

Eficácia das Metodologias Ativas e do Suporte Tecnológico no Ensino de *Machine Learning* na Educação Básica

Ramon Mayor Martins
Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis - SC - Brasil
ramon.mayor@posgrad.ufsc.br

Marcelo Fernando Rauber
Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis - SC - Brasil
magcid@gmail.com

Christiane Gresse von Wangenheim
Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis - SC - Brasil
c.wangenheim@ufsc.br

Jean Carlo Rossa Hauck
Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis - SC - Brasil
jean.hauck@ufsc.br

RESUMO

Considerando a relevância e inserção do *Machine Learning* (ML) no dia-a-dia das pessoas, torna-se fundamental popularizar as competências de ML desde cedo. Por ser um conteúdo emergente na educação básica, ainda há a necessidade de analisar a eficácia de estratégias pedagógicas para auxiliar na aprendizagem. Nesse contexto, apresentamos um relato da análise das metodologias de aprendizagem ativas e do suporte tecnológico utilizados no curso ML4ALL, para o ensino da aplicação de conceitos básicos de ML por meio de uma série de estudos de casos com um total de 87 estudantes dos anos finais do ensino fundamental e médio. Os resultados da avaliação mostraram que os estudantes desse nível educacional foram capazes de construir uma compreensão de ML e de desenvolver um modelo de classificação de imagem.

CCS CONCEPTS

• **Social and professional topics** → Computing education.

PALAVRAS-CHAVE

Educação computacional, *Machine Learning*, educação básica.

1 INTRODUÇÃO

A Inteligência Artificial (IA) desempenha um papel cada vez mais relevante no cotidiano. Muitas das soluções de IA foram desenvolvidas por meio do *Machine Learning* (ML),

um subcampo da IA [19][18]. Há um entendimento comum de que os aprendizes do século 21 estão envolvidos no uso de sistemas de IA/ML [20]. Neste sentido, a familiarização dos jovens com essas tecnologias é crucial, a fim de permitir-lhes uma participação social e econômica [23], além de encorajá-los a considerar carreiras nessa área, com vasta oportunidade de trabalho [21]. Para isso, é importante que os estudantes tenham contato com essas áreas o mais cedo possível [7], introduzindo fundamentos de IA/ML logo na educação básica [5], possibilitando-os que se tornem criadores de soluções inteligentes [23].

No entanto, como tradicionalmente o ML é ensinado principalmente no ensino superior [14] somente recentemente tem sido observada uma tendência de ensinar ML já a partir da educação básica [15][14]. Conforme as diretrizes curriculares da Inteligência Artificial para K-12 (AI4K12), nesse estágio educacional os estudantes devem aprender conceitos básicos de ML, como os fundamentos de redes neurais e aprendizado profundo, bem como seus impactos sociais e questões éticas [23]. Com o objetivo de ensinar a aplicação destes conceitos, eventualmente são abordadas também as principais etapas de um processo centrado no ser humano para o desenvolvimento de aplicações de ML [1]: preparação de dados, treinamento de modelo, avaliação de desempenho, bem como a implantação como parte de jogos, sites da web ou aplicativos móveis. Entretanto, ainda assim, existem poucas iniciativas que contemplam o ensino de ML nesse estágio, incluindo sobretudo sua aplicação em escolas brasileiras [15].

Diante desse cenário, foi desenvolvido o curso "*Machine Learning* para todos" (ML4ALL). Utilizando metodologias de aprendizagem ativas [4], o curso guia os estudantes a desenvolver um modelo de ML para a tarefa de classificação de imagens de lixo reciclável seguindo o processo de desenvolvimento de ML, incluindo preparação de dados, treinamento do modelo e avaliação de

Fica permitido ao(s) autor(es) ou a terceiros a reprodução ou distribuição, em parte ou no todo, do material extraído dessa obra, de forma verbatim, adaptada ou remixada, bem como a criação ou produção a partir do conteúdo dessa obra, para fins não comerciais, desde que sejam atribuídos os devidos créditos à criação original, sob os termos da licença CC BY-NC 4.0.

EduComp '23, Abril 24-29, 2023, Recife, Pernambuco, Brasil (On-line)

© 2023 Copyright mantido pelo(s) autor(es). Direitos de publicação licenciados à Sociedade Brasileira de Computação (SBC).

desempenho. Como suporte tecnológico é usado o Google Teachable Machine (GTM), uma ferramenta web, gratuita, que permite criar modelos de ML de forma rápida, fácil e acessível [8]. Contudo, há poucas análises das estratégias pedagógicas e tecnológicas, incluindo as metodologias e ferramentas de suporte tecnológico adotadas nos cursos existentes [15]. Portanto, neste relato de experiência, é apresentado a análise da eficácia das metodologias de aprendizagem ativas e do uso da ferramenta de suporte tecnológico GTM adotada no curso ML4ALL por meio de uma série de aplicações práticas. Os resultados deste relato de experiência podem sobretudo orientar e auxiliar no desenvolvimento e aplicação dos cursos de ML na educação básica, a fim de contribuir para a divulgação e popularização do ML entre os jovens estudantes.

2 TRABALHOS RELACIONADOS

As iniciativas de ensino de ML estão emergindo, e sendo propagadas na educação básica, principalmente no Ensino Médio em países como Estados Unidos, China e Grã Bretanha [14]. Neste contexto internacional, iniciativas como a AI4K12 se destaca, com o objetivo de desenvolver diretrizes de ensino sobre IA (incluindo ML) para os currículos do ensino fundamental e médio [23]. As diretrizes AI4K12 citam 5 grandes ideias que todos estudantes devem saber em relação à IA, dentre elas a “Grande Idéia 3”, referente à “aprendizagem”, que foca no *Machine Learning* e no entendimento que o estudante tem de ter desse tópico [23].

No Brasil, o ensino de IA é apenas sugerido como itinerário formativo, parte flexível do currículo ou atividade optativa, no novo currículo de Educação Básica brasileiro definido pela Base Nacional Comum Curricular (BNCC) [16]. Ainda assim, no Brasil existem poucas iniciativas para o ensino de IA e ML, dentre as quais observa-se o formato de cursos extracurriculares [15].

Conforme os levantamentos de mapeamentos sistemáticos da literatura previamente realizados [14][15], os cursos existentes tanto no Brasil, quanto no mundo, são em sua maioria voltados a iniciantes e variam de oficinas a cursos semestrais. Geralmente esses cursos são focados em fundamentos de ML e abordam tarefas como classificação de imagens. Esses cursos tipicamente são ensinados a partir de estratégias pedagógicas tais como as metodologias ativas de aprendizado, metodologia baseada em projeto e problema [15].

Nas metodologias ativas os estudantes estão ativamente envolvidos em seu próprio aprendizado [17]. Os princípios que norteiam estas metodologias, estão relacionados com a aprendizagem construtiva, interdisciplinar, contextualizada, reflexiva, crítica, investigativa, humanista e motivadora [17]. As metodologias

ativas são um guarda-chuva que cobre uma variedade de estratégias, tais como: atividades práticas e discussões [26]. Nas metodologias ativas, as atividades práticas visam engajar os estudantes no aprendizado por meio de tarefas de pensamento de ordem superior como (analisar, sintetizar, avaliar e refletir) [20]. Como parte integrante da aplicação das estratégias pedagógicas, ao adotar as metodologias ativas, muitos cursos utilizam ferramentas específicas para suporte tecnológico como apoio ao ensino/aprendizagem. Deste ferramental voltado ao ensino de ML nesse estágio escolar destaca-se o LearningML, PIC, PAC e o Google Teachable Machine [15].

Como forma de avaliação de seus projetos pedagógicos e metodológicos, alguns cursos avaliaram em relação à sua qualidade por meio de sua aplicação na prática. As avaliações variam em termos de fatores sendo analisados, incluindo principalmente a compreensão e aprendizagem dos conceitos de ML, entre outros, tais como motivação, engajamento, entusiasmo e interesse (Figura 1) [15].



Figura 1: Fatores de qualidade mais avaliados em relação a qualidade de cursos para o ensino de ML.

Dentre esses fatores, algumas contribuições positivas foram reportadas por [15] com relação à adoção de conjuntos de características das metodologias ativas. Tais quais apontam que foi possível engajar ativamente os estudantes na exploração, compreensão e pensamento sobre ML, além de dar-lhes mais confiança para discutir conceitos de ML e resolver problemas. Também foram encontradas contribuições positivas com relação ao uso de suporte tecnológico para o ensino/aprendizado, tal qual apontado quanto ao auxílio aos estudantes nas tarefas de pensamento de ordem superior.

Todavia explicitamente, apesar dos resultados positivos, não há achados que evidenciam a eficácia de aprendizagem ativa utilizando atividades práticas por meio de artefatos criados pelos estudantes. E também, quanto ao suporte tecnológico, não há avaliação ou achados quanto à eficácia da utilização da ferramenta GTM por meio dos artefatos que evidenciaram a aprendizagem.

3 METODOLOGIA DE PESQUISA

O objetivo desta pesquisa é relatar a análise da eficácia da estratégia pedagógica para o ensino da aplicação dos conceitos básicos de ML nos anos finais do ensino fundamental e médio. Para atingir este objetivo, foi realizada uma série de estudos de caso para compreender os fenômenos observados durante a aplicação do curso em diferentes contextos. A série de estudos de caso é realizada seguindo o procedimento proposto por [25]:

Definição do estudo. O estudo é definido em termos de objetivo e design de pesquisa. A partir do objetivo, as perguntas e medidas de pesquisa são sistematicamente derivadas usando a abordagem Goal/Question/Metric (GQM) [3]. Os instrumentos de coleta de dados são definidos e a coleta de dados é operacionalizada com base no design de pesquisa.

Execução do estudo. A execução do estudo é realizada aplicando o curso na prática e coletando dados conforme definido, incluindo os artefatos de ML criados pelos estudantes como resultados de aprendizagem e um feedback dos estudantes.

Análise e interpretação. Os dados coletados são analisados em relação às questões de análise, utilizando métodos quantitativos e qualitativos. Em seguida, os resultados são interpretados e discutidos.

Esta pesquisa foi aprovada pelo Comitê de Ética da Universidade Federal de Santa Catarina (Parecer no. 4.893.560).

4 DEFINIÇÃO DO ESTUDO

Com base no objetivo de pesquisa, foram definidas as seguintes questões de análise:

QA1. A estratégia pedagógica de metodologias ativas são eficazes para ensinar a aplicação de conceitos básicos no ensino de ML?

QA2. A ferramenta GTM é eficaz para prover suporte ao ensino da aplicação de conceitos básicos no ensino de ML?

A pesquisa foi conduzida aplicando o curso ML4ALL que tem o intuito de promover a educação de ML e popularizar o conhecimento de ML entre jovens. O curso ML4ALL foi desenvolvido para ensinar conceitos básicos de ML com foco na classificação de imagens para estudantes dos anos finais do ensino fundamental e médio sem conhecimentos prévios de programação ou IA/ML. De acordo com as diretrizes [23][13] os objetivos de aprendizagem foram definidos (Tabela 1).

O objetivo do curso é proporcionar aos estudantes uma percepção da aplicação de ML em suas vidas e também uma compreensão básica de como o ML funciona. Além disso, visa orientar os estudantes no nível de aplicação, desenvolvendo um modelo de ML pré-definido para a classificação de imagens seguindo as etapas básicas de

um processo de ML centrado no ser humano [1], incluindo a preparação de dados, treinamento de modelos, avaliação de desempenho e predição. A fim de permitir uma aplicação interdisciplinar, o modelo ML a ser desenvolvido tem como foco a tarefa de classificação das imagens de lixo reciclável, um tópico abordado na educação básica como parte das aulas de ciências [16] e também relacionado às Metas de Desenvolvimento Sustentável das Nações Unidas [24].

Tabela 1: Objetivos de aprendizagem.

ID	Objetivos de aprendizagem (OA)*
OA3	Coletar, limpar e rotular dados para o treinamento de um modelo de ML. Entender como os algoritmos de ML são influenciados pelos dados
OA4	Treinar um modelo de ML
OA5	Avaliar o desempenho de um modelo de ML

*Apresentado somente os objetivos de aprendizagem do curso ML4ALL voltados a competências de aplicação de ML.

4.1 Estratégia pedagógica de metodologias ativas

No curso são adotadas metodologias ativas envolvendo os estudantes ativamente no processo de aprendizagem [4]. A adoção dessas metodologias tem a finalidade de auxiliar os estudantes a construir sua compreensão e engajá-los nas tarefas de pensamento de ordem superior [20]. O uso das metodologias ativas ocorre por meio de atividades práticas que envolvem o estudante na análise, síntese interpretação, avaliação e reflexão sobre suas atividades [2][12]. A adoção das metodologias ativas no curso é principalmente direcionada aos objetivos de aprendizagem voltados às competências de aplicação de ML. Dessa forma, seguindo um processo iterativo centrado no ser humano, os estudantes são guiados a desenvolver um modelo de ML passo-a-passo. Como resultado de aprendizagem nesse processo, os estudantes criam artefatos que incluem o modelo gerado pelo GTM contendo as informações do conjunto de dados e treinamento e relatórios documentando o teste, análise e interpretação do desempenho do modelo treinado. Os estudantes são também motivados a relatar suas descobertas, expor suas dúvidas e discutir suas soluções.

4.2 Suporte tecnológico

Com foco no aprendizado da aplicação dos conceitos de ML, os estudantes fazem uso de materiais instrucionais que os guiam passo-a-passo para desenvolver um modelo de ML para classificação de imagens (Figura 2). Como suporte tecnológico é utilizada a ferramenta GTM [8]. A escolha do GTM tem por objetivo possibilitar que estudantes sem conhecimentos prévios de programação e ML desenvolvam rapidamente um modelo de ML. O GTM é um sistema web, gratuito e que permite de forma visual executar o processo de ML [10][6].

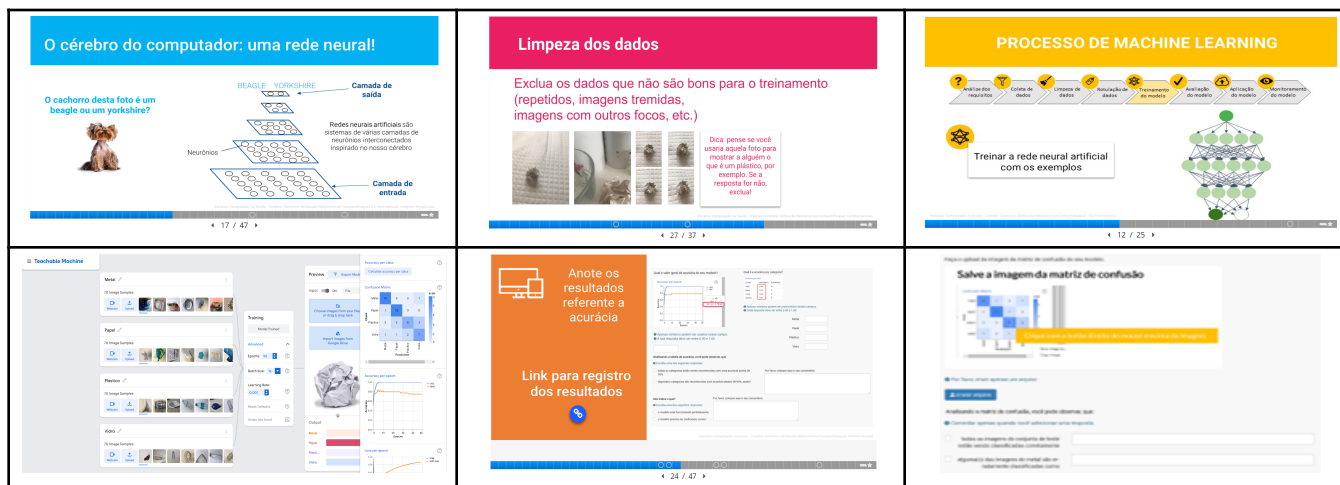


Figura 2: Exemplos de material instrucional.

A partir de um conjunto de dados pré-montados, os estudantes seguem o processo de ML, no qual inicialmente preparam o conjunto de dados, organizando, limpando e rotulando as imagens em categorias de reciclagem (papel, vidro, metal e plástico). Em seguida, realizam o treinamento do modelo, testam com novas imagens e analisam seu desempenho, considerando a acurácia e a matriz de confusão apresentada pelo GTM. Os estudantes também são orientados a ajustar o conjunto de dados e/ou parâmetros de treinamento com o intuito de melhorar o desempenho do modelo.

4.3 Avaliação dos resultados dos estudantes

De acordo com a utilização das metodologias ativas, é adotada uma avaliação autêntica [22] com base nos artefatos dos estudantes criados como resultados da aprendizagem. Essa avaliação é baseada na suposição de que certos atributos mensuráveis possam ser extraídos dos artefatos criados pelos estudantes durante o processo de aprendizagem. Dessa forma, é adotada uma avaliação baseada em desempenho utilizando uma rubrica de pontuação [9] (Tabela 2). Empregando a ferramenta GTM para ensinar a criação de modelos de ML nesta etapa educacional [6], a avaliação é realizada por meio dos artefatos de ML desenvolvidos pelos estudantes, incluindo o conjunto de dados preparado e os parâmetros de treinamento do modelo, bem como os relatórios referentes à interpretação do desempenho do modelo criado utilizando formulários online.

5 EXECUÇÃO

O curso ML4ALL foi aplicado em 4 casos na prática entre os anos de 2021 a 2022 com estudantes de 12 a 18 anos de idade. Com exceção de uma aplicação (AP1) em uma escola na qual o curso foi aplicado como parte integrante

das aulas escolares, as outras aplicações (AP2-AP4) foram conduzidas como atividades extracurriculares com participação voluntária. O curso teve duração de 8 horas, abordando os tópicos de noções gerais de IA (2h), conceitos básicos de ML (2h), desenvolvimento do primeiro modelo de ML (2h), revisão do conteúdo e processo de ML (1h) e questões éticas e impactos sociais (1h). O curso tem sido aplicado em diferentes modos de instrução, como aulas presenciais e aulas remotas com instrutores (Figura 3).

Foram coletados resultados do aprendizado da aplicação dos conceitos de ML relacionados às atividades propostas de acordo com os critérios de avaliação. Um total de 87 relatórios criados pelos estudantes documentando o desenvolvimento do modelo ML (modelo .tm) foram analisados (Tabela 3). Além disso, foi coletado o *feedback* de 82 estudantes por meio de um questionário ao final do curso, contendo suas opiniões sobre os pontos fortes e fracos do curso, baseado em [11].

Tabela 3: Visão geral dos dados coletados.

Objetivo de aprendizagem (voltado a aplicação de ML)	Critério (s) de avaliação da rubrica	Itens de dados coletados	Quantidade de resultados entregues por aplicação (AP#)				
			1	2	3	4	Total
OA3. Preparação de dados	C1-C5	Modelo .tm: Conjunto de dados	12	9	35	31	87
OA4. Treinamento do modelo (OA4)	C6	Modelo .tm: parâmetros de treinamento	12	9	35	31	87
OA5. Interpretação do desempenho (OA5)	C7-C11	Resultados dos testes, Análise da acurácia, Resultados das interpretações, Ajustes e Melhorias	12	9	35	31	87

Os resultados de aprendizagem, coletados por meio dos relatórios, foram avaliados pelos instrutores de forma

(semi-) automatizada adotando a rubrica de pontuação (Tabela 2) indicando o nível de desempenho de aprendizagem atingido pelos estudantes (Figura 4).

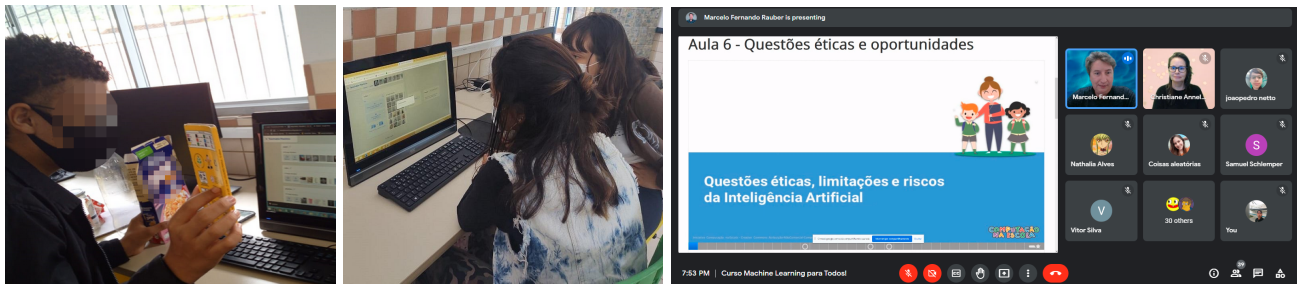


Figura 3: Aplicações presenciais e remotas com instrutores

Tabela 2: Rubrica de pontuação (Baseado em [9]).

Critérios	Níveis de desempenho		
	Ruim - 0 pt	Aceitável - 1 pt	Bom- 2 pt
Preparação de dados (OA3)			
C1. Quantidade de imagens	Menos de 20 imagens por categoria	21 a 35 imagens por categoria	Mais de 35 imagens por categoria
C2. Relevância das imagens	Várias imagens não estão relacionadas com a tarefa de ML (irrelevante) e/ou pelo menos uma imagem contém conteúdo antiético (violência, nudez, etc.)	Uma imagem é irrelevante e nenhuma imagem contendo conteúdo antiético	Todas as imagens estão relacionadas com a tarefa de ML e nenhuma imagem contendo conteúdo antiético
C3. Distribuição do conjunto de dados	As quantidades de imagens por categoria variam muito (mais de 10% de variação)	As quantidades de imagens por categoria variam pouco (entre 3 a 10% de variação)	As categorias têm aproximadamente a mesma quantidade de imagens (varia menos de 3%)
C4. Rotulação das imagens	Menos de 20% das imagens foram rotuladas corretamente	Entre 20 e 95% das imagens foram rotuladas corretamente	Mais de 95% foram rotulados corretamente
C5. Limpeza dos dados	Há várias imagens confusas (fora de foco, vários objetos na mesma imagem, etc.)	Há uma imagem confusa	Nenhuma imagem confusa foi incluída no conjunto de dados
Treinamento do modelo (OA4)			
C6. Treinamento	O modelo não foi treinado	O modelo foi treinado utilizando parâmetros padrão	O modelo foi treinado com parâmetros ajustados (por exemplo, época, tamanho do lote, taxa de aprendizagem)
Interpretação do desempenho (OA5)			
C7. Testes com novos objetos	Nenhum objeto testado	1 a 3 objetos testados	Mais de 4 objetos testados
C8. Interpretação dos testes	Interpretação incorreta	-	Interpretação correta
C9. Interpretação das acurácias	As categorias com baixa acurácia não são identificadas corretamente e a interpretação do modelo é incorreta.	Categorias corretamente identificadas com baixa acurácia, mas interpretação incorreta do modelo	Categorias corretamente identificadas com baixa acurácia e a consequente interpretação do modelo
C10. Interpretação da matriz de confusão	Os erros de classificação não são identificados corretamente e a interpretação do modelo é incorreta	Identificou corretamente as classificações erradas, mas interpretou incorretamente o modelo	Identificou corretamente o erro de classificação e a consequente interpretação do modelo
C11. Ajustes / Melhorias realizadas	Nenhuma nova iteração de desenvolvimento foi relatada	Uma nova iteração com mudanças no conjunto de dados e/ou parâmetros de treinamento foi relatada	Várias iterações com mudanças no conjunto de dados e/ou parâmetros de treinamento foram relatadas

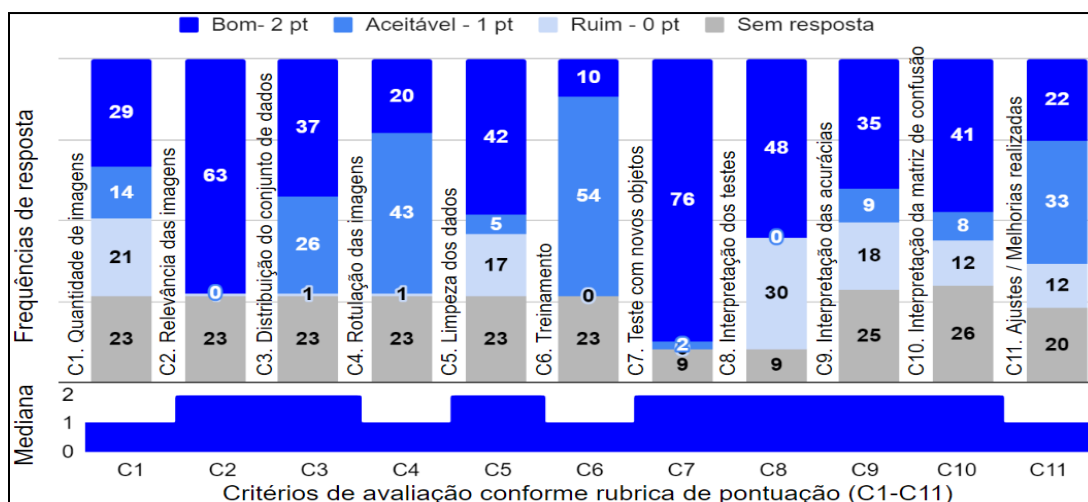


Figura 4: Frequências e medianas em relação aos critérios da rubrica de pontuação.

6 RESULTADOS

Nesta seção são apresentados os resultados das questões de análise a partir das aplicações realizadas do curso ML4ALL e seus resultados de desempenho.

6.1 As estratégias pedagógicas de metodologias ativas são eficazes para ensinar a aplicação de conceitos básicos no ensino de ML?

Com base nos resultados do desempenho alcançados na aprendizagem dos estudantes (Figura 4), é possível observar que aplicando as metodologias ativas a maioria dos estudantes (em média ~55 estudantes) foram capazes de completar as atividades propostas. Os poucos estudantes que não completaram atividades práticas (na média ~20 estudantes por atividade) foi decorrente de fatores tais como ausência em algumas aulas, e problemas técnicos (p. ex. queda de internet).

No geral, a eficácia das metodologias ativas são demonstradas pelos resultados dos estudantes em cada atividade para solucionar o problema de classificação de imagens proposto. Os estudantes em sua maioria (média de ~38 estudantes) realizaram a preparação dos dados com alto desempenho, usando uma quantidade aceitável ou boa de imagens relevantes. Isto indica que os estudantes foram capazes de decidir acerca do que consideraram pertinente ou não para o problema. A maioria dos estudantes também conseguiram treinar e executar um modelo de ML usando parâmetros padrão de treinamento.

A tarefa de pensamento de ordem superior de 'avaliar' foi incentivada pela atividade na qual os estudantes testaram seus modelos com outros objetos. A maioria dos estudantes (n=76) também relatou a execução dessa

atividade realizando testes com mais de 4 objetos diferentes, indicando um bom nível de desempenho. Esse resultado indica uma capacidade exploratória dos estudantes diante do modelo que desenvolveram, visto que todos os estudantes que realizaram a atividade testaram o novo modelo com novas imagens.

As atividades referentes à interpretação do desempenho do modelo (testes, acurácia e matriz de confusão) se enquadram na tarefa de pensamento de ordem superior de 'interpretar'. Essa interpretação é a capacidade de compreender a partir das ligações que conseguem fazer entre seu conhecimento construído e o resultado encontrado. Nessas atividades, em média (~40) estudantes alcançaram níveis 'bons' de desempenho. Porém, observou-se que, ao mesmo tempo, um número considerável de estudantes (n=30) não atingiram um desempenho aceitável, interpretando os resultados referentes aos testes da classificação erradamente. Isso pode ser devido a problemas na construção do conhecimento ou equívoco no preenchimento do questionário. Com base também no feedback dos estudantes, por exemplo: "*Infelizmente eu não tinha conseguido testar melhor a IA que criei no Google Teachable Machine*", observa-se que essa tarefa de interpretação dos resultados de desempenho do modelo de ML tem maior complexidade e pode necessitar de um suporte maior, bem como mais reforço nas explicações de modo a guiar os estudantes a realizar essas interpretações corretamente.

Com a finalidade de estimular os estudantes a refletir com base nos resultados de desempenho do modelo ML é proposta a atividade de realizar ajustes e melhorias em seus modelos. A maioria dos estudantes (n=55) realizaram pelo menos uma nova iteração de ajustes e melhorias. Nesta atividade, por meio da conexão entre a prática e seu

aprendizado adquirido, proporcionou-se aos estudantes a capacidade de tentar obter melhores resultados nos seus modelos de ML também de forma exploratória.

A eficácia das metodologias ativas foram avaliadas ainda por meio dos feedbacks dos estudantes quanto ao que mais gostaram no curso, como por exemplo: “A atividade de treinamento [do modelo de ML], onde eu poderia colocar em prática meus conhecimentos”, “Foi desenvolver o modelo e praticar vendo o que deu certo, e os erros também!”, “Quando colocamos a mão na massa e desenvolvemos um modelo de machine learning”, “A parte prática de criar a própria inteligência e fazer os testes”, “Gostei que além de ter estudado a teoria tive a oportunidade de colocar o que aprendi em prática”. Isso indica que as metodologias ativas foram pontos fortes do curso e auxiliaram a manter os estudantes engajados. Por outro lado, observou-se que as atividades práticas mais demoradas, repetitivas e monótonas como a separação e rotulação dos dados, foram citadas pelos estudantes como pontos fracos do curso: “Apesar de ser essencial, organizar a base de dados”, “Escolher e classificar as imagens de exemplo para o programa” e “Separar as imagens do conjunto de dados”. Isto levanta indícios de que somente as metodologias ativas não garantem o engajamento dos estudantes, necessitando de ajustes nas atividades para torná-las menos monótonas, ou uma maior motivação extrínseca explicando a necessidade dessas atividades, mesmo sendo monótonas, como parte essencial no processo de desenvolvimento de um modelo de ML.

Comparando a aplicação (AP1) como parte escolar com as aplicações extracurriculares com as aplicações (AP2-AP4) em que os estudantes participaram voluntariamente, observou-se também que a adoção das metodologias ativas em si podem não ser suficientes para despertar o interesse dos estudantes participando de forma compulsória, necessitando também da disposição/vontade de aprender e conseqüentemente realizar as atividades. Assim, observa-se a importância de tornar o curso motivante para os estudantes desde o início, apresentando a relevância do conteúdo em seu cotidiano.

6.2 A ferramenta GTM é eficaz para prover suporte ao ensino da aplicação de conceitos básicos no ensino de ML?

Os resultados da avaliação também apontaram que a ferramenta GTM é eficaz no ensino de ML de iniciantes nesses estágios educacionais. Seguindo as instruções passo-a-passo, os estudantes conseguiram facilmente e gratuitamente acessar a ferramenta mesmo utilizando diversos tipos de computadores em suas residências nas aplicações (AP2-AP4) ou na sala informatizada da escola da aplicação AP1.

Oferecendo uma interface visual disponível no idioma Português, a maioria dos estudantes (em média ~56) conseguiram executar todas as atividades práticas, incluindo fazer o *upload* das imagens do conjunto de dados, treinar o modelo, testar novas imagens, bem como também analisar o desempenho do modelo de ML.

Uma grande vantagem da ferramenta GTM também é o seu tempo de treinamento do modelo, que geralmente com um conjunto de dados de (~200 imagens) não ultrapassa 1 min. Isso possibilitou a conclusão dessa atividade de forma rápida, sem desviar a atenção dos estudantes ou diminuir seu entusiasmo. Essa rapidez no treinamento permitiu também que os estudantes pudessem treinar o modelo várias vezes durante a aula e assim pudessem construir seu aprendizado e conhecimento por meio dos seus esforços de tentativa e erro na ferramenta. Em apenas uma ocasião, um estudante relatou problema no treinamento, um *bug* que interrompia o treinamento em uma determinada época. Porém, mesmo assim não o inviabilizou prosseguir nas atividades.

A maioria dos estudantes (n=76) conseguiram realizar testes com novos objetos, expressando também a interface intuitiva da ferramenta, principalmente nessa atividade. Um estudante, na aplicação remota (AP4) relatou problemas com a webcam em seu computador para testar o GTM, no entanto como existe a alternativa de realizar os testes por meio de *upload* de um arquivo de imagem, também conseguiu realizar essa atividade.

Referente à análise de desempenho do modelo de ML, observou-se que mesmo sendo um tópico complexo, um grande número dos estudantes interpretou corretamente a acurácia dos modelos (n=35) e a matriz de confusão (n=41), demonstrando portanto que o GTM apresenta esses resultados de forma visual simples e clara na ferramenta. No entanto, um número considerável de estudantes (n=30) não interpretaram corretamente os resultados do teste. Assume-se que esse resultado pode ter sido causado devido a fatores externos à ferramenta como falta de compreensão do conteúdo ou mesmo equívoco no preenchimento do respectivo relatório.

Com base nos resultados de desempenho, alguns estudantes (n=22) também tentaram melhorar o modelo de ML, em várias iterações. Isto é facilitado pelo GTM principalmente por meio de opções intuitivas disponíveis para variação dos principais parâmetros de um treinamento de ML (como épocas e taxa de aprendizado), limitando os parâmetros de treinamento aos somente essenciais.

Estes resultados positivos são também reforçados pelo feedback dos estudantes, apontando como um dos pontos fortes do curso: “O aprendizado com *teachable machine*”, “Fazer a atividade do *Google Teachable Machine*”, “Ter

contato com o *Google Teachable Machine*”, afirmando a aceitação e a eficácia da ferramenta.

6.3 Ameaças à validade

Vários fatores podem influenciar a validade dos resultados deste estudo. Uma ameaça está relacionada à maneira de medir os objetivos da avaliação. Para reduzir esse risco, foi adotada a abordagem GQM [3] para refinar sistematicamente o objetivo da avaliação em questões de análise e medidas, operacionalizadas por instrumentos de coleta de dados. Para minimizar o risco de validação de dados, foram coletados dados de diferentes tipos, que foram analisados conjuntamente. Outra ameaça se refere ao tamanho da amostra. Entretanto, um tamanho de amostra de 87 estudantes pode ser considerado aceitável, especialmente nesta área de ensino emergente. No entanto, embora o curso tenha sido aplicado em diferentes escolas e contextos, será importante repetir o estudo em um número maior de escolas para permitir a generalização dos resultados, incluindo também um número maior de estudantes mais jovens com idade entre 10 e 14 anos. Mesmo assim, os resultados deste estudo representam um feedback sobre a eficácia da adoção da metodologia ativa e da ferramenta GTM como parte de uma pesquisa exploratória.

7 CONCLUSÃO

Os resultados deste estudo apontam em direção de que a adoção das metodologias ativas de aprendizagem no curso “ML4ALL” são eficazes em promover as condições adequadas aos estudantes para construir seu conhecimento referente a aplicação de conceitos básicos de ML. Também mostrou que o tipo de metodologia ativa, com as atividades práticas possibilitaram realizar tarefas de pensamento de ordem superior para solucionar um problema do mundo real, a reciclagem de lixo com classificação de imagens. Observou-se também que a ferramenta GTM foi eficaz em prover o suporte tecnológico necessário para que os estudantes desenvolvessem modelos de classificação de imagem, mesmo sem conhecimento prévio em programação e/ou ML, de forma rápida e intuitiva. Esses resultados apontam que essas estratégias pedagógicas podem viabilizar a construção de competências de ML também nos anos finais do ensino fundamental e médio e dessa forma contribuir para a popularização desse conhecimento.

Com base nos resultados positivos desta experiência prática, está sendo expandido tanto a aplicação deste curso quanto iniciando o desenvolvimento de cursos para dar sequência na aprendizagem de conceitos de ML, possibilitando que os alunos se tornem capazes de criar os seus próprios sistemas de classificação de imagens.

Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (CNPq).

REFERÊNCIAS

- [1] Amershi, S. et al. (2019) “Software Engineering for Machine Learning: A Case Study,” In Proc. of the 41st International Conference on Software Engineering: Software Engineering in Practice, Montreal, QC, Canada, 291–300.
- [2] Asok, D. et al. (2016). “Active Learning Environment for Achieving Higher-Order Thinking Skills in Engineering Education”. In IEEE 4th International Conference on MOOCs, Innovation and Technology in Education, 47–53.
- [3] Basili, V. R., Caldiera, G., Rombach, H. D. (1994) “Goal, Question Metric Paradigm”. In J. J. Marciniak, Encyclopedia of Software Engineering, 528–532. New York: Wiley-Interscience.
- [4] Bonwell, C. C. e Eison, J. A. (1991). “Active Learning: Creating Excitement in the Classroom”. ASHE-ERIC Higher Education Report, Washington DC: School of Education and Human Development, George Washington University, Washington, DC, USA.
- [5] 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, SBC, 1553–1562.
- [6] Carney, M. et al. (2020) “Teachable Machine: Approachable Web-based tool for exploring machine learning classification”. In Proc. of the Conference on Human Factors in Computing Systems, New York, NY, USA, 1–8
- [7] Estevez, J. G., Garate, G., Graña, M. (2019) “Gentle Introduction to Artificial Intelligence for High-School Students Using Scratch”, IEEE Access, 7
- [8] Google (2022) “Google Teachable Machine”, <https://teachablemachine.withgoogle.com/>
- [9] Gresse von Wangenheim, C. et al. (2022). A Proposal for Performance-based Assessment of the Learning of Machine Learning Concepts and Practices in K-12”, Informatics in Education, 21(3).
- [10] Gresse von Wangenheim, C. et al. (2021) “Visual tools for teaching machine learning in K-12: A ten-year systematic mapping. Education and Information Technology”, Education and Information Technologies, 26(5), 5733–5778
- [11] Gresse von Wangenheim, C. et al. (2017). dTECT: A model for the evaluation of instructional units for teaching computing in middle school. Informatics in Education, 16(2).
- [12] Kyriacou, C. (1992). “Active Learning in Secondary School Mathematics”. British Educational Research Journal, 18(3), 309–318
- [13] Long, D. e Magerko, B. (2020) “What is AI Literacy? Competencies and Design Considerations”. In Proc. of the Conference on Human Factors in Computing Systems. New York, NY, USA, 1–6.
- [14] Marques, L., Gresse von Wangenheim, C., Hauck, J. (2020) “Ensino de Machine Learning na Educação Básica: um Mapeamento Sistemático do Estado da Arte”. Anais do Simpósio Brasileiro de Informática na Educação, Natal, Brasil.
- [15] Martins, R. M. and Gresse von Wangenheim (2022). Findings on Teaching Machine Learning in High School: A Ten - Year Systematic Literature Review, Informatics in Education.
- [16] MEC. (2017) “Base Nacional Comum Curricular”. shorturl.at/adfnS
- [17] Mourão, A. (2017) “Uma proposta da eficiência do uso da Metodologia Ativa Baseada em Problemas, utilizando Dojo de Programação, aplicada na disciplina de Lógica de Programação”. Anais do Workshop de Informática na Escola, Recife, Brasil
- [18] Rodriguez-García, J. D., et al. (2021) “Evaluation of an Online Intervention to Teach Artificial Intelligence with LearningML to 10-16-Year-Old Students”. In Proc. of the 52nd ACM Technical Symposium on Computer Science Education, New York, NY, USA
- [19] Russell, S e Norvig, P. (2020). “Artificial Intelligence: A Modern Approach”, Pearson
- [20] Sanusi, I. T. e Oyelere, S. S. (2020) “Pedagogies of Machine Learning in K-12 Context”. In Proc. of the IEEE Frontiers in Education Conference, Uppsala, Sweden, 1–8.

- [21] Squicciarini, M. e Nachtigall, H. (2021). "Demand for AI skills in jobs: Evidence from online job posts". OECD Science, Technology and Industry Working Papers, No. 2021/03, OECD Publishing, Paris.
- [22] Torrance, H. (1995). Evaluating Authentic Assessment: Problems and Possibilities in New Approaches to Assessment. Buckingham: Open University Press
- [23] Touretzky, D. S., Gardner-McCune, C., Martin, F., Seehorn, D. (2019) "Envisioning AI for K-12: What Should Every Child Know about AI?". In Proc. of the 33rd AAAI Conference on Artificial Intelligence, Honolulu, Hawaii, USA
- [24] UNDESA. (2021) "Departamento de Assuntos Econômicos e Sociais das Nações Unidas", <https://sdqs.un.org>
- [25] Yin, R. K. (2017) "Case Study Research and Applications: Design and Methods", Los Angeles: SAGE Publications
- [26] Zhu, M. (2020) "Effective Pedagogical Strategies for STEM Education from Instructors' Perspective: OER for Educators ". Open Praxis, vol 12, 257-270.