

Uso de learning analytics para Avaliação de eficiência de curso de introdução à Inteligência Artificial

Marcelo Henrique Oliveira Henklain^a, Filipe Dwan Pereira^a, Luciano Ferreira Silva^a, Acauan Cardoso Ribeiro^a, Herbert Oliveira Rocha^a, Leandro Nelinho Balico^a, Marcelle Alencar Urquiza^a, Marcia Gabrielle Bonifácio de Oliveira^a, George Lucas Monção Zambonin^a, Rafael Ferreira Mello^b

^aDepartamento de Ciência da Computação – Universidade Federal de Roraima (UFRR)
Boa Vista – RR – Brasil

^bDepartamento de Computação – Universidade Federal Rural de Pernambuco (UFRPE) e CESAR School – Recife
– PE – Brasil

{marcelo.henklain, filipe.dwan, luciano.silva, acauan.ribeiro, herbert.rocha, leandro.balico, marcelle.urquiza}@ufr.br, {gabybonifacio2, georgezambonin}@gmail.com, rafael.mello@ufrpe.br

RESUMO

O objetivo deste estudo foi avaliar a eficiência do curso *on-line* ABC da Inteligência Artificial, tendo adotado a Análise do Comportamento como teoria educacional. Participaram 244 pessoas, ao longo de quatro ofertas do curso, desde graduandos em ciências exatas até pós-graduados de outras áreas. Foi aplicada prova de 30 itens de V/F no início (pré) e ao final do curso (pós-teste), para avaliar aprendizagem e autoconfiança em relação às próprias respostas na prova. Avaliamos, ainda, a satisfação com o curso. Observamos aumento estatisticamente significativo de acertos e de autoconfiança entre pré e pós-teste, com tamanhos do efeito de moderado a alto: $0,48 \geq d \leq 0,87$ (aprendizado) e $0,45 \geq d \leq 0,98$ (autoconfiança). A satisfação com o curso foi elevada ($M = 4,45$; $DP = 0,10$). Esperamos que esse curso seja replicado e seus recursos, principalmente objetivos de aprendizagem e avaliações, possam ser aperfeiçoados, a partir do material gratuitamente disponibilizado na Internet.

ABSTRACT

The aim of this study was to evaluate the effectiveness of the online course “ABC of Artificial Intelligence”, adopting Behavior Analysis as an educational theory. A total of 244 participants took part in four iterations of the course, ranging from undergraduates in exact sciences to postgraduates from other fields. A 30-item true/false test was administered at the beginning (pre-test) and at the end of the course (post-test) to assess learning and self-confidence regarding their answers. We also assessed satisfaction with the course. We observed a statistically significant increase in correct answers and self-confidence between pre-test and post-test, with effect sizes ranging from moderate to high: $0.48 \geq d \leq 0.87$

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 '24, Abril 22-27, 2024, São Paulo, São Paulo, Brasil (On-line)

© 2024 Copyright mantido pelo(s) autor(es). Direitos de publicação licenciados à Sociedade Brasileira de Computação (SBC).

(learning) and $0.45 \geq d \leq 0.98$ (self-confidence). Satisfaction with the course was high ($M = 4.45$, $SD = 0.10$). We hope that this course will be replicated and its resources, especially learning objectives and assessments, can be improved based on the freely available material on the Internet.

CCS CONCEPTS

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

PALAVRAS-CHAVE

Educação em computação, Ensino de Inteligência Artificial, Programação de condições de ensino

1 INTRODUÇÃO

A inteligência artificial (IA) tem impulsionado a inovação em diversos setores [1]. No Brasil, o mercado de trabalho em IA está em expansão, alavancado pelo crescimento da economia digital e pela necessidade que as empresas têm de aprimorar seus processos e serviços [2, 3]. Dado esse crescimento da IA, governantes no Brasil vêm legislando um Marco Legal da Inteligência Artificial (MLIA, <https://bit.ly/46HRwDS>). Esse documento consiste em um conjunto de regras, princípios e diretrizes que regulamentam o uso da IA no Brasil. Esse marco é uma importante iniciativa para garantir que a tecnologia seja desenvolvida e utilizada de forma ética, transparente e responsável, promovendo o desenvolvimento econômico e social do país.

Não obstante, o avanço da IA tem sido impactado no Brasil e no mundo pela defasagem na quantidade de profissionais para atuar nessa área, por causa de sua complexidade e por ser relativamente nova [2]. É provável que essa falta de mão de obra qualificada, dado o promissor futuro da IA, continue a crescer [3]. Uma vez que a falta de profissionais pode ser uma barreira para o desenvolvimento de novas tecnologias e para a aplicação da IA em diversos setores, é preciso desenvolver e avaliar a eficiência de estratégias para superar essa carência [1].

Para tanto, são necessários investimentos em formação de profissionais especializados em IA. Universidades e instituições de ensino têm um papel importante em oferecer cursos e programas de formação nessa direção, bem como incentivar a pesquisa e o desenvolvimento de novas técnicas e metodologias para o seu ensino. Além disso, é necessário que as empresas invistam em treinamento e capacitação de seus funcionários, para que possam desenvolver e aplicar soluções de IA em seus negócios.

Pensando nisso, desenvolvemos um curso de introdução a Machine Learning (ML), que denominamos de ABC da Inteligência Artificial (ABCIA), para sinalizar a ideia de primeiros passos no aprendizado sobre IA. O objetivo deste estudo foi avaliar a eficiência desse curso, para o ensino do comportamento de “caracterizar como funciona o aprendizado de máquina a partir de conceitos básicos dessa subárea da IA, de elementos da matemática subjacente aos seus algoritmos e das aplicações e limitações dessa tecnologia”. Para atingir esse objetivo, buscamos responder a quatro Perguntas de Pesquisa (PP): PP01. O curso ABCIA promoveu mudança de repertório comportamental dos alunos em relação aos objetivos de aprendizagem propostos? PP02. O curso ABCIA promoveu mudança no sentimento de autoconfiança dos alunos em relação aos objetivos de aprendizagem propostos? PP03. O curso ABCIA gerou uma percepção de satisfação nos estudantes? PP04. Quais são as características dos alunos que evadiram? Essa última pergunta nos ajuda a identificar hipóteses para a evasão. Importa ressaltar que realizamos quatro ofertas desse curso, sendo que a última foi realizada para oferecer uma nova oportunidade de capacitação a todos os estudantes que evadiram das primeiras três ofertas.

Empregamos técnicas estatísticas e de Learning Analytics (LA) para responder às PPs. O uso de LA se justifica porque foi necessário coletar, analisar e interpretar dados sobre o processo de aprendizagem e satisfação dos alunos no curso ABCIA. Tais dados foram necessários para que pudéssemos compreender e otimizar o processo de aprendizagem e o curso em si. Desse modo, ao responder às Perguntas de pesquisa (PPs), o uso de LA converge para um aprimoramento contínuo do curso.

Além da introdução, este trabalho conta com mais cinco seções. Na fundamentação, apresentamos conceito-chave para o entendimento do nosso estudo. Nos trabalhos relacionados, revisamos brevemente a literatura sobre ensino de IA. No método explicamos como o curso foi avaliado. Na seção de resultados e discussão, apresentamos os nossos achados e as respostas às PPs. Finalizamos com a conclusão.

2 FUNDAMENTAÇÃO TEÓRICA

Em pesquisas da área da Educação em Computação, trabalhamos com os processos de ensinar e aprender. Precisamos, portanto, de definições teóricas para que seja possível identificar o que podemos reconhecer como ensino e como aprendizado. Para lidar com esses fenômenos, adotamos a teoria analítico-comportamental, que tem se revelado promissora em termos de suas contribuições para a educação [4]. Ela propõe uma interpretação dos fenômenos psicológicos como relações entre propriedades das ações de um organismo, visto como um todo, e

propriedades do ambiente que antecede e sucede essas ações [5]. Essa relação é, tecnicamente, denominada de comportamento.

Quando aplicamos esse ponto de vista aos processos de ensinar e aprender, notamos que o ensinar pode ser interpretado como o conjunto de comportamentos que um professor apresenta para facilitar a produção de aprendizado e engajamento em relação ao estudo [6]. Esses comportamentos docentes envolvem desde o planejamento do que deve ser aprendido pelo aluno até as atividades de sala de aula, avaliações conduzidas e a implementação de melhorias ao longo do processo de ensino. Aprender, por sua vez, se refere a uma mudança duradoura no repertório comportamental do aluno, que pode se dar por aquisição ou aperfeiçoamento de comportamento presente no repertório de uma pessoa [6]. Portanto, quem aprende passa a se comportar de modo diferente do que conseguia antes do ensino.

A implicação desses conceitos é a de que não ensinamos conhecimentos e informações, mas comportamentos que, em última análise, são ações que ocorrem tendo por ambiente antecedente conhecimentos e informações (entre outros aspectos) e que visam produzir certas consequências no mundo (ambiente subsequente), tipicamente, para atenuar ou resolver situações-problema, que se apresentam em uma determinada realidade social [4, 6]. Logo, educadores não deveriam começar o seu trabalho perguntando por conteúdos a serem ministrados, mas pelos comportamentos que devem ser aprendidos de modo que seus alunos possam lidar de modo mais efetivo com a realidade em que vivem.

Vale destacar que a expressão objetivos de aprendizagem reflete essa noção dos comportamentos que um professor propõe como alvos de seu trabalho, sendo, então, referência para o planejamento de estratégias de ensino e de avaliação. Este trabalho se diferencia por iniciar uma proposta de descrição e teste de objetivos de aprendizagem para o ensino do comportamento de “caracterizar como funciona o aprendizado de máquina a partir de conceitos básicos dessa subárea da IA, de elementos da matemática subjacente aos seus algoritmos e das aplicações e limitações dessa tecnologia”, cuja importância é reconhecida pela BNCC e pela literatura científica de Educação em Computação [7, 8]. Abordaremos no método as condições de ensino organizadas para facilitar o alcance do objetivo de aprendizagem proposto e as tarefas avaliativas adotadas, que nos ofereceram indicadores de aprendizado, de desenvolvimento de autoconfiança acerca das aprendizagens e de satisfação com o curso.

Por fim, esclarecemos que definimos Inteligência Artificial (IA) como uma área de produção de conhecimentos e tecnologia cuja finalidade é desenvolver sistemas que se comportem de modo inteligente [9]. Dentro da IA, Machine Learning (ML) é uma subárea que busca conferir a sistemas a capacidade de aprendizado automático a partir de experiências, sem a necessidade de programação explícita. O aprendizado sobre ML importa porque permite que as pessoas compreendam as tecnologias que têm governado o mundo em que vivemos, bem como as capacitam a construir soluções para problemas sociais a partir dessas tecnologias [10]. Temos, assim, a democratização do conhecimento [11].

3 TRABALHOS RELACIONADOS

Nesta seção, apresentamos alguns trabalhos que ilustram o conhecimento científico existente sobre ensino de IA. Por meio deles, explicitaremos lacunas na literatura que serviram como ponto de partida para o presente estudo.

Começamos por um mapeamento sistemático sobre ensino de ML na educação básica, conduzido por Marques et al. (2020) [11]. Os pesquisadores buscaram por publicações sobre unidades instrucionais abrangendo o ensino de ML nas bibliotecas da ACM e IEEE, do Scopus e do Google Acadêmico e, finalmente, no site do MIT media lab. Foram encontradas apenas 39 unidades instrucionais. Tipicamente, a ênfase delas residia no ensino sobre o que é ML e algoritmos específicos, com destaque para árvores de decisão e redes neurais. Predominaram atividades práticas para o ensino e a população de alunos foi do ensino médio. Foram escassos os estudos sobre como avaliar o aprendizado discente. Cabe destacar que a população desse estudo tem pouco ou nenhum conhecimento sobre ML, assim como muitos dos participantes da presente pesquisa, ainda que mais velhos e com maior escolaridade.

Freitas et al. (2022) [8], por sua vez, desenvolveram curso introdutório de IA, com ênfase em ML e empreendedorismo, para estudantes de 14 a 19 anos da rede pública. Esse curso foi elaborado na modalidade *on-line*, tendo duração de semanas e previsão de encontros síncronos para sanar dúvidas e resolver desafios. Foram utilizadas metodologias ativas e estratégias de gamificação ao longo do curso. Os pesquisadores avaliaram a eficiência dessa capacitação ao aplicá-la a 56 jovens, cujas atividades consistiam em assistir a videoaulas, responder a quizzes semanais, resolver desafios, participar de, pelo menos, 75% dos encontros síncronos e desenvolver, ao final do curso, uma proposta de uso da IA, para resolver problema socialmente relevante. Os resultados mostraram que 20 alunos finalizaram o curso, tendo apresentado trabalhos finais coerentes com o potencial da IA. Isso sugeriu que o curso foi eficiente. Em todo caso, não foi apresentada uma estratégia avaliativa mais robusta.

Herta et al. (2019) [12], também criaram um projeto para ensino de ML, denominado de Deep Teaching. O objetivo desta ação foi superar os desafios de capacitação de alunos em ML, uma vez que a matemática que subjaz essa tecnologia pode ser uma barreira para muitas pessoas. Assim, os pesquisadores desenvolveram recursos teóricos e exercícios práticos para diferentes tópicos em ML, apresentando-os, tipicamente, por meio de jupyter notebooks. Foram adotadas diferentes estratégias para fornecimento de feedback automático para os alunos. O relato desse estudo focou no processo de desenvolvimento dos notebooks, descrevendo as suas estruturas, processo de criação e desafios envolvidos. Destaca-se que não foram apresentados dados de aprendizagem ou de motivação dos alunos, como indicadores de eficiência das condições de ensino implementadas, tampouco uma descrição dos objetivos de aprendizagem propostos.

Observamos, portanto, na literatura uma lacuna em relação à proposição de objetivos de aprendizagem e a construção de avaliações, para testar em que medida um curso de ML foi eficiente. Assim, a principal novidade deste relato de experiência foi propor e testar um conjunto de objetivos de aprendizagem, em uma

capacitação *on-line*, para um público diverso, e com um conjunto definido de avaliações, coerentes com os objetivos de aprendizagem e com a teoria educacional adotada.

4 MATERIAIS E MÉTODOS

Empregamos uma estratégia de avaliação de eficiência do curso baseada na comparação entre o desempenho dos alunos (variável dependente), antes e após a sua participação no curso (variável independente). Adicionalmente, ao final do curso, conduzimos uma avaliação de satisfação.

4.1 Uso de Learning Analytics

A abordagem de LA empregada neste estudo é baseada na coleta, interpretação e aplicação de informações obtidas a partir da aplicação de questionários para os alunos no contexto do Moodle. Com isso, almejamos aprimorar continuamente o curso. Utilizando técnicas de LA, pode-se fornecer informações valiosas em relação a quais objetivos de aprendizagem os alunos tendem a encontrar mais dificuldades e quais condições de ensino trazem melhores resultados [13]. Esses *insights* permitem ajustes contínuos na estrutura do curso e nas estratégias de ensino, melhorando a qualidade da experiência de aprendizagem [14]. Vale destacar que vários trabalhos na área de LA têm se dedicado a estudar o comportamento de alunos através da utilização de questionários, seguimos essa mesma direção [15, 16, 17].

4.2 Participantes

1ª Oferta do curso ABCIA. Participaram 65 estudantes, sendo que 63,08% se identificaram como pertencendo ao gênero masculino, 44,62% como brancos e 43,08% como pardos; 95,38% reportaram não ter deficiência; 70,77% indicaram que possuíam curso de pós-graduação concluído em área diferente de exatas, 21,54% estavam cursando pós-graduação, também em área diversa, e 7,69% eram alunos do ensino superior, cursando graduação na área de exatas.

2ª Oferta do curso ABCIA. Participaram 110 estudantes, sendo que 74,55% se identificaram como do gênero masculino, 58,18% como pardos, 33,64% como brancos e 99,09% reportaram não ter deficiência; 60% indicaram que estavam cursando graduação na área de exatas e 13,64% reportaram que haviam concluído graduação nessa área.

3ª Oferta do curso ABCIA. Participaram 55 estudantes, sendo que 72,73% se identificaram como do gênero masculino, 45,45% como pardos e 41,82% como brancos; 98,18% reportaram não ter deficiência; 67,27% indicaram que estavam cursando graduação na área de exatas e 14,55% reportaram que haviam concluído graduação nessa área.

4ª Oferta do curso ABCIA. Participaram 14 estudantes, sendo que 57,14% classificaram-se como do gênero masculino, 64,29% se identificaram como pardos, 14,29% como brancos, 14,29% como pretos e 92,86% reportaram não ter deficiência; 50,00% reportaram estar cursando o ensino superior na área de exatas e 7,14% concluíram ensino superior nessa área.

Com relação aos cuidados éticos, tendo por fundamento a Resolução CNS n. 510/2016, Art. 1º, Parágrafo único, inciso VII,

entendemos que este estudo decorreu da prática profissional dos professores, tendo por finalidade o aprofundamento teórico em relação ao desempenho dos estudantes, para auxiliar no aperfeiçoamento do curso ABCIA. Ademais, os dados foram analisados de modo agregado, sem possibilidade de identificação dos alunos. Portanto, nesse caso, não há necessidade de registro e avaliação deste trabalho pelo sistema CEP/CONEP. Por essa razão, este estudo consiste em um relato de experiência profissional.

4.3 Objetivos de aprendizagem e condições de ensino

O curso ABCIA foi desenvolvido para ser uma breve introdução ao estudo da Inteligência Artificial, especificamente, sobre ML, tendo por finalidade auxiliar os estudantes a definir conceitos da área e identificar como um computador pode aprender. Foram propostos 45 objetivos de aprendizagem, com diferentes graus de abrangência, observando as recomendações de Cortegoso e Coser (2013) [18] em relação ao procedimento simplificado para descrição de partes funcionais de objetivos de aprendizagem. Esse recurso foi o ponto de partida para orientar o trabalho dos docentes.

A presente proposição desses objetivos foi feita com base na experiência profissional e exame crítico dos professores do curso, sem que fosse feita uma consulta sistemática a outras experiências de ensino de ML. Não obstante, almejamos em estudos futuros sanar esta limitação. A Tabela 1 exhibe a relação de objetivos de aprendizagem propostos.

Cumpramos esclarecer, ainda, que objetivos de aprendizagem são descrições de comportamentos, sendo que cada comportamento pode ser mais (ex.: “caracterizar principais componentes de um computador”) ou menos abrangente (ex.: “identificar a memória principal”). Um objetivo mais geral, tipicamente, é constituído de outros mais específicos. Por exemplo: o objetivo mais geral “programar computadores” é constituído de outros mais específicos, tais como “escrever algoritmo para solução de um problema” e “formalizar algoritmo em conformidade com uma linguagem de programação”. A literatura recomenda que seja feito esse processo de decomposição do objetivo mais geral em termos de objetivos mais específicos, até que se chegue a um objetivo tão simples que, provavelmente, o aluno poderia aprendê-lo sem grandes dificuldades [18]. Tal cuidado permite que o aprendizado se dê de modo gradual, evoluindo do simples para o complexo. Por essa razão, cada objetivo mais geral pode ter quantidades diferentes de objetivos mais específicos. Tudo depende do comportamento que está sendo analisado.

Tabela 1. Módulos, unidades e objetivos de aprendizagem do curso ABCIA.

Módulos	Objetivos de aprendizagem
01. Introdução à Inteligência Artificial	1.1.1. Identificar IA como subárea da computação com diversas frentes de estudo, dentre elas o aprendizado de máquina. 1.1.2. Identificar aplicações do aprendizado de máquina na indústria. 1.1.3. Identificar impactos da IA em diferentes dimensões sociais. 1.1.4. Identificar estratégias para atenuação de impactos negativos da IA.

02. Machine Learning	2.1.1. Definir o significado de modelo matemático da realidade. 2.1.2. Identificar finalidade e limitações de modelos matemáticos na solução de problemas. 2.1.2.1. Identificar estratégia de avaliação da aderência do modelo a realidade baseada no erro médio absoluto e no desvio-padrão. 2.1.2.2. Conceituar predição. 2.1.2.3. Conceituar classificação. 2.1.3. Identificar o modelo linear em sua representação no plano cartesiano. 2.1.4. Definir o significado de aprendizado de máquina. 2.2.1. Identificar finalidade e limitações dos algoritmos de ML a partir das noções de modelo, predição e classificação. 2.2.1.1. Identificar a finalidade dos dados de treino. 2.2.1.2. Identificar a finalidade dos dados para teste. 2.2.1.3. Identificar a finalidade da noção de viés. 2.2.1.4. Identificar a finalidade da noção de variabilidade nos erros. 2.2.1.5. Identificar a finalidade da noção de sobreajuste. 2.2.1.6. Identificar finalidade e tipos de função de perda. 2.2.1.7. Identificar características de um modelo ideal de ML (baixo viés e baixa variabilidade de erros) como critério para o exame de outros modelos. 2.3.1. Identificar etapas na construção de modelo da realidade com ML. 2.3.1.1. Identificar a etapa de divisão da base em dados de teste e treino. 2.3.1.1.1. Identificar a finalidade da técnica de validação cruzada. 2.3.1.2. Identificar a etapa de seleção de algoritmo. 2.3.1.2.1. Definir o conceito de treinar algoritmo. 2.3.1.3. Identificar principais algoritmos existentes em função de sua aplicação para predição ou classificação. 2.3.1.4. Identificar a etapa de implementação do algoritmo com Python. 2.3.1.5. Identificar a etapa de teste do algoritmo. 2.3.1.5.1. Definir o conceito de testar algoritmo.
03. Prática - ML com Python I	3.1.1. Construir modelo de árvore de decisão com Python, no Google Collab.
04. Deep Learning	4.1.1. Definir o conceito de rede neural. 4.1.1.1. Definir o conceito de “node”. 4.1.1.2. Definir o conceito de “node connection”. 4.1.1.3. Definir o conceito de “weights”. 4.1.1.4. Definir o conceito de “bias” no contexto das redes neurais. 4.1.2. Identificar finalidade e limitações das redes neurais no contexto da criação de modelos não-lineares. 4.1.2.1. Identificar a finalidade das funções de ativação. 4.1.2.2. Identificar a finalidade do algoritmo de “backpropagation”. 4.1.2.2.1. Identificar a finalidade do algoritmo de “gradient descent”. 4.2.1. Definir o conceito de aprendizado profundo.

	4.2.1.1. Definir o conceito de "hidden layer".
	4.2.2. Identificar finalidade e limitações das redes neurais profundas.
	4.2.3. Identificar tipos de redes neurais profundas.
05. Prática - ML com Python II	5.1.1. Construir modelo de reconhecimento de imagem com Python, no Google Collab.
06. Frameworks para IA	6.1.1. Caracterizar frameworks de aprendizado profundo (TensorFlow, PyTorch, Keras e Mindspore).
	6.2.1. Caracterizar hardware específico para processamento de modelos de aprendizado de máquina.
	6.2.2. Caracterizar plataformas proprietárias para desenvolvimento de modelos de IA.

Nota. A numeração ao lado dos objetivos explicita no primeiro algarismo o módulo a que pertence, no segundo a unidade e os demais expressam a relação hierárquica entre os objetivos, pois alguns são mais gerais e contém outros que são pré-requisitos.

Esses objetivos de aprendizagem foram, então, organizados em seis módulos, a saber: (1) Introdução à Inteligência Artificial; (2) Machine Learning; (3) Prática de ML com Python I; (4) Deep Learning; (5) Prática de ML com Python II; e (6) Frameworks para IA. As condições de ensino envolveram (a) videoaulas gravadas, armazenadas no YouTube, cujos links foram disponibilizados via Moodle, (b) listas de exercício para treino de conceitos com *feedback* automático ao final da atividade e encontros *on-line* síncronos para solução de dúvidas. Também fornecemos apoio a eventuais dificuldades com o curso por meio de fórum no Moodle e suporte por e-mail e WhatsApp. A certificação no curso foi obtida mediante conclusão das atividades programadas: visualização das videoaulas, resolução das listas de exercício, preenchimento do pré e pós-teste e da avaliação de satisfação.

4.4 Instrumento de coleta de dados

Para este estudo, construímos o Questionário de Caracterização da Amostra (QCA) e adaptamos dois instrumentos, Questionário para Mensuração de Aprendizado e Autoconfiança (QMA) e Questionário para Mensuração de Satisfação com o Curso (QMS). Apresentaremos a seguir as características dessas medidas.

Questionário de Caracterização da Amostra (QCA). Continha cinco itens: data de nascimento, gênero, identidade étnico-racial, se possui deficiência e qual o tipo e grau de escolaridade.

Questionário para Mensuração de Aprendizado e Autoconfiança (QMA). O QMA era composto por 30 itens objetivos de Verdadeiro ou Falso, obtidos a partir de questões de provas de certificação em IA disponíveis na Internet. O estudante, diante de um item, deveria decidir se ele era Verdadeiro ou Falso, sendo o acerto adotado como indicativo de conhecimento/aprendizado, bem como avaliar o grau de segurança em relação à resposta que pretendia fornecer. Assim, utilizamos uma escala de resposta de quatro pontos, a saber: 1 - Totalmente seguro de que a resposta é 'Falsa'; 2 - Parcialmente seguro de que a resposta é 'Falsa'; 3 - Parcialmente seguro de que a resposta é 'Verdadeira'; 4 - Totalmente seguro de que a resposta é 'Verdadeira'.

Quando o estudante utilizava os Níveis 2 ou 3 da escala, mesmo que a resposta fosse correta, teríamos como saber que não havia segurança, sendo esperado que a quantidade de seleções de respostas 2 e 3 reduzisse entre o início e o final do curso, assim como aumentasse a quantidade de respostas 1 e 4. O QMA foi aplicado antes do ensino (Pré-teste) e reaplicado após (Pós-teste). É possível consultar na Tabela 2 os itens desse instrumento e os objetivos de aprendizagem aos quais estão relacionados.

Tabela 2. Objetivos de aprendizagem avaliados (OAA) pelos itens do QMA.

OAA	Item [Gabarito]
4.2.2. e 4.2.3.	Comparada com a rede neural recorrente, a rede neural convolucional é mais adequada para o reconhecimento de imagem. [V]
2.2.1.	O erro de generalização continuará diminuindo à medida que a complexidade do modelo aumenta. [F]
1.1.3.	A inteligência artificial nesta fase ainda está no estágio de inteligência artificial fraca. [V]
1.1.1.	A inteligência artificial é uma nova ciência técnica que estuda e desenvolve teorias, métodos e sistemas de aplicação para simular e estender a inteligência humana. E uma das principais áreas de pesquisa do aprendizado de máquina. [F]
M6	O Scikit-Learn é uma biblioteca de aprendizado de máquina de software livre para Python. Possui ferramentas poderosas para análise e mineração de dados. [V]
2.2.1.6.	Dados malformados não são dados sujos. [F]
4.2.3.	Na CNN, a camada convolucional pode reduzir a dimensão dos mapas de recursos. [V]
M6	Tensorflow é uma das estruturas de aprendizado profundo mais populares. [V]
4.2.3.	O GAN é um modelo de aprendizado profundo, que tem sido reconhecido como um dos métodos mais promissores para o aprendizado não supervisionado nos últimos anos. [V]
M6	No TensorFlow 2.x, a execução ansiosa (<i>eager execution</i>) é ativada por padrão. [V]
4.1.2.1.	A maior diferença entre regressão logística e perceptron é que a regressão logística usa a função de ativação sigmóide na camada de saída, enquanto o perceptron usa a função de sinal. Além disso, nenhum dos dois modelos pode resolver o problema XOR. [V]
4.1.1.	As redes neurais não são um tipo de aprendizado de máquina. [F]
1.1.2.	Em alguns campos de imagem e voz, a inteligência artificial tem um desempenho melhor do que os humanos, o que evidencia que alcançamos o estágio de forte da inteligência artificial. [F]
2.2.1.6.	A função de perda e a função do modelo são a mesma coisa. [F]
2.2.1.7.	O erro de teste continuará ficando menor à medida que a complexidade do modelo aumenta. [F]
2.2.1.6.	Uma função de perda na regressão logística é a entropia cruzada. [V]
4.1.2.2.	A técnica de <i>backpropagation</i> torna o algoritmo de gradiente descendente mais eficiente, por meio de programação dinâmica. [V]
1.1.2.	A inteligência artificial de reconhecimento de voz refere-se à identificação de dados textuais como dados de áudio. [F]
3.1.1.	Usamos o recuo para distinguir blocos de código no Python. [V]
2.3.1. e 2.2.1.5.	Regularizadores podem ser adicionados à regressão logística para evitar o sobreajuste (<i>overfitting</i>). [V]

1.1.4.	Os empregos inovadores e com altos requisitos de capacidades sociais podem ser facilmente substituídos pela inteligência artificial. [F]
M6	O TensorFlow não suporta várias linguagens de programação. [F]
4.2.3.	Em uma rede de <i>feedforward</i> , os neurônios na mesma camada estão conectados entre si. [F]
4.1.2.	Uma das desvantagens da aprendizagem profunda é que a interpretabilidade é muito fraca, mas ainda é possível visualizar o modelo usando métodos como Local Interpretable Model-Agnostic Explanations (LIME). [V]
2.1.2.	O modelo composto por algoritmos de aprendizado de máquina não pode representar a verdadeira função de distribuição de dados em um nível teórico. Apenas se aproxima disso. [V]
2.1.3.	O coeficiente de correlação, também conhecido como coeficiente de correlação linear, é usado para medir a relação linear entre duas variáveis, que é um número real maior que zero. [F]
2.1.3.	Na regressão polinomial, há um termo quadrado na fórmula do modelo, portanto não é linear. [V]
M6	A GPU é inadequada para paralelizar a execução de funções e para computação intensiva. [F]
4.1.2.1.	As funções de ativação convertem mapas não lineares em mapas lineares. [F]
4.2.1.	O aprendizado profundo é diferente do aprendizado de máquina e não há algoritmos não supervisionados. [F]

Questionário para Mensuração da Satisfação com o curso (QMS). A satisfação foi avaliada por meio de 15 itens, adaptados a partir da Escala de Satisfação com a Experiência Acadêmica (ESEA) [19], tendo por finalidade examinar a Satisfação com a infraestrutura, a Satisfação com o curso e a Satisfação com as oportunidades de desenvolvimento. Os itens foram respondidos com base em uma escala Likert, “1 = Nada Satisfeito” a “5 = Totalmente Satisfeito”.

Adicionalmente, criamos 10 listas de exercício, cada uma com cinco itens objetivos, podendo ser de Verdadeiro/Falso e/ou Múltipla-escolha (tendo uma ou mais alternativas corretas), que precisavam ser respondidas ao final de cada unidade de um módulo. As listas nos permitiram acompanhar o desempenho dos estudantes ao longo do curso, sendo adotadas como pré-requisito para que o ele avançasse no curso, conforme sugestão de Cortegoso e Coser (2013) [18]. Os itens tinham correção e *feedback* automáticos, e os estudantes precisavam obter 100% de acertos para avançar, sendo que as chances de obter esse resultado eram ilimitadas.

4.5 Procedimento de coleta e análise de dados

Construímos um site e uma conta em rede social, para a divulgação do edital do curso. A partir disso, na 1ª Oferta do ABCIA, obtivemos 405 inscritos. Foram selecionados 110 estudantes: 80 vagas eram para ampla concorrência, 20 foram reservadas para pessoas que se identificassem como pardas, pretas ou indígenas, cinco vagas foram reservadas para pessoas que declarassem ter deficiência e cinco para pessoas que se identificassem como mulheres. Quando essas vagas reservadas não eram preenchidas, elas foram designadas para a ampla concorrência. O curso teve duração de seis semanas, envolvendo quatro encontros *on-line* síncronos, nos quais foi realizada *live* pelo YouTube, com a finalidade de sanar dúvidas dos estudantes e incentivar que

continuassem no curso, além de um encontro nesses moldes para abertura do curso e outro para encerramento.

Na 2ª Oferta, convidamos todos os alunos que não foram selecionados em um primeiro momento. Foram 302 alunos chamados e 198 que iniciaram o ABCIA. O curso manteve as características supracitadas, mas reduzimos a sua duração em uma semana. Na 3ª Oferta, tivemos 186 inscritos e aprovamos 185 estudantes, observando os mesmos critérios de vagas reservadas da primeira oferta. Esse curso também teve a duração de cinco semanas. Por fim, na 4ª Oferta, convidamos todos os estudantes que evadiram dos cursos anteriores e obtivemos 77 inscrições. O curso manteve os recursos pedagógicos e critérios das versões anteriores, mas durou apenas quatro semanas.

Para respondermos à PP01, calculamos médias aritméticas e desvio padrão das notas dos alunos no pré e pós-teste e comparamos essas médias por meio de um teste T pareado, avaliando o tamanho do efeito a partir do d de Cohen. Para a PP02, usamos esse mesmo procedimento, mas tendo como dado a quantidade de respostas do tipo “totalmente seguro” no pré e pós-teste. Para a PP03, calculamos médias e desvio padrão relativos à satisfação com o ABCIA. Calculamos, ainda, a frequência de estudantes que concluíram o curso e que evadiram. Para a PP04, conduzimos uma exploração dos dados, a partir de estatísticas descritivas e de uma árvore de decisão, para avaliar se encontraríamos padrões, que nos permitissem identificar o perfil dos alunos que evadiram.

Por fim, com base na literatura em educação, definimos como nosso indicador de sucesso para aprendizado e autoconfiança o tamanho do efeito entre pré e pós-teste maior ou igual a 0,4 [cf. 20], bem como 100% de acertos nas 10 listas de exercício, criadas como critério para progressão ao longo do curso. Para satisfação com o curso, adotamos como meta obter média do grupo, em cada uma das três dimensões da escala, com valores maiores que 3, para indicar satisfação moderada.

5 RESULTADOS E DISCUSSÃO

5.1 Análise de aprendizado, autoconfiança e satisfação

Na 1ª Oferta, após a etapa de seleção, 103 alunos iniciaram o curso ABCIA, realizado no período de 06/03 a 14/04/2023. Desse total, 63,11% finalizaram o curso ($n = 65$) e foram certificados. Portanto, as análises foram conduzidas com essa amostra. A Tabela 3 exibe os nossos achados em relação ao aprendizado e a autoconfiança.

Tabela 3. Resultados de aprendizado e autoconfiança - 1ª Oferta.

Dados	Critérios		
	Aprendizado	Autoconfiança	
Pré-teste	Média	6,24	3,85
	DP	1,29	2,53
Pós-teste	Média	7,42	6,37
	DP	1,21	2,89
Teste-T	t	6,86	6,56
	gl	64	64
	p	***	***

Tam. do Efeito	<i>d</i>	0,85	0,81
		IC 95%	0,56-1,13

Nota. Nota máxima de aprendizado e autoconfiança = 10,00; *** = < 0,001.

Observamos na Tabela 3 que a diferença de acertos entre pré e pós-teste foi estatisticamente significativa, com tamanho do efeito que pode ser considerado grande [ver 20]. De acordo com Cortegoso e Coser (2013) [18], é a diferença de repertório comportamental entre início e fim de um programa de ensino que nos ajuda a identificar que o aprendizado ocorreu. Temos, portanto, uma evidência favorável nesse sentido.

Os resultados de autoconfiança foram nessa mesma direção. A média de segurança entre pré e pós-teste foi estatisticamente significativa e com tamanho do efeito grande. Devemos lembrar que esse sentimento é produto de experiências nas quais o aluno age em relação a conhecimento e informações sobre um assunto e obtém resultados positivos, tais como acertar questões, conseguir resolver problemas ou entender alguma situação que é apresentada. Trata-se, portanto, de um sentimento decorrente de um contexto no qual um comportamento foi bem-sucedido. Ressaltamos que, no presente curso, todos os concluintes tiveram que completar 10 listas de exercício ao longo do ABCIA, obtendo 100% de acertos, o que pode ser um dos mecanismos para explicar a ocorrência de aprendizado e de autoconfiança, uma vez que o estudante precisava treinar até adquirir os objetivos de aprendizagem propostos no planejamento do curso [18].

Com relação à satisfação, identificamos um escore geral de 4,38 em cinco pontos possíveis ($DP = 0,51$). Calculamos, ainda, escores por fator da escala. O escore de Satisfação com a Infraestrutura foi de 4,41 ($DP = 0,55$), o de Satisfação com o Curso foi 4,37 ($DP = 0,53$) e o de Satisfação com as Oportunidades de Desenvolvimento foi 4,37 ($DP = 0,62$). Todos os escores, portanto, foram superiores a 3,0. Isso indica um elevado grau de satisfação com o ABCIA. Acreditamos que, provavelmente, as evasões estiveram relacionadas a pessoas que não conseguiram se organizar para manter uma disciplina de estudos ao longo do curso.

Na 2ª Oferta, realizada no período de 17/04 a 19/05/23, convidamos 302 pessoas que estavam compondo o cadastro de reserva do primeiro curso e 198 iniciaram o ABCIA, sendo que 55,56% ($n = 110$) foram certificadas. A Tabela 4 exibe os resultados obtidos. Mantivemos resultados favoráveis à conclusão de que essa capacitação foi eficiente.

Tabela 4. Resultados de aprendizado e autoconfiança - 2ª Oferta.

Dados		Critérios	
		Aprendizado	Autoconfiança
Pré-teste	Média	6,30	3,56
	DP	1,23	2,63
Pós-teste	Média	7,53	6,39
	DP	1,20	2,33
Teste-T	<i>t</i>	9,12	10,31
	<i>gl</i>	109	109
	<i>p</i>	***	***
Tam. do Efeito	<i>d</i>	0,87	0,98
	IC 95%	0,65-1,10	0,75-1,21

Nota. Nota máxima de aprendizado e autoconfiança = 10,00; *** = < 0,001.

Podemos observar na Tabela 4 que houve diferença estatisticamente significativa e elevado tamanho do efeito em termos de aprendizado e de autoconfiança. Em termos de satisfação, o escore geral foi de 4,47 ($DP = 0,51$). O escore de Satisfação com a Infraestrutura foi de 4,45 ($DP = 0,59$), o de Satisfação com o Curso foi 4,48 ($DP = 0,51$) e o de Satisfação com as Oportunidades de Desenvolvimento foi 4,49 ($DP = 0,57$). Mais uma vez, a magnitude dos escores revelou elevado grau de satisfação com o ABCIA.

Na 3ª Oferta do curso, realizada no período de 22/05 a 23/06/23, 185 estudantes iniciaram o ABCIA, sendo que 29,73% ($n = 55$) foram certificados por concluí-lo. Voltamos a obter resultados satisfatórios (ver Tabela 5).

Tabela 5. Resultados de aprendizado e autoconfiança - 3ª Oferta.

Dados		Critérios	
		Aprendizado	Autoconfiança
Pré-teste	Média	6,05	3,37
	DP	1,32	2,66
Pós-teste	Média	7,32	6,22
	DP	1,27	2,48
Teste-T	<i>t</i>	6,06	6,72
	<i>gl</i>	54	54
	<i>p</i>	***	***
Tam. do Efeito	<i>d</i>	0,82	0,91
	IC 95%	0,51-1,12	0,59-1,22

Nota. Nota máxima de aprendizado e autoconfiança = 10,00; *** = < 0,001.

Podemos observar na Tabela 5 o mesmo padrão das duas primeiras ofertas do curso. Houve diferença estatisticamente significativa em termos de aprendizado e de autoconfiança, bem como elevado tamanho do efeito. Em termos de satisfação, o escore geral foi de 4,37 ($DP = 0,52$). O escore de Satisfação com a Infraestrutura foi de 4,40 ($DP = 0,55$), o de Satisfação com o Curso foi 4,37 ($DP = 0,53$) e o de Satisfação com as Oportunidades de Desenvolvimento foi 4,32 ($DP = 0,63$). Novamente, a magnitude dos escores revelou elevado grau de satisfação.

Por fim, conduzimos a 4ª Oferta do curso ABCIA, realizado no período de 03 a 28/07/23, da qual participaram apenas os alunos que haviam evadido de uma das três ofertas anteriores. De todos os 259 convidados (38 do 1º Ciclo, 91 do 2º e 130 do 3º), 77 estudantes se inscreveram e 18,18% ($n = 14$) foram certificados. A Tabela 6 exibe os resultados obtidos nessa oferta.

Tabela 6. Resultados de aprendizado e autoconfiança - 4ª Oferta.

Dados		Critérios	
		Aprendizado	Autoconfiança
Pré-teste	Média	6,09	4,50
	DP	1,21	2,93
Pós-teste	Média	6,76	6,29
	DP	1,43	3,28
Teste-T	<i>t</i>	1,81	1,68
	<i>gl</i>	13	13

	<i>p</i>	0,1	0,1
Tam. do Efeito	<i>d</i>	0,48	0,45
	IC 95%	-0,08-1,03	-0,11-0,99

Nota. Nota máxima de aprendizado e autoconfiança = 10,00; *** = < 0,001.

Podemos observar na Tabela 6 que os resultados dessa última oferta, embora tenham indicado ganhos de aprendizado e de autoconfiança, não foram estatisticamente significativos. O fato de não termos obtido um *p*-valor significativo pode estar relacionado ao fato de a amostra ser pequena. Além disso, trabalhamos com alunos que haviam evadido do curso e que, possivelmente, tiveram menos tempo para se dedicar aos estudos ou menor motivação. Ademais, esses resultados também nos levam a refletir sobre possibilidades de melhorias no ABCIA, tais como aperfeiçoar as listas de exercício, para que o estudante treine mais e, ainda, aperfeiçoar a própria medida de Pré e Pós-teste, no intuito de refletir melhor os comportamentos desenvolvidos por meio das condições de ensino propostas (videoaulas, listas e encontros síncronos para saneamento de dúvidas). Não obstante, vale sinalizar que os tamanhos do efeito estão dentro da faixa mínima aceitável, indicando que houve melhora de desempenho e autoconfiança entre o início e o final do curso [20].

Finalmente, com relação à satisfação, identificamos um escore de satisfação geral de 4,59 (*DP* = 0,37). Calculamos, ainda, escores por fator da escala. O escore de Satisfação com a Infraestrutura foi de 4,67 (*DP* = 0,37), o de Satisfação com o Curso foi 4,53 (*DP* = 0,38) e o de Satisfação com as Oportunidades de Desenvolvimento foi 4,64 (*DP* = 0,48). Esses achados sugerem que a satisfação dos alunos que concluíram o curso ABCIA no 4º ciclo, também foi elevada, assim como ocorreu nas três ofertas anteriores.

Com base nos nossos achados, podemos afirmar que o ABCIA obteve resultados promissores, afinal os indicadores calculados estão em conformidade com as expectativas do planejamento e com indicações da literatura científica. Merece destaque o fato de que os tamanhos do efeito obtidos foram superiores ao mínimo esperado [20].

5.2 Análise da evasão

O curso ABCIA teve uma evasão de 37%. Ela não é alta, pois em cursos *on-line* as taxas de concluintes ficam entre 5% e 25% [21]. Não obstante, trata-se de uma evasão que desejamos reduzir. Nessa perspectiva, buscamos identificar se havia algum perfil específico dos participantes que evadiram, em relação ao qual devamos ficar atentos em novas versões do curso.

Começamos a análise tentando construir uma Árvore de Decisão que nos ajudasse a identificar o perfil dos alunos que evadiram. Contudo, os resultados não foram promissores. Chegamos em uma acurácia baixa, de apenas 61%, com um modelo pouco interpretável porque não conseguia prever adequadamente as características de quem evadiu do curso.

Poderíamos encontrar resultados mais promissores com a Árvore de Decisão por meio de um tratamento dos dados, eliminado *outliers* que podem ser identificados na Figura 1A e 1B. Não obstante, em função do pequeno número de dados, avaliamos que os resultados são tornariam a árvore mais clara, sendo desejável

examinar em estudos futuros outros algoritmos de aprendizado de máquina, mesmo que não gerem modelos visuais e interpretáveis.

Ao analisarmos os dados, observamos poucas diferenças entre as características sociodemográficas dos participantes em função de terem concluído ou não o curso. Um exemplo nesse sentido é a idade dos participantes (ver Figura 1A). Por outro lado, identificamos que a nota no Pré-teste foi um aspecto que distinguiu aqueles que concluíram o curso daqueles que evadiram (ver Figura 1B).

Ao conduzirmos um teste *t* com essas duas variáveis, verificamos que apenas a variável nota no pré-teste ($t = -2,832$; $gl = 376$; $p = 0,005$) apresentou médias diferentes entre o grupo de participantes que evadiu ($M = 5,85$; $DP = 1,15$) e os que concluíram o curso ($M = 6,22$; $DP = 1,26$). A variável idade, por sua vez, ($t = 0,168$; $gl = 376$; $p = 0,866$) não apresentou essa diferença entre os grupos de participantes que evadiram ($M = 31,77$; $DP = 9,95$) e os que finalizaram o ABCIA ($M = 31,59$; $DP = 10,05$). Com base nesses resultados, notamos que pode ser importante incentivar os alunos com notas baixas no pré-teste a persistirem no curso.

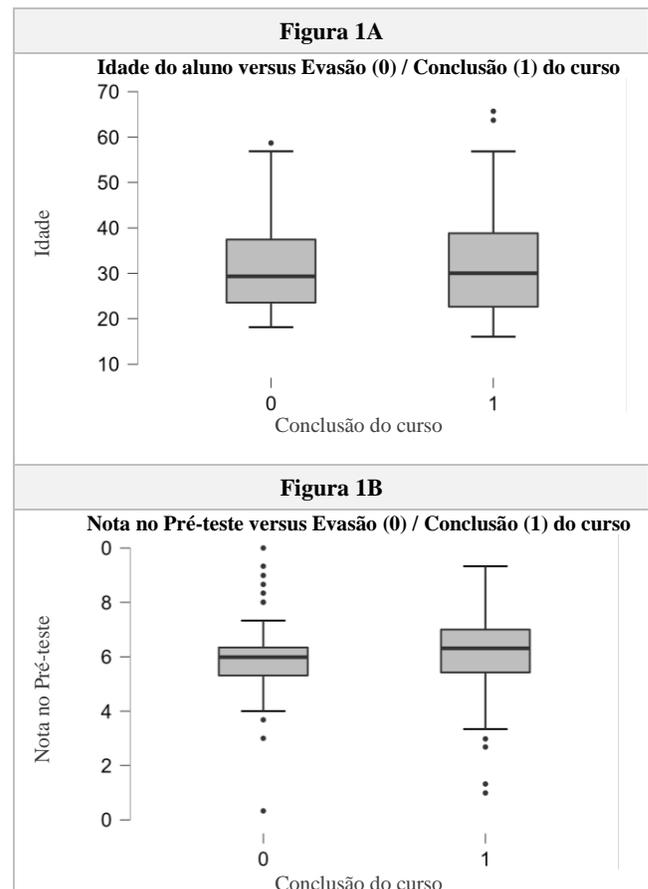


Figura 1. Boxplot com dados de idade (A) e nota no pré-teste (B) em função da conclusão (1) ou evasão (0) do curso ABCIA.

Observamos, ainda, informalmente, que outra variável que pode impactar na conclusão do ABCIA é o tempo de duração do curso. Quanto maior a duração, menor a probabilidade de que todos

consigam finalizá-lo. Adicionalmente, notamos que nem todos os alunos dispõem de acesso fácil a um computador, sendo conveniente, conforme Freitas et al. (2022) [8] detectaram, desenvolver uma versão do curso cujas atividades sejam compatíveis com a visualização e trabalho a partir de um smartphone. Por fim, é preciso propor e testar estratégias de promoção de engajamento, que podem envolver desde a presença de tutores *on-line*, realizando contatos diários com os alunos, até técnicas de gamificação.

Por fim, lembramos que os principais recursos desenvolvidos no curso ABCIA foram disponibilizados, gratuitamente, no seguinte endereço < <https://sites.google.com/view/abcia/> >. Esse material está disponível para ser reutilizado como está ou adaptado. Solicitamos apenas a citação a este artigo como reconhecimento pelo trabalho desenvolvido.

5.3 Ameaças à validade e Limitações do estudo

6.1.1. Ameaças à validade de construção. Não encontramos ameaça dessa natureza, uma vez que a relação encontrada entre as condições de ensino arranjadas (VI) e o desempenho dos alunos (VD) era esperada do ponto de vista teórico.

6.1.2. Ameaças à validade interna. A principal ameaça nesse sentido foi não dispor de um instrumento avaliativo dos objetivos de aprendizagem, que contemplasse todos eles e que contasse com evidências psicométricas favoráveis. Além disso, seria útil poder avaliar o aprendizado com itens de Pós-teste que fossem diferentes daqueles do Pré-teste, mas mantendo o grau de dificuldade. Isso afastaria a possibilidade de que os alunos aprendam com os erros do Pré-teste e, por esse motivo, melhorem o desempenho no Pós-teste. Assim, apesar dos avanços, seguimos precisando evoluir em termos de avaliação de eficiência das capacitações que realizamos, conforme apontado por Marques et al. (2020) [11].

6.1.3. Ameaças à validade de conclusão. Avaliamos que não ocorreram erros de escolha ou interpretação de estatísticas no presente estudo.

6.1.4. Ameaças à validade externa. Entendemos que a generalização dos resultados deva ser feita com cautela, uma vez que não trabalhamos com amostras aleatórias. Recomendamos, portanto, a replicação deste estudo com amostras maiores e mais diversas, se possível com seleção aleatória de participantes. Seria útil, ainda, comparar grupos controle e experimental. O primeiro grupo podendo receber outra atividade, que não o curso ABCIA, e o grupo experimental tendo acesso ao ABCIA.

Uma limitação importante deste estudo foi a falta de uma pesquisa prévia para a descoberta e formulação dos objetivos de aprendizagem, que orientaram a capacitação. Esse cuidado na fase de planejamento pode ajudar a tornar o curso mais eficaz em termos de seu impacto social [4, 6].

5.4 Trabalhos Futuros

Estudos futuros podem se concentrar na ampliação e diversificação da amostra, para avaliar se os resultados positivos podem ser replicados. Recomendamos também a condução de estudos de Educação em Computação com foco na construção de testes de conhecimento, que possam ser usados na avaliação de

eficiência do ensino, bem como trabalhos de descrição de objetivos de aprendizagem. Adicionalmente, observamos que seria importante avaliar junto aos alunos que evadiram do curso os motivos pelos quais isso aconteceu. Um levantamento preliminar dessa natureza poderia ser feito com o auxílio de um questionário *on-line* enviado para essas pessoas.

Por fim, sugerimos a realização de uma revisão da literatura que proponha para a comunidade de Educação em Computação um *framework* para a realização de cursos *on-line* similares ao que apresentamos aqui. Essa ferramenta poderia ajudar a organizar os principais aspectos de planejamento de um curso, do que tende a ser mais efetivo para a promoção de aprendizagens e de avaliação de eficiência dessa capacitação.

5.5 Lições aprendidas

Um dos aspectos que consideramos fundamental neste estudo, consiste na explicitação de quais são os objetivos de aprendizagem estabelecidos como alvos do curso ABCIA. Foi a partir deles que pensamos em metodologias ou condições de ensino e em estratégias de avaliação do aprendizado. Apesar de sua relevância, Henklain e Vieira-Santos (2022) [22] identificaram que, raramente, avaliações de desempenho docente consideram essa dimensão do planejamento de ensino ou examinam se professores formulam objetivos como ponto de partida para a sua atuação. Ademais, lembramos que nossos objetivos de aprendizagem contemplaram comportamentos relacionados à definição de conceitos e identificação de processos e fenômenos no âmbito da Inteligência Artificial. Isso contribuiu para que os alunos compreendessem noções básicas de IA, no lugar de aprender apenas a utilizar algoritmos específicos. Entender por qual motivo um algoritmo funciona é tão importante quanto saber aplicá-lo, até para que o futuro profissional dessa área saiba quais são as limitações e possibilidades do recurso que está utilizando.

Também ressaltamos a importância de que educadores, minimamente, avaliem repertórios de entrada (o que o aluno sabe antes de iniciar o curso) e de saída dos alunos (o que o aluno sabe ao final do curso). Essa comparação entre início e final contribuiu com a identificação sobre se e em que medida o aprendizado ocorreu, algo que também poucas vezes é contemplado nas avaliações de desempenho docente [22]. O que é comum é saber se o professor avalia e se usa critérios justos, mas não se ele usa os dados da avaliação como indicadores de eficiência das condições de ensino que implementou, servindo, portanto, como fonte de informação para o aperfeiçoamento do seu trabalho.

Em termos de aplicação deste curso, consideramos que ele pode ser utilizado em novos contextos, desde que sejam mantidas as características dos alunos, no sentido de idade e conhecimento de informática básica. Uma vez que os recursos que desenvolvemos estão disponíveis na Internet, é possível também adaptar esse material ou adotá-lo com referência para a elaboração de uma nova capacitação.

6 CONCLUSÃO

O objetivo deste estudo foi avaliar a eficiência do curso ABCIA em relação ao ensino do comportamento de “caracterizar

como funciona o aprendizado de máquina a partir de conceitos básicos dessa subárea da IA, de elementos da matemática subjacente aos seus algoritmos e das aplicações e limitações dessa tecnologia”. Os resultados de aprendizado, autoconfiança e satisfação sinalizaram que o curso foi eficiente nas quatro ofertas do curso ABCIA, enquanto os dados de evasão estiveram dentro dos parâmetros típicos para cursos à distância.

Esperamos ter contribuído com a literatura sobre ensino de elementos básicos de IA para a população. Seguramente, é premente a necessidade de que os membros de nossa sociedade saibam não só usar ou criar modelos de IA, como também compreendam o seu funcionamento e suas limitações.

Agradecimentos

Este projeto foi apoiado pelo Ministério da Ciência, Tecnologia e Inovação, com recursos da Lei nº 8.248, de 23 de outubro de 1991, no âmbito do PPI-SOFTEX, coordenado pela Softex.

REFERÊNCIAS

- [1] D. T. Wijayati, Z. Rahman, M. F. W. Rahman, I. D. C. Arifah, and A. Kautsar. 2022. A study of artificial intelligence on employee performance and work engagement: The moderating role of change leadership. *International Journal of Manpower*, 43, 2, 486-512. <https://doi.org/10.1108/IJM-07-2021-0423>
- [2] K. Schwab. 2019. A quarta revolução industrial. Edipro, São Paulo, Brasil.
- [3] T. Taulli. 2020. Introdução à Inteligência Artificial: Uma abordagem não técnica. Novatec Editora, São Paulo, Brasil.
- [4] B. C. Cianca, M. G. Panosso, and N. Kienen. 2020. Programação de Condições para Desenvolvimento de Comportamentos: Caracterização da produção científica brasileira de 1998-2017. *Perspectivas em Análise do Comportamento*, 11, 2, 114-136. <https://doi.org/10.18761/PAC.2020.v11.n2.01>
- [5] D. Zilio, and H. Neves-Filho. 2018. O que (não) há de “complexo” no comportamento? Behaviorismo radical, self, insight e linguagem. *Psicologia USP*, 29, 3, 374-384. <https://doi.org/10.1590/0103-656420170027>
- [6] N. Kienen, O. M. Kubo, and S. P. Botomé. 2013. Ensino programado e programação de condições para o desenvolvimento de comportamentos: Alguns aspectos no desenvolvimento de um campo de atuação do psicólogo. *Acta Comportamental: Revista Latina de Análisis del Comportamiento*, 21, 4, 481-494. Recuperado de: <https://bit.ly/3Fq6EtF>
- [7] Brasil. 2018. Base nacional comum curricular. Recuperado de: <https://bit.ly/2zzjW8p>
- [8] K. Freitas, I. Batista, W. Lima, P. Silva, and R. Ribeiro. 2022. Apresentando Inteligência Artificial para jovens do ensino médio: Um relato de experiência. In *Anais do XXX Workshop sobre Educação em Computação*, SBC, Porto Alegre, Rio Grande do Sul, 192-203. <https://doi.org/10.5753/wei.2022.223075>
- [9] G. F. Luger. 2013. Inteligência Artificial. Pearson Education do Brasil, São Paulo, Brasil.
- [10] L. Barboza, R. Mello, M. Modell, and E. S. Teixeira. 2023. Blockly-DS: Blocks Programming for Data Science with visual, statistical, descriptive and predictive analysis. In *LAK23: 13th International Learning Analytics and Knowledge Conference*, Association for Computing Machinery, New York, USA, 644-649. <https://doi.org/10.1145/3576050.3576097>
- [11] L. Marques, C. von Wangenheim, and J. R. Hauck. 2020. Ensino de Machine Learning na educação básica: Um mapeamento sistemático do estado da arte. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, SBC, Porto Alegre, 21-30. <https://doi.org/10.5753/cbie.sbie.2020.21>
- [12] Herta, C.; Voigt, B.; Baumann, P.; Strohmenger, K.; Jansen, C.; Fischer, O.; Zhang, G.... (2019). Deep Teaching: Materials for Teaching Machine and Deep Learning. In *HEAD'19. 5th International Conference on Higher Education Advances*. Editorial Universitat Politècnica de València. 1153-1131. <https://doi.org/10.4995/HEAD19.2019.9177>
- [13] C. Romero, and S. Ventura. 2020. Educational data mining and learning analytics: An updated survey. *Wiley interdisciplinary reviews: Data mining and knowledge discovery*, 10, 3, e1355. <https://doi.org/10.1002/widm.1355>
- [14] M. Scheffel, H. Drachler, S. Stoyanov, and M. Specht. 2014. Quality indicators for learning analytics. *Journal of Educational Technology & Society*, 17, 4, 117-132. <https://www.jstor.org/stable/jeductechsoci.17.4.117>
- [15] A. Whitelock-Wainwright, D. Gašević, R. Tejeiro, Y. Tsai, and K. Bennett. 2019. The student expectations of Learning Analytics Questionnaire. *Journal of Computer Assisted Learning*, 35, 5, 633-666. <https://doi.org/10.1111/jcal.12366>
- [16] Y. Tsai, R. F. Mello, J. Jovanović, and D. Gašević. 2021. Student appreciation of data-driven feedback: A pilot study on OnTask. In *LAK21: 11th International Learning Analytics and Knowledge Conference (LAK21)*, Association for Computing Machinery, New York, USA, 511-517. <https://doi.org/10.1145/3448139.3448212>
- [17] T. P. Falcão, R. L. Rodrigues, C. Cechinel, D. Dermeval, E. H. T. Oliveira, I. Gasparini, R. D. Araújo, T. Primo, D. Gasevic, and R. F. Mello. 2022. A Penny for your thoughts: Students and instructors' expectations about learning analytics in Brazil. In *LAK22: 12th International Learning Analytics and Knowledge Conference (LAK22)*, Association for Computing Machinery, New York, USA, 186-196. <https://doi.org/10.1145/3506860.3506886>
- [18] A. L. Cortegoso, and D. S. Coser. 2013. Elaboração de programas de ensino: Material autoinstrutivo. Edufscar, São Carlos, São Paulo, Brasil.
- [19] A. L. R. Schleich, S. A. J. Polydoro, and A. A. A. Santos. 2006. Escala de satisfação com a experiência acadêmica de estudantes do ensino superior. *Avaliação Psicológica*, 5, 1, 11-20. Recuperado de: <https://bit.ly/433aiTu>
- [20] J. Hattie. 2015. What works best in education: The politics of collaborative expertise. Pearson, London, UK. Recuperado de: <https://bit.ly/30dqJi2>
- [21] R. Poy Castro and A. Gonzales Aguilar. 2014. Factores de éxito de los MOOC: Algunas consideraciones críticas. *RISTI - Revista Ibérica de Sistemas e Tecnologías de Informação*, E1, 3, 105-118. Conference Location: El Paso, Texas USA. <http://bit.ly/3SkoiYG>
- [22] M. H. O. Henklain, and J. Vieira-Santos. 2022. O que se espera do professor universitário em relação ao ensino? Respostas a partir de instrumentos avaliativos. In M. H. O. Henklain (org.), *Desempenho acadêmico e profissional: Relatos de pesquisa para inspirar novas investigações científicas*, Pedro & João Editores, São Carlos, Brasil, 237-263. <https://bit.ly/49ktJL6>