

Explorando o Percéptron no Machine Learning para o ensino de Matemática na Educação Profissional e Tecnológica

 <https://doi.org/10.47236/2594-7036.2026.v10.1924>

Ciro Henrique Donnabella de Ávila¹
André Luiz Dias²

Data de submissão concluída: 12/11/2025. Data de aprovação: 20/2/2026. Data de publicação: 24/2/2026.

Resumo – O *Machine Learning* constitui um dos pilares da Inteligência Artificial, tema amplamente debatido na atualidade; entretanto, tais técnicas são, em geral, interpretadas como sistemas do tipo “caixa-preta”, o que evidencia a importância de promover, na Educação Profissional e Tecnológica, a compreensão dos fundamentos matemáticos que sustentam esses algoritmos e explicam seu funcionamento. Assim, o objetivo deste trabalho é investigar como fundamentos de Machine Learning podem ser utilizados no ensino de Matemática, superando uma abordagem meramente tecnicista da tecnologia. Para isso, propõe-se uma sequência didática que emprega Regressão Linear e Neurônio Artificial, com o intuito de favorecer a aprendizagem de estudantes do ensino médio integrado em conteúdos como estatística, equações de primeiro grau, construção e interpretação de gráficos, entre outros, promovendo o desenvolvimento do raciocínio correlacional. Para validar a Sequência Didática, se realizou coleta de dados por meio de um questionário sobre o conhecimento prévio dos participantes, um questionário de avaliação das atividades e uma Roda de Conversa. Os dados coletados foram avaliados por uma Análise Temática. Como resultado constatou-se, que a sequência didática motivou a utilização dos conteúdos de matemáticas propostos, além de promover a discussão sobre o uso dessa tecnologia na sociedade, em especial no mundo do trabalho.

Palavras-chave: Machine learning. Ensino de Matemática. Educação Profissional e Tecnológica.

Exploring the Perceptron in Machine Learning for Mathematics Teaching in Professional and Technological Education

Abstract – Machine Learning constitutes one of the pillars of Artificial Intelligence, a topic widely discussed today; however, such techniques are generally interpreted as “black-box” systems, which highlights the importance of promoting, within Professional and Technological Education, an understanding of the mathematical foundations that underpin these algorithms and explain how they operate. Thus, the objective of this study is to investigate how Machine Learning fundamentals can be applied in Mathematics teaching, moving beyond a merely technicist approach to technology. To this end, a didactic sequence employing Linear Regression and an Artificial Neuron is proposed, with the aim of supporting integrated high school students in learning topics

¹ Mestrando em Educação Profissional e Tecnológica pelo Instituto Federal de São Paulo. Sertãozinho, São Paulo, Brasil.  ciquedola@gmail.com  <https://orcid.org/0009-0009-7784-4950>  <http://lattes.cnpq.br/1725987341733295>

² Doutor em Engenharia Elétrica pela Universidade de São Paulo. Professor de Engenharia Elétrica do Ensino Básico, Técnico e Tecnológico do Campus Sertãozinho, do Instituto Federal de São Paulo, e professor do mestrado em Educação Profissional e Tecnológica do Instituto Federal de São Paulo. Sertãozinho, São Paulo, Brasil.  andre.dias@ifsp.edu.br  <https://orcid.org/0000-0001-7910-562X>  <http://lattes.cnpq.br/9036034274265658>

such as statistics, first-degree equations, and the construction and interpretation of graphs, among others, fostering the development of correlational reasoning. To validate the didactic sequence, data were collected through a questionnaire assessing participants' prior knowledge, an activity evaluation questionnaire, and a discussion circle. The collected data were examined using thematic analysis. The results indicated that the didactic sequence encouraged the application of the proposed mathematical content and promoted discussion about the use of this technology in society, particularly in the world of work.

Keywords: Machine learning. Mathematics teaching. Professional and Technological Education.

Explorando el Perceptrón en Machine Learning para la enseñanza de las Matemáticas en la Educación Profesional y Tecnológica

Resumen – El Machine Learning constituye uno de los pilares de la Inteligencia Artificial, un tema ampliamente debatido en la actualidad; sin embargo, estas técnicas suelen interpretarse como sistemas de tipo “caja negra”, lo que pone de manifiesto la importancia de promover, en la Educación Profesional y Tecnológica, la comprensión de los fundamentos matemáticos que sustentan estos algoritmos y explican su funcionamiento. Así, el objetivo de este trabajo es investigar cómo los fundamentos del Machine Learning pueden utilizarse en la enseñanza de las matemáticas, superando un enfoque meramente tecnicista de la tecnología. Para ello, se propone una secuencia didáctica que emplea la Regresión Lineal y la Neurona Artificial, con el fin de favorecer el aprendizaje de estudiantes de la enseñanza media integrada a la educación profesional en contenidos como estadística, ecuaciones de primer grado, construcción e interpretación de gráficos, entre otros, promoviendo el desarrollo del razonamiento correlacional. Para validar la secuencia didáctica, se realizó la recolección de datos mediante un cuestionario sobre los conocimientos previos de los participantes, un cuestionario de evaluación de las actividades y un círculo de diálogo. Los datos recopilados fueron analizados mediante un análisis temático. Como resultado, se constató que la secuencia didáctica promovió la utilización de los contenidos matemáticos propuestos, además de fomentar la discusión sobre el uso de esta tecnología en la sociedad, especialmente en el mundo del trabajo.

Palabras clave: *Machine learning*. Enseñanza de las Matemáticas. Educación Profesional y Tecnológica.

Introdução

Este trabalho explorou possibilidades de utilizar o *Machine Learning* para ensinar Matemática aos alunos do quarto ano do curso técnico em automação industrial integrado ao ensino médio, do IFSP, campus Sertãozinho, mas sobre o foco da Politécnica, visando a formação humana integral, provocando reflexões e discussões da utilização desta tecnologia para a sociedade, pois dessa forma os alunos não apenas utilizam essa tecnologia, mas entendem a base de seu funcionamento e suas implicações na prática, que é uma forma de se tornarem seres críticos e analíticos sobre o uso da tecnologia, pois novos conceitos tecnológicos e os seus impactos na sociedade acabam gerando uma nova demanda, que é a de compreender suas bases de sustentação, seus benefícios e problemas para a sociedade.

A ênfase do ensino e aprendizagem da Educação Profissional e Tecnológica, reforça a procura por recursos educacionais, que proporcione maior eficiência na

necessária resposta para as novas demandas de seus estudantes, à medida que elas emergem como novos desafios vinculados ao avanço da tecnologia, motivo principal do alinhamento com esta pesquisa, que direciona uma investigação sobre a aplicação de ferramentas de aprendizado de máquina, como o *Percéptron*, que possuem relevância para a compreensão de fundamentos da Matemática, como a Regressão Linear na área da Estatística, especificamente para os alunos do Ensino Médio Integrado ao Técnico em Automação Industrial, por fazer parte de seu contexto profissional.

Ramos (2014), indicando que a educação profissional não deve ser vista como alternativa à educação omnilateral, esta última busca desenvolver o indivíduo de forma completa e integral, enquanto a educação profissional, muitas vezes, é tratada de forma unilateral, como único caminho para o sucesso profissional.

O aprendizado de máquina serve como recurso para aprofundar a compreensão das pessoas sobre a causalidade e o raciocínio correlacional, que podem melhorar a qualificação profissional do aluno, pois auxilia a desenvolver habilidades profissionais das pessoas, permitindo a compreensão para além da forma como a tecnologia se apresenta, desvelando sua base de funcionamento, permitindo maior eficiência na análise das relações e associações de variáveis, que são partes integrantes das atividades pertencentes aos sistemas e às estruturas de controle e automação, assim como promove a discussão dos impactos de sua utilização para a sociedade, que é uma forma de superar um problema recorrente da formação fragmentada ou tecnicista.

Para Barboza; Dias (2025), as perspectivas para o ensino da Matemática atualmente são desafiadoras, apontando a urgência da adoção de práticas pedagógicas inclusivas e contextualizadas, capazes de superar os métodos de ensino tradicionais, sendo necessário o engajamento dos educadores com essa demanda de forma ética, reflexiva valorizando a diversidade. Os autores concluem que somente através de uma abordagem humanizada e bem articulada será possível superar as desigualdades na educação, garantindo aos estudantes o direito a uma educação capaz de promover a emancipação das pessoas, através da transformação da sociedade.

O contexto do tema apresentado nesta pesquisa constitui área de conhecimento da Inteligência Artificial, como os algoritmos e possui motivação para os alunos do quarto ano do curso Técnico em Automação Industrial, permitindo integrar conteúdo técnico com conteúdo de disciplina básica de forma aplicada, associando a prática com a teoria, ambas respaldadas pelos fundamentos do ensino e aprendizagem da Educação Profissional e Tecnológica

Conforme afirma Araújo (2022), os algoritmos estão presentes em nossa vida mais do que podemos imaginar, e eles ainda podem contribuir para elaborar outros algoritmos, auxiliando na solução de problemas muito complexos, como exemplo, ele cita o caso de um cientista, que levaria um tempo enorme testando hipóteses, enquanto as máquinas inteligentes são capazes de realizar esse mesmo trabalho em um espaço de tempo muito menor, sendo essa otimização extremamente importante para a sociedade.

Assim, o objetivo desta pesquisa é explorar esses fundamentos, investigando, desenvolvendo e analisando, como ferramentas de Machine Learning, a exemplo do *Percéptron*, podem ser utilizadas na Educação Profissional e Tecnológica, para suporte no ensino de Matemática, utilizando-se de uma Sequência Didática e uma planilha com duas atividades, uma de Regressão Linear e outra com o *Percéptron* ou Neurônio Artificial.

A hipótese proposta foi de verificar se recursos de *Machine Learning*, através da Regressão Linear univariada e multivariada, o *Percéptron* e as Redes Neurais Artificiais poderiam ser utilizados como motivação para auxiliar no ensino de Matemática aplicada aos alunos, superando o desinteresse deles em conteúdos áridos, além de estimular o desenvolvimento de competências para a compreensão das relações entre as associações de variáveis, através de uma Sequência Didática, com atividades teóricas e práticas, composta por três unidades, para serem aplicadas em três aulas presenciais de noventa minutos de duração cada uma.

Segundo Barboza; Dias (2025), existe a necessidade de um ensino estruturado, para evitar a fragmentação da aprendizagem, sendo fundamental a utilização de práticas pedagógicas, que superem a simples transferência de conteúdos utilizando o desenvolvimento da autonomia intelectual, favorecendo uma aprendizagem contínua e significativa.

Os resultados da aplicação da Sequência Didática tiveram ênfase nos debates provocados sobre os principais conteúdos desenvolvidos, como a capacidade do algoritmo de *Machine Learning* aprender com os dados, em contraste com a programação tradicional, que é rígida e necessita ser programada para cada evento realizado, assim como a identificação de *Outliers* em um conjunto de dados, que são dados coletados discrepantes, devido a erros ou anomalias de aferições durante a coleta desses dados, discutindo suas implicações e a forma como os algoritmos podem ser utilizados para identificá-los. Além disso, foram analisados também, os dados referentes aos benefícios e riscos da utilização de *Machine Learning* na sociedade, incluindo questões como o preconceito nos dados e suas consequências de uma forma abrangente, entre outros conceitos, às aplicações e implicações sobre a necessidade de regulamentação, destacando tanto suas vantagens quanto os desafios éticos e sociais associados ao seu uso.

Aprendizagem de máquina

Segundo Garcia (2022), da mesma forma que a aprendizagem de máquina utiliza modelos matemáticos, representados por Matemática do comportamento de sistemas, armazenando e aplicando aquilo que aprendeu, e embora os padrões sejam difíceis de serem encontrados pela percepção humana, quando existe uma grande quantidade de dados para análise, os algoritmos de aprendizado de máquina são mais eficientes na identificação de regras e exceções, com capacidade para superar os programas com embasamentos em regras.

O modelo mais utilizado e mais simples em *Machine Learning* utiliza a Regressão Linear, e conforme Kehl (2023), ele é utilizado na aproximação de um conjunto de pontos por uma reta, constituindo um modo de mensurar o quanto essa aproximação é boa, pois através do cálculo da média das distâncias entre a reta e os pontos distribuídos no campo, é que defini a margem de erro de aproximação. A forma mais comum de realizar o cálculo desse erro de aproximação, é definindo o melhor resultado quando for o mais próximo da reta, pois quanto menor for o erro, definido através do erro quadrático médio, que é a somatória das distâncias elevado ao quadrado, entre a reta estimada e os valores reais, do conjunto de pontos.

Segundo Machado (2009), a apresentação de um determinado padrão para uma Rede Neural Artificial, permite que ela gere uma determinada saída. Na sequência, ao realizar a medida entre o real e a esperada serão feitos os ajustes necessários nos pesos. Depois da aferição da distância entre a resposta real e a esperada, são ajustados adequadamente os pesos das entradas, para proporcionar a redução dessa distância, esse processo é designado por Regra Delta, que é aplicada

na maior parte de treinamentos de Redes Neurais Artificiais, que são formadas por Neurônios Artificiais.


Utilizando Machine Learning para o ensino de Matemática

Inicialmente, a proposta deste trabalho consiste em apresentar conceitos básicos sobre como a matemática é empregada em algoritmos de *Machine Learning*, o estudo adota como foco algoritmos simples, excluindo deliberadamente parte técnicas associadas à etapa de treinamento que envolvem métodos estatísticos mais sofisticados. A abordagem concentra-se, portanto, na compreensão de como, a partir de dados e de modelos matemáticos elementares, esses algoritmos são capazes de estimar e prever valores, evidenciando apenas o funcionamento fundamental do processo de aprendizagem baseada em dados.

Através de exercícios de Regressão Linear, como por exemplo calcular a melhor reta de aproximação a um conjunto de dados em um plano cartesiano, permitindo entender que um valor qualquer pode ser estimado ou determinado, o seu valor correspondente, com base nos dados coletados, utilizando-se uma equação de primeiro grau ou função Afim, proporcionou aos alunos através da atividade dos cálculos manuais para obter a melhor reta, inferir o potencial preditivo desse recurso matemático, expondo na prática ferramentas de *Machine Learning* dentro do contexto do mundo do trabalho, provocando o debate do paradigma das inovações, pois os benefícios esperados estão na maioria das vezes atrelados a alguma consequência negativa.

Na sequência didática, empregou-se algoritmos de treinamento supervisionado para obter-se a melhor resposta, onde os algoritmos ajustam os pesos sinápticos do(s) Neurônio(s) Artificiais. Após esta etapa de treinamento, os alunos são capazes de verificar que em princípio cada Neurônio Artificial, ilustrado na Fig. 1, representa também uma equação de primeiro grau, porém quando se utiliza vários neurônios é possível se ajustar mais adequadamente a resposta prevista dos dados coletados. Outros conceitos são utilizados, como o *outlier*, *overfitting* (excesso de dados de treinamento e dados sem relevância) e vieses dos dados coletados.

Figura 1 – Modelo de um Neurônio Artificial, ou *Percéptron*



Fonte: Haykin, 2001

Adicionalmente, existe uma ampliação do universo da proposta, adentrando ao contexto social, com debates sobre os problemas éticos envolvidos na utilização dessa tecnologia e a consequente necessidade de regulamentação sobre o uso dessa ferramenta, fomentando a discussão das interações sociais dessa tecnologia em que

o aluno está inserido, permite a articulação entre trabalho, ciência, cultura e tecnologia.

Materiais e métodos

Este trabalho foi aplicado no campus Sertãozinho, do IFSP, com a amostra de 40 alunos do quarto ano, do curso Técnico em Automação Industrial, integrado ao ensino médio, na data de 08 a 23 de novembro. Esta pesquisa obteve aprovação do Comitê de Ética em Pesquisa com Seres Humanos da instituição sede, CAAE 77468224.9.0000.5473 e Parecer número 6.754.173.

Para construção da Sequência Didática, se utiliza elementos da Pesquisa Baseada em Design, ou Design-Based Research (DBR) em língua inglesa, definida pela DBR-Collective (2003), com elementos complementares da metodologia de Zabala (1998).

Os elementos da DBR, complementados com elementos da metodologia de Zabala (1998) contribuíram no planejamento, desenvolvimento e conclusão deste trabalho, trazendo uma combinação empírica dos ambientes de aprendizagem com a teoria da educação, sendo imprescindível para compreender a forma que se apresenta a inovação no ensino e aprendizagem. A DBR deve ser vista como uma teoria a respeito da metodologia e organização do roteiro para conduzir o processo de implementação de novas ferramentas para serem utilizadas em sala de aula, visando auxiliar os alunos na compreensão de conteúdo.

Segundo Zabala (1998), para adquirir competências pessoais e interpessoais, para atuar nos contextos sociais e profissionais, a implementação de uma Sequência Didática, é um recurso adequado, pois tem a concepção construtivista, possuindo objetivos e conteúdo de aprendizagem: factuais, conceituais, procedimentais e atitudinais, que dão forma e fundamentos no desenvolvimento da Sequência Didática.

Inicialmente com o *Design* foi possível delinear a modelagem do objeto da pesquisa, que é uma ferramenta de Inteligência Artificial (*Machine Learning*) de forma a direcionar o conteúdo produzido nesta fase para a etapa seguinte, que é a do gerenciamento da implementação da Sequência Didática proposta, seguindo a etapa, que é o produto resultante sendo aplicado na sala de aula com os alunos de forma presencial, finalizando com a etapa, que foi a análise dos resultados obtidos, permitindo avaliar que os objetivos foram alcançados e as questões dessa pesquisa respondidas, observando que a última etapa dessa metodologia foi utilizado apenas um ciclo, e o re-design uma única vez, o que não impede que ele seja feito em uma nova aplicação dessa Sequência Didática, por um outro professor.

Para Long e Magerko (2020), os fundamentos para o aprimoramento da compreensão de novos conteúdos, devem ser significativos na realidade do aluno, para possibilitar a eles assimilar novas competências, necessárias para que a Inteligência Artificial transforme a forma como nos relacionamos entre nós mesmos e com as máquinas. Instituída a alfabetização da Inteligência Artificial como um acervo de competências capazes de permitir ao indivíduo analisar criticamente as tecnologias de IA interagindo de forma eficiente com essa ferramenta.


O PE foi desenvolvido, conforme ilustra o Fluxograma 1, visando o contexto dos discentes do quarto ano do curso do Ensino Médio Integrado ao Curso Técnico em Automação Industrial, do IFSP – Campus Sertãozinho, pensando em melhorar a compreensão de fundamentos de Matemática, que sustentam o funcionamento da aprendizagem das máquinas, assim este trabalho está inserido na Educação Profissional e Tecnológica (EPT), por contribuir objetivamente na formação profissional dos alunos, à medida em que ele expõe na prática o conhecimento técnico

de *Machine Learning* dentro do contexto do mundo do trabalho, provoca o debate do paradigma das inovações, pois existe a necessidade de avaliar os benefícios esperados em relação a alguma consequência negativa, que estão na maioria das vezes atrelados.

O fluxograma 1 apresenta graficamente as unidades didáticas do produto educacional desenvolvido, assim como sua aplicação. Na primeira unidade didática os objetivos foram apresentar a utilização de ferramentas de Machine Learning, coletar as informações sobre o conhecimento prévio dos alunos, utilizando um questionário com questões objetivas e dissertativas e realizar a coleta de dados físicos dos alunos. A coleta é realizada de forma orientada pelo professor de Educação Física da instituição, conforme ilustra o Quadro 1, como altura, peso, salto em distância, salto de impulsão vertical e o tempo da corrida de 50 metros, e finalizando através da Análise tema conforme descrita no Quadro 2.

O Fluxograma 1 apresenta as unidades da Sequência Didática.

FLUXOGRAMA DA APLICAÇÃO DO PRODUTO EDUCACIONAL



Fonte: Próprio autor

Como a coleta de dados é uma etapa importante na utilização de *Machine Learning*, optou-se pela utilização de dados reais dos alunos e não por banco de dados público. Estes dados foram utilizados nas atividades com Regressão Linear (unidade didática 2) e Neurônio Artificial (unidade didática 3), sendo especialmente trabalhado o salto de impulsão vertical.

Quadro 1 – Orientação do professor de educação física para o salto de impulsão

Explicação sobre o salto	Posição para o salto
	

Fonte: produzida pelo próprio autor.

Segundo a Fitescola (2025, p.1) o teste de Impulsão Vertical tem a função de mensurar a máxima altura obtida, pela impulsão dos membros inferiores; e está relacionada de forma inversa aos riscos das doenças cardiometabólicas.

Para a realização desse teste é necessário que se tenha um local com piso que não escorregue, fita métrica, fita adesiva e seguir as instruções:


1. Prenda a fita métrica na cintura do participante, e ao mesmo tempo no solo, de forma que ela fique em condições de se deslocar com o salto do participante, porém firme o suficiente para não deslizar, e de forma perpendicular a altura do aluno.
2. Posteriormente a preparação do item 1, o professor de educação física deve instruir o participante sobre a posição correta e a forma de saltar, realizando antes, diante do grupo de participantes, uma demonstração do salto:
 - a) O participante deve ficar em pé e de forma ereta, posicionando os pés distanciados na mesma medida entre os ombros, e colocar as mãos na cintura.
 - b) O professor deve repetir o salto individualmente, de forma a ensinar ao participante a forma de saltar.
 - c) O participante deve fletir os joelhos e saltar com o maior impulso possível.
 - d) O salto deve ser repetido três vezes, e o professor de educação física ou o orientador devem anotar em cada salto do participante: a medida inicial e a medida final da fita métrica.

Na unidade didática 2, os alunos realizaram a plotagem dos dados coletados sobre o salto de impulsão pela altura no plano cartesiano, foram encorajados a utilizar cálculos manuais, e definir a melhor reta (equação de primeiro grau) que estima o salto de impulsão baseada na altura do aluno. A seguir foi aplicada a Planilha do Excel que utiliza a Regressão Linear, e os alunos verificaram por meio do erro quadrático médio que o algoritmo de regressão apresenta menor erro, ou, no mínimo, igual as retas indicadas por eles. A ideia é mostrar que utilizando o algoritmo obtêm-se melhores resultados. Conceitos de *outlier* também foram apresentados nesta unidade, por serem pertinentes na observação de dados que se diferenciam dos demais.

A figura 2 apresenta um exemplo do gráfico feito manualmente pelos alunos, divididos em quatro equipes, utilizando os dados coletados no salto de impulsão, com

o objetivo de encontrar a melhor reta no Plano Cartesiano, e ao calcular o erro do estimador, obteve o melhor resultado a equipe 5, conforme resultados apurados na Tabela 1.

Figura 2 – Exemplo de gráfico feito manualmente pelos alunos




Fonte: Professor Dr. André Luiz Dias

Na unidade didática 3, se apresenta o conceito de Neurônio Artificial, mostrando que também se baseia em uma equação de primeiro grau, por meio da Planilha do Excel que foi desenvolvida com essa finalidade. Adicionalmente, se utilizou um script em Python para realizar outras configurações com mais neurônios, mostrando que com maior quantidade de neurônios, a resposta obtida tende a apresentar erros menores. Adicionalmente, se apresentou conceitos de overfitting (excesso de dados de treinamento e dados sem relevância) e de viés. Por exemplo, se treina o modelo de *Machine Learning* com vários neurônios apenas com dados de mulheres, só depois testa apenas com dados de homens, o que acaba gerando um aumento no erro.

A Fig. 3 apresenta o gráfico feito na aba “a” da planilha do Excel, com a mesma atividade de Regressão Linear, e com os mesmos dados utilizados no cálculo manual, da atividade ilustrada na Fig. 2, ajustando a melhor reta no Plano Cartesiano, porém o cálculo agora é realizado pela planilha Excel da Microsoft, permitindo aos alunos substituir valores desconhecidos da altura dos alunos, e a planilha irá calcular o valor correspondente estimado também do salto desconhecido, onde todas as medidas estão em centímetro, dessa forma é possível verificar a possibilidade de prever ou estimar qual seria a altura do salto de impulsão de um aluno cuja altura é conhecida.

Figura 3 – Regressão Linear, Aba a da planilha.

A reta no gráfico abaixo, que melhor se aproxime de todos os pontos




	X_i	$\hat{Y}$
1	184	36,2753
2	169	33,2791
3	175	34,4775
4	157	30,8821
5	173	34,0781
6	164	32,2804
7	183	36,0755
8	154	30,2829
9	162	31,8809
10	162	31,8809
11	177	34,877
12	179	35,2765
13	166	32,6798
14	154	30,2829
15	174	34,2778
16	165	32,4801
17	179	35,2765
18	165	32,4801
19	181	35,676

Fonte: Próprio autor

O Neurônio Artificial ou *Percéptron*, utilizado na aba “b” da planilha do Excel, que funciona para fins didáticos com uma entrada e uma saída, pois esse desenvolvimento permite ao aluno compreender melhor os cálculos básicos realizados pelo Neurônio Artificial e verificar que são cálculos similares ao que ele utilizou manualmente para encontrar a melhor reta na unidade didática 2, facilitando ao aluno entender o funcionamento elementar das Redes Neurais Artificiais, importante recurso no contexto de *Machine Learning*, conforme está ilustrado na Fig. 4.

Figura 4 Apresentação do conceito de Neurônio Artificial, Aba b da planilha Excel



Fonte: Próprio autor

Finalmente, é promovida uma discussão por meio de uma roda de conversa sobre os impactos desta tecnologia na sociedade. A roda de conversa foi transcrita e utilizada da mesma forma que os dados coletados pelos pesquisadores na Caderneta de Campo, durante as atividades, juntamente com os demais dados coletados durante os trabalhos da aplicação da Sequência Didática.

Esta pesquisa utilizou da Análise Temática, por ser um instrumento que permite espelhar tanto a realidade como transpor a sua própria superfície, aumentando a

compreensão do objeto para além da forma como ele se apresenta, considerando que o contexto teórico expõe os pressupostos das características da natureza dos dados, desvelando o real de forma transparente, pois é essencial em um método qualitativo, visando as experiências individuais ou coletivas, observando as vivências do real, com menos foco na contagem, mas explorando com maior intensidade as relações qualitativas dos dados, mas permitindo a incorporação de parte de dados quantitativos, que têm menor relevância na análise qualitativa.

A análise foi conduzida de forma indutiva por dois pesquisadores de forma independente. A codificação inicial foi realizada pelo primeiro autor e validada pelo segundo autor, com taxa de concordância de 80%. Divergências foram resolvidas por consenso. O processo seguiu as 6 etapas de Braun & Clarke (2006), conforme descrição do Quadro 2 abaixo.

Quadro 2 -Descrição das 6 etapas da Análise Temática realizadas.

6 Etapas	Forma de desenvolvimento
Familiarização com os dados	Inicialmente foram feitas as transcrições necessárias dos dados coletados, e organizados sistematicamente de acordo com a com a origem de dos dados.
Geração de códigos iniciais	Nesta etapa foi realizada a identificação por um dos pesquisadores e validada pelo outro pesquisador, a fragmentação em unidades dos dados de acordo com significado de cada unidade, vinculando cada unidade a códigos representando o significado de cada unidade.
Busca por temas	Nesta etapa a reflexão sobre os códigos permitiu a subdivisão nas categorias de acordo com sua significância e relevância. A busca de padrões nas categorias direcionou a aglutinação em temas.
Definição e nomeação dos temas	Nesta etapa foram definidos e nomeados três temas.
Revisão dos temas	Nesta etapa foi realizada uma análise por ambos os pesquisadores, se as categorias delimitavam corretamente os três temas, o resultou na validação por ambos os pesquisadores a revisão dos três temas.
Produção do relatório	Nesta etapa foi feito um relatório contendo três quadros, com cada um apresentando um tema suas categorias e respectivos substratos. Apresentando conjuntamente como resultados obtidos, discussões por temas e as conclusões inferidas.

Fonte: Próprio autor.

Neste trabalho a opção foi pelo método indutivo, pois a coleta de dados, através de questionário, atividades e roda de conversa, que foram destinadas especialmente para esta pesquisa, desconsideraram o interesse teórico do pesquisador no tema, pois a codificação dos dados não teve como parâmetros conceitos preexistentes da literatura ou do pesquisador, sendo essencialmente orientada pelos dados.


O processo de codificação na análise temática é uma abordagem indutiva, que reforça o não envolvimento com a literatura no início da análise, diferente da abordagem teórica, que exige embasamento na literatura antes do início da análise. “A análise indutiva é, portanto, um processo de codificação dos dados, sem tentar se encaixar em um quadro de codificação preexistente, ou preconceitos analíticos do pesquisador” (Braun e Clark, 2006, p. 10).

Segundo Braun; Clarke (2006), o processo de codificação na Análise Temática por ser amplamente indutivo, com códigos e temas desenvolvidos a partir dos próprios dados, proporciona a descoberta de informações relevantes, para se interpretar mais profundamente, incluindo a possibilidade de uma mudança radical da compreensão de um determinado fenômeno.

A aplicação da análise temática, permitiu após a transcrição e identificação das categorias dos dados coletados, nas atividades das unidades um, dois e três da Sequência Didática, o que inclui os questionários e a Roda de Conversa, agrupar as categorias identificadas em três temas, apresentados da seção dos resultados.

O Fluxograma 2 ilustra uma graficamente o percurso metodológico utilizado neste trabalho para o desenvolvimento da pesquisa e do Produto Educacional.

Fluxograma 2 – Etapas do percurso metodológico.



Fonte: elaborado pelo próprio autor.

Assim, a utilização dessa Sequência Didática, com uma abordagem mais abrangente, como um recurso didático para o ensino de Matemática aplicada, associando reflexões sobre os benefícios, desafios, riscos e ameaças da utilização desta tecnologia para a sociedade, visa que os alunos não apenas utilizem a tecnologia, mas entendam o seu funcionamento, e dessa forma se transformem em seres críticos e analíticos na utilização dessa tecnologia, contribuindo para sua formação humana integral.

Resultados

Os dados coletados no questionário sobre o conhecimento prévio apresentaram os resultados: que o grupo de alunos participantes desta pesquisa é composto por 36% com idade de 18 anos e 64% com idade de 19 anos; sendo 44% do sexo feminino e 56% do sexo masculino; e 80% não estudou em escola pública; os 20% que estudaram, 16% estudou de 6 a 10 anos em escola particular e 4% estudou de 1 a 5 anos em escola particular; a maioria, ou seja, 56% não tem conhecimento do que seja *Machine Learning*; dos que têm conhecimento, 30,43% relacionam com a inteligência artificial, 30,43% associam a treinamento e aprendizagem de máquina, 39,13%


desconhecem *Machine Learning*, 64% não têm conhecimento sobre Redes Neurais Artificiais; dos alunos participantes, que declararam ter conhecimento sobre Redes Neurais Artificiais, 27,78% na inteligência artificiais, 16,67% no Chat GPT, 11,11% nos diagnósticos e recomendações médicas e 44,44% não deram exemplos. Estes dados mostram que o termo *Machine Learning* e Redes Neurais Artificiais ainda é pouco conhecido pelos alunos.

Verifica-se também que apenas 15% sabem construir gráficos em softwares do tipo Excel e Google Sheets, assim cria-se uma oportunidade para que os alunos criem gráficos durante a Sequência Didática.

Todos os alunos participantes já tiveram contato com programação em Arduino ou similar; destes mesmos alunos participantes, que já utilizaram também outros tipos de linguagem, 20% utilizaram a linguagem de programação Ladder e 8% já utilizaram a linguagem de programação C. Este conhecimento pode ser útil uma vez que normalmente os algoritmos de *Machine Learning* empregam linguagem de programação. Entretanto, a programação utilizada na última unidade da Sequência Didática foi a linguagem *Python*.

A seguir é apresentado na Fig. 5 o Mapa Conceitual, relacionando conceitos e explicando os dados coletados sobre o conhecimento prévio dos alunos, conforme expostos acima de forma descritiva; apresenta uma síntese, apontando que a maioria dos alunos são do sexo masculino e estudaram em escola pública, e não tem conhecimento de *Machine Learning* ou Redes Neurais Artificiais, porém a totalidade dos alunos tem conhecimento sobre a plataforma Arduino, que é uma plataforma muito utilizada em projetos de automação não utilizada em plantas profissionais; apresenta a necessidade de aumentar significativa a aprendizagem dos alunos na plotagem de gráficos; e a eles indicaram como a disciplina de maior interesse a Matemática, mas também indicaram ser a disciplina que eles têm significativa dificuldade de aprendizagem. Esse contexto indicado pelos dados coletado com os alunos no questionário sobre o conhecimento prévio corrobora com os objetivos desse trabalho, que é de utilizar ferramentas de *Machine Learning* como o *Percéptron* para ensinar Matemática.


Figura 5 – Mapa Conceitual – Síntese sobre os dados do conhecimento prévio



Fonte: elaborado pelo próprio autor.

A partir da aplicação da análise temática, foram identificados os seguintes temas e categorias conforme apresenta a Figura 6, que são detalhados na sequência.

Figura 6 – Mapa temático



Fonte: Próprio autor.

A Tabela 1, apresenta o resultado do desempenho das quatro equipes formadas, para avaliar qual foi o melhor estimador da atividade ilustrada na Fig. 5, e obteve o melhor desempenho a equipe 4.

Tabela 1 – Cálculos dos erros do estimador dos alunos para pontos Xi e Y dados
MÉDIA DOS RESULTADOS DO MELHOR ESTIMADOR POR EQUIPE

EQUIPES	Xi	Y(medido)	Y(estimado)	Erro absoluto(dispersão)
1	1.78	3.9	3.76	0.14
2	1.78	3.9	4.16	0.26
3	1.78	3.9	1.6	2.3
4	1.78	3.9	3.82	0.08

Fonte: Próprio autor.

A seguir é apresentado, nos quadros 3, 4 e 5, os resultados obtidos na Análise Temática dos dados coletados, através do questionário elaborado no Google Forms, sobre o conhecimento prévio dos alunos, dos questionários com duas atividades, um aplicado na unidade didática 2 sobre o conteúdo desenvolvido nessa unidade, o outro aplicado na unidade 3, assim como foi utilizado os dados anotados na caderneta de campo do pesquisador coletados nas duas atividades, finalizando com os dados coletados na Roda de conversa, com as categorias e seus substratos, que consubstanciaram três Temas emergentes da reflexão sobre a aglutinação das suas respectivas categorias por um dos pesquisadores, com a respectiva validação do outro pesquisador.

Quadro 3 – Tema 1

TEMA 1: <i>Machine Learning</i> no Ensino de Matemática	
CATEGORIA	SUBSTRATO
Utilizando a função Afim para encontrar a melhor reta	Pesquisador: Cálculo da melhor reta, pelos alunos participantes desta pesquisa, em um plano cartesiano utilizando função Afim.
	Pesquisador: A utilização da planilha no Excel para demonstrar a relação dos cálculos da Regressão Linear, no desenvolvimento do gráfico da função de primeiro grau.
	Aluna X5: Após os cálculos, ela analisa os dados com os que foram dados e avalia o erro para se adaptar.
	Aluno Y4: Analisando os dados fornecidos e aproximar da realidade do resultado.
	Pesquisador: A melhor reta seria a que se ajustasse mais aos dados coletados sobre a altura do salto de impulsão dos alunos, disponíveis em uma tabela no apêndice C.
Utilizando a planilha de Regressão Linear, no Microsoft Excel, com geração de gráficos estatísticos para análises da melhor reta	Aluno Y1: Através da coleta dos dados conseguimos usar a média para fazer especulações das capacidades físicas dos alunos.
	Pesquisador: Os valores calculados por cada equipe eram digitados, gerando um gráfico da "melhor reta". Isso permitiu identificar a equipe com os melhores resultados.
Demonstração da função Afim, utilizando o software da Microsoft Excel, no processo matemático dos Neurônios Artificiais e das Redes Neurais Artificiais	Pesquisador: Foi apresentada uma segunda planilha no Excel, que demonstrava os cálculos utilizados em um Neurônio Artificial, evidenciando a relação com a função Afim.
	Pesquisador: A atividade incluiu uma explicação sobre como os cálculos realizados pelos alunos se relacionam com o funcionamento de um Neurônio Artificial.
	Aluna X6: Analisando os dados e encontrando padrões.
	Aluno Y6: Faz uma conexão entre "cálculos manuais" e o "funcionamento de um Neurônio Artificial"

O impacto de <i>Outliers</i> em um conjunto de dados, no desvio do resultado	Aluno Y2: Os <i>Outliers</i> são erros de medidas causados pelas máquinas, pode-se concluir que são <i>Outliers</i> por conta da grande diferença de medida em relação aos outros.
	Aluna X8: <i>Outliers</i> são pontos fora da curva, estatísticas. Podemos comprovar por meio da comparação com os outros pontos. Ver se o dado da <i>Outlier</i> é falso ou muito discrepante comparado aos restantes.
Demonstrando o refinamento do ajuste da melhor reta, utilizando uma rede neural artificial, com programação em <i>Python</i>	Pesquisador: Utilização de uma rede neural artificial em <i>Python</i> para um ajuste mais preciso da melhor função, demonstrando o processo de treinamento em <i>Machine Learning</i> .
	Aluna X7: Gerando maior evolução da automação por meio da precisão de dados em diversas áreas.
	Aluno Y2: É uma área da Inteligência Artificial que capacita computadores a aprender e melhorar a partir de dados, sem serem explicitamente programadas.

Quadro 4 – Tema 2

TEMA 2: Desafios e Impactos na Sociedade	
CATEGORIA	SUBSTRATO
O <i>Machine Learning</i> aprimora os recursos de sistemas e processos de automação, estabelecendo novas formas de construção social	Aluno Y5: Uma precisão maior, diversos dados positivos, otimização de tempo.
	Aluno Y7: Automação dos processos repetitivos, monitoramento de resultados, facilita a busca de oportunidades e melhoria na precisão de dados.
	Aluna X6: Gerando maior evolução da automação por meio da precisão de dados em diversas áreas.
Eficácia do <i>Machine Learning</i> em diagnósticos médicos em comparação com médicos humanos	Aluno Y1: Coleta dos exames e sintomas na medicina para associar às possíveis doenças junto com as análises dos médicos.
	Aluna X4: Pode ser utilizado como apoio na área da saúde.
	Aluno Y2: Tipo, se fosse uma pessoa humana, a pessoa saberia identificar só de olhar a pessoa. De tanta experiência.
	Aluna X3: Aí, se fosse uma máquina, por exemplo, só ver se a pessoa tá com febre, às vezes a pessoa não tá com febre e não é atendida mais rápido.
Importância dos dados representativos e não preconceituosos	Aluna X1: O <i>Machine Learning</i> em si não, mas os dados disponibilizados podem ter viés negativo.
	Aluna X4: Sim, pois utilizam de dados de uma sociedade preconceituosa.
	Aluna X5: Os algoritmos são os mesmos, porém os dados acabam sendo preconceituosos.
	Aluno Y3: O algoritmo não é preconceituoso, mas os dados presentes na internet refletem a sociedade preconceituosa que estamos.
	Aluna X2: O algoritmo age com reação aos dados, então se os dados são preconceituosos, os algoritmos também será. Os dados não são muito filtrados em relação a isso, então os dados podem ser preconceituosos.

O <i>Machine Learning</i> afeta a privacidade e necessidade de regulamentação	Aluno Y5: A gente está sempre preocupado que a empresa que criou a IAS não seja habilitada. É por causa da regulamentação que os dados não são distorcidos.
	Aluna X7: Durante as eleições, a gente sabe que algumas candidatas eleitorais não são fantásticas assim. Estão, tipo assim, errando a imagem delas, ou criando propagandas falsas delas e aí, tipo assim, prejudicavam a companhia delas
A importância da mitigação do erro no <i>Machine Learning</i>	Aluna X14: O erro é um fato real
	Aluna X7: Impossível evitar totalmente
	Aluno Y5: Quanto maior o treinamento do <i>Machine Learning</i> menor o erro
	Aluna X2: O erro depende também da qualidade dos dados

Quadro 5 – Tema 3

TEMA 3: Mundo do Trabalho	
CATEGORIA	SUBSTRATO
O <i>Machine Learning</i> não substitui o trabalhador especializado, e amplia a capacidade profissional	Aluna X6: Pode ajudar na identificação de defeitos no processo de fabricação.
	Aluno Y4: Agropecuária, ensina ela a dirigir um trator de arar terra e diminuir os gastos com funcionário.
O ensino integrado na Educação Profissional e Tecnológica	Aluna X4: No geral, no jornal, quando fala tal estatística de algo de <i>Machine Learning</i> , acho que tem um pouco mais que não lembro.
	Aluno Y8: Necessidade de aumentar o foco e a ênfase no conteúdo da área básica das disciplinas.
	Aluna X1: Utilização de metodologias diferentes, com didáticas adequadas e a necessidade de aumentar o foco, como ferramentas relevantes para o aprendizado.
A teoria e a prática integrada na aprendizagem de Matemática e <i>Machine Learning</i>	Aluna X3: O reforço da teoria e da prática, com exercícios e atividades como a principal forma de melhorar a compreensão.
	Aluno Y4: A Matemática é minha área de maior interesse.
	Aluno Y6: Os cálculos manuais se relacionam com o funcionamento de um Neurônio Artificial.
	Aluno Y2: A segunda planilha no Excel, com os cálculos utilizados em um Neurônio Artificial, mostra a função Afim.
Relacionando o <i>Machine Learning</i> com o trabalho repetitivo	Aluna X5: Na automatização do processo, em que é algo muito repetitivo, que uma, duas, três, quatro pessoas trabalharam, tipo, não precisaria dessas quatro pessoas que seriam mandadas embora, ou manteria apenas uma, só pra estar conseguindo dados.
Novas oportunidades de trabalho e a demanda do aprimoramento contínuo	Aluna X12: Depende do emprego. Por exemplo, a tecnologia tá surgindo. Se você ficar parado, sem procurar saber como a tecnologia funciona, você vai perder sua área de serviço. Tem que ir acompanhando.
	Aluna X8: Gerando maior evolução da automação por meio da precisão de dados em diversas áreas.
	Aluna X2: Uma aprendizagem mais inteligente
	Aluno Y11: Monitoramento de ações das pessoas

A principal contribuição deste trabalho foi demonstrar para os alunos e alunas que o funcionamento do Neurônio Artificial e do Aprendizado de Máquina utiliza fundamentos da Matemática, neste caso especificamente da Regressão Linear, pois e com esse contexto é possível ter um olhar para além da forma como a Inteligência Artificial se apresenta na maioria dos contextos, mas este trabalho também apresenta limitações, pois a amostra é pequena, representa uma classe com quarenta alunos do Campus de Sertãozinho do IFSP, diante de um universo muito maior de Campi dos IF do Brasil, com contextos regionais muito diferentes culturalmente, onde podem existir outros vieses, e assim apresentar resultados diferentes, o que limita a generalização dos resultados.

A coleta dos dados físicos do salto de impulsão também foi uma limitação importante registrada de medição, pois com a utilização da fita métrica presas na cintura dos participantes demonstrou não ser precisa, necessitando diversos ajustes.

Este trabalho não esgota o assunto, existem questões que podem ser aprofundadas, como a contribuição no ensino de outras disciplinas além da Matemática utilizando ferramentas de *Machine Learning*.

Neste trabalho, os autores atuaram como pesquisadores na elaboração do Produto Educacional, que é composto por Sequência Didática e Planilha do Excel com as atividade de Regressão Linear e do Neurônio Artificial, e na aplicação do Produto educacional em Sala de Aula com os alunos, um dos autores atuou como professor e outro como pesquisador, que utilizou da caderneta de campo para anotar suas observações da atividade da Sequência Didática, que foram posteriormente validadas pelo professor, com alguns substratos expostos no Quadro 3.

Araujo (2022), esclarece a função da avaliação do conhecimento prévio do aluno e a função do pesquisador, na sequência didática, que o objetivo é a avaliação das necessidades cognitivas dos alunos, para se fazer uma análise da capacidade de reconhecimento das correlações de forma preliminar a aplicação, e dessa forma ter um diagnóstico capaz de orientar nas sequências das atividades.

Discussões

Tema 1: *Machine Learning* no Ensino de Matemática

Utilizando a função Afim para encontrar a melhor reta: os alunos utilizaram conceitos de Regressão Linear e *Machine Learning* através de cálculos manuais, conforme a Fig. 5 que ilustra esta atividade, posteriormente através da planilha do Excel, conforme ilustra a Fig. 6, com os mesmos dados coletados sobre a altura do salto de impulsão dos alunos foi possível encontrar a reta que melhor se ajustasse aos dados, permitindo ao aluno entender e estabelecer correlações entre ordenadas e abcissas no plano cartesiano, sobre os valores da altura do salto de impulsão dos alunos, fornecidos em uma tabela, e a influência desses dados na construção da reta, entendendo nessa atividade, que a margem de erro é tanto menor quanto mais preciso forem os cálculos, conforme corrobora o substrato da aluna X5, no Quadro 3: “*Após os cálculos, ela analisa os dados com os que foram dados e avalia o erro para se adaptar*”.

Utilizando a planilha de Regressão Linear, no Microsoft Excel, com geração de gráficos estatísticos para análises da melhor reta: através do substrato do aluno Y1: “*Através da coleta dos dados conseguimos usar a média para fazer especulações das capacidades físicas dos alunos*”, podemos inferir que a prática associada à teoria, nesta mesma atividade sobre a Regressão Linear na planilha do Excel, demonstrou a importância dos cálculos matemáticos na aprendizagem de máquinas e na predição

de dados, o que incentiva os alunos a explorar a relação entre Matemática e tecnologia, dando evidências de um aprendizado significativo.

Araújo (2002), identificou que os estudantes trabalham com associações estatísticas observando alguns procedimentos específicos de raciocínio, indicando atuarem diretamente na identificação de correlações. O autor ainda afirma que os problemas de identificação de correlações são chamados problemas correlacionais e o conjunto de processos do raciocínio necessários para resolver esses problemas é chamado raciocínio correlacional.

Demonstração da função Afim, utilizando o software da Microsoft Excel, no processo matemático dos Neurônios Artificiais e das Redes Neurais Artificiais: nesta categoria o substrato do aluno Y6 entende que: *“Faz uma conexão entre cálculos manuais e o funcionamento de um Neurônio Artificial”*, ou seja ele consegue relacionar o funcionamento de um Neurônio Artificial como processos matemáticos iguais aos que eles utilizaram nas atividades com a função Afim, para calcularem a melhor reta; isso permite observar o aprofundamento da compreensão dos alunos sobre a Matemática utilizada em Neurônios Artificiais e sua relação com *Machine Learning*.

Conforme Cardoso et al (2023), entre as possibilidades que a Inteligência Artificial tem de contribuir com a educação, a de maior destaque é a que os professores usem os recursos da Inteligência Artificial como uma metodologia ativa para a aprendizagem, pois dessa forma os alunos podem desenvolver a capacidade de fazer perguntas à Inteligência Artificial, e através das respostas possam elaborar novas perguntas, dessa forma o destaque não é a resposta da Inteligência Artificial, mas o desenvolvimento da capacidade do aluno de articular perguntas.

O impacto de *Outliers* em um conjunto de dados, no desvio do resultado: embora os *Outliers* não são causados somente por erros de medidas por máquinas, pois são dados que se desviam do padrão em um conjunto de dados, sua comprovação pode ser feita através de algoritmos, comparando os dados suspeitos com os demais pontos do conjunto, no substrato do aluno Y2 desta categoria: *“Os Outliers são erros de medidas causados pelas máquinas, pode-se concluir que são Outliers por conta da grande diferença de medida em relação aos outros”*, demonstra que o aluno entendeu o significado.

Demonstrando o refinamento do ajuste da melhor reta, utilizando uma Rede Neural Artificial, com programação em *Python*: o substrato da aluna X7: *“Gerando maior evolução da automação por meio da precisão de dados em diversas áreas”*, denota que esse conteúdo obteve o objetivo educacional de facilitar a compreensão dos alunos sobre a base Matemática elementar das Redes Neurais Artificiais e sua aplicação em predição de dados estatísticos, de forma mais avançada, como de fato é utilizado na prática, através da programação na linguagem *Python*, pois os alunos puderam entender especialmente no contexto de predição de dados estatísticos com a Regressão Linear, e como seus resultados podem ser refinados na precisão, através do processo de treinamento em *Machine Learning*, evidenciando a importância dos cálculos matemáticos aplicados para a previsão de dados estatísticos.

Para Brandão (2023, p. 9), a práxis com foco no algoritmo de classificação do computador de base vetorial interligando à Matemática, enfatiza a estratégia pedagógica, que utiliza como recurso didático matemático a implementação do aprendizado de máquina, inclui abordagem integrada com diversos conteúdos e exercícios, aproximando com este trabalho em vários aspectos didáticos, como a implementação de programação em *Python*.

Tema 2: Desafios e Impactos na Sociedade

O *Machine Learning* aprimora os recursos de sistemas e processos de automação, estabelecendo novas formas de construção social: o substrato do aluno Y7 nesta categoria, *“Automação dos processos repetitivos, monitoramento de resultados, facilita a busca de oportunidades e melhoria na precisão de dados”*, aponta na visão do aluno como grandes benefícios do *Machine Learning*, a maior precisão, otimização de tempo, a automação de processos repetitivos, e o auxílio em análises de dados.

Eficácia do *Machine Learning* em diagnósticos médicos em comparação com médicos humanos: nestes dois substratos desta categoria, foi exposto como possibilidades que, aluna X4, *“Pode ser utilizado como apoio na área da saúde”*, aluno Y1, *“Coleta dos exames e sintomas na medicina para associar às possíveis doenças junto com as análises dos médicos”*, assim é possível inferir que o *Machine Learning* tem a capacidade de associar os sintomas para identificação de doenças, porém na visão dos alunos essa tecnologia auxilia, mas não substitui completamente o trabalho do médico.

Importância dos dados representativos e não preconceituosos: nesta categoria foi exposto claramente, que existem riscos inerentes a se considerar, como a possibilidade de preconceitos nos dados, baixa empregabilidade, erros devido à padronização, como também consideraram as consequências negativas de decisões baseadas em dados errados, de forma que foi possível inferir ser imprescindível a filtragem de dados, com um cuidado maior na seleção desses dados para o treinamento adequado dos algoritmos, caso contrário poderá ocorrer resultados enviesados e prejudiciais; pois embora os algoritmos em si não sejam preconceituosos, os dados utilizados podem refletir preconceitos da sociedade; isso pode resultar em algoritmos que reproduzem esses vieses, e assim afetar as decisões e resultados de forma inadequada, já que aprendem a partir dos dados disponíveis, onde podemos destacar o substrato da aluna X2, com forte convergência com os demais substratos dessa categoria, *“O algoritmo age com reação aos dados, então se os dados são preconceituosos, os algoritmos também será. Os dados não são muito filtrados em relação a isso, então os dados podem ser preconceituosos”*

O *Machine Learning* afeta a privacidade e necessidade de regulamentação: é possível compreender a gravidade da preocupação desse substrato exposto pelo aluno Y5, *“A gente está sempre preocupado que a empresa que criou a IAS não seja habilitada. É por causa da regulamentação que os dados não são distorcidos”*, pois podem conter preconceitos, mentiras e também violar a privacidade das pessoas, para responder adequadamente a esses riscos faz-se necessária a regulamentação da utilização da Inteligência Artificial, realizada pelo estado, que deve representar a sociedade nesta ação, sendo destacado pela aluna X7, *“Durante as eleições, a gente sabe que algumas candidatas eleitorais não são fantásticas assim. Estão, tipo assim, errando a imagem delas, ou criando propagandas falsas delas e aí, tipo assim, prejudicavam a companhia delas ser essencial, como no caso de notícias falsas em eleições”*, para evitar distorções, usos ilegais e antiéticos do *Machine Learning*.

Conforme Sharifani; Amini (2023), com o avanço da tecnologia é necessário considerar as implicações éticas, o que inclui questões como o viés do algoritmo, a discriminação e a privacidade, afirmando que deve ocorrer empenho dos pesquisadores e profissionais da área, para o desenvolvimento de modelos com transparência e responsabilidade, pois dessa forma é possível assegurar mais confiança na utilização dessas ferramentas. Os autores afirmam ainda, que existe a necessidade de pessoas e organizações adquirirem as competências e os conhecimentos adequados para utilizar corretamente essa tecnologia, e isso só é

possível através da educação e da colaboração da academia, iniciativa privada e governo.

A importância da mitigação do erro no Machine Learning: a qualidade dos dados e a eficácia do treinamento do Machine Learning permitem mitigar o erro, causado por dados enviesados e (ou) critérios (regras) inadequadas, que são considerados inevitáveis, é o que indica os substratos da aluna X7, “Impossível evitar totalmente” (o erro), do aluno Y5, “Quanto maior o treinamento do Machine Learning menor o erro” e da aluna X2, “O erro depende também da qualidade dos dados”

Dessa forma a educação ampla, omnilateral e politécnica é o instrumento necessário para superar a alienação imposta a sociedade por interesses em desinformar para enganar as pessoas, ficando evidente que os dados sofrem influências distorcidas e podem replicar erros nas ferramentas de Inteligência Artificial, produzindo resultados equivocados e essa desinformação também pode levar a compreensão equivocadas com a consequente alienação das pessoas, de forma que estas acabem por agir de forma contrária aos seus próprios interesses.

Para Silva; Souza (2025), a articulação entre a Inteligência Artificial e a Psicologia Cognitiva é capaz de desenvolver inovações para a educação básica, pois a tecnologia de algoritmos adaptativos e as redes neurais favorecem as práticas pedagógicas ligadas ao processo cognitivo dos alunos, valoriza a mediação do conhecimento e o protagonismo do aluno, porém ressalva, serem necessárias diretrizes éticas e pedagógicas, que considerem melhorar a eficiência em um contexto da formação integral do aluno.

Tema 3: Mundo do Trabalho

O *Machine Learning* não substitui o trabalhador especializado, e amplia a capacidade profissional: as percepções dos alunos sobre os impactos do *Machine Learning* no ambiente profissional demonstraram que essa tecnologia amplia as capacidades humanas, como uma ferramenta complementar, que potencializa o trabalho humano, especialmente na identificação de falhas e otimização de processos; visto como uma forma de substituição de mão de obra em algumas funções, o que pode gerar desemprego ou redirecionamento de trabalhadores, porém não apresenta respaldo para substituir totalmente o trabalhador especializado, de forma indiscriminada e imediata, conforme encontra embasamento no substrato do aluno Y4, que cita exemplo na Agropecuária, “*Agropecuária, ensina ela a dirigir um trator de arar terra e diminuir os gastos com funcionário*”.

O ensino integrado na Educação Profissional e Tecnológica: nesta categoria destacamos o substrato da aluna X1, “*Utilização de metodologias diferentes, com didáticas adequadas e a necessidade de aumentar o foco, como ferramentas relevantes para o aprendizado*”, expressa ser fundamental a renovação de metodologias, com didáticas mais adequadas, exigindo ênfase no aprofundamento das novas ferramentas tecnológicas, esse contexto reafirma a necessidade de um ensino profissional e tecnológico que integre teoria e prática, enfatizando a importância de metodologias de ensino inovadoras para atender a novos desafios de novas tecnologias, com abordagens pedagógicas mais eficientes.

Conforme Kuenzer (2010), a prática pedagógica influi na aprendizagem como uma ferramenta de construção do conhecimento, integrando o contexto cultural da sociedade, e tem o objetivo de contribuir na formação humana, transformando cidadãos, para serem críticos e capazes de compreender a realidade além da sua aparência ou da forma como ela se apresenta.

A teoria e a prática integrada na aprendizagem de Matemática e *Machine Learning*: a importância da integração entre teoria e prática no ensino de Matemática e tecnologia com ênfase em conteúdos básicos, como de estatística, além da necessidade de constante atualização de conteúdos profissionais e tecnológicos, para acompanhar as novas exigências do mundo do trabalho foi uma constatação recorrente da preocupação dos alunos, durante a aplicação das atividades desta pesquisa, como reforça o substrato desta categoria da aluna X3, “O reforço da teoria e da prática, com exercícios e atividades como a principal forma de melhorar a compreensão”. Analisando o conjunto dos dados coletados dos alunos, já destacados, fica evidente a valorização dos alunos pelas metodologias que unem teoria e prática através de exercícios, a exemplo da atividade utilizada na Sequência Didática aplicada nesta pesquisa, que mostra a utilização real de conceitos matemáticos no funcionamento de Redes Neurais Artificiais e algoritmos de *Machine Learning*.

Para Kuenzer (2010), o professor precisa adotar práticas de aprendizagem, para permitir aos alunos associarem o conhecimento prévio ao contexto do mundo do trabalho, assim os alunos adquirem a capacidade de analisar e elaborar soluções para resolver problemas concretos.

Relacionando o *Machine Learning* com o trabalho repetitivo: nesta categoria foi destacado o substrato da aluna X5, “Na automatização do processo, em que é algo muito repetitivo, que uma, duas, três, quatro pessoas trabalharam, tipo, não precisaria dessas quatro pessoas que seriam mandadas embora, ou manteria apenas uma, só pra estar conseguindo dados”, que denota a preocupação real com o desemprego causado por inovações tecnológicas como o *Machine Learning*, especialmente em trabalhos repetitivos, mas como pode ser constatado na próxima categoria, é necessário acompanhar as mudanças causadas por inovações tecnológicas, se atualizar e buscar novas oportunidades, pois alguns empregos irão desaparecer, mas outros irão surgir.

Novas oportunidades de trabalho e a demanda do aprimoramento contínuo: o substrato da aluna X12, “Depende do emprego. Por exemplo, a tecnologia tá surgindo. Se você ficar parado, sem procurar saber como a tecnologia funciona, você vai perder sua área de serviço. Tem que ir acompanhando”, reflete sobre a importância de acompanhar o avanço da tecnologia, pois se não se atualizar na sua área profissional, possivelmente ficará desempregado, dessa forma o *Machine Learning* pode resultar em redução de emprego em uma determinada área de trabalho, porém pode gerar empregos com a criação de novas oportunidades de trabalho em outras áreas, demandando aprimoramento contínuo e a capacidade de acompanhar a evolução tecnológica, pois de acordo com a ideia de que o *Machine Learning* não substitui o trabalhador especializado, mas sim amplia sua capacidade, a resposta a esse paradigma está na Educação Profissional e Tecnológica, que qualifica adequadamente os estudantes, para a vida e para o mundo do trabalho, conforme demanda apontada nesta pesquisa.

Para Ramos (2014), que identifica o trabalho como categoria econômica, o que justificaria a formação específica para se exercer determinada profissão, porém ressalta, que a formação voltada para a produção, não é o mesmo que uma formação profissionalizante, pois esta necessita de compreender a forma de construção da vida produtiva socialmente.

Considerações finais

Este trabalho permitiu investigar, desenvolver e analisar como fundamentos de *Machine Learning* podem ser utilizados na Educação Profissional e Tecnológica, para

suporte no ensino de Matemática. Buscou-se abordar o embasamento matemático das estruturas de funcionamento de ferramentas como Regressão Linear e Redes Neurais Artificiais, e sua aplicação em predição a partir de dados.

A Análise Temática, conduzida conforme os pressupostos de Braun e Clarke, foi aplicada aos dados provenientes da Roda de Conversa realizada após a aplicação do produto educacional. A partir do processo de familiarização com os dados, codificação inicial, busca e revisão dos temas, foram identificados três temas centrais que sintetizam os sentidos atribuídos pelos participantes à experiência formativa. Esses temas evidenciam que o produto educacional não se restringe a uma abordagem instrumental ou tecnicista, mas está alinhado às bases conceituais da Educação Profissional e Tecnológica, ao articular fundamentos científicos, reflexão crítica sobre a tecnologia e sua inserção no mundo do trabalho, bem como a integração entre formação geral e formação técnica.

Verificou-se ainda por meio desta análise que os alunos foram capazes de compreender como é desenvolvido alguns algoritmos de Machine Learning, contribuindo não apenas para simples utilização da tecnologia, mas entendendo seu funcionamento, associando com aplicações práticas do mundo do trabalho como em variáveis nos processos industriais; quanto também na sua formação pessoal, onde vivem uma era de revolução tecnológica, com o advento da Inteligência Artificial.

Adicionalmente, constatou-se que os alunos foram capazes de refletir sobre a utilização da tecnologia do Machine Learning no mundo do trabalho e na sociedade, repercutindo favoravelmente com o intuito de contribuir para formação de profissionais analíticos e críticos.

Finalmente, verificou-se que o produto educacional desenvolvido demonstra potencial de abrangência nacional, uma vez que utiliza ferramentas de machine learning em formato simples e acessível. Sua replicabilidade é viável, desde que haja adaptações metodológicas e tecnológicas para atender diferentes contextos educacionais e realidades locais.

Referências

ARAÚJO, T. D. **O ensino de modelos de Regressão Linear no Ensino Médio: uma proposta visando o desenvolvimento do raciocínio correlacional**. USP, Instituto de Matemática e Estatística. São Paulo, 2022.

BARBOSA, Maria Isabel Gomes; DIAS, Rodrigo Carvalho. Educação Profissional e Tecnológica e o ensino de matemática: reflexões sobre estratégias para o desenvolvimento da proficiência. **Revista Sítio Novo**, Palmas, v. 9, p. e1735, 2025. DOI: <https://doi.org/10.47236/2594-7036.2025.v9.1735>.

BRANDÃO, D. A. **Inteligência Artificial e Aprendizado de Máquina: da teoria ao algoritmo pronto no Ensino Médio** - Universidade de Brasília – UnB Departamento de Matemática – MAT PROFMAT – SBM – Brasília, DF, 2023.

BRAUN, V. AND CLARKE, V. Using thematic analysis in psychology. **Qualitative Research in Psychology**, 3 (2). pp. 77-101. ISSN 1478-0887, 2006. Available from: <http://eprints.uwe.ac.uk/11735>. DOI: <http://dx.doi.org/10.1191/1478088706qp0630a>.

CARDOSO, F. et al. **O uso da inteligência artificial na educação e seus benefícios: uma revisão exploratória e bibliográfica**. IFSP, 2023.

DBR-Collective. Design-Based Research: An Emerging Paradigm for Educational Inquiry. **Educational Researcher**, 32(1), 5–8, 003. DOI: [10.3102/0013189X032001005](https://doi.org/10.3102/0013189X032001005).

DOMINSCHEK, D. L. A concepção de ensino pensada por Roberto Mangea formação de mão de obra SENAI: a escola do SENAI-PR. **História & Ensino**, v. 17, n. 1, p. 195-210, 2011.

GARCIA, A. B. **Avaliação de aprendizagem de conceitos de Machine Learning nos anos finais do ensino fundamental e ensino médio**. UFSC, Florianópolis, 2022.

Haykin S. **Redes Neurais - Princípios E Práticas**. Porto Alegre: Bookman, 2001.

IMPULSÃO VERTICAL. **Fitescola**, 2025. Disponível em: <https://fitescola.dge.mec.pt/detalhesTeste.aspx?id=10>. Acesso em: 12 fev. 2025.

KEHL, R. Machine Learning: construindo meu primeiro modelo. **Ilegra**, 2023 Disponível: <https://www.ilegra.com/pt/blog/machine-learning-construindo-meu-primeiro-modelo>. Acesso em: 22 dez. 2023.

KUENZER, A. et al. (Org.). **Formação de professores para a educação profissional e tecnológica. Convergências e tensões no campo da formação e do trabalho docente**. Belo Horizonte: Autêntica, 2010.

KNEUBIL, F. B.; PIETROCOLA, M. A Pesquisa Baseada em Design: visão geral e contribuições para o ensino de Ciências. **Investigações em Ensino de Ciências**, v. 22, n. 2, p. 01, 2017. DOI: <https://doi.org/10.22600/1518-8795.ienci2017v22n2p01>.

LONG e MAGERKO. What is AI Literacy? Competencies and Design Considerations. **CHI '20: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems**, Honolulu HI USA April 25 - 30, 2020.

MACHADO, V. P. **Inteligência Artificial**, Universidade estadual do Ceará, Rio Grande do Norte, 2009. Apostila, Disponível em: <https://www.uece.br/cct/wp-content/uploads/sites/28/2021/07/Intelige%CC%82ncia-Artificial.pdf>.

MAUHNOM, Y. **Aprendizado de máquina: a partir da Teoria do Aprendizado Estatístico e aplicação em redes neurais**. Universidade Federal Fluminense - Instituto de Ciências Exatas - Curso de Matemática - Volta Redonda, RJ, 2023.

RAMOS, M. Filosofia da práxis e práticas pedagógicas de formação de trabalhadores. **Trabalho & Educação** (UFMG), v. 23, p. 207-218, 2014. Disponível em: <https://periodicos.ufmg.br/index.php/trabedu/article/view/9306>.

SALTO CONTRAMOVIMENTO. **Athlon**, 2025. Disponível em: <https://athlon-esportes.com/salto-contramovimento/>. Acesso em: 20 mar. 2025.

SILVA, Isac Neto da; SOUZA, Júlio Cesar de. Inteligência Artificial e Psicologia Cognitiva: contribuições no desenvolvimento de tecnologias educacionais

adaptativas na educação básica. **Revista Sítio Novo**, Palmas, v. 9, p. e1781, 2025. DOI: <https://doi.org/10.47236/2594-7036.2025.v9.1781>.

SHARIFANI, K.; AMINI, M. Machine Learning and Deep Learning: A Review of Methods and Applications. **World Information Technology and Engineering Journal**. Volume 10, Issue 07 – 2023.

ZABALA, Antoni. **A prática educativa**: como ensinar. Porto Alegre: Artmed, 1998.

Informações complementares

Descrição		Declaração
Financiamento		Não se aplica.
Aprovação ética		CAAE 77468224.9.0000.5473 e Parecer número 6.754.173.
Conflito de interesses		Não há.
Disponibilidade dos dados de pesquisa subjacentes		Este trabalho não é um <i>preprint</i> e os conteúdos subjacentes ao texto da pesquisa estão contidos neste artigo.
Uso de Inteligência Artificial		Não há.
CrediT	Ciro Henrique Donnabella de Ávila	Funções: conceitualização; curadoria de dados; análise formal; investigação; metodologia; programas; escrita – rascunho original.
	André Luiz Dias	Funções: conceitualização; curadoria de dados; análise formal; investigação; metodologia; administração do projeto; programas; supervisão; escrita – revisão e edição.

Avaliadores: Ma. Mariana Hochmann Narciso* (Rede Estadual de Educação de Santa Catarina. Santa Catarina, Brasil). O avaliador “B” optou pela avaliação fechada e pelo anonimato.

Revisor do texto em português: Flávio Pereira**.

Revisor do texto em inglês: Rodrigo Silva Pires**.

Revisora do texto em espanhol: Graziani França Claudino de Anicézio.

Como citar:

ÁVILA, Ciro Henrique Donnabella de; DIAS, André Luiz. Explorando o Percéptron no Machine Learning para o ensino de Matemática na Educação Profissional e Tecnológica. **Revista Sítio Novo**, Palmas, v. 10, p. e1924, 2026. DOI: 10.47236/2594-7036.2026.v10.1924. Disponível em: <https://sitionovo.ifto.edu.br/index.php/sitionovo/article/view/1924>.

* Optou pela avaliação fechada e autorizou a divulgação da identidade no trabalho publicado e do parecer na página da Revista.

** Conforme informado pelos autores e comprovado pelos documentos anexados ao sistema.