



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Ramon Mayor Martins

**Estratégias para o Ensino de *Machine Learning* para Estudantes em
Vulnerabilidade Social no Ensino Fundamental e Médio**

Florianópolis

2024

Ramon Mayor Martins

**Estratégias para o Ensino de *Machine Learning* para Estudantes em
Vulnerabilidade Social no Ensino Fundamental e Médio**

Tese submetida ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Doutor em Ciência da Computação.

Orientador(a): Prof.^a Dr.^a rer. nat. Christiane Gresse von Wangenheim

Florianópolis

2024

Ficha catalográfica

Martins, Ramon Mayor

Estratégias para o Ensino de Machine Learning para Estudantes em Vulnerabilidade Social no Ensino Fundamental e Médio / Ramon Mayor Martins ; orientador, Christiane Gresse von Wangenheim, 2024.

172 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Ciência da Computação, Florianópolis, 2024.

Inclui referências.

1. Ciência da Computação. 2. Educação em computação. 3. Machine Learning. 4. Estratégia para o ensino. 5. Vulnerabilidade social. I. Gresse von Wangenheim, Christiane. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Ciência da Computação. III. Título.

Ramon Mayor Martins

Estratégias para o Ensino de *Machine Learning* para Estudantes em Vulnerabilidade Social no Ensino Fundamental e Médio

O presente trabalho em nível de Doutorado foi avaliado e aprovado, em 02 de Julho de 2024, pela banca examinadora composta pelos seguintes membros:

Prof. Mário de Noronha Neto, Dr.
Instituto Federal de Santa Catarina

Prof. Jorge Henrique Busatto Casagrande, Dr.
Instituto Federal de Santa Catarina

Prof. Rafael de Santiago, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Doutor em Ciência da Computação.

Insira neste espaço a
assinatura digital

Prof. Márcio Bastos Castro, Dr.
Coordenação do Programa de Pós-Graduação

Insira neste espaço a
assinatura digital

Prof.^a Dr.^a rer. nat. Christiane Gresse von Wangenheim,
Orientadora

Florianópolis, 2024.

À minha amada avó Fabiana Mayor, a maior professora do universo

AGRADECIMENTOS

Gostaria de agradecer a todos que contribuíram de uma forma ou de outra para o planejamento, execução e conclusão deste trabalho. Sinto-me honrado e grato por todos que me apoiaram.

Primeiramente agradeço a Deus por me dar forças a cada dia que passou para levantar e lutar. Agradecer meus pais Maria Aparecida Mayor Martins e Antonio Mauro Martins, irmã Manoela e sobrinha Lamis pelo amor e apoio incondicional.

Sou extremamente e profundamente grato à minha orientadora, a Prof.a Christiane Gresse von Wangenheim, por tudo, pela orientação, atenção, ajuda, ensinamentos, disponibilidade, carinho, preocupação e principalmente pela paciência comigo nesses anos de doutorado. Eu aprendi muito!

Agradeço ao Prof. Marcelo Fernando Rauber pela parceria maravilhosa, amizade e todo auxílio, tal qual uma dupla campeã em uma final de copa do mundo.

Agradeço a UFSC, todos os membros do GQS e à toda equipe da iniciativa Computação na Escola. Aos professores Dr. Jean Hauck, Dr. Adriano Borgatto e Prof. Deise Arndt por toda contribuição técnica e científica. Agradeço a todos estudantes e colaboradores do Programa PodeCrer do Instituto Vilson Groh, sem os quais este estudo não seria possível. Principalmente a Melissa Silvestre, que virou uma grande amiga. Agradeço ao IFSC, principalmente a área de Telecomunicações por me permitir realizar este sonho. Ao amigo Prof. Mário de Noronha que me incentivou a fazer o doutorado.

Gostaria de agradecer a minha cachorrinha Marie pelos momentos de alegria que me proporciona todos os dias e cura meus dias. Aos áudios da Camilinha, filha do meu amigo Prof. Roberto pelas doses de felicidade no dia.

Agradecer à TN *en vivo*, uma emissora de televisão de notícias da Argentina que me fez companhia todos esses anos em minha casa, para não ficar em silêncio.

Eu gostaria acima de tudo, me agradecer, por não esmorecer, por ter forças para lutar, para resistir, por trabalhar enquanto me falavam para descansar, por ter que às vezes dar dois passos para trás para conseguir dar um para frente, por dormir e acordar com disposição, por aceitar todos os desafios de cabeça erguida e ter consciência de que cumpri todos desafios. Por ficar em pé até o último *round*. E enquanto não ouvia o gongo, mesmo sem forças, eu não parei.

Eu sinto orgulho de mim.

...Ninguém vai bater tão forte quanto a vida. Mas não é sobre o quão forte você bate, é sobre o quão forte você pode ser atingido e continuar seguindo em frente. O quanto você pode aguentar e continuar lutando. É assim que se vence.

(Rocky Balboa, 2006)

RESUMO

O *Machine Learning* (ML) está cada vez mais integrado em nosso dia a dia, e é essencial ensinar ML aos jovens desde cedo, incluindo também jovens em situação de vulnerabilidade social. Apesar de existirem iniciativas para o ensino de ML, lacunas significativas persistem, especialmente na escassez de estratégias para o ensino de ML em contextos de vulnerabilidade social. Esta pesquisa busca preencher essa lacuna, propondo estratégias para o ensino de ML para estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social, visando responder à pergunta: como ensinar ML para esse contexto de forma eficaz, motivadora e que promova uma boa experiência de aprendizagem?. Utilizando uma abordagem multi-método que inclui mapeamento sistemático da literatura, análise de contexto educacional e o aprimoramento e aplicação do curso "*Machine Learning* para todos", a pesquisa avança o conhecimento sobre estratégias para o ensino de ML à estudantes em vulnerabilidade social. O curso, baseado em diretrizes curriculares e no processo de desenvolvimento de modelo de ML centrado no ser humano, aborda conceitos básicos de ML, com ênfase na classificação de imagens, adotando abordagens pedagógicas ativas e centradas no estudante, além de suportes tecnológicos acessíveis. O curso foi aplicado em uma série de estudos de caso e quase-experimentos para diferentes contextos socioeconômicos, incluindo os estudantes em vulnerabilidade social. Os resultados, indicam que as estratégias para o ensino de ML permitiram que os estudantes em situação de vulnerabilidade social alcançassem os objetivos de aprendizagem, inclusive de aplicar conceitos básicos de ML e desenvolver seu primeiro modelo de ML. Além disso, as estratégias para o ensino de ML proporcionaram uma experiência de aprendizado positiva. Apesar de algumas diferenças pontuais com outros contextos e dos desafios enfrentados por esses estudantes, não se observaram prejuízos em termos de aprendizagem ou experiência quanto à origem socioeconômica, sexo atribuído ao nascimento ou etapa educacional. Esses achados indicam que essas estratégias são eficazes para ensinar ML de forma motivadora, promovendo igualdade, equidade e inclusão no acesso ao conhecimento para todos os estudantes, independente de sua origem socioeconômica. Desta forma esta pesquisa contribui com a proposição de um modelo instrucional suprido com as estratégias para o ensino que consideram as especificidades do contexto de vulnerabilidade social, destacando a importância e a viabilidade de democratizar o ensino de ML.

Palavras-chave: *Machine Learning*; Educação; Vulnerabilidade social; Ensino Fundamental; Ensino Médio.

ABSTRACT

Machine Learning (ML) is increasingly integrated into our daily lives, and it is essential to teach ML to young people from an early age, including those in socially vulnerable situations. Despite existing initiatives for teaching ML, significant gaps remain, particularly in the lack of strategies for teaching ML in contexts of social vulnerability. This research seeks to fill this gap by proposing strategies for teaching ML to students in the final years of middle and high school who are in socially vulnerable situations, aiming to answer the question: How to effectively and motivatingly teach ML in this context, promoting a good learning experience?. Using a multi-method approach that includes systematic literature mapping, analysis of the educational context, and enhancement and application of the 'Machine Learning for All' course, the research advances knowledge about strategies for teaching ML to students in social vulnerability. The course, grounded in curricular guidelines and a human-centered ML model development process, covers basic ML concepts, with a focus on image classification, and adopts active, student-centered pedagogical approaches, along with accessible technological supports. The course was implemented in a series of case studies and quasi-experiments studies across different socioeconomic contexts, including those involving socially vulnerable students. The results, analyzed comprehensively, indicate that the strategies for teaching ML enabled students in socially vulnerable situations to achieve learning objectives, including applying basic ML concepts and developing their first ML models. Furthermore, the strategies for teaching ML provided a motivating and positive learning experience. Despite some distinct differences from other contexts and the challenges faced by these students, there were no learning or experiential disadvantages related to socioeconomic background, sex assigned at birth, or educational stage. These findings suggest that the strategies are effective for teaching ML in an engaging manner, promoting equality, equity, and inclusion in access to knowledge for all students, regardless of their socioeconomic background. Thus, this research contributes by proposing an instructional model supplied with teaching strategies that consider the specificities of the socially vulnerable context, highlighting the importance and feasibility of democratizing ML education.

Keywords: Machine Learning; Education; Social vulnerability; Middle School; High School.

LISTA DE FIGURAS

Figura 1 – Componentes das estratégias para o ensino.....	30
Figura 2 – Características das estratégias para o ensino de ML.....	31
Figura 3 – Processo de desenvolvimento de ML centrado no ser humano.....	48
Figura 4 – Processo de desenvolvimento de ML centrado no ser humano.....	66
Figura 5 – Exemplos de materiais instrucionais do curso "ML para todos!".....	70
Figura 6 – Exemplos de suporte tecnológico utilizados no curso "ML para todos!"...	72
Figura 7 – Critérios da avaliação baseada em desempenho e processo de desenvolvimento de ML centrado no ser humano.....	73
Figura 8 – Ferramenta CodeMaster.....	75
Figura 9 – Estudantes durante as aplicações para um contexto geral.....	81
Figura 10 – Estudantes nas aplicações no Programa PodeCrer/IVG.....	82
Figura 11 – Diagrama de fluxo estatístico por dados coletados.....	90
Figura 12 – Média por critério: dos estudantes em situação de vulnerabilidade social.	93
Figura 13 – Média por critério da avaliação: por sexo atribuído ao nascimento.....	96
Figura 14 – Média por critério da avaliação: por etapa educacional.....	100
Figura 15 – Média por critério da avaliação: por origem socioeconômica.....	105
Figura 16 – Média por critério da avaliação: por aplicação do curso.....	110
Figura 17 – Mapa de calor dos resultados de aprendizagem por critérios específicos.	129
Figura 18 – Diagrama Sankey: limitações, consequências e soluções no curso.....	136

LISTA DE QUADROS

Quadro 1 – Metodologia de pesquisa.....	23
Quadro 2 – Termos associados/correlatos ao contexto de vulnerabilidade social.....	28
Quadro 3 – Conceitos e práticas para o ensino de computação na educação básica..	32
Quadro 4 – Competências do estudante em IA.....	33
Quadro 5 – Visão geral dos principais algoritmos de ML/DL.....	35
Quadro 6 – Visão geral das principais métricas usadas em ML e DL.....	36
Quadro 7 – Metodologias de aprendizagem.....	38
Quadro 8 – Métodos instrucionais.....	39
Quadro 9 – Tipos de materiais instrucionais.....	39
Quadro 10 – Tipos de modos instrucionais.....	40
Quadro 11 – Tipos de suportes tecnológicos.....	40
Quadro 12 – Métodos de avaliação da aprendizagem e feedback.....	43
Quadro 13 – Etapas do framework CRISP-ML(Q).....	45
Quadro 14 – Etapas do framework AWS Well-Architected Machine Learning Lens..	45
Quadro 15 – Etapas do framework TDSP.....	46
Quadro 16 – Processo de desenvolvimento de ML centrado no ser humano.....	48
Quadro 17 – Comparativo dos processos de desenvolvimento de ML.....	49
Quadro 18 – Critérios de inclusão/exclusão.....	51
Quadro 19 – Termos de busca.....	52
Quadro 20 – String de busca genérica.....	52
Quadro 21 – String de busca por fonte de dados.....	52
Quadro 22 – Visão geral das unidades instrucionais.....	54
Quadro 23 – Competências e conteúdos de IA/ML das unidades instrucionais.....	55
Quadro 24 – Características das unidades instrucionais.....	56
Quadro 25 – Limitações, consequências e soluções das unidades instrucionais.....	57
Quadro 26 – Principais achados quanto às estratégias para o ensino de IA/ML.....	58
Quadro 27 – Objetivos de aprendizagem do curso "ML para todos!".....	64

Quadro 28 – Processo de desenvolvimento de ML centrado no ser humano.....	67
Quadro 29 – Avaliação de aprendizagem por objetivo de aprendizagem.....	75
Quadro 30 – Plano de ensino do curso "ML para todos!".....	77
Quadro 31 – Coleta de dados.....	86
Quadro 32 – Desempenho dos estudantes em vulnerabilidade social.....	91
Quadro 33 – Desempenho por critério: dos estudantes em vulnerabilidade social..	92
Quadro 34 – Percepção de aprendizagem dos estudantes em vulnerabilidade social..	93
Quadro 35 – Comparação do desempenho por sexo atribuído ao nascimento.....	94
Quadro 36 – Análise por critério da avaliação: por sexo atribuído ao nascimento....	96
Quadro 37 – Percepção de aprendizagem por sexo atribuído ao nascimento.....	97
Quadro 38 – Comparação do desempenho por etapa educacional.....	98
Quadro 39 – Análise por critério da avaliação: por etapa educacional.....	100
Quadro 40 – Percepção de aprendizagem por etapa educacional.....	102
Quadro 41 – Comparação do desempenho por origem socioeconômica.....	103
Quadro 42 – Análise por critério da avaliação: por origem socioeconômica.....	106
Quadro 43 – Percepção de aprendizagem por origem socioeconômica.....	107
Quadro 44 – Comparação do desempenho por aplicação do curso.....	108
Quadro 45 – Análise por critério da avaliação: por aplicação do curso.....	111
Quadro 46 – Percepção de aprendizagem por aplicação do curso.....	112
Quadro 47 – Percepção de experiência dos estudantes em vulnerabilidade social	113
Quadro 48 – Percepção de experiência: por sexo atribuído ao nascimento.....	115
Quadro 49 – Percepção de experiência: por etapa educacional.....	116
Quadro 50 – Percepção de experiência: por origem socioeconômica.....	118
Quadro 51 – Percepção de experiência: por aplicação do curso.....	119
Quadro 52 – Limitações, consequências e soluções adotadas no curso.....	128
Quadro 53 – Publicações científicas com os objetivos específicos da pesquisa.....	144

LISTA DE TABELAS

Tabela 1 – Extrato de artigos identificados por etapa de seleção.....	53
Tabela 2 – Rubrica de pontuação da avaliação baseada em desempenho.....	74
Tabela 3 – Visão geral das aplicações do curso "ML para todos!".....	78
Tabela 4 – Distribuição demográfica dos estudantes.....	79
Tabela 5 – Quantidade de dados coletados – contexto geral.....	87
Tabela 6 – Quantidade de dados coletados – contexto de vulnerabilidade social....	87
Tabela 7 – Observações dos instrutores.....	88
Tabela 8 – Análises inferenciais por sexo atribuído ao nascimento.....	95
Tabela 9 – Desempenho por critério da avaliação: por sexo atribuído ao nascimento..	95
Tabela 10 – Análises inferenciais por etapa educacional.....	99
Tabela 11 – Desempenho por critério da avaliação: por etapa educacional.....	99
Tabela 12 – Análises inferenciais por origem socioeconômica.....	103
Tabela 13 – Desempenho por critério da avaliação: por origem socioeconômica...	104
Tabela 14 – Análises inferenciais por aplicação do curso.....	109
Tabela 15 – Desempenho por critério da avaliação: por aplicação do curso.....	109

LISTA DE ABREVIATURAS E SIGLAS

ADDIE	Analisar, Projetar, Desenvolver, Implementar e Avaliar
BNCC	Base Nacional Comum Curricular
CEB	Câmara de Educação Básica
CNE	Conselho Nacional de Educação
CNNs	Redes Neurais Convolucionais
CS	Ciência da Computação
CSTA	Associação de Professores de Ciência da Computação
CV	Coeficiente de variação
DBR	Pesquisa Baseada em Design (<i>Design-Based Research</i>)
DL	<i>Deep Learning</i>
DP	Desvio padrão
ES	Engenharia de <i>Software</i>
GANs	Redes Adversárias Generativas
GTM	Google Teachable Machine
HCML	Desenvolvimento de <i>ML</i> centrado no ser humano (<i>Human-centered Machine Learning</i>)
IA	Inteligência Artificial
IDEB	Índice de Desenvolvimento da Educação Básica
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IEC	<i>International Electrotechnical Commission</i>
IQR	Intervalo interquartil
IMT	<i>Interactive Machine Teaching</i>
IML	<i>Interactive Machine Learning</i>
INCoD	Instituto Nacional para Convergência Digital
INE	Departamento de Informática e Estatística
ISO	<i>International Organization for Standardization</i>
IVG	Instituto Pe. Wilson Groh
K-12	Ensino Fundamental e Médio (termo usado nos EUA para se referir a essas etapas de ensino)
LGPD	Lei Geral de Proteção de Dados Pessoais

MEC	Ministério da Educação
ML	<i>Machine Learning</i>
NLP	Processamento de linguagem natural
PPGCC	Pós-Graduação em Ciência da Computação
RNNs	Redes Neurais Recorrentes
RNA	Redes Neurais Artificiais
SAEB	Sistema de Avaliação da Educação Básica
SBC	Sociedade Brasileira de Computação
SES	Status socioeconômico
STEM	Ciência, Tecnologia, Engenharia e Matemática
TDAH	Transtorno do Déficit de Atenção com Hiperatividade
TI	Tecnologia da Informação
TIC	Tecnologias da Informação e da Comunicação
TPACK	<i>Technological Pedagogical Content Knowledge</i>
UFSC	Universidade Federal de Santa Catarina
UMC	Usar-Modificar-Criar (<i>Use-Modify-Create</i>)

LISTA DE SÍMBOLOS

α	Alfa
χ^2	Qui-quadrado
ω	Ômega
H_0	Hipótese nula
H_a	Hipótese alternativa

SUMÁRIO

1 INTRODUÇÃO.....	16
1.1 CONTEXTUALIZAÇÃO.....	16
1.2 PROBLEMA.....	18
1.3 OBJETIVOS.....	19
1.4 ORIGINALIDADE DA PESQUISA.....	20
1.5 CONTRIBUIÇÕES.....	21
1.6 ADERÊNCIA DO TEMA AO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO.....	22
1.7 METODOLOGIA DE PESQUISA.....	23
2 FUNDAMENTAÇÃO TEÓRICA.....	28
2.1 CARACTERIZAÇÃO DE JOVENS EM SITUAÇÃO DE VULNERABILIDADE SOCIAL.....	28
2.2 ESTRATÉGIAS PARA O ENSINO DE <i>MACHINE LEARNING</i> NA EDUCAÇÃO BÁSICA.....	30
2.3 PROCESSO DE DESENVOLVIMENTO DE <i>ML</i>	44
3 ESTADO DA ARTE.....	50
3.1 DEFINIÇÃO DO PROTOCOLO DE REVISÃO.....	50
3.2 EXECUÇÃO DA BUSCA.....	53
3.3 ANÁLISE DOS RESULTADOS.....	53
3.4 DISCUSSÃO.....	58
4 MODELO INSTRUCIONAL PARA ENSINO DE <i>ML</i> A ESTUDANTES VULNERÁVEIS.....	61
4.1 ANÁLISE DE CONTEXTO.....	61
4.2 DEFINIÇÃO, DESENVOLVIMENTO E PLANEJAMENTO DO CURSO.....	63
5 APLICAÇÃO DO CURSO "<i>ML</i> PARA TODOS!".....	78
6 AVALIAÇÃO DO MODELO INSTRUCIONAL DO CURSO "<i>ML</i> PARA TODOS!"	83
6.1 DEFINIÇÃO DA AVALIAÇÃO.....	83
6.2 COLETA DE DADOS.....	85

6.3 ANÁLISE E INTERPRETAÇÃO DOS DADOS COLETADOS.....	88
6.4 RESULTADOS.....	90
6.4.1 Quais foram os resultados de aprendizagem de conceitos básicos de <i>ML</i> dos estudantes em vulnerabilidade social?.....	91
6.4.2 Qual foi a percepção de experiência de aprendizagem dos estudantes em vulnerabilidade social?.....	112
6.4.3 Quais foram os desafios e soluções no ensino de <i>ML</i> para estudantes no contexto de vulnerabilidade social?.....	120
6.5 DISCUSSÃO.....	129
7 CONTRIBUIÇÕES.....	139
7.1 RESULTADOS DE PESQUISA.....	139
7.2 COMPARAÇÃO COM AS INICIATIVAS EXISTENTES.....	140
7.3 CONTRIBUIÇÕES CIENTÍFICAS.....	142
7.3.1 Publicações científicas.....	143
8 CONCLUSÃO.....	145
8.1 TRABALHOS FUTUROS.....	146
REFERÊNCIAS	147
APÊNDICE A — RUBRICA DE HABILIDADES DE INFORMÁTICA BÁSICA	160
APÊNDICE B — FEEDBACK DOS ESTUDANTES EM SITUAÇÃO DE VULNERABILIDADE SOCIAL SOBRE O CURSO	162
ANEXO A — CHECKLIST TESTE AMBIENTE TÉCNICO PARA A APLICAÇÃO DOS CURSOS DA COMPUTAÇÃO NA ESCOLA	165
ANEXO B — MODELO DO CARTÃO SENHA PARA OS ESTUDANTES	167

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Machine Learning (ML), é um ramo da Inteligência Artificial (IA) e da ciência da computação que se concentra no uso de dados e algoritmos para permitir que a IA imite a maneira como os humanos aprendem, melhorando gradualmente sua precisão (IBM, 2024). O *ML* desempenha um papel cada vez mais importante em nosso cotidiano como parte de uma grande variedade de aplicações, tais como sistemas de reconhecimento facial, assistentes inteligentes, reconhecimento de imagem, etc. (Li, 2022). Portanto, está se tornando um entendimento comum que os estudantes precisam estar preparados para desenvolverem-se no futuro com *IA/ML* já na escola (Pedró et al., 2019; Estevez et al., 2019; Burgsteiner et al., 2016). A familiarização dos jovens com estes temas são, portanto, aspectos cruciais para os sistemas educacionais em todo o mundo, a fim de permitir-lhes uma participação social e econômica (Touretzky et al., 2019). Além disso, é importante permitir que os jovens se tornem usuários responsáveis e criadores de soluções inteligentes (Touretzky et al., 2019). Essa necessidade é acentuada pela crescente demanda por profissionais de IA (World Economic Forum, 2020) e pelo surgimento de novas oportunidades de emprego nessa área (Squicciarini e Nachtigall, 2021).

Recentemente, iniciativas como o projeto AI4K12 (Inteligência Artificial para Ensino Fundamental e Médio) e o programa Erasmus+ surgiram para ensinar conceitos de *IA/ML* para estudantes desde cedo (Touretzky et al., 2022; UNESCO, 2022; AI4K12, 2020). Estudos mostraram que os estudantes dessa etapa educacional têm condições de compreender conceitos centrais de *IA/ML* (Huang et al., 2021; Chua et al., 2019). Nesta etapa educacional são tipicamente abordados o ensino de conceitos básicos de *ML*, como fundamentos de Redes Neurais Artificiais e questões éticas (Touretzky et al., 2019).

No entanto, é possível observar muitas desigualdades devido a vários aspectos do contexto dos jovens estudantes, como sua cidadania, raça, etnia, e status socioeconômico (SES) (Parker e Guzdial, 2015; UNRISDSP, 2015). Os estudantes em situação de vulnerabilidade social, provenientes de famílias socioeconomicamente desfavorecidas, são especialmente prejudicados devido a uma série de limitações que enfrentam, como p. ex. a falta de infraestrutura e

qualidade nas escolas que frequentam, a falta de conhecimento prévio ou experiência em computação básica (OECD PISA, 2018; Parker e Guzdial, 2015).

Algumas iniciativas começaram a abordar a educação em IA/ML como uma das missões para promover a inclusão, igualdade e a diversidade dos estudantes, como a AI4ALL (AI4ALL, 2023), *The Coding School* (TCS, 2023) e *IBM SkillsBuild* (IBM, 2023), oferecendo programas educacionais gratuitos para despertar o potencial dos estudantes. Entretanto, essas iniciativas não são específicas para o contexto de estudantes em situação de vulnerabilidade social. Poucos cursos têm como objetivo específico ensinar IA/ML para estudantes nesse contexto, acessível a estudantes sem conhecimento prévio de computação básica, sem experiência com dispositivos digitais e com heterogeneidade de idade, desde o Ensino Fundamental até o Ensino Médio (Martins e Gresse von Wangenheim, 2024).

Diante desse cenário, é necessário investigar estratégias para o ensino de ML para estudantes do Ensino Fundamental e Médio dentro de um contexto de vulnerabilidade social.

Em contraste, as estratégias para o ensino de ML para jovens estudantes em um contexto geral na educação básica emergiram (Martins e Gresse von Wangenheim, 2023; Marques et al., 2020; Martins-Pacheco et al., 2019; Lye e Koh, 2014; Garneli et al., 2015). E as questões do que ensinar (conteúdo), como ensinar (abordagens pedagógicas), qual suporte tecnológico utilizar (tecnologia), e como avaliar, gradualmente estão sendo reveladas (Martins e Gresse von Wangenheim, 2023; Yue et al., 2022). Alguns trabalhos realizaram esforços para identificar estratégias para o ensino de IA/ML para jovens estudantes em um contexto geral. Zhou et al. (2020), conduziram uma revisão exploratória da literatura com relação ao desenvolvimento de experiências de aprendizagem da IA na educação básica. Tedre et al. (2021) e Marques et al. (2020) conduziram revisões do ensino de ML nas escolas. Com foco em abordagens pedagógicas, Sanusi e Oyelere (2020) examinaram como o ML tem sido ensinado no passado recente e exploraram metodologias adequadas para a educação básica. Todavia, apesar desses avanços para estudantes em um contexto geral, existe uma lacuna evidente, pois nenhum desses trabalhos analisam e/ou propõem estratégias para o ensino de IA/ML no contexto de jovens em situação de vulnerabilidade social. Observa-se apenas panoramas gerais na educação em computação para esse contexto (Martins e Gresse von Wangenheim, 2024). Van der Meulen et al. (2021) estudaram os dados

demográficos dos estudantes envolvidos no ensino de computação no Ensino Fundamental e Médio, incluindo considerações sobre seus status socioeconômicos. Parker e Guzdial (2015) analisaram as pesquisas existentes visando identificar privilégios e a desigualdade na educação *STEM* (Ciência, Tecnologia, Engenharia e Matemática) e na computação.

Portanto, o objetivo desta pesquisa é analisar e propor estratégias para o ensino de conceitos básicos de *ML* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio. Isto inclui o desenvolvimento, aplicações e avaliação de um curso adotando diversos conteúdos, abordagens pedagógicas, suportes tecnológicos e forma de avaliação que podem ser utilizados neste contexto. As análises buscam compreender como esse ensino dentro das necessidades e/ou limitações específicas pode ser eficaz para possibilitar a aprendizagem desses conceitos de *ML*. Adicionalmente, como ensinar de forma motivadora e que promova uma boa experiência de aprendizagem para os estudantes em situação de vulnerabilidade social.

Os resultados desta pesquisa podem ser usados para orientar e facilitar o projeto e desenvolvimento de unidades instrucionais destinadas ao ensino-aprendizagem de *ML* nos anos finais do Ensino Fundamental e Ensino Médio dentro de um contexto de vulnerabilidade social. Desse modo, visa incentivar os estudantes a seguirem carreiras *STEM* e possibilitar melhores oportunidades na carreira profissional nesta área emergente. Sobretudo, visa construir a igualdade, equidade e inclusão, criando condições para que esses estudantes em situação de vulnerabilidade social possam ser competitivos no mercado de trabalho, superem as adversidades e conquistem um futuro mais promissor para si e para suas famílias.

1.2 PROBLEMA

A maioria dos cursos para ensinar conceitos e técnicas de *ML* são direcionados para estudantes adultos no Ensino Superior (p. ex., Wunderlich et al., 2021; Hagen et al., 2020; Wang et al., 2019). Somente mais recentemente estão emergindo também cursos para estudantes da educação básica (p. ex., Su e Zhong, 2022; Rodriguez-Garcia et al., 2021;2019; Van Brummelen et al., 2021; Van Brummelen, 2019). Ainda assim, há uma deficiência de estudos sobre a abordagem de iniciativas para o ensino de computação/IA/*ML* para o contexto de estudantes em

situação de vulnerabilidade social (Martins e Gresse von Wangenheim, 2024). Conseqüentemente, observa-se uma ausência de propostas de estratégias para o ensino de *ML* para estudantes neste contexto. E dessa forma, a questão do que ensinar (conteúdo e sequenciamento de conteúdo), como ensinar (abordagens pedagógicas), quais suportes tecnológicos utilizar e como avaliar, permanece em aberto. Adicionalmente, é escasso os achados quanto aos desafios impostos para o ensino de *IA/ML* nesse contexto como a identificação das necessidades e/ou limitações enfrentadas, as conseqüências e as abordagens para solução de mitigação na aplicação de cursos para esse contexto (Martins e Gresse von Wangenheim, 2024). Portanto, visa-se estudar nesta tese a seguinte pergunta de pesquisa:

Pergunta de pesquisa. Como ensinar *Machine Learning* para o contexto de estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio de forma eficaz para possibilitar a aprendizagem de conceitos básicos de *ML* e, ao mesmo tempo, de forma motivadora e que promova uma boa experiência de aprendizagem?

1.3 OBJETIVOS

O principal objetivo desta pesquisa é propor estratégias para o ensino de *Machine Learning* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio. Para atingir o objetivo principal, são definidos os seguintes objetivos específicos:

OE1. Identificar o estado da arte das estratégias para o ensino de *ML* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio.

OE2. Analisar o contexto de ensino de *ML* para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Ensino Médio.

OE3. Design de estratégias para o ensino como parte do curso para o ensino de *ML* em português do Brasil, incluindo a definição de recomendações de conteúdo/sequenciamento, abordagens pedagógicas, suportes tecnológicos e formas de avaliações. Neste contexto também prevê-se a definição de um modelo de processo de desenvolvimento de modelos de classificação de imagens usando *ML* simplificado a ser utilizado no curso.

OE4. Aplicação do curso para ensino de *ML* na prática, para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Ensino Médio.

OE5. Avaliação das estratégias recomendadas com relação à eficácia da aprendizagem e experiência de aprendizagem, incluindo a comparação por origem socioeconômica, sexo atribuído ao nascimento, e por etapa educacional.

1.4 ORIGINALIDADE DA PESQUISA

Essa pesquisa é inédita em relação a vários aspectos. Primeiramente, com base em resultados da análise do estado da arte, as questões que contemplam as estratégias para o ensino de *ML* são praticamente inexistentes. A questão do que ensinar (conteúdo e sequenciamento de conteúdo), como ensinar (abordagens pedagógicas), qual suporte tecnológico utilizar e como avaliar, ainda permanece em aberto (Martins e Gresse von Wangenheim, 2024; 2023). Essa pesquisa visa identificar e propor essas estratégias por meio de uma série de estudos de casos e quase-experimentos na prática.

Adicionalmente, as iniciativas existentes de ensino de *ML* para jovens estudantes não procedem o ensino por meio de um processo de desenvolvimento de modelo de *ML*, e esta pesquisa propõe estratégias para o ensino a partir de um processo de desenvolvimento de modelo de *ML* centrado no ser humano.

Do estado da arte, apesar dos resultados apontarem que existam esforços para o ensino de *IA/ML* para estudantes na educação básica, esses esforços se concentram em um contexto socioeconômico geral (Martins e Gresse von Wangenheim, 2024). Assim, essa pesquisa contribui ao cobrir essa lacuna com a identificação e proposta de estratégias para o ensino de *ML* com o foco em estudantes em um contexto de situação de vulnerabilidade social.

Mesmo iniciativas que visam ensinar computação, *IA/ML* para estudantes em vulnerabilidade social exibem limitações, como a barreira do idioma para estudantes que não são fluentes em inglês (Martins e Gresse von Wangenheim, 2024; EF EPI, 2023). Nesse sentido, a presente pesquisa visa estabelecer estratégias para o ensino de *ML* em português do Brasil.

Diferente das poucas iniciativas encontradas, que fornecem algumas descobertas sobre o aprendizado de conceitos de *IA/ML* entre estudantes em

vulnerabilidade social, estas se concentram apenas na avaliação de fatores (p. ex. resultados de aprendizagem, tensões e envolvimento), sem compará-los com estudantes de diferentes origens socioeconômicas (Martins e Gresse von Wangenheim, 2024). Porém, essa comparação é importante para determinar se, considerando os desafios e as disparidades enfrentadas por estudantes em vulnerabilidade social, há prejuízo de aprendizagem com estudantes de origens socioeconômicas diversas.

Portanto, essa pesquisa é inédita também em realizar análises comparativas sobre esses fatores, procurando investigar se há diferenças significativas no aprendizado do estudante. Além disso, visa analisar se os estudantes em vulnerabilidade social percebem e vivenciam o aprendizado de *ML* de forma diferente em comparação com seus pares de origem socioeconômica geral.

1.5 CONTRIBUIÇÕES

Esta pesquisa, em nível de tese de doutorado, possui as seguintes contribuições nos âmbitos científico, tecnológico, educacional e social.

Contribuição científica — Como resultado da presente pesquisa é fornecido a definição de um modelo de processo de desenvolvimento de *ML* para os anos finais do Ensino Fundamental e Ensino Médio, considerando os princípios de Engenharia de *Software*. Essa definição é importante, visto que nenhuma unidade instrucional nesta etapa educacional define o processo de *ML* ajustado para este contexto educacional. O modelo instrucional é suprido com as estratégias para o ensino da competência *ML* no contexto educacional para estudantes em situação de vulnerabilidade social. O modelo instrucional desenvolvido é inédito, no sentido de oferecer alternativas de conteúdo, abordagens pedagógicas, suporte tecnológico e forma de avaliação e *feedback* de acordo com características do contexto.

Contribuição tecnológica — Como contribuição tecnológica foi criada a instância do modelo por meio da criação de um curso online, desenvolvimento e melhorias de ferramentas para suporte tecnológico ao ensino de *ML* utilizando também mecanismos automatizados de avaliação da aprendizagem dos estudantes em situação de vulnerabilidade social.

Contribuição educacional e social — As contribuições sociais da presente pesquisa são significativas, pois neste âmbito as instituições e escolas dos anos

finais do Ensino Fundamental e Ensino Médio poderão utilizar o modelo instrucional proposto, com suas estratégias para o ensino de *ML* desenvolvidas, para fins interdisciplinares. De forma geral, a pesquisa contribui com a popularização de *ML* de forma prática, à sua aplicação e para o crescimento desta área de conhecimento entre jovens. Sobretudo, a pesquisa visa oportunizar e democratizar o acesso ao conhecimento de *ML* para jovens em situação de vulnerabilidade social de modo a promover sua inclusão, igualdade e equidade social e digital. Além disso, contribui potencialmente com a formação da população em geral, bem como também estimula o interesse para a atuação nesta área e áreas correlatas, tornando o estudante envolvido, um transformador social. Essa transformação é particularmente relevante para estudantes em situação de vulnerabilidade social, fomentando sua integração e participação ativa na sociedade, ajudando-os a superar adversidades, prepará-los para um mercado de trabalho competitivo e dar os subsídios para assegurar um futuro promissor para eles e suas famílias.

1.6 ADERÊNCIA DO TEMA AO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

A presente tese faz parte da linha de pesquisa de Engenharia de *Software* (ES) do Programa de Pós-Graduação em Ciência da Computação (PPGCC) sobre o subtópico Computação na Escola¹. Esta pesquisa está inserida nos tópicos de Processo de Desenvolvimento de *Software* e Qualidade de *Software*, consoante a definição da área de Engenharia de *Software* da Sociedade Brasileira de Computação (SBC, 2005). Especificamente, esta pesquisa se concentra em desenvolver um modelo instrucional de conceitos de ES aplicado ao desenvolvimento de modelos de *ML*. Modela-se um processo de *software* simplificado para desenvolver modelos de *ML* no contexto do ensino destes conceitos para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio. Além disso, aborda a avaliação e medição da qualidade de produtos de *ML*, criados como resultados da aprendizagem no contexto educacional.

¹ <https://ppgcc.ufsc.br/linhas-de-pesquisa-2/>

1.7 METODOLOGIA DE PESQUISA

Esta pesquisa é classificada, quanto à sua natureza, como aplicada, pois o modelo proposto poderá ser utilizado por instituições de ensino e escolas para ensinar *ML* para os anos finais do Ensino Fundamental e Ensino Médio. Quanto ao objetivo, a pesquisa se classifica como exploratória, pois para contemplar o objetivo é preciso analisar o estado da arte e levantamentos bibliográficos. Também é classificada como descritiva, uma vez que descreve uma realidade e será feito o uso de abordagens de campo, levantamento de dados e observação sistemática para a conclusão das etapas finais dos objetivos específicos (Saunders et al., 2019).

Para atingir os objetivos específicos, é adotado um método multi-método para cada etapa da pesquisa (Saunders et al., 2019). A abordagem definida para alcançar o objetivo desta pesquisa está dividida em 4 etapas (Quadro 1).

Quadro 1 – Metodologia de pesquisa

Etapas	Atividades	Métodos de pesquisa	Resultados	
Etapa 1. Identificar o estado da arte	<ul style="list-style-type: none"> Definição dos objetivos de pesquisa Definição do protocolo de revisão Busca, identificação e seleção de estudos relevantes Extração, análise, síntese e discussão dos estudos relevantes 	Mapeamento sistemático (Petersen et al., 2008)	<ul style="list-style-type: none"> Análise do estado da arte 	
Etapa 2. Analisar o contexto educacional	<ul style="list-style-type: none"> Identificar o público-alvo Identificar o conceito educacional Análise de ambiente de ensino-aprendizagem 	Análise, do método ADDIE (Branch, 2009)	<ul style="list-style-type: none"> Caracterização do contexto 	
Etapa 3. Desenvolver o curso	<ul style="list-style-type: none"> Design do curso Definição do processo de desenvolvimento de <i>ML</i> Desenvolvimento dos materiais 	Design, do método ADDIE (Branch, 2009) Pesquisa-ação (Kemmis et al., 2021) <i>Design-Based-Research</i> (DBR) (Philippakos et al., 2021)	<ul style="list-style-type: none"> Modelo instrucional para o ensino de <i>ML</i> para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio Plano de ensino (objetivos de aprendizagem e estratégias para o ensino) Materiais instrucionais 	
Etapa 4. Aplicar e analisar os resultados do curso	<ul style="list-style-type: none"> Etapa 4.1. Definição da série de estudos Etapa 4.2. Execução da série de estudos Etapa 4.3. Análise e interpretação dos dados coletados 	<ul style="list-style-type: none"> Aplicação do curso por meio de séries de estudos de caso e quase-experimento Definição de fatores mensuráveis ou observáveis da qualidade do curso Análise de dados coletados 	Aplicação e Avaliação, do método ADDIE (Branch, 2009) Abordagem <i>Goal/Question/Metric</i> (GQM) (Basili et al., 1994) Estudo de caso (Yin, 2017) Estudo quase-experimental (Shadish et al., 2002) Análises estatísticas (Spiegel e Stephens, 2008)	<ul style="list-style-type: none"> Dados coletados com os fatores de qualidade do curso Resultados, interpretação e discussão das análises

Fonte: elaborado pelo autor

Etapa 1. Identificar o estado da arte — A fim de identificar o estado da arte foi realizado um mapeamento sistemático da literatura para identificar o ensino de IA

e *ML* para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Ensino Médio. O processo em forma de mapeamento sistemático é dividido em três fases: definição, execução e análise. Na fase de definição, os objetivos da pesquisa são identificados, e um protocolo de mapeamento sistemático é definido (Petersen et al., 2008; 2015). O protocolo especifica as questões centrais de pesquisa e os procedimentos que serão utilizados para conduzir o mapeamento, incluindo a definição de critérios de inclusão/exclusão, critérios de qualidade, fontes de dados e *strings* de busca. A fase de execução consiste na busca e identificação de estudos relevantes, e sua seleção seguindo os critérios de inclusão/exclusão e de qualidade estabelecidos no protocolo. Uma vez identificados, os dados relacionados às questões de pesquisa são extraídos dos estudos relevantes, analisados, sintetizados e discutidos durante a fase de análise.

Etapa 2. Analisar o contexto educacional — Seguindo o método ADDIE (*Analysis, Design, Development, Implementation, Evaluation*) (Branch, 2009), é realizada a análise de contexto para identificar as características do público-alvo, estabelecer o conceito educacional e a abordagem a ser utilizada, bem como o ambiente de ensino-aprendizagem. Adicionalmente, é realizada a análise do currículo com base nos princípios definidos pelas Diretrizes Curriculares Nacionais, que orientam a Base Nacional Comum Curricular (BNCC) do Brasil (MEC, 2017).

Etapa 3. Desenvolvimento do curso — Seguindo o método ADDIE (Branch, 2009), o curso é projetado para atender às diretrizes curriculares e aos objetivos de ensino-aprendizagem previamente definidos. Nesse processo, é elaborado o modelo instrucional, que define e integra as estratégias para o ensino, incluindo a seleção de conteúdo, seu sequenciamento, abordagens pedagógicas, suportes tecnológicos, e métodos de avaliação da aprendizagem e *feedback*, documentados em um plano de ensino.

Dos objetivos, é definido um processo de desenvolvimento do modelo de *ML* simplificado com base em *frameworks* bem estabelecidos. É adotado um processo iterativo e centrado no ser humano, baseado nas etapas apresentadas por Amershi et al. (2019) e adaptado para o contexto educacional por Gresse von Wangenheim e von Wangenheim (2021). Integrou-se a esse processo a metodologia de Pesquisa-ação (Kemmis et al., 2014), que permite uma revisão cíclica para tratar o processo de desenvolvimento do modelo de *ML* centrado no ser humano, com base na aplicação prática e no *feedback* contínuo dos estudantes e instrutores. Essa

abordagem promove o alinhamento do processo de desenvolvimento e ensino com as necessidades reais dos estudantes, além de incentivar uma prática reflexiva constante entre instrutores.

Conforme estratégias para o ensino, é desenvolvido o material instrucional criando o curso online, bem como a seleção/desenvolvimento de ferramentas a serem utilizadas. Nesta etapa, é adotado o processo mais amplo de *Design-Based Research* (DBR) (Philippakos et al., 2021), que envolve ciclos iterativos de design, aplicação, análise e redesign. Assim, o curso passa por melhorias contínuas com base nos resultados das aplicações e *feedback* dos estudantes. Esse processo iterativo permite refinar as estratégias para o ensino de *ML* adaptando-os às necessidades do contexto educacional específico.

Etapa 4. Aplicação e análise dos resultados do curso — Visando avaliar a qualidade do modelo instrucional suprido com as estratégias para o ensino desenvolvidas, o curso é aplicado e avaliado seguindo o método ADDIE (Branch, 2009). As aplicações ocorrem por meio de uma série de estudos de caso (Yin, 2017) e quase-experimento (Shadish et al., 2002) de forma extracurricular ou como parte das aulas regulares. O estudo é definido em termos de objetivo e design de pesquisa. Para isso, as questões de pesquisa e medidas são sistematicamente derivadas usando a abordagem *Goal/Question/Metric* (GQM) (Basili et al., 1994). O GQM é um método estruturado para medição, estabelecendo metas claras, derivando questões de análise relacionadas às metas e identificando métricas apropriadas para avaliar o progresso em direção a essas metas. As questões de análise e medidas são baseadas no modelo dTECT (*Evaluating TEaching CompuTing*) (Gresse von Wangenheim et al., 2017). Esse modelo avalia a qualidade das unidades instrucionais para o ensino de computação nas escolas com base nas percepções de aprendizado dos estudantes e em sua experiência de aprendizado. O modelo dTECT demonstrou confiabilidade aceitável (alfa de Cronbach $\alpha = 0.787$) e validade de construto (Gresse von Wangenheim et al., 2017).

Em paralelo, durante a aplicação do curso, os resultados de aprendizagem, incluindo artefatos de *ML* criados pelos estudantes, são coletados. Nesta pesquisa, "resultados de aprendizagem" referem-se especificamente à capacidade dos estudantes de aplicar conceitos básicos de *ML* para desenvolver um modelo de *ML*. Adotando uma abordagem de avaliação baseada em desempenho, esses resultados de aprendizagem são avaliados usando a rubrica de pontuação proposta por Gresse

von Wangenheim et al. (2022) e Rauber et al. (2023). Em estudos anteriores, essa rubrica foi validada por meio de avaliação de especialistas e testes empíricos com 240 estudantes de diversos contextos socioeconômicos, demonstrando boa confiabilidade (Ômega de McDonald $\omega = 0.834$; alfa de Cronbach $\alpha = 0.83$) e validade de consistência interna (Rauber et al., 2023). O processo de avaliação é automatizado usando a ferramenta online "CodeMaster - estágio de uso", assegurando um processo de avaliação consistente e eficiente (Rauber et al., 2023; Gresse von Wangenheim, 2022).

Posteriormente esses dados são organizados, tabulados e analisados utilizando métodos estatísticos conforme Spiegel e Stephens (2008) para responder às questões de pesquisa definidas.

O método de pesquisa adotado para as análises dos dados pode ser considerado quase-experimental, pois os grupos são comparados em relação aos resultados de aprendizagem e percepções, embora as variáveis independentes não tenham sido diretamente manipuladas (Shadish et al., 2002). Para a análise dos dados, foram utilizadas estatísticas descritivas e inferenciais. Inicialmente, estatísticas descritivas como média, mediana, desvio padrão, intervalo interquartil e frequências foram empregadas para compreender as características dos dados (Spiegel et al., 2009). Em seguida, testes de hipóteses foram realizados, verificando a existência de uma diferença estatisticamente significativa (Spiegel e Stephens, 2008).

Para a análise dos resultados de aprendizagem, os métodos propostos por Spiegel et al. (2009), Spiegel e Stephen (2008) e as diretrizes de Cohen (1988) foram utilizadas. O teste de Shapiro-Wilk foi utilizado para avaliar a normalidade da distribuição dos dados. O teste Mann-Whitney U foi aplicado, quando não aderente a normalidade, para identificar diferenças estatísticas entre os grupos. O "*d* de Cohen" foi calculado para entender a magnitude das diferenças, quando existente. O Teste Exato de Fisher, com correção de Bonferroni, foi empregado para dados categóricos visando analisar diferenças entre grupos. Para a análise das percepções dos estudantes, o teste Qui-quadrado de Pearson (χ^2) com correção de continuidade de Yates foi aplicado para analisar as comparações. Quando diferenças significativas foram identificadas pelos testes, o valor "*V* de Cramer" foi calculado para indicar o tamanho do efeito dessas diferenças (Field, 2018; Spiegel e Stephens, 2008; Cohen, 1988).

Análises de potência estatística e cálculos de tamanho de efeito, foram realizados para determinar a capacidade do estudo de detectar diferenças significativas, garantindo a robustez dos resultados (Cohen, 1988).

Ao final, os resultados são então interpretados e discutidos em relação às questões de pesquisa.

A série de estudos foi aprovada pelo Comitê de Ética da Universidade Federal de Santa Catarina (Aprovações n.º 4.893.560 e n.º 5.610.912).

Destarte, como resultado, serão criadas e aprimoradas estratégias para o ensino de *ML* a estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio. Essas estratégias incluirão objetivos de aprendizagem, conteúdo/sequenciamento de conteúdo, abordagens pedagógicas, suporte tecnológico e avaliação da aprendizagem e *feedback*. As estratégias para o ensino consideraram as características específicas do contexto educacional dos estudantes em situação de vulnerabilidade social e são adaptadas às suas necessidades e realidade.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta inicialmente a caracterização do público alvo desta pesquisa, os jovens em situação de vulnerabilidade social. Ela também apresenta as estratégias para o ensino de *Machine Learning* para as etapas de ensino abordadas, os anos finais do Ensino Fundamental e Médio.

2.1 CARACTERIZAÇÃO DE JOVENS EM SITUAÇÃO DE VULNERABILIDADE SOCIAL

O termo "vulnerabilidade social" é o termo em português utilizado nesta pesquisa para se referir ao termo "*low socioeconomic status (SES)*" em inglês. Esse termo é utilizado também em concordância com a caracterização usada pela assistência social Instituto Vilson Groh para os jovens atendidos pelo instituto (IVG, 2022). Todavia, como há vários termos associados/correlatos usados na literatura para se referir a esse contexto, é resumido no Quadro 2 as principais caracterizações dos estudantes em situação de vulnerabilidade social encontrados na literatura (Martins e Gresse von Wangenheim, 2024).

Quadro 2 – Termos associados/correlatos ao contexto de vulnerabilidade social

Termos associados/correlatos	Referências
Por status socioeconômico	<ul style="list-style-type: none"> ● Grupos em desvantagem ● População marginalizada ● Pobreza ● Desigualdade ● Famílias de baixa renda (OECD PISA, 2018; UNICEF, 2018; UNESCO, 2017; Parker e Guzdial, 2015; UNRISDSP, 2015; UNICEF, 2011; REARDON, 2011)
Por sub-representação e representação de minorias	<ul style="list-style-type: none"> ● Grupos étnicos ● Grupos de gênero (Kim e Ryu, 2017; Parker e Guzdial, 2015; UNRISDSP, 2015)
Por situação social	<ul style="list-style-type: none"> ● Refugiados ● Estudantes de escolas públicas (de alto risco social ou poucos recursos) (ITWORX Education, 2023; UNRISDSP, 2015)
Por área de residência	<ul style="list-style-type: none"> ● Residentes de subúrbios/periferias ● Residentes de áreas de risco criminal ● Residentes de áreas rurais ou tribais ● Moradores de comunidades marginalizadas (Byker et al., 2014; UNRISDSP, 2015)

Fonte: elaborado pelo autor

Em alguns casos, estudantes em vulnerabilidade social, são caracterizados em termos de desprivilegio, associados à "sub-representação" de minorias. Kim e Ryu (2017) explicam que, no caso dos EUA, a raça ou os grupos étnicos, como afro-americanos, hispânicos e nativos americanos, são usados para se referir aos vulneráveis; na China, os estudantes com status social instável são definidos como vulneráveis. Byker et al. (2014) usam o termo para indicar crianças, que geralmente

são vítimas das desigualdades e injustiças que caracterizam a vida nas favelas da Índia. O ITWORX Education (2023) se refere às crianças refugiadas como desprivilegiadas e vulneráveis devido às condições escolares limitadas, dificuldades de transporte e discriminação.

Nesta pesquisa, o termo "vulnerabilidade social" é utilizado principalmente para se referir a estudantes provenientes de famílias com baixa renda e origem/histórico de baixo status socioeconômico. Esses estudantes se enquadram na condição de pobreza segundo o World Bank (2022) e/ou são pessoas sem acesso à infraestrutura adequada, que vivem em áreas marginalizadas ou isoladas. Optou-se por essa definição em vez de adotar uma classificação baseada em gênero ou raça, a fim de focar nas questões socioeconômicas que impactam diretamente o acesso e a qualidade da educação desses estudantes.

A vulnerabilidade social atinge um espectro mais amplo de conquistas educacionais, qualidade de vida e oportunidades sociais (Avvisati, 2020; APA, 2023). Os estudantes em vulnerabilidade social geralmente enfrentam desvantagens significativas, inclusive acesso reduzido a recursos financeiros, educacionais e de infraestrutura em comparação com seus pares de níveis mais altos de status socioeconômico (UNESCO, 2017). Essa desigualdade se manifesta em vários resultados educacionais, na qual os estudantes de famílias com status socioeconômico mais baixo têm menor probabilidade de se envolver com uma educação de qualidade e maior probabilidade de frequentar escolas públicas com poucos recursos (OECD PISA, 2019).

O desenvolvimento acadêmico desses estudantes é frequentemente mais lento, com uma lacuna nas habilidades de alfabetização ao ingressar no Ensino Médio (APA, 2023; Finau, 2021). As escolas com alta concentração de estudantes em vulnerabilidade social geralmente apresentam desempenho acadêmico inferior (Perry et al., 2022). Além disso, os estudantes em vulnerabilidade social também apresentam maior risco de problemas de saúde e distúrbios psicológicos (Li et al., 2020).

A vulnerabilidade social ainda pode influenciar as percepções de aprendizado dos estudantes. As restrições financeiras podem afetar indiretamente o desempenho e as percepções acadêmicas por meio do estresse, da desmotivação e da falta de acesso a recursos educacionais, sendo que o status socioeconômico

mais alto está geralmente correlacionado com uma perspectiva mais positiva e de maior resiliência acadêmica (Destin et al., 2019).

No âmbito do ensino em computação, a vulnerabilidade social pode prejudicar a integração e o sucesso do estudante. Os estudantes mais vulneráveis relatam menor confiança em suas habilidades em Tecnologias da Informação e da Comunicação e enfrentam desafios na aquisição de conhecimento técnico (Gretter et al., 2019; Vekiri, 2010).

2.2 ESTRATÉGIAS PARA O ENSINO DE *MACHINE LEARNING* NA EDUCAÇÃO BÁSICA

As estratégias para o ensino são elementos-chave do Design Instrucional em um processo de planejar, desenvolver e avaliar experiências de ensino-aprendizagem (Smith e Ragan, 2005). São definidas como os métodos, técnicas, procedimentos e processos utilizados durante uma unidade instrucional (p. ex. cursos, oficinas, *hackathons*, etc.) (Wayne e Young, 2003).

As estratégias para o ensino podem ser consideradas um termo "guarda-chuva" que abrange diversos componentes inter-relacionados, incluindo objetivos de aprendizagem, conteúdo e seu sequenciamento (o que ensinar), a abordagem pedagógica (como ensinar), o suporte tecnológico (quais ferramentas usar para apoiar o ensino-aprendizagem) e a avaliação da aprendizagem e *feedback* (como avaliar) (União Europeia, 2017; Mishra e Koehler, 2006; Wayne e Young, 2003; Saskatchewan Education, 1991) (Figura 1).

Figura 1 – Componentes das estratégias para o ensino



Fonte: elaborado pelo autor

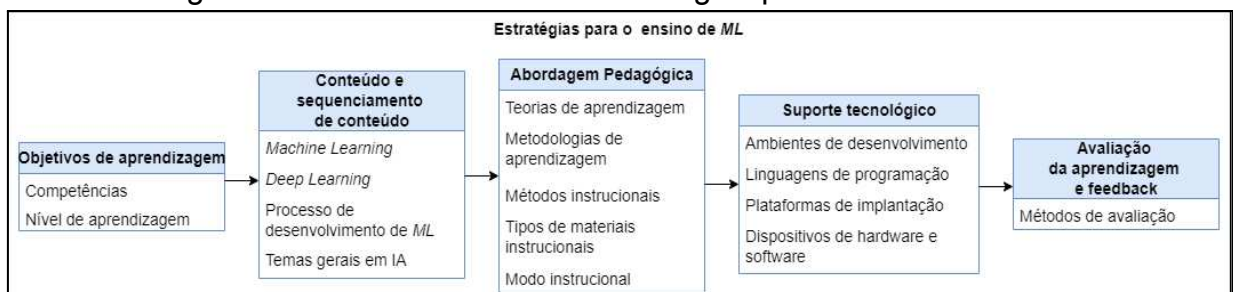
A integração organizada dos componentes das estratégias para o ensino, como conteúdo, abordagens pedagógicas, suporte tecnológico e avaliação, formam a base dos modelos instrucionais (Smaldino et al., 2008). Esses modelos são apoiados por *frameworks* como "*Instructional Approaches*" (Saskatchewan Education, 1991), TPACK (*Technological Pedagogical Content Knowledge*) (Mishra e

Koehler, 2006) e o DigCompEdu (*European Framework for the Digital Competence of Educators*) (União Europeia, 2017). Nesses *frameworks* os componentes (conteúdo, abordagens pedagógicas, suporte tecnológico e avaliação) estão inter-relacionados e devem ser pensados de forma articulada ao planejar estratégias para o ensino que promovam o aprendizado significativo dos estudantes (União Europeia, 2017; Smaldino et al., 2008; Mishra e Koehler, 2006; Saskatchewan Education, 1991).

O *framework "Instructional Approaches"* ressalta a importância de empregar estratégias para o ensino que atendam as necessidades individuais dos estudantes (Saskatchewan Education, 1991). Já o TPACK destaca a integração dinâmica entre conhecimento tecnológico, pedagógico e do conteúdo para um ensino que impacte positivamente o aprendizado dos estudantes (Mishra e Koehler, 2006). O DigCompEdu destaca a importância de competências digitais específicas que os instrutores devem desenvolver para integrar efetivamente as tecnologias digitais no ensino, como o uso de recursos digitais, o gerenciamento de tecnologias, a avaliação digital, o empoderamento e a promoção da competência digital dos estudantes (União Europeia, 2017).

A partir das premissas dos *frameworks* e de achados dos estudos sobre estratégias para ensino de computação, IA e *ML* (Martins e Gresse von Wangenheim, 2023; Casal-Otero et al., 2023; Yue et al., 2022; Sanusi e Oyelere, 2020; Marques et al., 2020; McMillan, 2015) são detalhadas as principais características das estratégias para o ensino de *Machine Learning* (Figura 2).

Figura 2 – Características das estratégias para o ensino de *ML*



Fonte: elaborado pelo autor

Objetivos de aprendizagem

Os objetivos de aprendizagem são declarações que definem o que se espera que os estudantes aprendam, descrevendo o que devem saber ou conseguirem fazer ao final de uma unidade instrucional (McMillan, 2015).

No contexto do ensino na educação básica no Brasil, os objetivos estão alinhados à Base Nacional Comum Curricular (BNCC) (MEC, 2017) e recentemente ao Parecer CNE/CEB n.º 2/2022 que estabelece as "Normas sobre Computação na Educação Básica — Complemento à BNCC" (MEC, 2022). Esses dispositivos legais estabelecem para o Ensino Fundamental eixos voltados ao pensamento computacional, enquanto para o Ensino Médio a IA e a ciência de dados são mencionadas. Do recente Parecer CNE/CEB n.º 2/2022 (MEC, 2022) se destacam:

(EM13CO10) "Conhecer os fundamentos da Inteligência Artificial, comparando-a com a inteligência humana, analisando suas potencialidades, riscos e limites" (MEC, 2022).

(EM13CO12) "Produzir, analisar, gerir e compartilhar informações a partir de dados, utilizando princípios de ciência de dados" (MEC, 2022).

Nesse contexto, no Brasil, a Sociedade Brasileira de Computação (SBC) criou diretrizes que incluem objetivos de aprendizagem para IA no Ensino Médio, propondo que os estudantes sejam capazes de "compreender os fundamentos da Inteligência Artificial e da robótica" (SBC, 2018).

Algumas iniciativas internacionais se concentram no estudo da educação em computação, incluindo vários conceitos e práticas fundamentais para o ensino na educação básica, como o "*K–12 Computer Science Framework*" (CSTA K-12 CS) (CSTA, 2017) (Quadro 3).

Quadro 3 – Conceitos e práticas para o ensino de computação na educação básica

Conceitos	Práticas
1- Sistemas de computação	1- Promovendo uma cultura de computação inclusiva
2- Redes e a Internet	2- Colaborando em torno da computação
3- Dados e análise	3- Reconhecendo e definindo problemas computacionais
4- Algoritmos e programação	4- Desenvolvendo e usando abstrações
5- Impactos da computação	5- Criando artefatos computacionais
	6- Testando e refinando artefatos computacionais
	7- Comunicando sobre computação

Fonte: CSTA (2017)

Dessas iniciativas, também se destaca o grupo de trabalho "Inteligência Artificial para K-12" (AI4K12) (Touretzky et al., 2019), que tem se empenhado em promover a integração da IA no currículo escolar do Ensino Fundamental e Médio. A AI4K12 desenvolve diretrizes baseadas nas "5 Grandes Ideias" em IA, as quais são competências-chave para a formação de estudantes nessas etapas educacionais em IA. (Touretzky et al., 2019) (Quadro 4). Isso compreende a "alfabetização em IA", para o aprendizado dos estudantes, caracterizada por Long e Magerko (2020).

Quadro 4 – Competências do estudante em IA

5 Grandes Ideias (AI4K12)	Competências do estudante
1-Percepção	Compreender que a percepção de linguagem falada ou imagens visuais por máquinas requer um amplo conhecimento de domínio.
2-Representação	Compreender o conceito de representação e saber que os computadores constroem representações usando dados, e que essas representações podem ser manipuladas aplicando algoritmos de raciocínio que derivam novas informações do que já se sabe.
3-Aprendizagem	Compreender que o <i>ML</i> é uma espécie de inferência estatística que encontra padrões em dados.
4-Interação Natural	Compreender que, embora os computadores possam entender a linguagem natural em certa medida, atualmente eles carecem das capacidades gerais de raciocínio e conversação até mesmo de uma criança.
5-Impacto Social	Ser capaz de identificar as formas como a IA está contribuindo para a vida das pessoas, bem como reconhecer que a construção ética de sistemas de IA requer atenção às questões de transparência e equidade.

Fonte: Touretzky et al. (2019)

Nível de aprendizagem — O aprendizado de IA/ML, sendo complexo, pode apresentar dificuldades para estudantes iniciantes, especialmente aqueles sem experiência prévia em computação (Sulmont et al., 2019). Para abordar isso, é importante estruturar a sequência de objetivos de aprendizado, começando com competências básicas e avançando para níveis superiores, evitando estagnar em níveis inferiores. A taxonomia cognitiva de Bloom auxilia nesse processo, organizando tarefas de pensamento em categorias como: lembrar, compreender, aplicar, criar, avaliar e analisar (Anderson e Krathwohl, 2001; Bloom et al., 1956).

No âmbito de ensino de computação também se adota o ciclo "Usar-Modificar-Criar" (UMC) (Lytle et al., 2019; Lee et al., 2011), aplicável no ensino de *ML* (Lao, 2020). O ciclo orienta os estudantes a se familiarizar com tópicos de *ML* "usando" e analisando artefatos, "modificando" artefatos existentes e, por fim, "criando" novos artefatos. Essa progressão promove uma transição fluida da reutilização à construção criativa de aprendizagem, superando a mera codificação ou uso de aplicações de *ML*, p.ex. por meio de tutoriais, permitindo compreensão e criatividade mais profundas (Bellettini et al., 2014).

Conteúdo e sequenciamento de conteúdo

Referente a "Grande idéia 3 - Aprendizagem", Touretzky et al. (2019) observam que os estudantes devem compreender o que é *ML*, e para isso algumas competências são desejadas para esse aprendizado em termos de conteúdo para o Ensino Fundamental e Ensino Médio. Essas competências incluem conceitos básicos de *ML*, tipos de algoritmos de aprendizado, preocupações éticas e implicações sociais. Desse modo, os principais enfoques em termos de conteúdo para o ensino de *ML* no Ensino Fundamental e Médio são:

Machine Learning — Subcampo da IA, o *ML* busca desenvolver programas de computador que melhorem automaticamente com a experiência (Mitchell, 1997). O *ML* utiliza teorias estatísticas para construir modelos matemáticos e realizar inferências a partir de amostras de dados (Alpaydin, 2014). Os principais tipos de aprendizado em *ML* são supervisionados, não supervisionados e por reforço (LeCun, 2018). O aprendizado supervisionado é o mais comum e realiza tarefas como classificação (p.ex. para distinguir classes) e regressão (p.ex. para realizar previsões) (Kamiri e Mariga, 2021; Al-Sahaf et al., 2019). Algoritmos populares de aprendizado supervisionado incluem Árvores de Decisão, *Support Vector Machines* (*SVM*), Redes Neurais Artificiais, entre outros. Esses algoritmos são amplamente utilizados para aplicações como visão computacional (p.ex. classificação de imagem) e reconhecimento de voz (IBM, 2024a). Já o aprendizado não supervisionado é frequentemente utilizado em *clustering* para encontrar agrupamentos em dados, sem intervenção humana (IBM, 2024a; Google Developers, 2022). O algoritmo *K-means* se destaca nesse tipo de aprendizado, sendo empregado para identificar padrões nos dados para que eles possam ser agrupados (Google Developers, 2022).

Deep Learning (*DL*) — Uma área emergente de pesquisa em *ML*, o *DL* tem feito grandes avanços na solução de problemas complexos que resistiram às melhores tentativas da comunidade de IA (LeCun, 2015). O *DL* é baseado em um conjunto de algoritmos que tentam modelar abstrações de alto nível em dados, usando redes neurais profundas com múltiplas camadas de processamento, compostas de transformações lineares e não lineares (Sherkhane & Vora, 2017). Algoritmos populares de *DL* incluem Redes Neurais Convolucionais (*CNNs*), utilizadas principalmente para aplicações de visão computacional como classificação

de imagem e detecção de objetos, e Redes Neurais Recorrentes (*RNNs*), empregadas em aplicações como reconhecimento de fala e processamento de linguagem natural (*NLP*) (IBM, 2024b). Outro algoritmo popular são as Redes Adversárias Generativas (*GANs*), usadas para geração de dados (Goodfellow et al., 2014). Recentemente os avanços em *DL* foram expandidos como os modelos de linguagem de grande escala (*Large Language Models, LLMs*) (OpenAI, 2022).

Uma visão geral dos principais algoritmos de *ML* e *DL* utilizados para o ensino na educação básica, bem como suas funções, tipos de algoritmos de aprendizagem, tarefas típicas e casos de uso é apresentado no Quadro 5.

Quadro 5 – Visão geral dos principais algoritmos de *ML/DL*

Algoritmos	Descrição	Tipos de algoritmos de aprendizagem	Tarefas típicas de <i>ML/DL</i>	Exemplos de casos de uso
Árvore de decisão	É um algoritmo que estrutura os dados em forma de árvore, iniciando com o atributo mais significativo na raiz. Cada nó subsequente representa uma decisão baseada nos atributos, e cada folha determina o resultado final (Hernández et al., 2021).	• Supervisionado	• Classificação • Regressão	• Sistemas de recomendação
<i>K-means</i>	São algoritmos de <i>clusters</i> baseados em sua proximidade a um centróide (Google Developers, 2022).	• Não supervisionado	• <i>Clustering</i>	• Agrupamento de dados
<i>K-Nearest Neighbor (KNN)</i> :	Algoritmo de classificação de novos objetos que identifica os dados de treinamento mais próximos a um novo objeto utilizando a distância euclidiana. O <i>KNN</i> garante que objetos semelhantes estejam próximos uns dos outros (Okfalisa et al., 2017).	• Supervisionado	• Classificação • Regressão	• Visão computacional (Classificação de imagem)
<i>Naive Bayes</i>	Classificador probabilístico baseado em sua relação com o Teorema de Bayes. Fornece um mecanismo para utilizar as informações nos dados da amostra para estimar a probabilidade <i>a posteriori</i> (Webb, 2011).	• Supervisionado	• Classificação • Regressão	• Classificação de texto em <i>NLP</i> • Sistemas de recomendação
<i>Q-Learning</i>	Algoritmo que permite que um agente aprenda a função Q ótima de um processo de decisão Markoviano (que modela um ambiente). Visa encontrar uma solução ótima para convergir para um valor ótimo previsto (Google Developers, 2022; Rincy e Gupta, 2020).	• Reforço	• Otimização	• Otimização de estratégias
<i>Support Vector Machine (SVM)</i>	Algoritmo que visa encontrar um hiperplano que separe classes de dados (Google Developers, 2022).	• Supervisionado	• Classificação • Regressão	• Visão computacional (Classificação de imagem) • Classificação de texto em <i>NLP</i>
<i>Random Forest</i>	É um método <i>ensemble</i> (de combinação de outros métodos), que se ajusta a vários classificadores de árvores de decisão em várias subamostras do conjunto de dados (Google Developers, 2022).	• Supervisionado	• Classificação • Regressão	• Visão computacional (Classificação de imagem)
Redes Neurais Artificiais (RNA)	Modelos computacionais paralelos massivos que imitam a função do cérebro humano. Uma RNA consiste em um grande número de processadores (neurônios) interligados por conexões ponderadas (Rincy e Gupta, 2020).	• Supervisionado • Não supervisionado	• Classificação • Regressão	• Visão computacional (Classificação de imagem) • Reconhecimento de fala
Redes Neurais Convolucionais (<i>CNN</i>)	Rede Neural que utiliza múltiplas camadas de convolução, camadas de <i>pooling</i> e camadas totalmente conectadas para extração de características e redução de dimensionalidade (Google Developers, 2022).	• Supervisionado	• Classificação • Otimização	• Visão computacional (Classificação de imagem, Detecção de objeto)
Redes Neurais Recorrentes (<i>RNN</i>)	Rede Neural que utiliza conexões recorrentes para processamento de dados sequenciais (Google Developers, 2022).	• Supervisionado • Reforço	• Classificação • Regressão • <i>Clustering</i>	• Reconhecimento de fala • Processamento de Linguagem Natural (<i>NLP</i>)
Redes Adversárias Generativas (<i>GANs</i>)	Rede Neural que consiste em um gerador (que cria dados) e um discriminador (que determina a validade dos dados) (Google Developers, 2022).	• Não supervisionado	• Geração de dados	• Geração de imagens realistas
Regressão Linear	Modela a relação entre uma variável dependente e uma ou mais variáveis independentes (Liu, 2020).	• Supervisionado	• Regressão	• Previsão de preço
Regressão Logística	Mede a relação entre a categoria de uma variável dependente e uma ou mais variáveis independentes por meio da estimativa das probabilidades utilizando uma função logística (Google Developers, 2022).	• Supervisionado	• Classificação • Regressão	• Classificação de texto em <i>NLP</i>

Fonte: elaborado pelo autor, baseado em IBM (2024a; 2024b), Google Developers (2022), Martins e Gresse von Wangenheim (2022), Marques et al. (2020)

Os modelos de *ML* e *DL* são ajustados por hiperparâmetros, variáveis definidas que controlam aspectos do aprendizado. Exemplos incluem, p.ex. a taxa de aprendizado, o número de épocas e tamanho do lote (*batch size*) em Redes Neurais Artificiais. Esses hiperparâmetros impactam diretamente o desempenho do modelo resultante (IBM, 2024a; Google Developers, 2022).

Os modelos de *ML* e *DL* são avaliados por meio de diversas métricas que medem seu desempenho em diferentes aspectos, como acurácia, precisão, entre outros. Essas métricas permitem comparar diferentes modelos e escolher o mais adequado para uma determinada tarefa (Google Developers, 2022; Microsoft, 2021). Nessa comparação, é importante considerar o *overfitting*, quando o modelo se ajusta excessivamente aos dados de treinamento, prejudicando a generalização, e o *underfitting*, quando o modelo é muito simples para capturar a complexidade dos dados (Google, 2023a). Uma visão geral das principais métricas usadas em *ML* e *DL* é apresentada no Quadro 6 (Google Developers, 2022; Microsoft, 2021).

Quadro 6 – Visão geral das principais métricas usadas em *ML* e *DL*

Métrica	Descrição
Acurácia	Proporção de predições corretas em relação ao total de predições.
Precisão	Proporção de verdadeiros positivos em relação a todos os positivos preditos.
Sensibilidade (<i>Recall</i>)	Proporção de verdadeiros positivos em relação a todos os positivos reais.
<i>F1-Score</i>	Média harmônica entre Precisão e Sensibilidade (<i>Recall</i>).
Erro Médio Absoluto (<i>MAE</i>)	Média das diferenças absolutas entre os valores preditos e os valores reais.
Erro Médio Quadrático (<i>MSE</i>)	Média dos quadrados das diferenças entre os valores preditos e os valores reais.
Raiz do Erro Médio Quadrático (<i>RMSE</i>)	Raiz quadrada do <i>MSE</i> .
Matriz de confusão	Uma tabela NxN que resume o número de previsões corretas e incorretas realizadas por um modelo de classificação, detalhando verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos.

Fonte: Google Developers(2022) e Microsoft (2021)

Temas gerais de IA — Adicionalmente, como conteúdo tipicamente ensinado na educação básica, aborda-se temas gerais de IA, como agentes de IA e tópicos de estatística (Van Brummelen, et al., 2021; Chua et al., 2019). Além disso, visando motivar os estudantes, podem ser abordadas questões de oportunidades de carreira nesta área do conhecimento. E principalmente, com a finalidade de tornar os estudantes usuários e criadores responsáveis, também se aborda impactos sociais e questões éticas relacionadas a IA (Martins e Gresse von Wangenheim, 2023; Yue et al., 2022; Marques et al., 2020; Long e Magerko, 2020; Touretzky et al., 2019).

Abordagem pedagógica

Um conjunto de práticas de ensino e aprendizagem é definido como "abordagem pedagógica" (Marc et al., 2018). Essas abordagens permitem a busca de múltiplos propósitos simultaneamente e fornecem formas confiáveis de organizar o aprendizado (Westbrook et al., 2013).

Devido às reformas curriculares, houve uma mudança das abordagens pedagógicas centradas no professor para as centradas no estudante (Westbrook et al., 2013). Enquanto a abordagem centrada no professor foca na apresentação do conteúdo pelo instrutor (Yuen e Hau, 2006), a abordagem centrada no estudante é projetada para permitir que os estudantes demonstrem os conhecimentos adquiridos, por exemplo, por meio de discussões e interação entre pares (Zeki e Guneyli, 2014).

Para o ensino-aprendizagem de *ML*, como um campo de estudo relativamente novo no contexto da educação básica, é necessária abordagens pedagógicas apropriadas (Yue et al., 2022; Sanusi e Oyelere, 2020). Dessa forma, alguns conceitos são considerados em termos da escolha de abordagens pedagógicas.

Teorias de aprendizagem — As abordagens pedagógicas são baseadas em teorias de aprendizagem (Westbrook et al., 2013). Teorias de aprendizagem são apresentadas em termos de dimensões pedagógicas, com extremos epistemológicos (objetivismo e construtivismo) e filosofia pedagógica (instrucionista e construtivista) (Cronjé, 2016). O "objetivismo" busca o conhecimento confiável sobre o mundo, enquanto o "construtivismo", fundamentado na teoria de Piaget, afirma que a realidade está na mente do conhecedor (Jonassen, 1991; Piaget, 1971). Papert et al. (1988) propõe o "construcionismo", e esta abordagem considera que a melhor maneira de aplicar o construtivismo é construir algo tangível, algo que esteja "fora da cabeça" do estudante, mas que também seja pessoalmente significativo. Alinhado ao construtivismo, se inclui a abordagem freiriana que propõe uma educação dialógica na construção conjunta do conhecimento a partir da realidade concreta e ação transformadora (Freire, 1968).

Metodologias de aprendizagem — Para o ensino de computação/IA/ML na educação básica, são utilizadas diversas metodologias de aprendizagem de acordo com Su et al. (2023), Yue et al. (2022), Tikva e Tambouris (2021), Sanusi e Oyelere (2020) e Hsu et al. (2018). Tem sido bastante difundido o uso das metodologias de aprendizagem ativa, baseada em problemas e baseada em projetos (Martins e

Gresse von Wangenheim et al., 2023; Su et al., 2023; Yue et al., 2022; Sanusi e Oyelere, 2020). Além disso, as metodologias de aprendizagem baseada em jogos tem apresentado bons resultados (Leitner et al., 2023; Zhan et al., 2022). Uma visão geral das principais metodologias de aprendizagem utilizadas para o ensino de computação/IA/ML é apresentada no Quadro 7.

Quadro 7 – Metodologias de aprendizagem

Metodologias de aprendizagem	Descrição
Aprendizagem ativa	Uma metodologia que envolve os estudantes ativamente no aprendizado, em vez de apenas ouvir passivamente as aulas (Sanusi e Oyelere, 2020; Prince, 2004).
Aprendizagem baseada em jogos	Uma metodologia em que os estudantes aprendem por meio de jogos, projetados para promover o engajamento, a motivação e a participação ativa no processo de aprendizagem (Tikva and Tambouris, 2021; Hsu et al., 2018).
Aprendizagem baseada em problemas	Uma metodologia centrada no estudante, na qual os estudantes aprendem sobre um assunto para resolver um problema proposto (Hsu et al., 2018).
Aprendizagem baseada em projetos	Uma metodologia que organiza a aprendizagem em torno de projetos que envolvem os estudantes para se engajar de forma relativamente autônoma em atividades de planejamento, tomada de decisões e investigação (Jones et al., 1997; Hsu et al., 2018).
Aprendizagem colaborativa e por pares	Uma metodologia na qual os estudantes em grupos se tornam responsáveis pelo aprendizado uns dos outros e pelo seu próprio aprendizado ao realizarem tarefas em conjunto (Teague e Roe, 2008; Hsu et al., 2018). Esta metodologia ainda pode ser expandida para tutoria entre pares (<i>peer-tutoring</i>) (Sein-Echaluze et al., 2017).
Aprendizagem interativa	Uma metodologia na qual os estudantes se envolvem em um processo de aprendizado ativo e colaborativo por meio do uso de tecnologia, ferramentas e atividades interativas (Sanusi e Oyelere, 2020).

Fonte: elaborado pelo autor

No campo da educação em computação, uma metodologia de aprendizagem mais ampla se destaca, a "Ação Computacional" (Tissenbaum et al., 2019). Essa abordagem metodológica propõe que enquanto os estudantes aprendem sobre computação, também devem ter oportunidades de criar com a computação artefatos que tenham impacto direto em suas vidas e em suas comunidades. Um componente desta abordagem é a "Identidade Computacional", que expressa a necessidade dos estudantes de se sentirem responsáveis por articular e projetar suas soluções e também de sentirem que seu trabalho é autêntico (Tissenbaum et al., 2019; Lao, 2020).

Das abordagens pedagógicas, outras características fundamentais que contemplam a prática de ensino-aprendizagem são:

Métodos instrucionais — Métodos instrucionais são as abordagens e técnicas utilizadas pelos educadores para envolver os estudantes no processo de aprendizagem e facilitar a aquisição de conhecimentos e habilidades (Lombardi, 2019). Para alcançar os objetivos de aprendizagem, diversos métodos instrucionais são utilizados no ensino de IA/ML, incluindo: atividades práticas, atividades de reflexão, aulas expositivas, atividades desconectadas (*unplugged*), discussão, trabalhos em grupo, entre outros (Lee e Kwon, 2024; Tikva e Tambouris, 2021). Uma

visão geral dos principais métodos instrucionais utilizados para o ensino de IA/ML é apresentada no Quadro 8.

Quadro 8 – Métodos instrucionais

Métodos instrucionais	Descrição
Atividade prática	Os estudantes participam ou realizam atividades práticas, relacionadas ao material da disciplina em vez de somente assistir/ouvir a aula (Ekwueme et al., 2015).
Atividade de reflexão	Um exercício de pensamento crítico, visando auxiliar os estudantes a analisar e avaliar argumentos por meio de um processo sistemático de identificação de alegações, razões, evidências e contra-argumentos, e avaliar seus pontos fortes e fracos (Chaffee, 2019).
Atividade cinestésica	Atividades que envolvem movimento físico, toque e manipulação de objetos para facilitar o aprendizado (Begel et al., 2004).
Aula expositiva	Um método centrado no professor, na forma de uma aula/palestra educacional (Tikva e Tambouris, 2021).
Atividade desconectada	Ensino de conceitos por meio de atividades construtivistas, geralmente cinestésicas, sem computadores ou dispositivos digitais (Conde et al., 2017).
Discussão	Processo colaborativo e inclusivo no qual os estudantes compartilham suas opiniões, pensamentos e experiências para explorar e analisar temas e problemas (Brookfield e Preskill, 1999).
Trabalho em grupo	Uma atividade colaborativa no qual os estudantes trabalham conjuntamente em problemas e avaliações (Wilson et al., 2018).

Fonte: elaborado pelo autor

Tipos de material instrucional — Materiais instrucionais consistem em um conjunto de recursos, impressos e digitais, utilizados para oferecer oportunidades de aprendizado aos estudantes (OSPI K-12, 2022). Alguns tipos de materiais utilizados podem ser usados para apoiar o ensino de ML na educação básica, sendo selecionados e/ou criados conforme abordagens pedagógicas pré-definidas (Martins e Gresse von Wangenheim, 2023; Marques et al., 2020; Saskatchewan Education, 1991). Isso inclui escolher ou desenvolver esses materiais que podem ser apresentações, vídeos, cartões, tutoriais, entre outros (Martins e Gresse von Wangenheim, 2023; Yue et al., 2022; Tedre et al., 2021; Marques et al., 2020; Touretzky et al., 2019; MIT, 2019). Uma visão geral dos principais tipos de materiais instrucionais são apresentados no Quadro 9.

Quadro 9 – Tipos de materiais instrucionais

Materiais instrucionais	Descrição
Apresentação	Conjunto sequencial de slides ou outros recursos visuais para comunicar conceitos ou informações (Mariescu-Istodor e Jormanainen, 2019; MIT, 2019; Mobasher et al., 2019).
Aplicativos de demonstração	Programas interativos que ilustram conceitos ou técnicas de forma prática (Sulmont et al., 2019; Zhu, 2019).
Cartão e jogos educacionais	Recurso físico para atividades desconectadas ou virtuais para atividades interativas (Ali et al., 2023; MIT, 2019).
Códigos	Conjuntos de instruções ou comandos escritos em uma linguagem de programação para modificar ou criar programas de computador ou modelos computacionais (Chua et al., 2019; Mobasher et al., 2019).
Conjunto de dados	Coleção de dados estruturados usados p.ex. para treinar ou testar modelos de ML (Chua et al., 2019; Mobasher et al., 2019).
Diário	Registros escritos ou falados das reflexões e aprendizados ao longo do curso (Bhatia, 2020).
Exemplo	Caso ilustrativo que demonstra a aplicação de um conceito (Chua et al., 2019; Kandhofer et al., 2019).
Exercício	Atividade prática proposta aos estudantes para aplicar conceitos aprendidos, podendo envolver resolução de problemas, programação, manipulação de dados, etc. (Essinger e Rosen, 2011).
Kit robótico	Conjunto de componentes para construção de robôs, integrando sensores e <i>software</i> (Kandhofer et al., 2019).
Papel e lápis	Materiais básicos para atividades desconectadas, de forma manuscrita, desenhada ou anotada (Burgsteiner et al., 2016).
Planilha	Ferramenta de <i>software</i> que permite organizar, analisar e visualizar dados em tabelas, gráficos e p.ex. para atividades envolvendo análise de dados (MIT, 2019).
Template	Modelos pré-definidos para orientar a criação de artefatos pelos estudantes (Van Brummelen et al., 2020).
Tutorial e guias	Guia passo-a-passo, em texto ou imagem, com instruções ou orientações para realizar uma tarefa ou explicar algum recurso (Code.org, 2024; Van Brummelen et al., 2020; MIT, 2019).
Video	Mídia audiovisual para instruções ou demonstrações (Rodríguez-Garcia et al., 2020; MIT, 2019).

Fonte: elaborado pelo autor, baseado em Martins e Gresse von Wangenheim (2023), Yue et al. (2022), Tedre et al. (2021), Touretzky et al. (2019) e Marques et al. (2020).

Modo instrucional — Considerado todos aspectos da abordagem pedagógica, a forma de facilitar e flexibilizar o ensino-aprendizagem de *ML* é caracterizada ainda em termos de modo instrucional. Os principais formatos para a entrega da instrução, podem ser descritos como presencial, remoto síncrono, remoto assíncrono e híbrido (Rizvi et al., 2023) (Quadro 10).

Quadro 10 – Tipos de modos instrucionais

Modos instrucionais	Descrição
Presencial	Envolve interação direta com o instrutor em um local físico
Remoto síncrono	Estudantes e instrutores não estão no mesmo local físico, mas interagem em tempo real
Remoto assíncrono	A instrução ocorre online sem a necessidade de interação entre estudantes e instrutores
Híbrido	Combina elementos dos modos presencial e remoto

Fonte: Rizvi et al. (2023)

Suporte tecnológico

Para dar suporte ao ensino de *ML* no Ensino Fundamental e Médio, diversas tecnologias são utilizadas com o objetivo de proporcionar a interação com os sistemas de *ML*, desmistificar conceitos de *ML* e facilitar o aprendizado dos estudantes (Martins e Gresse von Wangenheim, 2023; Yue et al., 2022; Gresse von Wangenheim et al., 2021; Sanusi et al., 2021; Tedre et al., 2021). Essas tecnologias podem ser categorizadas de forma geral em ambientes de desenvolvimento, linguagens de programação, plataformas de implantação, e dispositivos de *hardware* e *software*, conforme resumido no Quadro 11 (Lee e Kwon, 2024; Yim e Su, 2023; Sanusi et al., 2022; 2021; Yue et al., 2022; Tedre et al., 2021).

Quadro 11 – Tipos de suportes tecnológicos

Categorias	Exemplos de ferramentas	Referência
Ambientes de desenvolvimento	<ul style="list-style-type: none"> • Ambientes visuais 	<ul style="list-style-type: none"> • Google Teachable Machine (Google, 2023a; Carney et al., 2020) • LearningML (Rodríguez-García et al., 2020) • Cognimates (Druga, 2018)
	<ul style="list-style-type: none"> • Ambientes baseados em texto 	<ul style="list-style-type: none"> • Jupyter Notebooks (Jupyter, 2024; Nguyen et al., 2019) • Google Colab (Google, 2023b)
	<ul style="list-style-type: none"> • Ambientes baseados em blocos 	<ul style="list-style-type: none"> • MIT App Inventor (MIT, 2024a) • Scratch (MIT, 2024b; Alonso, 2020)
Linguagens de Programação	<ul style="list-style-type: none"> • Baseados em texto • Baseada em bloco 	<ul style="list-style-type: none"> • Python (Norouzi et al., 2020) • Scratch (MIT, 2024b; Alonso, 2020)
Plataforma de implantação	<ul style="list-style-type: none"> • MIT App Inventor • Scratch 	<ul style="list-style-type: none"> • MIT, 2024a) • MIT, 2024b; Alonso, 2020)
<i>Hardware</i>	<ul style="list-style-type: none"> • Plataformas de <i>hardware</i> programável 	<ul style="list-style-type: none"> • Arduino (Jagannathan e Komives, 2019) • Raspberry Pi (Gong et al., 2018) • Micro:Bits (Park e Kwon, 2023)
	<ul style="list-style-type: none"> • Kit robóticos educacionais 	<ul style="list-style-type: none"> • LEGO Mindstorms® (LEGO, 2024; Karalekas et al., 2023) • CogBots (COGBOTS, 2024; Karalekas et al., 2023) • Cozmo (COZMO, 2024; Karalekas et al., 2023)
<i>Softwares</i>	<ul style="list-style-type: none"> • Aplicações interativas 	<ul style="list-style-type: none"> • QuickDraw! (Google AI Experiments, 2022) • MIT <i>Moral Machine</i> (MIT, 2017) • ChatGPT (Hays et al., 2024; OpenAI, 2023)

Fonte: elaborado pelo autor, baseado em Lee e Kwon (2024), Martins e Gresse von Wangenheim (2023), Yim e Su (2023), Sanusi et al. (2022;2021), Yue et al. (2022), Gresse von Wangenheim et al., (2021) e Tedre et al. (2021)

Visando a interação com modelos de *ML*, uma das escolhas está em se utilizar ambientes visuais ou baseados em texto (Gresse von Wangenheim et al., 2021). Como ambientes visuais, é bem difundido o uso da ferramenta baseada em web Google Teachable Machine (GTM) (Google, 2023a). O GTM permite interagir com a forma como o *ML* funciona, sendo fácil de usar, mesmo para alguém sem experiência em programação (Carney et al., 2020). Outros exemplos de ambiente visual incluem o LearningML (Rodríguez-García et al., 2020) e Cognimates (Druga, 2018), para interagir com modelos de *ML* que classificam texto e imagem.

Ambientes de desenvolvimento usando linguagem baseada em texto, como Jupyter Notebooks (Jupyter, 2024) e Google Colab (Google, 2023b), são tipicamente mais utilizados no ensino superior e também no desenvolvimento profissional de modelos de *ML* (Gresse von Wangenheim et al., 2021). O Jupyter Notebooks é uma aplicação de código aberto que suporta a criação e compartilhamento de códigos, visualização de dados e resultados de *ML*, entre outros (Jupyter, 2024; Nguyen et al., 2019). Já o Google Colab é uma plataforma de desenvolvimento do Google baseada em nuvem, que permite que os estudantes trabalhem de forma colaborativa com um código (Google, 2023b). Esses ambientes permitem linguagem de programação baseada em texto, como Python, que tem muitas vantagens para interações com modelos de *ML* por ter uma variedade de bibliotecas que reduzem o código para programadores (Dhruv et al., 2021; Norouzi et al., 2020).

Como plataformas de implantação, visando criar um sistema utilizável, p.ex. implantar modelos de *ML* em *apps*, na educação básica tipicamente se utilizam ambientes baseados em blocos como Scratch e MIT App Inventor (MIT, 2024a; 2024b; Martins e Gresse von Wangenheim, 2023; Gresse von Wangenheim et al., 2021; Alonso, 2020; Marques et al., 2020). Esses ambientes simplificam conceitos abstratos de codificação para os estudantes mais jovens (Martins e Gresse von Wangenheim, 2023; Gresse von Wangenheim et al., 2021).

Outros tipos de suporte tecnológicos para o ensino dos conceitos de IA/*ML* no Ensino Fundamental e Médio, têm sido utilizados, como os dispositivos de *hardware* (Lee e Kwon, 2024; Yim e Su, 2023). Exemplos incluem os kits robóticos educacionais, como o LEGO Mindstorms®, o CogBots e o Cozmo, permitindo que os estudantes interajam e programem robôs educacionais com recursos de IA/*ML* (LEGO, 2024; CogBots, 2024; Cozmo, 2024; Karalekas et al., 2023). Além disso, plataformas de *hardware* programáveis, como o Micro:bit, Arduino e Raspberry Pi,

também são utilizadas para fins educacionais em projetos de IA como pequenos carros autônomos e robôs (Park e Kwon, 2023; Jagannathan e Komives, 2019; Gong et al., 2018).

Em termos de *software* e aplicações interativas com as potencialidades da IA e *ML*, destacam-se o QuickDraw! (Google AI Experiments, 2022) e o MIT *Moral Machine* (MIT, 2017), utilizados para visualizar e apoiar conceitos abstratos de IA por meio de jogos e experiências online (Martins e Gresse von Wangenheim, 2023). Mais recentemente, o uso e ensino de *chatbots* utilizando *LLMs* (*Large Language Models*), como o ChatGPT (OpenAI, 2023), têm sido explorados como uma forma de engajar os estudantes e demonstrar potencialidades da IA (Hays et al., 2024; Lee e Kwon, 2024).

Avaliação da aprendizagem e *feedback*.

A avaliação da aprendizagem dos estudantes é definida como (Huba e Freed, 2000):

”[...] o processo de coleta e discussão de informações provenientes de fontes múltiplas e diversas, a fim de desenvolver uma compreensão profunda do que os estudantes sabem, compreendem e podem fazer com o seu conhecimento como resultado das suas experiências educativas; o processo culmina quando os resultados da avaliação são usados para melhorar a aprendizagem subsequente”.

A avaliação é um elemento importante nas estratégias para o ensino, pois tem como objetivo orientar a aprendizagem dos estudantes, fornecendo *feedback* sobre seu desempenho em uma tarefa ou processo de aprendizagem (OECD/CERI, 2008). Além disso, permite aos instrutores identificar as necessidades de aprendizagem dos estudantes e ajustar as estratégias para o ensino adequadamente (OECD/CERI, 2008).

No contexto do ensino de IA/ML na educação básica, a avaliação é essencial para garantir que os estudantes não apenas compreendam os conceitos básicos, mas também consigam aplicá-los na prática, considerando o impacto e as

limitações dessas tecnologias em rápida evolução (Rauber e Gresse von Wangenheim, 2022; Touretzky et al., 2019).

Existem várias formas de avaliações para IA/ML na educação básica, incluindo avaliação baseada em desempenho, autoavaliação do estudante, observações, entre outros (Martins e Gresse von Wangenheim, 2023; Rauber e Gresse von Wangenheim, 2022; Yue et al., 2022; Tikva e Tambouris, 2021). Os métodos podem variar de avaliações de forma qualitativa como observações em sala de aula, entrevista e análise de artefatos a quantitativa como a aquisição de conhecimento usando testes pontuados (Yue et al., 2022).

Uma visão geral dos principais métodos de avaliação da aprendizagem e *feedback* é apresentada no Quadro 12 (Rauber e Gresse von Wangenheim, 2022; Yue et al., 2022; Tikva e Tambouris, 2021).

Quadro 12 – Métodos de avaliação da aprendizagem e *feedback*

Método de avaliação	Descrição	Exemplos
Avaliação baseada em desempenho	Um método que requer que os estudantes demonstrem ou apliquem suas habilidades criando uma resposta, um produto ou realizando uma tarefa. Avalia a habilidade dos estudantes de aplicar o que aprenderam em contextos autênticos ou do mundo real, medindo assim as habilidades de pensamento de ordem superior, como análise, síntese e avaliação (N.Y. State Education Department, 2024).	<ul style="list-style-type: none"> • Documentação de um projeto • Artefato (p.ex., aplicativos, código, rede neural treinada, documentação)
Autoavaliação do estudante	Os estudantes analisam seu próprio progresso de aprendizagem, para entender sua percepção da aprendizagem, suas atitudes e crenças (Morrison et al., 2019). Este método os incentiva a assumir um papel ativo em seu aprendizado (Andrade, 2019). No entanto, em alguns aspectos, há relatos de limitações em termos de precisão devido às características do próprio autoavaliador (Taylor, 2014).	<ul style="list-style-type: none"> • Questionário de autoavaliação (múltipla escolha, Escala Likert, etc.)
Observação	Método usado para avaliar as transformações no comportamento, desempenho, interações e outros aspectos por meio da observação dos estudantes (Allen et al., 2011).	<ul style="list-style-type: none"> • <i>Checklist</i> • Anotações do observador
Entrevista	Método usado para <i>feedback</i> e também para entender o aprendizado dos estudantes, os processos e a aplicação de seu pensamento. As entrevistas podem ser estruturadas, semiestruturadas ou não estruturadas, cada uma facilitando diferentes níveis de percepção (Creswell et al., 2018).	<ul style="list-style-type: none"> • Roteiro da entrevista • Anotações da entrevista
Testes/Quizzes	Método usado para avaliar a aquisição de conhecimento do estudante. Os testes podem ser aplicados no início (pré-teste) para definir um ponto de partida, testes integrados ao longo do processo de aprendizagem, e testes finais (pós-teste) para mensurar o progresso e o impacto da intervenção educacional, comparando o desempenho inicial e final dos estudantes (Morrison et al., 2019).	<ul style="list-style-type: none"> • Teste (p.ex. múltipla-escolha, perguntas abertas, etc.)

Fonte: adaptado de Rauber e Gresse von Wangenheim (2022), Yue et al. (2022) e Tikva e Tambouris (2021)

Para as avaliações baseada em desempenho, uma rubrica de pontuação pode ser utilizada a fim de analisar sistematicamente os artefatos criados pelos estudantes (Rauber e Gresse von Wangenheim, 2022). As rubricas podem definir critérios e níveis de desempenho esperados, fornecendo um *feedback* mais detalhado e direcionado (Rauber e Gresse von Wangenheim, 2022). Esse método pode apoiar o ensino de ML como parte de uma avaliação abrangente (Rauber et al., 2023, Hsu et al., 2022).

As avaliações podem ser conduzidas manualmente pelos instrutores (p.ex. incluindo indicação de níveis de desempenho) ou de forma automatizada (p. ex. a avaliação baseada em desempenho com a visualização das pontuações, quizzes com correção instantânea e visualização da qualidade de um artefato de *ML*) (Rauber e Gresse von Wangenheim, 2022).

O *feedback* fornecido aos estudantes por meio desses métodos de avaliação geralmente é simples, incluindo uma nota, pontuação ou indicação do nível de desempenho (Rauber e Gresse von Wangenheim, 2022; Yue et al., 2022). No caso de testes e quizzes, é frequentemente indicado se a resposta está correta ou não, eventualmente acompanhada de uma breve explicação referente à questão (Rauber e Gresse von Wangenheim, 2022).

2.3 PROCESSO DE DESENVOLVIMENTO DE *ML*

O desenvolvimento de modelos de *Machine Learning* geralmente segue um processo iterativo e cíclico, com etapas bem definidas (Microsoft, 2024; Amazon, 2021; Studer et al., 2021). Esse processo é orientado por *frameworks* estabelecidos e recentemente por normas ISO/IEC, que estabelecem práticas para um ciclo de vida controlado (ISO/IEC, 2023a; 2023b).

No contexto educacional, adota-se uma abordagem centrada no ser humano, envolvendo os estudantes em um ciclo interativo de desenvolvimento (Gillies et al., 2016; Amershi et al., 2019). Adaptado para o ensino, Gresse von Wangenheim e von Wangenheim (2021) propõem um processo de desenvolvimento de *ML* centrado no ser humano, enfatizando uma abordagem prática.

Uma visão geral dos principais *frameworks*, normas ISO/IEC e do processo de desenvolvimento centrado no ser humano para o ensino de *ML* é apresentada ao que se segue.

Frameworks

Um dos *frameworks* mais conhecidos para ciência de dados é o CRISP-DM (*CRoss-Industry Standard Process for Data Mining*) (TDWI, 2000). Recentemente este *framework* foi adaptado e expandido pelo grupo de pesquisa em IA da Mercedes-Benz, para o tratar do processo de desenvolvimento de modelos de *ML* com garantia de qualidade, o CRISP-ML(Q) (*CRISP for Machine Learning with*

Quality assurance) (Studer et al., 2021). Este *framework* define etapas para o processo de desenvolvimento de *ML* que são executadas de forma iterativa, realimentada e cíclica, permitindo refinar e aprimorar o modelo de *ML* até atingir um desempenho desejado. As etapas para esse processo são apresentadas no Quadro 13.

Quadro 13 – Etapas do *framework* CRISP-ML(Q)

Etapa	Breve descrição
1-Entendimento do Negócio e dos Dados	<ul style="list-style-type: none"> Compreender os objetivos de negócio e requisitos do projeto, alinhando-os com os dados disponíveis.
2-Preparação dos dados	<ul style="list-style-type: none"> Selecionar, limpar, construir e formatar os dados para deixá-los adequados para a modelagem. Aplicar engenharia de características e transformações nos dados.
3-Modelagem	<ul style="list-style-type: none"> Selecionar e aplicar algoritmos de <i>ML</i> apropriados considerando os requisitos. Definir, otimizar hiperparâmetros e treinar o modelo.
4-Avaliação	<ul style="list-style-type: none"> Avaliar rigorosamente o modelo treinado usando métricas de desempenho.
5-Implantação	<ul style="list-style-type: none"> Planejar a implantação, entrega e monitoramento do modelo em produção.
6-Monitoramento e manutenção	<ul style="list-style-type: none"> Monitorar o desempenho do modelo em produção. Planejar atualizações e retreinamento contínuo conforme necessário.

Fonte: Ogawa e Goto (2022); Studer et al. (2021)

Outro *framework* bem estabelecido é o processo de ciclo de vida de *ML* da Amazon, descrito no *AWS Well-Architected Machine Learning Lens* (Amazon, 2021). Esse processo também enfatiza a natureza iterativa e cíclica do desenvolvimento de *ML*, com processos de realimentação entre as etapas. As etapas do processo são apresentadas no Quadro 14.

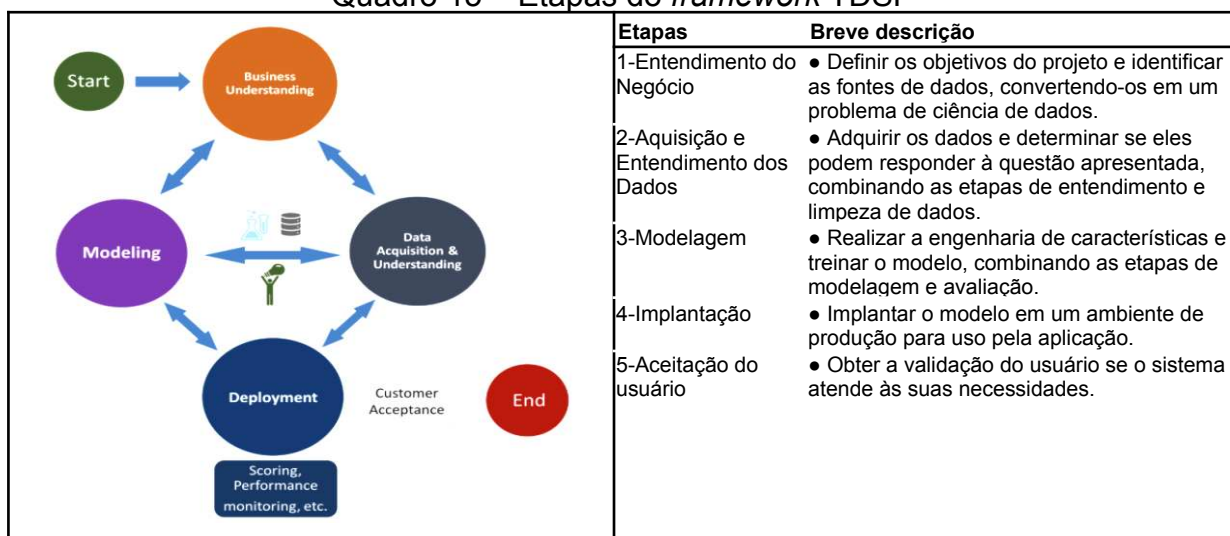
Quadro 14 – Etapas do *framework* AWS Well-Architected Machine Learning Lens

Etapas	Breve descrição
1-Identificação do objetivo de negócio	<ul style="list-style-type: none"> Definir claramente o objetivo do projeto de <i>ML</i>, alinhado com as metas de negócio.
2-Formulação do problema de <i>ML</i>	<ul style="list-style-type: none"> Traduzir o objetivo de negócio em um problema de <i>ML</i> bem definido, escolhendo a abordagem apropriada (supervisionada, não supervisionada, etc.).
3-Processamento de dados	<ul style="list-style-type: none"> Coletar, preparar e realizar engenharia de características nos dados necessários para treinar e avaliar o modelo.
4-Desenvolvimento do modelo	<ul style="list-style-type: none"> Treinar, ajustar hiperparâmetros e avaliar o modelo usando os dados processados, selecionando os algoritmos adequados.
5-Implantação do modelo	<ul style="list-style-type: none"> Colocar o modelo em produção para fazer inferências e previsões, integrando-o aos sistemas e aplicações.
6-Monitoramento do modelo	<ul style="list-style-type: none"> Acompanhar o desempenho do modelo em produção, coletando métricas e <i>feedbacks</i> para identificar necessidades de retreinamento ou ajustes.

Fonte: Amazon (2021)

Dentre os *frameworks* atuais para o processo de desenvolvimento de *ML*, está o TDSP (*Team Data Science Process*) da Microsoft (Microsoft, 2024), que combina elementos do ciclo de vida empregados em ciência de dados, engenharia de *software* e processos ágeis. Esse *framework* é considerado para p. ex. o desenvolvimento de modelos de *ML* na plataforma Azure da Microsoft (Azure *ML*) (Microsoft, 2024). O TDSP define um ciclo de vida em etapas cíclicas, realimentadas e iterativas (Quadro 15).

Quadro 15 – Etapas do *framework* TDSP



Fonte: Microsoft (2024)

Normas ISO/IEC

Além dos *frameworks* para o processo de desenvolvimento de *ML*, estão surgindo normas ISO/IEC específicas para o processo de desenvolvimento de sistemas de IA, como a ISO/IEC 5338 e a ISO/IEC 42001 (ISO/IEC, 2023a; 2023b).

Norma ISO/IEC 5338 — Esta norma define um conjunto de processos e conceitos associados para descrever o ciclo de vida de sistemas de IA baseados em *ML* e sistemas heurísticos (ISO/IEC, 2023a). Ela se baseia nas normas ISO/IEC/IEEE 15288 (processos de ciclo de vida de sistemas) e ISO/IEC/IEEE 12207 (processos do ciclo de vida de *software*), com modificações e adições de processos específicos para IA. Essa norma fornece processos que apoiam a definição, controle, gerenciamento, execução, manutenção e melhoria do sistema de IA ao longo de seu ciclo de vida (ISO/IEC, 2023a). Esses processos podem ser usados no projeto ao desenvolver sistemas de IA.

Norma ISO/IEC 42001 — Esta norma está em desenvolvimento para fornecer uma visão geral de alto nível e uma estrutura para processos de ciclo de vida de sistemas de IA, complementando a ISO/IEC 5338 (ISO/IEC, 2023b). Esta norma define requisitos para um sistema de gestão de IA como: planejamento, implementação, avaliação e melhoria de sistemas IA.

Enquanto os *frameworks* focam nos detalhes técnicos e nas etapas específicas do desenvolvimento de *ML*, essas normas ISO emergentes fornecem diretrizes e melhores práticas em um nível mais alto para o gerenciamento do ciclo de vida controlado desses sistemas (Microsoft, 2024; Amazon, 2021; ISO/IEC, 2023a; 2023b).

Processo de desenvolvimento de *ML* centrado no ser humano


Além dos *frameworks* gerais e normas ISO/IEC específicas, uma abordagem para o desenvolvimento de modelos de *ML*, é a centrada no ser humano. Essa abordagem, conhecida como *Human-Centered Machine Learning (HCML)*, visa colocar as necessidades, valores e bem-estar dos usuários no centro do processo, envolvendo-os em um ciclo iterativo de desenvolvimento (Gillies et al., 2016).

O processo de desenvolvimento de *ML* centrado no ser humano, proposto por Amershi et al. (2019) enfatiza a importância de envolver os usuários em todas as etapas, desde a definição do problema até a implantação e monitoramento do modelo. A importância da abordagem centrada no ser humano para o desenvolvimento de modelos de *ML* é reforçada por Ramos et al. (2020), Mathewson (2019) e Dudley e Kristensson (2018). A proposta de Ramos et al. (2020), o *Interactive Machine Teaching (IMT)*, é tornar a criação de modelos acessível, gerar modelos depuráveis, e aproveitar o conhecimento dos usuários para o desenvolvimento. Já Mathewson (2019) destaca que a abordagem centrada no ser humano melhora a usabilidade, interpretabilidade e aceitação dos sistemas de *ML*. Dudley e Kristensson (2018) explora o paradigma *Interactive Machine Learning (IML)* no qual o usuário iterativamente constrói, refina e revisa modelos de *ML*.

Para o contexto educacional, Gresse von Wangenheim e von Wangenheim (2021) propõem um processo de desenvolvimento de *ML* centrado no ser humano, com foco no ensino de *ML* para estudantes (Figura 3). Esse processo adapta as etapas gerais para o nível de conhecimento e habilidades dos estudantes, enfatizando a importância de uma abordagem prática e a discussão de questões

éticas. O processo proposto para o ensino segue uma abordagem iterativa e interativa, incorporando elementos de *Design Thinking* especialmente na fase de criação, como parte do ciclo Usar-Modificar-Criar (Gresse von Wangenheim e von Wangenheim, 2021). Uma síntese das etapas do processo é apresentada no Quadro 16.

Figura 3 – Processo de desenvolvimento de *ML* centrado no ser humano



Fonte: Gresse von Wangenheim e von Wangenheim (2021)

Quadro 16 – Processo de desenvolvimento de *ML* centrado no ser humano

Etapas	Descrição	
1-Identificação de necessidades e caracterização do contexto	<ul style="list-style-type: none"> Identificação de <u>necessidades</u> Caracterização do contexto 	<ul style="list-style-type: none"> Seguindo a abordagem de <i>Design Thinking</i>, a necessidade do sistema de <i>software</i> é identificada O contexto em que o sistema será aplicado é caracterizado em termos de público-alvo, dispositivos e ambientes de uso
2-Criação da ideia e especificação do sistema inteligente	<ul style="list-style-type: none"> Criação da ideia Especificação do sistema inteligente 	<ul style="list-style-type: none"> Com base na caracterização, uma solução é idealizada As tarefas e requisitos do sistema são analisados
3- Análise de requisitos do modelo de <i>ML</i>		<ul style="list-style-type: none"> O objetivo principal do modelo de <i>ML</i> e suas características alvo são especificados, incluindo a caracterização das entradas e saídas esperadas, especificando o problema
4-Preparação dos dados	<ul style="list-style-type: none"> Coleta e limpeza de <u>dados</u> Rotulagem dos dados Pré-processamento dos dados 	<ul style="list-style-type: none"> Conjuntos de dados potencialmente disponíveis são identificados e/ou os dados são coletados. Os dados são limpos e padronizados. Rótulos são atribuídos aos dados para aprendizado supervisionado Aumentações são realizadas nos dados, como p.ex. corte, rotação, etc. O tamanho do lote é definido. O conjunto de dados é dividido em conjuntos de treinamento (para treinar o modelo), validação (para selecionar o melhor candidato entre os modelos) e teste (para realizar uma avaliação de desempenho imparcial do modelo com dados não vistos em treinamento).
5-Treinamento e avaliação do modelo	<ul style="list-style-type: none"> Aprendizado do modelo (<i>Transfer Learning</i>) Aprendizado do modelo (<i>Fine-tuning</i>) Avaliação do desempenho 	<ul style="list-style-type: none"> Um modelo pré-treinado é selecionado e treinado usando os dados preparados. A aprendizagem por transferência é utilizada. Essa aprendizagem consiste em aproveitar as representações de recursos de um modelo pré-treinado, que geralmente é treinado em conjuntos de dados que são uma referência padrão (p.ex. o ImageNet) reutilizando os pesos obtidos em outras tarefas. Definição de rotinas de treinamento (configuração da taxa de aprendizado, número de épocas, além de métricas de desempenho). Os hiperparâmetros do modelo são ajustados para melhorar o desempenho (etapa opcional). O modelo treinado é avaliado usando métricas de desempenho específicas da tarefa (p.ex. acurácia, erro médio absoluto).
6-Implantação do modelo	<ul style="list-style-type: none"> Predição Exportação do modelo Implantação do modelo 	<ul style="list-style-type: none"> O modelo é testado com novos dados para obter uma aproximação de seu desempenho no mundo real. O modelo é exportado para permitir sua integração em um sistema de <i>software</i>. O modelo é implantado em um sistema de <i>software</i> para criar um sistema utilizável.
7-Avaliação de usabilidade		<ul style="list-style-type: none"> Teste de usabilidade

Fonte: Gresse von Wangenheim e von Wangenheim (2021)

Ao seguir essa abordagem iterativa e interativa de um processo de desenvolvimento de *ML* centrado no ser humano, os estudantes são envolvidos

ativamente nas etapas do desenvolvimento de um modelo de *ML* (Gresse von Wangenheim e von Wangenheim, 2021). Esse envolvimento ativo permite uma compreensão prática e aplicada dos conceitos de *ML*, possibilitando um aprendizado mais significativo e contextualizado (Martins et al., 2023c).

Resumo das etapas por processos de desenvolvimento de *ML*

Uma síntese das etapas dos *frameworks* para o desenvolvimento de *ML* e o processo de desenvolvimento de *ML* centrado no ser humano é destacado no Quadro 17.

Quadro 17 – Comparativo dos processos de desenvolvimento de *ML*

<i>Frameworks</i> para processo de desenvolvimento de <i>ML</i>			Processo de desenvolvimento de <i>ML</i> centrado no ser humano
CRISP-ML(Q) (Studer et al., 2021)	AWS <i>Well-Architected ML Lens</i> (Amazon, 2021)	TDSP (Microsoft, 2024)	(Gresse von Wangenheim e von Wangenheim, 2021; Amershi, 20219)
1-Entendimento do Negócio e dos Dados	1-Identificação do objetivo de negócio	1-Entendimento do Negócio	1-Identificação de necessidades e caracterização do contexto
	2-Formulação do problema de <i>ML</i>		2-Criação da ideia e especificação do sistema inteligente
2-Preparação dos dados	3-Processamento de dados	2-Aquisição e Entendimento dos Dados	3- Análise de requisitos do modelo de <i>ML</i>
		3-Modelagem	4-Preparação dos dados
3-Modelagem	4-Desenvolvimento do modelo	3-Modelagem	5-Treinamento e avaliação do modelo
4-Avaliação		4-Implantação	6-Implantação do modelo
5-Implantação	5-Implantação do modelo	5-Aceitação do usuário	7-Avaliação de usabilidade
6-Monitoramento e manutenção	6-Monitoramento do modelo		

Fonte: elaborado pelo autor

3 ESTADO DA ARTE

De modo a compreender como as estratégias para o ensino de computação (incluindo IA/ML) são aplicadas atualmente para os estudantes em situação de vulnerabilidade social, foi realizado um mapeamento sistemático da literatura. Este mapeamento foi realizado seguindo o procedimento definido por Petersen et al. (2008; 2015). Os resultados deste mapeamento foram publicados em Martins e Gresse von Wangenheim (2024) e expandem a busca para o ensino de ML para um contexto geral publicado em Martins e Gresse von Wangenheim (2023). No contexto desta tese, os resultados anteriormente publicados foram atualizados. Além disso, serão apresentados somente os resultados referentes ao ensino de competências relacionadas à IA/ML para estudantes em situação de vulnerabilidade social.

3.1 DEFINIÇÃO DO PROTOCOLO DE REVISÃO

Questão de pesquisa. Existem unidades instrucionais que ensinam IA/ML a estudantes em situação de vulnerabilidade social do Ensino Fundamental e Médio e quais são suas características? Essa pergunta de pesquisa é decomposta nas seguintes questões de análise:

- **QA1.** Quais unidades instrucionais existem ou foram ensinadas em um contexto de vulnerabilidade social?
- **QA2.** Quais são as características do contexto das unidades instrucionais?
- **QA3.** Quais competências são ensinadas nas unidades instrucionais?
- **QA4.** Quais são as características de instrução das unidades?
- **QA5.** Quais limitações foram observadas devido ao contexto de vulnerabilidade social, quais foram as consequências e como elas foram abordadas?
- **QA6.** Qual foi a qualidade percebida das unidades instrucionais?

Fontes de dados — Foram examinados artigos ou materiais publicados em inglês que estão disponíveis na web por meio de repositórios, bibliotecas digitais e bancos de dados reconhecidos na área de computação, incluindo o ACM Digital Library, IEEE Xplore, arXiv, Scopus, SocArXiv, ERIC (Departamento de Educação dos EUA), ScienceDirect (Elsevier) e SpringerLink. Além disso, foram realizadas

pesquisas no Google Scholar e no Google para complementar a pesquisa, minimizando o risco de omissão (Piasecki et al., 2018).

Critérios de inclusão/exclusão — Foram considerados qualquer artefato publicado até março de 2024, que apresenta resultados relacionados a uma unidade instrucional (curso, *oficina*, acampamento de verão, currículos) que inclua o ensino de IA/ML, direta ou indiretamente, para estudantes em situação de vulnerabilidade social do Ensino Fundamental e Médio (Quadro 18).

Quadro 18 – Critérios de inclusão/exclusão

Critérios de inclusão/exclusão	Inclusão	Exclusão
Foco	<ul style="list-style-type: none"> • Ensino de IA/ML 	<ul style="list-style-type: none"> • Ensinar computação sem tratar de IA/ML ou ensinar apenas o uso de dispositivos digitais e programas de <i>software</i> (por exemplo, editores de texto, planilhas eletrônicas)
Contexto	<ul style="list-style-type: none"> • Unidades instrucionais projetadas ou aplicadas a jovens em situação de vulnerabilidade social, de famílias de baixo nível socioeconômico ou que residem em áreas marginalizadas. 	<ul style="list-style-type: none"> • Desigualdade devido a gênero, raça, idade
Conteúdo	<ul style="list-style-type: none"> • Apresentação de qualquer tipo de unidade instrucional ou currículo para ensino/aprendizagem de IA/ML em um contexto de estudantes em vulnerabilidade social 	<ul style="list-style-type: none"> • Nenhuma apresentação de qualquer tipo de conteúdo, pedagogia, tecnologia, limitações e descobertas relacionadas ao ensino de IA/ML em um contexto de estudantes em vulnerabilidade social.
Etapa educacional	<ul style="list-style-type: none"> • Ensino Fundamental e Médio 	<ul style="list-style-type: none"> • Outras etapas educacionais
Idioma de publicação	<ul style="list-style-type: none"> • Inglês 	<ul style="list-style-type: none"> • Outros idiomas, p. ex., chinês, português, etc.
Tipo de publicação	<ul style="list-style-type: none"> • Artigos científicos em periódicos, conferências, repositórios online, internet, assim como trabalhos acadêmicos, tais como dissertações, teses, etc. 	<ul style="list-style-type: none"> • Blogs, vídeos ou ferramentas sem descrição adicional de uma unidade instrucional.

Fonte: Martins e Gresse von Wangenheim (2024)

Critérios de qualidade — Foram considerados apenas os materiais que fornecem informações substanciais sobre o ensino de IA/ML, direta ou indiretamente, para estudantes em vulnerabilidade social do Ensino Fundamental e Médio, indicando, por exemplo, o conteúdo, as abordagens pedagógicas, o suporte tecnológico utilizado, bem como as limitações e soluções de mitigação no ensino.

Definição da string de busca — A *string* de busca foi baseada em palavras-chave contextualizadas e composta de conceitos relacionados à pergunta da pesquisa, incluindo sinônimos, conforme indicado no Quadro 19. Além dos termos específicos relacionados a IA/ML, também foram incluídos termos mais amplos, como computação, para abranger estudos relevantes. Os termos utilizados estão no idioma da publicação original (Martins e Gresse von Wangenheim, 2024). A definição das palavras-chave foi calibrada com base em várias pesquisas informais para minimizar o risco de omissão.

Quadro 19 – Termos de busca

Principais conceitos	Sinônimos e termos correlatos
Computing	• machine learning, artificial intelligence, computer science, computational thinking, coding, programming
School	• k-12
Education	• teach*, course, learn*
Low socioeconomic status	• underprivileged, low income, poverty, poor, inequality, vulnerability, disadvantage students, slum, criminal suburbs, digital divide, marginalized communities

Fonte: Martins e Gresse von Wangenheim (2024)

Foi definida uma *string* de busca genérica, usando caracteres curinga para abranger o maior número possível de variações dos termos (Quadro 20).

Quadro 20 – String de busca genérica

String de busca genérica
("machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") AND ("k-12" OR school*) AND (teach* OR education OR course OR learn*) AND ("low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities").

Fonte: Martins e Gresse von Wangenheim (2024)

Subsequentemente foi ajustada a *string* de acordo com a sintaxe específica em cada fonte de dados, conforme apresentado no Quadro 21.

Quadro 21 – String de busca por fonte de dados

Principais conceitos	Sinônimos e termos correlatos
ACM Digital Library	[[Abstract: "machine learning"] OR [Abstract: "artificial intelligence"] OR [Abstract: ""] OR [Abstract: "computer science"] OR [Abstract: "computing"] OR [Abstract: "coding"] OR [Abstract: "programming"]] AND [[Abstract: "k-12"] OR [Abstract: school*]] AND [[Abstract: teach*] OR [Abstract: education] OR [Abstract: course] OR [Abstract: learn*]] AND [[Abstract: "low income"] OR [Abstract: "poverty"] OR [Abstract: "poor"] OR [Abstract: "socioeconomic"] OR [Abstract: "inequality"] OR [Abstract: "vulnerability"] OR [Abstract: "underprivileged"] OR [Abstract: "disadvantaged students"] OR [Abstract: "slum"] OR [Abstract: "criminal suburbs"] OR [Abstract: "digital divide"] OR [Abstract: "marginalized communities"]]
arXiv	include_cross_list: True; terms: AND abstract=machine learning OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming"; AND abstract="k-12" OR school*; AND abstract=teach* OR education OR course OR learn*; AND abstract="low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities"
ERIC (U.S. Dept. of Education)	abstract:(("machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") AND ("k-12" OR school*) AND (teach* OR education OR course OR learn*) AND ("low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities"))
Google	Devido às limitações do mecanismo de pesquisa do Google, foi usada uma <i>string</i> de pesquisa reduzida: "artificial intelligence" "computer science" "k-12" "learn" "teach" "low income" "poverty" "socioeconomic"
Google Scholar	("machine learning" OR "artificial intelligence" OR "deep learning" OR "data science") AND ("high school" OR "k-12" OR teen* OR school*) AND (teach* OR education OR course OR MOOC OR learn*)
IEEE Xplore	((("Abstract": "machine learning") OR ("Abstract": "artificial intelligence") OR ("Abstract": "deep learning") OR ("Abstract": "data science")) AND ((("Abstract": "high school") OR ("Abstract": "k-12") OR ("Abstract": "teen*") OR ("Abstract": "school*")) AND ((("Abstract": "teach") OR ("Abstract": "education") OR ("Abstract": "course") OR ("Abstract": "MOOC") OR ("Abstract": "learn*"))
ScienceDirect (Elsevier)	Devido às limitações do mecanismo de busca do ScienceDirect, foi usada uma string de busca reduzida: (("artificial intelligence" OR "computer science") AND ("k-12") AND (learn OR teach) AND ("low income" OR "poverty" OR "socioeconomic")) in Abstract
Scopus	(TITLE-ABS-KEY (machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") AND TITLE-ABS-KEY ("k-12" OR school*) AND TITLE-ABS-KEY (teach* OR education OR course OR learn*) AND TITLE-ABS-KEY ("low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities")) AND (LIMIT-TO (SUBJAREA , "COMP"))
SocArXiv	(machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") AND ("k-12" OR school*) AND (teach* OR education OR course OR learn*) AND ("low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities") in Abstract
SpringerLink	(machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") AND ("k-12" OR school*) AND (teach* OR education OR course OR learn*) AND ("low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities") Filter: within Computer Science. In Abstract
Wiley Online Library	machine learning" OR "artificial intelligence" OR "computer science" OR "computational thinking" OR "computing" OR "coding" OR "programming") in Abstract and "k-12" OR school* in Abstract and "teach* OR education OR course OR learn*" in Abstract and "low income" OR "poverty" OR "poor" OR "socioeconomic" OR "inequality" OR "vulnerability" OR "underprivileged" OR "disadvantaged students" OR "slum" OR "criminal suburbs" OR "digital divide" OR "marginalized communities" in Abstract

Fonte: Martins e Gresse von Wangenheim (2024)

3.2 EXECUÇÃO DA BUSCA

A busca foi realizada em janeiro de 2023 e atualizada em março de 2024. Na atualização da busca, os repositórios ACM Digital Library e Wiley Online Library não foram alcançados pelo Portal Capes. Foram identificados em uma primeira etapa 32.251 artefatos, analisando os 300 mais relevantes de cada fonte de dados. Após revisão de títulos, resumos "abstracts" e palavras-chave, 76 artefatos potencialmente relevantes foram selecionados. Aplicando critérios de inclusão/exclusão e de qualidade, 13 artigos foram selecionados. A fim de reduzir ainda mais o risco de omissão, também foi realizado um procedimento de *Snowballing (Forward e Backward)* (Wohlin, 2014), identificando mais 2 artigos. Um total de 15 artigos relevantes foram identificados para o ensino de computação para estudantes em situação de vulnerabilidade social. Desses, apenas 4 artigos tratam do ensino de IA/ML para estudantes em situação de vulnerabilidade social (Tabela 1).

Tabela 1 – Extrato de artigos identificados por etapa de seleção

Fonte de dados	Nº de resultados iniciais da busca	Nº de resultados analisados	Nº de resultados potencialmente relevantes	Nº de resultados relevantes (Ensino de Computação) (sem duplicatas)	Nº de resultados relevantes (Ensino IA/ML) (sem duplicatas)
ACM Digital Library	109	109	14	2	1
arXiv	31	31	1	0	0
ERIC	140	140	5	1	0
Google	12,717	517	10	0	0
Google Scholar	18,500	600	15	3	0
IEEE Xplore	82	82	10	4	0
ScienceDirect (Elsevier)	184	184	0	0	0
Scopus	314	314	15	2	2
SocArXiv	42	42	2	0	0
SpringerLink	45	45	2	1	1
Wiley Online Library	87	87	2	0	0
Snowballing					
<i>Backward snowballing</i>				2	0
<i>Forward snowballing</i>				0	0
Total	32.251	2.151	76	15	4

Fonte: elaborado pelo autor, adaptado de Martins e Gresse von Wangenheim (2024)

3.3 ANÁLISE DOS RESULTADOS

Com base nas informações extraídas, foram analisadas as unidades instrucionais em relação às questões de análise.

QA1. *Quais unidades instrucionais existem ou foram ensinadas em um contexto de vulnerabilidade social?*

Um total de 4 unidades instrucionais (Araya et al., 2021; Eguchi, 2021; Everson et al., 2022; Zhang et al., 2022) ensinam competências de IA/ML para estudantes em situação de vulnerabilidade social do Ensino Fundamental e Médio (Quadro 22).

Quadro 22 – Visão geral das unidades instrucionais

Referências	Breve descrição
(Araya et al., 2021)	Uma estrutura para o pensamento computacional do Projeto Matemática Inclusiva para Sustentabilidade em uma Economia Digital da Cooperação Econômica Ásia-Pacífico (APEC): pensamento algorítmico, modelagem computacional e ML.
(Eguchi, 2021)	Um projeto focado no desenvolvimento de uma ferramenta de código aberto acessível para atender à necessidade de promover a alfabetização em IA em todo o mundo e, especialmente, apoiar as necessidades urgentes dos países em desenvolvimento e das comunidades carentes.
(Everson et al., 2022)	Um curso de Ensino Médio co-construído para salas de aula com diversidade racial, étnica, socioeconômica e de gênero, que enquadra o curso como uma introdução criativa e crítica à computação/IA.
(Zhang et al., 2022)	Um <i>workshop</i> que integra ética e futuros de carreira com aprendizado técnico para promover a alfabetização em IA para estudantes do Ensino Médio.

Fonte: elaborado pelo autor

QA2. Quais são as características do contexto das unidades instrucionais?

As unidades instrucionais são aplicadas para estudantes de escolas de alta vulnerabilidade social (Araya et al., 2021), residentes de comunidades marginalizadas (Eguchi, 2021), estudantes de baixo status socioeconômico, e/ou que seus responsáveis não possuem ensino superior (Everson et al., 2022), e provenientes de famílias de baixa renda (Zhang et al., 2022).

QA3. Quais competências são ensinadas nas unidades instrucionais?

As unidades instrucionais seguem as diretrizes da AI4K12, contemplando as principais competências-chave das "5 Grandes Ideias" a serem ensinadas de IA para estudantes na educação básica. As unidades instrucionais abordam diferentes aspectos do ensino e aprendizagem de IA/ML, desde conceitos básicos como a exploração de dados (Araya et al., 2021) até tópicos complexos como algoritmos de Redes Adversárias Generativas (GANs) (Zhang et al., 2022). O algoritmo de ML mais observado é a Árvore de Decisão (Araya et al., 2021; Zhang et al., 2022). Todas as unidades instrucionais contemplam questões éticas, impactos sociais e oportunidades de carreira (Quadro 23).

Quadro 23 – Competências e conteúdos de IA/ML das unidades instrucionais

Referência	Competências de acordo com as "5 Grandes Ideias" da AI4K12 (Touretzky et al., 2019)	Conteúdos de IA/ML
(Araya et al., 2021)	<ul style="list-style-type: none"> Percepção; Representação e raciocínio; Aprendizagem 	<ul style="list-style-type: none"> Modelagem computacional: previsão; Algoritmo de ML (Árvore de decisão): tarefa de classificação; métricas (p. ex., precisão, classificação correta e incorreta)
(Eguchi, 2021)	<ul style="list-style-type: none"> Percepção; Representação e raciocínio; Aprendizagem; Interação natural; Impacto social 	<ul style="list-style-type: none"> Classificação de imagens; ética e impactos sociais.
(Everson et al., 2022)	<ul style="list-style-type: none"> Percepção; Representação e raciocínio; Aprendizagem; Interação natural; Impacto social 	<ul style="list-style-type: none"> Exploração de dados, como a IA funciona; Ética e impactos sociais
(Zhang et al., 2022)	<ul style="list-style-type: none"> Percepção; Representação e raciocínio; Aprendizagem; Interação natural; Impacto social 	<ul style="list-style-type: none"> Introdução à IA; ML: Aprendizado supervisionado, algoritmos (Árvore de decisão, Redes Neurais Artificiais), aprendizado não supervisionado, Redes Adversárias Generativas (GANs); ética e impactos sociais; oportunidades de carreira.

Fonte: elaborado pelo autor

QA4. Quais são as características de instrução das unidades?

As unidades instrucionais têm duração variando de 3 a 6 semanas. Diversos modos instrucionais são adotados, como ensino presencial, remoto e híbrido.

Para o ensino, as unidades instrucionais utilizam abordagens pedagógicas tais quais metodologia de aprendizagem colaborativa, baseada em jogos e interativa. Na unidade instrucional de Araya et al. (2021) os estudantes trabalham analisando colaborativamente um conjunto de dados de treinamento para identificar regras e padrões, para depois aplicar essas regras em um conjunto de testes, ilustrando um processo de ML. Everson et al. (2022) estimularam os estudantes a trabalhar colaborativamente para tratar de privacidade e implicações éticas em um conjunto de dados. Zhang et al. (2022) utilizaram a aprendizagem baseada em jogos e interativa, com atividades práticas e cinestésicas para os estudantes vivenciarem como um sistema se torna "inteligente" ao realizar certas tarefas e assim desenvolverem uma ideia de como os processos de IA funcionam.

Para o suporte tecnológico Zhang et al. (2022) e Eguchi (2021) utilizaram principalmente a ferramenta Google Teachable Machine para o treinamento de modelos de ML pelos estudantes. Eguchi (2021) também faz uso do kit robótico com IA chamado CogBot. Para o funcionamento desse robô, é utilizado o Arduino para o mecanismo e o Scratch com o modelo de ML implantado para o controle. Já Araya et al. (2021) adota uma abordagem diferente, utilizando atividades "desconectadas" (*unplugged*) que não requerem o uso direto de tecnologia, como atividades com papel e lápis, para ensinar conceitos de IA.

Para a avaliação do aprendizado, Araya et al. (2021) e Zhang et al. (2022) utilizaram testes para medir o conhecimento dos estudantes sobre os conceitos ensinados. Everson et al. (2022) combinaram observação da participação dos

estudantes e avaliação baseada em desempenho a partir de artefatos reflexivos criados por eles. Uma síntese das principais características das unidades instrucionais é apresentada no Quadro 24.

Quadro 24 – Características das unidades instrucionais

Referência	Duração	Abordagem pedagógica			Suporte tecnológico	Avaliação e feedback	
		Modo instrucional	Metodologia de aprendizagem	Método instrucional			Material instrucional
(Araya et al., 2021)	1 mês	Presencial	Aprendizagem colaborativa	Atividade práticas; Atividade desconectada; Trabalho em grupo; Discussão	Papel e lápis	-	Teste
(Eguchi, 2021)	Não Informado	Não Informado	Não Informado	Atividade prática	Kit robótico com IA	CogBots; Arduino; Google Teachable Machine; Scratch	Não Informado
(Everson et al., 2022)	6 semanas	Remoto	Aprendizagem colaborativa	Trabalho em grupo	Conjunto de dados	Não Informado	Observação; Avaliação baseada em desempenho (artefatos reflexivos)
(Zhang et al., 2022)	10 horas	Híbrido	Aprendizagem baseada em jogos Aprendizagem interativa	Atividade prática; Atividades cinestésicas; Discussão	Vídeos	Google Teachable Machine	Observação e Teste

Fonte: elaborado pelo autor

QA5. Quais limitações foram observadas devido ao contexto de vulnerabilidade social, quais foram as consequências e como elas foram abordadas?

As principais limitações relatadas pelos trabalhos no contexto de estudantes em vulnerabilidade social incluem principalmente a falta de infraestrutura em suas escolas e residências. A consequência disso é uma exclusão social e digital que afeta as atividades e o engajamento dos estudantes. Para mitigar essa questão, Araya et al. (2021) utilizaram atividades desconectadas e Everson et al. (2022) receberam dispositivos por meio de parcerias com a universidade. Eguchi et al. (2021) utilizaram para o ensino ferramentas acessíveis, com valor mais baixo (como o kit robótico com IA) e grátis/online (como o Google Teachable Machine). Apesar desses esforços, foi observada uma limitação significativa: muitos estudantes não têm conhecimento prévio de computação ou mesmo de habilidades digitais básicas (Everson et al., 2022; Araya et al., 2021). Isso resulta em desigualdades, segregação social e exclusão digital. Uma solução de mitigação encontrada por Everson et al. (2022) e Araya et al. (2021) foi introduzir conteúdos de *STEM* com foco em computação e pensamento computacional. Uma síntese das limitações, consequências e soluções de mitigação é apresentada no Quadro 25.

Quadro 25 – Limitações, consequências e soluções das unidades instrucionais

Limitações ou necessidades identificadas	Consequências	Soluções de mitigação	Referências
Falta de infraestrutura	Pode levar à divisão social, à divisão digital e à exclusão digital. Também pode afetar as atividades e o envolvimento dos estudantes.	<ul style="list-style-type: none"> • Uso de atividades desconectadas • Uso de ferramentas mais acessíveis • Uso de dispositivos facilitado por universidade parceira 	(Araya et al., 2021; Eguchi, 2021; Everson et al., 2022)
Falta de conhecimento básico de computação pré-existente ou de experiência no uso de dispositivos digitais	Pode levar a desigualdades, segregação social, exclusão digital e divisão dos estudantes	<ul style="list-style-type: none"> • Introdução à computação com foco em <i>STEM</i> e pensamento computacional • Co-construção do curso com os estudantes 	(Araya et al., 2021; Everson et al., 2022)
Contextos específicos (por exemplo, etnia, sexo, grupos minoritários, área de residência)	Cria dificuldade de compreensão, comunicação e a percepção de que a computação é um campo para apenas um grupo (p. ex. um sexo atribuído ao nascimento dominante).	<ul style="list-style-type: none"> • Projetar um currículo específico para um determinado grupo (de baixa renda) para cobrir uma lacuna no acesso ao conhecimento do conteúdo (IA). • Ensinar sobre oportunidades de carreira para um grupo específico (estudantes femininas de baixa renda). 	(Araya et al., 2021; Zhang et al., 2022)

Fonte: elaborado pelo autor

QA6. Qual foi a qualidade percebida das unidades instrucionais?

Dos achados positivos há a indicação de que os estudantes têm condições de aprender e aplicar conceitos de IA/ML, reconhecer vieses e discutir implicações éticas e sociais da tecnologia. No entanto, as dificuldades apontam para a necessidade de abordagens pedagógicas aprimoradas, incluindo a duração das aulas, o ambiente da sala de aula e o papel do instrutor. Além disso, conceitos de ML, como Redes Neurais Artificiais, podem exigir mais tempo e exposição para serem compreendidos pelos estudantes. O modo instrucional remoto também pode limitar a interação e a interpretação dos estudantes, impactando seu aprendizado. Uma síntese com os principais achados com relação aos impactos positivos e dificuldades das estratégias para o ensino das unidades instrucionais é apresentada no Quadro 26.

Quadro 26 – Principais achados quanto às estratégias para o ensino de IA/ML

Referências	Impactos positivos	Dificuldades
(Araya et al., 2021)	<ul style="list-style-type: none"> • O exemplo de modelagem computacional pode ser implementado pelos professores e compreendido corretamente pelos estudantes. • Os estudantes conseguiram conectar modelagem computacional a um problema real, compreender algumas das limitações do modelo e refletir de forma eficaz sobre como estendê-lo para superar algumas de suas limitações. 	<ul style="list-style-type: none"> • A curta duração das aulas (apenas 90 minutos) pode ter prejudicado o aprendizado.
(Eguchi, 2021)	-	-
(Everson et al., 2022)	<ul style="list-style-type: none"> • Os estudantes se envolveram discutindo tópicos de equidade, preconceito, justiça e marginalização no contexto da IA. 	<ul style="list-style-type: none"> • Necessidade de estabelecer um clima de sala de aula que permita conversas tensas no contexto de ética em IA • Necessidade de um instrutor consciente e equilibrado que motive a discussão de questões relacionadas à IA
(Zhang et al., 2022)	<ul style="list-style-type: none"> • A maioria dos estudantes compreendeu os conceitos e processos de IA. • Os estudantes conseguiram identificar os vieses de IA/ML e formas de mitigá-la. • Um total de 37,5% dos estudantes com entendimento prévio incorreto sobre IA, melhoraram após o <i>workshop</i>. • Houve ganhos significativos em conhecimento técnico sobre tópicos de IA como: conceitos gerais, sistemas lógicos, ML e aprendizado supervisionado. • Os estudantes conseguiram fazer diferenciação entre aprendizagem supervisionada e não supervisionada. • Houve melhoria na compreensão dos estudantes sobre aprendizagem supervisionada por meio da atividade com o Google Teachable Machine. • Houve ganhos no entendimento de GANs, porém não estatisticamente significativos. • Houve melhoria da percepção dos estudantes da relevância da IA e implicações éticas e sociais após o <i>workshop</i>. 	<ul style="list-style-type: none"> • Dos estudantes que começaram o <i>workshop</i> com um entendimento incorreto de IA, 25% continuaram a manter esse entendimento incorreto. • Conceitos de ML como Redes Neurais Artificiais, podem exigir exposições mais longas e mais tempo para os estudantes refletirem e internalizarem. • Os estudantes tendem a raciocinar sobre predição com base em sua experiência cotidiana de inteligência humana. Eles encontraram desafios ao discernir tecnologias que fazem previsões. • Os estudantes não obtiveram ganhos nos instrumentos que examinam a compreensão do estudante sobre os processos das Redes Neurais Artificiais. Possíveis motivos: intervenção muito curta, o modo instrucional remoto limitou as interações e as próprias interpretações dos estudantes. • As atividades de Redes Neurais Artificiais não incluíram aplicações reais para promover a compreensão desse conceito pelos estudantes.

Fonte: elaborado pelo autor

3.4 DISCUSSÃO

Considerando a crescente importância de popularizar o conhecimento de IA/ML já na educação básica e de oportunizar esse conhecimento também para estudantes em situação de vulnerabilidade social, foi realizado um mapeamento sistemático da literatura. Foram analisados 4 artigos de modo a identificar se existem unidades instrucionais que tratam do ensino de IA/ML a estudantes em situação de vulnerabilidade social do Ensino Fundamental e Médio e também quais são suas características, limitações, consequências e soluções de mitigação adotadas.

Das análises, nos artigos encontrados, observou-se que o ensino de IA/ML para jovens estudantes em situação de vulnerabilidade social têm mostrado resultados positivos no que diz respeito às condições de compreensão desde conceitos básicos de IA/ML até algoritmos mais avançados como GANs. Houveram resultados positivos quanto a aprender sobre conteúdos como exploração de dados, algoritmos como Árvores de decisão e Redes Neurais Artificiais. No entanto, foi observado que para o ensino de jovens em situação de vulnerabilidade social pode ser necessário um foco maior em conteúdos de STEM e pensamento computacional, principalmente àqueles que enfrentam a falta de conhecimento básico em

computação e/ou experiência no uso de dispositivos digitais. Ainda sobre o conteúdo, as questões éticas em IA podem ser, ao mesmo tempo, motivadoras como desafiadoras. Os estudantes em vulnerabilidade social se mostraram envolvidos em discussões atreladas a tópicos sobre preconceitos e desigualdade no contexto de IA. Os achados apontaram que ao tratar desses temas sensíveis é requerido dos instrutores maiores cuidados na condução de discussões.

Como um importante achado positivo no contexto de situação de vulnerabilidade social, foram reportados aumento do interesse dos estudantes em seguir carreira em IA. Esse interesse é principalmente evidenciado por achados nos quais os estudantes começam a considerar carreira em IA para mudar seu futuro, principalmente as estudantes femininas provenientes de famílias de baixa renda. Esse fato aponta em direção de que esse conhecimento é significativo e pode ser transformador para esses estudantes.

As abordagens pedagógicas empregadas no ensino de IA/ML para esse contexto, incluem metodologias centradas no estudante, com princípios construtivistas. As metodologias ativas, interativas e colaborativas tiveram resultados positivos ao envolver os estudantes e promover a compreensão dos conceitos de IA/ML. A metodologia colaborativa teve achados positivos para estudantes em situação de vulnerabilidade social, principalmente no aprendizado por pares, e ao trabalhar em grupos. Para esses estudantes, a conexão com a realidade foi alcançada por meio de discussões e atividades práticas. Também no ensino de IA/ML para esses estudantes, ao adotar a metodologia de aprendizagem baseada em jogos observou-se resultados satisfatórios no engajamento e motivação. Em alguns casos, foi observado a necessidade de adaptação das abordagens pedagógicas, co-construindo o curso com os estudantes. Neste contexto, também, para lidar com a falta de infraestrutura nas escolas, o uso de atividades desconectadas foi uma solução para oportunizar o ensino de IA/ML.

Os suportes tecnológicos para o ensino de IA/ML para os estudantes em situação de vulnerabilidade social tiveram achados positivos quanto ao uso de ferramentas como ambientes visuais, principalmente o Google Teachable Machine. Para esses estudantes o GTM serviu para desmistificar os processos de ML. No entanto, o uso de ferramentas tecnológicas para dar suporte ao ensino de ML para estudantes nesse contexto é reportado como um problema devido à falta de

infraestrutura, contudo o uso de dispositivos facilitados por parceria com a universidade foi uma solução de mitigação encontrada.

Ameaças a validade

Com a intenção de minimizar as ameaças à validade dos resultados deste estudo, foi identificadas ameaças potenciais e aplicadas estratégias de mitigação. Mapeamentos sistemáticos podem sofrer com o risco de omissão de estudos relevantes. Para mitigar esta questão, foi definido cuidadosamente as *strings* de busca, considerando não apenas conceitos-chave, mas também sinônimos relevantes. Além disso, foi incluído não apenas artigos científicos, mas também teses e dissertações, para evitar o risco de excluir unidades instrucionais existentes. Também foi pesquisado vários repositórios relacionados com o objetivo do mapeamento, bem como a realização de *snowballing* (Wohlin, 2014), a fim de minimizar ainda mais o risco de omissão. As ameaças à seleção de unidades instrucionais relevantes foram mitigadas por meio do detalhamento dos critérios de inclusão/exclusão, e critérios de qualidade, e consequentemente aplicando esses critérios cuidadosamente durante a seleção. A extração de dados foi dificultada em alguns casos como informações relevantes que não foram apresentadas explicitamente. Nesses casos, foi inferido de acordo com o contexto e informações disponíveis. A extração de dados foi cuidadosamente feita pelo autor.

4 MODELO INSTRUCIONAL PARA ENSINO DE *ML* A ESTUDANTES VULNERÁVEIS

Com base nos resultados encontrados no estado da arte e em alinhamento com diretrizes como o *framework* CSTA K-12 CS (CSTA, 2017) assim como guiados pelas diretrizes AI4K12 (Touretzky et al., 2019), MEC (2017), SBC (2018), competências-chave para a alfabetização de IA de Long e Magerko (2020), foram desenvolvidas e aprimoradas estratégias para o ensino de *ML* no curso "*Machine Learning* para todos!" a partir de uma versão inicial (v1.0) de Gresse von Wangenheim et al. (2020). O curso visa ensinar conceitos básicos de *ML* para estudantes dos anos finais do Ensino Fundamental e Médio no Brasil, contribuindo para a popularização da área. E, além disso, o curso visa oportunizar o conhecimento de *ML* para todos, promovendo dessa forma igualdade e inclusão para estudantes em situação de vulnerabilidade social (Martins et al., 2023a; 2023b; 2023c; 2023d).

4.1 ANÁLISE DE CONTEXTO

O curso "*ML* para todos!" tem como objetivo principal democratizar e popularizar o acesso ao conhecimento básico de *Machine Learning*, especialmente para estudantes dos anos finais do Ensino Fundamental e Médio, incluindo aqueles em situação de vulnerabilidade social (Martins et al., 2023b; Gresse von Wangenheim et al., 2020). Ao tornar esse conhecimento mais acessível e inclusivo, o curso visa contribuir para a alfabetização em Inteligência Artificial desses jovens, preparando-os melhor para os desafios e oportunidades do futuro.

Público alvo — O público alvo do curso são estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio entre 14 e 18 anos. Os estudantes são alfabetizados em sua língua nativa (português do Brasil) e têm certa familiaridade com o idioma inglês (MEC, 2017), porém não costumam ser fluentes em inglês (EF EPI, 2023). Nesta faixa de idade, espera-se que tenham conhecimentos básicos em linguagens, matemática, ciências naturais e ciências humanas, de acordo com a BNCC (Base Nacional Comum Curricular do Brasil) (MEC, 2017). Além disso, em sua etapa educacional, eles desenvolveram algumas

habilidades de pensamento crítico e reflexivo, bem como a capacidade de resolver problemas e tomar decisões éticas (MEC, 2017).

Estes estudantes são considerados nativos digitais, mais de 90% dos estudantes usam computadores, *smartphones* e outros dispositivos tecnológicos, além de demonstrar habilidades digitais básicas como pesquisar na internet (OECD PISA, 2022; TIC Kids Online Brasil 2021).

Estudantes em situação de vulnerabilidade social — Os estudantes dentro desse contexto, em particular, enfrentam dificuldades significativas no acesso à educação, impostas por barreiras como a necessidade de entrar no mercado de trabalho prematuramente e a falta de recursos financeiros (IBGE PNAD, 2023; 2019; UNICEF, 2021). Esses estudantes frequentemente vivem em comunidades marginalizadas, onde fatores externos como moradia inadequada, violência e discriminação afetam negativamente sua qualidade de vida e suas oportunidades educacionais (IBGE, 2023).

O impacto da pandemia de COVID-19 agravou ainda mais as desigualdades sofridas por esses estudantes, revelando e intensificando as dificuldades de acesso à educação. A transição abrupta para o ensino remoto destacou a lacuna digital existente, com muitos estudantes em situação de vulnerabilidade social enfrentando barreiras significativas ao acesso à tecnologia e à Internet (UNICEF, 2021; TIC Educação 2021).

Os estudantes em situação de vulnerabilidade social estão geralmente matriculados em escolas públicas. Os indicadores educacionais compostos pelas notas do SAEB (Sistema de Avaliação da Educação Básica) e IDEB (Índice de Desenvolvimento da Educação Básica) do INEP/MEC apontam notas inferiores dos estudantes das escolas públicas comparado com as escolas privadas (Brasil, 2022). Da infraestrutura tecnológica, 58% das escolas públicas brasileiras de Ensino Fundamental e Médio possuem computador e acesso à internet para uso dos estudantes (TIC Educação, 2022). Dos recursos dos estudantes matriculados em escolas públicas, cerca de 41% têm computador em casa, porém 39% não possuem nenhum tipo de dispositivo de acesso à internet em casa (TIC Educação, 2021).

Iniciativas de empoderamento e inclusão educacional — Recentemente surgiram algumas iniciativas governamentais e não governamentais que visam mitigar os efeitos da vulnerabilidade social na educação para jovens estudantes. Entre elas, destacam-se o Programa "Pé-de-Meia", um programa de incentivo

financeiro-educacional do governo federal para promover a permanência e a conclusão de estudantes matriculados no Ensino Médio público (MEC, 2024).

Outra iniciativa que se destaca é o Programa PodeCrer, do Instituto Vilson Groh (IVG, 2022), que atua diretamente com jovens em situação de vulnerabilidade social de comunidades marginalizadas. O objetivo do programa é alinhar as oportunidades educacionais com objetivos mais amplos de justiça social, como o combate à pobreza e à violência, promovendo a liderança, a criatividade e as habilidades tecnológicas. Ele também visa aproximar os estudantes do ecossistema de inovação e tecnologia para melhorar suas oportunidades educacionais e de carreira. O programa oferece suporte abrangente para os estudantes participantes do programa, incluindo apoio social, pedagógico e psicológico, além de refeições diárias, bolsas de estudo e vales-transporte (IVG, 2022).

Diante de todo esse cenário, está a iniciativa Computação na Escola (CnE, 2024), uma iniciativa do INCoD/INE/UFSC, que visa promover e facilitar o ensino de computação para todos os estudantes do Ensino Fundamental e Médio no Brasil. Para alcançar esse objetivo, a Computação na Escola se propõe a criar unidades instrucionais de acordo com diretrizes curriculares e adequadas às respectivas faixas etárias. Uma série de tutoriais e cursos são disponibilizados pela iniciativa, tais como "Aprenda a desenvolver apps", "Explorando as Artes Visuais com IA Generativa", "Tutorial Implantar ChatGPT em apps com App Inventor", entre outros (CnE, 2024). Adicionalmente, a iniciativa visa capacitar professores do Ensino Fundamental e Médio para o ensino de computação e compartilhar relatos de experiências e recursos referentes ao ensino de computação, criando uma comunidade de prática. Por fim, a iniciativa busca aumentar o número de formados na área de computação, com ênfase no aumento da representação de mulheres e minorias (CnE, 2024).

4.2 DEFINIÇÃO, DESENVOLVIMENTO E PLANEJAMENTO DO CURSO

O curso "*ML para todos!*" (v1.0) foi inicialmente desenvolvido por pesquisadores da iniciativa Computação na Escola (CnE) do Departamento de Informática e Estatística da Universidade Federal de Santa Catarina (Gresse von Wangenheim et al., 2020). Durante esta pesquisa de doutorado, o curso "*ML para todos!*" foi evoluído e aprimorado adotando o *Design-Based Research* (Philippakos

et al., 2021) em termos de conteúdo, abordagens pedagógicas, suporte tecnológico e avaliação de aprendizagem, além de apresentar alternativas para extensão das estratégias para o ensino, tornando-o adequado para estudantes em vulnerabilidade social.

Objetivos de aprendizagem

O curso é projetado para ensinar os conceitos básicos de *ML* para estudantes em vulnerabilidade social dos anos finais do Ensino Fundamental e Médio sem conhecimento prévio em computação, programação ou IA/*ML* (Martins et al., 2023a).

Com base nessas premissa, os objetivos de aprendizado são definidos em conformidade com a BNCC para a educação básica no Brasil (MEC, 2017), enfocando especialmente a "Grande Ideia 3 – Aprendizado de IA" em conformidade com as diretrizes K-12 para Inteligência Artificial (AI4K12) (Touretzky et al., 2019), a alfabetização em IA (Long e Magerko, 2020) e o processo de *ML* centrado no ser humano (Amershi et al., 2019) (Quadro 27).

Quadro 27 – Objetivos de aprendizagem do curso "*ML* para todos!"

ID	Objetivos de aprendizagem	Referências
OA1	Conhecer e identificar exemplos de aplicações de <i>ML</i>	(Touretzky et al., 2019; Long e Magerko, 2020)
OA2	Descrever conceitos básicos de <i>ML</i> : o que é uma Rede Neural Artificial e como ela funciona, e o processo de <i>ML</i>	(Touretzky et al., 2019; Long e Magerko, 2020)
OA3	Coletar, limpar e rotular dados para o treinamento de um modelo de <i>ML</i> ; entender como os algoritmos de <i>ML</i> são influenciados pelos dados	(Amershi et al., 2019; Long e Magerko, 2020)
OA4	Treinar um modelo de <i>ML</i>	(Amershi et al., 2019; Touretzky et al., 2019; Long e Magerko, 2020)
OA5	Avaliar o desempenho de um modelo de <i>ML</i>	(Amershi et al., 2019; Long e Magerko, 2020)
OA6	Discutir preocupações éticas e o impacto do <i>ML</i> na sociedade	(Touretzky et al., 2019; Long e Magerko, 2020)

Fonte: adaptado de Gresse von Wangenheim et al. (2020)

Nível de aprendizagem — Dado que o aprendizado de *ML* é complexo, e o público alvo são estudantes iniciantes, com pouca ou nenhuma experiência prévia em computação/IA/*ML*, o curso adota uma progressão de aprendizagem baseada na taxonomia cognitiva de Bloom para estruturar a sequência de objetivos de aprendizagem (Anderson e Krathwohl, 2001; Bloom, 1956). O curso inicia com competências básicas e leva os estudantes até os níveis superiores de "aplicação" e "análise". Dessa forma o curso incentiva os estudantes a usar o conhecimento adquirido em situações práticas, aprofundando assim o aprendizado e aumentando a relevância do conhecimento (Anderson e Krathwohl, 2001; Bloom, 1956).

O curso se concentra no estágio de "uso" do ciclo "Usar-Modificar-Criar" (UMC) (Lytle et al., 2019; Lee et al., 2011). Nesse estágio os estudantes são guiados passo a passo pelo processo de desenvolvimento de *ML* centrado no ser humano, para interagirem com um artefato, seu próprio modelo de *ML* (Gresse von Wangenheim e von Wangenheim, 2021; Amershi et al., 2019). No estágio de "uso", os estudantes ainda procedem na análise desses seus artefatos (Lytle et al., 2019; Lee et al., 2011).

Conteúdo e sequenciamento de conteúdo

O curso "*ML* para todos" consiste em seis aulas com duração total de 8 horas-aula, com os seguintes conteúdos e sequenciamento:

Na primeira aula, intitulada "Motivação", com duração de 2 horas, é apresentado no curso noções gerais de IA, assim como seus potenciais e importância. Além disso, apresenta uma visão geral de tecnologias IA/*ML* do cotidiano dos estudantes como, por exemplo, sistemas de recomendação em redes sociais, reconhecimento facial, até alternativamente estendendo às tecnologias emergentes como p.ex. os modelos de linguagem (ChatGPT).

Na segunda aula, intitulada "Conceitos básicos", com duração de 2 horas, o curso introduz os conceitos básicos *ML* e como o computador aprende. Nessa aula também é apresentado fundamentos de Redes Neurais Artificiais e seu funcionamento. Esse funcionamento é ilustrado pelo uso do cenário de uma tarefa de classificação de imagem de "raças de cachorro" introduzindo e percorrendo de forma didática as principais etapas de um processo de desenvolvimento de *ML* centrado no ser humano: preparação de dados, treinamento do modelo e previsão.

Na terceira aula, intitulada "Preparação dos dados", com duração de 1 hora, a partir do processo de desenvolvimento de *ML* centrado no ser humano, os estudantes são orientados no desenvolvimento de seu primeiro modelo pré-definido de *ML*. É abordado nessa aula, especificamente, a tarefa de classificação de imagens. Essa tarefa aborda o problema dos lixos recicláveis, um problema do mundo real relacionado aos "Objetivos de Desenvolvimento Sustentável" das Nações Unidas (ONU, 2015). Nessa aula é procedido a preparação do conjunto de dados, abordando etapas como coletar imagens de lixo reciclável, limpeza dos dados e rotulação dos dados (em papel, plástico, metal e vidro).

Na quarta aula, intitulada "Treinamento do modelo", com duração de 1 hora, é realizado o treinamento do modelo de *ML*, com a explanação dos procedimentos para o treinamento como configuração de hiperparâmetros e avaliação do desempenho. Também são abordadas questões como *overfitting* e ajustes no modelo, apresentando opções para melhorias no desempenho do modelo.

Na quinta aula, intitulada "Processo de *ML*", com duração de 1 hora, todo processo de desenvolvimento de um modelo de *ML* é revisado e discutido.

Por fim, na sexta aula, intitulada "Questões éticas e oportunidades", com duração de 1 hora, o curso explora conteúdos como questões éticas, limitações e riscos da IA/*ML*. Além do impacto da IA/*ML* na sociedade e oportunidades de carreira.

Processo de desenvolvimento de *ML* centrado no ser humano

Para o ensino de *ML* no curso "*ML* para todos" foi definido um processo de desenvolvimento de *ML* centrado no ser humano com base nas propostas de Gresse von Wangenheim e von Wangenheim (2021) e Amershi et al. (2019). O curso guia os estudantes passo a passo por esse processo iterativo se concentrando no estágio de "uso" do ciclo "Usar-Modificar-Criar" (Lee et al., 2011). Para esse estágio o curso abrange as etapas básicas do desenvolvimento de um modelo de *ML*, incluindo: preparação de dados, treinamento do modelo, avaliação do modelo e predição (Gresse von Wangenheim e von Wangenheim, 2021). As etapas do processo são apresentadas na Figura 4 e explicadas no Quadro 28.

Figura 4 – Processo de desenvolvimento de *ML* centrado no ser humano



Fonte: elaborado pelo autor, adaptado de Gresse von Wangenheim e von Wangenheim (2021)

Quadro 28 – Processo de desenvolvimento de *ML* centrado no ser humano

Etapas	Passos	Descrição	Resultado	Artefato
Análise de requisitos		<ul style="list-style-type: none"> O objetivo principal do modelo e suas características-alvo são especificados. Inclui a caracterização das entradas e saídas esperadas, especificando o problema. 	<ul style="list-style-type: none"> Decisão das classes de imagens a serem utilizadas (metal, papel, plástico e vidro) 	
Preparação de dados	Coleta de dados e limpeza dos dados	<ul style="list-style-type: none"> O conjunto de dados disponíveis são verificados e/ou novos dados são coletados. Para a tarefa do curso, o conjunto de dados é composto de imagens. Os dados (imagens) são limpos, o que envolve p.ex. a remoção de duplicatas das imagens ou imagens fora do contexto do problema. Os dados (imagens) também podem ser padronizados (p.ex com relação ao formato, convertendo imagens .webp em .jpg ou .png) 	<ul style="list-style-type: none"> Conjunto de imagens limpas e opcionalmente padronizadas 	
	Rotulação dos dados	<ul style="list-style-type: none"> Os dados (imagens) coletados são rotulados. A rotulação de dados envolve a atribuição de nomes verdadeiros que representam cada classe conforme o problema, para o aprendizado supervisionado. As classes para a tarefa proposta são (metal, papel, plástico e vidro). 	<ul style="list-style-type: none"> Conjunto de dados (imagens) rotuladas conforme classes definidas. Separadas em pastas (uma por classe). Salvos no Google Drive ou localmente 	<ul style="list-style-type: none"> Arquivo GTM (.tm) que consiste em um arquivo compactado, contendo as imagens usadas no treinamento, e um arquivo json com informações de configuração e hiperparâmetros de treinamento.
Treinamento do modelo e Avaliação	Aprendizagem de modelos	<ul style="list-style-type: none"> É realizada a configuração dos hiperparâmetros para o processo de treinamento que envolve a definição da quantidade de época, tamanho do lote e taxa de aprendizado. O modelo é treinado. 	<ul style="list-style-type: none"> Execução do treinamento Visualização do processo 	
	Avaliação de desempenho	<ul style="list-style-type: none"> O modelo treinado é avaliado com base em informações sobre a acurácia por classe, acurácia total, acurácia por época, perda por época e matriz de confusão (apresentando as classes x predição) 	<ul style="list-style-type: none"> Visualização das métricas de desempenho 	<ul style="list-style-type: none"> Informações coletadas dos estudantes em relatório online.
Predição		<ul style="list-style-type: none"> O modelo é testado com novos dados (imagens) para avaliar seu desempenho na generalização para dados não vistos durante o treinamento. Isso permite estimar a capacidade preditiva do modelo quando aplicado a dados reais, fora do conjunto de treinamento. 	<ul style="list-style-type: none"> Visualização dos resultados de predição 	
Exportação		<ul style="list-style-type: none"> O modelo treinado pode ser exportado no formato do TensorFlow.js para permitir análise ou implantação em aplicações web e <i>mobile</i>. 		<ul style="list-style-type: none"> Link para o modelo na Google Cloud ou download de um arquivo .zip contendo os componentes do TensorFlow.js: metadata.json (metadados do modelo com informações sobre as classes/rótulos) model.json (arquitetura do modelo) weights.bin (contém pesos treinados do modelo que permitem fazer previsões/classificações).

Fonte: elaborado pelo autor, adaptado de Gresse von Wangenheim e von Wangenheim (2021)

Os artefatos produzidos pelos estudantes durante o curso "*ML* para todos!" são coletados como resultados de aprendizagem. Os seguintes artefatos são coletados: arquivo de projeto do Google Teachable Machine (.tm) contendo as especificações do modelo de *ML* desenvolvido, como arquitetura, hiperparâmetros e metadados sobre as classes, bem como as imagens utilizadas no treinamento. E também relatórios online preenchidos pelos estudantes documentando a análise e interpretação dos resultados de desempenho e previsão do modelo.

Ao coletar esses artefatos, busca-se avaliar a capacidade dos estudantes de desenvolver, refinar, interagir e analisar sistemas de *ML* utilizáveis, mantendo-os no centro do processo de aprendizagem.

Abordagem pedagógica

O curso adota uma abordagem pedagógica construcionista (Papert et al., 1988) e de "Ação Computacional" (Tissenbaum et al., 2019), na qual os estudantes interagem com um artefato tangível e com relevância, desenvolvendo seus próprios modelos de *ML* treinados, que tenham significado em suas vidas e comunidades, permitindo que aprendam conceitos de *ML* nesse processo.

Metodologias de aprendizagem — As metodologias de aprendizagem empregadas no curso são: ativa, baseadas em problema, e baseada em jogos. A metodologia de aprendizagem ativa é aplicada no curso por meio de atividades práticas, nas quais os estudantes desenvolvem ativamente seus próprios modelos de *ML*. Essas atividades envolvem os estudantes diretamente no processo de aprendizagem, em vez de serem apenas receptores passivos de informações. Já a metodologia baseada em problemas é adotada através da proposição de tarefas que abordam problemas do mundo real, como a classificação de lixo reciclável. Dessa forma, os estudantes adquirem conhecimentos sobre conceitos básicos de *ML* enquanto buscam soluções para uma questão relevante e autêntica.

A metodologia baseada em jogos é adotada no curso por meio da gamificação de algumas atividades propostas e do envolvimento dos estudantes com jogos educacionais. A gamificação consiste na atribuição de pontos de experiência, ranking e "estrelas virtuais" quando os estudantes cumprem as atividades propostas. E como jogos educacionais, foi desenvolvido o jogo de cartas chamado "Dilema IA" (Arndt et al., 2024; CnE, 2024c) utilizado para engajar os estudantes na discussão de questões éticas relacionadas à IA/*ML* de forma lúdica e interativa.

Métodos instrucionais — O curso inclui métodos instrucionais variados, desde as explicações das aulas e atividades pelo instrutor até discussões entre os estudantes. Para manter um ambiente de aprendizado proveitoso, a duração das explicações das aulas são minimizadas em favor de métodos instrucionais centrados nos estudantes e que promovam sua autonomia, como, por exemplo, demonstrações e atividades práticas. As atividades práticas visam que os estudantes apliquem seus conhecimentos adquiridos por meio da interação com as atividades propostas para o desenvolvimento de seus modelos de *ML*.

Algumas aulas visam promover a discussão entre os estudantes, como as aulas iniciais com relação aos seus conhecimentos e concepções prévias sobre IA/ML (como forma de "quebrar o gelo") e nas aulas finais por meio de suas considerações e reflexões sobre questões éticas de IA/ML. Na abordagem de questões éticas, considerando a necessidade de fomentar mais discussões e princípios de pensamento crítico sobre esse conteúdo, o jogo de cartas "Dilema IA" é utilizado. O jogo como uma atividade desconectada, tem uma série de outras vantagens como desenvolver a interação social dos estudantes e permitir que os instrutores possam moderar temas sensíveis na discussão do tema. Além disso, esse método instrucional também pode ser alternativa quando houver infraestrutura limitada nos locais de aplicação do curso.

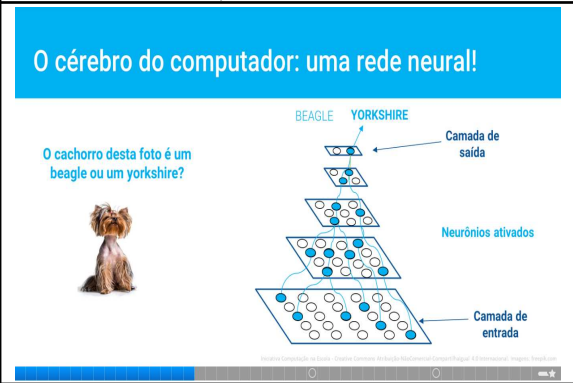
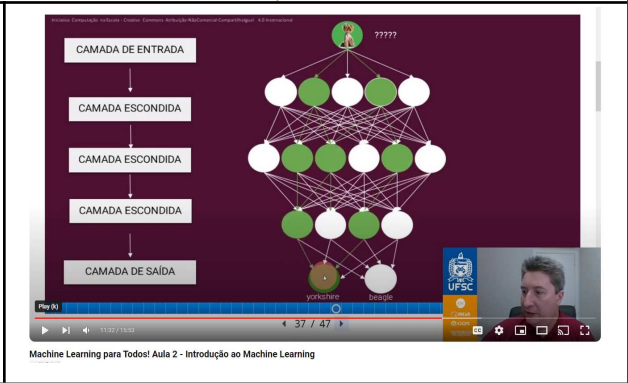
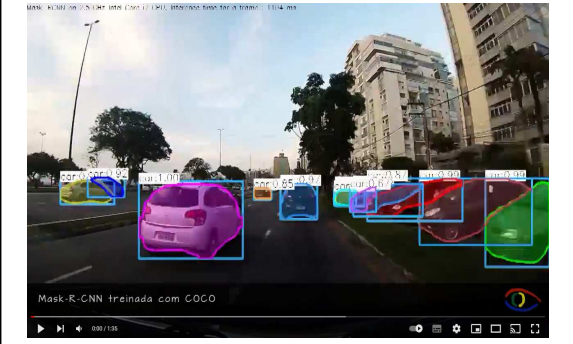
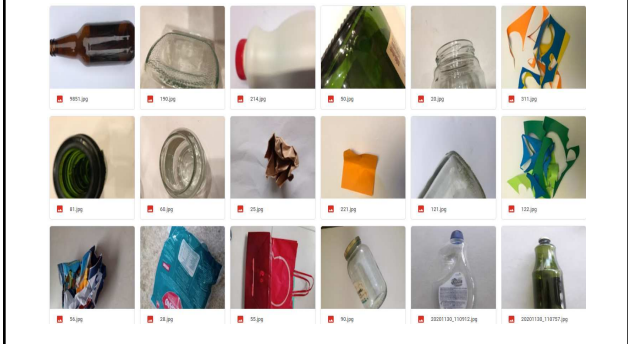

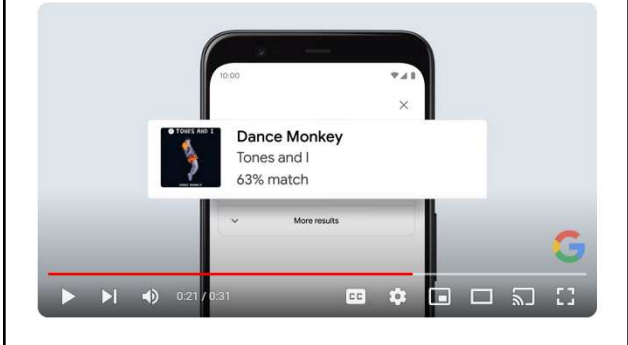
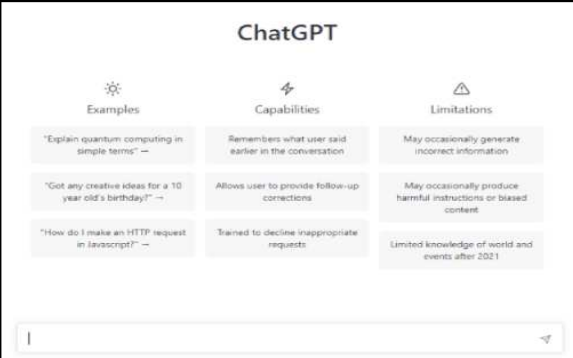

Tipos de materiais instrucionais — Para apoiar o ensino e manter o envolvimento dos estudantes, uma variedade de materiais instrucionais é fornecida. Slides interativos apresentam os conceitos de IA/ML com o objetivo de ser uma instrução dinâmica e motivadora, facilitando a compreensão. Videoaulas com explicações das aulas e atividades permitem que os estudantes acessem e revisem o conteúdo do curso quando necessário, promovendo sua autonomia. Aplicações demonstrativas, incluindo vídeos como por exemplo "Visão Computacional - Reconhecendo objetos em Florianópolis e na UFSC com *Mask-R-CNN*" (von Wangenheim, 2020), "música criada por IA" (Sweaty Machines, 2019) e "cantarolar para achar uma música" (Google, 2020), que apresentam práticas do potencial da IA/ML, ilustrando casos de uso reais. Também, como material instrucional, um conjunto de dados é disponibilizado aos estudantes como ponto de partida para as atividades propostas, permitindo a aplicação prática dos conceitos aprendidos.

No escopo de materiais instrucionais, o jogo de cartas "Dilema IA" oferece uma alternativa lúdica para abordar questões éticas relacionadas à IA, promovendo a sociabilização entre os estudantes e estabelecendo um ambiente de aprendizagem mais dinâmico (Arndt et al., 2024; CnE, 2024c). O material para o jogo de cartas "Dilema IA" está disponível gratuitamente em (CnE, 2024c): <http://apps.computacaonaescola.ufsc.br/codemaster/>

Além desses materiais principais, materiais instrucionais extras, como o vídeo "*Ethics & AI: Equal Access and Algorithmic Bias*" da Code.org (2020) com legenda em português, são disponibilizados para os estudantes aprofundarem seu aprendizado.

Visando tornar o curso acessível, todos os materiais instrucionais foram desenvolvidos em português do Brasil, idioma nativo dos estudantes do Ensino Fundamental e Médio no país. Alguns exemplos de materiais instrucionais adotados no curso "ML para todos!" são apresentados na Figura 5.

Figura 5 – Exemplos de materiais instrucionais do curso "ML para todos!"

<p>a) Slides interativos</p> 	<p>b) Videoaulas</p> 
<p>c) Vídeos</p> 	<p>d) Conjunto de dados</p> 
<p>e) Vídeos complementares</p> <div style="display: flex; justify-content: space-between;"> <div data-bbox="229 1301 804 1644">  </div> <div data-bbox="804 1301 1433 1644">  </div> </div>	
<p>f) ChatGPT</p> 	<p>g) Jogo de cartas Dilema IA</p> 

Fonte: elaborado pelo autor

Suporte tecnológico

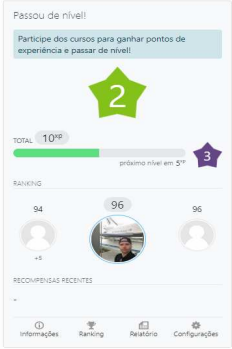
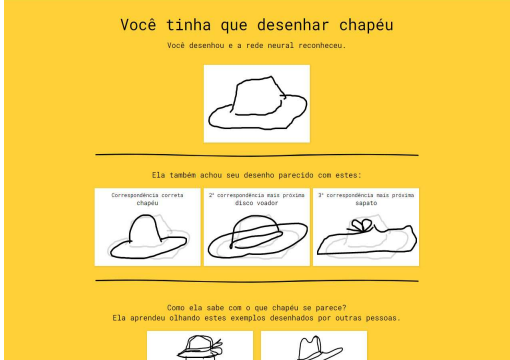
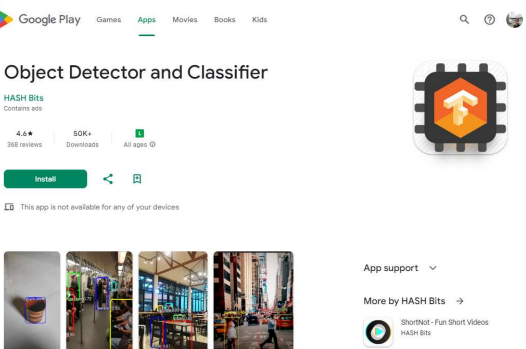
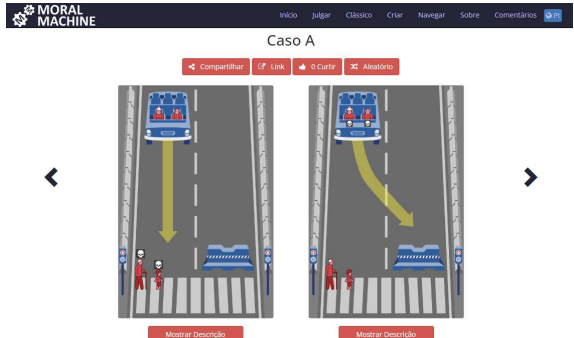
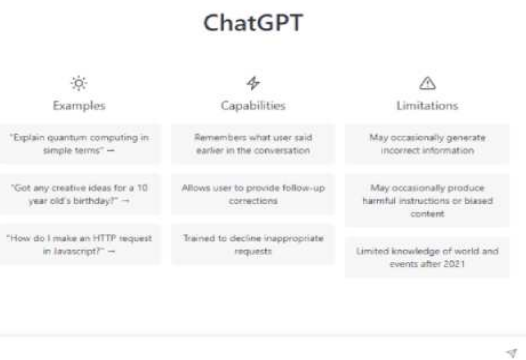
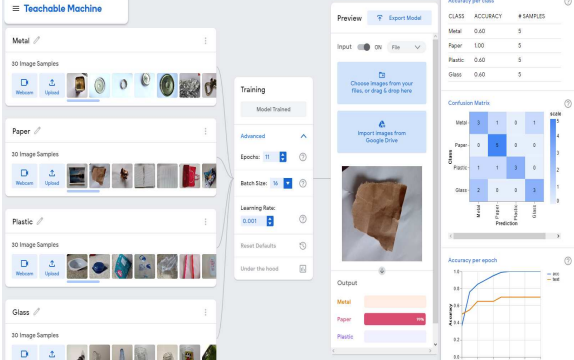
O curso é apoiado por várias ferramentas interativas e online de código aberto/livre para o suporte tecnológico. Isso inclui as aplicações utilizadas para os estudantes explorarem o potencial da IA/ML, p. ex., com foco no aprendizado baseado em jogos, como o *QuickDraw!* (Google AI Experiments, 2022) e o aplicativo "*Object Detector and Classifier - TensorFlow App*" (Hash Bits, 2018) para motivação de aprendizado. Além disso, o MIT *Moral Machine* (MIT, 2017) é empregado no curso para fornecer percepções sobre a reflexão humana em decisões tomadas pela IA, como carros autônomos, e estimular discussões relacionadas à ética em IA. Alternativamente, os estudantes ainda podem interagir com o modelo de linguagem ChatGPT (Open, 2023).

Para desenvolver o modelo de classificação de imagens, a ferramenta tecnológica utilizada é o Google Teachable Machine (GTM) (Google, 2023a). O GTM é uma ferramenta visual, gratuita, intuitiva, que permite o treinamento de modelos de *ML* mesmo por usuários sem conhecimento prévio de codificação (Gresse von Wangenheim et al., 2021). O GTM também oferece suporte para avaliação inicial do modelo de *ML* e a predição de novas imagens para avaliação de desempenho. O projeto contendo os dados de treinamento e as especificações do modelo de *ML* pode ser exportado como um arquivo ".tm", criando um artefato essencial para a avaliação subsequente de seu aprendizado (Rauber et al., 2023). O GTM também é utilizado e adequado para escolas brasileiras por oferecer uma versão em português do Brasil (Martins et al., 2023a; 2023c).

O curso está atualmente disponível gratuitamente via o site da CnE/UFSC (CnE, 2024a) bem como também via a plataforma Moodle, utilizando o *plugin* H5P, hospedada no servidor da UFSC para apoiar a aplicação no contexto da presente pesquisa. Nesse caso, os estudantes que não são diretamente filiados à UFSC precisam criar uma conta externa para obter acesso à plataforma Moodle. O conjunto de dados inicial, contendo as imagens sugeridas para o treinamento do modelo de *ML*, é disponível aos estudantes por meio do serviço de nuvem do Google, o Google Drive. Adicionalmente, nos modos instrucionais remotos e híbridos do curso, a comunicação com os instrutores é facilitada pelo Google Meet. A utilização dos recursos Google Drive e Google Meet é acessível aos estudantes por meio de suas contas do Google (Martins et al., 2023a; 2023b; 2023c).

Como alternativa, e com base no conhecimento de que os estudantes dos anos finais do Ensino Fundamental e Médio se motivam com jogos e disputas, foi adaptado um recurso tecnológico como estratégia de motivação. Esse recurso consiste na inserção de um sistema de gamificação na plataforma de aprendizagem Moodle. O sistema de gamificação escolhido foi o *plugin* "LevelUp" da Branch Up (2024), que permite aos estudantes acumularem pontos, subirem de nível e receberem "estrelas com pontuação" conforme avançam nas atividades e desafios propostos no ambiente virtual de aprendizagem. Alguns exemplos de suporte tecnológico utilizados no curso "ML para todos!" são apresentados na Figura 6.

Figura 6 – Exemplos de suporte tecnológico utilizados no curso "ML para todos!"

a) Gamificação (LevelUP)	b) QuickDraw!																																								
 <p>Passou de nível! Participe dos cursos para ganhar pontos de experiência e passar de nível!</p> <p>TOTAL: 10XP próximo nível em 5XP</p> <p>RANKING: 94, 96, 96</p> <p>RECOMPENSAS RECEBIDAS</p>	 <p>Você tinha que desenhar chapéu Você desenhou e a rede neural reconheceu.</p> <p>Ela também achou seu desenho parecido com estes:</p> <p>Correspondência correta: chapéu, 3ª correspondência mais próxima: disco voador, 2ª correspondência mais próxima: sapato</p> <p>Como ela sabe com o que chapéu se parece? Ela aprendeu olhando estes exemplos desenhados por outras pessoas.</p>																																								
c) Aplicativo (Object Detector and Classifier - TensorFlow App)	d) MIT Moral Machine																																								
 <p>Google Play Games Apps Movies Books Kids</p> <p>Object Detector and Classifier</p> <p>HASH Bits Conteúdo ads</p> <p>4.6★ 50K+ Downloads All ages 12+</p> <p>Install</p> <p>This app is not available for any of your devices</p> <p>App support</p> <p>More by HASH Bits</p>	 <p>MORAL MACHINE</p> <p>Caso A</p> <p>Compartilhar Link Curtir Algoritmo</p> <p>Mostrar Descrição</p>																																								
e) ChatGPT	f) Google Teachable Machine																																								
 <p>ChatGPT</p> <p>Examples Capabilities Limitations</p> <p>"Explain quantum computing in simple terms" → Remembers what user said earlier in the conversation May occasionally generate incorrect information</p> <p>"Got any creative ideas for a 10 year old's birthday?" → Allows user to provide follow-up corrections May occasionally produce harmful instructions or biased content</p> <p>"How do I make an HTTP request in Javascript?" → Trained to decline inappropriate requests Limited knowledge of world and events after 2021</p>	 <p>Teachable Machine</p> <p>Preview Experts Mode</p> <table border="1"> <thead> <tr> <th>CLASS</th> <th>ACCURACY</th> <th># SAMPLES</th> </tr> </thead> <tbody> <tr> <td>Metal</td> <td>0.60</td> <td>5</td> </tr> <tr> <td>Paper</td> <td>1.00</td> <td>5</td> </tr> <tr> <td>Plastic</td> <td>0.60</td> <td>5</td> </tr> <tr> <td>Glass</td> <td>0.60</td> <td>5</td> </tr> </tbody> </table> <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Metal</th> <th>Paper</th> <th>Plastic</th> <th>Glass</th> </tr> </thead> <tbody> <tr> <th>Metal</th> <td>5</td> <td>1</td> <td>1</td> <td>1</td> </tr> <tr> <th>Paper</th> <td>1</td> <td>5</td> <td>1</td> <td>1</td> </tr> <tr> <th>Plastic</th> <td>1</td> <td>1</td> <td>5</td> <td>1</td> </tr> <tr> <th>Glass</th> <td>1</td> <td>1</td> <td>1</td> <td>5</td> </tr> </tbody> </table> <p>Accuracy per epoch</p> <p>Output: Metal, Paper, Plastic</p>	CLASS	ACCURACY	# SAMPLES	Metal	0.60	5	Paper	1.00	5	Plastic	0.60	5	Glass	0.60	5	Class	Metal	Paper	Plastic	Glass	Metal	5	1	1	1	Paper	1	5	1	1	Plastic	1	1	5	1	Glass	1	1	1	5
CLASS	ACCURACY	# SAMPLES																																							
Metal	0.60	5																																							
Paper	1.00	5																																							
Plastic	0.60	5																																							
Glass	0.60	5																																							
Class	Metal	Paper	Plastic	Glass																																					
Metal	5	1	1	1																																					
Paper	1	5	1	1																																					
Plastic	1	1	5	1																																					
Glass	1	1	1	5																																					

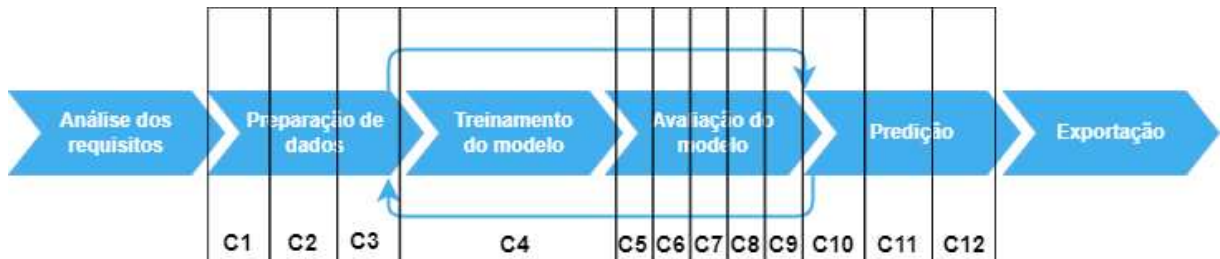
Fonte: elaborado pelo autor

Avaliação da aprendizagem e *feedback*

Avaliação alinhada aos objetivos de aprendizagem — Para avaliar se os estudantes atingiram os objetivos de aprendizagem do curso, é adotado uma abordagem de avaliação baseada em desempenho. Durante o curso os estudantes se envolvem no desenvolvimento de um modelo de *ML*, para classificar imagens de lixo reciclável, produzindo assim resultados de aprendizado tangíveis. Os artefatos criados nas aulas, são a entrada para uma avaliação baseada no desempenho do aprendizado do estudante utilizando uma rubrica de pontuação (Rauber et al., 2023; Gresse von Wangenheim et al., 2022).

A rubrica define as variáveis observáveis para avaliar a capacidade dos estudantes de desenvolver um modelo de *ML*, inferindo sobre o aprendizado dos conceitos abordados (Rauber et al., 2023) (Tabela 2). A rubrica define 12 critérios de avaliação (C1–C12) referente ao estágio de "uso" do ciclo "Usar-Modificar-Criar" (Lee et al., 2011) para o processo de desenvolvimento de modelo de *ML* centrado no ser humano (Figura 7). Os níveis de desempenho são especificados em uma escala ordinal de 4 pontos, variando de "não submetido" (0 pontos), quando um estudante não submete para avaliação seu artefato, a "bom" (3 pontos), refletindo a adesão à realização esperada de metas de aprendizado específicas (Rauber et al., 2023). A validação da rubrica demonstrou boa confiabilidade (Ômega de McDonald $\omega = 0.834$; alfa de Cronbach $\alpha = 0.83$) e validade de consistência interna (Rauber et al., 2023).

Figura 7 – Critérios da avaliação baseada em desempenho e processo de desenvolvimento de *ML* centrado no ser humano



Fonte: adaptado de Gresse von Wangenheim e von Wangenheim (2021)

Tabela 2 – Rubrica de pontuação da avaliação baseada em desempenho

Critérios observáveis	Item/Variáveis	Níveis de Desempenho			
		Não submetido - 0 ponto	Fraco - 1 ponto	Aceitável - 2 pontos	Bom - 3 pontos
Preparação de dados					
C1	Quantidade de imagens	Nenhum arquivo GTM (.tm) enviado para avaliação	Menos de 20 imagens por categoria	21 a 35 imagens por categoria	Mais de 35 imagens por categoria
C2	Distribuição do conjunto de dados	Nenhum arquivo GTM (.tm) enviado para avaliação	A quantidade de imagens em cada categoria varia muito. Mais de 10% de variação em ao menos uma categoria (relativo ao total)	A quantidade de imagens entre as categorias têm entre 3% e 10% de variação	Todas as categorias têm a mesma quantidade de imagens (menos de 3% de variação)
C3	Rotulação das imagens (amostragem de 10% das imagens para testar por meio do modelo <i>ML</i> de alta acurácia)	Nenhum arquivo GTM (.tm) enviado para avaliação	Menos de 20% das imagens foram rotuladas corretamente	Entre 20% e 95% das imagens foram rotuladas corretamente	Mais de 95% das imagens foram rotuladas corretamente
Treinamento do modelo					
C4	Treinamento	Nenhum arquivo GTM (.tm) enviado para avaliação	O modelo não foi treinado	O modelo foi treinado usando os parâmetros padrões	O modelo foi treinado com parâmetros ajustados (ex. épocas, <i>batch size</i> , taxa de aprendizado)
Interpretação de desempenho					
C5	Análise da acurácia por categoria	Não foram enviadas informações sobre categorias e/ou interpretação.	Categorias com baixa acurácia não identificadas	--	Todas as categorias com baixa acurácia identificadas corretamente
C6	Interpretação da acurácia	Não há informações enviadas sobre categorias e/ou interpretação.	Interpretação incorreta da análise de acurácia do modelo	--	Interpretação correta da análise de acurácia do modelo
C7	Análise da matriz de confusão	Não há informações enviadas sobre a Matriz de Confusão e/ou interpretação.	Identificação incorreta dos erros de classificação (mais de 2 erros)	Identificação incorreta de um ou dois erros de classificação	Identificação correta de todos os erros de classificação
C8	Interpretação da matriz de confusão	Não há informações enviadas sobre a Matriz de Confusão e/ou interpretação.	Interpretação incorreta da análise da matriz de confusão do modelo	--	Interpretação correta da análise da matriz de confusão do modelo
C9	Ajustes/melhorias realizadas	Não foram enviadas informações sobre melhorias.	Não foram relatadas novas iterações de desenvolvimento	Foi relatada uma nova iteração com alterações no conjunto de dados e/ou nos parâmetros de treinamento	Foram relatadas várias alterações no conjunto de dados e/ou nos parâmetros de treinamento
C10	Testes com novos objetos	Nenhuma informação foi enviada sobre Testes e/ou interpretação.	Nenhum objeto novo foi testado	1-3 objetos testados	Mais de 3 objetos testados
C11	Análise dos resultados dos testes	Nenhuma informação foi enviada sobre Testes e/ou interpretação.	Indicação incorreta do número de erros nos testes	--	Indicação correta da quantidade de erros nos testes
C12	Interpretação dos resultados dos testes	Nenhuma informação foi enviada sobre Testes e/ou interpretação.	Interpretação incorreta dos resultados dos testes	--	Interpretação correta dos resultados dos testes

Fonte: adaptado de Rauber et al. (2023) e Gresse von Wangenheim et al. (2022)

Na aula 3 (Preparação de dados) do curso, referente ao objetivo de aprendizagem (OA3) a avaliação ocorre sobre o conjunto de dados criado pelos estudantes, utilizando os critérios C1 a C3 da rubrica de pontuação. Já na aula 4 (Treinamento e avaliação do modelo), referente ao objetivo de aprendizagem (OA4 e OA5) a avaliação da aprendizagem se baseia no desempenho do treinamento do

modelo (critério C4 da rubrica) e na avaliação do modelo treinado (critérios C5 a C12 da rubrica). A avaliação de aprendizagem por objetivo de aprendizagem é apresentada no Quadro 29.

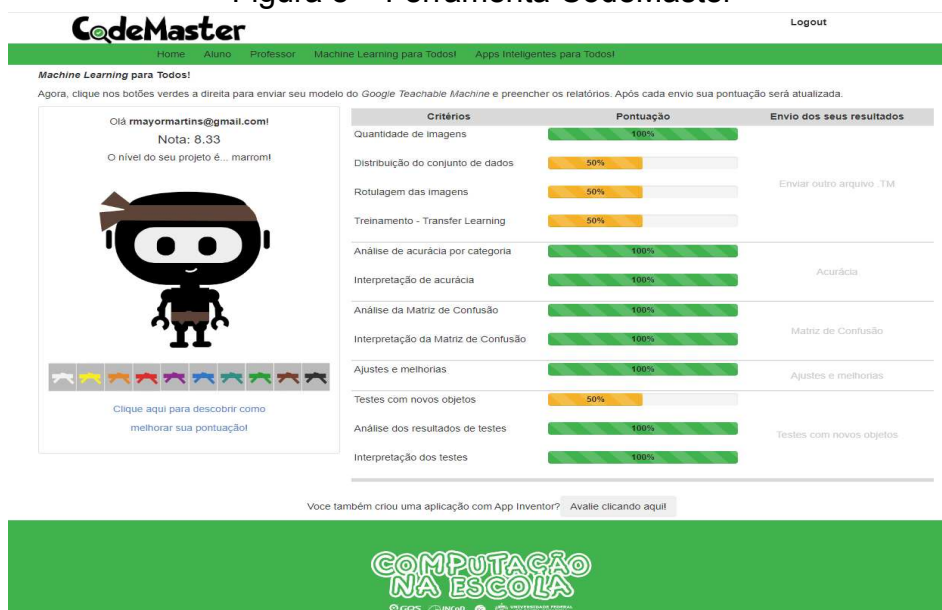
Quadro 29 – Avaliação de aprendizagem por objetivo de aprendizagem

ID	Objetivos de aprendizagem	Avaliação da aprendizagem
OA1	Conhecer e identificar exemplos de aplicações de <i>ML</i>	
OA2	Descrever conceitos básicos de <i>ML</i> : o que é uma Rede Neural Artificial e como ela funciona, e o processo de <i>ML</i>	
OA3	Coletar, limpar e rotular dados para o treinamento de um modelo de <i>ML</i> ; entender como os algoritmos de <i>ML</i> são influenciados pelos dados	<ul style="list-style-type: none"> • Avaliação baseada em desempenho: <ul style="list-style-type: none"> • Conjunto de dados (Critérios C1-C3)
OA4	Treinar um modelo de <i>ML</i>	<ul style="list-style-type: none"> • Avaliação baseada em desempenho: <ul style="list-style-type: none"> • Treinamento do modelo (Critério C4)
OA5	Avaliar o desempenho de um modelo de <i>ML</i>	<ul style="list-style-type: none"> • Avaliação baseada em desempenho: <ul style="list-style-type: none"> • Avaliação (Critérios C5-C12)
OA6	Discutir preocupações éticas e o impacto do <i>ML</i> na sociedade	

Fonte: elaborado pelo autor

A partir dessa avaliação, é fornecido o *feedback* em tempo real para os estudantes sobre seu desempenho por meio da automação da avaliação baseada em desempenho como parte da ferramenta CodeMaster (Rauber et al., 2023; CnE, 2024b). A ferramenta CodeMaster é online, gratuita e disponível em português do Brasil para interação dos estudantes. O *feedback* inclui a pontuação total e a pontuação para cada critério de avaliação. Além disso, a ferramenta CodeMaster oferece uma representação lúdica da pontuação, simbolizada pela cor da faixa de um ninja (Figura 8). A ferramenta CodeMaster está disponível gratuitamente em: <http://apps.computacaonaescola.ufsc.br/codemaster/>.

Figura 8 – Ferramenta CodeMaster



Fonte: CodeMaster (CnE, 2024b; Rauber et al., 2023)

Aplicabilidade do curso "*Machine Learning* para todos!"

Suprido com as estratégias para o ensino de *ML* elencadas, propostas, aprimoradas, desenvolvidas e definidas, o curso "*Machine Learning* para todos!" pode ser aplicado. O curso foi projetado para ser flexível, podendo ser integrado como parte das aulas regulares das escolas, com possibilidade de interdisciplinaridade, por exemplo, em aulas de ciências (Gresse von Wangenheim et al., 2020; Martins et al., 2023a). Além disso, o curso também pode ser oferecido como parte de atividades extracurriculares (Martins et al., 2023b; 2023c).

O curso "*ML* para todos!" completo está disponível gratuitamente em: <https://cursos.computacaonaescola.ufsc.br/cursos/curso-mlparatodos/> sob a Licença Creative Commons Atribuição-NãoComercial-Compartilha Igual 4.0 Internacional.

Plano de ensino do curso "*Machine Learning* para todos!"

O plano de ensino do curso "*ML* para todos!", apresentado no Quadro 30, organiza as principais estratégias para o ensino adotadas em cada aula, alinhadas aos objetivos de aprendizagem. Esse plano serve como um guia para a aplicação do curso, apresentando as estratégias para o ensino de *ML*, indicando o conteúdo/sequenciamento de conteúdo, abordagens pedagógicas, suporte tecnológico e avaliação da aprendizagem e *feedback*, visando o alcance dos objetivos propostos.

Quadro 30 – Plano de ensino do curso "ML para todos!"

Aula		Tópicos		Duração		Estratégia para o ensino de ML (▲ estratégias alternativas)					
		Objetivos de aprendizagem		Conteúdo		Abordagem pedagógica			Suporte tecnológico		Avaliação da aprendizagem e feedback
						Metodologia de aprendizagem	Método instrucional	Material instrucional			
1	Motivação	2h	OA1, OA6	<ul style="list-style-type: none"> Motivação sobre IA e sua aplicação no cotidiano Exemplos de aplicações de IA 	<ul style="list-style-type: none"> Aprendizagem ativa Aprendizagem baseada em jogos 	<ul style="list-style-type: none"> Aula explicativa, Discussão, Demonstrações práticas 	<ul style="list-style-type: none"> Slides interativos; Vídeo ▲ Videoaulas Aplicações de demonstração 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle Aplicativo <i>Object Detector and Classifier</i>, QuickDraw! ▲ ChatGPT ▲ LevelUP (Moodle) 			
2	Conceitos básicos	2h	OA2, OA4	<ul style="list-style-type: none"> Conceitos básicos de ML Processo de desenvolvimento de ML centrado no ser humano 	<ul style="list-style-type: none"> Aprendizagem ativa 	<ul style="list-style-type: none"> Aula explicativa 	<ul style="list-style-type: none"> Slides interativos ▲ Videoaulas 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle Google Teachable Machine ▲ LevelUP (Moodle) 			
3	Preparação de dados	1h	OA3-OA5	<ul style="list-style-type: none"> Classificação de imagens; Processo de desenvolvimento de ML centrado no ser humano (Preparação de dados) 	<ul style="list-style-type: none"> Aprendizagem ativa; Aprendizagem baseada em problemas 	<ul style="list-style-type: none"> Aula explicativa, Atividade prática 	<ul style="list-style-type: none"> Slides interativos Conjunto de dados ▲ Videoaulas 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle Google Drive Google Teachable Machine ▲ LevelUP (Moodle) 	<ul style="list-style-type: none"> Avaliação baseada em desempenho - conjunto de dados (Rubrica C1-C3) 		
4	Treinamento do modelo	1h	OA4, OA5	<ul style="list-style-type: none"> Processo de desenvolvimento de ML centrado no ser humano (Treinamento e predição) 	<ul style="list-style-type: none"> Aprendizagem ativa; Aprendizagem baseada em problemas 	<ul style="list-style-type: none"> Aula explicativa, Atividade prática 	<ul style="list-style-type: none"> Slides interativos Conjunto de dados ▲ Videoaulas 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle Google Drive Google Teachable Machine ▲ LevelUP (Moodle) 	<ul style="list-style-type: none"> Avaliação baseada em desempenho - treinamento do modelo (Rubrica C4) e avaliação (Rubrica C5-C12) 		
5	Processo de ML	1h	OA1- OA4	<ul style="list-style-type: none"> Revisão dos conceitos e do processo de ML 	<ul style="list-style-type: none"> Aprendizagem ativa; 	<ul style="list-style-type: none"> Aula explicativa, Discussão 	<ul style="list-style-type: none"> Slides interativos ▲ Videoaulas 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle ▲ LevelUP (Moodle) 			
6	Questões éticas e oportunidades	1h	OA1, OA6	<ul style="list-style-type: none"> Questões éticas com relação à IA/ML (riscos e impactos) Oportunidades de trabalho 	<ul style="list-style-type: none"> Aprendizagem ativa; Aprendizagem baseada em problemas ●/▲ Aprendizagem baseada em jogos 	<ul style="list-style-type: none"> Aula explicativa Discussão Atividade prática, ▲ Atividade desconectada 	<ul style="list-style-type: none"> Slides interativos Vídeo ▲ Videoaulas ▲ Jogo de Carta Dilema IA 	<ul style="list-style-type: none"> Google Meet Plataforma Moodle MIT Moral Machine ▲ LevelUP (Moodle) 			

Fonte: elaborado pelo autor.

5 APLICAÇÃO DO CURSO "ML PARA TODOS!"

O curso "ML para todos!" foi aplicado em 7 casos na prática, entre 2021 e 2023 com 338 estudantes do Ensino Fundamental e Médio com idades entre 12 e 19 anos de diferentes origens socioeconômicas. Nesta pesquisa, os estudantes foram categorizados com base em seus contextos socioeconômico como estudantes em situação de vulnerabilidade social (reconhecidos com base em avaliações de especialistas) ou em um contexto socioeconômico geral. Os estudantes, em um contexto geral, são estudantes de todas as origens socioeconômicas e não reconhecidos como em vulnerabilidade social (por especialistas).

O curso foi aplicado em diferentes modos instrucionais, desde aulas presenciais e aulas remotas com instrutores até autoaprendizagem remota.

Em todas as aplicações o consentimento para a participação dos estudantes foi obtido, e os estudantes enviaram voluntariamente seus resultados de aprendizagem e *feedback*.

Para o contexto geral, o curso "ML para todos!" foi aplicado em 5 casos na prática (AP1–AP5), entre 2021 e 2022 com 108 estudantes do Ensino Fundamental e Médio com idades entre 12 e 18 anos. Para o contexto de vulnerabilidade social, foi aplicado em 2 casos na prática (AP6) em 2022 e (AP7) em 2023, com 230 estudantes do Ensino Fundamental e Médio com idades entre 14 e 19 anos.

Uma visão geral das aplicações do curso "ML para todos!" é apresentado na Tabela 3.

Tabela 3 – Visão geral das aplicações do curso "ML para todos!"

Contexto socioeconômico	Aplicação	Data	Instituição	Modo instrucional	Tipo instrucional	Idade	Etapa educacional	Nº de estud antes
Geral	AP1	Setembro 2021	Escola Básica Municipal. Dilma Lúcia dos Santos	Híbrido	Como parte das aulas	15-16 anos	Ensino Fundamental	12
Geral	AP2	Outubro 2021	Instituto Federal Catarinense (IFC)	Remoto no ritmo do instrutor	Extracurricular	15-17 anos	Ensino Fundamental e Médio	10
Geral	AP3	Novembro 2021	Aberto a quaisquer estudantes interessado, organizado pela Universidade Federal de Santa Catarina (UFSC)	Remoto no ritmo do instrutor	Extracurricular	12-18 anos	Ensino Fundamental	35
Geral	AP4	Março 2022	Aberto a quaisquer estudantes interessado, organizado pela Universidade Federal de Santa Catarina (UFSC)	Remoto no ritmo do instrutor	Extracurricular	14-18 anos	Ensino Fundamental	40
Geral	AP5	-	Remotamente via site	Remoto em ritmo próprio	Extracurricular	≤ 18 anos	Ensino Fundamental	11
Vulnerabilidade social	AP6	Setembro 2022-Outubro 2022	Programa PodeCrer/Instituto Pe. Vilson Groh	Híbrido	Extracurricular	14-19 anos	Ensino Fundamental e Médio	158
Vulnerabilidade social	AP7	Agosto 2023-Setembro 2023	Programa PodeCrer/Instituto Pe. Vilson Groh	Híbrido	Extracurricular	14-19 anos	Ensino Fundamental e Médio	72
Total Geral								108
Total Vulnerabilidade social								230
TOTAL								338

Fonte: elaborado pelo autor

Distribuição demográfica

Considerando todas as aplicações do curso (AP1–AP7), a participação teve certo equilíbrio com relação ao sexo atribuído ao nascimento e etapa educacional.

Nas aplicações para um contexto geral (AP1–AP4), mais da metade (~65%) era do sexo atribuído ao nascimento masculino (Tabela 4). A maioria (71.3%) dos participantes eram estudantes do Ensino Médio, com estudantes com mais de 15 anos. Na aplicação AP2, dois estudantes de 12 e 13 anos com conhecimento básico de dispositivos tecnológicos e curiosidade no assunto participaram do curso. Dos estudantes do contexto geral, mais de 80% dos participantes estavam matriculados na rede pública de ensino brasileira. As informações sobre sexo atribuído ao nascimento não foram coletadas como parte da AP5, contudo nessa aplicação via site, seis estudantes eram do Ensino Fundamental, enquanto cinco estudantes eram do Ensino Médio.

Nas aplicações para o contexto de vulnerabilidade social (AP6 e AP7) a participação foi equilibrada com relação ao sexo atribuído ao nascimento, com 53% dos estudantes do sexo feminino e ~47% dos estudantes do sexo masculino. A participação também foi equilibrada em termos de etapa educacional, com 52.1% estudantes com idade menor ou igual a 15 anos do Ensino Fundamental e 47.8% com mais de 15 anos, do Ensino Médio (Tabela 4).

Nesse contexto, um total de 74.3% dos participantes estavam matriculados na rede pública de ensino brasileira, os demais recebiam bolsas para frequentar escolas particulares. Ainda do contexto de vulnerabilidade social, nove estudantes imigrantes também participaram, entre eles seis de língua espanhola e três de língua francesa/crioula, todos com bom entendimento do português brasileiro.

Tabela 4 – Distribuição demográfica dos estudantes

Contexto socioeconômico	Aplicação	Sexo atribuído ao nascimento (% por aplicação)		Etapa educacional (% por aplicação)	
		Feminino	Masculino	Ensino Fundamental (≤ 15 anos)	Ensino Médio (>15 anos)
Geral	AP1	3 (25.00%)	9 (75.00%)	9 (75.00%)	3 (25.00%)
Geral	AP2	6 (60.00%)	4 (40.00%)	1 (10.00%)	9 (90.00%)
Geral	AP3	9 (25.71%)	26 (74.29%)	9 (25.71%)	26 (74.29%)
Geral	AP4	16 (40.00%)	24 (60.00%)	6 (15.00%)	34 (85.00%)
Geral	AP5	-	-	6 (54.55%)	5 (45.45%)
Vulnerabilidade social	AP6	77 (48.73%)	81 (51.27%)	63 (39.87%)	95 (60.13%)
Vulnerabilidade social	AP7	45 (62.5%)	27 (37.5%)	57 (79.17%)	15 (20.83%)
Total Geral		34 (35.05%)	63 (64.94%)	31 (28.7%)	77 (71.3%)
Total Vulnerabilidade social		122 (53.04%)	108 (46.96%)	120 (52.17%)	110 (47.83%)
TOTAL		156 (46.1%)	171 (50.5%)	151 (44.6%)	187 (55.3%)

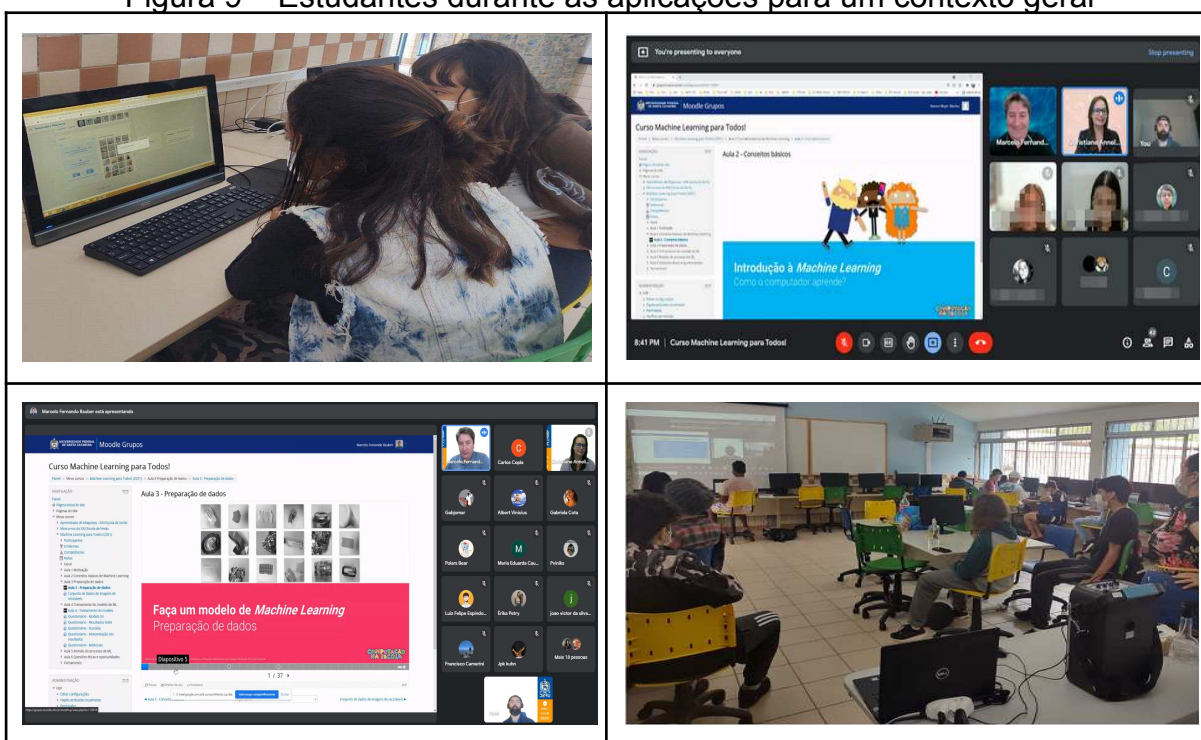
Fonte: elaborado pelo autor

Aplicações do curso para estudantes de um contexto socioeconômico geral

As aplicações para os estudantes, em um contexto geral, contemplaram estudantes de todas as origens socioeconômicas e não reconhecidos como em vulnerabilidade social por especialistas (Figura 9). Das aplicações, com exceção de uma aplicação (AP1) em uma escola de Ensino Fundamental na qual o curso foi aplicado como parte das aulas escolares, todas as outras aplicações foram realizadas como atividades extracurriculares.

O curso foi aplicado em diferentes modos instrucionais, desde aula híbrida (AP1), aulas remotas (no ritmo dos instrutores) (AP2–AP4) até remoto assíncrono (no ritmo do estudante) (AP5). A aplicação (AP1) foi ministrada por um instrutor presencialmente (com suporte remoto de um instrutor com experiência em *ML* da iniciativa CnE/UFSC), adicionalmente nesta aplicação, um professor da escola atuou como assistente. As atividades da AP1 foram realizadas no laboratório de computação da escola com instrutor via Google Meet. As aplicações remotas no ritmo do instrutor (AP2–AP4) foram ministradas online via Google Meet por dois instrutores com experiência em *ML*, da iniciativa CnE/UFSC. Nas aplicações (AP1–AP4) os instrutores ensinaram os conceitos básicos de *ML* em aulas online, enquanto as atividades práticas foram executadas individualmente pelos estudantes, com os instrutores disponíveis online para responder às perguntas e ajudar a resolver eventuais dúvidas e problemas. A aplicação (AP5) foi executada de forma autônoma e assíncrona pelos estudantes por meio do site da iniciativa CnE.

Figura 9 – Estudantes durante as aplicações para um contexto geral



Fonte: elaborado pelo autor

Imagens em conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD) do Brasil.

Aplicação do curso para estudantes em um contexto de vulnerabilidade social

Os estudantes participantes nesta aplicação são reconhecidos como em situação de vulnerabilidade social a partir de uma extensa avaliação dos especialistas em assistência social e pedagogia do Programa PodeCrer do Instituto Vilson Groh (IVG, 2022) (Figura 10). O programa PodeCrer atua diretamente com estudantes em situação de vulnerabilidade social promovendo justiça social com habilidades como tecnologia (IVG, 2022). O curso fez parte de uma parceria com o Programa PodeCrer do Instituto Vilson Groh (IVG, 2022), com vistas à aproximação desses estudantes com o ecossistema de inovação e tecnologia, e a iniciativa CnE/UFSC (CnE, 2024a), com enfoque em facilitar o ensino de computação para esses estudantes.

Nesse cenário, o curso foi aplicado como uma atividade extracurricular com uma aula por semana. Cada aula tinha duração de 2 horas por semana, totalizando quatro encontros, com 8 horas de curso no total por turma.


As aulas na aplicação (AP6) realizada em 2022 e (AP7) realizada em 2023, eram ministradas quatro vezes ao dia, duas no turno matutino e duas no turno vespertino. Um total de 10 turmas realizaram o curso na AP6 (158 estudantes) e 4 turmas na AP7 (72 estudantes), somando 112 horas de aplicações do curso.

O modo instrucional adotado para esse contexto, foi híbrido. Para a aplicação realizada em 2022 (AP6) um instrutor da iniciativa CnE/UFSC estava disponível remotamente (por meio do Google Meet), explicando os conceitos básicos de *ML* e as atividades, e um presencial prestando assistência. Para a aplicação realizada em 2023 (AP7), foram adotadas algumas estratégias alternativas para o ensino. Nessa aplicação, o ensino e a explicação das atividades foram explanadas via videoaulas (hospedadas no YouTube/Moodle), enquanto dois instrutores (com experiência em *ML*) estavam presentes prestando assistência.

Em ambas aplicações, um instrutor do Programa PodeCrer/IVG estava presente para organizar as salas de aula, e havia também monitores (estudantes que já haviam realizado o curso anteriormente e se destacaram), atuando como "tutores de pares".

As aulas foram realizadas nos laboratórios informatizados do IVG, com capacidade para 25 estudantes por turma, equipados com um computador e *headset* por estudante. Os laboratórios foram previamente testados e verificados pelos instrutores da CnE/UFSC antes da aplicação do curso, por meio de um *checklist* de ambiente técnico (Anexo A).

Figura 10 – Estudantes nas aplicações no Programa PodeCrer/IVG



Fonte: elaborado pelo autor

Imagens em conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD) do Brasil

6 AVALIAÇÃO DO MODELO INSTRUCIONAL DO CURSO "ML PARA TODOS!"

O objetivo da avaliação é analisar a qualidade do modelo instrucional, com as estratégias recomendadas para o ensino de *ML* em termos de aprendizado dos estudantes e da experiência de aprendizado por meio de uma série de estudos de caso/quase-experimento do curso "ML para todos!".

6.1 DEFINIÇÃO DA AVALIAÇÃO

Esta pesquisa tem como objetivo responder à pergunta de pesquisa: Como ensinar *Machine Learning* para o contexto de estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio de forma eficaz para possibilitar a aprendizagem de conceitos básicos de *ML* e, ao mesmo tempo, de forma motivadora e que promova uma boa experiência de aprendizagem?

Com base nesse objetivo, são derivadas as seguintes questões de pesquisa (QP) e hipóteses de pesquisas (H_0 - hipótese nula e H_a - hipótese alternativa):

QP 1. Aprendizagem de conceitos básicos de *ML*: Os estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social conseguem atingir os objetivos de aprendizagem referente aos conceitos básicos de *ML* com base no modelo instrucional?

- **QP1.1.** *Os estudantes atingiram os objetivos de aprendizagem?*
- **QP1.2.** *Há alguma diferença nos resultados de aprendizagem desses estudantes com relação ao sexo atribuído ao nascimento e etapa educacional?*
 - H_0 1.2. Não há diferenças significativas nos resultados de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento e à etapa educacional.
 - H_a 1.2. Existem diferenças significativas nos resultados de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento e à etapa educacional.
- **QP 1.3.** *Há alguma diferença nos resultados de aprendizagem desses estudantes com relação à estudantes em um contexto geral (não reconhecidos como de vulnerabilidade social)?*
 - H_0 1.3. Não há diferenças significativas nos resultados de aprendizagem entre estudantes em situação de vulnerabilidade social e estudantes em um contexto geral.

- $H_a1.3$. Existem diferenças significativas nos resultados de aprendizagem entre estudantes em situação de vulnerabilidade social e estudantes em um contexto geral.
- **QP 1.4.** *Há alguma diferença nos resultados de aprendizagem desses estudantes com relação à aplicação do curso com estratégias alternativas para o ensino?*
 - $H_01.4$. As estratégias alternativas para o ensino aplicadas ao curso não resultaram em diferenças significativas na aprendizagem dos estudantes.
 - $H_a1.4$. As estratégias alternativas para o ensino aplicadas ao curso resultaram em diferenças significativas na aprendizagem dos estudantes.

QP 2. Experiência de aprendizagem dos estudantes em vulnerabilidade social:

Os estudantes dos anos finais do Ensino Fundamental e Ensino Médio em situação de vulnerabilidade social tiveram uma boa experiência de aprendizagem?

- **QP 2.1.** *Os estudantes tiveram uma boa experiência de aprendizagem?*
- **QP 2.2.** *Há alguma diferença nos resultados de experiência de aprendizagem desses estudantes com relação ao sexo atribuído ao nascimento e à etapa educacional?*
 - $H_02.2$. Não há diferenças significativas nos resultados da experiência de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento e à etapa educacional.
 - $H_a2.2$. Existem diferenças significativas nos resultados da experiência de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento e à etapa educacional.
- **QP 2.3.** *Há alguma diferença nos resultados de experiência de aprendizagem desses estudantes com relação à estudantes em um contexto geral (não reconhecidos como de vulnerabilidade social)?*
 - $H_02.3$. Não há diferenças significativas na experiência de aprendizagem entre estudantes em situação de vulnerabilidade social e estudantes em um contexto geral.
 - $H_a2.3$. Existem diferenças significativas na experiência de aprendizagem entre estudantes em situação de vulnerabilidade social e estudantes em um contexto geral.
- **QP 2.4.** *Há alguma diferença na experiência de aprendizagem com as estratégias alternativas para o ensino aplicadas no curso?*
 - $H_02.4$. As estratégias alternativas para o ensino aplicadas no curso não resultaram em diferenças significativas na experiência de aprendizagem dos estudantes.
 - $H_a2.4$. As estratégias alternativas para o ensino aplicadas no curso resultaram em diferenças significativas na experiência de aprendizagem dos estudantes.

- **QP 3. Quais foram os desafios e soluções de mitigação no ensino de *ML* para estudantes dos anos finais do Ensino Fundamental e Médio no contexto de vulnerabilidade social?**

6.2 COLETA DE DADOS

Conforme definido foram coletados os dados durante e ao final do curso.

Durante a aplicação do curso — Os resultados de aprendizagem criados pelos estudantes são coletados. Nesta pesquisa, "resultados de aprendizagem" referem-se especificamente à capacidade dos estudantes de aplicar conceitos básicos de *ML* para desenvolver um modelo de *ML*. Adotando uma abordagem de avaliação baseada em desempenho, esses resultados de aprendizagem são avaliados usando a rubrica de pontuação proposta por Gresse von Wangenheim et al. (2022) e Rauber et al. (2023). Em estudos anteriores, essa rubrica foi validada por meio de avaliação de especialistas e testes empíricos com 240 estudantes de diversos contextos socioeconômicos, demonstrando boa confiabilidade (Ômega de McDonald $\omega = 0.834$; alfa de Cronbach $\alpha = 0.83$) e validade de consistência interna (Rauber et al., 2023). O processo de avaliação é automatizado usando a ferramenta online "CodeMaster - estágio de uso" (CnE, 2024b), garantindo um processo de avaliação consistente e eficiente (Rauber et al., 2023; Gresse von Wangenheim, 2022). Assim, o resultado de aprendizagem é aqui expresso por meio da pontuação do estudante fornecida pela ferramenta CodeMaster.

Ao final do curso — Foram coletados dados por meio de questionários sobre a percepção de aprendizado e percepção de experiência de aprendizado dos estudantes. Esse questionário é baseado nas questões definidas a partir do modelo dTECT (Gresse von Wangenheim et al., 2017), incluindo itens que medem vários fatores de qualidade da percepção do estudante sobre o aprendizado e as experiências como autoconfiança, prazer e qualidade geral do curso. O modelo dTECT demonstrou confiabilidade aceitável (alfa de Cronbach $\alpha = 0.787$) e validade de construto (Gresse von Wangenheim et al., 2017).

Durante e após as aulas do curso — Foram coletados dados por meio de observações de instrutores da CnE/UFSC. Essas observações visam um diagnóstico do perfil, comportamento, características de desempenho dos estudantes e turmas. Visam uma compreensão das limitações e necessidades, bem como ponto de

partida para intervenções pontuais e soluções de mitigação. Além disso, servem como autoavaliação e reflexão dos próprios instrutores. Uma visão geral da coleta de dados é apresentada no Quadro 31.

Quadro 31 – Coleta de dados

Questões de Pesquisa	Com base em	Instrumento para coleta de dados	Fator de qualidade	Itens de coleta de dados	Escala de resposta
QP1	Resultados de aprendizagem OA3–OA5	Rubrica de pontuação da avaliação baseada em desempenho (CodeMaster) Critérios C1–C12	Aprendizagem	Conjunto de dados Modelo .tm (GTM) Relatório reportado pelo estudante: <ul style="list-style-type: none"> • Análise e interpretação de acurácia • Análise e interpretação da matriz de confusão • Ajustes e melhorias • Testes 	Escala ordinal de 4 pontos (0-3)
	Percepção de aprendizagem	Questionário de feedback pós-curso (baseado no modelo dTECT)	Aprendizagem / Autoconfiança	Eu entendo o que é <i>ML</i> Posso aprender a criar soluções com IA/ <i>ML</i> ? Posso desenvolver um modelo de <i>ML</i> para reconhecimento de imagens Desenvolver um modelo de <i>ML</i> é Posso explicar a um amigo o que é <i>ML</i>	Sim, não Sim, não Sim, não Escala ordinal de 5 pontos • Muito fácil/ Fácil/ Mais ou menos/ Difícil/ Muito difícil Sim, não
QP2	Percepção de experiência de aprendizagem	Questionário de feedback pós-curso (baseado no modelo dTECT)	Satisfação	O curso foi?	Escala ordinal de 5 pontos • Muito divertido/ Divertido/ Mais ou menos/ Chato/ Muito chato
				O curso foi?	Escala ordinal de 5 pontos • Muito fácil/ Fácil/ Mais ou menos/ Difícil/ Muito difícil
				O tempo das aulas passou?	Escala ordinal de 5 pontos • Muito rápido/ Rápido/ Mais ou menos/ Devagar/ Muito devagar
			Qualidade geral do curso	Quero aprender mais sobre o <i>ML</i>	Sim, não
				No geral, o curso foi bom?	Escala ordinal de 4 pontos • Excelente/ Bom/ Regular/ Ruim
			Motivação	O que você mais gostou no curso de <i>ML</i> ?	Texto livre
				O que você menos gostou no curso de <i>ML</i> ?	Texto livre
				Algun outro comentário?	Texto livre
QP3	Desafios e soluções de mitigação	Observações dos instrutores		Observações sobre características dos estudantes e turmas, limitações e necessidades identificadas, soluções de mitigação.	Texto livre

Fonte: elaborado pelo autor

A quantidade de dados coletados é apresentada nas Tabelas 5 e 6. Na Tabela 5 é apresentada a quantidade de dados coletados nas aplicações para o contexto geral (AP1–AP4) e seus demográficos, que servirão de comparação para responder às questões de pesquisa QP1.3 e QP 2.3. Na Tabela 6 é apresentada a quantidade de dados coletados dos estudantes no contexto de vulnerabilidade social (AP6 e AP7) e seus demográficos, os quais são a base para a questão de pesquisa principal.

Nem todos os estudantes submeteram seus dados. Isso se deve a vários fatores como o tempo, faltas, motivação, atenção a outras atividades, além de outros fatores como responsabilidade e interesse. No caso dos estudantes em situação de vulnerabilidade social, os fatores podem ainda estar atrelados às questões do seu contexto. Alguns exemplos incluem faltas devido ao transporte público, motivação reduzida em dias estressantes decorrente de situações familiares sensíveis e dependência apenas do tempo do curso para conclusão de suas atividades.

Tabela 5 – Quantidade de dados coletados – contexto geral

Origem socioeconômica	Grupo	Avaliação baseada em desempenho (número de artefatos por critério da avaliação C1–C12)												% média de coleta	Questionários (n)	% média de coleta
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12			
Geral	Todos	62	62	62	62	67	67	65	65	70	70	70	70	~66%	93	86%
Aplicação do curso	AP1	8	8	8	8	6	6	5	5	5	6	6	6	~53%	11	91.6%
	AP2	5	5	5	5	8	8	8	8	8	9	9	9	~72%	7	70%
	AP3	24	24	24	24	26	26	25	25	31	30	30	30	~76%	30	85.7%
	AP4	25	25	25	25	27	27	27	27	26	25	25	25	~64%	34	85%
	AP5	-	-	-	-	-	-	-	-	-	-	-	-	-	11	100%
Sexo atribuído ao nascimento	Feminino	17	17	17	17	19	19	19	19	19	20	20	20	~55%	29	85.2%
	Masculino	45	45	45	45	48	48	46	46	51	50	50	50	~75%	53	84.1%
Etapa Educacional	Ensino Fundamental (≤ 15 anos)	18	18	18	18	19	19	17	17	18	19	19	19	~59%	28	90.3%
	Ensino Médio (>15 anos)	44	44	44	44	48	48	48	48	52	51	51	51	~62%	64	83.1%

Fonte: elaborado pelo autor

Tabela 6 – Quantidade de dados coletados – contexto de vulnerabilidade social

Origem socioeconômica	Grupo	Avaliação baseada em desempenho (número de artefatos por critério da avaliação C1–C12)												% média de coleta	Questionários (n)	% média de coleta
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12			
Contexto de vulnerabilidade social	Todos	134	134	134	134	126	126	122	122	117	118	118	118	~54%	178	77.3%
Aplicação do curso	AP6	79	79	79	79	74	74	73	73	75	73	73	73	~48%	122	77.2%
	AP7	55	55	55	55	52	52	49	49	42	45	45	45	~70%	56	77.7%
Sexo atribuído ao nascimento	Feminino	68	68	68	68	63	63	60	60	56	56	56	56	~51%	102	83.6%
	Masculino	66	66	66	66	63	63	62	62	61	62	62	62	~59%	76	70.3%
Etapa Educacional	Ensino Fundamental (≤ 15 anos)	67	67	67	67	64	64	63	63	58	57	57	57	~53%	89	74.1%
	Ensino Médio (>15 anos)	67	67	67	67	62	62	59	59	59	61	61	61	~57%	89	80.9%

Fonte: elaborado pelo autor

Na Tabela 7 é apresentada a quantidade de estudantes observados, bem como a carga horária total de observação pelos instrutores da CnE/UFSC.

Tabela 7 – Observações dos instrutores

Origem socioeconômica	Grupo	Observações	No. de estudantes observados	Carga horária total de todas as turmas e aplicações
Geral	Todos AP1–AP4	Anotações informais durante e após as aulas. Características das aplicações quanto às limitações e necessidades identificadas e soluções de mitigação.	108	40 horas
Contexto de vulnerabilidade de social	Todos AP6 e AP7	Anotações informais durante e após as aulas. Características dos estudantes, turmas e aplicações quanto às limitações e necessidades identificadas e soluções de mitigação.	230 (10 turmas em 2022 e 4 turmas em 2023)	112 horas

Fonte: elaborado pelo autor

6.3 ANÁLISE E INTERPRETAÇÃO DOS DADOS COLETADOS

Os dados coletados na forma de artefatos criados pelos estudantes como resultados de aprendizagem foram avaliados automaticamente usando a ferramenta CodeMaster (Rauber et al., 2023). As avaliações realizadas por essa ferramenta, assim como as respostas do questionário relativas às percepções dos estudantes, foram documentadas em planilhas e, posteriormente, tabuladas.

Os resultados de aprendizagem e percepções foram então organizados e analisados usando a linguagem R (RStudio) e a ferramenta G*Power (versão 3.1). Foi realizada uma análise em dois níveis com estatísticas descritivas e inferenciais. Inicialmente, as estatísticas descritivas foram usadas para compreender, capturar características dos dados e analisar diferenças substanciais. Essas estatísticas incluíram assimetria, coeficiente de variação (CV), curtose, desvio padrão, frequência absoluta, função de densidade de probabilidade, intervalo interquartil (IQR), média, mediana e quartis.

Em um segundo nível, envolveu estatísticas inferenciais para analisar as características mais complexas dos dados e identificar diferenças significativas, baseando-se em testes de hipóteses previamente formuladas. Todos testes estatísticos, operam sob a premissa da hipótese nula (H_0), que postula a ausência de efeito ou diferença estatística significativa, conforme o contexto específico do teste. A hipótese alternativa (H_a), por sua vez, propõe a existência de um efeito ou diferença estatisticamente significativa (Field, 2018; Spiegel e Stephens, 2008). O objetivo dos testes é determinar se há evidências suficientes nos dados coletados para rejeitar a hipótese nula em favor da hipótese alternativa. O nível de significância adotado foi de 0.05, um valor comumente usado em pesquisas científicas, indicando

que um p -valor inferior a 0.05 indica uma diferença estatisticamente significativa, enquanto um p -valor superior a 0.05 sugere que a diferença não é significativa (Spiegel e Stephens, 2008).

Adicionalmente, análises de potência estatística e cálculos de tamanho de efeito, usando a ferramenta G*Power, foram realizados para determinar a capacidade do estudo de detectar diferenças significativas, garantindo a robustez dos resultados (Cohen, 1988).

Das análises dos resultados de aprendizagem — Inicialmente a normalidade da distribuição dos dados foi avaliada usando o teste de Shapiro-Wilk (Shapiro e Wilk, 1965). Para identificar diferenças estatísticas entre os grupos, o teste Mann-Whitney U foi usado, quando as amostras não seguiram uma distribuição normal (Mann e Whitney, 1947). Quando uma diferença significativa é encontrada, é calculada a estimativa " d de Cohen", uma análise de efeito prático que permite compreender a magnitude da diferença estatística (Cohen, 1988). Adicionalmente, para analisar critérios específicos dos resultados da avaliação baseada em desempenho, entre diferentes grupos, o Teste Exato de Fisher (Fisher, 1922) foi aplicado. Em complemento a esse teste, a correção de Bonferroni foi empregada para ajustar comparações múltiplas, garantindo a integridade dos testes estatísticos ao controlar a taxa de erro do tipo I em um contexto de múltiplas análises (Field, 2018). Para os critérios em que diferenças significativas foram encontradas após a correção de Bonferroni, o valor " V de Cramer" foi calculado para indicar o tamanho do efeito da diferença estatística (Field, 2018; Cohen, 1988).

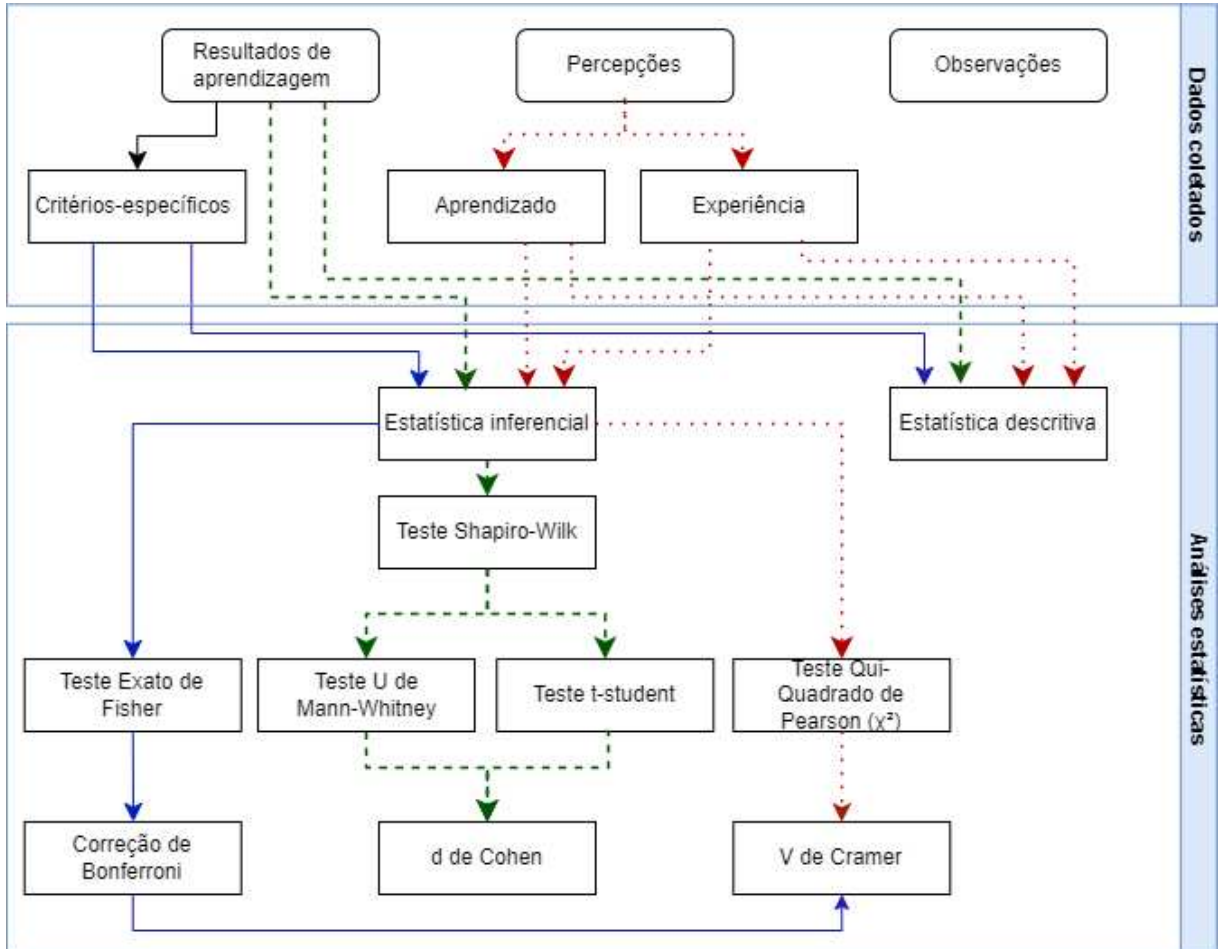
Das análises das percepções dos estudantes — O teste Qui-quadrado de Pearson (χ^2) com correção de continuidade de Yates foi aplicado para avaliar as comparações, seguindo diretrizes metodológicas de Spiegel e Stephens (2008). Quando uma diferença significativa é encontrada, o valor " V de Cramer" foi calculado para indicar o tamanho do efeito da diferença estatística (Field, 2018; Cohen, 1988).

Para todos os testes, os p -valores extremamente pequenos são representados resumidamente como $p < 0.001$, conforme convenção para reporte de resultados estatísticos da APA (2020).

Das observações dos instrutores — As anotações das observações dos instrutores foram organizadas e analisadas qualitativamente por meio da análise de conteúdo (Bardin, 2011). Esse método envolveu a leitura cuidadosa das anotações, a identificação de padrões e a organização para discussão.

Um diagrama de fluxo estatístico é apresentado na Figura 11 indicando a sequência de etapas para análises estatísticas por dados coletados.

Figura 11 – Diagrama de fluxo estatístico por dados coletados



Fonte: elaborado pelo autor

O método de pesquisa adotado pode ser considerado quase-experimental, pois os grupos são comparados em relação aos resultados de aprendizagem e percepções, embora as variáveis independentes não tenham sido diretamente manipuladas (Shadish et al., 2022).

Ao final, todos resultados são então analisados, interpretados e discutidos para somar evidências às conclusões das questões de pesquisa.

6.4 RESULTADOS

Esta seção apresenta os resultados das análises empíricas visando abordar as questões de pesquisa (QP) e as hipóteses. O foco está no efeito/impacto da situação de vulnerabilidade social sobre os resultados de aprendizagem, percepção

de aprendizagem e percepção de experiência de aprendizagem dos estudantes no curso "ML para todos!", bem como realizar comparações com fatores como origem socioeconômica, sexo atribuído ao nascimento e etapa educacional. Em seguida são realizadas as análises quanto ao efeito das estratégias alternativas para o ensino de ML empregados no curso na aplicação 7 em 2023, comparando a aprendizagem e percepções com a aplicação 6 em 2022. Adicionalmente, os desafios e soluções no ensino de ML para estudantes em um contexto de vulnerabilidade social são analisados.


6.4.1 Quais foram os resultados de aprendizagem de conceitos básicos de ML dos estudantes em vulnerabilidade social?

Os estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social conseguem atingir os objetivos de aprendizagem referente aos conceitos básicos de ML com base no modelo instrucional?

QP1.1. Os estudantes atingiram os objetivos de aprendizagem?

Análise descritiva — Os estudantes em situação de vulnerabilidade social obtiveram um desempenho satisfatório em relação aos objetivos de aprendizagem dos conceitos básicos de ML. A média de 7.2 e mediana de 7.5 indicam uma boa compreensão geral do conteúdo. O desvio padrão (=1.6) com variabilidade moderada e o intervalo interquartil (=1.5) sugerem consistência nos resultados da maioria dos estudantes (Quadro 32).

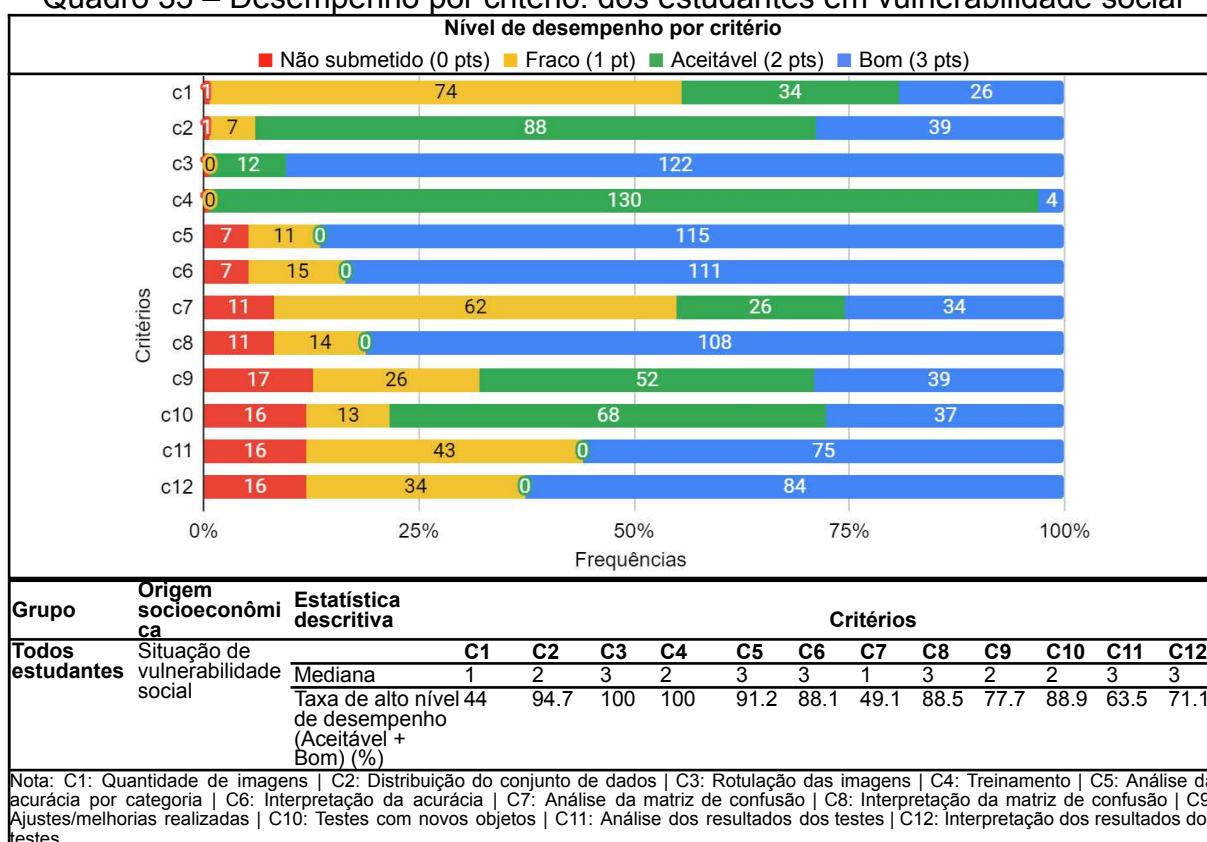
Quadro 32 – Desempenho dos estudantes em vulnerabilidade social



Fonte: elaborado pelo autor

Análise por critério específico — A fim de ter uma compreensão mais aprofundada dos resultados de aprendizagem, foi realizada uma análise por critério específico da avaliação baseada em desempenho (Quadro 33). Os critérios C3 (Rotulação de imagens) e C4 (Treinamento) se destacaram por ter 100% de taxa de alto nível de desempenho e medianas altas. Já os critérios C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão) apresentaram as menores medianas (=1) e menores taxas de alto nível de desempenho (44% e 49%), sugerindo maiores dificuldades dos estudantes nesses critérios.

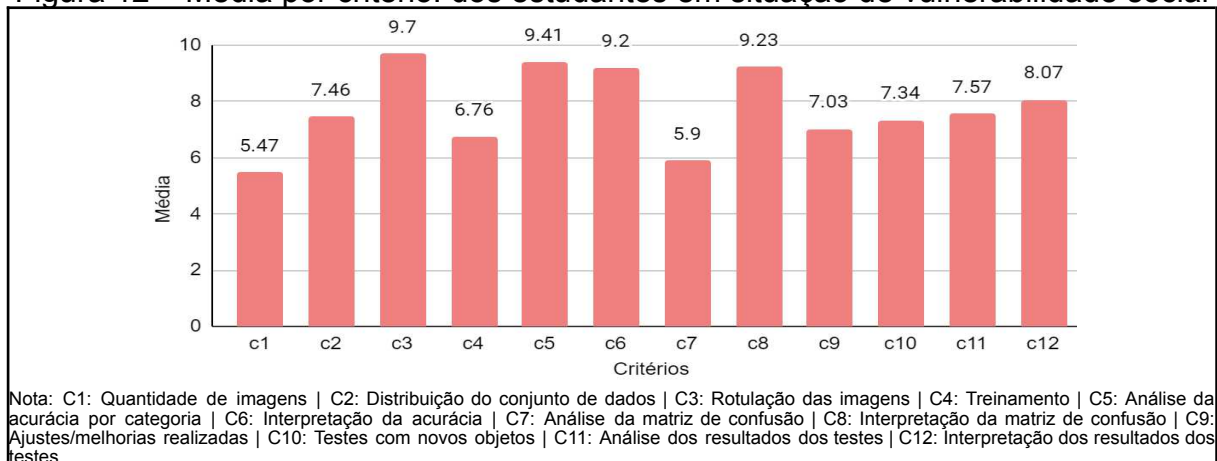
Quadro 33 – Desempenho por critério: dos estudantes em vulnerabilidade social



Fonte: elaborado pelo autor

Na média por critério da avaliação baseada em desempenho dos estudantes, os critérios C3 (Rotulação das imagens), C5 (Análise da acurácia por categoria), C6 (Interpretação da acurácia) e C8 (Interpretação da matriz de confusão) apontaram as maiores médias (>9 pontos) (Figura 12). Enquanto C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão) com médias abaixo de 6 pontos, se mostraram mais desafiadores aos estudantes.

Figura 12 – Média por critério: dos estudantes em situação de vulnerabilidade social



Fonte: elaborado pelo autor

Análise da percepção de aprendizado do estudante — A grande maioria dos estudantes em situação de vulnerabilidade social (87%) indicou que entendeu "o que é *ML*" (Quadro 34). Em destaque, apenas 4 estudantes responderam que não podem aprender a fazer soluções com IA/*ML*. Além disso, uma porção significativa dos estudantes (90.3%) respondeu que se sente capaz de desenvolver um modelo de *ML* para reconhecimento de imagens. Mais da metade dos estudantes (59%) considerou a dificuldade de desenvolver um modelo de *ML* como "mais ou menos", com apenas 5 estudantes considerando muito difícil. Por outro lado, cerca de 60% dos estudantes acham que conseguem explicar o que é *ML*.

Quadro 34 – Percepção de aprendizagem dos estudantes em vulnerabilidade social

Item	Frequência absoluta	
	Sim	Não
Eu entendi o que é <i>Machine Learning</i>	155	23
Eu posso aprender a fazer soluções com Inteligência Artificial/ <i>Machine Learning</i> ?	174	4
Eu consigo desenvolver um modelo de <i>Machine Learning</i> para reconhecimento de imagens	160	17
Desenvolver um modelo de <i>Machine Learning</i> é	■ Muito fácil ■ Fácil ■ Mais ou menos ■ Difícil ■ Muito difícil	
	5	35
	106	
	27	
	5	
Consigo explicar para um amigo(a) o que é <i>Machine Learning</i>	107	71


Fonte: elaborado pelo autor

QP1.2. Há alguma diferença nos resultados de aprendizagem desses estudantes com relação ao sexo atribuído ao nascimento e etapa educacional?

Quanto ao sexo atribuído ao nascimento, várias análises foram realizadas para comparar o desempenho dos estudantes femininos e masculinos em situação de vulnerabilidade social.

Análise descritiva — Os estudantes em situação de vulnerabilidade social apresentaram um desempenho semelhante quando comparados por sexo atribuído ao nascimento (Quadro 35). As médias das pontuações totais e medianas foram próximas entre estudantes do sexo feminino e masculino. Apesar das semelhanças nas medidas de tendência central, algumas leves diferenças foram observadas na variabilidade dos resultados. O desvio padrão foi ligeiramente maior para o sexo feminino (=1.72) em comparação com o masculino (=1.46).

Quadro 35 – Comparação do desempenho por sexo atribuído ao nascimento



Fonte: elaborado pelo autor

Análise inferencial — De modo a investigar os resultados da análise descritiva, foi realizada a análise inferencial (Tabela 8). O teste não paramétrico de Mann-Whitney U foi utilizado para investigar diferenças entre as pontuações médias dos dois grupos por sexo atribuído ao nascimento. Esse teste foi escolhido devido à sua adequação para amostras que não se aderem a uma distribuição normal (após o teste de Shapiro-Wilk). A potência estatística do estudo foi avaliada para capacidade de identificar diferenças significativas nos resultados de aprendizagem com base no sexo atribuído ao nascimento. Com um nível de confiança de 95% e um tamanho de efeito médio de 0.5, a potência do teste calculada foi de 80.4%. Isso está de acordo com o padrão para identificar diferenças estatísticas que deve ser idealmente de pelo menos 80% (Cohen, 1988). Os resultados do teste de Mann-Whitney U, portanto, não indicaram diferenças significativas entre os grupos ($U=2180$; $p=0.667$).

Consequentemente, as evidências iniciais não apoiam a hipótese alternativa ($H_a1.2$) de que "Existem diferenças significativas nos resultados de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento".

Tabela 8 – Análises inferenciais por sexo atribuído ao nascimento

Grupo	Origem socioeconômica	Teste estatístico	Valor estatístico	p-valor	Diferença (p > 0.05) ● Não significativa (p > 0.05) ▲ Significativa (p < 0.05)
Feminino	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.8449	< 0.001	-
Masculino	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.8604	< 0.001	-
	Comparação Feminino vs Masculino situação de vulnerabilidade social	Mann-Whitney U	U = 2180	0.667	●

Fonte: elaborado pelo autor

Análise por critério específico — Ao comparar as medianas por critério específico, observa-se não haver diferenças substanciais entre os grupos feminino e masculino nos critérios da avaliação baseada em desempenho (Tabela 9). Para os critérios C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão) a mediana é (=1) para ambos os grupos, revelando inicialmente um ponto de dificuldade para os dois grupos. Quanto às taxas de alto nível de desempenho (Aceitável + Bom) é destacada algumas diferenças, sendo a mais substancial em C1 com os estudantes femininos obtendo um desempenho superior (feminino: 51.4%, masculino: 37.8%).

Tabela 9 – Desempenho por critério da avaliação: por sexo atribuído ao nascimento

Grupo	Origem socioeconômica	Estatística descritiva	Critérios											
			C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
■ Feminino	Situação de vulnerabilidade social	Mediana	1	2	3	2	3	3	1	3	2	2	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom)(%)	51.4	91.1	100	100	95.2	90.4	53.3	85	73.2	87.5	62.5	67.5
■ Masculino	Situação de vulnerabilidade social	Mediana	1	2	3	2	3	3	1	3	2	2	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom)(%)	37.8	98.4	100	100	87.3	85.7	45.1	91.9	81.9	90.3	64.5	74.1

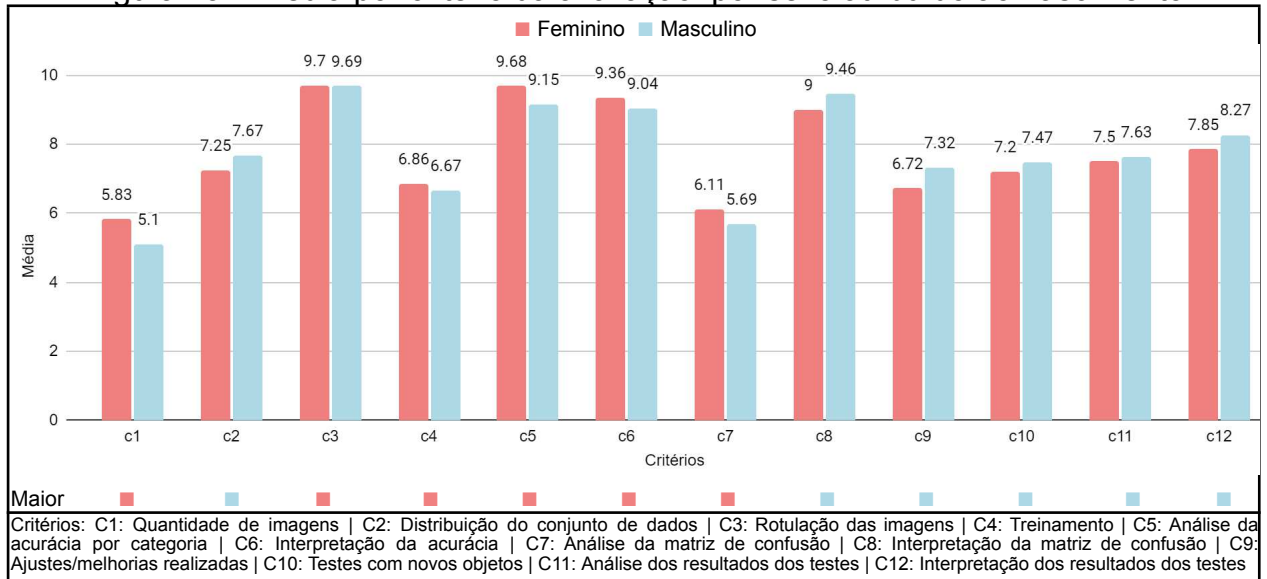
Critérios: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Na comparação das médias por critério, observa-se que as médias são muito próximas entre os grupos na maioria dos critérios (Figura 13). Os grupos se destacam nos critérios C3 (Rotulação das imagens), C5 (Análise da acurácia por categoria), C6 (Interpretação da acurácia) e C8 (Interpretação da matriz de confusão) com média (>9 pontos). Porém, com desempenho baixo (média < 6.1 pontos) em C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão). As maiores diferenças observáveis estão nos critérios C7 com médias ligeiramente

superiores para o grupo feminino (feminino: 6.03, masculino: 5.37) e C1 (feminino: 5.88, masculino: 5.37). E C8 com média superior para o grupo masculino (feminino: 9, masculino: 9.46).

Figura 13 – Média por critério da avaliação: por sexo atribuído ao nascimento



Fonte: elaborado pelo autor

Para avaliar a significância estatística das diferenças observadas nos critérios específicos da avaliação, foi realizado o Teste Exato de Fisher, com os *p*-valores ajustados por critério após a correção de Bonferroni (Quadro 36). Estas análises não revelaram diferenças significativas em nenhum dos critérios entre estudantes femininos e masculinos em situação de vulnerabilidade social (todos os *p*-valores ajustados > 0.05). Portanto, não rejeitamos a hipótese nula (H_0 1.2), que postula não haver diferenças significativas nos resultados de aprendizagem com base no sexo atribuído ao nascimento.

Quadro 36 – Análise por critério da avaliação: por sexo atribuído ao nascimento

		valores por critério											
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Grupo	Testes Estatísticos												
	Comparação Feminino vs Masculino situação de vulnerabilidade social	0.20	0.17	1.00	0.11	0.20	0.58	0.70	0.26	0.42	0.77	0.84	0.54
	Correção de Bonferroni (p-valor ajustado)	1	1	1	1	1	1	1	1	1	1	1	1

● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$) - p -valor = 0.05

Critérios: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Análise da percepção de aprendizado — De modo geral, a maioria dos estudantes de ambos os sexos relataram ter entendido o que é *ML*, se sentem capazes de aprender a fazer soluções com *IA/ML* e desenvolver um modelo de *ML*

para reconhecimento de imagens (Quadro 37). Além disso, a maioria dos estudantes de ambos os sexos (feminino: 61.22%, masculino: 60.24%) considerou a dificuldade de desenvolver um modelo de *ML* como "mais ou menos". Apesar da maioria apontar que conseguem explicar para um amigo o que é *ML*, uma porção relevante de estudantes femininos (37.25%) e masculinos (37.31%) acham que não.

Para verificar se há diferenças na percepção de aprendizagem entre os estudantes femininos e masculinos em situação de vulnerabilidade social foi realizado o teste Qui-quadrado (χ^2). Desse teste, com um nível de confiança de 95% e um tamanho de efeito de 0.3, considerado médio, a análise de potência *post hoc* revelou uma potência estatística de 97%. Isso indica que o estudo possui uma capacidade alta de detectar diferenças significativas. Assim, ao realizar o teste Qui-quadrado, os resultados indicam que não houve diferenças estatisticamente significativas entre estudantes femininos e masculinos em sua percepção de aprendizagem em todos os itens (todos os p -valores > 0.05). Esses achados indicam uma falha em rejeitar a hipótese nula (H_0 1.2) para todos os aspectos analisados que postula que "Não há diferenças significativas nos resultados de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento".

Quadro 37 – Percepção de aprendizagem por sexo atribuído ao nascimento

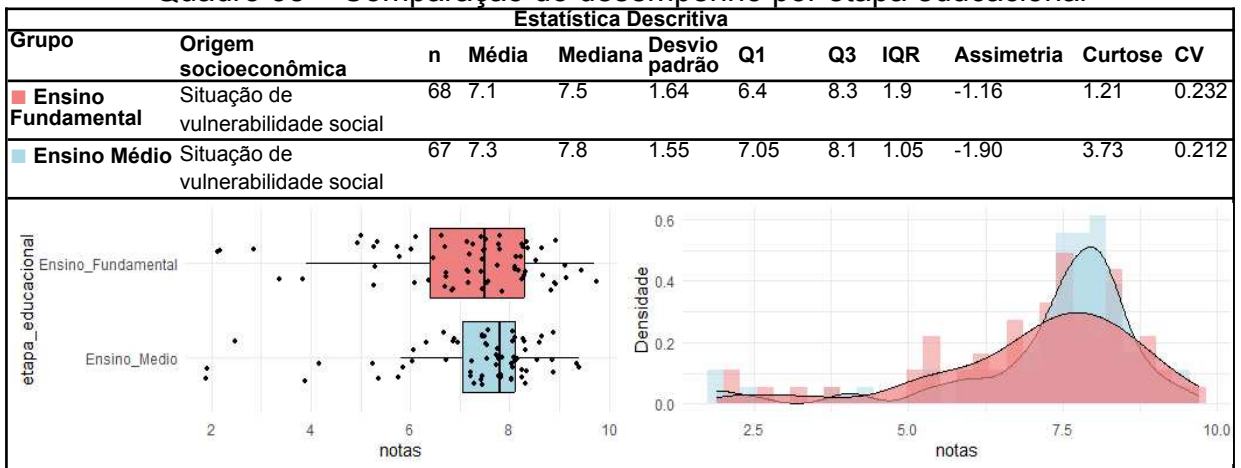
Item	Grupo	Frequência absoluta	Teste estatístico	p -valor	Diferença (● Não significativa ($p > 0.05$), ▲ Significativa ($p < 0.05$))
Eu entendi o que é <i>Machine Learning</i>	Feminino	Sim: 89, Não: 13	$\chi^2 < 0.001$	$p=1$	●
	Masculino	Sim: 66, Não: 10			
Eu posso aprender a fazer soluções com Inteligência Artificial/ <i>Machine Learning</i> ?	Feminino	Sim: 99, Não: 3	$\chi^2 = 0.045$	$p=0.83$	●
	Masculino	Sim: 75, Não: 1			
Eu consigo desenvolver um modelo de <i>Machine Learning</i> para reconhecimento de imagens	Feminino	Sim: 95, Não: 7	$\chi^2 = 1.4056$	$p=0.2385$	●
	Masculino	Sim: 65, Não: 10			
Desenvolver um modelo de <i>Machine Learning</i> é	Feminino	Muito fácil: 2, Fácil: 18, Mais ou menos: 63, Difícil: 16, Muito difícil: 3	$\chi^2 = 0.772$	$p=0.3794$	●
	Masculino	Muito fácil: 3, Fácil: 17, Mais ou menos: 43, Difícil: 11, Muito difícil: 2			
Consigo explicar para um amigo(a) o que é <i>Machine Learning</i>	Feminino	Sim: 63, Não: 39	$\chi^2 = 134537$	$p=0.71$	●
	Masculino	Sim: 44, Não: 32			

Fonte: elaborado pelo autor

Quanto à etapa educacional, o conjunto de análises também foram realizadas para comparar o desempenho dos estudantes do Ensino Fundamental e Médio em situação de vulnerabilidade social.

Análise descritiva — Os resultados indicam que o desempenho de aprendizagem, apesar de bastante similar entre estudantes do Ensino Fundamental e Médio em situação de vulnerabilidade social, teve ligeiras diferenças. A média é levemente maior para o grupo do Ensino Médio, enquanto as medidas de dispersão, apresentam variabilidade levemente maior no grupo do Ensino Fundamental (Quadro 38).

Quadro 38 – Comparação do desempenho por etapa educacional



Fonte: elaborado pelo autor

Análise inferencial — O teste não paramétrico de Mann-Whitney U foi utilizado para investigar diferenças entre as pontuações médias dos dois grupos por etapa educacional (Tabela 10). Esse teste foi escolhido devido à sua adequação para amostras que não aderiram a uma distribuição normal (após o teste de Shapiro-Wilk). A potência estatística do estudo foi avaliada. Com um nível de confiança de 95% e um tamanho de efeito médio de 0.5, a potência do teste calculada foi de 80.4%, considerado adequado para identificar diferenças estatísticas (Cohen, 1988). Os resultados do teste de Mann-Whitney U não indicaram diferenças significativas entre os grupos ($U=2069$; $p=0.3569$). Assim, as evidências iniciais não apoiam a hipótese alternativa (H_a 1.2) de que "Existem diferenças significativas nos resultados de aprendizagem dos estudantes em relação à etapa educacional".

Tabela 10 – Análises inferenciais por etapa educacional

Grupo	Origem socioeconômica	Teste estatístico	Valor estatístico	p-valor	Diferença ● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$)
Ensino Fundamental	Situação de vulnerabilidade social	Shapiro-Wilk	W =0.9040	< 0.001	-
Ensino Médio	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.7867	< 0.001	-
	Comparação Ensino Fundamental e Ensino Médio situação de vulnerabilidade social	Mann-Whitney U	U = 2069	0.3569	●

Fonte: elaborado pelo autor

Análise por critério específico — Os resultados sugerem que, embora o desempenho geral seja semelhante entre os grupos, existem algumas diferenças substanciais na mediana e taxa de alto nível (Aceitável+Bom) (Tabela 11). Em destaque, as diferenças estão principalmente nos critérios C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão), com o Ensino Médio apresentando melhor desempenho em C1, e o Ensino Fundamental em C7.

Tabela 11 – Desempenho por critério da avaliação: por etapa educacional

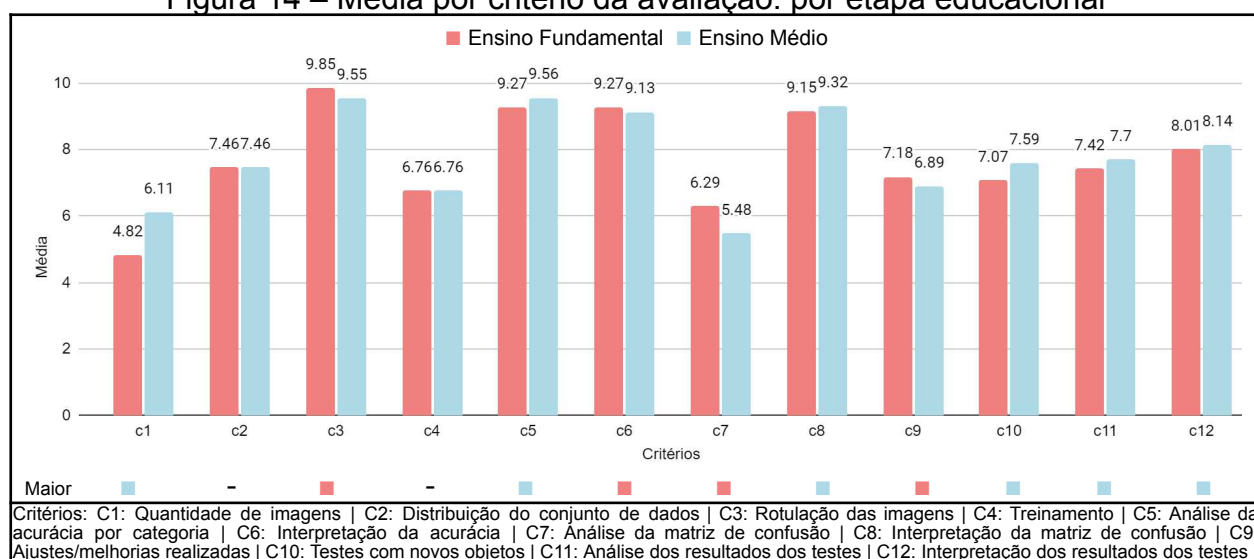
Grupo	Origem socioeconômica	Estatística descritiva	Critérios											
			C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Ensino Fundamental	Situação de vulnerabilidade social	Mediana	1	2	3	2	3	3	2	3	2	2	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom) (%)	34.3	97	100	100	89.1	89.1	55.6	87.3	79.3	84.2	61.4	70.2
Ensino Médio	Situação de vulnerabilidade social	Mediana	2	2	3	2	3	3	1	3	2	2	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom) (%)	55.2	92.5	100	100	93.5	87.1	42.4	89.8	76.3	93.4	65.6	72.1

Critérios: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Na comparação das médias por critério, observa-se que as médias são iguais ou muito próximas entre os grupos na maioria dos critérios (Figura 14). Os grupos se destacam nos critérios C3 (Rotulação das imagens), C5 (Análise da acurácia por categoria), C6 (Interpretação da acurácia) e C8 (Interpretação da matriz de confusão), com médias acima de 9 pontos. Porém, ambos apresentam desempenho baixo (média < 6.3 pontos) em C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão). Nesses critérios é encontrada as maiores diferenças observáveis: nos critérios C1, com média superior para o Ensino Médio (fundamental: 4.82, médio: 6.11), e C7, com média superior para o Ensino Fundamental (fundamental: 6.29, médio: 5.48).

Figura 14 – Média por critério da avaliação: por etapa educacional



Fonte: elaborado pelo autor

Para avaliar a significância estatística das diferenças observadas nos critérios específicos da avaliação, foi realizado o Teste Exato de Fisher, com os p -valores ajustados por critério após a correção de Bonferroni (Quadro 39). Esta análise revelou uma diferença significativa no critério C1 (Quantidade de imagens) ($p = 0.015$) antes da correção de Bonferroni. No entanto, após a correção, essa diferença não mostrou ser significativa (p -valor ajustado = 0.181). Para os demais critérios, não foram encontradas diferenças significativas entre estudantes do Ensino Fundamental e Médio em situação de vulnerabilidade social (todos os p -valores ajustados > 0.05). Dado que os p -valores ajustados para todos os critérios ficaram acima do limiar de significância de 0.05, não rejeitamos a hipótese nula (H_0), que postula não haver diferenças significativas nos resultados de aprendizagem com base na etapa educacional.

Quadro 39 – Análise por critério da avaliação: por etapa educacional

		p-valores por critério											
Grupo	Testes Estatísticos	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Comparação Ensino Fundamental vs Ensino Médio	Teste Exato de Fisher (p -valor)	0.015	0.40	0.12	1.0	0.53	0.78	0.29	0.77	0.81	0.28	0.70	0.84
	Correção de Bonferroni (p -valor ajustado)	0.181	1	1	1	1	1	1	1	1	1	1	1

● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$) - p -valor = 0.05

Critérios: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Análise da percepção de aprendizado — A maioria dos estudantes de ambas as etapas educacionais relataram ter entendido o que é *ML*, se sentem capazes de aprender a fazer soluções com *IA/ML* e desenvolver um modelo de *ML* para

reconhecimento de imagens (Quadro 40). Contudo, apesar da maioria dos estudantes de ambas as etapas apontarem que conseguem explicar para um amigo o que é *ML*, uma porção considerável de estudantes do Ensino Fundamental (48.31%) acham que não conseguem, enquanto essa porção é mais baixa entre os estudantes do Ensino Médio (31.46%).

Para verificar se há diferenças estatisticamente significativas na percepção de aprendizagem entre os estudantes do Ensino Fundamental e Médio em situação de vulnerabilidade social, foi realizado o teste Qui-quadrado (χ^2). Desse teste, para detectar diferenças significativas, com um nível de confiança de 95% e um tamanho de efeito de 0.3, considerado médio, a análise de potência *post hoc* revelou uma potência estatística alta de 97%, adequado conforme Cohen (1988). Os resultados indicam que houve diferenças significativas entre as etapas educacionais na percepção da dificuldade de desenvolver um modelo de *ML* ($\chi^2=7.255$; $p=0.007$) e na capacidade de explicar o que é *ML* para um amigo ($\chi^2=4.592$; $p=0.032$). Esses achados apoiam a hipótese alternativa ($H_a1.2$) apenas para esses dois itens, de que existem diferenças significativas na etapa educacional que afeta a percepção de aprendizagem dos estudantes. Para medir o tamanho do efeito dessas diferenças, foi calculado o "V de Cramer". Os resultados indicaram um tamanho de efeito pequeno entre a etapa educacional e a percepção de aprendizagem, com ($V=0.202$) para a dificuldade de desenvolver um modelo de *ML* e ($V=0.161$) para a capacidade de explicar o que é *ML* para um amigo. Por outro lado, não foram encontradas diferenças significativas nos demais itens de percepção de aprendizagem (todos os p -valores > 0.05).

Quadro 40 – Percepção de aprendizagem por etapa educacional

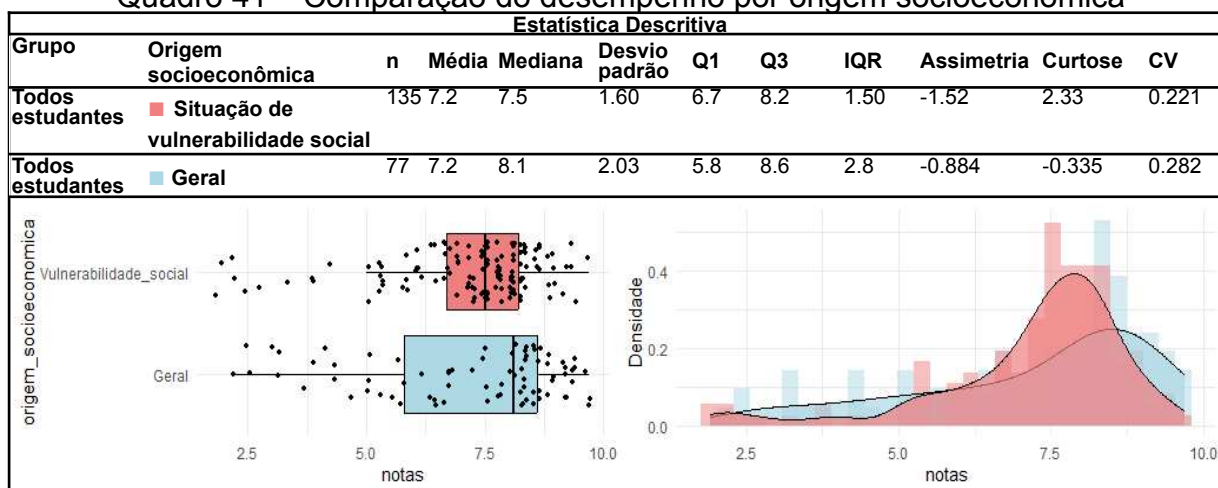
Item	Grupo	Frequência absoluta	Teste estatístico*	p-valor	Diferença significativa (p > 0.05) / Significativa (p < 0.05)	V de Cramer (Tamanho de efeito)
Eu entendi o que é <i>Machine Learning</i>	Ensino Fundamental		$\chi^2 = 0.1997$	p=0.6549	● Não significativa (p > 0.05)	-
	Ensino Médio					
Eu posso aprender a fazer soluções com Inteligência Artificial/ <i>Machine Learning</i> ?	Ensino Fundamental		$\chi^2 = 0.2557$	p=0.6131	● Não significativa (p > 0.05)	-
	Ensino Médio					
Eu consigo desenvolver um modelo de <i>Machine Learning</i> para reconhecer o conteúdo de imagens	Ensino Fundamental		$\chi^2 = 0.2359$	p=0.6272	● Não significativa (p > 0.05)	-
	Ensino Médio					
Desenvolver um modelo de <i>Machine Learning</i> é	Ensino Fundamental		$\chi^2 = 7.2554$	p=0.007	▲ Significativa (p < 0.05)	V = 0.202 (Pequena)
	Ensino Médio					
Consigo explicar para um amigo(a) o que é <i>Machine Learning</i>	Ensino Fundamental		$\chi^2 = 4.5923$	p=0.032	▲ Significativa (p < 0.05)	V = 0.161 (Pequena)
	Ensino Médio					

Fonte: elaborado pelo autor

QP1.3. Há alguma diferença nos resultados de aprendizagem desses estudantes com relação à estudantes em um contexto geral (não reconhecidos como de vulnerabilidade social)?

Análise descritiva — Os estudantes em situação de vulnerabilidade social apresentaram um desempenho positivo quando comparados aos estudantes em um contexto geral (Quadro 41). As médias das pontuações totais foram iguais entre os grupos (=7.2). No entanto, a mediana foi ligeiramente menor para os estudantes em situação de vulnerabilidade social (=7.5) em comparação com o contexto geral (=8.1). Algumas pequenas diferenças também foram observadas na variabilidade dos resultados. O desvio padrão e intervalo interquartil foi menor para os estudantes em situação de vulnerabilidade social (DP=1.60; IQR=1.5), indicando uma menor dispersão dos resultados em comparação com o contexto geral (DP=2.03; IQR=2.8).

Quadro 41 – Comparação do desempenho por origem socioeconômica



Fonte: elaborado pelo autor

Análise inferencial — Mesmo que as médias dos dois grupos tenham sido iguais, foi procedida a realização da análise inferencial que pode fornecer percepções adicionais sobre o resultado de aprendizagem entre os grupos (Tabela 12). Essa análise tem o intuito de reforçar as conclusões da análise descritiva e revelar nuances que podem não ser aparentes. Para essa análise, o teste não paramétrico de Mann-Whitney U foi utilizado para investigar diferenças entre as pontuações médias dos dois grupos por origem socioeconômica. Esse teste foi escolhido devido à sua adequação para amostras que não aderiram a uma distribuição normal (após o teste de Shapiro-Wilk). A potência estatística do estudo foi avaliada para detectar diferenças significativas nos resultados de aprendizagem com base na origem socioeconômica. Com um nível de confiança de 95% e um tamanho de efeito médio de 0.5, a potência do teste calculada foi de 92.5%, considerado alto e adequado para identificar diferenças estatísticas (Cohen, 1988). Desse modo, os resultados do teste de Mann-Whitney U corroboram a análise descritiva e não indicaram diferenças significativas entre os grupos ($U=4644$; $p=0.1967$). Assim, as evidências não apoiam a hipótese alternativa (H_a 1.3) de que "existem diferenças significativas nos resultados de aprendizagem entre estudantes em situação de vulnerabilidade social e estudantes em um contexto geral".

Tabela 12 – Análises inferenciais por origem socioeconômica

Grupo	Origem socioeconômica	Teste estatístico	Valor estatístico	p-valor	Diferença
Todos estudantes	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.85519	< 0.001	-
Todos estudantes	Geral	Shapiro-Wilk	W = 0.8884	< 0.001	-
	Comparação situação de vulnerabilidade social e contexto geral	Mann-Whitney U	U = 4644	0.1967	●

Fonte: elaborado pelo autor

Análise por critério específico — Ao comparar as medianas por critério, observa-se haver algumas diferenças substanciais entre os grupos de estudantes em situação de vulnerabilidade social e em um contexto geral em alguns critérios (Tabela 13). Nos critérios C1 (Quantidade de imagens), C2 (Distribuição do conjunto de dados), C7 (Análise da matriz de confusão) e C10 (Testes com novos objetos), a mediana é maior para o grupo em um contexto geral, revelando um melhor desempenho nesses aspectos. Já nos demais critérios, as medianas são iguais entre os grupos. Em complemento, às taxas de alto nível de desempenho (Aceitável + Bom), destaca as diferenças mais notáveis nos critérios C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão), com o grupo em um contexto geral apresentando taxas consideravelmente maiores. Todavia, ressalta-se o desempenho nos critérios C3 (Rotulação de imagens) e C4 (Treinamento), que apresentaram 100% de taxa de alto nível de desempenho em ambos os grupos.

Tabela 13 – Desempenho por critério da avaliação: por origem socioeconômica

Grupo	Origem socioeconômica	Estatística descritiva	Critérios											
			C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Todos estudantes	■ Situação de vulnerabilidade e social	Mediana	1	2	3	2	3	3	1	3	2	2	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom) (%)	44.8	94.8	100	100	91.3	88.1	49.2	88.5	77.8	89	63.6	71.2
Todos estudantes	■ Geral	Mediana	2	3	3	2	3	3	3	3	2	3	3	3
		Taxa de alto nível de desempenho (Aceitável + Bom) (%)	66.1	98.4	100	100	94	91	78.5	86.2	78.6	100	58.6	70

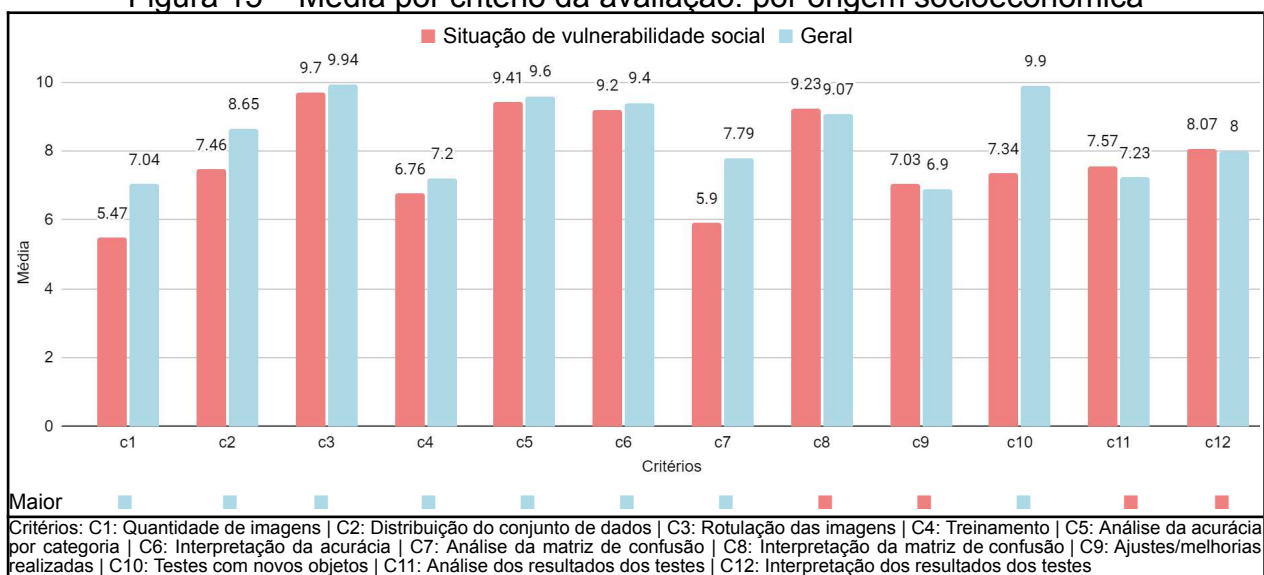
Nota: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Na comparação das médias por critério, observa-se que as médias são próximas entre os grupos na maioria dos critérios, com ambos se destacando nos critérios C3 (Rotulação das imagens), C5 (Análise da acurácia por categoria), C6 (Interpretação da acurácia) e C8 (Interpretação da matriz de confusão), com médias acima de 9 pontos (Figura 15). No entanto, o grupo de estudantes em situação de vulnerabilidade social apresenta desempenho baixo (média < 6 pontos) em C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão).

As maiores diferenças observáveis estão nos critérios C1 (vulnerabilidade social: 5.47, geral: 7.04), C7 (vulnerabilidade social: 5.9, geral: 7.79) e C10 (vulnerabilidade social: 7.34, geral: 9.9), com médias superiores para o grupo em um contexto geral.

Figura 15 – Média por critério da avaliação: por origem socioeconômica



Fonte: elaborado pelo autor

Para verificar a significância estatística das diferenças observadas nos critérios específicos da avaliação, foi realizado o Teste Exato de Fisher, com os p -valores ajustados por critério após a correção de Bonferroni (Quadro 42). Esta análise revelou diferenças significativas nos critérios C1 (Quantidade de imagens), C2 (Distribuição do conjunto de dados), C4 (Treinamento), C7 (Análise da matriz de confusão) e C10 (Testes com novos objetos), todos com p -valores ajustados < 0.05 . Para os critérios em que diferenças significativas foram encontradas após a correção de Bonferroni, o valor "V de Cramer" foi calculado para indicar o tamanho do efeito da diferença estatística. Os valores indicaram tamanho de efeito médio em C1 ($V=0.3924$), C2 ($V=0.3084$) e C7 ($V=0.3067$), pequeno em C4 ($V=0.2373$) e grande em C10 ($V=0.6406$). Para os demais critérios, não foram encontradas diferenças significativas entre estudantes em situação de vulnerabilidade social e em um contexto geral (p -valores ajustados > 0.05). Assim, estes achados apoiam a hipótese alternativa (H_a 1.3), somando evidências que a origem socioeconômica afeta significativamente alguns critérios específicos dos resultados de aprendizagem dos estudantes.

Quadro 42 – Análise por critério da avaliação: por origem socioeconômica

		● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$) - p -valor = 0.05											
		p-valores* por critério											
Grupo	Testes Estatísticos	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Comparação o contexto	Teste Exato de Fisher (p -valor)	<0.001	<0.001	0.06	0.002	0.583	0.632	<0.001	0.644	0.755	<0.001	0.537	0.87
	Correção de Bonferroni (p -valor ajustado)	0.01	<0.001	0.79	0.02	1	1	0.002	1	1	<0.001	1	1
vulnerabilidade social	V de Cramer (Tamanho de efeito)	0.3924 (Médio)	0.3084 (Médio)	0.2373 (Pequeno)			0.3067 (Médio)			0.6406 (Grande)			

Crítérios: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Análise da percepção de aprendizado — A grande maioria dos estudantes em situação de vulnerabilidade social e em um contexto geral relataram ter entendido o que é *ML*, se sentem capazes de aprender a fazer soluções com *IA/ML* e desenvolver um modelo de *ML* para reconhecimento de imagens (Quadro 43). Todavia, uma diferença substancial foi observada. Apesar da maioria dos estudantes de ambos os contextos apontarem que conseguem explicar para um amigo o que é *ML*, uma porção considerável de estudantes em situação de vulnerabilidade social (39.89%) acham que não conseguem, em contraste com apenas 9.68% dos estudantes em um contexto geral.

Para verificar se há diferenças estatisticamente significativas na percepção de aprendizagem entre os estudantes em situação de vulnerabilidade social e em um contexto geral, foi realizado o teste Qui-quadrado (χ^2). A potência estatística do estudo foi avaliada para detectar diferenças significativas na percepção sobre aprendizagem de *ML* com base na origem socioeconômica dos participantes. Utilizando o teste Qui-quadrado, com um nível de confiança de 95% e um tamanho de efeito de 0.3, considerado médio, a análise de potência *post hoc* revelou uma potência estatística de 99%. Isso indica que o estudo possui uma capacidade muito alta de detectar uma diferença significativa (Cohen, 1988).

Desse modo, os resultados do teste Qui-quadrado indicam que houve diferenças significativas entre os estudantes em situação de vulnerabilidade social e em um contexto geral em sua percepção de entendimento sobre o que é *ML* ($\chi^2=5.549$; $p=0.0184$), na percepção da dificuldade de desenvolver um modelo de *ML* ($\chi^2=6.279$; $p=0.012$) e na capacidade de explicar o que é *ML* para um amigo ($\chi^2=25.6$; $p<0.001$). Esses achados apoiam o que postula a hipótese alternativa (H_a 1.3), somando evidências que a origem socioeconômica afeta significativamente a percepção dos estudantes nesses itens. Contudo, para avaliar o tamanho do efeito

dessas diferenças, foi calculado o "V de Cramer". Os valores encontrados foram (V=0.143) para a percepção de entendimento sobre o que é *ML*, (V=0.152) para a percepção da dificuldade de desenvolver um modelo de *ML* e (V=0.306) para a capacidade de explicar o que é *ML* para um amigo. Esses resultados indicam um tamanho de efeito pequeno a médio entre a origem socioeconômica e a percepção de aprendizagem dos estudantes nesses itens. Ademais, não foram encontradas diferenças significativas na percepção da capacidade de aprender a fazer soluções com IA/*ML* e desenvolver um modelo de *ML* (ambos os *p*-valores > 0.05).

Quadro 43 – Percepção de aprendizagem por origem socioeconômica

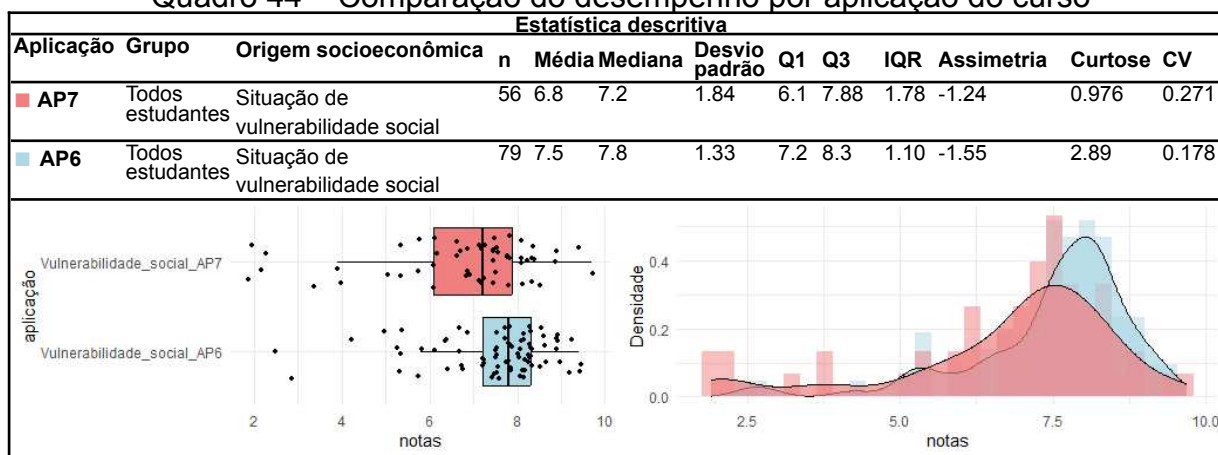
Item	Grupo	Frequência absoluta	Teste estatístico	p-valor	Diferença significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$)	V de Cramer (Tamanho de efeito)
Eu entendi o que é <i>Machine Learning</i>	Vulnerabilidade social	■ Sim ■ Não 155 23	$\chi^2 = 5.549$	$p=0.0184$	▲	V= 0.143 (Pequeno)
	Geral	90 3				
Eu posso aprender a fazer soluções com Inteligência Artificial/ <i>Machine Learning</i> ?	Vulnerabilidade social	■ Sim ■ Não 174 4	$\chi^2 < 0.001$	$p=1$	●	-
	Geral	119 3				
Eu consigo desenvolver um modelo de <i>Machine Learning</i> para reconhecimento de imagens	Vulnerabilidade social	■ Sim ■ Não 160 17	$\chi^2 = 0.007$	$p=0.932$	●	-
	Geral	83 10				
Desenvolver um modelo de <i>Machine Learning</i> é	Vulnerabilidade social	■ Muito fácil ■ Fácil ■ Mais ou menos ■ Difícil ■ Muito difícil 5 35 106 27 5	$\chi^2 = 6.279$	$p=0.012$	▲	V=0.152 (Pequeno)
	Geral	8 27 47 11				
Consigo explicar para um amigo(a) o que é <i>Machine Learning</i>	Vulnerabilidade social	■ Sim ■ Não 107 71	$\chi^2 = 25.36$	$p<0.001$	▲	V=0.306 (Médio)
	Geral	84 9				

Fonte: elaborado pelo autor

QP 1.4. Há alguma diferença nos resultados de aprendizagem desses estudantes com relação à aplicação do curso com estratégias alternativas para o ensino?

Análise descritiva — Os estudantes em situação de vulnerabilidade social apresentaram um desempenho ligeiramente menor quando comparados seus resultados de aprendizagem na aplicação 7 do curso em 2023 (AP7), adotadas estratégias alternativas para o ensino, com a aplicação 6 do curso em 2022 (AP6) (Quadro 44). A média das pontuações foi menor na AP7 (=6.8) em comparação com a AP6 (=7.5). A mediana também foi menor na AP7 (=7.2) em relação à AP6 (=7.8). Além disso, foram observadas pequenas diferenças na variabilidade dos resultados. O desvio padrão e intervalo interquartil foram maiores na AP7 (DP=1.84; IQR=1.78) indicando uma maior dispersão dos resultados em comparação com a AP6 (DP=1.33; IQR=1.10).

Quadro 44 – Comparação do desempenho por aplicação do curso



Fonte: elaborado pelo autor

Análise inferencial — O teste não paramétrico de Mann-Whitney U foi utilizado para investigar com mais profundidade as diferenças entre as pontuações médias dos estudantes em situação de vulnerabilidade social nas aplicações 7 e 6 do curso "ML para todos!" (Tabela 14). Esse teste foi escolhido devido à sua adequação para amostras que não aderiram a uma distribuição normal (após o teste de Shapiro-Wilk). A potência estatística do estudo foi avaliada para detectar diferenças significativas nos resultados de aprendizagem. Com um nível de confiança de 95% e um tamanho de efeito médio de 0.5, a potência do teste calculado foi de 80%, considerado adequado para identificar diferenças estatísticas (Cohen, 1988). Os resultados do teste de Mann-Whitney U indicaram diferenças significativas entre os grupos ($U=1620$, $p=0.008$). Assim, as evidências iniciais apontam em direção de que as diferenças estatísticas reforcem as observações da análise descritiva em favor da AP6 (em 2022).

Para explorar melhor essa diferença, foi calculada a estimativa "d de Cohen", uma medida do tamanho do efeito que permite entender a magnitude da diferença estatística entre as aplicações (Cohen, 1988). O resultado foi um tamanho de efeito médio (d de Cohen = -0.454), sugerindo que, embora haja uma diferença estatisticamente significativa entre os grupos, a magnitude dessa diferença é pequena. Além disso, o resultado dessa análise informa a direção do efeito, assim, o valor negativo da estimativa "d de Cohen" sustenta que os resultados na AP7 apresentaram uma média menor que a AP6, respaldando a análise descritiva.

Tabela 14 – Análises inferenciais por aplicação do curso

Aplicação	Grupo	Origem socioeconômica	Teste estatístico	Valor estatístico	p-valor	Diferença ● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$)
AP7	Todos estudantes	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.8664	< 0.001	-
AP6	Todos estudantes	Situação de vulnerabilidade social	Shapiro-Wilk	W = 0.8625	< 0.001	-
		Comparação situação de vulnerabilidade social (aplicação do curso 7 e 6)	Mann-Whitney U	U = 1620	0.008	▲
		Análise de efeito prático (magnitude da diferença)	d de Cohen (intervalo de confiança de 95%)	Estimativa d de Cohen = -0.454 (Pequena)		-

Fonte: elaborado pelo autor

Análise por critério específico — Ao comparar as medianas por critério, é observada diferenças substanciais entre os grupos de estudantes em situação de vulnerabilidade social das aplicações 7 e 6 em alguns critérios (Tabela 15). No critério C1 (Quantidade de imagens), a mediana é maior para a aplicação 6, revelando um melhor desempenho nesse aspecto. Já no critério C7 (Análise da matriz de confusão), a mediana é maior para a aplicação 7, indicando um melhor desempenho neste critério em comparação com a aplicação 6. Nos demais critérios, as medianas são iguais entre os grupos.

Quanto às taxas de alto nível de desempenho (Aceitável + Bom), destacam-se os critérios C3 (Rotulação das imagens) e C4 (Treinamento), com 100% em ambos os grupos. As diferenças mais notáveis aparecem nos critérios C1 (Quantidade de imagens) (AP7: 32.7%, AP6: 53.2%) e C9 (Ajustes/melhorias realizadas) (AP7: 69%, AP6: 82.7%), com a aplicação 6 apresentando taxas maiores.

Tabela 15 – Desempenho por critério da avaliação: por aplicação do curso

Aplicação	Grupo	Origem socioeconômica	Estatística descritiva	Critérios											
				C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
AP7	Todos estudantes	Situação de vulnerabilidade social	Mediana	1	2	3	2	3	3	2	3	2	2	3	3
			Taxa de alto nível de desempenho (Aceitável + Bom) (%)	32.7	94.5	100	100	90.4	84.6	51	87.8	69	88.9	68.9	66.7
AP6	Todos estudantes	Situação de vulnerabilidade social	Mediana	2	2	3	2	3	3	1	3	2	2	3	3
			Taxa de alto nível de desempenho (Aceitável + Bom) (%)	53.2	94.9	100	100	91.9	90.5	47.9	89	82.7	89	60.3	74

Nota: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes


Fonte: elaborado pelo autor

Na comparação das médias por critério, observa-se que as médias são próximas entre os grupos na maioria dos critérios, com ambos se destacando nos critérios C3 (Rotulação das imagens), C5 (Análise da acurácia por categoria) e C8

(Interpretação da matriz de confusão), com médias acima de 9 pontos (Figura 16). As aplicações 7 e 6 apresentaram desempenho baixo (média < 6 pontos) em C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão).

As maiores diferenças observáveis entre as aplicações estão nos critérios C1 (Quantidade de imagens) (AP7: 4.72, AP6: 5.99), C2 (Distribuição do conjunto de dados) (AP7: 7.03, AP6: 7.76) e C9 (Ajustes/melhorias realizadas) (AP7: 6.5, AP6: 7.33), com médias superiores para a aplicação 6.

Figura 16 – Média por critério da avaliação: por aplicação do curso



Fonte: elaborado pelo autor

Para avaliar a significância estatística das diferenças observadas nos critérios específicos da avaliação baseada em desempenho, foi realizado o Teste Exato de Fisher, com os p -valores ajustados por critério após a correção de Bonferroni (Quadro 45). Esta análise revelou diferenças significativas nos critérios C1 (Quantidade de imagens) e C2 (Distribuição do conjunto de dados) antes da correção de Bonferroni (p -valores < 0.05). No entanto, após a correção, essas diferenças mostraram-se não significativas (p -valores ajustados > 0.05). Para os demais critérios, não foram encontradas diferenças significativas entre estudantes da aplicação 7 e aplicação 6 do curso "ML para todos!" (todos os p -valores ajustados > 0.05).

Dessa forma, estes achados não apoiam a hipótese alternativa (H_a 1.4), sugerindo que as estratégias alternativas para o ensino de ML aplicadas ao curso não afetaram significativamente o desempenho em critérios específicos dos resultados de aprendizagem dos estudantes em situação de vulnerabilidade social.

Quadro 45 – Análise por critério da avaliação: por aplicação do curso

● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$) - p -valor = 0.05													
p-valores* por critério													
Grupo	Testes Estatísticos	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
Comparação AP 7 vs AP 6	Teste Exato de Fisher (p -valor)	0.02	0.01	1	1	0.76	0.40	0.94	1	0.19	0.73	0.43	0.41
	Correção de Bonferroni (p -valor ajustado)	0.25	0.19	1	1	1	1	1	1	1	1	1	1


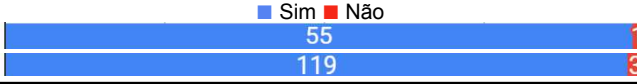
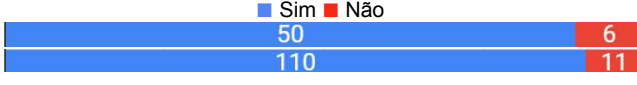
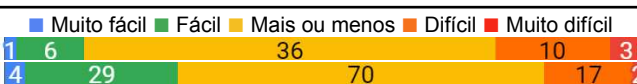
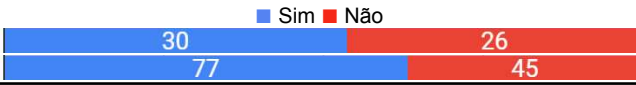
Nota: C1: Quantidade de imagens | C2: Distribuição do conjunto de dados | C3: Rotulação das imagens | C4: Treinamento | C5: Análise da acurácia por categoria | C6: Interpretação da acurácia | C7: Análise da matriz de confusão | C8: Interpretação da matriz de confusão | C9: Ajustes/melhorias realizadas | C10: Testes com novos objetos | C11: Análise dos resultados dos testes | C12: Interpretação dos resultados dos testes

Fonte: elaborado pelo autor

Análise da percepção de aprendizado — A maioria dos estudantes de ambas as aplicações do curso (7 e 6) relataram ter entendido o que é *ML*, se sentem capazes de aprender a fazer soluções com IA/*ML* e desenvolver um modelo de *ML* para reconhecimento de imagens (Quadro 46). Contudo, algumas leves diferenças substanciais foram observadas. No item da percepção da dificuldade de desenvolver um modelo de *ML*, enquanto a maioria dos estudantes da aplicação 7 (64.3%) considerou a dificuldade como "mais ou menos", os estudantes da aplicação 6 ficaram divididos entre "mais ou menos" (57.3%) e "fácil" (23.7%).

Para verificar se a diferença encontrada é estatisticamente significativa na percepção de aprendizagem entre os estudantes da aplicação 7 e 6 do curso "*ML* para todos!", foi realizado o teste Qui-quadrado (χ^2). A potência estatística do estudo foi verificada: com um nível de confiança de 95% e um tamanho de efeito de 0.3, considerado médio, a análise de potência *post hoc* revelou uma potência estatística de 97%. Isso indica que o estudo possui uma capacidade alta de detectar diferenças significativas (Cohen, 1988). Os resultados do teste Qui-quadrado indicam que houve diferença significativa entre os estudantes da aplicação 7 e 6 apenas na percepção da dificuldade de desenvolver um modelo de *ML* ($\chi^2=3.865$; $p=0.0498$). Para medir o tamanho do efeito dessa diferença, foi calculado o "V de Cramer", que resultou em ($V=0.147$), indicando um tamanho de efeito pequeno entre as aplicações e a percepção da dificuldade de desenvolver um modelo de *ML*. Contudo, para os demais itens não foram encontradas diferenças significativas.

Quadro 46 – Percepção de aprendizagem por aplicação do curso

Item	Grupo	Frequência absoluta	Teste estatístico*	p-valor	Diferença significativa (p > 0.05) ● Não Significativa (p < 0.05) ▲ Significativa (p < 0.05)	V de Cramer (Tamanho de efeito)
Eu entendi o que é <i>Machine Learning</i>	Aplicação 7 Aplicação 6		$\chi^2 = 1.733$	$p=0.188$	●	-
Eu posso aprender a fazer soluções com Inteligência Artificial/ <i>Machine Learning</i> ?	Aplicação 7 Aplicação 6		$\chi^2 < 0.001$	$p=1$	●	-
Eu consigo desenvolver um modelo de <i>Machine Learning</i> para reconhecimento de imagens	Aplicação 7 Aplicação 6		$\chi^2 = 0.004$	$p=0.9466$	●	-
Desenvolver um modelo de <i>Machine Learning</i> é	Aplicação 7 Aplicação 6		$\chi^2 = 3.865$	$p=0.0498$	▲	V=0.147 (Pequeno)
Consigo explicar para um amigo(a) o que é <i>Machine Learning</i>	Aplicação 7 Aplicação 6		$\chi^2 = 1.087$	$p=0.2971$	●	

Fonte: elaborado pelo autor

6.4.2 Qual foi a percepção de experiência de aprendizagem dos estudantes em vulnerabilidade social?

Os estudantes dos anos finais do Ensino Fundamental e Ensino Médio em situação de vulnerabilidade social tiveram uma boa experiência de aprendizagem?

Para responder essa questão de pesquisa, a percepção dos estudantes sobre a experiência de aprendizagem no curso "*ML para todos!*" foi analisada.

QP 2.1. Os estudantes tiveram uma boa experiência de aprendizagem?

Em geral, as respostas de todos os estudantes foram positivas (Quadro 47). A maioria dos estudantes (74.1%) apontou que o curso foi "muito divertido" ou "divertido". Além disso, 40.4% dos estudantes acharam o curso "fácil" ou "muito fácil". No entanto, uma porção relevante (52.2%) considerou a dificuldade do curso como "mais ou menos". Quanto à percepção do tempo das aulas, as opiniões foram divididas. Enquanto metade dos estudantes achou que o tempo das aulas passou "muito rápido" ou "rápido", 32% consideraram "mais ou menos" e 18% acharam "devagar" ou "muito devagar". Em destaque, da avaliação geral do curso, a grande maioria dos estudantes (90.4%) classificou o curso como "excelente" ou "bom", com apenas 9.5% considerando-o "regular". Nenhum estudante avaliou o curso como "ruim". Ao final do curso, a maioria dos estudantes (72.4%) indicou que gostaria de aprender mais sobre *ML*.

Quadro 47 – Percepção de experiência dos estudantes em vulnerabilidade social

Item	Frequência absoluta				
O curso foi?	Muito divertido	Divertido	Mais ou menos	Chato	Muito chato
	47	86	43	1	1
O curso foi?	Muito fácil	Fácil	Mais ou menos	Difícil	Muito difícil
	12	60	93	12	1
O tempo das aulas passou?	Muito rápido	Rápido	Mais ou menos	Devagar	Muito devagar
	29	60	57	25	7
Em geral o curso foi?	Excelente	Bom	Regular	Ruim	
	65	96	17	0	
Quero aprender mais sobre <i>Machine Learning</i>	Sim	Não			
	129	49			

Fonte: elaborado pelo autor

Em complemento, os estudantes forneceram seus *feedbacks* por meio de questões abertas do questionário que compreende a percepção de experiência de aprendizagem. Dentre os *feedbacks* positivos do curso que demonstra a eficácia do curso em suas estratégias para o ensino, bem como motivar e tornar o tema relevante, destacam-se: "Gostei do fato de que mostrou o quão simples é para criar esse modelo de inteligência artificial"; "Achei uma experiência incrível por ser novo aprendizado"; "Entender como a Inteligência Artificial aprende as coisas, como cada rede neural ajuda ela a identificar as coisas"; "As atividades práticas quando tivemos a oportunidade de realmente treinar essa inteligência artificial"; "Gostei das aulas práticas, tipo 'criar' uma IA para reconhecer materiais recicláveis"; "Fazer um modelo de machine learning pra identificar imagens". Os estudantes também reportaram elogios ao material instrucional e aos instrutores do que mais gostaram, p.ex.: "Vídeo explicando o que fazer" e "O professor".

Adicionalmente os estudantes também apontaram o que menos gostaram no curso, como: "Os vídeos aulas [sic], pois poderia ser pessoalmente"; "Muita informação em uma explicação só, e como tenho TDH [sic] é meio difícil de compreender, às vezes"; "Ficar separando imagens"; "O tempo das vídeo aulas [sic]".

Os *feedbacks* dos estudantes são apresentados no Apêndice B.

QP 2.2. Há alguma diferença nos resultados de experiência de aprendizagem desses estudantes com relação ao sexo atribuído ao nascimento e a etapa educacional?

Quanto ao sexo atribuído ao nascimento, os resultados da percepção de experiência de aprendizagem foram analisados (Quadro 48).

Análise descritiva — De modo geral, a maioria dos estudantes de ambos os sexos relataram que o curso foi "muito divertido" ou "divertido" (feminino: 71.5%, masculino: 78.9%), e a maioria considerou o curso "excelente" ou "bom" (feminino: 89.2%, masculino: 92.1%). Quanto à percepção da dificuldade do curso, uma porção relevante dos estudantes de ambos os sexos (feminino: 54.9%, masculino: 48.6%) considerou a dificuldade do curso como "mais ou menos". Em relação à percepção do tempo das aulas, as opiniões foram divididas, com uma porção considerável de estudantes femininos (48.4%) e masculinos (44.7%) indicando que o tempo passou "muito rápido" ou "rápido", enquanto outros consideraram "mais ou menos" (feminino: 24.7%, masculino: 43.4%) ou "devagar" (feminino: 18.5%, masculino: 9.2%). Além disso, a maioria dos estudantes de ambos os sexos (feminino: 69.61%, masculino: 76.3%) indicou que gostaria de aprender mais sobre *ML*.

Análise inferencial — Para verificar se há diferenças estatisticamente significativas na percepção de experiência de aprendizagem entre os estudantes femininos e masculinos em situação de vulnerabilidade social, foi realizado o teste Qui-quadrado (χ^2), com potência estatística de 97%, adequado para detectar diferenças estatísticas segundo Cohen (1988). Os resultados do teste Qui-quadrado indicam que não houve diferenças estatisticamente significativas entre estudantes femininos e masculinos em sua percepção de experiência de aprendizagem em todos os itens analisados (todos os p -valores > 0.05). Esses achados não rejeitam a hipótese nula ($H_{02.2}$) para todos os itens analisados, que postula que "Não há diferenças significativas nos resultados da experiência de aprendizagem dos estudantes em relação ao sexo atribuído ao nascimento".

Quadro 48 – Percepção de experiência: por sexo atribuído ao nascimento

Item	Grupo	Frequência absoluta	Teste estatístico	p-valor	Diferença ● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$)
O curso foi?	Feminino Masculino	<p> ■ Muito divertido ■ Divertido ■ Mais ou menos ■ Chato ■ Muito chato Feminino: 24, 49, 27, 11, 0 Masculino: 23, 37, 16, 0, 0 </p>	$\chi^2 = 0.8950$	$p=0.3441$	●
O curso foi?	Feminino Masculino	<p> ■ Muito fácil ■ Fácil ■ Mais ou menos ■ Difícil ■ Muito difícil Feminino: 5, 32, 56, 8, 1 Masculino: 7, 28, 37, 4, 0 </p>	$\chi^2 = 1.3465$	$p=0.2459$	●
O tempo das aulas passou?	Feminino Masculino	<p> ■ Muito rápido ■ Rápido ■ Mais ou menos ■ Devagar ■ Muito devagar Feminino: 17, 38, 24, 18, 5 Masculino: 12, 22, 33, 7, 2 </p>	$\chi^2 = 1.1251$	$p=0.288$	●
Em geral o curso foi?	Feminino Masculino	<p> ■ Excelente ■ Bom ■ Regular ■ Ruim Feminino: 36, 55, 11, 0 Masculino: 29, 41, 6, 0 </p>	$\chi^2 = 0.1529$	$p=0.6958$	●
Quero aprender mais sobre Machine Learning	Feminino Masculino	<p> ■ Sim ■ Não Feminino: 71, 31 Masculino: 58, 18 </p>	$\chi^2 = 0.6748$	$p=0.4114$	●

Fonte: elaborado pelo autor

Quanto à etapa educacional, os resultados da percepção de experiência de aprendizagem foram também analisados (Quadro 49).

Análise descritiva — De modo geral, a maioria dos estudantes de ambas etapas educacionais relataram que o curso foi "muito divertido" ou "divertido" (Ensino Fundamental: 69.6%, Ensino Médio: 79.7%), e a maioria considerou o curso "excelente" ou "bom" (Ensino Fundamental: 89.89%, Ensino Médio: 91%). Quanto à percepção da dificuldade do curso, a maioria dos estudantes de ambas as etapas (Ensino Fundamental: 57.3%, Ensino Médio: 47.2%) considerou a dificuldade do curso "mais ou menos". No entanto, uma porção maior de estudantes do Ensino Médio (38.2%) considerou o curso "fácil" ou "muito fácil" em comparação com o Ensino Fundamental (32.5%). Em relação à percepção do tempo das aulas, uma porção considerável de estudantes do Ensino Fundamental (44.9%) e do Ensino Médio (55%) achou que o tempo passou "muito rápido" ou "rápido". Além disso, a maioria dos estudantes de ambas etapas (Ensino Fundamental: 68.5%, Ensino Médio: 76.4%) indicaram que gostaria de aprender mais sobre ML.

Análise inferencial — Para verificar se há diferenças estatisticamente significativas na percepção de experiência de aprendizagem entre os estudantes do Ensino Fundamental e Médio em situação de vulnerabilidade social, foi realizado o teste Qui-quadrado (χ^2). Esse teste teve potência estatística de 97%, alta e adequada para detectar diferenças significativas, de acordo com Cohen (1988). Os resultados do teste Qui-quadrado indicam que houve diferença significativa entre os

estudantes do Ensino Fundamental e Médio apenas na percepção da dificuldade do curso ($\chi^2=3.941$; $p=0.0471$). Esse achado apoia a hipótese alternativa ($H_a2.2$) para esse item, levantando indícios que a etapa educacional afeta significativamente a percepção de experiência de aprendizagem dos estudantes quanto a dificuldade do curso. Contudo, para medir o tamanho do efeito dessa diferença, foi calculado o "V de Cramer", que resultou em ($V=0.149$), indicando um tamanho de efeito pequeno entre a etapa educacional e a percepção da dificuldade do curso. No entanto, não foram encontradas diferenças significativas na percepção de experiência de aprendizagem para os outros itens (todos os p -valores > 0.05).

Quadro 49 – Percepção de experiência: por etapa educacional

Item	Grupo	Frequência absoluta	Teste estatístico	p-valor	Diferença significativa ($p > 0.05$) ● Não Significativa ($p < 0.05$) ▲ Significativa ($p < 0.05$)	V de Cramer (Tamanho de efeito)
O curso foi?	Ensino Fundamental		$\chi^2 = 1.9034$	$p=0.1677$	●	-
	Ensino Médio					
O curso foi?	Ensino Fundamental		$\chi^2 = 3.9416$	$p=0.0471$	▲	$V = 0.149$ (Pequeno)
	Ensino Médio					
O tempo das aulas passou?	Ensino Fundamental		$\chi^2 = 1.438$	$p=0.2304$	●	-
	Ensino Médio					
Em geral o curso foi?	Ensino Fundamental		$\chi^2 = 0$	$p=1$	●	-
	Ensino Médio					
Quero aprender mais sobre Machine Learning	Ensino Fundamental		$\chi^2 = 1.013$	$p=0.314$	●	-
	Ensino Médio					

Fonte: elaborado pelo autor

QP 2.3. Há alguma diferença nos resultados de experiência de aprendizagem desses estudantes com relação à estudantes em um contexto geral (não reconhecidos como de vulnerabilidade social)?

Análise descritiva — De modo geral, a maioria dos estudantes em situação de vulnerabilidade social e em um contexto geral relataram que o curso foi "muito divertido" ou "divertido" (vulnerabilidade social: 74.7%, geral: 89.2%), e a grande maioria considerou o curso "excelente" ou "bom" (vulnerabilidade social: 90.4%, geral: 92.4%). Da percepção da dificuldade do curso, enquanto a maioria dos estudantes em situação de vulnerabilidade social (52.2%) considerou a dificuldade como "mais ou menos", os estudantes em um contexto geral ficaram divididos entre "mais ou menos" (44%) e "fácil" (44%). Em relação à percepção do tempo das aulas,

metade dos estudantes em situação de vulnerabilidade social e 68.8% em um contexto geral achou que o tempo passou "muito rápido" ou "rápido". Além disso, a maioria dos estudantes de ambos os contextos (vulnerabilidade social: 72.4%, geral: 87.1%) indicou que gostaria de aprender mais sobre *ML* (Quadro 50).

Análise inferencial — Para verificar se as diferenças observadas na análise descritiva são estatisticamente significativas na percepção de experiência de aprendizagem entre os estudantes em situação de vulnerabilidade social e em um contexto geral, foi realizado o teste Qui-quadrado (χ^2) (com potência estatística de 99%, alta e adequada segundo Cohen, 1988). Os resultados do teste indicam que houve diferenças significativas entre os estudantes em situação de vulnerabilidade social e em um contexto geral em sua percepção de diversão do curso ($\chi^2=7.097$; $p=0.0077$), na percepção da dificuldade do curso ($\chi^2=3.853$; $p=0.0496$), na percepção do tempo das aulas ($\chi^2=8.049$; $p=0.0045$) e no desejo de aprender mais sobre *ML* ($\chi^2=6.67$; $p=0.0097$). Esses achados apoiam a hipótese alternativa ($H_a2.3$) para esses quatro itens, sugerindo que a origem socioeconômica afeta significativamente a percepção dos estudantes nesses quesitos. Contudo, para medir o tamanho do efeito dessas diferenças, foi calculado o "V de Cramer", que resultou em ($V=0.162$) para a percepção de diversão do curso, ($V=0.119$) para a percepção da dificuldade do curso, ($V=0.172$) para a percepção do tempo das aulas e ($V=0.157$) para o desejo de aprender mais sobre *ML*. Esses resultados indicam um tamanho de efeito pequeno entre a origem socioeconômica e a percepção de experiência de aprendizagem nesses itens. O único item que não foi encontrada diferença significativa foi na avaliação geral do curso ($p=0.7402$) (Quadro 50).

Quadro 50 – Percepção de experiência: por origem socioeconômica

Item	Grupo	Frequência absoluta	Teste estatístico	p-valor	Diferença significativa ($p > 0.05$) ● Não significativa ($p < 0.05$) ▲ Significativa ($p < 0.05$)	V de Cramer (Tamanho de efeito)																		
O curso foi?	Vulnerabilidade social Geral	<table border="1"> <tr><th>Grupo</th><th>Muito divertido</th><th>Divertido</th><th>Mais ou menos</th><th>Chato</th><th>Muito chato</th></tr> <tr><td>1</td><td>47</td><td>86</td><td>43</td><td>7</td><td>12</td></tr> <tr><td>2</td><td>40</td><td>43</td><td>7</td><td>12</td><td>1</td></tr> </table>	Grupo	Muito divertido	Divertido	Mais ou menos	Chato	Muito chato	1	47	86	43	7	12	2	40	43	7	12	1	$\chi^2 = 7.097$	$p=0.0077$	▲	V = 0.162 (Pequeno)
Grupo	Muito divertido	Divertido	Mais ou menos	Chato	Muito chato																			
1	47	86	43	7	12																			
2	40	43	7	12	1																			
O curso foi?	Vulnerabilidade social Geral	<table border="1"> <tr><th>Grupo</th><th>Muito fácil</th><th>Fácil</th><th>Mais ou menos</th><th>Difícil</th><th>Muito difícil</th></tr> <tr><td>1</td><td>12</td><td>60</td><td>93</td><td>12</td><td>1</td></tr> <tr><td>2</td><td>9</td><td>41</td><td>41</td><td>1</td><td>1</td></tr> </table>	Grupo	Muito fácil	Fácil	Mais ou menos	Difícil	Muito difícil	1	12	60	93	12	1	2	9	41	41	1	1	$\chi^2 = 3.853$	$p=0.0496$	▲	V = 0.119 (Pequeno)
Grupo	Muito fácil	Fácil	Mais ou menos	Difícil	Muito difícil																			
1	12	60	93	12	1																			
2	9	41	41	1	1																			
O tempo das aulas passou?	Vulnerabilidade social Geral	<table border="1"> <tr><th>Grupo</th><th>Muito rápido</th><th>Rápido</th><th>Mais ou menos</th><th>Devagar</th><th>Muito devagar</th></tr> <tr><td>1</td><td>29</td><td>60</td><td>57</td><td>25</td><td>7</td></tr> <tr><td>2</td><td>18</td><td>46</td><td>17</td><td>9</td><td>3</td></tr> </table>	Grupo	Muito rápido	Rápido	Mais ou menos	Devagar	Muito devagar	1	29	60	57	25	7	2	18	46	17	9	3	$\chi^2 = 8.0497$	$p=0.0045$	▲	V = 0.172 (Pequeno)
Grupo	Muito rápido	Rápido	Mais ou menos	Devagar	Muito devagar																			
1	29	60	57	25	7																			
2	18	46	17	9	3																			
Em geral o curso foi?	Vulnerabilidade social Geral	<table border="1"> <tr><th>Grupo</th><th>Excelente</th><th>Bom</th><th>Regular</th><th>Ruim</th></tr> <tr><td>1</td><td>65</td><td>96</td><td>17</td><td>0</td></tr> <tr><td>2</td><td>54</td><td>32</td><td>6</td><td>1</td></tr> </table>	Grupo	Excelente	Bom	Regular	Ruim	1	65	96	17	0	2	54	32	6	1	$\chi^2 = 0.1099$	$p=0.7402$	●	-			
Grupo	Excelente	Bom	Regular	Ruim																				
1	65	96	17	0																				
2	54	32	6	1																				
Quero aprender mais sobre Machine Learning	Vulnerabilidade social Geral	<table border="1"> <tr><th>Grupo</th><th>Sim</th><th>Não</th></tr> <tr><td>1</td><td>129</td><td>49</td></tr> <tr><td>2</td><td>81</td><td>12</td></tr> </table>	Grupo	Sim	Não	1	129	49	2	81	12	$\chi^2 = 6.675$	$p=0.0097$	▲	V=0.157 (Pequeno)									
Grupo	Sim	Não																						
1	129	49																						
2	81	12																						

Fonte: elaborado pelo autor

QP 2.4. Houve diferença na experiência de aprendizagem com as estratégias alternativas para o ensino aplicadas no curso?

Análise descritiva — A maioria dos estudantes de ambas as aplicações do curso (AP7 e AP6) relataram que o curso foi "muito divertido" ou "divertido" (AP7: 82.1%, AP6: 71.3%), e a maioria considerou o curso "excelente" ou "bom" (AP7: 91%, AP6: 90.1%). Contudo, uma diferença substancial foi observada na percepção da dificuldade do curso. Enquanto a maioria dos estudantes da aplicação 7 (60.7%) considerou a dificuldade como "mais ou menos", os estudantes da aplicação 6 ficaram divididos entre "mais ou menos" (48.3%) e "fácil" (36.9%). Em relação à percepção do tempo das aulas, as percepções foram semelhantes entre as aplicações, com muitos estudantes da aplicação 7 (55.3%) e da aplicação 6 (47.5%) achando que o tempo passou "muito rápido" ou "rápido". Além disso, a maioria dos estudantes de ambas as aplicações indicou que gostaria de aprender mais sobre ML. No entanto, na aplicação 7 foi em menor proporção do que na aplicação 6 (AP7: 66%, AP6: 75.4%) (Quadro 51).

Análise inferencial — Para verificar se há diferenças estatisticamente significativas na percepção de experiência de aprendizagem entre os estudantes da aplicação 7 e 6 do curso "ML para todos!" em situação de vulnerabilidade social, foi realizado o teste Qui-quadrado (χ^2) (com potência estatística de 97%, alta e adequada para detecção de diferenças estatísticas de acordo com Cohen, 1988). Os resultados do teste Qui-quadrado indicam que houve diferença significativa entre os

estudantes da aplicação 7 e 6 apenas na percepção da dificuldade do curso ($\chi^2=4.093$; $p=0.0430$). Para medir o tamanho do efeito dessa diferença, foi calculado o "V de Cramer", que resultou em ($V=0.152$), indicando um tamanho de efeito pequeno entre a aplicação do curso e a percepção da dificuldade. Ademais, não foram encontradas diferenças significativas nos outros itens da percepção de experiência de aprendizagem (todos os p -valores > 0.05) (Quadro 51).

Quadro 51 – Percepção de experiência: por aplicação do curso

Item	Grupo	Frequência absoluta	Teste estatístico	p-valor	Diferença significativa ($p > 0.05$) ● Não significativa ($p > 0.05$) ▲ Significativa ($p < 0.05$)	V de Cramer (Tamanho de efeito)
O curso foi?	Aplicação 7 Aplicação 6		$\chi^2 = 1.8449$	$p=0.1744$	●	-
O curso foi?	Aplicação 7 Aplicação 6		$\chi^2 = 4.0932$	$p=0.0430$	▲	$V=0.152$ (Pequeno)
O tempo das aulas passou?	Aplicação 7 Aplicação 6		$\chi^2 = 0.6513$	$p=0.4196$	●	-
Em geral o curso foi?	Aplicação 7 Aplicação 6		$\chi^2 < 0.001$	$p=1$	●	-
Quero aprender mais sobre Machine Learning	Aplicação 7 Aplicação 6		$\chi^2 = 1.2423$	$p=0.265$	●	-

Fonte: elaborado pelo autor

Complementarmente aos resultados, os *feedbacks* fornecidos pelos estudantes por meio de questões abertas do questionário que compreende a percepção de experiência de aprendizagem foram analisados. Estes *feedbacks* fornecem alguns pontos de observação para a utilização de estratégias alternativas para o ensino de *ML* adotadas na aplicação 7 do curso (em 2023). Quando perguntados sobre o que mais gostaram no curso, relataram algumas estratégias alternativas como o jogo de cartas e videoaulas: "*Jogo de cartas*"; "*Tudo, e confesso que com as vídeo aulas [sic] aprendi muito mais*"; "*A saber que cada vez foi evoluindo mais a tecnologia*". Enquanto, por outro lado, as videoaulas também foram mencionadas no que menos gostaram do curso "*Os vídeos aulas [sic], pois poderia ser pessoalmente*"; "*Muita informação em uma explicação só, e como tenho TDH [sic] é meio difícil de compreender, às vezes*".

Os *feedbacks* dos estudantes são apresentados no Apêndice B.

6.4.3 Quais foram os desafios e soluções no ensino de *ML* para estudantes no contexto de vulnerabilidade social?

Com base nas observações realizadas pelos instrutores da CnE/UFSC nas aplicações do curso "*ML* para todos!" para o ensino de *ML* para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio foram identificados vários desafios, com consequências diretas para os estudantes e exigindo soluções de mitigação (Quadro 51). Estes desafios incluem:

Necessidades tecnológicas — A necessidade tecnológica é um obstáculo, pois o curso utiliza materiais online e muitos estudantes não possuem computadores em casa. Apesar de terem *smartphones*, algumas etapas do curso são difíceis de serem realizadas nesses dispositivos. Centralizar os estudantes nos laboratórios de computação no IVG, como salas de aula, viabilizou a aplicação do curso. Os laboratórios contavam com computadores robustos que facilitavam a realização das atividades. Os estudantes tinham à disposição 25 *laptops* modelo Lenovo Thinkpad (tela de 14") e 25 computadores *all-in-one* Positivo (monitores de 21"), com 4 a 8 GB de memória RAM e processador Intel Core i5, adequados para realização do curso. Além disso, todos os estudantes possuíam *headsets* exclusivos para acompanhar o curso.

A boa conectividade do IVG também foi fundamental para o sucesso do curso, permitindo o uso de várias ferramentas/plataformas simultaneamente, como Moodle, Google Meet, Google Drive, GTM e CodeMaster. Os laboratórios foram previamente testados pelos instrutores da CnE/UFSC para verificar condições de aplicação do curso (Anexo A).

Habilidades básicas de computação — Inicialmente, as aulas seriam à distância, com instrutores do programa PodeCrer/IVG organizando os laboratórios e os instrutores da CnE/UFSC ensinando remotamente. Contudo, devido às limitações nas habilidades básicas de computação dos estudantes, houve a necessidade de um instrutor presencial da CnE/UFSC para reforçar essas habilidades. Por exemplo, os estudantes não estavam acostumados a usar e-mail e frequentemente esqueciam suas senhas necessárias para acessar o Google Meet (na aplicação 6, em 2022) e a plataforma Moodle (aplicações 6 e 7 do curso, em 2022 e 2023). Para resolver isso, foram criados cartões físicos com suas senhas (Anexo B) que os auxiliava no acesso às ferramentas.

Na aplicação 7 do curso (em 2023), antes de iniciarem o curso "ML para todos!", os estudantes realizaram uma oficina de informática básica ministrada pelos instrutores do programa PodeCrer/IVG (no período de 1 semana), avaliados com o auxílio de uma rubrica de informática básica desenvolvida pelos instrutores da CnE/UFSC (Apêndice A). Essa solução teve em vista preparar/nivelar os estudantes para algumas habilidades básicas relevantes para a participação no curso.

Gerenciamento de turmas — Nos laboratórios do IVG, que comportam 25 estudantes, foi necessário um instrutor do programa PodeCrer/IVG com experiência em pedagogia para preparar e organizar as salas de aula a fim de manter um ambiente respeitoso e tranquilo. Na aplicação 6, no período da manhã, as aulas atrasavam devido à chegada dos instrutores do PodeCrer/IVG coincidir com o início das aulas. Como solução na aplicação 6 e continuado na aplicação 7, um instrutor da iniciativa CnE/UFSC atuou em conjunto, facilitando os procedimentos de preparação da sala de aula. Muitos estudantes moram e estudam longe do IVG, dependendo do transporte público, o que ocasionava atrasos. As aulas no período vespertino tiveram que ser atrasadas e o término adiantado, permitindo a chegada e saída dos estudantes. As faltas eram comuns devido a diversos fatores, como situações familiares sensíveis, transporte público, entre outras questões. Para os estudantes que faltavam, uma revisão rápida era realizada pelos instrutores e em certos casos, estes estudantes eram convidados a trabalhar em grupos com colegas que não faltaram, para acompanharem as atividades.

Na aplicação 7 (em 2023) do curso, com as estratégias alternativas para o ensino de *ML*, as videoaulas foram determinantes nesse papel, permitindo aos estudantes acompanharem as aulas de forma assíncrona e retomarem aos pontos que tinham dificuldades.

Necessidade de mentoria — Devido à falta de habilidades básicas em computação de muitos estudantes, bem como a dificuldade dos estudantes em seguir as atividades, a presença de um instrutor da CnE/UFSC com conhecimento em *IA/ML* se tornou necessária, principalmente para reforçar e auxiliar particularmente os estudantes. Na aplicação 7 (em 2023), como alternativa para o ensino, estavam presencialmente 2 instrutores da CnE/UFSC com conhecimento em *IA/ML* para reforçar ainda mais as necessidades dos estudantes e tornar o suporte, orientações e auxílios mais próximo e mais disponível aos estudantes.

Ainda assim, alguns estudantes se sentiam desconfortáveis e tímidos para solicitar ajuda aos instrutores. Para contornar isso, alguns estudantes considerados estudantes avançados foram designados como "tutores entre pares". Por serem colegas e da mesma idade, conseguiam explicar as atividades de maneira mais clara aos que tinham mais dificuldades. Os "tutores entre pares" eram também estudantes do programa PodeCrer/IVG, e também inseridos em uma situação de vulnerabilidade social do Ensino Fundamental e Médio. Estes "tutores entre pares" foram selecionados pelo próprio programa por sua maturidade, interesse e desempenho em outras atividades no IVG, como cursos de desenvolvimento web e prototipagem. O desempenho dos tutores foi louvável, aumentando sua autoestima, e fazendo-os se sentirem valorizados ao serem referidos como professores perante os colegas. A tutoria entre pares foi fundamental, pois, com estudantes em ritmos diferentes, surgiam várias dúvidas e necessidades, o que demandava vários atendimentos simultaneamente. Esses tutores entre pares auxiliaram os instrutores da CnE/UFSC e PodeCrer/IVG, tornando a assistência amplamente disponível.

Na aplicação 7 do curso (em 2023), foram selecionados pelo programa PodeCrer/IVG e instrutores da CnE/UFSC, "tutores entre pares" que foram estudantes na aplicação 6 (em 2022) e que se destacaram em seu desempenho e interesse.

Condução das aulas — Outra dificuldade enfrentada foi o tempo dilatado entre as aulas (uma semana), fazendo com que os estudantes tivessem dificuldade em recordar o conteúdo anterior. Para mitigar isso, os instrutores da CnE/UFSC faziam revisões rápidas antes de iniciar novos conteúdos. Na aplicação 7 (em 2023), como estratégia alternativa para o ensino, a solução de mitigação foi a utilização de videoaulas. A adoção das videoaulas permitiram aos estudantes retomarem e revisarem as aulas anteriores antes de procederem em novos conteúdos.

Da condução das aulas ainda, temas sensíveis, como ética em IA, que envolvem mais profundamente questões de preconceito e viés em IA, foram abordados com cuidado, uma vez que muitos estudantes podem vivenciar essa realidade. Além disso, para tratar desses temas na aplicação 7 do curso (em 2023) a metodologia de aprendizagem baseada em jogos foi empregada como alternativa para o ensino. Com a atividade desconectada, de um jogo baseado em cartas "Dilema IA" (Arndt et al., 2024; CnE, 2024c), essa atividade permitiu que os

instrutores pudessem moderar temas sensíveis com mais controle e promovendo discussões sobre o tema.

Motivação e interesse dos estudantes — Durante as aulas, notou-se que alguns estudantes não tinham interesse no curso e se mostraram apáticos. Os instrutores tentaram motivá-los, conversando pessoalmente com os estudantes. Em muitos casos, apenas o acompanhamento pedagógico e assistência social do PodeCrer/IVG tinham a experiência de intervenção. Muitas dessas atitudes são decorrentes do contexto e realidade em que os estudantes estão inseridos, incluindo situações familiares conflituosas. Muitos estudantes estão no PodeCrer/IVG devido às exigências ou imposições familiares, o que acaba resultando em desinteresse por parte deles. Para mitigar isso, os instrutores tentavam motivá-los apresentando oportunidades possíveis a partir do curso, como empregos na área ou criação de soluções próprias (p. ex. criação de aplicativos). Um exemplo ocorreu com a explicação da aplicação de *ML* nos carros autônomos da Tesla para um estudante que gostava de carros. Essa abordagem pareceu convencer o estudante a se envolver mais nas atividades, interesse ampliado após uma visita à Universidade, onde pôde ver pesquisas sobre carros autônomos.

Na aplicação 7 (em 2023), como alternativa, a solução de mitigação envolveu aproximar os estudantes de tecnologias emergentes como p.ex. o ChatGPT (OpenAI, 2023), permitindo que pudessem interagir com essa ferramenta a fim de despertar suas curiosidades sobre as novas potencialidades da IA.

Além disso, na aplicação 7, como alternativa para motivar os estudantes, a plataforma Moodle foi atualizada com um sistema com características de gamificação, o *plugin* LevelUp (Branch Up, 2024). A cada atividade que os estudantes cumpriam, ganhavam e avançavam em suas pontuações de experiência. Observou-se com isso que muitos estudantes começaram a fazer as atividades para alcançar suas pontuações e ficavam orgulhosos de seus avanços, inclusive mostrando para os instrutores e para os colegas o avanço.

Condições particulares dos estudantes — Alguns estudantes apresentaram extrema dificuldade e certa dispersão, levantando sinais da possibilidade de Transtorno do Déficit de Atenção com Hiperatividade (TDAH). Nesses casos, a coordenação pedagógica e assistência social do programa PodeCrer/IVG possuem trabalhos de orientação específicos com os responsáveis dos estudantes para fornecer suporte fora do contexto do curso. Para casos menos sensíveis, como

relacionados à motivação e baixa autoestima, os instrutores da CnE/UFSC, principalmente na aplicação 7, adotaram a abordagem freiriana (Freire, 1968) de maior proximidade com os estudantes, com acompanhamento da coordenação pedagógica do programa PodeCrer/IVG.

Percepção de domínio do sexo atribuído ao nascimento — Apesar de não relacionada exclusivamente com a vulnerabilidade social, das observações dos instrutores, essa percepção de domínio é muito latente nas estudantes do sexo feminino nesse contexto. Algumas estudantes femininas no início do curso perceberam a computação como uma área voltada para homens, o que fez com que muitas indicassem que não consideram essa área em sua formação acadêmica ou trabalho. Como solução de mitigação, os instrutores reforçaram, principalmente na aula 6 do curso, oportunidades de carreira e histórias de sucesso de mulheres na área de TI. Essa iniciativa pareceu promissora, considerando os comentários positivos no *feedback* das estudantes e depoimentos dos instrutores, ao observar que ao final, principalmente as estudantes femininas consideraram a importância do tema do curso em suas vidas e na busca de uma carreira.

Abordagem pedagógica adaptada às necessidades do estudante — Em algumas ocasiões, também devido à falta de conhecimentos básicos de computação, as atividades do curso pareciam complexas demais para alguns estudantes, que desistiam rapidamente das atividades. Como solução de mitigação, os instrutores da CnE/UFSC identificaram colegas com quem o estudante se sentia mais confortável e os convidou a fazer as atividades em grupos. Essa abordagem colaborativa foi positiva, por discutirem e encontrarem soluções conjuntamente em várias atividades. Alguns estudantes com extrema dificuldade, às vezes por constrangimento ou desinteresse, nem tentavam fazer as atividades. A estratégia de fazer com um colega também foi positiva. Os instrutores da CnE/UFSC tiveram o cuidado para que esses estudantes formassem grupos também com colegas que já haviam avançado nas atividades. Isso não prejudicou o estudante mais adiantado, pelo contrário, o estudante mais adiantado além de auxiliar também reforçava o assunto para si e parecia se sentir valorizado.

Compreendendo as dificuldades no contexto dos estudantes e do dia estressante que os estudantes poderiam ter, os instrutores buscaram adotar também nesse caso a abordagem freiriana (Freire, 1968) de proximidade com os estudantes, com mais profundidade na aplicação 7. Os instrutores sempre os auxiliavam com

palavras de motivação, elogios e vibração ao completarem as atividades, com isso o *feedback* era sempre positivo. Os instrutores tentavam se envolver com assuntos de interesse do estudante (como animes, esportes, redes sociais, moda, quadrinhos e jogos) para criar associações com IA/ML e aproximá-los das atividades. Isso tornou as aulas mais fluidas, leves e em um clima de ensino-aprendizagem de confiança.

Heterogeneidade de habilidades — Os estudantes participantes eram de várias escolas da região, com diferentes qualidades de ensino e, conseqüentemente, conhecimentos e habilidades diversas. Nesse sentido, também havia diferentes maturidades e experiências. Isso pode levar a diferentes ritmos e interesses no curso. Como solução de mitigação, o programa PodeCrer/IVG separou as turmas principalmente por etapa educacional, turmas compostas majoritariamente por estudantes dos anos finais do Ensino Fundamental e turmas majoritariamente por estudantes do Ensino Médio. Além disso, os instrutores da CnE/UFSC procuraram adotar uma abordagem mais lenta e gentil no ensino. Os estudantes do Ensino Médio pareciam mais interessados; muitos estavam preocupados com seu futuro, as possibilidades de ingressar na universidade e oportunidades de trabalho. Um estudante indicou a intenção de incluir o curso "ML para todos!" no currículo. Outro estudante gostaria de saber mais sobre os cursos de tecnologia da UFSC e IFSC. Para motivar esses estudantes, eles foram convidados a fazer um *tour* pela UFSC, conhecendo as principais pesquisas na área de IA/ML.

Já os estudantes do Ensino Fundamental estavam mais preocupados com seu dia a dia. Muitos, após a conclusão das atividades planejadas, abriram abas de jogos online. Os instrutores aproveitaram essas oportunidades para discutir um pouco sobre a relação de jogos e IA/ML, motivando-os no assunto. Essas outras atividades não foram impedidas, pois os instrutores reconheceram que, mesmo os jogos fora do curso eram saudáveis, na medida em que os estudantes não tinham computadores em casa e isso proporcionava oportunidade de aprimorar suas habilidades em computação.

Adaptação do material instrucional — Os principais materiais instrucionais das atividades propostas no curso "ML para todos!" são compostos por slides interativos. No entanto, observou-se que os estudantes não liam as instruções passo a passo, evidenciando a falta de hábito de leitura. A consequência disso é que os estudantes realizavam as atividades muitas vezes de maneira incorreta. Como solução de mitigação, e sabendo que esses estudantes estão acostumados a

interagir com vídeos curtos nas redes sociais (como *stories* no Instagram e TikTok), os instrutores da CnE/UFSC prepararam materiais extras de apoio, criando vídeos curtos para explicar algumas atividades passo a passo.

Em relação às ferramentas, embora o GTM seja intuitivo e adequado para estudantes sem conhecimento prévio em programação, os vídeos produzidos foram essenciais para explicar o funcionamento da ferramenta. Além disso, a ferramenta CodeMaster também precisou de um vídeo para explicar seu funcionamento. Com relação à ferramenta CodeMaster, muitos estudantes pareciam motivados pelos resultados de seu aprendizado em tempo real, motivando alguns a melhorar seu modelo de *ML* treinado para obter uma nota mais alta e "faixa ninja de outra cor" (uma forma visual de *feedback* de sua nota).

Na aplicação 7, como estratégia alternativa para o ensino de *ML*, as videoaulas foram integradas ao material instrucional. Observou-se a condição proporcionada aos estudantes de revisão e retomada de pontos específicos em uma aula ou atividade. Contudo, alguns estudantes demonstraram ansiedade, atenção dispersa e pulavam o vídeo ou assistiam acelerado. Os instrutores procuravam motivá-los a assistir com tranquilidade e também reforçaram particularmente os pontos que se era percebido que os estudantes pulavam.

Também como adoção de estratégias alternativas, o jogo de cartas "Dilema IA" foi adicionado ao material instrucional. Das observações e achados em Arndt et al. (2024), o jogo contribuiu positivamente para o objetivo de aprendizagem do curso (OA6 — Discutir preocupações éticas e o impacto do *ML* na sociedade) enquanto os estudantes discutiam e interagiam entre si e com o conteúdo de ética em IA. Dos achados, em destaque, a usabilidade do jogo foi avaliada positivamente, com a maioria dos estudantes considerando o design visual do jogo atraente. O material instrucional de jogo de cartas, sendo uma metodologia de aprendizagem baseada em jogos, foi observado como importante para motivar jovens estudantes. E sendo um método instrucional de atividade desconectada, foi observado como adequada pela aderência às situações quando a infraestrutura for impossibilitada devido ao contexto de vulnerabilidade social.

Processo de desenvolvimento de ML — Os estudantes conseguiram proceder nas etapas de um processo de desenvolvimento de *ML* centrado no ser humano. No entanto, foram observadas dificuldades em algumas atividades relacionadas às etapas básicas do desenvolvimento de um modelo de *ML*. As

principais dificuldades observadas em ambas as aplicações do curso (aplicação 6 e 7) foram relacionadas à atividade da etapa de preparação do conjunto de dados na "quantidade de imagens" e na etapa de avaliação do modelo, na atividade de "análise da matriz de confusão".

Um dos desafios observados para proceder na etapa de preparação do conjunto de dados foi o tempo limitado em sala de aula para os estudantes trabalharem com a separação e coleta de imagens. Como alternativa, na aplicação 7 do curso, as videoaulas visaram mitigar essa questão para viabilizar mais tempo para os estudantes procederem nas atividades, e conseqüentemente terem condições de preparar mais adequadamente seus conjuntos de dados. Contudo, os estudantes devido à ansiedade de avançar para as próximas etapas ainda utilizavam poucas imagens para realizar o treinamento do modelo. Como futuras aplicações, uma solução de mitigação sugerida é reforçar nas explicações das aulas a necessidade para os estudantes de utilizar mais imagens para a etapa de treinamento do modelo a fim de possivelmente obterem um melhor desempenho em seus modelos de *ML*.

Quanto à atividade relacionada à "análise da matriz de confusão", alguns estudantes não compreendiam a lógica das matrizes de confusão, resultando em dificuldade em compreender esta etapa da atividade. Isso pode estar atrelado à qualidade de ensino em suas escolas regulares, que pode ter influência em seus conhecimentos basais adquiridos. Como solução de mitigação, principalmente na aplicação 7, uma explicação mais próxima dos estudantes sobre a lógica da matriz de confusão foi conduzida pelos instrutores da CnE/UFSC. Como resultado, observou-se melhores entendimentos dessa lógica pelos estudantes.

As limitações, conseqüências e soluções de mitigação adotadas são sintetizadas no Quadro 52.

Quadro 52 – Limitações, consequências e soluções adotadas no curso

Limitações e/ou necessidades identificadas	Consequências	Soluções de mitigação	
		Iniciado na aplicação 6 (2022)	Alternativa na aplicação 7 (2023)
Necessidades tecnológicas	<ul style="list-style-type: none"> Desvantagem tecnológica Exclusão social Desigualdades; Falta de oportunidade de aprender 	<ul style="list-style-type: none"> Centralizar os estudantes em um laboratório de computação (como uma sala de aula) no IVG. Disponibilizar recursos tecnológicos 	
Falta de conhecimentos básicos de computação	<ul style="list-style-type: none"> Dificuldade de aprendizado Barreira digital Dificuldade em acompanhar as aulas Desvantagem no aprendizado 	<ul style="list-style-type: none"> Instrutor presencial do CnE/UFSC para reforçar as habilidades de computação Cartões para recordar a senha das plataformas usadas nas aulas. 	<ul style="list-style-type: none"> Oficina de informática básica (rubrica elaborada pelos instrutores CnE/UFSC e aplicado pelos instrutores PodeCrer/IVG)
Necessidades de gerenciamento de turma	<ul style="list-style-type: none"> Dificuldade em acompanhar as aulas Atrasos no início da aula Distúrbios na sala de aula Dificuldade de acompanhamento de estudantes ausentes 	<ul style="list-style-type: none"> Instrutores do programa PodeCrer/IVG organizando as salas de aula. Instrutores CnE/UFSC auxiliando na preparação da sala de aula. Início um pouco mais tarde das aulas, aguardando a chegada dos estudantes (p. ex. usuários de transporte público) Revisão rápida e apontamento dos destaques do material pelos instrutores da CnE/UFSC. 	<ul style="list-style-type: none"> Videoaulas para acompanhamento de forma assíncrona.
Necessidades de mentoria	<ul style="list-style-type: none"> Dificuldade em acompanhar as aulas Dificuldade em acompanhar as atividades Dificuldade para os estudantes aprenderem o conteúdo. Menor envolvimento dos estudantes Menor motivação dos estudantes <u>Sobrecarga de trabalho dos instrutores.</u> 	<ul style="list-style-type: none"> Instrutores de CnE/UFSC com experiência em IA/ML (remoto e presencial). Instrutores do programa PodeCrer/IVG para ajudar na computação básica. Os estudantes de turmas avançadas atuando como tutores entre pares. 	<ul style="list-style-type: none"> Reforço presencial de instrutores do programa PodeCrer/IVG para ajudar na computação básica, e tornar o suporte, orientações mais próximas dos estudantes
Necessidades de condução em sala de aula	<ul style="list-style-type: none"> Dificuldade em acompanhar as aulas Dificuldade em acompanhar as atividades Sensibilidade de temas 	<ul style="list-style-type: none"> Os instrutores fazem uma revisão rápida para tentar colocar os estudantes no mesmo nível do novo conteúdo. 	<ul style="list-style-type: none"> Videoaulas para revisões e retomadas de pontos de interesse Moderação de temas sensíveis como ética em IA, por meio de jogo de cartas "Dilema IA".
Falta de motivação e interesse dos estudantes	<ul style="list-style-type: none"> Desinteresse na área Possível evasão do curso Perda de futuras oportunidades de emprego ou de ingresso no Ensino Superior Menor envolvimento dos estudantes Menor motivação dos estudantes Menor participação em sala de aula Baixo desempenho nas atividades Impacto negativo no clima da sala de aula e na dinâmica entre os estudantes Desmotivação de outros estudantes 	<ul style="list-style-type: none"> Conversas pessoais para motivar e envolver os estudantes; Assistência social do PodeCrer/IVG para questões com situações particulares ou sociais delicadas; Vinculação do conteúdo do curso aos interesses dos estudantes; Realização de um <i>tour</i> pela universidade apresentando a pesquisa e o potencial da IA/ML 	<ul style="list-style-type: none"> Aproximação dos estudantes com tecnologias emergentes. Metodologia de aprendizagem baseada em jogos/ estratégia de gamificação.
Condições particulares dos estudantes.	<ul style="list-style-type: none"> Dificuldade de aprendizado Exclusão social Menor motivação dos estudantes Baixa autoestima 	<ul style="list-style-type: none"> A coordenação pedagógica e a assistência social do PodeCrer/IVG procedem em trabalhos de orientação específicos com os responsáveis dos estudantes. 	<ul style="list-style-type: none"> Abordagem pedagógica freiriana de maior proximidade com os estudantes.
Percepção de dominância do sexo atribuído no nascimento.	<ul style="list-style-type: none"> Desigualdades no sexo atribuído no nascimento Desinteresse na área Baixa autoestima 	<ul style="list-style-type: none"> Os instrutores reforçaram e apresentaram histórias de sucesso de mulheres na área de Tecnologia da Informação. 	<ul style="list-style-type: none"> Abordagem pedagógica freiriana (Freire, 1968) de maior proximidade com os estudantes.
Abordagem pedagógica adaptada às necessidades dos estudantes.	<ul style="list-style-type: none"> Desistência ou dispersão nas atividades do curso; Perda de oportunidade de aprendizado Baixa autoestima e insegurança em relação à sua capacidade e potencial; Falta de envolvimento nas atividades do curso 	<ul style="list-style-type: none"> Aprendizagem colaborativa e trabalho em grupo/programação em pares: para incentivar a colaboração e o compartilhamento de conhecimento entre os estudantes; Vinculação do conteúdo do curso aos interesses dos estudantes; 	<ul style="list-style-type: none"> Abordagem freiriana (Freire, 1968) na criação de um ambiente de aprendizado inclusivo e acolhedor para todos os estudantes.
Heterogeneidade de habilidades	<ul style="list-style-type: none"> Desinteresse de alguns estudantes Falta de envolvimento dos estudantes Falta de motivação dos estudantes Ritmos de atividade muito divergente Resultados de desempenho muito divergentes 	<ul style="list-style-type: none"> Adoção de um aprendizado mais lento e suave Separação de turmas por idade Criação de um ambiente inclusivo e acolhedor, reconhecendo as diferenças individuais de cada estudante Realização de um <i>tour</i> pela universidade apresentando a pesquisa e o potencial da IA/ML para nivelar esse conhecimento 	
Adaptação do material instrucional	<ul style="list-style-type: none"> Dificuldade para os estudantes aprenderem o conteúdo. Dificuldade em acompanhar as atividades Falta de motivação dos estudantes 	<ul style="list-style-type: none"> Criação de vídeos curtos, passo a passo do funcionamento do ferramental tecnológico e atividades. 	<ul style="list-style-type: none"> Videoaulas para instrução Jogo de cartas "Dilema IA"
Processo de desenvolvimento de ML	<ul style="list-style-type: none"> Dificuldade para os estudantes aprenderem o conteúdo. Dificuldade em acompanhar as atividades 	<ul style="list-style-type: none"> Maior suporte dos instrutores da CnE/UFSC 	<ul style="list-style-type: none"> Videoaulas para orientação passo a passo das principais etapas do processo de desenvolvimento de ML. Explicação mais próxima dos instrutores da CnE/UFSC

Fonte: Elaborado pelo autor

6.5 DISCUSSÃO

Considerando a importância de tornar o conhecimento de IA/ML disponível para todos e tornar a popularização desse conhecimento mais igualitária e inclusiva para jovens em situação de vulnerabilidade social, foi aplicado o curso "ML para todos!". O curso foi desenvolvido a partir das estratégias para o ensino de ML de acordo com os objetivos de aprendizagem estabelecidos.

A partir das análises procedidas foi possível responder à pergunta de pesquisa: Como ensinar *Machine Learning* para o contexto de estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio de forma eficaz para possibilitar a aprendizagem de conceitos básicos de ML. Além disso, como ensinar de forma motivadora e que promova uma boa experiência de aprendizagem.

Resultados de aprendizagem dos estudantes — Os resultados indicam que os estudantes em situação de vulnerabilidade social atingiram, de modo geral, os objetivos de aprendizagem do curso "ML para todos!", com um desempenho satisfatório na avaliação baseada em desempenho. Os estudantes conseguiram proceder em um processo de desenvolvimento de modelo de ML centrado no ser humano, demonstrando facilidade principalmente em critérios específicos que envolvem atividades como rotulação de imagens (C3) e análise da acurácia (C5). Alguns critérios, como quantidade de imagens (C1) e análise da matriz de confusão (C7), foram mais desafiadores, possivelmente devido à falta de familiaridade prévia com conceitos básicos de computação, tempo para a atividade e à complexidade dos conceitos lógico-matemáticos (Figura 17).

Figura 17 – Mapa de calor dos resultados de aprendizagem por critérios específicos



Fonte: elaborado pelo autor

A percepção de aprendizado dos estudantes corrobora os resultados de aprendizagem. A maioria dos estudantes relatou ter entendido os conceitos básicos de *ML* e se sentir capaz de desenvolver modelos para classificação de imagens. No entanto, alguns não se sentem confiantes para explicar *ML* para os amigos, ressaltando a importância de atividades que estimulem a discussão dos conceitos aprendidos, para promover a autoconfiança.

Quanto ao sexo atribuído ao nascimento e à etapa educacional, não foram encontradas diferenças significativas nos resultados de aprendizagem. Ambos os grupos apresentaram desempenho com médias altas na maioria dos critérios e dificuldades comuns nos critérios C1 (Quantidade de imagens) e C7 (Análise da matriz de confusão). A análise da percepção de aprendizado endossa os resultados de aprendizagem, com a maioria dos estudantes de ambos os sexos e etapas educacionais relatando entender o que é *ML* e se sentir capaz de desenvolver soluções nessa área. No entanto, para o sexo atribuído ao nascimento, uma parcela relevante, tanto femininos quanto masculinos, relatou não conseguir explicar o que é *ML* para outras pessoas, indicando que a autoconfiança é independente do sexo atribuído ao nascimento e representa um ponto de atenção para futuras aplicações. Para a etapa educacional, a análise da percepção de aprendizado revelou diferenças significativas na percepção da dificuldade de desenvolver um modelo de *ML* e em conseguir explicar o que é *ML* para um amigo, com estudantes do Ensino Médio tendo uma percepção mais positiva nesses aspectos. Essa diferença pode estar relacionada à maior maturidade cognitiva e capacidade de abstração dos estudantes do Ensino Médio, representando outro ponto de observação para aplicações futuras.

Contudo, os resultados sugerem a universalidade em relação ao sexo atribuído ao nascimento. Além disso, apesar de algumas diferenças de percepção, não foram observados prejuízos no aprendizado entre as etapas educacionais, indicando que as estratégias para o ensino de *ML* são eficazes tanto para estudantes do Ensino Fundamental quanto do Ensino Médio.

Ao comparar o desempenho dos estudantes por origem socioeconômica, observa-se um desempenho próximo e positivo. A média das pontuações foi igual para ambos contextos socioeconômicos. Do desempenho por critério específico, algumas diferenças significativas foram observadas, com os estudantes em um contexto geral apresentando desempenho mais destacado nos critérios C1

(Quantidade de imagens), C2 (Distribuição do conjunto de dados), C7 (Análise da matriz de confusão) e C10 (Testes com novos objetos). Essas diferenças pontuais podem estar relacionadas a fatores como maior familiaridade com recursos tecnológicos, conhecimento prévio em computação, qualidade da educação em suas escolas regulares e mais tempo para realizarem novos testes (pela maioria ter computadores em suas casas).

Contudo, apesar dessas diferenças pontuais, os resultados de aprendizagem demonstram condições de inclusão e equidade do curso, independente da origem socioeconômica.

Da análise da percepção de aprendizagem por origem socioeconômica, foram reveladas diferenças em três aspectos: percepção de entendimento sobre o que é *ML*, percepção da dificuldade de desenvolver um modelo de *ML* e capacidade de explicar *ML* para um amigo. Os estudantes em um contexto geral parecem ter uma percepção mais positiva nesses aspectos, o que pode estar relacionado a fatores como autoconfiança e exposição prévia a conceitos tecnológicos. Esses resultados se alinham com o exposto por Destin et al. (2019) de que a vulnerabilidade social pode afetar as percepções por meio do estresse e da desmotivação resultante de seu contexto.

A partir dessas diferenças, é reforçada a importância de realizar melhorias contínuas no projeto e implementação das estratégias para o ensino de *ML*, considerando as particularidades relacionadas à origem socioeconômica, tornando o ensino cada vez mais inclusivo e adequado às necessidades dos estudantes em situação de vulnerabilidade social.

Entre as aplicações do curso, o desempenho foi próximo, porém levemente menor na aplicação 7 (em 2023) em comparação com a aplicação 6 (em 2022). A análise indicou diferença significativa entre os grupos, entretanto o tamanho do efeito aponta que a magnitude dessas diferenças é pequena. Este resultado pode estar atrelado a maior autonomia dada aos estudantes com a adoção de videoaulas como estratégia alternativa para o ensino na aplicação 7. Os estudantes pela ansiedade ou atenção dispersa podem pular etapas importantes das videoaulas.

Do desempenho por critério específico, foram identificadas pequenas diferenças substanciais entre as aplicações. Como destaque, a aplicação 7 obteve leves melhoras nos critérios C7 (Análise da matriz de confusão) e C10 (Teste com novos objetos) em relação à aplicação 6. A melhora no critério C7 pode estar

relacionada às estratégias alternativas para o ensino, como abordagens pedagógicas mais próximas ao estudante. E a melhoria no critério C10, a utilização de videoaulas levanta indícios de ter proporcionado mais tempo para os estudantes procederem melhor nesta etapa final do processo de desenvolvimento de modelo de *ML*.

Na análise da percepção de aprendizado foi revelado uma diferença significativa, apenas na percepção da dificuldade de desenvolver um modelo de *ML*. Contudo, essa diferença apresenta um tamanho de efeito pequeno. Uma possível razão para a existência dessa diferença pode ser o reflexo da grade curricular estruturada pelo Programa PodeCrer/Instituto Vilson Groh. Na aplicação 6 o curso "*ML para todos!*" foi aplicado após outros cursos de tecnologia do IVG, enquanto na aplicação 7, foi aplicado em paralelo.

De forma geral, os resultados de aprendizagem em todas as comparações demonstram consistência e eficácia do material instrucional para a aprendizagem de conceitos básicos de *ML* pelos estudantes em situação de vulnerabilidade social, mesmo com diferenças pontuais que não resultaram em prejuízo de aprendizado diante dos objetivos de aprendizagem.

Experiência de aprendizagem dos estudantes — Os resultados sugerem que os estudantes em situação de vulnerabilidade social tiveram uma experiência positiva no curso "*ML para todos!*". A maioria considerou o curso divertido, com dificuldade moderada e uma avaliação geral muito boa, despertando o interesse em aprender mais sobre *ML*. Esse aspecto é respaldado pelas interações com os instrutores e pela coordenação pedagógica do IVG, que relatou que alguns estudantes começaram a cursar o ensino superior em áreas técnicas no IFSC e na UFSC. Alguns estudantes também se sentiram confiantes em participar de competições como *Hackathons*, aplicando diretamente conhecimentos adquiridos no curso.

Os *feedbacks* dos estudantes corroboram com os objetivos propostos, apontando aspectos positivos como o aprendizado sobre *ML*, as abordagens pedagógicas e a didática dos instrutores, além de indicar pontos de melhoria, como o tempo das videoaulas e dificuldades de *login*.

Quanto ao sexo atribuído ao nascimento, não foram reveladas diferenças significativas na percepção de experiência de aprendizagem, reforçando que o curso foi igualmente eficaz em proporcionar uma experiência positiva para ambos os

sexos. Já em relação à etapa educacional, apesar de uma experiência positiva para os estudantes de ambas etapas, foi encontrada apenas uma diferença significativa na percepção da dificuldade do curso, com estudantes do Ensino Médio considerando-o mais fácil comparado aos do Ensino Fundamental. No entanto, essa diferença apresenta um tamanho de efeito pequeno. Contudo, uma razão para a existência dessa diferença pode estar relacionada também às diferenças de maturidade cognitiva e experiência prévias entre as etapas educacionais. Os estudantes do Ensino Fundamental estão em um estágio em que os conceitos fundamentais estão sendo formados, o que pode torná-los suscetíveis às influências do contexto de vulnerabilidade social na percepção de dificuldade em suas experiências de aprendizagem (Langenkamp e Carbonaro, 2018). Isso destaca a importância de considerar diferenças de desenvolvimento cognitivo ao desenvolver estratégias para o ensino.

Nas análises por origem socioeconômica, mesmo com uma experiência positiva para a maioria dos estudantes em ambos os contextos, foram reveladas diferenças significativas em aspectos específicos, como percepção de diversão, dificuldade, tempo das aulas e desejo de aprender mais, com proporções mais positivas para estudantes de um contexto geral. Entretanto, todas as diferenças apresentaram um tamanho de efeito pequeno. Contudo, a existência dessas diferenças podem estar relacionadas aos desafios e limitações enfrentados pelos estudantes em situação de vulnerabilidade social, considerados estressores adicionais: como situações familiares, questões logísticas (p.ex. transporte público) e baixa autoconfiança (Destin et al., 2019). Além disso, cabe ressaltar que o curso para esses estudantes em vulnerabilidade social não é totalmente voluntário por fazerem parte do programa PodeCrer/IVG que os ampara com necessidades específicas. Dessa forma, o grau de voluntariedade e a influência das necessidades específicas dos estudantes são fatores a serem considerados em investigações futuras. Todavia os resultados destacam a importância também de considerar diferenças socioeconômicas ao projetar e implementar estratégias para o ensino de *ML*, oferecendo condições iguais aos estudantes em situação de vulnerabilidade social, considerando os desafios e limitações que eles enfrentam em suas percepções de experiências de aprendizagem.

Sobretudo, a avaliação geral do curso foi positiva para ambos os grupos, sugerindo que o curso proporcionou uma experiência satisfatória para todos. Assim,

as percepções positivas no curso, para ambos os contextos, corroboram com os esforços de equidade, igualdade e inclusão nas estratégias para o ensino utilizadas.

Entre as aplicações do curso para estudantes em vulnerabilidade social, apesar de percepções positivas em geral, houve uma diferença significativa na percepção da dificuldade, com o curso sendo percebido como mais compreensível na aplicação 6 (2022) comparado à aplicação 7 (2023). No entanto, essa diferença apresenta um tamanho de efeito pequeno. Entretanto, a existência dessa diferença pode estar atrelada à maior autonomia dada aos estudantes na aplicação 7, devido às estratégias alternativas adotadas, como videoaulas. Nos demais aspectos, não foram encontradas diferenças significativas, sugerindo que as estratégias alternativas para o ensino não impactaram a experiência de aprendizagem de modo geral.

Contudo, o fato de ambas as aplicações terem tido percepções positivas pode ser atribuído à consistência das estratégias para o ensino de *ML* utilizadas no curso "*ML para todos!*", que se mostraram eficazes em promover uma experiência positiva e envolvente.

Desafios e soluções no ensino de ML para estudantes dos anos finais do Ensino Fundamental e Médio no contexto de vulnerabilidade social — O ensino de *ML* para estudantes dos anos finais do Ensino Fundamental e Médio em um contexto de vulnerabilidade social apresentou diversos desafios, exigindo soluções de mitigação para assegurar um aprendizado efetivo. Um dos principais obstáculos foi a necessidade tecnológica, uma vez que muitos estudantes não possuem computadores em casa e vivem em comunidades com infraestrutura inadequada. A centralização dos estudantes em um laboratório de computação com boa infraestrutura e conectividade foi uma estratégia importante para tornar o ensino de *IA/ML* equitativo e igualitário.

Outro desafio significativo foi a falta de habilidades básicas de computação dos estudantes. A presença de instrutores especializados e a oferta de uma oficina de informática básica previamente ao curso ajudaram a suprir essas demandas. O gerenciamento das turmas também foi desafiador, com atrasos e faltas frequentes dos estudantes. Ajustes nos horários, revisões, apoio de instrutores experientes e a introdução de videoaulas para acompanhamento assíncrono foram soluções adotadas, com resultados positivos para essa finalidade.

Despertar a motivação e o interesse dos estudantes foi outro desafio, devido ao contexto em que estão inseridos. Como solução de mitigação, os instrutores apresentaram oportunidades de empregos e futuro em IA/ML, relacionando o conteúdo aos interesses dos estudantes. A abordagem pedagógica freiriana (Freire, 1968) como abordagem alternativa, em um processo de ensino-aprendizagem sem hierarquia, com proximidade aos estudantes, palavras motivacionais, foi fundamental para conquistar a confiança dos estudantes e motivá-los. Além disso, o envolvimento com assuntos de interesse dos estudantes (como p.ex. *animes*, moda, esportes), inclusive recorrendo a tecnologias emergentes como o ChatGPT (OpenAI, 2023) e elementos de gamificação também foram positivos para engajar os estudantes e despertar seus interesses.

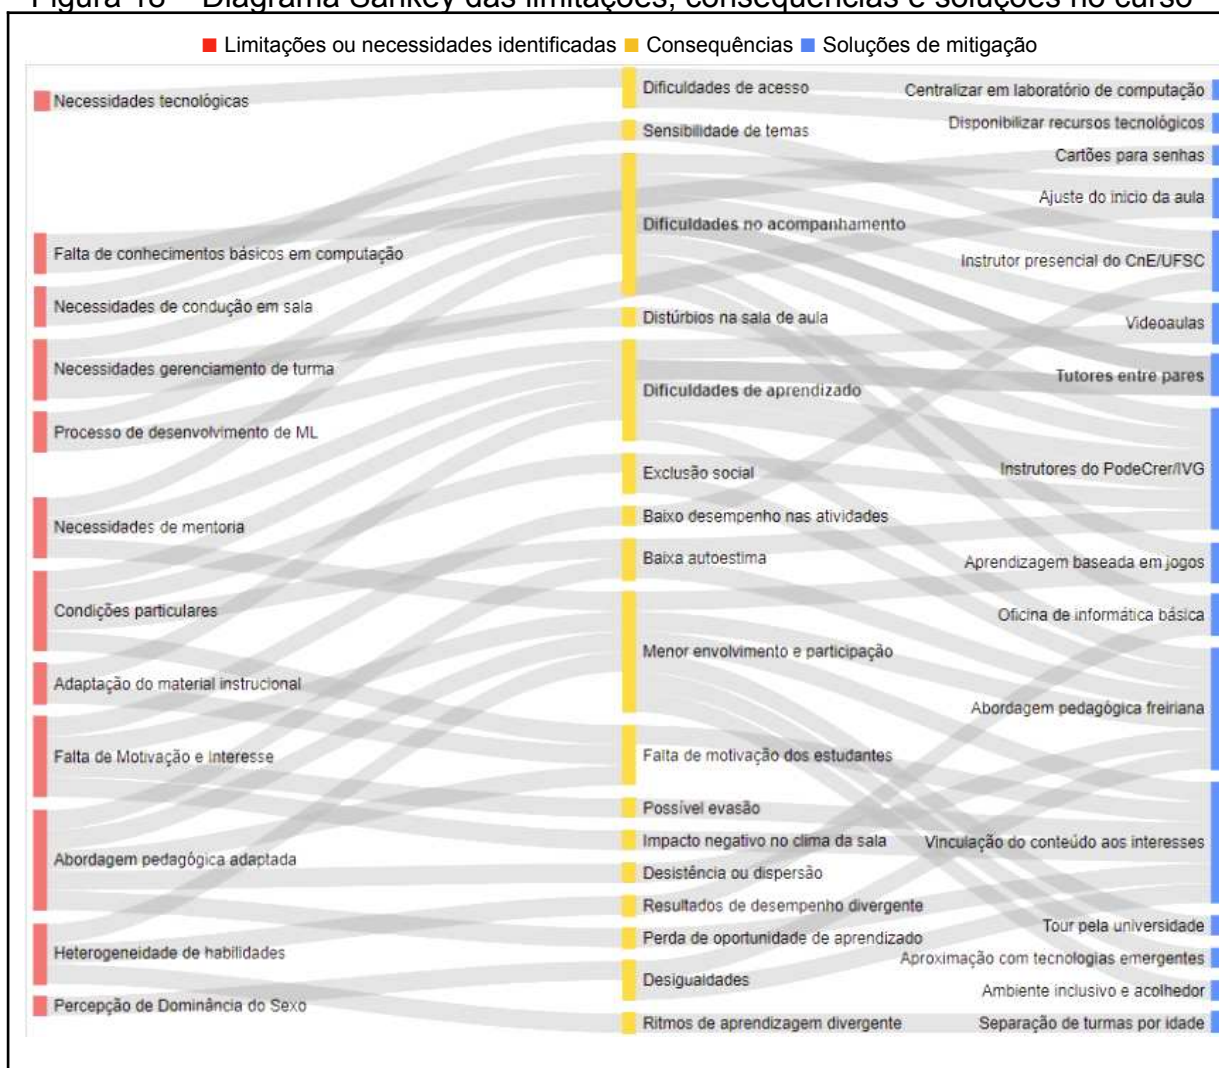
O material instrucional precisou de adaptações, com a criação de vídeos curtos explicativos na aplicação 6 do curso, e estendido com a utilização de videoaulas na aplicação 7 (com estratégias alternativas para o ensino). No entanto, a falta de atenção à própria videoaula e a ansiedade dos estudantes parece influenciar alguns aspectos de seus aprendizados e suas percepções.

Como estratégia alternativa para o ensino, o jogo de cartas "Dilema IA" foi incluído para reforçar a questão de ética em IA, promovendo discussões saudáveis e maior interação entre os estudantes. Os resultados da aplicação desse jogo foram positivos quanto à usabilidade e aprendizado, além de ser observado pelos instrutores princípios de pensamento crítico e reflexivo nas discussões.

Outrossim, apesar dos estudantes conseguirem seguir as etapas do processo de desenvolvimento de ML, muitos tiveram dificuldades principalmente na análise da matriz de confusão, possivelmente devido a lacunas em conceitos lógico-matemáticos na formação escolar. Maior proximidade e explicações particulares foram adotadas como solução de mitigação, com o cuidado de manter a autonomia dos estudantes na interpretação, análises e prosseguimento nas atividades.

Uma síntese das limitações, consequências e soluções de mitigação no curso é apresentada na Figura 18.

Figura 18 – Diagrama Sankey das limitações, consequências e soluções no curso



Fonte: Elaborado pelo autor

Apesar dos vários desafios devido ao contexto de vulnerabilidade social, com as devidas adaptações e alternativas, foi possível proporcionar um aprendizado eficaz de conceitos básicos de *ML* para esses estudantes.

Dessa forma, as estratégias para o ensino de *ML* precisam considerar os vários desafios, bem como as consequências enfrentadas pelos estudantes em situação de vulnerabilidade social, buscando alternativas como soluções para atender às necessidades desses estudantes de forma inclusiva, igual e equitativa.

Ameaças a validade

Devido à natureza empírica do nosso estudo, vários fatores podem potencialmente impactar a validade de nossos resultados (Wohlin, 2012). Portanto,

foram identificadas as possíveis ameaças e aplicadas estratégias de mitigação para minimizar seu impacto nos resultados.

Validade de conclusão — Um desses fatores é o tamanho da amostra. No entanto, com 338 estudantes participando do estudo, sendo 230 estudantes do contexto de situação de vulnerabilidade social, foco central do estudo, o tamanho da amostra é considerado adequado para os resultados objetivados. As amostras comparáveis nas análises foram avaliadas quanto a sua potência estatística, estando todas adequadas ao padrão de que a potência de um teste para identificar diferenças estatísticas deve ser idealmente de pelo menos 80% (Cohen, 1988).

Outro fator que pode impactar a validade da conclusão é a coleta de dados e os modelos de avaliação. Para mitigar os riscos associados à avaliação de aprendizagem, empregamos uma rubrica estatisticamente validada com boa confiabilidade, evidenciada pelos coeficientes Ômega de McDonald ($\omega = 0.88$) e alfa de Cronbach ($\alpha = 0.78$). Esses indicadores garantem que as medidas sejam consistentes e confiáveis. Além disso, a elevada consistência interna reforça a validade das conclusões, demonstrando que os itens da rubrica estão efetivamente medindo o mesmo construto subjacente. Aliado a isso, o modelo para avaliação das percepções dTECT também demonstrou boa confiabilidade (Ômega de McDonald $\omega = 0.82$; alfa de Cronbach $\alpha = 0.76$) indicando uma consistência interna robusta. Dessa forma, a mesma rubrica para avaliação de aprendizagem e modelo para avaliar as percepções foram aplicados sistematicamente em todas as aplicações do curso, garantindo uniformidade e consistência no processo de avaliação e confiabilidade nas medidas obtidas.

Validade Interna — Em relação à validade interna, observamos uma taxa de evasão de 8.37% no grupo de estudantes em vulnerabilidade social e 9.2% no grupo de um contexto socioeconômico geral. Com isso, assumimos que a taxa de evasão foi baixa para ambos os contextos e não influenciou significativamente os resultados. No entanto, mesmo com uma baixa taxa de evasão, é essencial reconhecer que vários fatores atrelados principalmente ao contexto de vulnerabilidade social podem influenciar as taxas de evasão e podem afetar os resultados do estudo em certa medida.

Além disso, diferenças em relação ao ambiente de aprendizagem, modo instrucional e dinâmica dos instrutores podem representar ameaças internas à validade. O suporte adicional pode influenciar o engajamento e a aprendizagem dos

estudantes em certa medida, introduzindo variabilidade nos resultados. Quanto ao modo instrucional, uma das aplicações para o grupo de origem socioeconômica de contexto geral (AP1) foi realizada como parte das aulas regulares de uma escola, enquanto as demais aplicações foram extracurriculares. Outro fator está relacionado ao interesse, participação e motivação dos próprios estudantes: enquanto os estudantes do grupo de contexto socioeconômico geral (com exceção da AP1) participaram do curso voluntariamente por interesse no assunto, os estudantes do grupo de vulnerabilidade social participaram do curso, apesar de também de modo voluntário, porém como parte de sua admissão em um programa social que abrange outros cursos de tecnologia. Esses fatores devem ser considerados ao interpretar nossos resultados e projetar estudos futuros.

Validade Externa — Os resultados apresentados são baseados em dados coletados durante a aplicação do curso "ML para todos!", que incluiu estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio no Brasil. Como tal, a generalização de nossos resultados pode ser limitada e os resultados devem ser extrapolados com cautela para diferentes contextos ou populações. Embora a generalização de nossas descobertas possa ser limitada, consideramos estes achados valiosos para o campo, bem como para a orientação de projetos, implementações e aplicações de estratégias para o ensino de *ML* que compõe a construção de modelos instrucionais para estudantes em um contexto de situação de vulnerabilidade social. Isso é reforçado dada a escassez de pesquisas sobre educação em *ML* para esses estudantes e comparação com seus pares de diferentes origens socioeconômicas.

7 CONTRIBUIÇÕES

7.1 RESULTADOS DE PESQUISA

Com base nos resultados da avaliação das estratégias para o ensino de *ML* por meio das aplicações do curso "*ML para todos!*" apresentados nesta tese, é possível responder à questão de pesquisa: Como ensinar *Machine Learning* para o contexto de estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio de forma eficaz para possibilitar a aprendizagem de conceitos básicos de *ML* e, ao mesmo tempo, de forma motivadora e que promova uma boa experiência de aprendizagem?.

O modelo instrucional, suprido com as estratégias para o ensino de *ML* adotadas no curso "*ML para todos!*" demonstrou, por meio de análises estatísticas detalhadas no Capítulo 6, resultados positivos tanto na aprendizagem de conceitos básicos de *ML* quanto na percepção da experiência de aprendizagem por parte dos estudantes em situação de vulnerabilidade social.

Além disso, o modelo demonstrou que pode apoiar os estudantes em situação de vulnerabilidade social a aprender um processo de desenvolvimento de *ML* centrado no ser humano.

Quanto a experiência de aprendizagem, bem como a motivação dos estudantes, apesar de algumas diferenças identificadas entre estudantes de diferentes contextos socioeconômicos, os resultados foram positivos na qualidade geral, no aproveitamento, percepção do tempo de aula e desejo dos estudantes em querer aprender mais sobre *ML*. A similaridade nas percepções da dificuldade e avaliação geral do curso entre os grupos indica que o curso "*ML para todos!*" pode fornecer condições equitativas e igualitárias em termos de conteúdo e complexidade.

Ao responder à questão de pesquisa, as estratégias para o ensino adotadas no curso "*ML para todos!*" indicaram que podem conseguir oferecer uma abordagem eficaz para o ensino de *ML* no contexto de estudantes em situação de vulnerabilidade social. Isso demonstra que podem suportar o desenvolvimento e reconhecimento da aprendizagem de conceitos básicos de *ML* como um resultado de aprendizagem significativa, de forma motivadora e promovendo uma boa experiência.

Assim, conclui-se que o curso "*ML para todos!*" pode proporcionar que estudantes em situação de vulnerabilidade social aprendam conceitos básicos de *ML*, representando uma forma de ensinar essa área de maneira democrática e acessível, promovendo a equidade de oportunidades educacionais, fomentando a inclusão digital e reduzindo a desigualdade no acesso a esse conhecimento.

7.2 COMPARAÇÃO COM AS INICIATIVAS EXISTENTES

Ao comparar as estratégias para o ensino de *ML* para estudantes em situação de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio, com as poucas iniciativas encontradas na literatura, é possível destacar algumas semelhanças e diferenças importantes.

Tanto o curso "*ML para todos!*" aplicado quanto as iniciativas encontradas demonstraram que estudantes em vulnerabilidade social têm condições de aprender e aplicar conceitos básicos de *ML*, se envolvendo com êxito com conceitos como a tarefa de classificação de imagens e Redes Neurais Artificiais, alinhando-se aos achados de Araya et al. (2021) e Zhang et al. (2022).

A percepção de aprendizado dos estudantes em vulnerabilidade social do Ensino Fundamental e Médio sobre os conceitos básicos de IA/*ML* também foi positiva, corroborando com os achados de Zhang et al. (2022). Os resultados de aprendizagem demonstraram que os estudantes em situação de vulnerabilidade social, assim como os achados das iniciativas de Zhang et al. (2022) e Everson et al. (2022) conseguiram reconhecer vieses em IA e discutir implicações éticas.

Das aplicações do curso "*ML para todos!*" assim como as iniciativas de Araya et al. (2021), Eguchi (2021) e Everson et al. (2022), também foi percebida as limitações na infraestrutura para prover condições de ensino de *ML* para estudantes em situação de vulnerabilidade social. E assim como essas iniciativas, a solução de mitigação para o ensino de *ML* foi empregar algumas estratégias tais como: atividades desconectadas (p.ex. ao utilizar o jogo de cartas "Dilema IA"), o uso de ferramentas mais acessíveis (p.ex. ao utilizar o ambiente Google Teachable Machine) e o uso de dispositivos facilitados por parcerias (p.ex. a parceria entre a CnE/UFSC e o Programa PodeCrer/IVG).

As estratégias para o ensino de *ML* a partir do curso "*ML para todos!*", empregaram abordagens pedagógicas centradas no estudante utilizando métodos

instrucionais como atividades práticas, e como suporte tecnológico, o uso do ambiente visual Google Teachable Machine, assim como Araya et al. (2021), Eguchi (2021) e Zhang et al. (2022), reportando resultados positivos.

Um diferencial das estratégias para o ensino de *ML* adotado no curso é orientar os estudantes adotando um processo de desenvolvimento de *ML* centrado no ser humano, desde a coleta de dados até a avaliação do modelo. Enquanto as iniciativas encontradas focaram mais em atividades isoladas.

Outro diferencial das estratégias para o ensino de *ML* do curso é a inovação ao adotar a avaliação baseada em desempenho usando uma rubrica com boa confiabilidade e validade (Rauber et al., 2023). Isso permitiu identificar áreas específicas da aprendizagem de *ML*, em contraste com as iniciativas encontradas.

Nesta pesquisa foi realizada uma análise comparativa detalhada e abrangente entre estudantes de diferentes origens socioeconômicas quanto à aprendizagem, a percepção de aprendizado e a percepção da experiência de aprendizagem, considerando também fatores como sexo atribuído ao nascimento e etapa educacional. As análises em várias camadas não foram reportadas nas iniciativas encontradas. Em contraste com as iniciativas que não entraram nessa estrutura de análise, essa pesquisa soma as evidências das análises para sustentar uma compreensão mais ampla. Os resultados indicam que, de modo geral, os estudantes compreendem bem os aspectos de um processo de desenvolvimento de *ML* centrado no ser humano, independente da sua origem socioeconômica, sexo atribuído ao nascimento e etapa educacional.

Nossos resultados aprofundam os achados do estado da arte ao sugerir que a qualidade do material instrucional, a incorporação de atividades práticas e a abordagem pedagógica mais próxima ao estudante podem aumentar a percepção da compreensão dos conceitos de *ML*. Além disso, essas estratégias parecem estimular a confiança dos estudantes em desenvolver soluções de *IA/ML*, mesmo em períodos de tempo limitados.

Portanto, nosso estudo contribui para a área ao fornecer uma compreensão mais abrangente de como o contexto socioeconômico pode influenciar o ensino-aprendizagem de *ML*, com análises de vários fatores ainda não presentes na literatura.

7.3 CONTRIBUIÇÕES CIENTÍFICAS

A pesquisa avança o conhecimento sobre estratégias para o ensino de *ML* considerando o contexto de vulnerabilidade social de jovens estudantes, um tópico ainda pouco explorado na literatura. Como contribuições científicas resultantes dessa pesquisa estão:

- Um modelo instrucional, suprido com as estratégias para o ensino de *ML* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Médio. Esse modelo considera as especificidades e desafios do contexto de vulnerabilidade social.
- Definida uma proposta de um processo de desenvolvimento de *ML* centrado no ser humano, com base em Gresse von Wangenheim e von Wangenheim (2021) e Amershi (2019). Esse processo abrange as etapas básicas do desenvolvimento de um modelo de *ML* que fornece condições de desenvolver uma compreensão prática de como os modelos de *ML* são criados e aplicados nesta etapa educacional.
- O aprimoramento do curso "*ML* para todos!" a partir da sua primeira versão (*ML4ALL!* v1.0)(Gresse von Wangenheim et al., 2020) baseado em diretrizes curriculares e no processo de desenvolvimento de *ML* centrado no ser humano. O curso aborda conceitos básicos de *ML* de forma acessível e adota estratégias para o ensino de *ML* adequado ao contexto.
- Uma série de estudos de caso e quase-experimentos aplicando o curso "*ML* para todos!" em diferentes contextos socioeconômicos, incluindo estudantes em situação de vulnerabilidade social. Os resultados indicaram que os estudantes alcançaram os objetivos de aprendizagem, tendo condições de compreender e aplicar conceitos básicos de *ML* e proceder em um processo de desenvolvimento de modelos de *ML* centrado no ser humano.
- Achados por meio de comparações, mostrando que apesar de algumas diferenças pontuais e desafios, não houve prejuízo na aprendizagem ou experiência entre estudantes de diferentes origens socioeconômicas, sexo atribuído ao nascimento ou etapa educacional. Esses achados indicam que o curso pode ser eficaz para ensinar *ML* de forma motivadora. Achados elencando os desafios e soluções de mitigação no ensino de *ML* para

estudantes dos anos finais do Ensino Fundamental e Médio no contexto de vulnerabilidade social.

7.3.1 Publicações científicas

Durante este doutorado, os resultados parciais foram publicados como artigos em periódicos, artigos em conferências, capítulo de livro, relatórios técnicos, entre outros. O Quadro 53 apresenta as publicações científicas produzidas durante o período desta pesquisa com seus respectivos QUALIS. O QUALIS atualizado é fornecido pela CAPES com base no quadriênio 2017–2020, em que os graus (os chamados "estratos") estão em uma escala de 1 a 9 (A1, o mais alto; A2; A3; A4; B1; B2; B3; B4; C - não listado) (MEC, 2023). Não há QUALIS para capítulos de livros ou relatórios técnicos. A UFSC/PPGCC por meio da RESOLUÇÃO n.º 1/2018/PPGCC, DE 14 DE MAIO DE 2018 dispõe sobre o Sistema Interno de Classificação de Produção Científica (SICLAP) do PPGCC/UFSC e sua equivalência com o QUALIS, que resolve nos Art. 3º e Art. 4º:

Art. 3º O SICLAP enquadra os periódicos e os eventos científicos nos seguintes estratos indicativos de qualidade: A1, A2, B1, B2, B3, B4, B5 e C. O estrato A1 é o mais elevado, o estrato C é o menos elevado. O conjunto dos estratos A1 a B5 é referido por "Índice Geral" (IGeral) e o conjunto dos três estratos que indicam maior qualidade {A1, A2, B1} é referido por "Índice Restrito" (IRestrito) ou "estrato superior".

Art. 4º Os estratos a que se refere o Art. 3º são equivalentes, em termos de identificação de qualidade, àqueles definidos no sistema de classificação QUALIS da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). (Resolução n.º 1/2018/PPGCC, 2018).

Quadro 53 – Publicações científicas com os objetivos específicos da pesquisa

#	Referência	Objetivos específicos da pesquisa	SIC LAP	QUALIS 2017-2020	Status
Artigos em periódicos					
1	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M. F. et al. Machine Learning for All—Introducing Machine Learning in Middle and High School. <i>International Journal of Artificial Intelligence in Education</i> , 2023. https://doi.org/10.1007/s40593-022-00325-y	OE3; OE4	A1	A1	Publicado
2	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C. Findings on Teaching Machine Learning in High School: A Ten - Year Systematic Literature Review. <i>Informatics in Education</i> , 22(3), 421-440, 2023. doi:10.15388/infedu.2023.18	OE1	A1	A1	Publicado
3	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C. Teaching Computing to Middle and High School Students from a Low Socio-Economic Status Background: A Systematic Literature Review. <i>Informatics in Education</i> , 23(1), 179-222, 2024. doi:10.15388/infedu.2024.01	OE1	A1	A1	Publicado
4	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R.; SILVESTRE, M. F. Teaching Machine Learning to Middle and High School Students from a Low Socio-Economic Status Background. <i>Informatics in Education</i> , 2023. doi:10.15388/infedu.2024.13	OE2; OE4; OE5	A1	A1	Publicado
5	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; BORGATTO, A. F.; HAUCK, J. Exploring the Relationship between Learning of Machine Learning Concepts and Socioeconomic Status Background among Middle and High School Students: A Comparative Analysis. <i>ACM Transactions on Computing Education</i> , 2023.	OE4; OE5	A1	A1	Aceito
6	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; BORGATTO, A. F.; HAUCK, J. Comparing the Perceptions of Middle and High School Students from Different Socioeconomic Status Backgrounds on Learning Machine Learning. <i>Informatics in Education</i> , 2023.	OE4; OE5	A1	A1	Submetido
7	RAUBER, M. F.; GRESSE VON WANGENHEIM, C.; BARBETTA, P. A.; BORGATTO, A. F.; MARTINS, R. M. ; HAUCK, J. C. A Scale for Assessing the Learning of Machine Learning for Image Classification in Middle and High School Using the "ML4ALL" Course. <i>ACM Transactions on Computing Education</i> , 2023.	OE3	A1	A1	Submetido
8	RAUBER, M. F.; GRESSE VON WANGENHEIM, C.; BARBETTA, P. A.; BORGATTO, A. F.; MARTINS, R. M. ; HAUCK, J. C. R. Reliability and Validity of an Automated Model for Assessing the Learning of Machine Learning in Middle and High School: Experiences from the "ML for All" course. <i>Informatics in Education</i> , 2023. doi:10.15388/infedu.2024.10	OE3	A1	A1	Publicado
9	RAUBER, M. F.; GRESSE VON WANGENHEIM, C.; BORGATTO, A. F.; MARTINS, R. M. Uma Análise Detalhada do Desempenho de Aprendizagem ensinando Machine Learning na Educação Básica aplicando a Teoria de Resposta ao Item. <i>Revista Brasileira De Informática Na Educação</i> , 31, 1031-1056, 2023. https://doi.org/10.5753/rbie.2023.3442	OE3	B1	B1	Publicado
10	ARNDT, D. M.; MARTINS, R. M. ; GRESSE von WANGENHEIM, C.; von WANHEINHEIM, L.; RAUBER, M. F.; VON WANGENHEIM; HAUCK, J. C. Teaching AI Ethics with a Card Game to Middle and High School Students from a Low Socioeconomic Status Background. <i>International Journal of Artificial Intelligence in Education</i> , 2023.	OE4; OE5	A1	A1	Submetido
Artigos em conferências/simpósios/workshops					
11	MARTINS, R.M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M.; HAUCK, J. Eficácia das Metodologias Ativas e do Suporte Tecnológico no Ensino de Machine Learning na Educação Básica. <i>Anais do III Simpósio Brasileiro de Educação em Computação</i> , pp. 154-162, Porto Alegre: SBC, 2023. doi:10.5753/educomp.2023.228162	OE3; OE4	B4	B3	Publicado
12	MARTINS, R. M. ; FRANZ, A. C.; GRESSE VON WANGENHEIM, C.; HAUCK, J. VULCAN - Uma Camada Visual para Jupyter Notebook para o Ensino de Classificação de Imagem. <i>XIV Computer on the Beach</i> , Edição v. 14, pp. 387-394, 2023. doi:10.14210/cotb.v14.p387-394	-	B4	-	Publicado
13	MARTINS, R. M. ; ESPINDOLA, B. M.; ARAUJO, P. P.; GRESSE VON WANGENHEIM, C.; de CARVALHO PINTO, C. J.; CAMINHA, G. Development of a Deep Learning Model for the Classification of Mosquito Larvae Images. Naldi, M. C.; Bianchi, R. A. C. (eds) <i>Intelligent Systems. Brazilian Conference on Intelligent System. Lecture Notes in Computer Science</i> , vol 14197, Springer, Cham, 2023. https://doi.org/10.1007/978-3-031-45392-2_9	-	B1	A4	Publicado
14	MARTINS, R.M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M.; HAUCK, J.; SILVESTRE, M. Desafios e Soluções no Ensino de ML para Estudantes em Situação de Vulnerabilidade Social. In <i>Anais do XXIX Workshop de Informática na Escola</i> , pp. 1-12, Porto Alegre: SBC, 2023. doi:10.5753/wie.2023.232864	OE4; OE5	B1	A4	Publicado
15	RAUBER, M.; GRESSE VON WANGENHEIM, C.; BORGATTO, A.; MARTINS, R.M. Análise do desempenho de aprendizagem de Machine Learning na Educação Básica aplicando a Teoria de Resposta ao Item. <i>Anais do III Simpósio Brasileiro de Educação em Computação</i> , pp. 37-48, Porto Alegre: SBC, 2023. doi:10.5753/educomp.2023.228159	OE3	B4	B3	Publicado
16	CARDOZO, J.; MARTINS, R.M. ; GRESSE VON WANGENHEIM, C. ML4Teens - Introduzindo Machine Learning no Ensino Médio. <i>Anais do XXX Workshop sobre Educação em Computação</i> , pp. 204-214, Porto Alegre: SBC, 2022. doi:10.5753/wei.2022.222424	-	B1	A4	Publicado
17	RAUBER, M.; GARCIA, A.; GRESSE VON WANGENHEIM, C.; BORGATTO, A. F.; MARTINS, R.M. ; HAUCK, J. Confiabilidade e Validade da Avaliação do Desempenho de Aprendizagem de Machine Learning na Educação Básica. <i>Anais do XXXIII Simpósio Brasileiro de Informática na Educação</i> , pp. 1255-1267, Porto Alegre: SBC, 2022. doi:10.5753/sbie.2022.224688	OE3	A2	A3	Publicado
Capítulo de livro					
18	GRESSE VON WANGENHEIM, C.; da CRUZ ALVES, N.; RAUBER, M. F.; MARTINS, R. M. ; HAUCK, J. C. <i>Creating Mobile Applications with Artificial Intelligence Adopting Computational Action. Education, Development and Intervention: Toward Participatory and Integrated Solutions</i> , 2023.	-	-	-	Submetido
Registro de Software/Propriedade Intelectual					
19	GRESSE VON WANGENHEIM, C.; MARTINS, R. M. ; ARAUJO, P. P.; VON WANGENHEIM, L.; PINTO, C. J. de C. XôDengue. Certificado de Registro de Programa de Computador, Processo INPI No: BR512023003755-9.	-	-	-	Certificado
Relatórios técnicos					
20	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. Evaluation of the course Machine Learning for All Supplementary Material. WP_GQS_01_2022_v10_INCoD/GQS.09.2022.E, 2022.	OE3; OE4	-	-	Publicado
21	MARTINS, R. M. ; GRESSE VON WANGENHEIM, C. Findings on Teaching Machine Learning in High School. Supplementary Material, INCoD/GQS.09.2022.E, 2022.	OE4; OE5	-	-	Publicado
22	RAUBER, M. F.; MARTINS, R. M. ; GRESSE VON WANGENHEIM, C.; HAUCK, J. C. Modelo de Avaliação da Aprendizagem – Cursos Computação na Escola – Instituto Pe. Wilson Groh 2022. INCoD/GQS.012.2022.P, 2022.	OE3	-	-	Publicado

Fonte: Elaborado pelo autor

8 CONCLUSÃO

Esta pesquisa teve como objetivo propor estratégias para o ensino de *Machine Learning* para estudantes em situação de vulnerabilidade social nos anos finais do Ensino Fundamental e Ensino Médio. Para atingir esse objetivo, foi aprimorado o modelo instrucional suprido com as estratégias para o ensino do curso "*Machine Learning* para todos!". O curso "*ML* para todos!" foi por conseguinte aplicado em uma série de estudos de caso e quase-experimentos com estudantes de diferentes origens socioeconômicas no Brasil.

Das aplicações para os estudantes em situação de vulnerabilidade social, público alvo da pesquisa, os resultados revelaram que o modelo pode apoiar os estudantes a atingir os objetivos de aprendizagem do curso. Os estudantes demonstraram que compreenderam conceitos básicos de *ML* e executaram as principais etapas de um processo de desenvolvimento de *ML* centrado no ser humano. Além disso, muitos estudantes perceberam o curso como uma experiência de aprendizagem divertida e agradável, demonstrando o interesse em aprender mais sobre *ML*.

Análises detalhadas foram realizadas para comparar os resultados e percepções de aprendizagem com outros contextos socioeconômicos, etapas educacionais e sexo atribuído ao nascimento. Apesar de diferenças em alguns critérios específicos do desenvolvimento de *ML*, que merecem observações futuras, os resultados em geral foram satisfatórios. Dessa forma, o modelo instrucional suprido com as estratégias para o ensino de *ML* demonstram com as evidências coletadas não haver prejuízo de aprendizado em termos de origem socioeconômica, sexo atribuído ao nascimento ou etapa educacional. Em consequência, os resultados demonstram inclusão, igualdade e equidade no ensino de *ML* para esses estudantes.

Durante a aplicação do curso, foram observadas uma série de limitações e desafios enfrentados pelos estudantes em situação de vulnerabilidade social. Alguns exemplos incluem a falta de habilidades básicas de computação, além de dificuldades com motivação e interesse. Para mitigar esses desafios, foram adotadas estratégias alternativas de ensino. Uma abordagem pedagógica de maior proximidade com os estudantes e materiais instrucionais mais envolventes, como um jogo de cartas, foram incorporados ao curso. Essas soluções permitiram que os

estudantes alcançassem os resultados de aprendizagem esperados. Além disso, essas estratégias contribuíram para criar uma experiência de aprendizagem positiva para os estudantes em situação de vulnerabilidade.

Os resultados desta pesquisa somam evidências de que, apesar dos desafios enfrentados pelos estudantes em situação de vulnerabilidade social, é possível alcançar resultados positivos no ensino de *ML* para esse público. As estratégias propostas, incluindo a aproximação da tecnologia na prática aos estudantes, demonstraram ser eficazes para possibilitar a aprendizagem de conceitos básicos de *ML* de forma motivadora e promovendo uma boa experiência de aprendizagem.

Esses achados ressaltam a importância de desenvolver estratégias para o ensino que promovam ambientes de aprendizagem inclusivos e motivadores para todos os estudantes, independentemente de sua origem socioeconômica, considerando suas características e particularidades.

Dessa forma, ao compartilhar as percepções, abordagens e achados desta pesquisa, espera-se contribuir para a proposição de estratégias eficazes para o ensino de *ML* a estudantes em situação de vulnerabilidade social. Busca-se, assim, fomentar o diálogo e ações sobre educação igual, equitativa e inclusiva nessa área, destacando práticas e lições aprendidas a partir das experiências desta pesquisa, que promovam o acesso justo e a qualidade do ensino de *ML* para os jovens estudantes.

8.1 TRABALHOS FUTUROS

Como pesquisas futuras, sugere-se investigar outros fatores que podem potencialmente influenciar os resultados de aprendizagem e percepções de experiências de aprendizagem dos estudantes no campo da *IA/ML*, como o grau de voluntariedade, influência de necessidades específicas dos estudantes em vulnerabilidade social, grau de autonomia, autoconfiança dos estudantes em explicar o que aprendeu para amigos, e influência dos instrutores no ensino.

Com a rápida expansão e evolução da *IA/ML*, as estratégias para o ensino para o curso "*Machine Learning* para todos" estão em aberto e em constante aprimoramento e atualização. Sugere-se o incremento de demonstrações para interação com potencialidades de *IA* na aula 1 do curso (Motivação), como p.ex.

chatbots e IA generativa, e a disponibilidade de mais tempo para discussões de ética em IA na aula 6 (Questões éticas e oportunidades), promovendo maior interação entre os estudantes e seu pensamento reflexivo.

Trabalhos futuros podem ainda explorar a aplicação do curso "*ML para todos!*" em contextos de vulnerabilidade social de outras regiões, expandir o ensino de *ML* para estudantes acima de 18 anos e/ou que cursam ensino superior, e verificar diferenças relacionadas ao modo instrucional.

Os resultados promissores dessa pesquisa motivam a continuar o desenvolvimento de cursos de *ML*, avançando ao estágio "criar" (do ciclo Usar-Modificar-Criar) para permitir que os estudantes em situação de vulnerabilidade social criem seu próprio modelo de *ML* e resolvam problemas que considerem relevantes. Em consequência, análises comparativas entre os resultados de aprendizagem e percepções entre os estágios "usar" e "criar" podem ser importantes para revelar a evolução do processo de aprendizagem e motivação dos estudantes em situação de vulnerabilidade social no aprendizado de *ML*.

Além disso, estudos longitudinais podem fornecer entendimentos sobre o desenvolvimento da criatividade, pensamento crítico e das habilidades em *ML* ao longo do tempo, contribuindo para o avanço das práticas educacionais nessa área.

REFERÊNCIAS

- AI4ALL. **AI4ALL**. 2023. Disponível em: <https://ai-4-all.org/>. Acesso em: 26 mar. 2024.
- AI4K12. **Artificial Intelligence (AI) for K-12**. 2020. Disponível em: <https://ai4k12.org/>. Acesso em: 26 mar. 2024.
- AL-SAHAF, H., et al. A survey on evolutionary machine learning. **Journal of the Royal Society of New Zealand**, [S.l.], v. 49, n. 2, p. 205–228, 2019.
- ALI, Safinah; KUMAR, Vishesh; BREAZEAL, Cynthia. AI audit: a card game to reflect on everyday AI systems. In: **Proceedings of the AAAI Conference on Artificial Intelligence**, Vol. 37, AAAI Press, Article 1828, p. 15981–15989, 2023.
- ALONSO, J. M. Teaching explainable artificial intelligence to high school students. **International Journal of Computational Intelligence Systems**, v. 13, n. 1, p. 974–987, 2020.
- ALPAYDIN E. **Introduction to machine learning**. 3rd ed. Cambridge, MA, USA: The MIT Press, 2014.
- AMERSHI, S., et al. Software engineering for machine learning: A case study. In: **International Conference on Software Engineering: Software Engineering in Practice**, 2019, Montreal, QC, Canada, 2019. p. 291–300.
- ANDERSON, L. W.; KRATHWOHL, D. R. (Eds.). **A taxonomy for learning, teaching, and assessing: A revision of Bloom's taxonomy of educational objectives**. [S.l.]: Longman, 2001.
- AMAZON. **Amazon Machine Learning Lens: AWS Well-Architected Framework**. Documentation, 2021. Disponível em: <https://docs.aws.amazon.com/wellarchitected/latest/machine-learning-lens/wellarchitected-machine-learning-lens.pdf#welcome>. Acesso em: 26 mar. 2024.
- AMERICAN PSYCHOLOGY ASSOCIATION — APA. **Education and Socioeconomic Status**. 2023. Disponível em: <https://www.apa.org/pi/ses/resources/publications/education>. Acesso em: 30 mar. 2024.
- AMERICAN PSYCHOLOGY ASSOCIATION — APA. **Publication manual of the American Psychological Association: The Official Guide to APA Style**. 7. ed. 2020.
- ARAYA, R.; ISODA, M.; VAN DER MOLEN MORIS, J. Developing Computational Thinking Teaching Strategies to Model Pandemics and Containment Measures. **International Journal of Environmental Research and Public Health**, [S.l.], v. 18, n. 23, p. 12520, 2021.
- ARNDT, D. M.; MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; VON WANGENHEIM, L.; RAUBER, M. F.; HAUCK, J. C. Teaching AI Ethics with a Card Game to Middle and High School Students from a Low Socioeconomic Status Background. **Informatics in Education**, 2024. <submetido>.
- AVVISATI, F. **The measure of socio-economic status in PISA: a review and some suggested improvements**. Large-scale Assessments in Education, [S.l.], v. 8, n. 8, p. 2-37, 2020.
- BARDIN, L. **Análise de conteúdo**. São Paulo: Edições 70, 2011.
- BASILI, V. R.; CALDIERA, G.; ROMBACH, H. D. **Goal Question Metric Paradigm**. In: Encyclopedia of Software Engineering. [S.l.]: Wiley, 1994.
- BEGEL, A.; GARCÍA, D. D.; WOLFMAN, S. A. Kinesthetic learning in the classroom. In: **Proceedings of the 35th SIGCSE Technical Symposium on Computer Science Education**, Norfolk, VA, USA, p. 183-184, 2004.

BELLETTINI, C., et al. Informatics education in Italian secondary school. **ACM Transactions on Computing Education**, [S.l.], v. 14, n. 2, p. 15.1–15.6, 2014.

BLOOM, B. S., et al. **Taxonomy of educational objectives: The classification of educational goals, Handbook I: Cognitive domain**. New York: David McKay Company, 1956.

BHATIA, N. **Using Transfer Learning, Spectrogram Audio Classification, and MIT App Inventor to Facilitate Machine Learning Understanding**. 2020. M. Eng thesis, Elect. Eng. Comput. Sci., Massachusetts Institute of Technology, Cambridge, MA, USA.

BILSTRUP, K. K.; KASPERSEN, M. H.; PETERSEN, M. G. Staging Reflections on Ethical Dilemmas in Machine Learning: A Card-Based Design Workshop for High School Students. In: **Proceedings of the ACM Designing Interactive Systems Conference**. Eindhoven, Netherlands: ACM, 2020. p. 1211–1222.

BRANCH, R. **Instructional design: The ADDIE approach**. 2nd ed. Athens: Springer, 2009.

BRANCH UP PTY LTD. **LevelUp Quest: Turn courses into exciting adventures with Level Up Quest**. [S.l.], 2024. Disponível em: https://www.levelup.plus/quest/?ref=xp_notice. Acesso em: 28 mar. 2024.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. **Lei Geral de Proteção de Dados Pessoais**. Diário Oficial da União, Brasília, DF, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm. Acesso em: 27 mar. 2024.

BRASIL. Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. **Índice de Desenvolvimento da Educação Básica - IDEB 2021: Resultados do Ensino Fundamental Regular e Ensino Médio Regular**. Brasília: Inep, 2022. Disponível em: https://download.inep.gov.br/educacao_basica/portal_ideb/planilhas_para_download/2021/divulgacao_brasil_ideb_2021.zip. Acesso em: 28 mar. 2024.

BROOKFIELD, S. D.; PRESKILL, S. **Discussion as a way of teaching: Tools and techniques for university teachers**. [S.l.]: McGraw-Hill Education (UK), 1999.

BURGSTEINER, H.; KANDLHOFER, M.; STEINBAUER, G. IRobot: Teaching the Basics of Artificial Intelligence in High Schools. In: **Proceedings of the Sixth Symposium on Educational Advances in Artificial Intelligence**. Phoenix, AZ, USA: [s.n.], 2016.

BYKER, E. ICT Oriented Toward Nyaya: Community Computing in India's Slums. **International Journal of Education and Development using ICT**, v. 10, n. 2, p. 19–28, 2014.

CARNEY, Michelle et al. Teachable Machine: Approachable Web-Based Tool for Exploring Machine Learning Classification. In: **CHI Conference on Human Factors in Computing Systems**, Honolulu, HI, USA, p. 1–8, 2020.

CASAL-OTERO, L.; CATALA, A.; FERNÁNDEZ-MORANTE, C. et al. AI literacy in K-12: a systematic literature review. **International Journal of STEM Education**, v. 10, n. 29, 2023.

CHAFFEE, J. **Thinking Critically**. 12th ed. [S.l.]: Cengage Learning, 2019.

CHUA, X. H.; CHUA, E.; SOO, K. Budding Data Scientists Hackathon. **Special Interest Group on Knowledge Discovery in Data Explorations Newsletter**, v. 21, n. 1, p. 38–40, 2019.

CNE. **Computação na Escola**. 2024a. Disponível em: <https://computacaonaescola.ufsc.br/>. Acesso em: 21 mar. 2024.

CNE. **CodeMaster - Machine Learning para Todos**. 2024b. Disponível em: <http://apps.computacaonaescola.ufsc.br/codemaster/>. Acesso em: 11 abr. 2024.

CNE. **Jogo de cartas "Dilema IA"**. 2024c. Disponível em: <http://computacaonaescola.paginas.ufsc.br/dilema-ia-jogo-de-cartas/>. Acesso em: 11 abr. 2024.

CODE.ORG. **Hour of Code**. 2024. Disponível em: <https://hourofcode.com/br/learn>. Acesso em: 05 mai. 2024.

CODE.ORG. **Ethics & AI: Equal Access and Algorithmic Bias**. [S. l.: s. n.], 2020. Video (4 min). Disponível em: <https://www.youtube.com/watch?v=tJQSyZBUAew>. Acesso em: 30 mar. 2024.

COGBOTS. **UC San Diego — CogBots-AIBot**. Disponível em: <https://sites.google.com/ucsd.edu/airoboticswithcogbots/home>. Acesso em: 30 abr. 2024.

CONDE, M. A., et al. Promoting Computational Thinking in K-12 students by applying unplugged methods and robotics. In: **Proceedings of the 5th International Conference on Technological Ecosystems for Enhancing Multiculturality**. Cádiz, Spain: [s.n.], 2017. p. 1–6.

COHEN, J. **Statistical power analysis for the behavioral sciences**. 2nd ed. Hillsdale, NJ: Lawrence Erlbaum Associates, 1988.

COZMO. **Digital Dream Labs — Cozmo**. Disponível em: <https://www.digitaldreamlabs.com/pages/cozmo>. Acesso em: 30 abr. 2024.

CRONJÉ, J. Paradigms Regained: Toward Integrating Objectivism and Constructivism in Instructional Design and the Learning Sciences. **Educational Technology Research and Development**, [S.l.], v. 54, n. 4, p. 387–416, 2006.

CSTA. **K–12 Computer Science Framework**. 2017. Disponível em: <http://www.k12cs.org/>. Acesso em: 26 mar. 2024.

DESTIN, M.; HANSELMAN, P.; BUONTEMPO, J.; TIPTON, E.; YEAGER, D. S. Do Student Mindsets Differ by Socioeconomic Status and Explain Disparities in Academic Achievement in the United States? **AERA Open**, [S.l.], v. 5, n. 3, 2019.

DHRUV, A.; PATEL, R.; DOSHI, N. Python: The Most Advanced Programming Language for Computer Science Applications. In: **Proceedings of the International Conference on Culture Heritage, Education, Sustainable Tourism, and Innovation Technologies**. Online. 2021. p. 292–299.

DRUGA, S. Growing up with AI Cognimates: From coding to teaching machines. 2018. Dissertation (Doctorate) – Massachusetts Institute of Technology, Cambridge, MA.

DUDLEY, J. J.; KRISTENSSON, P. O. A Review of User Interface Design for Interactive Machine Learning. **ACM Transactions on Interactive Intelligent Systems**, v. 1, n. 1, art. 1, p. 1–37, Mar. 2018.

EF EPI. **English proficiency index report 2023**. [S.l.]: Education First, 2023. Disponível em: <https://www.ef.com.br/assetscdn/WIBlwq6RdJvcD9bc8RMd/cefcom-epi-site/reports/2023/ef-epi-2023-portuguese.pdf>. Acesso em: 28 mar. 2024.

EGUCHI, A. AI-Robotics and AI Literacy. In: **Education in & with Robotics to Foster 21st-Century Skills: Proceedings of Conference Edurobotics, Studies in Computational Intelligence**. Online: [s.n.], 2021. p. 75–89.

EKWUEME, C.; EKON, E. E.; EZENWA-NEBIFE, D. The Impact of Hands-On-Approach on Student Academic Performance in Basic Science and Mathematics. **Higher Education Studies**, [S.l.], v. 47, n. 5, 2015.

ESSINGER, S. D.; ROSEN, G. L. An introduction to machine learning for students in secondary education. In: **Proceedings of Digital Signal Processing and Signal Processing Education Meeting**, Sedona, AZ, USA, p. 243-248, 2011.

ESTEVEZ, J.; GARATE, G.; GRAÑA, M. Gentle Introduction to Artificial Intelligence for High-School Students Using Scratch. **IEEE Access**, [S.l.], v. 7, p. 179027–179036, 2019.

EVERSON, J.; KIVUVA, F. M.; KO, A. J. "A Key to Reducing Inequities in Life, AI, is by Reducing Inequities Everywhere First": Emerging Critical Consciousness in a Co-Constructed Secondary CS Classroom. In: **Proceedings of the 53rd ACM Technical Symposium on Computer Science Education**. Providence, RI, USA: [s.n.], 2022. p. 209–215.

FIELD, A. **Discovering Statistics Using IBM SPSS Statistics**. 5th ed. [S.l.]: SAGE Publications, 2018.

FINAU, J. **How socioeconomic status affects students**. 2021. Capstone project, Liberal Studies Program, California State University. ScholarWorks. Disponível em: <https://scholarworks.calstate.edu/downloads/qv33s2864>. Acesso em: 30 mar. 2024.

FISHER, Ronald A. On the interpretation of χ^2 from contingency tables, and the calculation of P. **Journal of the Royal Statistical Society**, [S.l.], v. 85, n. 1, p. 87–94, 1922.

FREIRE, P. **Pedagogia do Oprimido**. Rio de Janeiro: Paz e Terra, 1968.

GARNELI, V.; GIANNAKOS, M. N.; CHORIANOPOULOS, K. Computing education in K-12 schools: A review of the literature. In: **IEEE Global Engineering Education Conference**. Tallinn, Estonia: [s.n.], 2015. p. 543–551.

GILLIES, M. et al. Human-Centered Machine Learning. In: **Proceedings of the Conference on Human Factors in Computing Systems**, ACM, San Jose, CA, USA, p. 3558-3565, 2016.

GONG, X.; WU, Y.; YE, Z.; LIU, X. Artificial Intelligence course design: iSTREAM-based visual cognitive smart vehicles. In: **2018 IEEE Intelligent Vehicles Symposium (IV)**, Changshu, China, p. 1731–1735, 2018.

GOODFELLOW et al. Generative Adversarial Networks. **arXiv:1406.2661 [stat.ML]**, 2014.

GOOGLE. **Google Teachable Machine**. 2023a. Disponível em: <https://teachablemachine.withgoogle.com/>. Acesso em: 26 mar. 2024.

GOOGLE. **Google Colab**. 2023b. Disponível em: <https://colab.research.google.com/>. Acesso em: 26 mar. 2024.

GOOGLE. **Hum to Search - Now in the Google app**. Disponível em: <https://www.youtube.com/watch?v=DW61PpKJGm8>. Acesso em: 11 mai. 2024.

GOOGLE A. I. EXPERIMENT. **Quick Draw!**. 2022. Disponível em: <https://quickdraw.withgoogle.com>. Acesso em: 26 mar. 2024.

GOOGLE DEVELOPERS. **Machine Learning Glossary**. 2022. Disponível em: <https://developers.google.com/machine-learning/glossary?hl=en>. Acesso em: 26 mar. 2024.

GRESSE VON WANGENHEIM, C.; DA CRUZ ALVES, N.; RAUBER, M. F.; HAUCK, J. C. R.; YETER, I. H. A Proposal for Performance-based Assessment of the Learning of Machine Learning Concepts and Practices in K-12. **Informatics in Education**, [S.l.], v. 21, n. 3, 2022.

GRESSE VON WANGENHEIM, C.; HAUCK, J. C. R.; PACHECO, F. S.; BUENO, M. F. B. Visual tools for teaching machine learning in K-12: A ten-year systematic mapping. **Education and Information Technologies**, [S.l.], v. 26, n. 5, p. 5733–5778, 2021.

GRESSE VON WANGENHEIM, C.; VON WANGENHEIM, A. **Overview on a human-centric interactive ML process for teaching ML in K-12**. Working Paper WP_GQS_01_2021_v10, GQS/INCoD/UFSC, 2021.

GRESSE VON WANGENHEIM, C.; MARQUES, L. S.; HAUCK, J. C. R. Machine Learning for All – Introducing Machine Learning in K-12. **SocArXiv**, [S.l.], p. 1–10, 2020.

GRESSE VON WANGENHEIM, C.; PETRI, G.; ZIBETTI, A. W.; BORGATTO, A. F.; HAUCK, J. C. R.; PACHECO, F. S.; FILHO, R. M. DETECT: A model for the evaluation of instructional units for teaching computing in middle school. **Informatics in Education**, [S.l.], v. 16, n. 2, 2017.

GRETTER, S.; YADAV, A.; SANDS, P.; HAMBRUSCH, S. Equitable Learning Environments in K-12 Computing: Teachers' Views on Barriers to Diversity. **ACM Transactions on Computing Education**, [S.l.], v. 19, n. 3, Article 24, 2019.

HAGEN, T., et al. Teaching Practical Machine Learning Concepts to Professionals and Students: An Integrated and Interdisciplinary Qualification Project. In: **IEEE Frontiers in Education Conference (FIE)**. Uppsala, Sweden: [s.n.], 2020.

HASH BITS. **Object Detector**. 2018. Disponível em: <https://play.google.com/store/apps/details?id=com.tecomen.android.objectdetector&hl=pt&gl=US>. Acesso em: 20 mar. 2024.

HAYS, L.; JURKOWSKI, O.; SIMS, S.K. ChatGPT in K-12 Education. **TechTrends**, v. 68, p. 281–294, 2024.

HERNÁNDEZ, V. A. S., et al. A Practical Tutorial for Decision Tree Induction: Evaluation Measures for Candidate Splits and Opportunities. **ACM Computing Surveys**, [S.l.], v. 54, n. 1, 2021.

HSU, T.-C.; ABELSON, H.; VAN BRUMMELEN, J. The Effects of Applying Experiential Learning into the Conversational AI Learning Platform on Secondary School Students. **The International Review of Research in Open and Distributed Learning**, v. 23, n. 1, p. 82-103, 2022.

HSU, T.-C., et al. How to learn and how to teach computational thinking: Suggestions based on a review of the literature. **Computers & Education**, [S.l.], v. 16, p. 296-310, 2018.

HUANG, CHAO-JUNG., et al. Developing a medical artificial intelligence course for high school students. In: **Proceedings of SPIE — the International Forum on Medical Imaging in Asia**. Taipei, Taiwan: [s.n.], 2021. p. 11792.

HUBA, M. E.; FREED, J. E. **Learner-Centered Assessment on College Campuses: Shifting the Focus from Teaching to Learning**. Allyn and Bacon, 2000.

IBM. **What is machine learning (ML)?** 2024a. Disponível em: <https://www.ibm.com/topics/machine-learning>. Acesso em: 8 abr. 2024.

IBM. **What is deep learning?** 2024b. Disponível em: <https://www.ibm.com/topics/deep-learning>. Acesso em 25 abr. 2024.

IBM. **IBM SkillsBuild**. 2023. Disponível em: <https://skillsbuild.org/>. Acesso em: 26 mar. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA — IBGE. **Síntese de Indicadores Sociais**. 2023. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9221-sintese-de-indicadores-sociais.html?=&t=downloads>. Acesso em: 21 mar. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA — IBGE. **Pesquisa Nacional por Amostra de Domicílios — PNAD 2023**. 2023. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/educacao/9173-pesquisa-nacional-por-amostra-de-domicilio-continua-trimestral.html?=&t=destaques>. Acesso em: 26 mar. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA — IBGE. **Pesquisa Nacional por Amostra de Domicílios — PNAD 2019**. 2019. Disponível em: https://agenciadenoticias.ibge.gov.br/media/com_mediaibge/arquivos/89ec0c1b18b88b2e1b5ad7123becb548.pdf. Acesso em: 21 mar. 2024.

ISO/IEC DIS 5338. **Information technology — Artificial intelligence — AI system life cycle processes**. 2023a. Disponível em: <https://www.iso.org/standard/81118.html>. Acesso em: 26 mar. 2024.

ISO/IEC 42001. **Information technology — Artificial intelligence — Management system**. 2023b. Disponível em: <https://www.iso.org/standard/81230.html>. Acesso em: 03 abr. 2024.

ITWORX Education. **ITWorx Education**. 2023. Disponível em: <https://itworx.education/>. Acesso em: 26 mar. 2024.

IVG. **Pode Crer Program: 2022 Social Impact Report**. 2022. Disponível em: <https://vilsongroh.org/>. Acesso em: 26 mar. 2024.

JAGANNATHAN, R. K.; KOMIVES, C. Teaching by Induction: Project-Based Learning for Silicon Valley. **Journal of Engineering Education Transformations**, Special Issue No. 1, v. 33, 2019.

JONASSEN, D. H. Objectivism versus constructivism: Do we need a new philosophical paradigm? **Educational Technology Research and Development**, [S.l.], v. 39, p. 5–14, 1991.

JONES, B. F.; RASMUSSEN, C. M.; MOFFITT, M. C. **Real-life problem solving: A collaborative approach to interdisciplinary learning**. [S.l.]: American Psychological Association, 1997.

JUPYTER. **Jupyter Notebook**. Disponível em: <https://jupyter.org/>. Acesso em: 30 abr. 2024.

KAMIRI, J.; MARIGA, G. Research Methods in Machine Learning: A Content Analysis. **International Journal of Computer and Information Technology**, [S.l.], v. 10, n. 2, p. 2279–0764, 2021.

KANDLHOFER, M. et al. Enabling the Creation of Intelligent Things: Bringing Artificial Intelligence and Robotics to Schools. **Proceedings of the IEEE Frontiers in Education Conference**, Covington, KY, USA, 2019, p. 1-5.

KARALEKAS, G.; VOLOGIANNIDIS, S.; KALOMIROS, J. Teaching Machine Learning in K–12 Using Robotics. **Education Sciences**, v. 13, n. 1, p. 67, 2023.

KEMMIS, S.; MCTAGGART, R.; NIXON, R. **The Action Research Planner: Doing Critical Participatory Action Research**. Springer, 2014.

KIM, J.; RYU, J. Analysis of Educational Effects according to the Teaching Methods in Online-Education for Underprivileged Elementary Students. In: **Proceedings of the 2017 International Conference on Education and E-Learning**. Bangkok, Thailand: [s.n.], 2017. p. 47–49.

LANGENKAMP, A. G.; CARBONARO, W. How school socioeconomic status affects achievement growth across school transitions in early educational careers. **Sociology of Education**, v. 91, n. 4, p. 358–378, 2018.

LAO, N. **Reorienting Machine Learning Education Towards Tinkerers and ML-Engaged Citizens**. 2020. PhD dissertation, Elect. Eng. Comput. Sci., Massachusetts Institute of Technology, Cambridge, MA, USA.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, [S.l.], v. 521, p. 436–444, 2015.

LECUN, Y. The Power and Limits of Deep Learning. **Research Technology Management**, [S.l.], v. 61, n. 6, p. 22–27, 2018.

LEE, S. J.; KWON, K. A systematic review of AI education in K-12 classrooms from 2018 to 2023: Topics, strategies, and learning outcomes. **Computers and Education: Artificial Intelligence**, v. 6, 2024.

LEE, I. et al. Computational thinking for youth in practice. **ACM Inroads**, [S.l.], v. 2, n. 1, p. 32–37, 2011.

LEGO. **LEGO Mindstorms Inventor Kit**. Disponível em: <https://www.lego.com/en-gr/product/robot-inventor-51515>. Acesso em: 30 abr. 2024.

LEITNER, M. et al. Designing game-based learning for high school artificial intelligence education. **International Journal of Artificial Intelligence in Education**, v. 33, n. 2, p. 384-398, 2023.

LI, S.; XU, Q.; XIA, R. Relationship Between SES and Academic Achievement of Junior High School Students in China: The Mediating Effect of Self-Concept. **Frontiers in Psychology**, [S.l.], v. 10, p. 1664–1078, 2020.

LI, Y. Research and Application of Deep Learning in Image Recognition. In: **Proceedings of the IEEE International Conference on Power, Electronics and Computer Applications**. Shenyang, China: [s.n.], 2022. p. 994–999.

LIU, H. Application of Artificial Neural Network for Daily Evaporation Forecasting Using Weather Data. In: **4th International Conference on Advances in Artificial Intelligence**. London, United Kingdom: [s.n.], 2020. p. 67–71.

LOMBARDI, P. **Instructional Methods, Strategies and Technologies to Meet the Needs of All Learners**. Pressbooks, 2019.

LONG, D.; MAGERKO, B. What is AI Literacy? Competencies and Design Considerations. In: **Proceedings of the Conference on Human Factors in Computing Systems**. Honolulu, HI, USA: [s.n.], 2020. p. 1–6.

LYE, S. Y.; KOH, J. H. L. Review on teaching and learning of computational thinking through programming: What is next for K-12?. **Computers in Human Behavior**, [S.l.], v. 41, p. 51–61, 2014.

LYTLE, N. et al. Use, Modify, Create: Comparing Computational Thinking Lesson Progressions for STEM Classes. In: **Proceedings of the ACM Conference on Innovation and Technology in Computer Science Education**. Aberdeen, Scotland: [s.n.], 2019.

MANN, H. B.; WHITNEY, D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. **The Annals of Mathematical Statistics**, [S.l.], v. 18, n. 1, p. 50–60, 1947.

MARC, L., et al. Understanding innovative pedagogies: Key themes to analyze new approaches to teaching and learning. **OECD Education Working Papers**, Paris, France, n. 172, 2018.

MARQUES, L. S.; GRESSE VON WANGENHEIM, C.; HAUCK, J. C. R. Teaching Machine Learning in School: A Systematic Mapping of the State of the Art. **Informatics in Education**, [S.l.], v. 19, n. 2, p. 28–321, 2020.

MARTINS-PACHECO, L. H.; DA CRUZ ALVES, N.; GRESSE VON WANGENHEIM, C. Educational Practices in Computational Thinking: Assessment, Pedagogical Aspects, Limits, and Possibilities: A Systematic Mapping Study. In: LANE H.C.; ZVACEK S.; UHOMOIBHI J. (eds) **Computer Supported Education. Communications in Computer and Information Science**, v. 1220. Cham: Springer, 2020.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C. Teaching Computing to Middle and High School Students from a Low Socio-Economic Status Background: A Systematic Literature Review. **Informatics in Education**, [S.l.], v. 23, n. 1, p. 179–222, 2024.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C. Findings on Teaching Machine Learning in High School: A Ten - Year Systematic Literature Review. **Informatics in Education**, [S.l.], v. 22, n. 3, p. 421–440, 2023.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; BORGATTO, A. F.; HAUCK, J. C. R. Exploring the Relationship between Learning of Machine Learning Concepts and Socioeconomic Status Background among Middle and High School Students: A Comparative Analysis. **ACM Transactions on Computing Education**, 2024a. <submetido>

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; BORGATTO, A. F.; HAUCK, J. C. R. Comparing the Perceptions of Middle and High School Students from Different Socioeconomic Status Backgrounds on Learning Machine Learning. **Informatics in Education**, 2024b. <submetido>

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R. Machine Learning for All!—Introducing Machine Learning in Middle and High School. **International Journal of Artificial Intelligence in Education**, 2023a.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R.; SILVESTRE, M. F. Teaching Machine Learning to Middle and High School Students from a Low Socio-Economic Status Background. **Informatics in Education**, 2023b.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R. Eficácia das Metodologias Ativas e do Suporte Tecnológico no Ensino de Machine Learning na Educação Básica. In: **Anais do III Simpósio Brasileiro de Educação em Computação**. Porto Alegre: SBC, 2023c. p. 154–162.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R.; SILVESTRE, M. F. Desafios e Soluções no Ensino de ML para Estudantes em Situação de Vulnerabilidade Social. In: **Anais do XXIX Workshop de Informática na Escola**. Porto Alegre: SBC, 2023d. p. 1–12.

MARTINS, R. M.; GRESSE VON WANGENHEIM, C.; RAUBER, M. F.; HAUCK, J. C. R. **Avaliação do Ensino de Machine Learning — Cursos Computação na Escola — Instituto Pe. Vilson Groh 2022**. INCoD/GQS.xx.2023.P, 2023e. <não publicado>

MARIESCU-ISTODOR, R.; JORMANAINEN, I. Machine Learning for High School Students. In: **Proceedings of the 19th Koli Calling International Conference on Computing Education Research**, Koli, Finland, 2019, Article 10, p. 1–9.

MATHEWSON, K. W. A Human-Centered Approach to Interactive Machine Learning. **arXiv**, 1905.06289v1 [cs.HC], 2019. Disponível em: <https://arxiv.org/abs/1905.06289>.

MCMILLAN, J. H. Classroom Assessment. In: WRIGHT, J. D. (Ed.). **International Encyclopedia of the Social & Behavioral Sciences**. 2nd ed. [S.l.]: Elsevier, 2015. p. 819–824.

MICROSOFT. **.NET — Machine learning glossary of important terms**. 2021. Disponível em: <https://learn.microsoft.com/en-us/dotnet/machine-learning/resources/glossary>. Acesso em: 29 abr. 2024.

MINISTÉRIO DA EDUCAÇÃO (MEC). **Programa Pé-de-meia**. 2024. Disponível em: <https://www.gov.br/mec/pt-br/pe-de-meia>. Acesso em: 21 mar. 2024.

MINISTÉRIO DA EDUCAÇÃO (MEC). **Parecer CNE/CEB n.º 2/2022 , Normas sobre Computação na Educação Básica — Complemento à BNCC**. 2022. Disponível em: http://portal.mec.gov.br/index.php?option=com_docman&view=download&alias=236791-anexo-ao-par-ecer-cneceb-n-2-2022-bncc-computacao&category_slug=fevereiro-2022-pdf&Itemid=30192. Acesso em: 30 mar. 2024.

MINISTÉRIO DA EDUCAÇÃO (MEC). **Base Nacional Comum Curricular**. 2017. Disponível em: <http://basenacionalcomum.mec.gov.br>. Acesso em: 26 mar. 2024.

MISHRA, P.; KOEHLER, M. J. Technological Pedagogical Content Knowledge: A Framework for Teacher Knowledge. **Teachers College Record**, v. 108, n. 6, p. 1017–1054, 2006.

MIT. **MIT App Inventor**. 2024a. Disponível em: <https://appinventor.mit.edu/>. Acesso em: 30 abr. 2024.

MIT. **MIT Scratch**. 2024b. Disponível em: <https://scratch.mit.edu/>. Acesso em: 06 mai. 2024.

MIT. **AI + Ethics Curriculum for Middle School project**. 2019. Disponível em: <https://www.media.mit.edu/projects/ai-ethics-for-middle-school/overview/>. Acesso em: 05 mai. 2024.

MIT. **MIT Moral Machine**. 2017. Disponível em: <https://www.moralmachine.net/>. Acesso em: 26 mar. 2024.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill-Education, 1997.

MOBASHER, B. et al. Data Science Summer Academy for Chicago Public School Students. **ACM SIGKDD Explorations Newsletter**, v. 21, n. 1, 2019.

MORRISON, G. R.; ROSS, S. M.; MORRISON, J. R.; KALMAN, H. K. **Designing effective instruction**. 8. ed. Wiley, 2019.

NGUYEN, G., et al. Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. **Artificial Intelligence Review**, [S.l.], v. 52, p. 77–124, 2019.

NOROUZI, N.; CHATURVEDI, S.; RUTLEDGE, M. Lessons learned from teaching machine learning and natural language processing to high school students. In: **Proceedings of the AAI Conference on Artificial Intelligence**, vol. 34, n. 9, p. 13397–13403, 2020.

OECD PISA. **PISA 2022 results: Brazil [Factsheet]**. 2022. Disponível em: <https://www.oecd.org/publication/pisa-2022-results/country-notes/brazil-61690648/#chapter-d1e11>. Acesso em: 28 mar. 2024.

OECD PISA. **PISA 2018 Results (Volume II): Where All Students Can Succeed: Country Note Brazil**. 2019.

OECD PISA. **Programme for International Student Assessment**. 2021. Disponível em: <https://www.oecd.org/pisa/>. Acesso em: 26 mar. 2024.

OECD/CERI. **Learning in the 21st Century: Research, Innovation and Policy**. 2008. Assessment for learning formative assessment. Disponível em: <https://www.actedu.in/wp-content/uploads/2016/03/Assessment-for-Learning.pdf>. Acesso em: 9 abr. 2024.

OGAWA, J.; GOTO, M. **Pesquisa sobre Garantia de Qualidade em Sistemas de ML, Iniciando com CLISP-ML(Q)**. [Traduzido do japonês]. Apresentado na Conferência Nacional de IA 2022, Dentsu International Information Service (ISID), Sessão Industrial 1, 14 jun. 2022. Disponível em: <https://speakerdeck.com/isidaitc/clisp-ml-q-wohazimetositamlsisutemufalsepin-zhi-que-bao-niguan-sur-udiao-cha?slide=56>. Acesso em: 09 mai. 2024.

OKFALISA, et al. Comparative Analysis of K-Nearest Neighbor and Modified K-Nearest Neighbor Algorithm for Data Classification. In: **2nd Int. conferences on Information Technology, Information Systems and Electrical Engineering**. Yogyakarta, Indonesia: [s.n.], 2017. p. 294–298.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). **The 17 Goals**. Department of Economic and Social Affairs, Sustainable Development. 2015. Disponível em: <https://sdgs.un.org/goals>. Acesso em: 26 mar. 2024.

OPENAI. **OpenAI**. 2023. Disponível em: <https://openai.com/>. Acesso em: 30 mar. 2024.

OPENAI. **Best practices for deploying language models**. 2022. Disponível em: <https://openai.com/blog/best-practices-for-deploying-language-models>. Acesso em: 26 mar. 2024.

OSPI K-12. Washington Office of Superintendent of Public Instruction. **Course Design and Instructional Materials Selection and Adoption**. 2022. Disponível em: <https://ospi.k12.wa.us/sites/default/files/2022-12/coursedesign-instructionalmaterials-toolkit.pdf>. Acesso em: 01 mai. 2024.

PAPERT, S. A critique of technocentrism in thinking about the school of the future. In: **Children in the information age**. [S.l.: s.n.], 1988. p. 3–18.

PARK, W.; KWON, H. Implementing artificial intelligence education for middle school technology education in Republic of Korea. **International Journal of Technology and Design Education**, 2023.

PARKER, M. C.; GUZDIAL, M. A critical research synthesis of privilege in computing education. In: **Proceedings of Research in Equity and Sustained Participation in Engineering, Computing, and Technology**. Charlotte, NC, USA: [s.n.], 2015. p. 1–5.

PIASECKI, J.; WALIGORA, M.; DRANSEIKA, V. Google Search as an Additional Source in Systematic Reviews. **Science and Engineering Ethics**, [S.l.], v. 24, n. 2, p. 809–810, 2018.

PEDRÓ, F., et al. **Artificial intelligence in education and opportunities for sustainable development**. [S.l.]: UNESCO Education Sector, 2019.

PERKEL, J, M. Why Jupyter is data scientists' computational notebook of choice. **Nature**, [S.l.], v. 563, p. 145–146, 2018.

PERRY, L. B.; SAATCIOGLU, A.; MICKELSON, R. A. Does school SES matter less for high-performing students than for their lower-performing peers? A quantile regression analysis of PISA 2018 Australia. **Large-scale Assessments in Education**, [S.l.], v. 10, n. 17, p. 2–29, 2022.

PETERSEN, K; FELDT, R.; MUJTABA, S.; MATTSSON, M. **Systematic mapping studies in software engineering**. 12th international conference on Evaluation and Assessment in Software Engineering. Swindon, UK: BCS Learning & Development Ltd. 2008. p. 68–77.

PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. Guidelines for conducting systematic mapping studies in software engineering: An update. **Information and Software Technology**, v. 64, p. 1–18, 2015.

PHILIPPAKOS, Z. A.; HOWELL, E.; PELLEGRINO, A. (Ed.). **Design-Based Research in Education: Theory and Applications**. 1. ed. New York: Guilford Press, 2021.

PIAGET, J. **A epistemologia genética**. Tradução de Nathanael C. Caixeira. Petrópolis: Vozes, 1971.

PRINCE, M. Does active learning work? A review of the research. **Journal of Engineering Education**, [S.l.], v. 93, n. 3, p. 223–31, 2004.

RAMOS, G., et al. Interactive machine teaching: a human-centered approach to building machine-learned models. **Human-Computer Interaction**, v. 35, n. 5-6, 2020.

RAUBER, M. F. e GRESSE VON WANGENHEIM C. Assessing the Learning of Machine Learning in K-12: A Ten-Year Systematic Mapping. **Informatics in Education**, [S.l.], v. 34, 2022.

RAUBER, M. F.; GRESSE VON WANGENHEIM, C.; BARBETTA, P. A.; BORGATTO, A. F.; MARTINS, R. M.; HAUCK, J. C. R. Reliability and Validity of an Automated Model for Assessing the Learning of Machine Learning in Middle and High School: Experiences from the "ML for All!" course. **Informatics in Education**, 2023.

RAUBER, M. F.; GRESSE VON WANGENHEIM, C.; BARBETTA, P. A.; BORGATTO, A. F.; MARTINS, R. M.; HAUCK, J. C. R. A Scale for Assessing the Learning of Machine Learning for Image Classification in Middle and High School Using the "ML4ALL!" Course. **ACM Transactions on Computing Education**, 2024, <submetido>.

REARDON, S. F. The Widening Academic Achievement Gap Between the Rich and the Poor: New Evidence and Possible Explanations. In: MURNANE, R.; DUNCAN, G. (Eds.). **Whither Opportunity? Rising Inequality, Schools, and Children's Life Chances**. New York: Russell Sage Foundation, 2011. p. 91–116.

RINCY, T. N.; GUPTA, R. A Survey on Machine Learning Approaches and Its Techniques. In: **IEEE International Students' Conference on Electrical, Electronics and Computer Science**. Bhopal, India: [s.n.], 2020. p. 1–6.

RIZVI, S.; WAITE, J.; SENTANCE, S. Artificial Intelligence teaching and learning in K-12 from 2019 to 2022: A systematic literature review. **Computers and Education: Artificial Intelligence**, [S.l.], v.4, p. 1–15, 2023.

RODRÍGUEZ-GARCÍA, J. D.; MORENO-LEON, J.; ROMÁN-GONZÁLEZ, M.; ROBLES, G. Evaluation of an Online Intervention to Teach Artificial Intelligence with LearningML to 10-16-Year-Old Students. In: **Proceedings of the 52nd ACM Technical Symposium on Computer Science Education**. Virtual Event, USA: [s.n.], 2021.

RODRÍGUEZ-GARCÍA, J. D.; MORENO-LEON, J.; ROMÁN-GONZÁLEZ, M.; ROBLES, G. Developing Computational Thinking at School with Machine Learning: An exploration. In: **Proceedings of the International Symposium on Computers in Education**. Tomar, Portugal: [s.n.], 2019. p. 1–6.

SANTANA, O. A., et al. Deep learning practice for high school student engagement in STEM careers. In: **IEEE Global Engineering Education Conference**. Porto, Portugal: [s.n.], 2018. p. 164–169.

SANUSI, I. T.; OYELERE, S. S.; VARTIAINEN, H.; SUHONEN, J.; TUKIAINEN, M. A systematic review of teaching and learning machine learning in K-12 education. **Education and Information Technologies**, v. 28, p. 5967–5997, 2023.

SANUSI, I. T.; OYELERE, S. S. Pedagogies of Machine Learning in K-12 Context. In: **IEEE Frontiers in Education Conference**. Uppsala, Sweden: [s.n.], 2020. p. 1–8.

SASKATCHEWAN EDUCATION. **Instructional Approaches: A Framework for Professional Practice**. Canada: Saskatchewan Education, 1991.

SAUNDERS, M.; LEWIS, P.; THORNHILL, A. **Research Methods for Business Students**. 8. ed. New York: Pearson, 2019.

SBC. **Diretrizes para ensino de Computação na Educação Básica**. 2018. Disponível em: <https://www.sbc.org.br/educacao/diretrizes-para-ensino-de-computacao-na-educacao-basica>. Acesso em: 26 mar. 2024.

SBC. **Currículo de Referência da SBC para Cursos de Graduação em Bacharelado em Ciência da Computação e Engenharia de Computação**. [S.l.]: Sociedade Brasileira de Computação, 2005.

SEIN-ECHALUCE, M.L.; FIDALGO BLANCO, Á.; GARCÍA PEÑALVO, F. J. Trabajo en equipo y Flip Teaching para mejorar el aprendizaje activo del alumnado - Peer to Peer Flip Teaching. In: **La innovación docente como misión del profesorado: Congreso Internacional Sobre Aprendizaje, Innovación y Competitividad**. Zaragoza, Spain: [s.n.], 2017. p. 610–615.

SHADISH, W. R.; COOK, T. D.; CAMPBELL, D. T. **Experimental and quasi-experimental designs for generalized causal inference**. Belmont, CA: Wadsworth/Cengage Learning, 2002.

- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, [S.l.], v. 52, n. 3-4, p. 591–611, 1965.
- SHERKHANE, P.; VORA, D. Survey of deep learning software tools. In: **International Conference on Data Management, Analytics and Innovation**. Pune, India: [s.n.], 2017. p. 236–238.
- SHRESTHA, A.; MAHMOOD, A. Review of Deep Learning Algorithms and Architectures. In: **IEEE Access**, v. 7, p. 53040–53065, 2019.
- SMALDINO, S. E.; LOWTHER, D. L.; RUSSELL, J. D. **Instructional Technology and Media for Learning**. 9. ed. Upper Saddle River, N.J: Pearson/Merrill/Prentice Hall, 2008.
- SMITH, P. L.; RAGAN, T. J. **A framework for instructional strategy design**. In: SMITH, P. L.; RAGAN, T. J. (Eds.). **Instructional design**. 3. ed. New York, NY: Wiley & Sons, 2005.
- SPERLING, A.; LICKERMAN, D. Integrating AI and machine learning in software engineering courses for high school students. In: **Proceedings of the 17th ACM Annual Conference on Innovation and Technology in Computer Science Education**. Haifa, Israel: [s.n.], 2012.
- SPIEGEL, M.; SRINIVASAN, R. A.; SCHILLER, J. **Schaum's Outline of Probability and Statistics**, 3rd Ed. (Schaum's Outline Series). 3rd ed. New York: McGraw Hill, 2009.
- SPIEGEL, M. R.; STEPHENS, L. J. **Statistics. Theory and Problems of Statistics**. 4th ed. Schaum's Outline Series. [S.l.]: McGraw-Hill, 2008.
- SQUICCIARINI, M.; NACHTIGALL, H. Demand for AI skills in jobs: Evidence From online job posts. **OECD Science, Technology and Industry Working Papers**, No. 2021/03, Paris: OECD Publishing, 2021.
- SU, J. et al. Teaching artificial intelligence in K–12 classrooms: a scoping review. **Interactive Learning Environments**, p. 1-20, 2023.
- SU, J.; ZHONG, Y. Artificial Intelligence (AI) in early childhood education: Curriculum design and future directions. **Computers and Education: Artificial Intelligence**, [S.l.], v. 3, 2022.
- SULMONT, E.; PATITSAS, E.; COOPERSTOCK, J. R. Can You Teach Me To Machine Learn?. In: **Proceedings of the 50th ACM Technical Symposium on Computer Science Education**. [S.l.]: ACM, 2019. p. 948–954.
- STUDER, S. et al. Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology. **Machine Learning and Knowledge Extraction**, v. 3, n. 2, p. 392-413, 2021.
- SWEATY MACHINES. **Sweaty Machines a Eurovision song created by Artificial Intelligence: Blue Jeans and Bloody Tears**. 2019. Disponível em: https://www.youtube.com/watch?v=4MKAf6YX_7M. Acesso em: 11 abr. 2024.
- TISSENBAUM, M.; SHELDON, J.; ABELSON, H. From Computational Thinking to Computational Action. **Communications of the ACM**, [S.l.], v. 62, n. 3, p. 34–36, 2019.
- TEAGUE, D.; ROE, P. Collaborative learning: towards a solution for novice programmers. In: **Proceedings of the 10th Conference on Australasian computing education**. Wollongong, Australia: [s.n.], 2008. p. 147–153.
- TEDRE, M. et al. Teaching Machine Learning in K–12 Classroom: Pedagogical and Technological Trajectories for Artificial Intelligence Education. **IEEE Access**, [S.l.], v. 9, p. 110558–110572, 2021.
- THE CODING SCHOOL. **The Coding School — Training the future workforce in emerging technologies**. 2023. Disponível em: <https://the-cs.org/>. Acesso em: 26 mar. 2024.

TIC Educação 2019. 2019. Disponível em: https://cetic.br/media/analises/tic_educacao_2019_coletiva_imprensa.pdf. Acesso em: 26 mar. 2024.

TIC Kids Online Brasil 2019. 2019. Disponível em: https://cetic.br/media/analises/tic_kids_online_brasil_2019_coletiva_imprensa.pdf. Acesso em: 26 mar. 2024.

TIKVA, C.; TAMBOURIS, E. A systematic mapping study on teaching and learning Computational Thinking through programming in higher education. **Thinking Skills and Creativity**, [S.l.], v. 41, p. 1871–1871, 2021.

TOURETZKY, D. S.; GARDNER-MCCUNE, C.; SEEHORN, D. Machine learning and the five big ideas in AI. **International Journal of Artificial Intelligence in Education**, [S.l.], Springer Nature, 2022.

TOURETZKY, D. et al. Envisioning AI for K-12: What Should Every Child Know about AI?. In: **Proceedings of the AAAI Conference on Artificial Intelligence**, Honolulu, Hawaii, USA, v. 33, n. 01, p. 9795–9799, 2019.

UNESCO. **K-12 AI curricula — A mapping of government-endorsed AI curricula**. Paris: [s.n.], 2022.

UNESCO. **Reducing Global Poverty Through Universal Primary and Secondary Education**. Policy Paper 32, Paris: [s.n.], 2017.

UNICEF Brasil. **Cenário da Exclusão Escolar no Brasil: Um alerta sobre os impactos da pandemia da COVID-19 na Educação**. 2021. Disponível em: <https://www.unicef.org/brazil/media/14026/file/cenario-da-exclusao-escolar-no-brasil.pdf>. Acesso em: 21 mar. 2024.

UNICEF. **Regional Study on Parenting Adolescents and Parenting Support Programmes in Belarus, Bulgaria, Georgia, Moldova, Montenegro, and Romania**. Geneva: [s.n.], 2018.

UNICEF. **Adolescence: An Age of Opportunity: The State of the World's Children**. Geneva: [s.n.], 2011.

UNIÃO EUROPEIA. **European Framework for the Digital Competence of Educators: DigCompEdu**. Y. Punie (Ed.), C. Redecker. Luxembourg: Publications Office of the European Union, 2017.

UNRISDSP. **United Nations Research Institute for Social Development, According to Social Protection and Human Rights**. [S.l.: s.n.], 2015.

VAN DER MEULEN, A., et al. Who participates in computer science education studies? A literature review on K-12 subjects. **PeerJ Computer Science**, [S.l.], v. 7, 2021.

VAN BRUMMELEN, J. **Tools to Create and Democratize Conversational Artificial Intelligence**. 2019. M.S. thesis, Elect. Eng. Comput. Sci., Massachusetts Institute of Technology, Cambridge, MA, USA.

VAN BRUMMELEN, J.; HENG, T.; TABUNSHCHYK, V. Teaching Tech to Talk: K-12 Conversational Artificial Intelligence Literacy Curriculum and Development Tools. In: **Proceedings of the AAAI Conference on Artificial Intelligence**, vol. 35, no. 17, p. 15655–15663, Virtual Event, USA, 2021.

VON WANGENHEIM, A. **Visão Computacional - Reconhecendo objetos em Florianópolis e na UFSC com Mask-R-CNN**. Disponível em: <https://www.youtube.com/watch?v=FXUD-XtsUDM>. Acesso em: 11 mai. 2024.

VEKIRI, I. Socioeconomic differences in elementary students' ICT beliefs and out-of-school experiences. **Computers & Education**, [S.l.], v. 54, n. 4, p. 941–950, 2010.

- WAN, X., et al. SmileyCluster: supporting accessible machine learning in K-12 scientific discovery. In: **Proceedings of the Interaction Design and Children Conference**. New York, NY, USA: [s.n.], 2020.
- WANG, C., et al. Introducing Machine Learning in a Sophomore Signals and Systems Course. In: **IEEE Frontiers in Education Conference**. Covington, KY, USA: [s.n.], 2019. p. 1–4.
- WAYNE, A. J.; YOUNGS, P. Teacher Characteristics and Student Achievement Gains: A Review. **Review of Educational Research**, v. 73, n. 1, p. 89–122, 2003.
- WEBB, G. I; SAMMUT, C. **Encyclopedia of Machine Learning**. [S.l.]: Springer, 2011.
- WESTBROOK J., et al. **Pedagogy, Curriculum, Teaching Practices and Teacher Education in Developing Countries, Final Report. Education Rigorous Literature Review**. Department for International Development, 2013. Disponível em: <https://eppi.ioe.ac.uk/cms/Portals/0/PDF%20reviews%20and%20summaries/Pedagogy%202013%20Westbrook%20report.pdf?ver=2014-04-24-121331-8>. Acesso em: 26 mar. 2024.
- WILSON, K. J.; BRICKMAN, P.; BRAME, C. J. Group Work. **CBE-Life Sciences Education**, [S.l.], v. 17, n. 1, 2018.
- WING, J.M. Computational Thinking. **Communications of the ACM**, [S.l.], v. 49, p. 33–35, 2006.
- WOHLIN, C. Guidelines for snowballing in systematic literature studies and a replication in software engineering. In: **Proceedings of the 18th International Conference on Evaluation and Assessment in Software Engineering**. London, England: ACM, 2014. p. 38, 1–10.
- WOHLIN, C et al. **Experimentation in Software Engineering**. Heidelberg New York Dordrecht London: Springer-Verlag Berlin Heidelberg, 2012.
- WORLD BANK. **World Bank Open Data**. 2022. Disponível em: <https://data.worldbank.org/>. Acesso em: 26 mar. 2024.
- WORLD ECONOMIC FORUM. **The Future of Jobs Report**. [S.l.: s.n.], 2020.
- WUNDERLICH, L. et al. Machine Learning for Business Students: An Experiential Learning Approach. In: **Proceedings of the 26th Conference on Innovation and Technology in Computer Science Education**. Virtual Event, Germany: [s.n.], 2021.
- YIN, R. K. **Case Study Research and Applications: Design and Methods**. 6. ed. Los Angeles: SAGE Publications, 2017.
- YIM, I. H. Y.; SU, J. Artificial intelligence (AI) learning tools in K-12 education: A scoping review. **Journal of Computers in Education**, 2024.
- YUE, M.; JONG, M.S-Y.; DAI, Y. Pedagogical Design of K-12 Artificial Intelligence Education: A Systematic Review. **Sustainability**, [S.l.], v.14, n.23, p. 15620, 2022.
- YUEN, K.; HAU, K. Constructivist teaching and teacher-centered teaching: a comparison of students' learning in a university course. **Innovations in Education and Teaching International**, [S.l.], v. 43, n. 3, p. 279–290, 2006.
- ZEKI, C.; GUNEYLI, A. Student Teachers' Perceptions about Their Experiences in a Student Centered Course. **South African Journal of Education**, [S.l.], v. 34, p. 1–11, 2014.
- ZHAN, Z; TONG, Y.; LAN, X.; ZHONG, B. A systematic literature review of game-based learning in Artificial Intelligence education. **Interactive Learning Environments**, p. 1–22, 2022.
- ZHANG, H., et al. Integrating Ethics and Career Futures with Technical Learning to Promote AI Literacy for Middle School Students: An Exploratory Study. **International Journal of Artificial Intelligence in Education**, [S.l.], 2022.

ZHOU, X.; VAN BRUMMELEN, J.; LIN, P. Designing AI Learning Experiences for K-12: Emerging Works, Future Opportunities and a Design Framework. **arXiv abs/2009.10228[cs.CY]**, 2020.

ZHU, K. An Educational Approach to Machine Learning with Mobile Applications. M.Eng thesis, Elect. Eng. Comput. Sci., Massachusetts Institute of Technology, Cambridge, MA, USA, 2019.

APÊNDICE A — RUBRICA DE HABILIDADES DE INFORMÁTICA BÁSICA

Rubrica de informática básica

ID	Critério	Desempenho - Nível de performance			
		Não avaliado	Fraco	Adequado	Excelente
Operação do Computador					
	Saber ligar o computador	Não avaliado	Não consegue ligar um desktop ou não sabe abrir a tampa e ligar um notebook	Sabe ligar um desktop ou notebook que estejam preparados para uso	Liga e sabe identificar facilmente problemas comuns, como cabos desconectados
	Saber desligar o computador	Não avaliado	Deixa o local de estudo com o computador ligado ou o desliga diretamente da tomada	As vezes desliga o computador utilizando o botão iniciar do Windows	Sempre desliga o computador utilizando o botão iniciar do Windows
	Zelar pelos equipamentos eletrônicos	Não avaliado	Não percebe a fragilidade dos equipamentos eletrônicos	Manuseia com cuidados os equipamentos eletrônicos e evita aproximar líquidos	Alerta aos colegas sobre os cuidados com equipamentos eletrônicos
Operação do sistema Operacional					
	Habilidade em manipular o mouse	Não avaliado	Não conhece os botões do mouse e associação entre seu movimento e ponteiro na tela.	Movimenta o mouse com dificuldade, parando o movimento para realizar clicks.	Movimenta com destreza o mouse, sendo capaz de realizar ajustes finos.
	Habilidade em digitação	Não avaliado	Não encontra as letras no teclado ou digita apenas com 2 dedo	Conhece a posição dos dedos no teclado e tenta digitar utilizando todos os dedos	Consegue digitar um texto na velocidade que uma pessoa fala lentamente
	Atalhos do sistema operacional	Não avaliado	Não conhece atalhos comuns relacionados a copiar e colar.	Dificuldade em utilizar os atalhos comuns relacionados a copiar e colar.	Sabe utilizar os atalhos comuns relacionados a copiar e colar.
	Manipulação de arquivos e pastas	Não avaliado	Não conhece a estrutura de pastas e não consegue copiar arquivos ou pastas	Consegue criar novas pastas e arquivos de forma lenta.	Entende a estrutura de pastas e arquivos, manipulando-s com facilidade, usando teclas de atalho
	Compactação de arquivos e pastas	Não avaliado	Não sabe o que são arquivos compactados (exemplo .ZIP)	Consegue identificar um arquivo compactado e extrair seu conteúdo.	Consegue criar novos arquivos ou pastas compactadas e manipulá-las com facilidade.
	Conectar o computador na internet	Não avaliado	Não sabe identificar se o computador está conectado a internet	Identifica se o computador está conectado a internet	Consegue conectar o computador a uma nova rede Wi-Fi
Operação básica da internet					
	Ética e direitos autorais	Não avaliado	Não conhece ética e direitos autorais	Compreende que os conteúdos disponibilizados na internet tem autores com direitos autorais	Conhece as leis brasileiras 9609/98 e 9610/98
	Entende a estrutura de domínios da internet	Não avaliado	Não conhece a estrutura de domínios da internet	Conhece a estrutura de domínios	Compreende a estrutura de endereços da internet (IPs x domínios)
	Utilizar o navegador de internet	Não avaliado	Não sabe o que é um navegador de internet	Sabe digitar um endereço no navegador e navegar na estrutura de links.	Navega na internet com facilidade, digitando endereços e navegando pelos links com destreza.
	Realizar pesquisas na internet	Não avaliado	Não sabe o que são mecanismos buscadores	Conhece o Google e realiza buscas simples	Sabe utilizar os filtros e buscas com aspas
	Segurança - importância de senhas seguras	Não avaliado	Não entende a importância das senhas seguras e privacidade de dados	Entende a importância das senhas seguras e privacidade de dados	Utiliza senhas seguras, sabe utilizar mnemônicos e preza pela sua privacidade
	VideoChamada - Utilização do Meet	Não avaliado	Não sabe utilizar uma videoChamada	Sabe entrar em uma videoChamada agenda no Meet, e operar seu microfone, câmera e chat.	Sabe criar uma nova videoChamada no Meet e operá-la.
Utilização básica do Gmail					
	Entender a estrutura básica de um endereço de e-mail	Não avaliado	Não conhece a estrutura de endereços de e-mail	Sabe identificar corretamente um endereço de e-mail	Consegue identificar o domínio associado a um endereço de e-mail
	Enviar e-mail	Não avaliado	Não sabe enviar um e-mail	Sabe enviar um e-mail., distinguindo entre os campos assunto e corpo do e-mail.	Envia emails com maestria e verifica se foram enviados.
	Anexar arquivos aos e-mail	Não avaliado	Não sabe anexar arquivos	Consegue anexar um arquivo ao e-mail.	Anexa vários arquivos e demonstra preocupação com o tamanho desses anexos
	Verificar o recebimento de e-mails	Não avaliado	Não sabe verificar o recebimento de emails	Identifica corretamente novos emails na caixa de entrada padrão ao entrar no Gmail.	Consegue procurar email nas demais caixas do Gmail, inclusive nos Spams.
	Ética e Spams	Não avaliado	Não reconhece Spams e direitos de conteúdo indesejado	Identifica corretamente emails que podem ser classificados como Spams	Não cria emails de Spams.
Utilizar serviços em nuvem - Google Drive					
	Entender o funcionamento do	Não avaliado	Não entende o funcionamento das nuvens	Compreende que na nuvem os arquivos ficam	Conhece os principais serviços gratuitos de

	armazenamento em nuvem			armazenados em outro computador e disponíveis na internet.	nuvem.
	Enviar um arquivo para a nuvem	Não avaliado	Não consegue enviar um arquivo para a nuvem	Consegue enviar um arquivo para a nuvem arrastando e soltando	Consegue enviar um ou vários arquivos selecionando-os na estrutura de pastas.
	Baixar um arquivo da nuvem	Não avaliado	Não consegue baixar um arquivo da nuvem	Consegue baixar um arquivo da nuvem	Consegue identificar e baixar vários arquivos de uma vez
	Compartilhar arquivos da nuvem	Não avaliado	Não consegue compartilhar um arquivo na nuvem	Consegue compartilhar um arquivo ou pasta na nuvem (link e usuários)	Sabe diferenciar formas de compartilhamento (somente leitura, editor, visualizador)
Editor de textos - Google Documentos					
	Digitação e formatação de textos	Não avaliado	Não consegue replicar um documento impresso (Tamanho e estilo de Fontes, conteúdo)	Consegue replicar um documento impresso (Tamanho e estilo de Fontes, conteúdo)	Replica com perfeição um documento impresso (Tamanho e estilo de Fontes, conteúdo)
	Manipulação de blocos de texto	Não avaliado	Não consegue manipular blocos de texto	Consegue mover e formatar blocos de texto	Consegue copiar e colar blocos de texto com teclas de atalho.
	Manipulação de figuras	Não avaliado	Não consegue inserir figuras em documento	Consegue inserir figuras em um documento	Inserir figuras e consegue alterar suas propriedades
	Manipulação de tabelas	Não avaliado	Não consegue inserir tabelas em um documento	Inserir tabelas com formatação básica	Consegue inserir tabelas e alterar suas propriedades (ie., linhas, cores, tamanhos, mesclagem)
	Exportar cópias do documento	Não avaliado	Não consegue fazer uma cópia do documento	Consegue realizar o download do documento para o computador (Docx, PDF)	Consegue compartilhar o documento criado, dando permissões a diferentes usuários.
Editor de apresentações - Google Apresentações					
	Estrutura e funcionamento de uma apresentação	Não avaliado	Não entende o funcionamento de uma apresentação	Consegue criar novos slides.	Consegue trabalhar com diferentes layouts e modelos.
	Boas práticas em apresentações	Não avaliado	Não conhece boas práticas e apresentação	Compreende que os slides devem ter pouco texto	Sabe da importância da postura e dicção ao realizar uma apresentação
	Inserir textos e formatação em apresentações	Não avaliado	Não sabe como inserir textos em uma apresentação	Consegue inserir novos textos em uma apresentação	Sabe utilizar os layouts de slides
	Manipulação de figuras em apresentações	Não avaliado	Não sabe inserir figuras	Consegue inserir uma figura	Inserir figuras e sabe manipular suas propriedades.
	Manipulação de tabelas em apresentações	Não avaliado	Não sabe inserir tabelas	Consegue inserir uma nova tabela.	Inserir nova tabela e consegue modificar sua apresentação.
Editor de apresentações - Google Planilhas (nao necessario para os cursos ML, mas talvez interessante para a formação geral dos estudantes)					
	Estrutura e funcionamento de uma planilha eletrônica	Não avaliado	Não entende o funcionamento de planilhas	Compreende a estrutura de células e Sheets	Diferencia entre os diferentes tipos de dados (números, texto)
	Inserir dados em planilha	Não avaliado	Não consegue inserir dados em uma planilha	Consegue inserir dados tabelados	Consegue manipular grandes quantidades de dados
	Inserir fórmulas básicas (simples)	Não avaliado	Não sabe utilizar as fórmulas	Consegue inserir fórmulas que trabalham com células específicas	Consegue inserir fórmulas que trabalham com intervalos
	Geração de gráficos a partir dos dados	Não avaliado	Não sabe gerar gráficos	Consegue gerar gráficos padrões	Consegue alterar as propriedades dos gráficos para gerar gráficos personalizados
	Interoperabilidade	Não avaliado	Não sabe levar gráficos ou tabelas entre os diferentes aplicações	Consegue copiar e colar gráficos ou tabelas entre diferentes aplicações	Demonstra desenvoltura em copiar gráficos ou tabelas entre diferentes aplicações

Fonte: elaborado pelo autor em conjunto com o prof. Marcelo Fernando Rauber em colaboração com a iniciativa Computação na Escola.

APÊNDICE B — FEEDBACK DOS ESTUDANTES EM SITUAÇÃO DE VULNERABILIDADE SOCIAL SOBRE O CURSO

Feedback dos estudantes em situação de vulnerabilidade social (em texto aberto e por escrito) sobre o curso "ML para todos!"

O que você mais gostou no curso? (x=Frequência de respostas similares)* †

Aplicação 6 (em 2022)

Tudo (10x) / Não sei (5x) / A parte de separar as imagens (2x) / Separar as imagens (2x) / Programar (2x) / As aulas (2x) / Fazer a identificação dos objetos / Aprender haha / As imagens / Dos aprendizados / Reconhecimento das imagens / O trabalho em grupo / Não sei dizer / Programação / Gostei do fato de que mostrou o quão simples é para criar esse modelo de inteligência artificial / O reconhecimento das imagens / O modelo que nós podemos criar para fazer reciclagem / Não sei porque não lembro / A facilidade prática para fazer as atividades / Sim / De aprender o que significa Machine Learning / Nsei / Um pouco de cada coisa / Aprender a programar o sistema / Treinar a máquina / Separar os lixos / Na hora de treinar o robô / Mais ou menos / A parte de ensinar uma máquina / Sei lá / Legal / A ideia de criar uma inteligência artificial / A questão de ensinar uma máquina / Eu gostei da parte de como faz para reconhecer as imagens / A ATIVIDADE DE Separar o lixo / Acho que gostei de tudo / Separar as imagens de reciclagem / Live / Aprender sobre computadores e sistemas / Saber selecionar as imagens corretamente e mexer com pastas / Gostei mais desse, o reconhecimento da máquina sabe o que é metal, plástico, etc... / De tudo / Eu gostei da forma que faz para ensinar a IA aprender sobre as coisas / Eu gostei da seleção de imagens, mexer com as pastas do PC e fazer os conhecimentos da imagem para preencher a barra de progresso no site / Gostei de tudo / Eu gostei da identificação de imagens / Facilita as coisas no dia a dia como básica com lixo / Terça-feira passada foi minha primeira vez nesse curso e estou gostando muito aprendendo coisas novas / O que eu mais gostei foi como um robô pode ser inteligente, e como podemos ensiná-lo a ser inteligente / Slá / Apenas agora sei o que é e acredito que algum dia irá servir para que eu faça algum jogo ou etc / Muitas coisas / Separar metal de papel, plástico / A inteligência Artificial / Tudo achei bem interessante / Eu gostei de criar site / Não sei dizer o que mais gostei / Separar as imagens para o computador tentar acertar / Gostaria de ter mais aulas / Gostei pois aprendi bastante coisa que para a área de trabalho é muito importante / Separação de recicláveis e conhecimento / No modo de que você pega as imagens e as máquinas dizem o que é / Quase tudo / Reconhecimento de imagem! / "Tudo" / Da parte de criar uma inteligência artificial / Não gostei, mas aprendi algo a mais para o mercado de trabalho caso precise / Das atividades práticas / Aprender sobre o que é o Machine Learning e como funciona / Aprender sobre as máquinas e saber que elas aprendem / Ver como a inteligência funciona, de como ela aprende e tal / Tudo um pouco... Gostei de aprender tudo / Achei uma experiência incrível por ser novo aprendizado / Separar o lixo / A montar os neurônios / Aprender mais sobre tecnologia / O professor / Foi uma experiência interessante e didática / A capacidade de ver as diferenças de objetos / Que é sobre coisas que vai haver no futuro, já está havendo / Que foi conteúdo novo / Tive algumas dificuldades então não tenho uma opinião sobre / Alguns exemplos do que pode me ajudar / Poder fazer um app de reconhecer qual tipo o material é / A parte teórica / Eu gostei da parte de criar uma IA / Desenvolvimento / Foi ensinado de forma prática / Foi o desenvolvimento de uma IA em sala / Da atividade de reconhecimento do papel, plástico, metal e vidro / O aprendizado e desenvolvimento na área / Entender como a Inteligência Artificial aprende as coisas, como cada rede neural ajuda ela a identificar as coisas / De aprender / As aulas práticas quando tivemos a oportunidade de realmente treinar essa inteligência artificial / Até agora nenhum / As atividades em geral como o codemaster / De fazer uma inteligência aprender a identificar imagens / O jeito que fomos tratados / Gostei de tudo em geral / De aprender mais sobre coisas que eu nem sabia

Aplicação 7 (em 2023)

Tudo (9x) / Gostei de tudo (3x) / O jogo das cartas (3x) / As atividades (3x) / As tarefas / Fazer a parte dos blocos / Aprender mais / Gostei das aulas práticas, tipo 'criar' uma IA para reconhecer materiais recicláveis / Criar uma animação usando sistema de captura de movimento / Não sei, eu gostei do jogo / Das imagens / Separação de fotos através do IA / Aprender que as inteligências artificiais também aprendem / Usar as inteligências artificiais na prática / Atividades e praticidade pela aula online / O poder da inteligência artificial / Seus jogos criativos para desenvolver minha criatividade / Parte de criar o app / Gostei mais dos joguinhos e quizzers interativos / Praticamente tudo / Fazer o aplicativo / Identificação / O jogo do último curso / A saber que cada vez foi evoluindo mais a tecnologia / Nada / Vídeo explicando o que fazer / Aquele que a pessoa tem que desenhar o que o sistema pede / Montar as fotos / O APRENDIZADO / De selecionar as imagens / Criar um reconhecimento de imagens / Tudo, e confesso que com as vídeo aulas aprendi muito mais / Tudo, aprendi muitas coisas que eu não fazia ideia / TUDO / As atividades de dança / Dos questionários, jogo, e separar as imagens recicláveis / Não entendi muito / Tudos achei interessante / De fazer atividades / Eu gostei de aprender a fazer esse tipo de inteligência / Todas as atividades / Amei, é uma oportunidade única / Fazer um modelo de machine learning pra identificar imagens / O jeito das imagens serem identificadas / O curso em si

O que você menos gostou no curso? (x=Frequência de respostas similares)* †

Aplicação 6 (em 2022)

Nada (11x) / Gostei de tudo (7x) / A explicação (4x) / Não sei (4x) / As aulas (2x) / Separar as imagens (2x) / Não lembro (2x) / Programa / Não aprendi muita coisa / A maioria das aulas / Fazer no computador / Não tive nenhuma decepção / Todo me gustó / Tbm não sei / Em nada / Passa rápido demais / É meio difícil de aprender / Não sei dizer / Da primeira aula / Poderia ser presencial e não por chamada / Acho que foi a explicação / Não teve essa opinião / Escolher as coisas para podar no lixo / Sei lá / Mais ou menos / É bom / A questão de desenvolver / Separar as imagens por pastas / As aulas são um pouco chatas / Foi um pouco difícil a parte do cérebro / Pessoas que bagunçam / Que está chegando ao fim / Do tempo de duração das aulas, e a aula não ser presencial / Não tem nada que gostei menos ou mais / Não tenho / Daquele aplicativo de desenhos / Não tem nada / Programar / A demora e qualidade das aulas / Os jogos / Achei um pouco difícil / Sim / As aulas, aprendizado / Algumas coisas eu acho difícil / Muito rápido as questões de cada semana / Teve muitas teorias e não teve muitas práticas / Meio diferente / Achei perfeito / Ficar separando imagens / Queria que ele estivesse mais tempo presente e não só por vídeo / Gostei muito / De saber que há uma grande probabilidade de ser problemático no futuro / Acho que a aula a distância é mais difícil de aprender mas dá para aprender / Tive algumas dificuldades então não tenho uma opinião sobre / Algumas explicações que não entendi / Na parte das aulas online / Foi ter menos prática e mais teórica / Até agora nada / Da parte de separar as fotos / Enrolação com informações não tão úteis para desenvolver uma IA e ofuscando as informações importantes / O curso foi incrível, nada a reclamar / Algumas vezes a gente ficava muito tempo parado sem fazer nada / O ritmo da aula poderia ser mais rápida e prática / Talvez o fato de ser demorado / Pelas poucas aulas e muita informação em pouco tempo / Não tem nada que eu não tenha gostado

Aplicação 7 (em 2023)

Nada (12x) / Gostei de tudo (3x) / Não sei (3x) / As vídeo aulas (4x) / Tudo (2x) / Os apps eu nem consigo mexer / Códigos / Os aplicativos / Eu gosto de tudo / Não acho que tenha algo que eu não gostei, é bom aprender algo novo / Muitos vídeos e questionários para assistir em uma aula / SLA / Não tem algo certo ainda que eu não tenha gostado / Coletas de dados complicada / Parte do questionário / As aulas com o moço falando me deram um pouco de sono / As partes mais chatinhas de fazer / Das pessoas / As etapas que tem que serem seguidas / Aulas repetitivas / As máquinas acessar dados / Ver as aulas eram muito demoradas / Acho que nada / Não teve / Foi as dificuldades constantes para fazer o login / De quando tinha que fazer muita coisa / Ver vídeo / A parte de ter que desenhar / Os vídeos aulas, pois poderia ser pessoalmente / Muita informação em uma explicação só, e como tenho TDH é meio difícil de compreender, às vezes / Não entendi muito / O vídeo em movimento / Eu achei as atividades complicadas / Eu não sei exatamente / Ensinar um sistema a ter autonomia / O tempo das vídeo aulas

O que o motiva a estudar Inteligência Artificial/Aprendizado de Máquina? x=Frequência de respostas similares)* †

Aplicação 6 (em 2022)

Aprender coisas novas (15x) / Aprender mais (8x) / Me interesse pelo o assunto (3x) / Robôs (2x) / Trabalhar com isso (2x) / Ganhar experiência na área (2x) / Ter mais conhecimento (2x) / O conhecimento (2x) / A curiosidade (2x) / As pessoas (2x) / Não sei (2x) / Minha mãe (2x) / Nada / No momento nada / Aprender um pouco sobre inteligência artificial / Fazer o meu próprio / Muito coisa / A internet, as diferentes experiências que podem ser usadas no futuro também / La programación / Desenvolvimento pessoal / A vontade de aprender / Emprego / Sinto que é um jeito de estar à frente da sociedade do futuro / Acho interessante e pode me ajudar futuramente no meu conhecimento / Que é um campo de estudo muito bom para o futuro / A falta de pessoas no mercado, faz que ocorra a supervalorização do serviço / Saber que terei mais coisas para adicionar no meu currículo / O meu futuro / A busca por experiência novas / Bem legal / Desenvolver dispositivos inteligentes / Aprender a construir uma máquina / Aprender mais sobre as máquinas / Legal / Aprender e ajudar com mais criações / Isso pode me ajudar numa carreira futura / É obrigatório / Fazer um robô / Interesse em fazer máquinas / Me motiva pois é um meio de trabalho que eu planejo para trabalhar / Pra próxima evolução do mundo / A vida / Para criar uma IA que cumpra os objetivos que desejo / Me motiva me aperfeiçoar cada vez mais na área de computação e seguir essa área futuramente a trabalho / Mais pra frente vou ter um conhecimento melhor / Aprender e desenvolver novos conhecimentos / Poder facilitar coisa básica no dia a dia / O meu desempenho lá na frente / Me motiva pois vai ter bastante oportunidades e tals / Eu acho legal, como o robô pode ter tanto conhecimento / O funcionamento / Criar algo que facilite meu dia a dia / Talvez seja útil mais pra frente / O futuro / Bom sendo sincero quase nada / Motiva a saber mais sobre o assunto / Aprender a mexer com inteligência artificial / A ajudar as pessoas, não sei o que dizer na verdade / As oportunidades que isso pode me trazer / A curiosidade e querer saber mais sobre machine / Eu quero algum dia trabalhar no ramo / Mexer com computação / Que podes fazer coisas legais / Eu posso criar alguma coisa que possa me ajudar e ajudar a sociedade / Quero entender desta área / Nada, a não ser o mercado de trabalho / O resultado / Ter conhecimento para futuros empregos / Quero aprender tudo sobre tecnologia / Querer aprender mais sobre inteligência artificial / É necessário aprender coisas novas, pois bem será útil no futuro / A prática de mexer com tecnologia / O meu futuro, porque quero trabalhar de computação / É útil / Acho que tentar mudar um pouco o cotidiano, mudar algumas profissões / Quando penso sobre o que eu quero aprender / Na parte de programar / Porque eu posso desenvolver qualquer tipo de inteligência artificial / Pode usar futuramente / Saber mais sobre como posso fazer do meu futuro mais moderno e autônomo / Pois é algo muito presente na nossa realidade e vai estar mais ainda no futuro / As infinitas possibilidades / Acho muito interessante / Eu gosto / O desenvolvimento das aulas fizeram eu me interessar cada vez mais na área / Saber que é um mercado que cresce cada dia mais e isso pode me gerar uma renda / Ter uma mente mais culta / O conhecimento de novas dessa tecnologia que está diretamente a nossa vida / Na verdade é mais para saber e conhecer o que é machine learning, no caso, não seria uma motivação / Aprender mais sobre o potencial da tecnologia / Acredito que fazer desenvolver uma máquina que possa auxiliar no dia a dia de alguém / Saber mais sobre e poder falar o que pra um amigo / Gosto de estudar sobre tudo em um geral / Aprender sobre tecnologia.

Aplicação 7 (em 2023)

Aprender mais (7x) / Saber mais (5x) / Achar interessante (2x) / Mercado de trabalho (2x) / Minha mãe (2x) / O futuro (2x) / As pessoas (2x) / Gosto de tecnologia (2x) / Curiosidade (2x) / A tecnologia (2x) / Para ter mais conhecimento / Para que eu me destaque no futuro / Aprender sobre os riscos da robótica / Acho interessante o que pode ser feito com as IAs futuramente / A quantidade de vagas de trabalho para a área que a cada ano cresce mais / Experiências / Querer aprender mais / O quão a tecnologia está virando inovadora / Desenvolvimento da inteligência / Poder trabalhar nessa área / Programação com Python / Gosto de sempre aprender mais e acumular conhecimentos gerais / Medicina / A vontade de aprender mais sobre sistemas computacionais / Os robôs não têm muitas de nossas limitações / Eu gosto de computação / Ser alguém na vida / Elevar ao máximo o desempenho nas tarefas que são atribuídas / Capacidades de tomar decisões com o objetivo de elevar o máximo desempenho / O futuro é bom estar por dentro de tudo e saber algumas coisas / Minha família / Aprender mais para no futuro desenvolver algo maior / Criar mais modelos de machine learning

Algun outro comentário?

Aplicação 6 (em 2022)

Não (49x) / Gostei muito de tudo / Deu tudo certo / Gostei muito do conceito de aprendizagem e dos profissionais / Nenhum / Foi muito boa as aula, mais eu gostaria que fosse presencial porque eu consigo aprender mais assim / Não, muito obrigada pela oportunidade de aprender machine learning professor! / Obrigado por essa oportunidade / Aulas ótima, professor ensina muito bem, não é à toa que ele é professor da UFSC / Não obrigada por tudo bjs / Aulas perfeitas! / Achei muito legal o curso em geral / Nada mais a acrescentar / Ganhar experiência na área ajudar no meu futuro / Gostei de tudo até agora, e os professores são muito bons também

Aplicação 7 (em 2023)

Não (38x)/ O Ramon é legal / Nada, obrigada.

Fonte: elaborado pelo autor, baseado em Martins e Gresse von Wangenheim,(2022) e Marques et al.(2020)

Legenda: *exatamente como foi escrito. / †apenas comentários com conteúdo são revelados.

**ANEXO A — CHECKLIST TESTE AMBIENTE TÉCNICO PARA A APLICAÇÃO DOS CURSOS DA
COMPUTAÇÃO NA ESCOLA**



**Checklist teste ambiente técnico para a aplicação dos
cursos de *Machine Learning* e desenvolvimento de
aplicativos móveis**

SALA DE AULA

- Quantidade de computadores suficiente para os estudantes?
- Computadores funcionam?
- Computadores a ser utilizados têm mouse webcam caixas de som fone de ouvido
(casos em que o curso é ministrado por instrutor a distância deve ter também microfone)?

APP INVENTOR

- Todos os computadores estão com acesso a internet/wifi?
- Os estudantes têm acesso ao mesmo wifi em que estão os computadores da sala de informática?
- Os computadores acessam o App Inventor?
 - Site: http://ai2.appinventor.mit.edu/?locale=pt_BR
- Entrar no App Inventor, abrir o app Classificador de Recicláveis. Para isso:
 - Fazer o download do .aia
 - https://drive.google.com/file/d/1NEudixSAMVNJyG7_12YSKdv6JutYzKmR/view
 - Entrar no App Inventor: http://ai2.appinventor.mit.edu/?locale=pt_BR
 - Ir no menu Projetos
 - Selecionar a opção: Importar projeto .aia do meu computador
- Testar o app pelo App Inventor. Para isso
 - Baixar o app MIT App Inventor companion no celular:
https://play.google.com/store/apps/details?id=edu.mit.appinventor.aicompanion3&hl=pt_BR&gl=US
 Depois, no computador, na página do App Inventor
 - Clicar em Conectar

- Clicar em Assistente AI
- Abrir o MIT App Inventor companion no celular e Scanear o QR Code e testar no celular
-

SITE CURSOS COMPUTAÇÃO NA ESCOLA/UFSC

- [] Acessar site da computação na escola:
 - Site: <https://cursos.computacaonaescola.ufsc.br>
- [] Testar acessar o primeiro curso ML4ALL:
 - Site: <https://cursos.computacaonaescola.ufsc.br/cursos/curso-mlparatodos/>

GOOGLE TEACHABLE MACHINE

- [] Acessar Google Teachable Machine
 - Site: <https://teachablemachine.withgoogle.com/>
- [] Fazer um teste com o Google Teachable Machine
 - Site: https://teachablemachine.withgoogle.com/models/qeMV_sSKO/

CODEMASTER

- [] Acessar CodeMaster
 - Site: <http://apps.computacaonaescola.ufsc.br/codemaster/>

ANEXO B — MODELO DO CARTÃO SENHA PARA OS ESTUDANTES

Conta Google
_____@gmail.com
Senha _____
CPF ou e-mail do ID UFSC

Senha _____