

# Ferramentas Visuais Web para o Estudo de Aprendizado de Máquina no Ensino Superior: Um Mapeamento Sistemático

Denis W. da Silva<sup>1</sup>, Luiz Carlos B. Barbosa<sup>2</sup>, Rodrigo D. Seabra<sup>1</sup>

<sup>1</sup>Instituto de Matemática e Computação – Universidade Federal de Itajubá (UNIFEI) – Itajubá – MG – Brasil

<sup>2</sup>Instituto de Recursos Naturais – Universidade Federal de Itajubá (UNIFEI) – Itajubá – MG – Brasil

03willian10@gmail.com, luizcbb@unifei.edu.br, rodrigo@unifei.edu.br

**Abstract.** *The systematic mapping conducted in this study identified eight visual web tools for studying machine learning (ML) in higher education, highlighting their educational characteristics, ML resources offered, visual elements used to facilitate studies and evaluation methodologies. The results revealed that the tools do not require users to have any experience in ML and that most of the tools are used to demonstrate the workings of neural networks, with image classification being the most commonly addressed task. The main contribution lies in the characterization of accessible web-based visual tools for studying ML, intending to help educators and students select those that best suit their interests and study contexts.*

**Resumo.** *O mapeamento sistemático conduzido neste estudo identificou oito ferramentas visuais web para o estudo de aprendizado de máquina (AM) no ensino superior, com destaque para suas características educacionais, recursos de AM oferecidos, elementos visuais utilizados para a facilitação dos estudos e metodologias de avaliação. Os resultados revelaram que as ferramentas não requerem experiência em AM pelos usuários e que a maioria delas serve para a demonstração do funcionamento de redes neurais, sendo a classificação de imagens a tarefa mais comumente abordada. A principal contribuição do artigo reside na caracterização de ferramentas visuais web acessíveis para o estudo de AM, visando auxiliar educadores e estudantes a selecionarem aquelas que mais se adaptem aos seus interesses e contextos de estudo.*

## 1. Introdução

O aprendizado de máquina, subcampo da inteligência artificial (IA), corresponde ao estudo e à construção de algoritmos que podem aprender a partir de dados, permitindo aos computadores inferirem padrões, automaticamente, sem serem explicitamente informados sobre quais são esses padrões. Essas inferências são frequentemente baseadas no uso de algoritmos para examinar, automaticamente, as propriedades estatísticas dos dados e suas relações [Mitchell 1997; Goodfellow *et al.* 2016].

Já o aprendizado profundo representa uma subcategoria do AM, focada na implementação de redes neurais profundas. Embora a popularidade do aprendizado profundo tenha aumentado significativamente nos últimos anos, o AM clássico ainda é prevalente em diferentes campos de pesquisa e no contexto de empresas e indústrias [Raschka *et al.* 2020].

Atualmente, o AM está presente em variados dispositivos e serviços que fazem parte da vida humana, como serviços de recomendação [Lalitha e Sreeja 2021], diagnóstico de cuidados de saúde [Zhang *et al.* 2022], veículos autônomos [Parekh *et al.* 2022], ambientes virtuais de aprendizagem [Silva Filho 2023], dentre outros.

Devido ao crescimento da IA, preparar os cidadãos para esta área, incluindo os jovens não universitários, tornou-se uma importante estratégia para promover a competitividade, exigindo que mais pessoas procurem uma carreira no campo da IA. O desenvolvimento de aplicações habilitadas para o AM, entretanto, não é trivial. Por exemplo, o desenvolvimento de um modelo preditivo envolve várias tarefas, requerendo uma compreensão de algoritmos e processos de trabalho complexos, além de exigir que o usuário possua certo nível de habilidades de programação, fazendo com que ele fique imerso em uma gama cada vez maior de arquiteturas e frameworks. Por conseguinte, a aprendizagem de alunos iniciantes nesta área é uma tarefa difícil [Wangenheim *et al.* 2021], portanto, para popularizar o AM, é desejável reduzir o esforço cognitivo desse perfil discente.

Nesse sentido, algumas plataformas e ferramentas com recursos visuais foram desenvolvidas para alunos dos ensinos fundamental e médio, revisadas na pesquisa de Wangenheim *et al.* (2021). Em se tratando de adultos, o caminho mais comum para a compreensão de conceitos na área de AM ocorre por meio de programas universitários, cursos *online* e treinamento no local de trabalho.

Devido à possibilidade de aplicação da IA em basicamente todas as outras áreas do conhecimento, é muito comum hoje o educador na área de AM se deparar com aprendizes que não são especificamente da grande área da ciência da computação. Em cursos introdutórios (incluindo livros) nesta área, cada conceito e algoritmo ensinados costumam serem seguidos por implementações no computador, usando uma linguagem de programação baseada em texto, como Python. Devido à complexidade da área e a concomitante exigência de conhecimento aprofundado da linguagem de programação, a transição da teoria para a prática é, muitas vezes, intimidadora para o aluno. Nesse âmbito, ainda são poucos os projetos que visam a construção de ferramentas visuais propícias ao estudo de conceitos de AM para alunos iniciantes, especialmente no que diz respeito a ferramentas *web*.

Este trabalho conduziu um mapeamento sistemático da literatura, visando identificar, analisar e comparar ferramentas visuais *web* desenvolvidas para o estudo de AM, direcionadas a estudantes do ensino superior. Pretende-se apresentar um panorama de uso dessas ferramentas, bem como compreender o estado da arte neste campo de pesquisa.

A identificação sistemática de recursos de estudo disponíveis na *web*, na forma das mais variadas funcionalidades, poderá contribuir para futuros trabalhos de seleção desses recursos, representando a principal contribuição da pesquisa. Esse argumento se justifica, pois, considerando o fato de ferramentas *web* geralmente não envolverem qualquer tipo de instalação, este aspecto pode favorecer a adesão dos aprendizes quanto ao uso, disponibilidade e acesso. O artigo também abrange uma descrição de situações de uso e avaliação das ferramentas identificadas, de forma a destacar os resultados obtidos com suas aplicações e observar desafios e oportunidades nesse contexto de pesquisa.

O artigo está estruturado da seguinte forma: a Seção 2 apresenta a metodologia de pesquisa empregada para procurar, extrair e classificar informações dos trabalhos

identificados; os resultados são discutidos na Seção 3; e as conclusões do estudo são explanadas na Seção 4.

## 2. Definição da Pesquisa

Com o objetivo de identificar, analisar e classificar ferramentas visuais *web* desenvolvidas para o estudo de AM, voltadas para o ensino superior, o mapeamento sistemático da literatura proposto por este trabalho seguiu os procedimentos definidos por Petersen *et al.* (2015), sendo estruturado de forma a empregar questões de pesquisa, protocolos de busca, critérios de seleção, classificação e extração de dados.

### 2.1 Questões de Interesse

Estabelecido o objetivo principal do estudo, foram definidas cinco questões de pesquisa:

**Q1: *Quais são e como se caracterizam as ferramentas visuais web para o estudo de AM direcionadas ao ensino superior?*** Esta questão objetiva descrever as ferramentas visuais para o estudo de AM encontradas, de forma que sejam mencionadas suas principais finalidades e especificados os principais componentes importantes para seus funcionamentos e disponibilização das interfaces gráficas.

**Q2: *Quais são suas características educacionais?*** Um dos objetivos dessa questão é reunir informações sobre o tipo de intervenção recomendado pelos autores das ferramentas para seus usos, como a necessidade ou não de aulas introdutórias ou detalhamento da carga horária de estudo. Também se espera a obtenção de informações como a escolaridade do público-alvo, seu nível de experiência com AM e a existência ou não de materiais suplementares para o estudo, como tutoriais ou vídeos, por exemplo.

**Q3: *Quais funcionalidades de AM são fornecidas pelas ferramentas?*** Nesta questão, objetiva-se caracterizar os recursos de AM fornecidos pelas ferramentas, por exemplo, detalhando se há suporte aos tipos de aprendizado supervisionado, não-supervisionado ou por reforço. Além disso, visa reunir informações a respeito dos tipos de dados de entrada suportados e as tarefas que podem ser desempenhadas por cada ferramenta, bem como se há suporte a explicações ou outras facilidades para os estudantes durante a realização dessas tarefas.

**Q4: *Que tipos de recursos visuais são disponibilizados pelas ferramentas para a facilitação dos estudos?*** Esta questão visa caracterizar os ambientes onde são executados os estudos de AM relativos aos tipos de elementos visuais fornecidos para reduzir a carga cognitiva envolvida na utilização de códigos.

**Q5: *Como as ferramentas foram desenvolvidas e avaliadas?*** Esta questão reúne informações a respeito dos métodos utilizados no desenvolvimento das aplicações, buscando a obtenção de dados como os perfis dos participantes envolvidos nos testes com as ferramentas e as possíveis medidas tomadas por seus autores com relação às experiências relatadas pelos usuários.

### 2.2 Execução da Pesquisa

As buscas foram executadas nas principais bases de documentação científica: *ACM Digital Library*, *ERIC – Education Resource Information Center*, *IEEE Xplore*, *ScienceDirect*, *Springer Link* e *Wiley Online Library*, acessadas por meio do Portal Capes. Foi utilizado, ainda, o *Google Scholar*, de forma a ampliar a abrangência de

resultados e minimizar o risco de omissões. Também foram incluídos trabalhos obtidos por meio de *snowballing*, referenciados pelos artigos relevantes localizados.

Com base nas diretrizes propostas por Keele (2007) e na temática desta pesquisa, procurou-se responder aos seguintes critérios para a construção de uma *string* de busca para o retorno de publicações relacionadas aos propósitos deste trabalho: (i) público-alvo: estudantes do ensino superior; (ii) tipo de intervenção: ferramenta visual com pouca codificação; (iii) resultados esperados: estudo por parte do usuário; (iv) contexto: aprendizado de máquina. Foram executados vários testes nas bases com o objetivo de ajustar a calibragem da *string* de busca, de forma a otimizar os resultados da pesquisa.

Levando em consideração os tópicos supracitados como termos imprescindíveis para as pesquisas por publicações de temas semelhantes a este estudo, fazendo a adaptação dos termos para a língua inglesa e adicionando termos correlatos, foi elaborada a seguinte *string* de busca: ("visual tool" OR "visual application" OR "visual programming" OR "low-code" OR "no-code") AND ("teach" OR "teaching") AND ("machine learning" OR "ml") AND ("undergraduate" OR "undergraduation" OR "college" OR "university").

Vale destacar que não foram incluídas restrições de datas no mapeamento, de forma a ampliar o resultado em termos de identificação das ferramentas. A *string* completa de busca, utilizada em cada plataforma, pode ser consultada no Quadro 1.

**Quadro 1. String de busca nas bases digitais. Fonte: Os autores.**

Fonte	String de Busca
<i>ACM Digital Library</i>	[[All: "visual tool"] OR [All: "visual application"] OR [All: "visual programming"] OR [All: "low-code"] OR [All: "no-code"]] AND [[All: "teach"] OR [All: "teaching"]] AND [[All: "machine learning"] OR [All: "ml"]] AND [[All: "undergraduate"] OR [All: "undergraduation"] OR [All: "college"] OR [All: "university"]] Filtragem: Journals, Acesso livre
<i>ERIC</i>	("visual" OR "low-code" OR "no-code") AND ("teach" OR "teaching") AND ("machine learning" OR "ml") AND ("undergraduate" OR "undergraduation" OR "college" OR "university") Filtragem: Full text available on ERIC, Acesso livre
<i>IEEE Xplore</i>	("All Metadata": "visual tool" OR "All Metadata": "visual application" OR "All Metadata": "visual programming" OR "All Metadata": "low-code" OR "All Metadata": "no-code") AND ("All Metadata": "teach" OR "All Metadata": "teaching") AND ("All Metadata": "machine learning" OR "All Metadata": "ml") AND ("All Metadata": "undergraduate" OR "All Metadata": "undergraduation" OR "All Metadata": "college" OR "All Metadata": "university") Filtragem: Acesso livre
<i>Google Scholar</i>	("visual tool" OR "visual application" OR "visual programming" OR "low code" OR "no code") AND "machine learning" AND teaching AND undergraduate -"K 12" -"high school" -"elementary school" -"middle school" Filtragem: nenhuma
<i>ScienceDirect</i>	("visual tool" OR "visual programming" OR "low-code" OR "no-code") AND ("teach") AND ("machine learning") AND ("undergraduate" OR "college" OR "university") Filtros: Review articles, Research articles, Computer Science, Acesso livre
<i>Springer Link</i>	("visual tool" OR "visual application" OR "visual programming" OR "low-code" OR "no-code") AND ("teach" OR "teaching") AND ("machine learning" OR "ml") AND ("undergraduate" OR "undergraduation" OR "college" OR "university") Filtros: Article, Computer Science, English, Acesso livre
<i>Wiley Online Library</i>	("visual tool" OR "visual application" OR "visual programming" OR "low-code" OR "no-code") AND ("teach" OR "teaching") AND ("machine learning" OR "ml") AND ("undergraduate" OR "undergraduation" OR "college" OR "university") Filtros: Journals, Acesso livre

As buscas com a *string* definitiva foram executadas pelos autores deste trabalho em dezembro de 2023, sendo que o resultado obtido totalizou 884 artefatos, a saber: *ACM Digital Library* – 69; *ERIC* – 6; *IEEE Xplore* – 1; *Google Scholar* – 720; *ScienceDirect* – 29; *Springer Link* – 42; *Wiley Online Library* – 17.

Aplicando os critérios de inclusão e exclusão previamente estabelecidos (Quadro 2), tornou-se notável o fato de que a maior parte das publicações encontradas não

possuía relação com o tema da pesquisa. Isso foi constatado por meio de análises em duas etapas para a seleção de publicações relevantes.

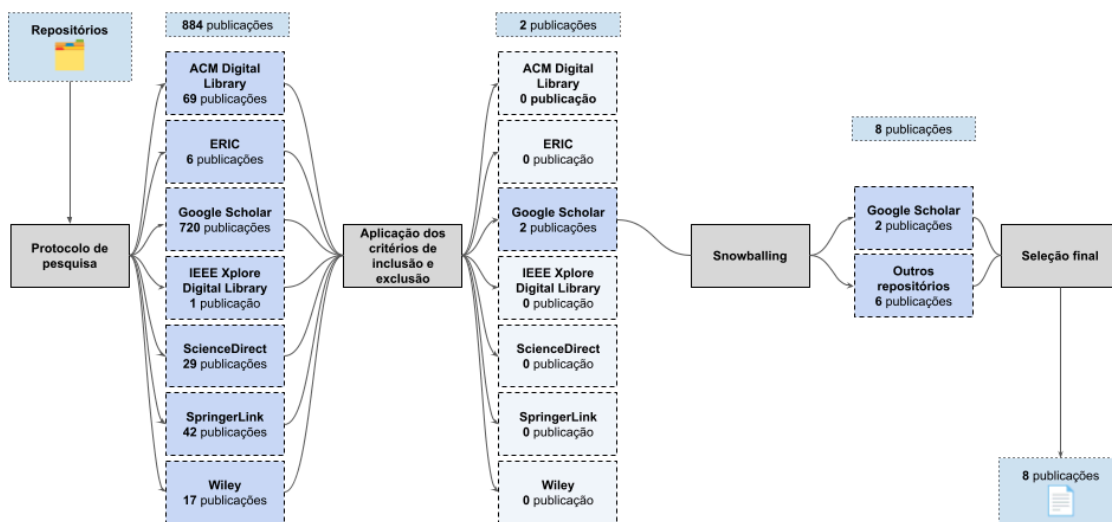
A primeira etapa consistiu na análise dos 884 resultados obtidos, levando à eliminação de 862 publicações não relevantes para esta pesquisa, restando, portanto, 22 publicações potencialmente relevantes. Subsequentemente, as publicações que não foram eliminadas na primeira etapa foram submetidas a uma nova análise na segunda etapa.

Esse processo, que consistiu em uma releitura mais aprofundada dos 22 resultados restantes, levou à eliminação de 20 publicações devido aos critérios de exclusão. Ademais, essa etapa também proporcionou a obtenção de novos trabalhos relevantes (seis) devido ao processo de *snowballing*, que consistiu na checagem de ferramentas visuais *web* para estudo de AM mencionadas pelos autores das publicações, para, assim, encontrar mais resultados relevantes. Por conseguinte, somando-se as publicações consideradas relevantes pelos critérios de inclusão 1 e 2, foram encontradas oito publicações relevantes para o estudo em tela.

A Figura 1 mostra um infográfico que retrata o protocolo de pesquisa seguido para a seleção das publicações.

**Quadro 2. Critérios de inclusão (CI) e exclusão (CE). Fonte: Os autores.**

Critério	Descrição
CI-01	Publicação descreve uma nova ferramenta com recursos visuais para a execução de processos de AM.
CI-02	Publicação relevante encontrada por meio do processo de <i>snowballing</i> .
CE-01	Publicação não relacionada a ferramentas visuais para o contexto de AM.
CE-02	Idioma diferente de português ou inglês.
CE-03	Publicação descreve ferramenta direcionada apenas para o público infantil ou adolescente;
CE-04	Publicação duplicada.
CE-05	Publicação ou ferramenta inacessível (acesso ao <i>website</i> não permitido, publicação retirada ou ferramenta não disponibilizada pelos autores para uso).
CE-06	Publicação ou ferramenta voltada para propósitos diferentes ao estudo de AM.
CE-07	Publicação discute elementos visuais relacionados ao contexto de AM, mas não descreve uma ferramenta <i>web</i> que utilize recursos visuais para facilitar a compreensão ou utilização dos algoritmos de AM.



**Figura 1. Protocolo utilizado no mapeamento sistemático. Fonte: Os autores.**

A quantidade de publicações aprovadas pelos critérios de inclusão representa uma porção irrisória do total de publicações retornadas pelas plataformas de busca. Essa escassez de resultados relevantes pode ser vista como uma motivação para a realização de investimentos em recursos e esforços para o desenvolvimento de ferramentas visuais *web* voltadas para o estudo de AM, já que essa área parece ter sido pouco explorada por pesquisadores.

Na Figura 2 são mostrados os anos de lançamentos das publicações.



Figura 2. Anos de lançamentos das publicações utilizadas como referências. Fonte: Os autores.

### 3. Resultados e Discussão

Visando a responder as questões de pesquisa propostas no artigo, foram analisados os trabalhos identificados no mapeamento conduzido. No que tange à primeira questão de pesquisa – **Q1: Quais são e como se caracterizam as ferramentas visuais web para o estudo de AM direcionadas ao ensino superior?**, foram identificadas oito ferramentas para essa finalidade. As ferramentas consideradas relevantes para este estudo são mostradas no Quadro 3, que relaciona seus nomes, descrições e referências. Foram utilizadas identificações genéricas definidas a partir dos sobrenomes dos autores para fazer referência às ferramentas cujos nomes não foram especificados nos trabalhos publicados.

Quadro 3. Catálogo das ferramentas identificadas. Fonte: Os autores.

Ferramenta	Descrição	Referências
Aplicação de Harley	Uma ferramenta para explorar redes neurais convolucionais (CNNs) treinadas para reconhecer dígitos manuscritos.	[Harley 2015]
Aplicação de Schultze <i>et al.</i>	Uma aplicação baseada em classificação de imagens, que permite aos usuários a criação de modelos personalizados.	[Schultze <i>et al.</i> 2020]
Biblioteca <i>Snap!</i> de Kahn <i>et al.</i>	Uma biblioteca de aprendizado de máquina para a plataforma <i>Snap!</i> , que consiste em um sistema de programação baseado em blocos.	[Kahn <i>et al.</i> 2020]
<i>CNN Explainer</i>	Uma aplicação para facilitar o entendimento de CNNs (redes neurais convolucionais).	[Wang <i>et al.</i> 2020]
<i>GAN Lab</i>	Uma aplicação para facilitar o entendimento de GANs (redes generativas adversariais), que são modelos complexos de aprendizado profundo.	[Kahng <i>et al.</i> 2018]
<i>Script Scratch</i> de Estevez <i>et al.</i>	Um <i>script</i> utilizado em um <i>workshop</i> para o estudo de AM por meio da plataforma de programação em blocos <i>Scratch</i> .	[Estevez <i>et al.</i> 2019]
<i>Teachable Machine</i>	Uma aplicação que permite que os usuários treinem seus próprios modelos de AM a partir de imagens e sons.	[Carney <i>et al.</i> 2020]
<i>TensorFlow Playground</i>	Uma aplicação cujo principal objetivo é auxiliar os usuários a entenderem o funcionamento de redes neurais.	[Smilkov <i>et al.</i> 2017]

A maioria das ferramentas encontradas utiliza *Javascript* para a disponibilização de interfaces gráficas. Isso provavelmente se deve ao fato de que esta linguagem,

usualmente, permite a execução de aplicações em navegadores *web*, sem a necessidade do *download* de dependências, extensões ou *plugins* adicionais. Kahn

Duas delas utilizam ambientes de programação visual em bloco, sendo elas o *script* desenvolvido por Estevez *et al.* (2019) e a biblioteca de Kahn *et al.* (2020) baseadas nas plataformas *Scratch* e *Snap!*, respectivamente. Essas ferramentas permitem que o usuário defina as instruções a serem executadas por meio do arrasto e posicionamento de blocos, sem a necessidade de escrever códigos a partir do zero. Dentre as ferramentas encontradas, apenas essas duas também fornecem uma versão *offline*. Em ambos os casos, essas versões podem ser baixadas e executadas como aplicações nativas para diferentes sistemas operacionais, como *Windows* e *MacOS*.

A biblioteca *TensorFlow.js*, do *JavaScript*, é utilizada na maioria das ferramentas para o processamento dos modelos. Em contrapartida, apenas a aplicação desenvolvida por Schultze *et al.* (2020) mencionou o uso da versão para Python do *TensorFlow*, no lado do servidor. Entretanto, os autores dessa ferramenta também citaram a existência de uma versão da aplicação puramente baseada no cliente, usando apenas *TensorFlow.js* para permitir que o usuário treine modelos em seu próprio *hardware*.

Quanto às bibliotecas utilizadas para a visualização de dados, destaca-se a *D3.js*, mencionada pelos autores de três ferramentas como a biblioteca utilizada para visualização. Apenas duas ferramentas explicitaram o uso de *APIs*, sendo elas a aplicação de Schultze *et al.* (2020), para o carregamento de *datasets* de imagens, e a biblioteca de Kahn *et al.* (2020), que requer a utilização de *APIs* em algumas de suas funcionalidades.

Quanto às linguagens naturais utilizadas, todas as ferramentas encontradas fornecem o idioma inglês como padrão. Porém, algumas delas permitem a alteração do idioma para outras opções, como é o caso da *Teachable Machine*. Nesse aspecto, observou-se uma particularidade na biblioteca de Kahn *et al.* (2020), na qual é permitida a alteração do idioma da plataforma *Snap!*, mas diversas anotações previamente feitas pelos autores da biblioteca continuam no idioma inglês.

No Quadro 4<sup>1</sup>, são feitas caracterizações das ferramentas com relação aos componentes importantes para seus funcionamentos e disponibilização das interfaces gráficas.

Em relação à segunda questão de pesquisa – **Q2: Quais são suas características educacionais?**, todas as ferramentas são acessíveis a usuários com experiência limitada em AM clássico ou aprendizado profundo. Porém, a utilização de algumas delas também é recomendável para usuários experientes, como mencionado pelos autores da *TensorFlow Playground*, que citam a possibilidade de executar muitas variações rapidamente como atrativa até mesmo para usuários com maior experiência em codificação. A maioria das ferramentas encontradas é recomendada não somente a estudantes de ensino superior, mas também aos de ensino médio.

Apenas uma ferramenta conta com um plano de estudo elaborado, no qual são envolvidos professores e aulas introdutórias. Trata-se do *script Scratch*, desenvolvido por Estevez *et al.* (2019), para um *workshop* de IA. Na publicação referente a essa ferramenta, os autores definem cargas horárias para aulas, bem como a ordem das atividades a serem realizadas pelos usuários da aplicação.

---

<sup>1</sup> <https://1drv.ms/f/c/47b20ac7a6225e72/EqheY-kyjOFDooS6KDoRWtcBj1W6kcBXNwpuPx6hjCmAfQ>

Para melhor entendimento das etapas envolvidas nos algoritmos de AM executados pelas aplicações, as ferramentas *CNN Explainer*, *Teachable Machine* e a aplicação de Schultze *et al.* (2020) mostram anotações de texto em toda a visualização para melhor orientar o usuário. Esta última também disponibiliza vídeos explicativos em algumas etapas do processamento do modelo para melhor entendimento do processo por parte do usuário.

A maioria das ferramentas conta com tutoriais *web* disponibilizados pelos autores para facilitar o aprendizado das funcionalidades de suas aplicações, sendo a maioria desses tutoriais rica em recursos visuais, como é o caso da *Teachable Machine*, cujo tutorial fornece não só explicações em texto, mas também em imagens e *GIFs* para que o usuário obtenha maior clareza. *CNN Explainer* e *GAN Lab* também fornecem tutoriais em vídeo em seus *websites*. A única ferramenta que não oferece um tutorial é o *script Scraeth*, de Estevez *et al.* (2019).

No Quadro 5<sup>2</sup>, são feitas caracterizações das ferramentas com relação aos seus atributos educacionais.

No âmbito da terceira questão de pesquisa – **Q3: Quais funcionalidades de AM são fornecidas pelas ferramentas?**, a maioria das ferramentas encontradas oferece suporte ao tipo de aprendizado supervisionado. Contudo, algumas delas possuem tarefas relacionadas a mais de um tipo de aprendizado, como é o caso da ferramenta de Estevez *et al.* (2019), que possui uma tarefa de aprendizado não supervisionado (baseada no método *K-means*) e outra relacionada ao uso de redes neurais, utilizadas para aprendizado supervisionado nessa tarefa.

Imagens podem ser utilizadas como dados de entrada na maioria das ferramentas. Porém, destaca-se uma peculiaridade na aplicação desenvolvida por Harley (2015), que recebe imagens de números desenhados pelo usuário como entrada. *Teachable Machine* é uma das ferramentas que suporta a maior diversidade de dados de entrada, já que permite a utilização de imagens ou áudios, tanto por meio do *upload* de arquivos quanto por meio do uso de *webcam* ou microfone.

Outra ferramenta que suporta uma diversidade de dados é a biblioteca *Snap!* para AM, de Kahn *et al.* (2020), que permite o uso de arquivos *CSV* e *JSON*, além de também possibilitar que o usuário forneça dados por meio de dispositivos de entrada como *webcam* ou microfone.

O tipo de algoritmo de AM mais comumente abordado é o das redes neurais, presente em quase todas as ferramentas analisadas. Já a tarefa de AM mais observada foi a de classificação de imagens. O treinamento de modelos de AM é permitido em quase todas as ferramentas, mas algumas delas utilizam modelos treinados, como *CNN Explainer* e a aplicação de Harley (2015), que fornecem números finitos de classes a serem retornadas como resultado.

A maioria das ferramentas permite a manipulação de hiperparâmetros para experimentação e visualização dos resultados obtidos por meio de suas variações. O número de épocas e a taxa de aprendizado são exemplos de hiperparâmetros comumente alteráveis. As ferramentas que não oferecem o recurso de modificação de hiperparâmetros para o treinamento dos modelos são a aplicação de Harley (2015) e *CNN Explainer*, que fornecem modelos treinados. *CNN Explainer*, no entanto, possui demonstrações interativas em seu tutorial para a simples visualização dos efeitos de

---

<sup>2</sup> <https://1drv.ms/f/c/47b20ac7a6225e72/EqheY-kyjOFDooS6KDoRWtcBj1W6kcBXNwpuPx6hjCmAfQ>



variações de hiperparâmetros, não interferindo no modelo treinado de AM no qual se baseia o funcionamento da aplicação.

No Quadro 6<sup>3</sup>, são feitas caracterizações das ferramentas com relação às suas funcionalidades de AM.

Na quarta questão de pesquisa – **Q4: Que tipos de recursos visuais são disponibilizados pelas ferramentas para a facilitação dos estudos?**, todas as ferramentas contêm botões por meio dos quais os usuários podem executar ações de forma intuitiva. *GAN Lab*, por exemplo, conta com um painel de controle que dispõe de diversos botões, como um botão de *play/pause* que serve para executar ou pausar o treinamento do modelo *GAN* e que se destaca dos demais devido ao seu posicionamento na tela (centralizado horizontalmente) e à sua coloração.

Metade das aplicações analisadas faz uso do recurso de *drag-and-drop*, por meio do qual é possível arrastar elementos pela tela e posicioná-los nas áreas mais adequadas. Por serem baseadas nas plataformas de programação em bloco *Scratch* e *Snap!*, as ferramentas desenvolvidas por Estevez *et al.* (2019) e Kahn *et al.* (2020) permitem a visualização e a modificação dos blocos de códigos utilizados para o processamento dos modelos.

Outras aplicações que fazem uso do recurso de *drag-and-drop* são *Teachable Machine* e a aplicação de Schultze *et al.* (2020), que permitem que o usuário faça o *upload* de arquivos salvos em seu dispositivo. A aplicação de Schultze *et al.* (2020) também utiliza o recurso de *drag-and-drop* na etapa de definição das ordens e tipos de camadas de redes neurais a serem utilizados no modelo de AM a ser desenvolvido pelo usuário.

Como forma de simplificar a visualização dos processos e permitir que o usuário foque sua atenção em detalhes específicos, metade das aplicações permite o ocultamento de recursos. Por exemplo, *TensorFlow Playground* tem, abaixo de sua interface, diversas caixas de seleção que, quando desmarcadas, desabilitam a visualização de alguns recursos da ferramenta (como a opção de alterar a taxa de aprendizado, por exemplo), tornando assim possível a realização de abordagens que revelem progressivamente os recursos da ferramenta, de forma a não sobrecarregar usuários iniciantes com muitas opções de escolha.

Um artifício semelhante pode ser encontrado na *Teachable Machine*, que, inicialmente, não mostra todos os hiperparâmetros modificáveis (como número de épocas e tamanho do lote), mas permite alterações após a abertura de um *menu* de opções avançadas.

A maioria das ferramentas utiliza o recurso de *dropdown* (ou *menu* suspenso) para a amostragem das opções que podem ser escolhidas pelo usuário, a exemplo da *GAN Lab*, na qual, após a liberação da edição de hiperparâmetros, são mostrados *menus* suspensos com as opções de hiperparâmetros modificáveis, como a taxa de aprendizado.

Outro tipo de componente muito utilizado é o *slider* (ou controle deslizante), presente na metade das aplicações. *CNN Explainer*, por exemplo, utiliza *sliders* em seu tutorial interativo, presente na mesma página do *website* da aplicação. Nessa ferramenta, por meio do arrasto horizontal do *slider*, o usuário pode visualizar os efeitos das alterações de hiperparâmetros, como, por exemplo, o impacto gerado pelo aumento ou diminuição do tamanho do *kernel* (ou matriz de núcleo) em uma tarefa de classificação

<sup>3</sup> <https://1drv.ms/f/c/47b20ac7a6225e72/EqheY-kyjOFDooS6KDoRWtcBj1W6kcBXNwpuPx6hjCmAfQ>

de imagem. Entretanto, ressalta-se que o modelo de AM treinado no qual se baseia o funcionamento da *CNN Explainer* não é afetado pelas variações de hiperparâmetros possibilitadas pelo tutorial.

Mais um artifício presente em metade das aplicações é o uso de cores para a representação de saídas em redes neurais, como é o caso da aplicação desenvolvida por Harley (2015), na qual neurônios e arestas são coloridos de acordo com a força de sua conexão, de forma que seus valores (dos mais altos e positivos aos mais baixos e negativos) são associados a tons e cores definidos com base em uma variação da paleta arco-íris.

Também foram observadas algumas outras funcionalidades presentes em menos da metade das aplicações, como o recurso de *hovering* (ato de passar o cursor do *mouse* sobre algum elemento) para a visualização de detalhes, como as fórmulas matemáticas empregadas em neurônios na aplicação de Harley (2015) e gráficos de barras para a demonstração das probabilidades de que uma amostra pertença a determinada classe, artifício utilizado pela *Teachable Machine*, por exemplo.

No Quadro 7<sup>4</sup>, são feitas caracterizações das ferramentas com relação aos seus recursos visuais.

Por fim, na quinta questão de pesquisa – **Q5: Como as ferramentas foram desenvolvidas e avaliadas?**, a maioria das publicações não fornece detalhes sobre as metodologias empregadas na avaliação das ferramentas desenvolvidas, sendo que duas delas sequer abordaram esse tema e outras três não detalharam os métodos utilizados durante as realizações de testes com usuários. Por outro lado, três publicações detalharam suas metodologias de avaliação das ferramentas, como é o caso da aplicação de Schultze *et al.* (2020), que descreve a realização de entrevistas, o desenvolvimento de protótipos de baixa e alta fidelidade e a utilização de *feedback* dos usuários para a realização de melhorias na aplicação. Outras duas publicações também informaram terem utilizado *feedback* dos usuários para melhorias de suas ferramentas, sendo uma delas a *GAN Lab*, que, apesar disso, não detalha como esse procedimento foi realizado.

A maioria das publicações não deixou claro os perfis dos usuários envolvidos nas avaliações, mas três delas informaram que suas ferramentas foram testadas tanto por especialistas quanto por iniciantes no ramo de AM. Três publicações não relataram a realização de mudanças decorrentes do recebimento do *feedback* de usuários após a realização de testes em suas respectivas ferramentas.

Uma delas é a da *CNN Explainer*, que, apesar disso, fez considerações a respeito de limitações observadas pelos usuários para a realização de mudanças no futuro. Ainda com relação ao planejamento de avaliações, tanto Schultze *et al.* (2020) quanto Kahn *et al.* (2020) também informaram haver planos para a realização de novas avaliações de suas ferramentas posteriormente às publicações de seus trabalhos.

No Quadro 8<sup>5</sup>, são feitas caracterizações das ferramentas com relação às suas avaliações.

A seleção das bases científicas pesquisadas e a pesquisa manual dos trabalhos representam duas ameaças à validade do estudo em tela. Apesar de terem sido selecionadas sete bases renomadas em pesquisas de estudos primários, outros veículos de publicações poderiam ser incluídos no estudo, permitindo, possivelmente, a

<sup>4</sup> <https://1drv.ms/f/c/47b20ac7a6225e72/EqheY-kyjOFDooS6KDoRWtcBj1W6kcBXNwpuPx6hjCmAfQ>

<sup>5</sup> <https://1drv.ms/f/c/47b20ac7a6225e72/EqheY-kyjOFDooS6KDoRWtcBj1W6kcBXNwpuPx6hjCmAfQ>

identificação de outros trabalhos relevantes. Apesar de as buscas terem sido bem planejadas e executadas, algum trabalho relacionado ao tema pode não ter sido incluído devido a alguma falha humana.

Como forma de mitigar essa última ameaça, os três autores desta pesquisa revisaram os trabalhos identificados, visando resolver possíveis divergências. Além disso, a restrição de pesquisa relativa ao enfoque apenas em ferramentas visuais *web* desenvolvidas para contexto educacional constitui uma limitação deste estudo, reduzindo o número de trabalhos selecionados.

#### 4. Considerações Finais

Como resultado deste trabalho, foram encontradas oito ferramentas *web* que fornecem interfaces visuais apropriadas para o estudo de AM no ensino superior. Apesar disso, a maioria das ferramentas também é recomendada para estudantes do ensino médio. Isso também se alinha com o fato de que essas ferramentas são acessíveis mesmo a usuários com pouca experiência no ramo de AM.

O algoritmo de AM mais comumente abordado pelas ferramentas é o das redes neurais. Já a tarefa de AM mais observada foi a de classificação de imagens. Com relação aos recursos mais utilizados para a disponibilização de interfaces gráficas, foi observado que bibliotecas de *JavaScript* são utilizadas pela maioria das ferramentas. Para a simplificação da execução de processos, constatou-se que o uso de botões é o principal recurso disponibilizado pelas ferramentas. Também se destaca que a maioria das publicações utilizadas como referências não fornece detalhes sobre as metodologias empregadas na avaliação de suas ferramentas.

Como resultado desta pesquisa, espera-se que este mapeamento sistemático possa auxiliar tanto educadores quanto estudantes a selecionarem as ferramentas mais apropriadas para os contextos e objetivos de seus estudos. Também se espera que este trabalho sirva como um incentivo para o desenvolvimento de projetos futuros que proporcionem maior variedade de ferramentas visuais *web* para o estudo de AM de formas simplificadas, visando a reduzir ainda mais a barreira de entrada representada pelo esforço cognitivo ao qual usuários com pouca experiência no ramo são submetidos.

#### Agradecimentos

Os autores agradecem à CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – pelo financiamento desta pesquisa.

#### Referências

- Carney, M. *et al.* (2020). “Teachable Machine: Approachable web-based tool for exploring machine learning classification”, In: Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems, p. 1-8.
- Estevez, J. *et al.* (2019). Using Scratch to teach undergraduate students’ skills on artificial intelligence, arXiv preprint arXiv:1904.00296.
- Goodfellow, I. *et al.* (2016). Deep learning, The Mit Press.
- Harley, A. W. (2015). “An interactive node-link visualization of convolutional neural networks”, In: Bebis, G. *et al.* Advances in Visual Computing, ISVC 2015, Lecture Notes in Computer Science, vol 9474. Springer, Cham.

- Kahng, M. *et al.* (2018). “GAN lab: Understanding complex deep generative models using interactive visual experimentation”, *IEEE Transactions on Visualization and Computer Graphics*, v. 25, n. 1, p. 310-320.
- Keele, S. *et al.* (2007). Guidelines for performing systematic literature reviews in software engineering, EBSE Technical Report.
- Kahn, K. *et al.* (2020). Deep learning programming by all, Constructionism.
- Lalitha, T. B. and Sreeja, P. S. (2021). “Recommendation system based on machine learning and deep learning in varied perspectives: A systematic review”, In: Kaiser, M. S., Xie, J., Rathore, V.S. (eds) *Information and Communication Technology for Competitive Strategies (ICTCS 2020)*, *Lecture Notes in Networks and Systems*, v. 190, Springer, Singapore.
- Mitchell, T. M. (1997). *Machine learning*, McGraw-Hill.
- Parekh, D. *et al.* (2022). “Review on autonomous vehicles: Progress, methods and challenges. *Electronics*”, v. 11, p. 2162.
- Petersen, K. *et al.* (2015). “Guidelines for conducting systematic mapping studies in software engineering: an update”, *Information and Software Technology*, v. 64, p. 1-18.
- Raschka, S. *et al.* (2020). “Machine learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence”, *Information*, v. 11, n. 4, p. 193.
- Schultze, S. *et al.* (2020). “Demystifying deep learning: Developing a learning App for beginners to gain practical experience”, In: *Proceedings of the Mensch und Computer 2020 Workshop on User-Centered Artificial Intelligence (UCAI 2020)*.
- Silva Filho, F. R. *et al.* (2023). “Uso de aprendizado de máquina em fóruns de ambientes virtuais de aprendizagem: Uma revisão sistemática de literatura”, *RENOTE*, v. 21, n. 2, p. 220–233.
- Smilkov, D. *et al.* (2017). Direct-manipulation visualization of deep networks, arXiv preprint arXiv:1708.03788.
- Wang, Z. J. *et al.* (2020). “CNN explainer: Learning convolutional neural networks with interactive visualization”, *IEEE Transactions on Visualization and Computer Graphics*, v. 27, n. 2, p. 1396-1406.
- Wangenheim, C. G. V. *et al.* (2021). “Visual tools for teaching machine learning in K-12: A ten-year systematic mapping”, *Education and Information Technologies*, v. 26, n. 5, p. 5733–5778, 2021.
- Zhang, A. *et al.* (2022). “Shifting machine learning for healthcare from development to deployment and from models to data”, *Nature Biomedical Engineering*, v. 6, p. 1330–1345.