i^u$  conforme as equações já demonstradas anteriormente. Calcular também o padrão de ensino  $t_i^u$ , que representa o resultado almejado, também pelas mesmas equações.

Calcular o erro delta para cada unidade de saída:

$$\delta_i^u = f'\left(\sum_{j=1}^n w_{i,j} h_j^u\right) (t_i^u - y_i^u)$$

Calcular o erro delta para cada unidade oculta:

$$\delta_j^u = f'\left(\sum_{k=1}^m v_{j,k} x_k^u\right) \sum_{i=1}^p w_{i,j} \delta_i^u$$

Computar as modificações nos pesos sinápticos das duas camadas:

$$\Delta w_{i,j}^u = \delta_i^u h_j^u$$

$$\Delta v_{j,k}^u = \delta_j^u x_k^u$$

Por fim, atualizar os pesos das arestas adicionando a proporção  $\eta$  (que representa a taxa de aprendizagem) aos seus valores:

$$w_{i,j}^t = w_{i,j}^{t-1} + \eta \Delta w_{i,j}^u$$
$$v_{j,k}^t = v_{j,k}^{t-1} + \eta \Delta v_{j,k}^u$$

### 3. Trabalhos Relacionados

A atenção por parte de pesquisadores para desenvolver estudos relacionados ao ensino de Aprendizagem de Máquina parece ter aumentado nos últimos anos. O estudo apresentado por Estevez et al. (2019) utiliza o framework use-crie-modifique para introduzir conceitos de ML para estudantes do ensino médio. Neste sentido, os pesquisadores desenvolveram uma estrutura de código base, na plataforma Scratch, de uma RNA (para reconhecer o operador lógico AND) e da técnica K-Médias. Os alunos poderiam programar parcialmente esta base de código e explorar o comportamento dos algoritmos. Cabe observar que este artigo se difere do estudo de Estevez et al. (2019) por apresentar uma RNA com uma estrutura mais elaborada que se foca no entendimento das operações para reconhecimento de expressões de sentimento. Em um sentido similar, Kahn et al. (2018) apresentam uma abordagem que utiliza uma linguagem de programação em blocos, chamada Snap!, para ensinar conceitos de ML para crianças. A linguagem usada possui funções de computação em nuvem para suporte à Inteligência Artificial. O estudo incluiu atividades de programação para reconhecimento de fala e de conteúdo de imagens. No entanto, o trabalho envolveu uma alta abstração dos conceitos de ML se focando mais nas entradas e saídas do que nas estruturas internas do sistema.

Cardozo et al. (2022) propõem o curso online ML4Teens para ensinar ML no Ensino Médio brasileiro. O curso foi projetado para poder ser aplicado de forma interdisciplinar tendo seu conteúdo programático incluído na área de biologia. Como material didático principal, os autores utilizaram apresentações interativas e vídeos. Entre os resultados, os pesquisadores relataram que o design atrativo, exemplos e os vídeos que expõem o conteúdo de forma interativa foram citados como os pontos fortes na avaliação do curso. Em uma situação similar, Karalekas et al. (2023) descrevem ferramentas de Robótica Educacional para ensinar ML para crianças. Os autores também propõem um conjunto de diretrizes conceituais para o ensino de ML com robótica baseado no construtivismo.

No contexto do ensino superior, Jovanović et al. (2023) apresentam a NNeduca, um software de simulação projetado para ensinar aos alunos de graduação os conceitos fundamentais de RNAs. O sistema permite que os estudantes explorem conceitos como definições, topologias, métodos de treinamento e estrutura de RNAs. Também neste sentido, Smilkov e Carter (2024) desenvolveram a plataforma de código aberto *Tensorflow Playgorund*. A plataforma permite a visualização e simulação de uma RNA. O software possibilita que usuários manipulem livremente a estrutura e parâmetros da Rede Neural, podendo testar diferentes entradas para avaliar diferentes saídas.

Por fim, apesar dos estudos apresentados nesta seção buscarem aperfeiçoar o ensino de técnicas de ML, ainda é possível notar que ainda há lacunas a serem exploradas neste assunto. Neste sentido, este trabalho se diferencia das demais pesquisas por apresentar um objeto de aprendizagem digital com o potencial de ensinar a estrutura

interna de RNAs e seu funcionamento, para estudantes do ensino médio e iniciantes em cursos superiores, de forma interativa e lúdica por meio de um exemplo prático que pode se encaixar em seus cotidianos e não se limita em trabalhar apenas com questões matemáticas abstratas.

#### 4. Metodologia

Em resumo, o desenvolvimento do objeto de aprendizagem seguiu as seguintes etapas:

- A. Identificação das necessidades e justificativas para o desenvolvimento do artefato proposto.
- B. Estudo do referencial teórico a respeito de Aprendizado de Máquina e Educação em Ciência da Computação.
- C. Desenvolvimento de um protótipo de baixa fidelidade do objeto de aprendizagem.
- D. Modelagem do sistema.
- E. Codificação do Objeto de Aprendizagem Digital
- F. Validação do artefato desenvolvido e retorno às etapas anteriores se necessário.

As etapas A e B foram descritas nas seções anteriores deste artigo. Durante a etapa C foi realizado o processo de design da interação do artefato. Neste sentido, foi desenvolvido um protótipo de baixa fidelidade com o objetivo de se introduzir/ensinar conceitos de classificação e aprendizagem de máquina por meio de RNAs de forma lúdica e simples. O projeto levou em consideração o modelo de RNA descrito na seção de referencial teórico deste artigo para reconhecimento de emoticons - que são elementos comuns na cultura digital. A utilização deste protótipo poderia indicar se o artefato poderia ser viável no ensino destas técnicas de Inteligência Artificial. A Figura 2 ilustra o protótipo inicial desenvolvido. Portanto, este rascunho foi utilizado em aulas de IA, em um curso de Bacharelado em Sistemas de Informação, para respaldar a possibilidade de aplicação do sistema (a ser desenvolvido) em sala de aula.

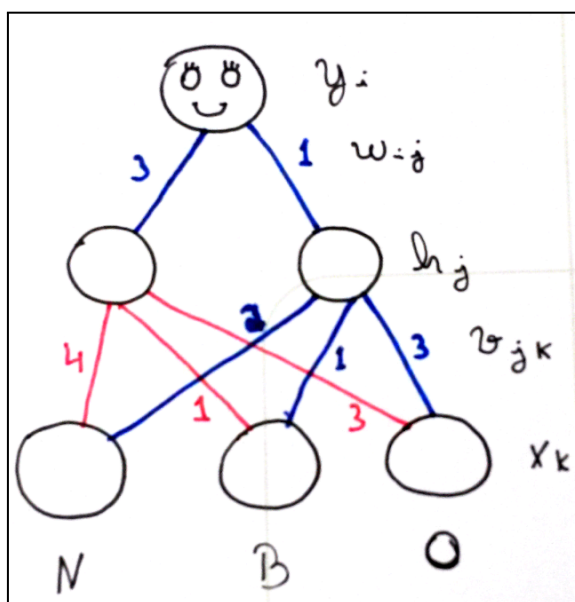


Figura 2. Protótipo de Baixa Fidelidade do Objeto de Aprendizagem

O design foi desenvolvido para se tentar atender os seguintes requisitos definidos para o sistema:

- a) Possibilitar que os estudantes testem diferentes entradas e observem as saídas para entenderem como funciona o conceito de classificação de dados e o funcionamento geral de uma RNA.
- b) Possibilitar a visualização do funcionamento interno da RNA. Neste sentido, permitir a observação dos cálculos e variáveis envolvidos no processo (em tempo real) de acordo com as entradas definidas pelos alunos. Esta questão deveria ser viável tanto para realizar a classificação quanto para realizar o treinamento.
- c) Permitir atender os requisitos anteriores de forma menos abstrata - portanto, por meio de exemplos visuais, que refletem a realidade, contextualizados na vida do aluno. Cabe observar que muitos exemplos de RNA encontrados em livros didáticos são muito abstratos utilizando entradas e saídas numéricas que não se aproximam da realidade dos estudantes.
- d) Permitir atender os requisitos anteriores de forma lúdica e interativa.
- e) Possuir código fonte aberto para que estudantes com conhecimento em programação possam aprender implementando novas funcionalidades.

Conforme o projeto, foi definido que o objeto educacional utilizaria o rosto de um personagem (no estilo “emoticon”) que poderia expressar diferentes sentimentos como entrada. O software deve permitir que os estudantes escolham diferentes configurações de expressões faciais na boca, olhos e sobrancelhas para reconhecer sentimentos de felicidade, tristeza ou neutralidade. Uma vez que os conceitos matemáticos envolvidos neste tipo de classificador podem ser muito complexos para estudantes iniciantes, para facilitar o entendimento dos cálculos, a estrutura da RNA não deveria conter um número muito elevado de elementos. Por outro lado, a estrutura deveria permitir uma aplicação que fosse próxima da realidade. Desta forma, a RNA foi modelada em três camadas: a primeira apresentando três unidades de entrada, a segunda contendo duas unidades ocultas e a última apresentando apenas uma unidade de saída. Neste sentido, as unidades de entrada representam as expressões faciais já mencionadas enquanto que a unidade de saída representa a classificação da emoção geral do rosto do personagem.

Tendo em mãos o protótipo inicial, a etapa de modelagem do sistema foi iniciada. Desta forma, foram definidos diagramas de casos de uso, diagramas de classes e arquitetura do sistema. Neste sentido, foi adotado o padrão Model-View-Controller (MVC) que define uma arquitetura em camadas. Portanto, o sistema foi modelado nas camadas de 1. Interface com usuário (*View*), 2. Lógica de aplicação (*Controller*) e 3. modelo de dados (*Model*), como sugere o padrão MVC.

Na etapa de avaliação, o software foi apresentado, por meio de uma aula expositiva, para um grupo de estudantes do curso Bacharelado em Sistemas de Informação que ainda não tinha passado pelas aulas de Inteligência Artificial. Após a demonstração, os estudantes foram solicitados a responder um questionário (no modelo Likert) contendo as seguintes questões:

1. A plataforma é de fácil entendimento e manipulação?
2. O contexto dos cálculos está bem explicado ao longo do sistema?

3. Na sua opinião, o sistema tem potencial para ajudar alunos a entenderem mais facilmente o funcionamento de uma RNA?
4. O sistema trata o tema de forma lúdica e didática?
5. Conseguiu abstrair os conceitos básicos e definições de uma RNA e de como seus parâmetros influenciam seus resultados?
6. Conseguiu entender o potencial de uma RNA e em que ela pode ser aplicada?
7. Baseando-se na atividade, poderia ter ideias de outras aplicações que utilizam RNA?
8. Achou o sistema útil e proveitoso para o ambiente acadêmico?
9. Se você tiver acesso ao código fonte do sistema, ele poderia ser útil para você consultar, estudar e desenvolver sua própria aplicação?

## 5. O Sistema IAprender

### 5.1. Módulo Principal: Classificador

O objeto de aprendizagem digital desenvolvido visou atender os requisitos definidos na seção de metodologia. A Figura 3 ilustra a interface gráfica do software desenvolvido.

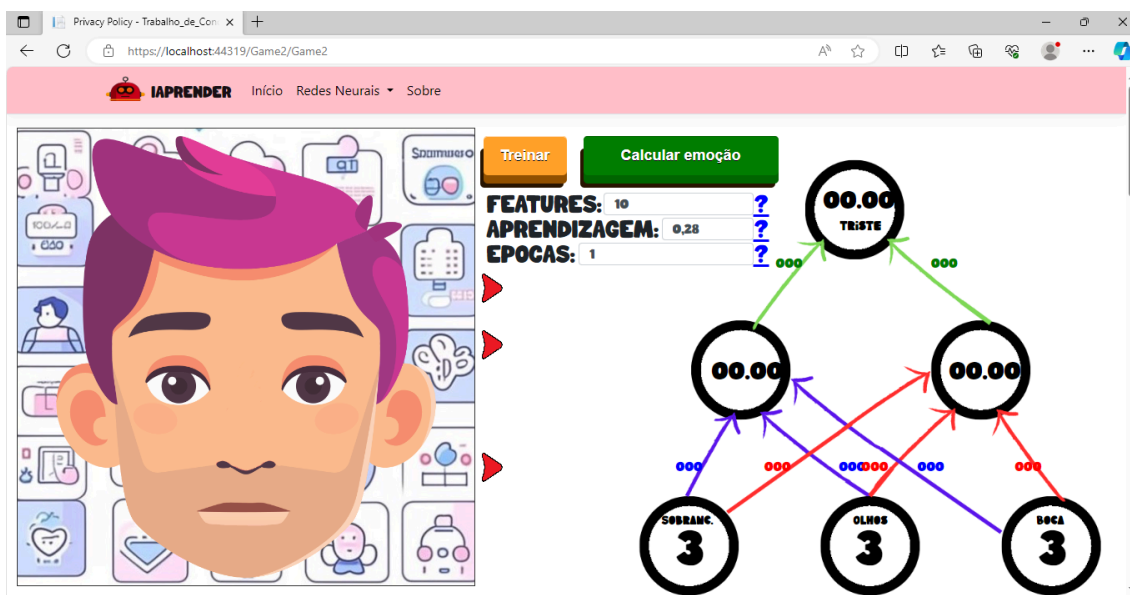


Figura 3. Interface principal do IAprender

Como pode ser observado na Figura 3, o software permite que, de forma interativa, os usuários selecionem diferentes expressões de sobrancelhas, olhos e boca. À medida que o usuário seleciona estes itens a face do personagem vai se alterando. Ao se modificar estas expressões, as entradas da Rede Neural, representada visualmente à direita, também têm seus valores alterados. Os resultados dos cálculos da rede neural são apresentados de maneira interativa e em tempo real, proporcionando uma visão detalhada do processamento que está ocorrendo na plataforma. Os usuários podem observar como as mudanças nos parâmetros afetam diretamente os resultados, promovendo uma aprendizagem prática e dinâmica.



O objeto de aprendizagem oferece a flexibilidade desejada, permitindo que os usuários ajustem os parâmetros da rede neural de acordo com suas preferências. Neste sentido, na parte superior central da janela, os usuários poderão configurar os valores de *features*, épocas e a taxa de aprendizagem. Essa capacidade de parametrização personalizada tem a intenção de promover a exploração e compreensão mais aprofundada dos conceitos subjacentes.

## 5.2. Módulo Extrator de Características

Uma das questões que pode causar dúvidas nos estudantes diz respeito à extração das características da imagem para gerar a entrada da RNA. Tratar esta entrada apenas como um vetor numérico exclui o entendimento da abstração e dos algoritmos envolvidos nesta importante etapa. Neste sentido, o módulo extrator de características foi desenvolvido para possibilitar que os alunos entendam como este processo funciona de forma relativamente simples, interativa e lúdica.

Desta forma, o módulo é capaz de ler uma imagem, representando um elemento facial do emoticon (boca, olhos ou sobrancelhas), fornecida pelo usuário. Os próprios estudantes podem desenhar seus elementos de emoticons para aplicar no software. Após isso, o sistema marca os pontos de interesse (características) na imagem e mostra o passo-a-passo dos cálculos para se formatar a entrada da RNA. Desta forma, os estudantes podem realizar diversos experimentos de forma lúdica e interativa para se extrair características de itens que eles mesmos desenharam.

Para se extrair as devidas características, o algoritmo aplicado leva em consideração o formato linear do desenho por meio de pontos específicos. A ideia principal é aplicar uma função heurística que detecta uma concavidade do objeto na imagem. Por exemplo, uma imagem de uma boca “feliz” apresenta um formato de concavidade para cima. Desta forma, dois pontos de interesse das extremidades esquerda e direita do objeto são obtidos. Além disso, pontos de interesse da região central do objeto também são detectados. A quantidade de pontos centrais varia entre 1 e 2 dependendo do elemento de que se deseja extrair suas características. Portanto, um valor que representa uma medida da concavidade é dada pela simples equação:

$$x_e = \text{média}(pa, pb) - \text{média}(\text{pontos centrais})$$

Sendo que  $pa$  e  $pb$  são os pontos das extremidades direita e esquerda do objeto e a função *média* representa o cálculo de uma média aritmética simples.


Por fim, o algoritmo aplica uma regra de três simples para alterar a escala do valor numérico calculado para a escala de entrada padrão do IAprender. No entanto, é preciso observar que, conforme a fórmula apresentada, o valor da característica pode ser negativo (dependendo da concavidade), portanto a regra de três deve levar em consideração este aspecto. Desta forma, a equação é dada por  $x_i = t/2 - t/2 * x_e/h_o$ , onde  $t$  indica o total máximo da nova escala e  $h_o$  representa a altura do objeto.

A Figura 4 ilustra a interface do módulo de extração de características da imagem. Pela figura é possível observar que o software é capaz de desenhar os pontos

de interesse na imagem enviada pelo usuário e mostrar detalhadamente os cálculos envolvidos na extração das características conforme a abordagem descrita.

### Extrair Características

Escolher arquivo boca\_test.png  
Qual é a parte do emoticon? Boca  
Aplicar



**Vamos para os cálculos!**

**Altura do ponto A = 151**  
**Altura do ponto B = 147**  
**Altura do ponto C = 30**  
**valor da feature = média(151,147) - média(30) = 119**  
**Vamos mudar para a escala de 0 a 3 para aplicar no IAprender!**  
**Regra de três:  $\frac{3}{2} * (\frac{119.00}{126}) = 1.42$**   
**Resultado =  $\frac{3}{2} + 1.42 = 2.92$**

Figura 4. Módulo Extrator de Características do Objeto de Aprendizagem Digital proposto sendo aplicado para o desenho de uma boca.

## 6. Metodologia Educacional para IAprender

O IAprender foi desenvolvido especialmente para apoiar atividades construtivistas de ensino/aprendizado. Neste sentido, este artigo recomenda duas atividades didáticas possíveis. Uma aplicação mais simples e direta poderia seguir seguinte sequência didática: (1) Introduzir conceitos teóricos básicos de Aprendizado de Máquina e RNAs por meio de uma aula expositiva; (2) Mostrar exemplos práticos por meio do Objeto de Aprendizagem, solicitando que os alunos reproduzam a aplicação em seus computadores; (3) Deixar os alunos explorarem livremente o IAprender; (4) Formar grupos e solicitar que cada grupo realize classificações diferentes; e (5) Solicitar que cada grupo apresente e discuta os resultados encontrados com outros grupos.

Uma aplicação mais apurada do Objeto de Aprendizagem Digital poderia se dar por uma adaptação do método de Aprendizagem Colaborativa denominado *Jigsaw* [Monereo e Gisbert 2005]. Neste sentido, o professor facilitador poderia criar grupos de especialistas responsáveis por classificar um sentimento em específico - cada grupo deste tipo se especializaria em um sentimento. Os grupos de base, compostos por diferentes especialistas em sentimentos, poderiam fazer, por meio da experimentação,

um mapeamento em amplitude de como a RNA funciona de forma geral para fazer diferentes classificações.

Em atividades realizadas para o desenvolvimento do Pensamento Computacional (PC), estas abordagens propostas podem possibilitar que estudantes exercitem habilidades essenciais deste campo de conhecimento como as descritas por Barr e Stephenson (2011). Neste sentido, por meio da exploração do software e com o apoio do professor, estudantes podem aplicar conceitos de Reconhecimento de Padrões/Análise de Dados, Abstração, Algoritmos, Simulação, Automação dentre outros que fazem parte do arcabouço mental do PC conforme Barr e Stephenson (2011).

Cabe observar que, se o objetivo for aplicar o software para estudantes do ensino médio para os ensinar o treinamento de RNAs, é preciso abstrair o conceito de derivada de funções - uma vez que não é comum isto ser estudado neste nível de ensino. No entanto, isso pode ser feito muito facilmente, uma vez que o sistema utiliza função linear de ativação.

No contexto de cursos superiores voltadas para área de Tecnologia da Informação, caso o professor deseje se aprofundar na implementação de RNAs, o código fonte do IAprender, que é aberto, pode ser trabalhado para que os alunos entendam seu funcionamento e/ou implementem novas funcionalidades para o Objeto de Aprendizagem.

## 6. Resultados

No total 21 alunos do Bacharelado em Sistemas de Informação participaram da aula expositiva. A Tabela 1 mostra os gráficos correspondentes a respostas para as questões do questionário. Como pode ser observado, as respostas mostraram um resultado favorável ao uso do sistema em todas as questões. No entanto, cabe observar que a questão 2, que trata dos cálculos envolvidos, precisa de uma maior atenção dos desenvolvedores pelo relativo elevado número de respostas neutras.

**Tabela 1. Respostas ao questionário de avaliação**

Questão	Discordo Tot.	Disc. Parc.	Neutro	Concordo Parc.	Concordo Tot.
1	0	0	2	11	8
2	0	1	7	7	6
3	0	0	1	2	18
4	0	0	1	5	15
5	0	0	0	9	12
6	0	0	0	10	11
7	0	1	3	8	9
8	0	0	0	8	13
9	0	0	3	5	13

## 7. Discussão e Conclusão

Ensinar e introduzir conceitos de ML para estudantes de diferentes níveis de ensino pode ser um grande desafio. Para contribuir com esse objetivo, este trabalho propõe o desenvolvimento do objeto de aprendizagem digital IAprender. O artefato permite que estudantes simulem os processos de classificação e treinamento de uma RNA para reconhecer expressões faciais de um avatar digital - entendendo assim a estrutura de dados, algoritmos e cálculos envolvidos nestes processos. A validação do sistema, por meio da sua exposição e aplicação de um questionário, mostrou que a proposta pode ser promissora para ser aplicada em sala de aula. Cabe observar que as respostas ao questionário mostraram, em sua maioria, que o artefato pode contribuir muito para o ensino. No entanto, entendemos que a questão que diz respeito ao entendimento dos cálculos realizados pela RNA ainda poderia ser melhorada - apesar das respostas no questionário que diziam respeito a este aspecto terem sido em sua maioria positivas, o número de respostas neutras foi maior que em outras questões que avaliaram outros aspectos do software. Neste sentido, um componente da interface gráfica para visualização dos cálculos de forma interativa já foi desenvolvido. Este componente exibe, em tempo real, todas as etapas dos cálculos realizados em cada unidade da RNA. Isto é feito ao se exibir as equações tendo suas variáveis devidamente substituídas pelos seus respectivos valores. A Figura 5 ilustra a interface para visualização dos cálculos realizados nas unidades ocultas utilizando uma função linear.

Unidades ocultas:

$$h_1 = ((4.00 * 1.00) + (1.20 * 3.00) + (3.30 * 2.00)) = 14.20$$

$$h_2 = ((1.40 * 1.00) + (0.50 * 3.00) + (0.80 * 2.00)) = 4.50$$

Figura 5. Exemplo do componente para visualização dos cálculos.

**Limitações/Ameaças à Validade.** A maior limitação deste estudo diz respeito a validação do artefato, que envolveu apenas estudantes do ensino superior em uma aula expositiva. Neste sentido, o estudo carece de uma avaliação do software a ser realizada com estudantes do ensino médio por meio de metodologias ativas de aprendizagem.

**Trabalhos Futuros.** Os trabalhos futuros propostos dizem respeito a atacar as limitações e achados na validação desta pesquisa já mencionados anteriormente. Portanto, como trabalhos futuros, propõe-se a aplicação/validação do artefato para/por estudantes do ensino médio, incluindo a avaliação do novo componente de interface desenvolvido para mostrar as etapas dos cálculos nos componentes da RNA. Esta validação poderá envolver a criação de grupos de controle, uma análise estatística estratificada, uma descrição detalhada do perfil dos participantes e a definição de métricas para medir a eficácia do artefato.

## 8. Disponibilidade do Artefato

O IAprender possui código fonte aberto que está disponível no repositório do GitHub e pode ser acessado pelo link: <<https://github.com/HugoMTeodoro/IAprender>>.

## Referências

- Barr, V., e Stephenson, C. (2011). Bringing computational thinking to K-12: What is involved and what is the role of the computer science education community?. *ACM inroads*, 2(1), p. 48-54.
- Calsavara et al. (2017). “Bacharelado em Ciência da Computação”, In: Referenciais de Formação para os Cursos de Graduação em Computação, Editado por Zorzo et al., Sociedades Brasileira de Computação (SBC).
- Cardozo, J., Martins, R. M., e von Wangenheim, C. G. (2022, July). ML4Teens-Introduzindo Machine Learning no Ensino Médio. In *Anais do XXX Workshop sobre Educação em Computação* (pp. 204-214). SBC.
- Estevez, J., Garate, G., & Graña, M. (2019). Gentle introduction to artificial intelligence for high-school students using scratch. *IEEE access*, 7, 179027-179036.
- Floriano, D. e Nolfi, S. (2000) *Evolutionary Robotics: The Biology, Intelligence, and Technology of Self-Organizing Machines* Stefano Nolfi, Massachusetts, The MIT Press.
- Jovanović, N., Stamenković, S., & Jovanović, S. (2023). NNeduca: A software environment to teach artificial neural networks. *Computer Applications in Engineering Education*, 31(5), 1447-1464.
- Kahn, K. M., Megasari, R., Piantari, E., & Junaeti, E. (2018). AI programming by children using Snap! Block programming in a developing country. In *CEUR Workshop Proceedings*, vol. 2193, p. 1–14.
- Karalekas, G., Vologiannidis, S., e Kalomiros, J. (2023). Teaching Machine Learning in K–12 Using Robotics. *Education Sciences*, 13(1), 67.
- Marques, L. S., von Wangenheim, C. G., e Hauck, J. C. R. (2020). Ensino de machine learning na educação básica: um mapeamento sistemático do estado da arte. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação* (pp. 21-30). SBC.
- Monereo, C. e Gisbert, D. D. (2005) *Tramas: Procedimentos para a aprendizagem cooperativa*. Porto Alegre, Artmed.
- Sagan, C. (2011). *The demon-haunted world: Science as a candle in the dark*. Ballantine books.
- Sanusi, I. T., Oyelere, S. S., Vartiainen, H., Suhonen, J., & Tukiainen, M. (2023). A systematic review of teaching and learning machine learning in K-12 education. *Education and Information Technologies*, 28(5), p. 5967-5997.
- Segaran, T. (2008). *Programando a inteligência coletiva: desenvolvendo aplicativos inteligentes web 2.0*. O'Reilly Media, Inc e Alta Books.
- Senac (2024) “O impacto da Inteligência Artificial na sociedade”, <https://forumsetorial.senac.br/o-impacto-da-inteligencia-artificial-na-sociedade.html>, acesso em Janeiro de 2024.
- Smilkov, D. e Carter, S. “Playground Tensorflow”, <https://playground.tensorflow.org/>, acesso em Janeiro de 2024.