

Desafios e Soluções no Ensino de *ML* para Estudantes em Situação de Vulnerabilidade Social

Ramon Mayor Martins¹, Christiane Gresse von Wangenheim¹, Marcelo F. Rauber¹,
Jean C. R. Hauck¹, Melissa Figueiredo Silvestre²

¹Departamento de Informática e Estatística – Universidade Federal de Santa Catarina
(UFSC)

Caixa Postal 476 – 88.040-900 – Florianópolis – SC – Brazil

²Programa PodeCrer – Instituto Vilson Groh
88.015-415 – Florianópolis – SC – Brazil

{ramon.mayor,marcelo.rauber}@posgrad.ufsc.br, {c.wangenheim,
jean.hauck}@ufsc.br, melissa@redeivg.org.br

Abstract. *Considering the importance of Machine Learning today, it is essential to promote ML education from an early age, aiming for equality and including students from a low socio-economic status background. This study analyzes the application of the ML4ALL! course to 158 middle and high school underprivileged students. The results show that the students are able to learn to understand basic ML concepts and to develop their first ML model. Despite the challenges in this context, the results suggest that barriers can be overcome by building partnerships between social institutions and universities, close one-on-one support, and adapted pedagogical approaches.*

Resumo. *Considerando a importância do Machine Learning atualmente, é essencial promover o ensino de ML desde cedo, visando à igualdade e incluindo também estudantes em situações de vulnerabilidade social. Este relato de experiência analisa e discute a aplicação do curso ML4ALL! a 158 estudantes do ensino fundamental e médio em situação de vulnerabilidade social. Os resultados mostram que os estudantes aprenderam a entender conceitos de ML e a desenvolver seu primeiro modelo de ML. Apesar dos desafios nesse contexto, os resultados sugerem que as barreiras podem ser superadas por meio da criação de parcerias entre instituições sociais e universidades, do apoio individualizado e de abordagens pedagógicas adaptadas.*

1. Introdução

O *Machine Learning* (*ML*), um subcampo da Inteligência Artificial (*IA*), surgiu da necessidade de criar programas de computador capazes de melhorar seu desempenho em uma tarefa específica, à medida que ganham mais experiência [Mitchell 1997]. É cada vez mais comum a presença do *ML* em aplicações cotidianas, como reconhecimento facial e assistentes inteligentes [Li 2022]. Assim, a preparação dos estudantes para um futuro com *IA/ML* torna-se crucial já nas escolas [Camada e Durães 2020][Caruso e Cavalheiro 2021]. Oportunizar esses temas é importante inclusive para a participação social e econômica dos jovens [Touretzky et al. 2022], considerando também as emergentes oportunidades para profissionais de *IA* [WEF, 2020].

Recentemente têm surgido iniciativas, tais como AI4K12 e o programa Erasmus+, com o objetivo de introduzir *IA/ML* a jovens na educação básica, incluindo o ensino de conceitos básicos de *ML*, redes neurais artificiais e questões éticas

[Touretzky et al. 2022] [UNESCO 2022]. No entanto, para o ensino de *ML*, assim como de computação em geral, as desigualdades são significativas, afetadas por fatores como cidadania, raça, etnia e contexto socioeconômico dos estudantes [Parker e Guzdial 2015] [UNRISDSP 2015]. De maneira particular, os estudantes em situação de vulnerabilidade social, provenientes de famílias socioeconomicamente desprivilegiadas, enfrentam circunstâncias como falta de infraestrutura e qualidade de ensino em suas escolas, bem como conhecimento limitado em computação e informática básica [OECD PISA 2018] [Parker e Guzdial 2015]. Algumas iniciativas como AI4ALL [AI4ALL 2023], The Coding School [TCS 2023] e IBM SkillsBuild [IBM 2023] começaram a incorporar a educação em IA/*ML* em suas missões para promover inclusão e igualdade entre os estudantes, oferecendo programas educacionais gratuitos. No entanto, esses programas não são específicos para estudantes em situação de vulnerabilidade social. Cursos voltados para ensinar IA/*ML* a esse público alvo, acessíveis mesmo àqueles que não possuem conhecimento prévio de computação ou experiência com dispositivos digitais, são raros [Martins e Gresse von Wangenheim 2023]. Assim, o ensino de IA/*ML* para estudantes em situação de vulnerabilidade social apresenta diversos desafios relacionados a limitações ou necessidades específicas, que como consequência podem agravar as desigualdades na vida desses estudantes, limitando as oportunidades de carreira, trabalho e perpetuando o ciclo de exclusão social. Contudo, é imperativo que sejam desenvolvidas estratégias de mitigação eficazes para promover a inclusão desses jovens [UNESCO 2022].

Neste contexto, este estudo analisa os desafios e soluções no ensino de *ML* para estudantes em situação de vulnerabilidade social aplicando o curso "*Machine Learning para Todos!*" (ML4ALL!). O curso visa introduzir conceitos básicos de *ML* aos estudantes dos anos finais do Ensino Fundamental e Médio no Brasil, popularizando o conhecimento de IA/*ML* e promovendo igualdade e inclusão, especialmente para aqueles em situação de vulnerabilidade social. A aplicação foi realizada como parte do Programa PodeCrer do Instituto Vilson Groh (IVG), que fornece uma formação integral desenvolvendo competências técnicas e socioemocionais, de forma totalmente gratuita para jovens em vulnerabilidade social. Os resultados desta pesquisa podem orientar e auxiliar no design e implementação de cursos de *ML* na educação básica para este contexto. E, assim, contribuir para a promoção de igualdade, equidade e inclusão, além de proporcionar novas oportunidades e possibilidades na vida desses jovens.

2. Metodologia de Pesquisa

O objetivo dessa pesquisa é analisar de forma exploratória os principais desafios e soluções de mitigação envolvidos no ensino de *ML* para estudantes no contexto de vulnerabilidade social dos anos finais do Ensino Fundamental e Médio. Para atingir este objetivo, foi realizado um estudo de caso para compreender os fenômenos observados durante a aplicação do curso neste contexto seguindo Yin [2017].

Definição do estudo. O estudo é definido em termos de objetivo e design de pesquisa. O objetivo estabelece as bases para a criação sistemática de questões e métricas de pesquisa, utilizando o método Goal/Question/Metric [Basili et al. 1994]. Com base no objetivo da pesquisa, foram definidas as seguintes questões de análise:

QA1. Os estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social atingiram os objetivos de aprendizagem?

QA2. Quais foram os desafios e soluções no ensino de *ML* para estudantes dos anos finais do Ensino Fundamental e Médio no contexto de vulnerabilidade social?

A partir destas questões de análise são definidas as métricas e instrumentos de coleta de dados. A aprendizagem dos estudantes é avaliada baseada em desempenho com base em artefatos criados pelos estudantes como resultado da aprendizagem usando a rubrica proposta por Gresse von Wangenheim (2022). A rubrica demonstrou ser confiável (coeficiente $\omega = 0,834$ /alfa de Cronbach $\alpha = 0,83$) e com validade em relação à consistência interna [Rauber et al. 2023]. A rubrica foi automatizada como parte da ferramenta online CodeMaster [Rauber et al. 2023]. Informações sobre os desafios e soluções foram coletadas por meio de observações e relatos dos instrutores, coordenação pedagógica e assistência social.

Execução do estudo. Durante a execução do estudo foi aplicado o curso na prática e os dados foram coletados conforme definido, incluindo os artefatos de *ML* desenvolvidos pelos estudantes como resultado do processo de aprendizagem e as observações e relatos em relação aos desafios e soluções.

Análise e interpretação. Os dados coletados foram analisados em relação às questões de análise. Os dados relacionados à aprendizagem dos estudantes foram avaliados com a ferramenta CodeMaster [Rauber et al. 2023] que automatiza a avaliação da rubrica. Estes resultados da avaliação foram analisados usando estatísticas descritivas, incluindo frequência acumulada e médias. Os dados coletados relacionados às observações e relatos foram analisados de forma qualitativa e organizados em termos de limitações e necessidades identificadas, consequências e ações de mitigação. O estudo foi aprovado pelo Comitê de Ética da Universidade Federal de Santa Catarina (Nº de parecer 4.893.560).

3. Curso ML4ALL!

O curso ML4ALL! [Gresse von Wangenheim et al. 2020] visa ensinar *ML* em alinhamento com diretrizes CSTA (2017), Touretzky et al. (2022), MEC (2017), SBC (2018), e Long e Magerko (2020), além das etapas do processo de desenvolvimento de *ML* centrado no ser humano [Amershi et al. 2019]. Os objetivos de aprendizagem são especificados de acordo com o perfil dos estudantes (Tabela 1).

Tabela 1. Objetivos de aprendizagem.

ID	Objetivos de aprendizagem (OA)
OA1	Conhecer e identificar exemplos de aplicação de <i>ML</i>
OA2	Descrever conceitos básicos de <i>ML</i> : o que é uma rede neural e como ela funciona, bem como 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
OA4	Treinar um modelo de <i>ML</i>
OA5	Avaliar o desempenho de um modelo de <i>ML</i>
OA6	Discutir as preocupações éticas e o impacto do <i>ML</i> na sociedade

O conteúdo do curso inclui conceitos básicos de *IA/ML*, seus potenciais e fundamentos de redes neurais. Além disso, são abordadas no curso questões éticas, impactos sociais e oportunidades de carreira. Como abordagem pedagógica, se utiliza metodologias ativas de aprendizagem. Por meio de atividades práticas, o curso leva os estudantes a aplicar o conhecimento adquirido adotando uma estratégia de "ação computacional",

motivando-os a criar artefatos significativos que tenham impacto direto em suas vidas e comunidades [Tissenbaum et al. 2019]. O curso enfoca no estágio "usar" do ciclo "Usar-Modificar-Criar" [Lee et al. 2011], no qual os estudantes são guiados passo a passo a criar um modelo de classificação de imagens de lixo reciclável, seguindo o processo de desenvolvimento de *ML* centrado no ser humano, incluindo a preparação de dados, treinamento de modelo, avaliação do desempenho e previsão. Como material instrucional, são utilizados slides interativos, demonstrações e vídeos, com foco nas atividades práticas. Como recursos tecnológicos, utiliza-se a plataforma Moodle da universidade para disponibilizar materiais didáticos. O instrutor ministra as aulas pelo Google Meet. O desenvolvimento do modelo de *ML* é suportado pelo Google Teachable Machine (GTM) [Google 2022] acessível via conta Google. O curso já foi aplicado em outras oportunidades com sucesso, para estudantes do Ensino Fundamental e Médio de todos os níveis socioeconômicos [Martins et al. 2023].

4. Aplicação e Coleta de Dados

O curso ML4ALL! foi aplicado em 2022 como parte do programa PodeCrer no Instituto Vilson Groh (IVG) para estudantes dos anos finais do Ensino Fundamental e Ensino Médio em situação de vulnerabilidade social em cooperação com a iniciativa Computação na Escola/UFSC. O curso foi aplicado como uma atividade extracurricular, com um encontro de 2 horas por semana, totalizando uma duração de 8 horas de curso. As aulas foram ministradas em turmas no turno matutino e vespertino. O curso foi realizado com os estudantes presencialmente no laboratório de informática do IVG junto com um instrutor assistente. Um instrutor da iniciativa Computação na Escola/UFSC ministrava as aulas à distância (via Google Meet) explicando as atividades. Além disso, um instrutor do Programa PodeCrer/IVG estava presente para ajudar a organizar as salas de aula. Houve também a participação de *peer* tutores que já haviam realizado o curso anteriormente e se destacaram em termos de interesse e desempenho. As aulas foram realizadas nos laboratórios informatizados do IVG, com capacidade para 25 estudantes por turma, equipados com um *notebook/mouse* e fone de ouvido com microfone por estudante.

Participantes. Um total de 178 estudantes iniciaram o curso, porém devido a vários fatores como desistências e decisões institucionais, 158 estudantes concluíram o curso. Os estudantes são do Ensino Fundamental (63 estudantes) e Ensino Médio (95 estudantes), com idades entre 14 e 19 anos. Desses, 77 estudantes são do sexo atribuído ao nascimento feminino e 81 estudantes são do sexo atribuído ao nascimento masculino. Os estudantes são predominantemente de escolas públicas (74%), enquanto os demais recebem bolsas de estudo para frequentar escolas particulares. A maioria dos estudantes é brasileiro e fluente em seu idioma nativo (português brasileiro). Sete estudantes migrantes também participaram, entre eles seis de língua espanhola e um de língua francesa/crioula, todos com bom entendimento do português brasileiro.

Os estudantes do programa PodeCrer/IVG que participaram do curso enfrentam desafios como vulnerabilidade socioeconômica, situações delicadas familiares, criminalidade em suas comunidades e falta de infraestrutura educacional de qualidade em suas escolas [IVG 2022]. Muitos dependem do programa para sua alimentação e sem incentivo adequado, podem optar pela criminalidade. Apesar das expectativas

curriculares da Base Nacional Comum Curricular para seus níveis educacionais, suas habilidades em linguagens, matemática e ciências são baixas. Além disso, há casos de dificuldades de leitura, compreensão e expressão, bem como suspeitas de Transtorno do Déficit de Atenção com Hiperatividade e atraso cognitivo. Embora as escolas desses estudantes possuam equipamentos de computação, muitos dos estudantes demonstraram um conhecimento limitado em computação. A grande maioria não tem computador em casa, porém, são acostumados a usar dispositivos móveis no seu dia a dia.

Coleta de dados. Como dados foram coletados os artefatos de *ML* desenvolvidos pelos estudantes como resultado da aprendizagem. Os artefatos entregues foram avaliados baseado no desempenho utilizando uma rubrica de pontuação automatizada na ferramenta CodeMaster [Rauber et al. 2023]. Os dados dos estudantes que submeteram artefatos para 3 ou menos critérios da rubrica foram desconsiderados em razão de poucas informações disponíveis para análise. A quantidade de artefatos coletados por critério da rubrica de pontuação da avaliação baseada em desempenho é apresentada na Tabela 2.

Tabela 2. Quantidade de artefatos coletados por critérios da rubrica da avaliação baseada em desempenho [Rauber et al. 2023]

Crítérios	Quantidade de artefatos coletados
C1 - Quantidade de imagens	79
C2 - Distribuição do conjunto de dados	79
C3 - Rotulação das imagens	79
C4 - Treinamento	79
C5 - Análise da acurácia por categoria	74
C6 - Interpretação da acurácia	74
C7 - Análise da matriz de confusão	73
C8 - Interpretação da matriz de confusão	73
C9 - Ajustes/melhorias realizadas	76
C10 - Testes com novos objetos	73
C11 - Análise dos resultados dos testes	73
C12 - Interpretação dos resultados dos testes	73

Os dados coletados referentes aos desafios e soluções do ensino de *ML* para estudantes em situação de vulnerabilidade social foram baseados em observações e relatos dos instrutores da iniciativa Computação na Escola/UFSC e programa PodeCrer/IVG. Esses dados foram discutidos e analisados em conjunto com a coordenação pedagógica e assistência social do programa PodeCrer/IVG. Ao final, os resultados foram organizados em termos de limitações e necessidades identificadas, as consequências diretas aos estudantes e soluções de mitigação para o ensino adequado aos estudantes neste contexto.

5. Resultados e Análise dos Dados

5.1. Os estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social atingiram os objetivos de aprendizagem?

A partir da avaliação baseada em desempenho, em geral o resultado da aprendizagem dos estudantes foi considerado alto, com uma média total de 7.5 pontos, em uma escala de 0 a 10. Este resultado indica que os estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social são capazes de adquirir e desenvolver conhecimentos básicos de *IA/ML*. Os resultados da aprendizagem revelam

que estes estudantes também são capazes de executar as principais etapas de um processo de desenvolvimento de *ML* centrado no ser humano, mesmo aqueles sem conhecimento prévio em computação/IA/*ML*, com médias > 7 pontos na maioria dos critérios de avaliação da rubrica (Figura 1). A média baixa (6 pts), no critério que avalia a "quantidade de imagens" utilizadas para treinar o modelo, pode indicar que os estudantes utilizaram o mínimo de imagens para avançar mais rápido às próximas etapas da atividade. Já a média mais baixa dentre todas (5.8 pts) referente ao critério "análise da matriz de confusão" pode ser causada pelo fato que muitos estudantes ainda não aprenderam o tópico de matrizes na escola, dificultando a compreensão dos dados da matriz de confusão (o que foi previsto *vs* a rotulação correta). Observa-se, por outro lado, que eles conseguiram posteriormente interpretar de forma correta os acertos e não acertos do modelo treinado, com uma média alta (9.3 pts). Isto pode demonstrar que mesmo analisando de forma equivocada a matriz de confusão muitas vezes, eles conseguem saber de forma visual se teve muitas ou poucas confusões, e se precisa ou não de melhorias.

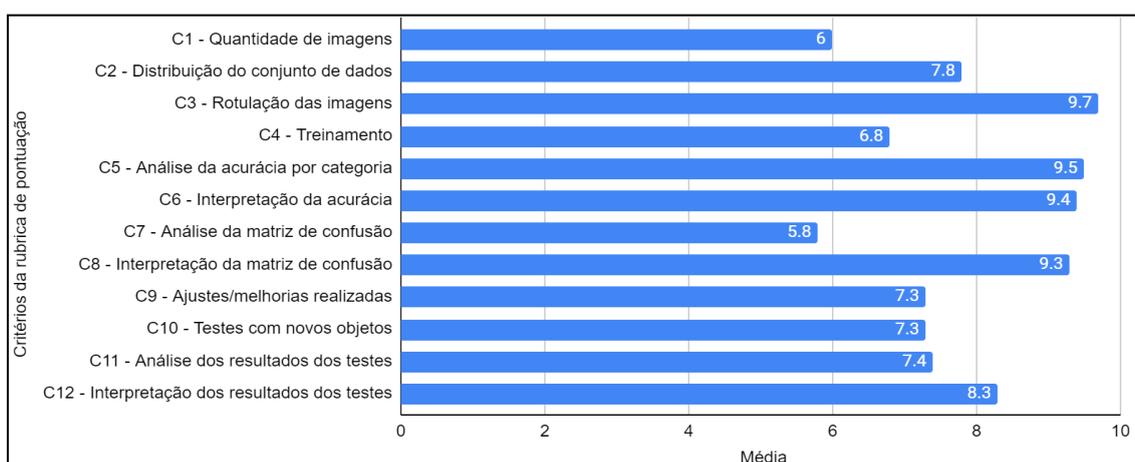


Figura 1. Resultado da aprendizagem dos estudantes por critérios de avaliação na rubrica de pontuação da avaliação baseada em desempenho.

Durante as aulas também se observou que as tarefas manuais, principalmente a "distribuição do conjunto de dados", foi a etapa em que os estudantes mais levaram tempo, enquanto que a etapa de "treinamento" foi observada como a mais rápida, reforçando a praticidade da ferramenta GTM para essa etapa.

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

A aplicação do curso ML4ALL! em um contexto de estudantes em situação de vulnerabilidade social enfrenta vários desafios, com consequências diretas para a aprendizagem e exigindo soluções de mitigação (Tabela 3).

Necessidade tecnológica. O curso foi realizado no laboratório de informática do IVG. O instituto disponibilizou um *notebook* com mouse para estudantes e fones de ouvido com microfone para possibilitar a execução do curso em ritmos individuais de cada estudante. O IVG contava com uma conexão robusta com a Internet com largura de banda suficiente. Isso permitiu que os estudantes acessassem o Sistema de

Gerenciamento de Aprendizagem (plataforma Moodle/UFSC) para executar as atividades práticas em seu próprio ritmo. No entanto, como a maioria dos estudantes não têm computador em casa, o escopo das atividades teve de se limitar àquelas que poderiam ser concluídas durante as aulas, devido à impossibilidade de se fazer qualquer lição de casa.

Habilidades básicas de computação. Inicialmente, as aulas foram previstas a serem realizadas com o instrutor do programa PodeCrer/IVG organizando as salas, junto com os estudantes presencialmente no IVG e os instrutores da Computação na Escola/UFSC ensinando remotamente. Devido às limitações observadas no início do curso nas habilidades básicas de computação dos estudantes, foi identificada a necessidade de um instrutor da Computação na Escola/UFSC presente também na sala de aula para reforçar a assistência aos estudantes, principalmente nas atividades práticas. Outra questão observada foi a falta do costume dos estudantes em usar e-mail e conseqüentemente, frequentemente esqueciam suas senhas necessárias para acessar a sua conta Google e a plataforma Moodle/UFSC. Como mitigação, foram criados cartões com suas senhas, para auxiliá-los a lembrar.

Atrasos e Faltas. Muitos estudantes que residiam ou estudavam longe do IVG e dependiam do transporte público, se atrasavam. Portanto, as aulas do período vespertino começavam um pouco mais tarde e terminavam um pouco mais cedo para se ajustar aos horários de transporte dos estudantes. As faltas dos estudantes eram comuns devido também a vários fatores ligados ao contexto de vulnerabilidade social, incluindo situações familiares, problemas de transporte e também situações sociais e ambientais de forma geral, como bloqueio de estradas e enchentes. Para mitigar isso, os instrutores realizaram revisões rápidas para estudantes que faltavam ou destacavam pontos chave dos slides interativos da aula anterior. Os estudantes que perderam várias aulas eram também encorajados a trabalhar em colaboração com colegas que haviam assistido às aulas, ajudando-os a manterem-se atualizados com as atividades.

Necessidade de mentoria. Percebemos que muitos estudantes, por carecerem de conhecimentos básicos de computação, tinham dificuldade para acompanhar as atividades. Em alguns casos os estudantes não sabiam realizar tarefas simples como o *download* de um arquivo. Para reforçar o apoio, especialmente durante atividades práticas, foi alocado um instrutor adicional com experiência em *AI/ML* da iniciativa Computação na Escola/UFSC para prestar assistência de forma presencial um-a-um. Além disso, com a adoção da estratégia de aprendizado prático, permitindo que os estudantes seguissem instruções online passo a passo, muitas dúvidas sobre tópicos diferentes eram geradas, necessitando de vários assistentes de ensino simultaneamente. Conseguimos mitigar essa questão com a ajuda combinada dos instrutores da Computação na Escola/UFSC, PodeCrer/IVG e especialmente da designação de estudantes mais avançados atuando como *peer* tutores. Esses *peer* tutores, também estudantes do Ensino Fundamental e Médio foram selecionados por sua maturidade, interesse e desempenho em outras atividades no IVG. A atuação dos *peer* tutores também ajudou positivamente nos casos em que alguns estudantes tímidos se sentiam desconfortáveis em pedir ajuda dos instrutores. Dessa forma, esses estudantes conseguiram estabelecer uma conexão melhor com os *peer* tutores, inclusive os estudantes com dificuldades sentiram mais a vontade de procurar ajuda com eles. De

forma geral a atuação dos *peer* tutores foi muito eficaz e eficiente, demonstrando proatividade, empatia e preocupação pelos colegas. A atuação como *peer* tutores também ajudou em aumentar a sua autoestima, ao serem reconhecidos como “professores” perante a turma.

Organização do cronograma das aulas. O curso, integrado ao programa PodeCrer/IVG, foi planejado com aulas apenas uma vez por semana, criando assim um grande intervalo entre as aulas, o que dificultou a retenção do conteúdo pelos estudantes. Para mitigar essa questão, os instrutores começaram a fazer revisões rápidas no início das aulas para recapitular o conteúdo da aula anterior antes de introduzir novos conteúdos.

Interesse e motivação do estudante. Durante as aulas, alguns estudantes demonstravam desinteresse pelo curso, muitas vezes não participando das atividades e apresentando certa apatia. Isso era compreensível, uma vez que diante do contexto desafiador que estão inseridos, vivenciam situações complexas. Além disso, muitos estudantes foram inscritos no programa PodeCrer/IVG por suas famílias como uma forma de lhes oferecer oportunidades e evitar que eles se envolvessem em outras atividades externas que os prejudiquem. Isso às vezes resultava em falta de interesse, já que alguns se sentiam obrigados a participar. Para mitigar essa questão, os instrutores buscavam motivar os estudantes ao destacar as oportunidades oferecidas pelo curso, como seguir uma carreira na área ou desenvolver suas próprias soluções comercializáveis. Adicionalmente, buscou-se também conectar os interesses dos estudantes com o conteúdo do curso. Por exemplo, para um estudante interessado em carros, os instrutores demonstraram como o *ML* é aplicado em veículos autônomos.

Estudantes mais velhos do Ensino Médio demonstraram mais preocupações sobre suas perspectivas futuras, como ingressar na universidade ou explorar oportunidades de emprego. Para motivá-los, foi realizada uma visita à universidade para apresentar pesquisas proeminentes em *IA/ML*, inclusive a apresentação do projeto de carro de corrida autônomo. Já os estudantes do Ensino Fundamental tendiam a priorizar suas vidas cotidianas, muitas vezes abrindo jogos online após as atividades do dia. Os instrutores utilizavam essas oportunidades para discutir brevemente sobre jogos que utilizam *IA/ML*, reconhecendo que essas atividades poderiam ser válidas para reforçar suas habilidades em computação básica, especialmente considerando que muitos estudantes não possuíam computadores em casa.

Dificuldade em aprender *ML*. Ocasionalmente, as atividades do curso pareciam excessivamente complexas para alguns estudantes devido à falta de conhecimento básico de computação, timidez ou falta de interesse, levando-os a desistir rapidamente. Consequentemente, esses estudantes se distraíam facilmente, se envolviam em outras atividades ou simplesmente esperavam o tempo passar. Para mitigar essas questões, os instrutores identificaram colegas mais próximos desses estudantes ou aqueles com quem se sentiam mais à vontade para conversar na sala de aula. Eles foram então convidados a trabalhar em pares ou pequenos grupos. Esta abordagem colaborativa se mostrou positiva, pois incentivou a discussão e a resolução de problemas em conjunto em algumas atividades.

Heterogeneidade de competências. Os estudantes participantes do curso frequentam várias escolas da região, que possuem diferentes níveis de qualidade de ensino, resultando portanto em uma gama de diferentes níveis de competências, experiências e maturidade. Essa diversidade resulta em diferentes ritmos e interesses dentro do curso. Como estratégia de mitigação, a coordenação pedagógica do IVG procurou separar as turmas principalmente com base no estágio escolar (turmas com maioria dos estudantes do Ensino Fundamental e turmas com a maioria dos estudantes do Ensino Médio). De forma geral, observando a falta de conhecimentos básicos, os instrutores adotaram um ritmo de ensino mais lento e suave. Observou-se também que a estratégia instrucional do curso ML4ALL! de atividades práticas realizadas individualmente pelos estudantes, possibilitou a cada um avançar no seu ritmo e assim atingir os objetivos de aprendizagem.

Adaptação do material instrucional. O material didático do curso ML4ALL! consiste principalmente de slides interativos. No entanto, observou-se que os estudantes muitas vezes descartavam a leitura das instruções passo a passo, uma vez que muitos não têm o hábito ou paciência para leitura. Isso resultou na execução incorreta das atividades. Observando que esses estudantes estão acostumados a seguir vídeos curtos em plataformas de redes sociais, preparamos vídeos instrucionais curtos para explicar certas atividades passo a passo e demonstrar o uso de ferramentas como o GTM e o CodeMaster. Esses vídeos se mostraram cruciais para esclarecer a funcionalidade das ferramentas e orientar as atividades.

Tabela 3. Síntese das limitações, consequências e ações de mitigação no ensino de ML para estudantes em situação de vulnerabilidade social

Limitações	Consequências	Ações de mitigação
Necessidade tecnológica	<ul style="list-style-type: none"> Falta de oportunidade de aprender 	<ul style="list-style-type: none"> Realização do curso em um laboratório de informática com um <i>notebooks</i>/fone de ouvido com microfone por estudante Não há lição de casa como parte do curso
Habilidades básicas de computação	<ul style="list-style-type: none"> Dificuldade de aprendizado Dificuldade em acompanhar as atividades 	<ul style="list-style-type: none"> Instrutor presencial para reforçar as habilidades de computação Cartões para lembrar a senha das plataformas usadas nas aulas.
Atrasos e Faltas	<ul style="list-style-type: none"> Dificuldade em acompanhar as aulas Atrasos no início da aula Dificuldade de acompanhamento dos estudantes ausentes 	<ul style="list-style-type: none"> Os instrutores preparando as salas de aula Início das aulas um pouco mais tarde e término mais cedo Revisão rápida e apontamento dos destaques do material pelos instrutores
Necessidade de mentoria	<ul style="list-style-type: none"> Dificuldade em acompanhar as aulas e atividades Maior dificuldade para os estudantes aprenderem o conteúdo. Menor envolvimento e motivação dos estudantes. Sobrecarga de trabalho dos instrutores. 	<ul style="list-style-type: none"> Instrutores com experiência em AI/ML (remoto e presencial). Instrutores para ajudar com a computação básica. Alunos de turmas avançadas atuando como <i>peer</i> tutores
Organização do cronograma de aula	<ul style="list-style-type: none"> Dificuldade de retenção do conteúdo pelos estudantes 	<ul style="list-style-type: none"> Os instrutores fazem uma revisão rápida para que os estudantes estejam no mesmo nível do novo conteúdo.
Interesse e motivação do estudante	<ul style="list-style-type: none"> Baixo envolvimento e participação nas atividades e na sala de aula. Estudantes poderiam se sentir obrigados a participar Desistência do curso 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; Abordagens alternativas para envolver os estudantes que não têm interesse em tecnologia, vinculando o conteúdo do curso aos interesses dos estudantes Visita à universidade apresentando a pesquisa e o potencial de IA/ML
Dificuldade em aprender ML	<ul style="list-style-type: none"> Desistência ou dispersão nas atividades do curso 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
Heterogeneidade de competências	<ul style="list-style-type: none"> Desinteresse de alguns estudantes Diferentes ritmos Resultados de desempenho muito divergentes 	<ul style="list-style-type: none"> Adoção de um aprendizado mais lento e suave Realização de atividades práticas individualmente ou em grupos, em seu próprio ritmo Criação de um ambiente inclusivo e acolhedor, reconhecendo as diferenças individuais de cada estudante <i>Peer</i> tutores para ajudar os estudantes com mais dificuldades

Adaptação do material instrucional	<ul style="list-style-type: none">• Dificuldade de entender o conteúdo• Dificuldade em acompanhar as atividades• Dificuldade de aprendizado• Desmotivação do estudante	<ul style="list-style-type: none">• Criação de vídeos curtos, além de slides interativos
------------------------------------	---	--

5.3. Ameaças a validade

Diversos fatores podem ter impactado a validade dos resultados neste estudo. Uma destas questões é o tamanho da amostra. Contudo, acreditamos que a amostra de 158 estudantes é adequada em relação às perguntas de pesquisa neste estudo. Outra questão é a validade da conclusão. Neste contexto utilizamos para a avaliação da aprendizagem uma rubrica estatisticamente validada com alto nível de confiabilidade (coeficiente ômega = 0,834/alfa de Cronbach $\alpha = 0,83$) e com validade em relação à consistência interna [Rauber et al. 2023]. Em termos de validade interna, foi observada uma taxa de evasão baixa, especialmente quando se considera que os participantes do estudo eram estudantes de um contexto de vulnerabilidade social. Portanto, presumimos que essa baixa taxa de evasão não teve uma influência substancial nos resultados. Os resultados apresentados aqui se baseiam em dados coletados da aplicação do curso ML4ALL! no IVG, no sul do Brasil. Portanto, a possibilidade de generalização dos resultados pode ser limitada. Entretanto, considerando a falta de achados na literatura sobre o ensino de *ML* para estudantes em situação de vulnerabilidade social, consideramos que os resultados ainda são uma contribuição valiosa.

6. Conclusão

Com o objetivo de deixar o ensino de *ML* mais inclusivo, estudamos nesta pesquisa os resultados, desafios e soluções para ensinar *ML* para estudantes dos anos finais do Ensino Fundamental e Médio em situação de vulnerabilidade social. Neste estudo o curso ML4ALL! foi aplicado como parte do programa PodeCrer/IVG com 178 estudantes. Os resultados mostram que é possível para os estudantes em situação de vulnerabilidade social alcançarem os objetivos de aprendizado de compreender o funcionamento de *ML* e também de executar as principais etapas de um processo de desenvolvimento centrado no ser humano para desenvolver um modelo de *ML*, mesmo aqueles sem conhecimento prévio em computação/IA/*ML*.

Ensinar *ML* em um contexto de vulnerabilidade social apresenta vários desafios, como a falta de conhecimento básico de computação, a heterogeneidade de habilidades e a necessidade de despertar o interesse e a motivação desses estudantes. Muitos desses desafios estão relacionados ao próprio contexto do estudante. No entanto, ações de mitigação como provimento de maior suporte instrucional e abordagem pedagógica adaptada, proporcionaram resultados promissores de aprendizado. Desta forma, os resultados desta pesquisa podem apontar formas de adaptações de ensino para este contexto. Com base nestes resultados promissores, estamos dando sequência no desenvolvimento de cursos para este público alvo voltado ao nível "criar" para permitir que esses estudantes criem seus próprios modelos de *ML* e resolvam problemas relevantes para eles e suas comunidades.

Agradecimentos

Gostaríamos de agradecer a todos os estudantes que participaram do curso e toda equipe do IVG. O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (CNPq).

Referências

- AI4ALL. (2023). <https://ai-4-all.org/>.
- Amershi, S., et al. (2019). Software engineering for machine learning: A case study. Proc. of the Int. Conference on Software Engineering: Software Engineering in Practice. Montreal, QC, Canada.
- Basili, V. R., Caldiera, G., & Rombach, H. D. (1994). Goal question metric paradigm. In Encyclopedia of Software Engineering. Wiley.
- Camada M. Y. e Durães G. M., (2020), Ensino da Inteligência Artificial na Educação Básica: um novo horizonte para as pesquisas brasileiras. Anais do XXXI Simpósio Brasileiro de Informática na Educação, Natal, RN, Brasil.
- Caruso A. L. M. e Cavalheiro S. A. da C., (2021), Integração entre Pensamento Computacional e Inteligência Artificial: uma Revisão Sistemática de Literatura. Anais do XXXII Simpósio Brasileiro de Informática na Educação. Online
- CSTA. (2017). K–12 Computer Science Framework. <http://www.k12cs.org>.
- Google. (2022). Google Teachable Machine. <https://teachablemachine.withgoogle.com/>
- Gresse von Wangenheim, C., Marques, L. S., Rauber, M. F., & Hauck, J. C. R. (2022). A Proposal for Performance-based Assessment of the Learning of Machine Learning Concepts and Practices in K-12. Informatics in Education, 21(3).
- Gresse von Wangenheim, C., Marques, L. S., & Hauck, J. C. R. (2020). Machine Learning for All – Introducing Machine Learning in K-12. SocArXiv.
- IBM. (2023). IBM SkillsBuild. <https://skillsbuild.org/>.
- Lee, I. et al. (2011). Computational thinking for youth in practice. ACM Inroads, 2(1).
- Li, Y. (2022). Research and application of deep learning in image recognition. Proc. of the Int. Conference on Power, Electronics and Computer Applications . Shenyang, China.
- Martins, R. M., Gresse von Wangenheim, C., Rauber, M. F., & Hauck, J. C. (2023). Machine Learning for All!—Introducing Machine Learning in Middle and High School. International Journal of Artificial Intelligence in Education. Online.
- Martins, R. M. & Gresse von Wangenheim, C., (2023). Teaching Computing to Middle and High School Students from a Low Socio-Economic Status Background: A Systematic Literature Review. Informatics in Education. Online.
- MEC. (2017). Base Nacional Comum Curricular. <http://basenacionalcomum.mec.gov.br>.
- OECD PISA. (2018). PISA 2018 Results Where All Students Can Succeed: Country Note Brazil.

- Parker, M. C., & Guzdial, M. (2015). A critical research synthesis of privilege in computing education. Proc. of Research in Equity and Sustained Participation in Engineering, Computing, and Technology, Charlotte, NC, USA.
- Rauber, M. F. et al. (2023). Reliability and Validity of an Automated Model for Assessing the Learning of Machine Learning in Middle and High School. Informatics in Education. Submetido.
- SBC. (2018). Diretrizes para ensino de Computação na Educação Básica. Sociedade Brasileira de Computação. <https://www.sbc.org.br/educacao/diretrizes-para-ensino-de-computacao-na-educacao-basica>.
- The Coding School. (2023). <https://the-cs.org/>.
- Tissenbaum, M., Sheldon, J., & Abelson, H. (2019). From Computational Thinking to Computational Action. Communications of the ACM, 62(3).
- Touretzky, D. S., Gardner-McCune, C., & Seehorn, D. (2022). Machine learning and the five big ideas in AI. International Journal of Artificial Intelligence in Education. Springer Nature.
- UNESCO. (2022). K-12 AI curricula – A mapping of government-endorsed AI curricula. Paris.
- UNRISDSP. (2015). According to Social Protection and Human Rights. United Nations Research Institute for Social Development.
- World Economic Forum. (2020). The Future of Jobs Report.
- Yin, R. K. (2017). Case study research and applications: Design and methods. SAGE Publications.