

**VISUAL-AM: UMA FERRAMENTA VISUAL *WEB*
PARA O ESTUDO DE APRENDIZADO DE MÁQUINA**

DENIS WILLIAN DA SILVA

ORIENTADOR: PROF. DR. RODRIGO DUARTE SEABRA

COORIENTADOR: PROF. DR. LUIZ CARLOS BERTUCCI BARBOSA

Itajubá - MG
Junho/2026

VISUAL-AM: UMA FERRAMENTA VISUAL *WEB* PARA O ESTUDO DE APRENDIZADO DE MÁQUINA

DENIS WILLIAN DA SILVA

Dissertação apresentada ao Programa de Mestrado em Ciência e Tecnologia da Computação da Universidade Federal de Itajubá, como parte dos requisitos para a obtenção do título de Mestre em Ciência e Tecnologia da Computação.

Área de concentração: Matemática da Computação

Orientador: Prof. Dr. Rodrigo Duarte Seabra
Coorientador: Prof. Dr. Luiz Carlos Bertucci
Barbosa

Itajubá – MG
Junho/2026

AGRADECIMENTOS

A realização deste mestrado representou uma etapa muito importante da minha trajetória acadêmica e profissional, marcada por desafios, aprendizados e crescimento pessoal. Ao longo desse percurso, contei com o apoio de pessoas que, direta ou indiretamente, contribuíram para que este trabalho se tornasse possível.

Primeiramente, agradeço aos meus pais, pelo apoio e pela presença constante ao longo da minha caminhada. Mesmo à distância em diversos momentos, sempre estiveram ao meu lado, oferecendo suporte emocional e incentivo para que eu pudesse seguir em frente.

Não poderia deixar de agradecer também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido por meio da bolsa de estudos, o que possibilitou minha dedicação total ao mestrado.

Ao meu orientador, Prof. Dr. Rodrigo Duarte Seabra, pela atenção e pela condução cuidadosa deste trabalho. Sua contribuição foi fundamental, principalmente na organização da pesquisa, na definição dos caminhos metodológicos, na estruturação de cada etapa do estudo e no aprimoramento da escrita acadêmica, sempre disposto a colaborar com sugestões para elevar a qualidade da redação.

Ao meu coorientador, Prof. Dr. Luiz Carlos Bertucci Barbosa, pelas contribuições fundamentais para a definição e adequação do conteúdo de aprendizado de máquina abordado nesta pesquisa. Também gostaria de mencionar que, ainda durante minha graduação, sua atuação como orientador do meu trabalho de conclusão de curso foi o que me incentivou a ingressar na área de ciência de dados, por meio de recomendações, direcionamentos e sugestões de estudo que despertaram meu interesse nessa área e acabaram sendo determinantes para que eu tomasse a decisão de ingressar neste mestrado em Ciência e Tecnologia da Computação.

Aos professores integrantes da banca examinadora, Prof. Dr. Rafael de Magalhães Dias Frinhani (UNIFEI) e Prof.^a Dra. Lucia Maria Martins Giraffa (PUCRS), expresso minha gratidão pelas valiosas considerações e apontamentos

realizados tanto na qualificação quanto na defesa. Suas percepções críticas permitiram identificar pontos de melhoria essenciais, cujos refinamentos foram fundamentais para elevar o rigor científico e a qualidade final deste trabalho.

Aos amigos que conheci na minha cidade natal, Volta Redonda, que permanecem ao meu lado desde os tempos de escola, e aos amigos que conheci em Itajubá, com quem também compartilhei momentos que vão muito além da vida acadêmica. As conversas, as risadas e os momentos de descontração, principalmente em repúblicas, bares e viagens, foram essenciais para manter o equilíbrio emocional ao longo dessa jornada e certamente serão lembrados por toda a vida.

Aos alunos do curso de Engenharia de Bioprocessos da UNIFEI que participaram voluntariamente deste estudo, pela disponibilidade em dedicar seu tempo à utilização da ferramenta desenvolvida e pelo cuidado ao fornecerem *feedbacks* detalhados e construtivos. Suas contribuições foram fundamentais não apenas para a validação da pesquisa, mas também para que eu pudesse perceber, a partir de diferentes perspectivas, a relevância deste estudo, o que contribuiu para que eu me mantivesse motivado e confiante no meu trabalho.

Por fim, a todos que, de alguma forma, estiveram presentes durante essa trajetória, contribuindo para que este desafio fosse vencido. Este trabalho também é resultado do apoio, da convivência e das experiências compartilhadas ao longo desse caminho.

RESUMO

O estudo de Aprendizado de Máquina (AM) tem se mostrado um desafio significativo para iniciantes, que costumam enfrentar dificuldades ao começar seus estudos nessa área. Isso acontece porque sua compreensão normalmente requer o entendimento de algoritmos e processos complexos, além de habilidades de programação. Apesar dessas dificuldades, a tecnologia de AM tem se tornado cada vez mais presente em dispositivos e serviços cotidianos, o que torna relevante preparar os cidadãos para se tornarem usuários e criadores responsáveis de soluções inteligentes. Diante disso, há uma necessidade crescente de democratizar o estudo de AM, especialmente entre estudantes que raramente têm acesso a esse conteúdo, como discentes de cursos de graduação pouco relacionados às áreas de matemática ou de computação. Nesse contexto, esta pesquisa propõe o desenvolvimento de uma ferramenta visual *web*, denominada Visual-AM, para tornar mais acessíveis os estudos de AM por meio de navegadores *web*, oferecendo uma interface visual intuitiva para orientar iniciantes na área. Com seu desenvolvimento baseado na metodologia DSRM (*Design Science Research Methodology*), a ferramenta visa a facilitar uma transição suave entre teoria e prática, por meio de uma interface gráfica que permite aos usuários trabalhar com uma variedade de algoritmos de AM por meio de elementos visuais, como botões, caixas de seleção e controles deslizantes. Dessa forma, objetiva-se proporcionar uma experiência interativa, na qual o usuário pode manipular modelos de AM, visualizar os efeitos de suas escolhas em tempo real e comparar abordagens. Entre as opções de conteúdo oferecidas pela ferramenta, estão introduções teóricas sobre AM e atividades práticas de classificação, regressão, clusterização e redução de dimensionalidade, além de *quizzes* para testar os conhecimentos do usuário. A Visual-AM foi avaliada por graduandos voluntários matriculados no curso de Engenharia de Bioprocessos da UNIFEI em um estudo empírico com questionários mistos. Os resultados indicaram ótima aceitação e eficácia como apoio didático ao estudo de AM, considerando os construtos “Facilidade de Uso”, “Fluidez Informacional”, “Engajamento”, “Sensação de Progresso” e “Contribuição dos Recursos Visuais”.

Palavras-chave: Ferramenta Visual *Web*; Aprendizado de Máquina; Visual-AM.

ABSTRACT

The study of Machine Learning (ML) has proven to be a significant challenge for beginners, who often face difficulties when starting their studies in this field. This is because mastering it typically requires an understanding of complex algorithms and processes, as well as programming skills. Despite these difficulties, ML technology has become increasingly prevalent in everyday devices and services, making it essential to prepare citizens to become responsible users and creators of intelligent solutions. Given this, there is a growing need to democratize the study of ML, especially among students who rarely have access to this content, such as those in undergraduate programs not closely related to mathematics or computer science. This research thus proposes developing a web-based visual tool, called Visual-AM, to make ML studies more accessible via web browsers, offering an intuitive visual interface to guide beginners in the field. Developed based on the DSRM (Design Science Research Methodology), the tool aims to facilitate a smooth transition between theory and practice through a graphical interface that allows users to work with a variety of ML algorithms using visual elements such as buttons, checkboxes, and sliders. The goal is to provide an interactive experience in which users can manipulate AM models, visualize the effects of their choices in real time, and compare different approaches. The content options offered by the tool include theoretical introductions to AM, practical exercises in classification, regression, clustering, and dimensionality reduction, and quizzes to test users' knowledge. Visual-AM was evaluated by volunteer undergraduate students enrolled in the Bioprocess Engineering program at UNIFEI in an empirical study using mixed-methods questionnaires. The results indicated excellent acceptance and effectiveness as a teaching aid for the study of AM, across the constructs "Ease of Use," "Information Flow," "Engagement," "Sense of Progress," and "Contribution of Visual Resources."

Keywords: Web Visual Tool; Machine Learning; Visual-AM.

LISTA DE FIGURAS

Figura 1. Esquema simplificado de previsões com AM. Fonte: Tradução de SARKER (2021).	23
Figura 2. Representação de uma rede neural artificial. Fonte: Tradução de KHALEEL; AHMED; ALSHARIF (2023).	24
Figura 3. Relação entre IA, AM e DL. Fonte: Tradução de KHALEEL; AHMED; ALSHARIF (2023).	25
Figura 4. Exemplo de classificação por aprendizado supervisionado. Fonte: Adaptação de BALADRAM <i>et al.</i> (2020).	27
Figura 5. Reconhecimento facial por meio de um algoritmo de aprendizado não supervisionado. Fonte: Adaptação de TSENG <i>et al.</i> (2020).	28
Figura 6. Casos de <i>underfitting</i> , ajuste equilibrado e <i>overfitting</i> . Fonte: O autor.	34
Figura 7. Validação cruzada <i>k-fold</i> . Fonte: O autor.	36
Figura 8. Exemplo de curva ROC. Fonte: O autor.	40
Figura 9. Anos de lançamento das publicações utilizadas como referências. Fonte: DA SILVA; BARBOSA; SEABRA (2024).	47
Figura 10. Fluxograma representativo da aplicação da DSRM no desenvolvimento da Visual-AM. Fonte: O autor.	57
Figura 11. Menu lateral e página de introdução. Fonte: O autor.	59
Figura 12. Arquitetura simplificada da Visual-AM. Fonte: O autor.	61
Figura 13. Demonstração de elementos visuais e interativos na página inicial. Fonte: O autor.	64
Figura 14. Página inicial da Visual-AM. Fonte: O autor.	71
Figura 15. Tópico de introdução da Visual-AM. Fonte: O autor.	72
Figura 16. Tópico “Próximos passos: mãos à obra!”. Fonte: O autor.	73
Figura 17. Divisão dos dados em conjuntos de treino e de teste. Fonte: O autor.	74
Figura 18. Escolha dos algoritmos de classificação. Fonte: O autor.	75
Figura 19. Configurações de treinamento no tópico de classificação. Fonte: O autor.	75
Figura 20. Escolha dos hiperparâmetros antes da busca em grade. Fonte: O autor.	76
Figura 21. Predição de classe com novos dados. Fonte: O autor.	77
Figura 22. Seleção de configurações para o treinamento de algoritmos de regressão. Fonte: O autor.	78
Figura 23. Gráfico de superfície de resposta. Fonte: O autor.	79
Figura 24. Exemplo de gráfico de valores previstos versus valores reais. Fonte: O autor.	80
Figura 25. Pergunta do tópico “Quiz sobre aprendizado supervisionado”. Fonte: O autor.	81
Figura 26. Definição dos hiperparâmetros de um algoritmo de clusterização. Fonte: O autor.	82
Figura 27. Agrupamentos formados por meio de um dos algoritmos de clusterização. Fonte: O autor.	83
Figura 28. Formação do primeiro componente principal. Fonte: O autor.	85
Figura 29. Formação de outros componentes principais. Fonte: O autor.	86
Figura 30. Formação de outros componentes principais. Fonte: O autor.	87

Figura 31. <i>Biplot</i> de uma combinação de componentes principais. Fonte: O autor.....	87
Figura 32. Reconstrução dos dados. Fonte: O autor.....	88
Figura 33. Quiz de aprendizado não supervisionado. Fonte: O autor.....	89
Figura 34. Distribuição de gênero dos participantes. Fonte: O autor.....	97
Figura 35. Condições de acesso à internet. Fonte: O autor.....	98
Figura 36. Dispositivos que se conectam à internet. Fonte: O autor.....	99
Figura 37. Contato prévio com ferramentas visuais para estudo de AM. Fonte: O autor.....	99
Figura 38. Níveis prévios de conhecimento em AM. Fonte: O autor.....	100
Figura 39. Utilização da internet para estudos. Fonte: O autor.....	100
Figura 40. Opiniões sobre a oportunidade de utilizar uma ferramenta visual <i>web</i> gratuitamente. Fonte: O autor.....	101
Figura 41. Resumo das questões e respostas ao Questionário de Identificação de Perfil. Fonte: O autor.....	102
Figura 42. Compreensibilidade e facilidade de manuseio. Fonte: O autor.....	103
Figura 43. Interesse despertado por conteúdos de AM. Fonte: O autor.....	104
Figura 44. Entendimento de conceitos de AM. Fonte: O autor.....	105
Figura 45. Autoconfiança ao utilizar a Visual-AM. Fonte: O autor.....	106
Figura 46. Expectativas de reaproveitar o conhecimento. Fonte: O autor.....	107
Figura 47. Aprofundamento de conhecimentos de AM. Fonte: O autor.....	108
Figura 48. Opiniões sobre os recursos visuais. Fonte: O autor.....	109
Figura 49. Recursos visuais para facilitação dos estudos. Fonte: O autor.....	110
Figura 50. Sobrecarga cognitiva enfrentada pelos participantes. Fonte: O autor.....	111
Figura 51. Sobrecarga enfrentada pelos participantes. Fonte: O autor.....	112
Figura 52. Adequação da apresentação e do detalhamento do conteúdo. Fonte: O autor.....	113
Figura 53. Irrelevância do conteúdo. Fonte: O autor.....	114
Figura 54. Repetição de informações. Fonte: O autor.....	115
Figura 55. Dispositivos utilizados pelos participantes para acessar a Visual-AM. Fonte: O autor.....	116
Figura 56. Propensão a utilizar a ferramenta novamente. Fonte: O autor.....	116
Figura 57. Interesse por ferramentas similares em outras disciplinas. Fonte: O autor.....	117
Figura 58. Intenção de fazer comentários sobre a ferramenta. Fonte: O autor.....	118
Figura 59. Possibilidades de melhorias. Fonte: O autor.....	120
Figura 60. Resumo das questões e respostas ao Questionário de Reação ao Uso e Aceitação da Ferramenta. Fonte: O autor.....	121
Figura 61. Representação gráfica das dimensões avaliativas. Fonte: O autor.....	132
Figura 62. Diagrama de atividades UML do tópico de classificação (parte 1 de 3). Fonte: O autor.....	171
Figura 63. Diagrama de atividades UML do tópico de classificação (parte 2 de 3). Fonte: O autor.....	172
Figura 64. Diagrama de atividades UML do tópico de classificação (parte 3 de 3). Fonte: O autor.....	173
Figura 65. Diagrama de atividades UML do tópico de regressão (parte 1 de 3). Fonte: O autor.....	174
Figura 66. Diagrama de atividades UML do tópico de regressão (Parte 2 de 3). Fonte: O autor.....	175

Figura 67. Diagrama de atividades UML do tópico de regressão (parte 3 de 3). Fonte: O autor.....	176
Figura 68. Diagrama de atividades UML do tópico de clusterização. Fonte: O autor.....	177
Figura 69. Diagrama de atividades UML do tópico de redução de dimensionalidade. Fonte: O autor.....	178

LISTA DE QUADROS

Quadro 1. Métricas de classificação binária. Fonte: YILMAZ <i>et al.</i> (2020).....	38
Quadro 2. Exemplo de matriz de confusão. Fonte: Adaptação de HERRERO; ZORRILLA (2022) e HEYDARIAN <i>et al.</i> (2022).....	39
Quadro 3. Métricas para regressão. Fonte: AYKO; KESER (2021).....	42
Quadro 4. Descrição das ferramentas. Fonte: DA SILVA; BARBOSA; SEABRA. (2024).....	49
Quadro 5. Outros recursos visuais utilizados. Fonte: O autor.....	63
Quadro 6. Resumo dos tópicos disponíveis na ferramenta Visual-AM. Fonte: O autor.....	65
Quadro 7. Desafios, procedimentos pedagógicos e exemplos de funcionalidades da Visual-AM (continua). Fonte: O autor.....	66
Quadro 8. Apresentação dos datasets incorporados à Visual-AM (continua). Fonte: O autor..	68
Quadro 9. Codificação das respostas das Questões 2.09, 2.12 e 2.13. Fonte: O autor.....	122
Quadro 10. Codificação das respostas da Questão 2.07. Fonte: O autor.....	123
Quadro 11. Codificação das respostas às Questões 2.01 a 2.08, 2.10, 2.11, 2.15 e 2.16. Fonte: O autor.....	123
Quadro 12. Codificação das respostas às Questões 1.1, 1.2 e 1.4. Fonte: O autor.....	124
Quadro 13. Codificação das respostas das Questões 1.5 e 1.6. Fonte: O autor.....	124
Quadro 14. Correlações entre as questões. Fonte: O autor.....	126
Quadro 15. Correlações significativas entre questões (continua). Fonte: O autor.....	127
Quadro 16. Médias de respostas por participante, por dimensão. Fonte: O autor.....	130
Quadro 17. Síntese dos resultados em cada dimensão avaliativa. Fonte: O autor.....	131

LISTA DE ABREVIATURAS E SIGLAS

AM – Aprendizado de Máquina
API – *Application Programming Interface*
CNN – *Convolutional Neural Network*
GAN – *Generative Adversarial Network*
GPU – *Graphics Processing Units*
DL – *Deep Learning*
DSRM – *Design Science Research Methodology*
GIF – *Graphics Interchange Format*
GUI – *Graphic User Interfaces*
IA – Inteligência Artificial
MAE – *Mean Absolute Error*
MAPE – *Mean Absolute Percentage Error*
ML – *Machine Learning*
NIDDK – *National Institute of Diabetes and Digestive and Kidney Diseases*
OvA – *One-versus-All*
OvO – *One-versus-One*
PCA – *Principal Component Analysis*
PCK – *Pedagogical Content Knowledge*
REA – Recurso Educacional Aberto
RMSE – *Root Mean Squared Error*
RNA – Redes Neurais Artificiais
ROC – *Receiver Operating Characteristics*
SVM – *Support Vector Machine*
TL – *Transfer Learning*
TPU – *Tensor Processing Unit*
UNIFEI – Universidade Federal de Itajubá

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	13
1.1 Justificativa.....	16
1.2 Objetivos.....	18
1.3 Organização do trabalho.....	19
CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA.....	21
2.1 Inteligência artificial.....	21
2.2 Aprendizado de máquina.....	22
2.3 Aprendizado profundo.....	24
2.4 Tipos de aprendizado de máquina.....	26
2.4.1 Aprendizado supervisionado.....	26
2.4.2 Aprendizado não supervisionado.....	27
2.5 Etapas do processamento de modelos de aprendizado supervisionado.....	30
2.5.1 Etapa de análise.....	30
2.5.2 Etapa de treinamento.....	31
2.5.3 Etapa de teste.....	32
2.5.4 Etapa de aplicação.....	33
2.6 Otimização de hiperparâmetros.....	34
2.7 Métricas para avaliação de modelos de AM.....	37
2.7.1 Métricas para classificação.....	37
2.7.2 Métricas para regressão.....	41
2.8 Ferramentas e recursos para AM.....	42
2.8.1 Linguagem <i>Python</i>	43
2.8.2 Ferramentas interativas para estudo e prática de AM.....	44
2.8.3 Ferramentas visuais <i>web</i>	45
2.9 Estado da arte.....	46
2.10 Estudo de Aprendizado de Máquina.....	50
2.10.1 Desafios para discentes.....	50
2.10.2 Desafios para docentes.....	51
2.10.3 Democratização do AM.....	52
CAPÍTULO 3 - MÉTODO.....	54
3.1 Aplicação da DSRM à pesquisa.....	55
3.2 Desenvolvimento da ferramenta Visual-AM.....	58
3.2.1 Descrição da ferramenta.....	58
3.2.2 Implementação.....	60
3.2.3 Recursos visuais utilizados.....	62
3.2.4 Funcionalidades da ferramenta.....	62
3.2.5 Relação entre os desafios e as soluções pedagógicas encontradas.....	64
3.2.6 <i>Datasets</i> disponibilizados.....	67
3.3 Tópicos de estudo presentes na ferramenta.....	70
3.3.1 Página inicial.....	71

3.3.2 Introdução: conceitos básicos.....	71
3.3.3 Próximos passos: mãos à obra!.....	72
3.3.4 Aprendizado supervisionado: classificação.....	73
3.3.5 Aprendizado supervisionado: regressão.....	77
3.3.6 Quiz sobre aprendizado supervisionado.....	81
3.3.7 Aprendizado não supervisionado: clusterização.....	82
3.3.8 Aprendizado não supervisionado: redução de dimensionalidade.....	84
3.3.9 Quiz sobre aprendizado não supervisionado.....	88
CAPÍTULO 4 - AVALIAÇÃO DA FERRAMENTA.....	90
4.1 Metodologia de avaliação.....	90
4.2 Caráter da pesquisa.....	93
4.3 Execução da pesquisa.....	94
CAPÍTULO 5 - RESULTADOS.....	96
5.1 Análise descritiva das respostas aos questionários.....	96
5.1.1 Perfil dos participantes.....	96
5.1.2 Reação ao uso e aceitação da ferramenta.....	103
5.2 Quantificação de respostas.....	122
5.2.1 Codificação de respostas ao Questionário de Reação ao Uso e Aceitação da Ferramenta.....	122
5.2.2 Codificação de respostas ao Questionário de Identificação do Perfil.....	123
5.3 Correlações.....	125
5.4 Resultados por dimensões avaliativas.....	128
5.4.1 Organização das questões em dimensões.....	129
5.4.2 Quantificação dos resultados por dimensões.....	130
5.5 Discussão.....	133
CAPÍTULO 6 - CONSIDERAÇÕES FINAIS.....	136
6.1 Conclusão.....	136
6.2 Limitações.....	138
6.3 Trabalhos futuros.....	138
REFERÊNCIAS.....	140
APÊNDICE A: EMENTA DA DISCIPLINA DE INTRODUÇÃO À CIÊNCIA DE DADOS....	156
APÊNDICE B: TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO.....	160
APÊNDICE C: QUESTIONÁRIO DE IDENTIFICAÇÃO DO PERFIL DO RESPONDENTE.....	161
APÊNDICE D: QUESTIONÁRIO DE REAÇÃO AO USO E ACEITAÇÃO DA FERRAMENTA.....	164
APÊNDICE E: DIAGRAMAS UML.....	171

Capítulo 1

INTRODUÇÃO

Esta pesquisa visa contribuir para a proposição de uma ferramenta *web* interativa para o estudo de aprendizado de máquina (AM), de modo a tornar mais intuitivo o processo de exploração de fundamentos inerentes a essa área da ciência.

O AM (também chamado de ML, sigla do termo da língua inglesa *Machine Learning*) é um subcampo da inteligência artificial (IA) que visa desenvolver algoritmos capazes de aprender padrões e relações a partir de dados, embora não sejam explicitamente programados para essa finalidade (MALIK *et al.*, 2023; MURRAY *et al.*, 2023). Essa abordagem permite que os modelos de AM descubram conexões entre os dados e tomem decisões com base em associações recém-descobertas, sem depender de declarações do tipo “se-então” inseridas por um usuário. Em vez disso, os modelos extraem conhecimento diretamente a partir dos dados de entrada, sem instruções explícitas sobre como abordar um problema (KINGSMORE *et al.*, 2021).

Algoritmos de AM demonstram alta aplicabilidade em diversas áreas, especialmente em tarefas que envolvem dados de alta dimensionalidade. Dessa forma, auxiliam na tomada de decisões confiáveis e reproduzíveis em campos como o processamento de linguagem natural e o reconhecimento de imagens, além de sua aplicabilidade em outros domínios, como finanças, educação e esportes (JANIESCH; ZSCHECH; HEINRICH, 2021; KIANI *et al.*, 2020). O AM está presente em diversos dispositivos e serviços específicos que vêm se tornando parte da vida humana, como é o caso de veículos autônomos e de diagnósticos médicos (MOHSENI *et al.*, 2020).

Devido aos avanços da IA, diversos países adotaram a estratégia de exigir que mais pessoas busquem uma carreira nesse campo para estimular a competitividade (GRESSE VON WANGENHEIM *et al.*, 2021). O Brasil, entretanto,

apresenta escassez de investimentos efetivos em IA, o que resulta em um número reduzido de profissionais com a formação necessária na área. Outras consequências negativas são a fuga de profissionais qualificados para o mercado externo, atraídos por melhores remunerações, e a perda de competitividade em relação ao cenário mundial (ACADEMIA BRASILEIRA DE CIÊNCIAS, 2024). Buscando modificar esse quadro e considerando a crescente, embora relativamente pequena, contribuição brasileira à produção científica mundial na temática de IA, as instituições públicas de ensino e pesquisa, responsáveis pela grande maioria das publicações brasileiras sobre o tema, ocupam posição estratégica no processo de desenvolvimento científico e tecnológico do país (GROENNER *et al.*, 2022).

Contudo, a adesão a essa tecnologia pode não ser tão simples, e estudantes costumam ter dificuldades ao iniciarem seus estudos em AM, pois o processo de construção de modelos e aplicações nessa área não é trivial e pode requerer o entendimento de algoritmos e processos complexos, além de exigir o conhecimento de uma crescente gama de arquiteturas, frameworks e de certo nível de habilidades de programação (GRESSE VON WANGENHEIM *et al.*, 2021).

Para evitar o desestímulo de estudantes iniciantes na área, pode-se considerar a constatação de Wang e Durrant (2022) de que o uso de aplicações de *software* acessíveis por meio de navegadores *web* pode ser vantajoso, já que essas aplicações estão disponíveis nos principais sistemas operacionais. Além disso, elas permitem a execução de aplicações na maioria dos dispositivos modernos e eliminam a necessidade de *downloads* e instalações.

Nesse sentido, a computação em nuvem também pode atuar como uma facilitadora estratégica, pois a possibilidade de executar aplicações de *software* em servidores remotos reduz as limitações impostas pelo *hardware* local do usuário final. Isso permite que estudantes com diferentes níveis de recursos tecnológicos utilizem ferramentas complexas a partir de qualquer dispositivo conectado à rede, transcendendo barreiras socioeconômicas ao eliminar a necessidade de adquirir infraestrutura física onerosa (MALTA *et al.*, 2025; SULTAN, 2013).

Outro fator que pode ser considerado um ponto crucial nas decisões dos usuários quanto ao uso de um sistema é as interfaces gráficas de usuário (GUIs, sigla do termo em inglês *Graphic User Interfaces*) (PAIVA *et al.*, 2007), que podem ser consideradas uma fronteira onde ocorre a interação entre o computador e o ser humano (PODRZAJ, 2019). Em geral, as GUIs contêm elementos como gráficos, botões, caixas de seleção e controles deslizantes, além de dicas que orientam os usuários no *design* (JIANG *et al.*, 2024). Isso posto, para que os usuários possam compreender, analisar e compartilhar percepções sobre sistemas de AM, uma quantidade substancial de pesquisas passou a ser dedicada à criação de interfaces de AM (BÄUERLE *et al.*, 2022).

Quanto à utilização de linguagens de programação e às formas de implementação de aplicações de AM, considera-se a existência de duas categorias de linguagens: visuais e textuais (LU; FAN, 2023). Em linguagens textuais, os programas consistem em coleções de arquivos de código-fonte, cujos recursos são codificados em texto e contêm informações sintáticas e semânticas, que são analisados por compiladores e interpretadores (ORTIN *et al.*, 2023). Já as linguagens visuais de programação são alternativas mais acessíveis para não programadores. Sua abordagem tipicamente consiste em representações gráficas de um problema por meio de blocos (ou nós) aos quais são fornecidos parâmetros de entrada, que podem ser processados por diferentes métodos. Ademais, é possível conectar esses blocos entre si por arestas, que transmitem seus resultados de saída (KORUS; SALAMAK; JASIŃSKI, 2021).

Embora não exista uma única linguagem que possa ser considerada a melhor opção para todos os cenários (FARSHIDI *et al.*, 2021), a linguagem textual *Python* é frequentemente utilizada como meio de desenvolvimento de aplicações e de ensino de IA, devido à sua riqueza de recursos e à gama de plataformas que ela suporta (LU; FAN, 2023).

A partir dos argumentos expostos nesta introdução, surgiu a motivação para o desenvolvimento de uma aplicação acessível por meio de navegadores *web*, que

forneça uma interface visual intuitiva para a iniciação de aprendizes nos estudos de AM, sendo esta sua principal contribuição.

1.1 Justificativa

Como a tecnologia do AM vem se tornando presente em muitos dispositivos e serviços que já fazem parte do cotidiano, é importante preparar os cidadãos para se tornarem usuários e criadores responsáveis por soluções inteligentes (GRESSE VON WANGENHEIM *et al.*, 2021). Devido à ascensão de produtos baseados em AM (como o *ChatGPT*, por exemplo) e ao impacto causado por eles na sociedade, espera-se que não só as indústrias passem a utilizar AM em processos, mas também que instituições de ensino superior passem a incorporar aspectos de AM em seus currículos para formar as próximas gerações de engenheiros e estudantes de diversas outras áreas, como ciência da computação, física, medicina, biologia, ecologia e políticas públicas (SCHULZ *et al.*, 2023). Isso vai de encontro à necessidade de popularizar o AM, ciência à qual alunos de graduação fora das áreas de matemática, de ciência da computação ou de engenharia da computação raramente eram introduzidos (WAY *et al.*, 2017).

Discussões recentes também têm enfatizado a importância de promover o letramento em IA (*AI literacy*), entendido como um conjunto de competências que permite a um indivíduo compreender, avaliar criticamente e interagir com tecnologias baseadas em IA (LONG; MAGERKO, 2020). Em consonância com essa perspectiva, estratégias educacionais voltadas à introdução de conceitos de IA para estudantes não especialistas na área vêm sendo exploradas no ensino superior, a exemplo do estudo de Laupichler *et al.* (2022), no qual estudantes de medicina participaram de uma intervenção educacional sobre o uso de IA em imagens médicas, visando ampliar sua compreensão acerca dessa tecnologia. Para isso, foi empregada uma dinâmica de sala de aula invertida, abordagem na qual atividades realizadas fora do

ambiente de sala de aula podem contribuir para apoiar o estudo dos conteúdos e estimular o engajamento dos estudantes (DIWANJI; HINKELMANN; WITSCHERL, 2018).

Entretanto, como o entendimento e a implementação de algoritmos de AM podem ser difíceis e complexos para iniciantes na área, essa tecnologia requer certas habilidades e esforços por parte dos estudantes (ÇAĞLAYAN, 2019). Parte disso se deve ao fato de que o desenvolvimento de aplicações de AM pode envolver diversas tarefas, como a aquisição de conjuntos de dados, a seleção de um algoritmo de aprendizado adequado e a avaliação do desempenho do modelo treinado (GRESSE VON WANGENHEIM *et al.*, 2021). Além disso, o rápido crescimento do número de algoritmos de AM disponíveis pode tornar difícil a seleção do algoritmo mais adequado para um conjunto de dados (KIANI *et al.*, 2020). Em consequência dos fatores apresentados, a aprendizagem dessa tecnologia pode ser intimidante para novos usuários (RAFF; AURELIO; NICHOLAS, 2019).

Com vistas a popularizar o AM, é desejável reduzir o esforço cognitivo a que os aprendizes iniciantes nesta área são submetidos, para que possam focar-se mais na lógica da resolução do problema em questão (GRESSE VON WANGENHEIM *et al.*, 2021). Considera-se também que o uso de aplicações de *software* visuais no ensino de AM pode aumentar o nível de interesse dos estudantes iniciantes na área, como sugerem os resultados do estudo de Çağlayan (2019).

A pesquisa realizada por Gresse Von Wangenheim *et al.* (2021) demonstra que algumas ferramentas visuais propícias ao estudo de AM já foram desenvolvidas para alunos dos ensinos fundamental e médio. Embora parte dessas ferramentas também possa ser utilizada em contextos introdutórios do ensino superior, como o Teachable Machine (CARNEY *et al.*, 2020), o estudo de mapeamento sistemático realizado por da Silva, Barbosa e Seabra (2024) apontou escassez de ferramentas visuais *web* adequadas ao estudo de AM no ensino superior no contexto investigado nesta pesquisa.

Com base nas considerações expostas, este trabalho visa desenvolver uma ferramenta visual e interativa que forneça uma interface gráfica para uma gama de algoritmos de AM, permitindo uma transição não intimidante entre a teoria e a prática e, por conseguinte, facilitando a iniciação de estudantes do ensino superior no estudo de AM. A proposta da ferramenta não consiste em substituir o aprofundamento em técnicas de programação, matemática ou no desenvolvimento tradicional de aplicações de AM, mas em atuar como recurso introdutório e complementar, voltado à redução das barreiras iniciais enfrentadas por estudantes.

1.2 Objetivos

O objetivo desta pesquisa foi desenvolver uma ferramenta visual *web* para o estudo de AM no ensino superior. Para isso, foram realizadas pesquisas em diversas bases literárias a fim de levantar informações sobre ferramentas visuais para o estudo de IA e AM já existentes. A condução desta pesquisa seguiu a metodologia DSRM (sigla do termo da língua inglesa *Design Science Research Methodology*) (FREITAS JUNIOR *et al.*, 2017; PEFFERS *et al.*, 2007), que consiste nas seguintes etapas: identificação do problema e motivação (I), definição dos objetivos (II), *design* e desenvolvimento (III), demonstração (IV), avaliação (V) e comunicação dos resultados (VI).

Fundamentados nesta premissa, os objetivos específicos da pesquisa, pautados pela DSRM, foram:

- I: Realizar uma investigação do estado da arte no que tange à utilização de ferramentas visuais para o estudo de AM;
- II: Definir quais áreas do ramo de AM deveriam ser estrategicamente abordadas para a consecução dos objetivos deste trabalho;

-
- III: Desenvolver uma ferramenta computacional visual e interativa para o estudo de AM, alinhando-a a procedimentos pedagógicos que apoiem a superação de desafios comuns enfrentados por discentes e docentes;
 - IV: Permitir que discentes utilizem a ferramenta desenvolvida para a realização de testes;
 - V: Avaliar, por meio de formulários, a possível contribuição da ferramenta proposta no estudo de AM, segundo a perspectiva discente;
 - VI: Disponibilizar a ferramenta e publicar este estudo.

Cabe destacar que a avaliação realizada no passo V concentrou-se na percepção discente acerca de construtos relacionados à utilização e aceitação da ferramenta por meio de aspectos subjetivos — como a autopercepção de progresso nos estudos, a mitigação da sobrecarga cognitiva, a facilidade de utilização da ferramenta, a contribuição dos recursos visuais para os estudos e a capacidade da ferramenta de estimular o engajamento do usuário —, não contemplando mensurações objetivas de desempenho ou ganho de aprendizagem.

1.3 Organização do trabalho

Este trabalho encontra-se estruturado em seis capítulos, a saber:

- O Capítulo 1 apresenta a introdução e a justificativa do desenvolvimento da pesquisa, expondo seus objetivos e a forma como o trabalho está organizado.
- O Capítulo 2 destina-se à revisão bibliográfica sobre AM. Também são discutidos as ferramentas e os recursos utilizados na área, como a linguagem *Python* e o *Jupyter Notebook*, bem como ferramentas *web* visuais. O capítulo também apresenta o estado da arte no uso de ferramentas visuais no estudo de AM. Por fim, são discutidas estratégias

para democratizar o AM, bem como os desafios enfrentados por discentes e docentes nesse contexto.

- O Capítulo 3 apresenta a ferramenta visual *web* desenvolvida, descrevendo os recursos visuais e os procedimentos pedagógicos que serviram de base para sua implementação. Além disso, são apresentados os *datasets* disponibilizados na ferramenta e detalhadas as atividades de AM que fundamentam os estudos.
- O Capítulo 4 descreve o caráter da pesquisa e os métodos empregados para identificar os perfis dos participantes e avaliar a ferramenta, considerando aspectos como a facilidade de uso e a compreensão dos temas abordados.
- O Capítulo 5 apresenta os resultados obtidos com a aplicação dos questionários de avaliação da ferramenta. Inicialmente, são descritas as respostas individuais dos participantes e é realizada a quantificação delas. Em seguida, os itens do questionário são organizados em dimensões avaliativas, permitindo a síntese dos resultados e a análise exploratória das respostas.
- O Capítulo 6 encerra o trabalho com as conclusões da pesquisa e as sugestões para estudos futuros.

Por fim, apresentam-se as referências bibliográficas que fundamentam o embasamento teórico desta pesquisa.

Capítulo 2

REVISÃO BIBLIOGRÁFICA

Neste capítulo, serão descritos aspectos importantes do aprendizado de máquina, incluindo algumas de suas subcategorias, os tipos de AM, as etapas do processamento de modelos, os conceitos relacionados à otimização de hiperparâmetros e as técnicas de avaliação de modelos. Também serão abordados recursos para o estudo de AM relacionados à linguagem *Python* e o estado da arte em ferramentas visuais *web* voltadas ao estudo de AM no ensino superior. Por fim, serão apresentados alguns desafios enfrentados por discentes e docentes dessa área e discutidos aspectos relacionados à democratização do AM.

2.1 Inteligência artificial

O termo inteligência artificial refere-se à capacidade de uma máquina de realizar operações que, normalmente, requerem o intelecto humano, como a compreensão de linguagem natural, o reconhecimento de fala e a tomada de decisões (SOORI *et al.*, 2023). Por conseguinte, essa técnica permite que um computador imite comportamentos humanos (BALYEN; PETO, 2019).

Com a ascensão da ciência de dados desde 2010, também se ampliou a capacidade da IA de identificar padrões cientificamente relevantes e fornecer orientações valiosas a partir de grandes conjuntos de dados. Dessa forma, a IA tem se tornado cada vez mais essencial em diversas disciplinas científicas, podendo auxiliar em tarefas como a integração de dados, o refinamento de medições e a

orientação de experimentos, além da criação de modelos para a resolução de problemas em diferentes domínios do conhecimento (WANG *et al.*, 2023).

Nos últimos anos, a IA também tem ganhado destaque em ramos como a engenharia, por exemplo, por meio da transformação do *design* de produtos e de processos. Técnicas de IA, como o aprendizado de máquina e o aprendizado profundo, são amplamente utilizadas para otimizar operações e reduzir custos, facilitando, por exemplo, a gestão de processos complexos (KHALEEL; AHMED; ALSHARIF, 2023).

2.2 Aprendizado de máquina

Proposto por Arthur Samuel em 1959, o termo Aprendizado de Máquina descreve um subcampo da IA que utiliza técnicas estatísticas para capacitar sistemas a aprender e a melhorar automaticamente com base na experiência, sem que sejam programados explicitamente para isso (LOFTUS *et al.*, 2020; MATHUR *et al.*, 2020). Com base nisso, muitos desenvolvedores consideram que utilizar exemplos de comportamentos de entrada-saída desejados para treinar um sistema pode ser mais simples do que programá-lo manualmente em diversas tarefas (KARTHIKEYAN; PRIYAKUMAR, 2022).

O processo de aprendizado ocorre por meio do uso de dados para o treinamento de máquinas, de modo que diferentes algoritmos podem ser utilizados para processá-los (JAKHAR; KAUR, 2020). Por meio de técnicas de AM, é possível extrair padrões complexos e ocultos a partir de conjuntos de dados, bem como expressá-los como objetos matemáticos (KARTHIKEYAN; PRIYAKUMAR, 2022). Dessa forma, os modelos matemáticos construídos a partir do processamento de dados com algoritmos de AM podem auxiliar na previsão ou na identificação de padrões, por exemplo. Além disso, esses modelos permitem executar tarefas de

forma mais rápida e precisa do que um intérprete humano em algumas situações (AUGER *et al.*, 2021).

A Figura 1 ilustra, de forma simplificada, como algoritmos de AM podem ser utilizados em conjuntos de dados para realizar previsões sobre novos dados não vistos antes.




Figura 1. Esquema simplificado de previsões com AM. Fonte: Tradução de SARKER (2021).

Apesar de ter grande utilidade em problemas de diferentes domínios da vida real, o uso de técnicas de AM envolve alguns obstáculos, como a necessidade de compreender conceitos técnicos de áreas como a matemática e a programação (ABD RAHMAN *et al.*, 2021). Ademais, é recomendável compreender os princípios básicos dos algoritmos a serem utilizados, sendo a seleção do algoritmo mais apropriado sempre dependente da natureza específica da tarefa em questão (AUGER *et al.*, 2021).

Considerando que o termo “aprendizado de máquina” também pode incluir a subcategoria de aprendizado profundo, é comum utilizar o termo “aprendizado de máquina clássico” para se referir às abordagens não baseadas em aprendizado profundo (RASCHKA; PATTERSON; NOLET, 2020).

2.3 Aprendizado profundo

O aprendizado profundo (ou DL, sigla derivada do termo em inglês *deep learning*) é uma subcategoria do AM cuja adoção desencadeou o desenvolvimento de diversas aplicações de IA (KATSUMATA, 2023; RASCHKA; PATTERSON; NOLET, 2020). Esse tipo de AM baseia-se em redes neurais, arquiteturas inspiradas nos sistemas nervosos biológicos dos cérebros de animais (HSIEH *et al.*, 2023). Com base nisso, as chamadas redes neurais artificiais (RNA) simulam a estrutura e os relacionamentos entre componentes de sistemas nervosos vivos, como axônios, dendritos e neurônios (KHALEEL; AHMED; ALSHARIF, 2023).

Os neurônios das RNAs consistem em nós, organizados em camadas, de modo que a saída de uma camada pode servir de entrada para a próxima (WONG; DORNBERGER; HANNE, 2024). A utilização de um modelo matemático baseado nesses sistemas visa à resolução de problemas complexos e mal definidos por meio da otimização dos pesos das conexões entre neurônios interconectados, sendo esse processo a base do aprendizado profundo (KHALEEL; AHMED; ALSHARIF, 2023). As RNAs geralmente são compostas por três tipos de camadas: de entrada, ocultas e de saída (WONG; DORNBERGER; HANNE, 2024), como mostrado na Figura 2.




Figura 2. Representação de uma rede neural artificial. Fonte: Tradução de KHALEEL; AHMED; ALSHARIF (2023).

Por meio da introdução de uma estrutura multicamada nas camadas ocultas de uma rede neural, o aprendizado profundo permite captar relações mais complexas entre variáveis do que as obtidas por técnicas de AM clássico (KATSUMATA, 2023; RASCHKA; PATTERSON; NOLET, 2020). Dessa forma, obtém-se o processamento de diferentes tipos de dados de entrada (como textos, vídeos e sons) e a resolução de problemas complexos, como diagnósticos médicos, análise de fraudes e reconhecimento facial (FRI; ELOUAHBI, 2020).

Sendo o aprendizado profundo uma subdivisão do AM, que, por sua vez, é uma subdivisão da IA, a relação entre essas três áreas de conhecimento pode ser ilustrada na Figura 3.




Figura 3. Relação entre IA, AM e DL. Fonte: Tradução de KHALEEL; AHMED; ALSHARIF (2023).

Diferentemente do AM clássico, as abordagens de aprendizado profundo podem oferecer uma configuração de aprendizado de ponta a ponta, na qual as características são aprendidas diretamente a partir dos dados brutos. Dessa forma, elimina-se a necessidade de engenharia manual de atributos e possibilita-se a extração de características de alto nível (ABBASSI *et al.*, 2023; FAOUZI; COLLIOT, 2023). Além disso, enquanto métodos convencionais de AM podem não operar bem em conjuntos de dados de alta dimensionalidade, o aprendizado profundo

geralmente requer grandes conjuntos de dados de treinamento, já que as RNAs podem ser extremamente complexas, com muitos parâmetros a serem ajustados durante o treinamento (RASCHKA; KAUFMAN, 2020).

2.4 Tipos de aprendizado de máquina

Alguns autores, como Raschka e Mirjalili (2019), consideram que há três tipos de AM: aprendizado supervisionado, não supervisionado e por reforço. Porém, outros autores também consideram a existência de outros tipos, como o aprendizado semissupervisionado (ZHUANG *et al.*, 2021). Nas próximas subseções, serão discutidos os tipos de aprendizado supervisionado e não supervisionado.

2.4.1 Aprendizado supervisionado

No aprendizado supervisionado, utilizam-se *datasets* (termo comum para “conjuntos de dados”) que contêm informações de entrada e de saída para treinar modelos capazes de prever os dados de saída a partir de relações observadas nos dados de entrada (BHATT *et al.*, 2023; PARKAVI *et al.*, 2024).

Considera-se que as duas categorias mais usuais de aprendizado supervisionado são: a classificação, que visa à categorização de diferentes elementos; e a regressão, que busca prever valores contínuos com base nas variáveis de entrada (ALSHAIKH; PARKINSON; KHAN, 2023).

A Figura 4 é uma ilustração de um cenário no qual um algoritmo de aprendizado supervisionado para classificação é treinado a partir de dados rotulados, cujas classes são representadas por círculos abertos e círculos preenchidos. A estrela desenhada no gráfico representa um novo dado cuja classe

deve ser prevista. Por meio do traçado de uma fronteira de decisão que separa as classes, percebe-se que o novo dado, representado pela estrela, está associado à classe dos círculos abertos, com a qual apresenta maior similaridade.




Figura 4. Exemplo de classificação por aprendizado supervisionado. Fonte: Adaptação de BALADRAM *et al.* (2020).

2.4.2 Aprendizado não supervisionado

Tratando-se de métodos de aprendizado não supervisionado, apenas dados de entrada são fornecidos ao algoritmo de aprendizagem, que deve, então, encontrar padrões e relações entre dados que não dispõem de saídas rotuladas (MALIK *et al.*, 2023).

Duas estratégias destacáveis de aprendizado não supervisionado são a clusterização e as técnicas de transformação não supervisionadas (MÜLLER; GUIDO, 2016).

A clusterização consiste em dividir os dados em grupos (ou *clusters*) distintos, de modo que os componentes de um mesmo grupo apresentem características mais semelhantes entre si do que em relação aos componentes de outros grupos

(AYTAÇ, 2020). Como resultado desse processo, as relações de similaridade entre amostras podem ser exploradas para diferentes propósitos, como, por exemplo, a análise de conjuntos de dados para identificar alternativas semelhantes a um material de referência, como na descoberta de novos medicamentos (KUBAN *et al.*, 2022).

A Figura 5 ilustra o resultado de um processo de reconhecimento facial realizado por um algoritmo não supervisionado, no qual imagens de faces similares são reconhecidas e agrupadas sem a necessidade de saídas rotuladas que as identifiquem.



Figura 5. Reconhecimento facial por meio de um algoritmo de aprendizado não supervisionado.
Fonte: Adaptação de TSENG *et al.* (2020).

Já as técnicas de transformações não supervisionadas são utilizadas para criar uma nova representação dos dados, adaptando-os a padrões mais compreensíveis para humanos ou para outros algoritmos de AM (MÜLLER; GUIDO, 2016). Essas transformações também podem ser utilizadas como ferramentas de pré-processamento para modelos de aprendizado supervisionado, que podem se beneficiar dos dados transformados, obtendo melhores resultados em comparação com o conjunto de dados original (GROZAVU *et al.*, 2012). Como exemplos de técnicas de transformação não supervisionada, citam-se: o escalonamento, que visa garantir que diferentes atributos tenham a mesma escala, melhorando a eficácia de outros algoritmos posteriormente utilizados; e a redução de dimensionalidade, utilizada para simplificar dados de alta dimensionalidade, preservando suas características essenciais, mesmo com menos atributos (MÜLLER; GUIDO, 2016).

Segundo Kaur *et al.* (2021), alguns dos principais algoritmos de aprendizado não supervisionado são a clusterização *K-means* e a técnica de redução de dimensionalidade chamada análise dos componentes principais, também conhecida pela sigla PCA, devido ao termo da língua inglesa *Principal Component Analysis*.

De forma geral, o processo de aprendizagem não supervisionada começa com a definição dos objetivos do problema, seguida da coleta de dados pertinentes. Em seguida, os dados podem ser fornecidos aos algoritmos apropriados, que devem ser escolhidos e configurados adequadamente antes de serem utilizados na etapa de treinamento. Após o uso de algoritmos de treinamento e de reconhecimento de padrões nos dados, devem ser realizadas interpretações críticas dos resultados para que a informação obtida seja útil (WULFF; KUBSCH; KRIST, 2025).

2.5 Etapas do processamento de modelos de aprendizado supervisionado

Nas próximas subseções, serão descritas as principais etapas envolvidas no processamento de modelos de AM supervisionado, a saber: análise, treinamento, teste e aplicação (KONTSEWAYA *et al.*, 2021). Essas etapas são divididas em fases menores, complementares ao processo. Também é importante destacar que, muitas vezes, essas etapas podem ocorrer simultaneamente e se ajustar mutuamente com base nas informações e nos resultados obtidos ao longo do processo (PALEYES *et al.*, 2022).

2.5.1 Etapa de análise

Esta etapa compreende outras subetapas nas quais ocorrem a análise e o processamento dos dados originais.

Os primeiros passos no processamento de um modelo de AM são a obtenção e a preparação dos dados (ALZUBI; NAYYAR; KUMAR, 2018). Nesse estágio, são realizadas análises e tratamentos dos dados para evitar erros e melhorar a qualidade dos resultados (KONTSEWAYA *et al.*, 2021). Para isso, realizam-se limpezas para remover dados inadequados, como ruídos, dados faltantes, inconsistentes ou desnecessários (NDUNG'U, 2022).

Outra prática que pode ser essencial na preparação dos dados é escaloná-los por meio de técnicas de pré-processamento, como a normalização, para que eles passem a ocupar uma faixa de valores em comum. Esse método é necessário quando há grandes variações nos intervalos de diferentes atributos e, por meio dele,

evita-se que características com valores numéricos maiores dominem outras com valores menores (ALI; FARAJ, 2014; SINGH; SINGH, 2020).

Para evitar o problema conhecido como *overfitting*, no qual um modelo memoriza os dados de treinamento, mas não apresenta bom desempenho em novos dados, é comum dividir os *datasets* em dois conjuntos: um para treinamento e outro para testes. O conjunto de treinamento é utilizado para ajustar o modelo, enquanto o conjunto de testes é utilizado para avaliar o desempenho do modelo e garantir que ele não se ajuste excessivamente aos dados de treinamento, evitando, assim, o *overfitting* (JOSEPH; VAKAYIL, 2022; MÜLLER; GUIDO, 2016). É comum que os conjuntos de treinamento representem entre 60% e 80% do total, enquanto os conjuntos de teste correspondem à porção restante (RAFAŁO, 2022). Além disso, realizar a divisão dos dados de forma estratificada garante que o *dataset* original seja dividido em subconjuntos que mantenham a distribuição adequada das classes ou dos perfis de amostras nos diferentes conjuntos (RAFAŁO, 2022).

Também é importante garantir o balanceamento de dados, que consiste em ajustar a distribuição de determinadas variáveis em um conjunto de dados por meio de subamostragem ou sobreamostragem, por exemplo. Assim, evita-se que determinados perfis de amostras apresentem números significativamente maiores de instâncias do que outros (TALUKDER *et al.*, 2024).

2.5.2 Etapa de treinamento

A segunda etapa consiste na aplicação de algoritmos de AM aos dados (KONTSEWAYA *et al.*, 2021). Após o tratamento dos dados, costuma-se selecionar o algoritmo a ser utilizado. Como nem todos os algoritmos de AM são adequados a todos os problemas, é fundamental selecionar o mais adequado à tarefa em questão para obter melhores resultados. Com o algoritmo definido, o modelo precisa ser

treinado, sendo, para isso, utilizada a parte do *dataset* designada como conjunto de treinamento (ALZUBI; NAYYAR; KUMAR, 2018).

A partir dos dados de treinamento, um modelo de AM estima automaticamente propriedades denominadas “parâmetros”, que não podem ser definidas manualmente pelo usuário, como os coeficientes de uma regressão linear (CORNETTA; TOUHAFI, 2021). Essenciais para que um modelo possa realizar previsões (ADEGBOYE, 2024), esses parâmetros são ajustados com base em funções de custo, que indicam o quão bem um modelo aprende a partir dos dados, sendo a minimização dessas funções o principal objetivo do treinamento (PARK *et al.*, 2020; TIAN *et al.*, 2022). Exemplos comuns de funções de custo incluem o erro quadrático médio e o erro absoluto médio (TIAN *et al.*, 2022).

Para aumentar a qualidade dos modelos, a etapa de treinamento também pode envolver a variação de hiperparâmetros (KONTSEWAYA *et al.*, 2021), que são configurações ajustáveis antes da execução dos algoritmos de AM, visando otimizar o desempenho de um modelo (RASCHKA, 2018; WEERTS *et al.*, 2020).

2.5.3 Etapa de teste

Nesta fase, os modelos treinados devem ser testados em dados não utilizados nas etapas anteriores. Para isso, várias métricas de desempenho podem ser usadas para avaliar o modelo (KONTSEWAYA *et al.*, 2021), o que implica determinar o quão bem o modelo aprende com os dados fornecidos e quão bem esse aprendizado se aplica na prática (SOMOGYI, 2021). Com esse objetivo, devem ser selecionadas métricas adequadas para avaliar o modelo construído (HERRERO; ZORRILLA, 2022).

Alguns dos métodos de avaliação aplicáveis nesta etapa também podem ser utilizados como funções de custo para o treinamento de modelos, como é o caso do

erro absoluto médio e do erro quadrático médio (ATMAJA; AKAGI, 2021), citados na Subseção 2.7.2.

2.5.4 Etapa de aplicação

Após a realização das avaliações, chega-se à etapa de aplicação, na qual deve ocorrer a implantação (*deployment*) do modelo mais bem avaliado (KONTSEWAYA *et al.*, 2021). É importante mencionar que, no contexto de AM, o termo “implantação” refere-se à integração de um modelo treinado à infraestrutura de um *software* necessário para executá-lo, além de estar relacionado a questões de manutenção e atualização (PALEYES *et al.*, 2022).

Para garantir que o modelo desenvolvido seja facilmente compreendido e gerido, é importante que a implantação envolva a elaboração de uma documentação detalhada do modelo, incluindo sua arquitetura, suas dependências e os procedimentos adotados para colocá-lo em operação. Além disso, o compartilhamento de conhecimento entre os membros da equipe de desenvolvimento é fundamental para assegurar a continuidade na administração do modelo e facilitar futuras manutenções e atualizações (SINGLA, 2023).

Alguns desafios relacionados à etapa de implantação incluem a chegada de dados em alta frequência e em grande quantidade; mudanças na distribuição dos dados de entrada ou na distribuição da variável alvo; dificuldades no aumento da escala de modelos pequenos desenvolvidos em *hardware* local e, até mesmo, o gerenciamento do consumo de energia de infraestruturas de alto poder computacional (BAIER; JÖHREN; SEEBACHER, 2019).

2.6 Otimização de hiperparâmetros

Por meio do ajuste de hiperparâmetros, é possível evitar que um modelo de AM seja prejudicado por problemas de sobreajuste (*overfitting*) ou de subajuste (*underfitting*) (KOLLURI *et al.*, 2020). Como mencionado anteriormente, o *overfitting* ocorre quando um modelo de AM se ajusta excessivamente aos dados de treinamento e apresenta alta precisão nesse conjunto, mas falha em generalizar para novos dados. Entre outras causas, isso pode ocorrer devido a dados ruidosos ou ao uso de um modelo excessivamente complexo. Em contrapartida, o *underfitting* ocorre quando o modelo não aprende o suficiente com os dados, resultando em desempenho ruim até mesmo no conjunto de treinamento. Algumas de suas causas são o uso de volumes de dados insuficientes e a seleção de modelos inadequados ou de complexidade insuficiente (PRAJAPATI; SINGH, 2023). Na Figura 6, são apresentados diferentes níveis de ajuste de um modelo a dados arbitrariamente gerados, para ilustrar casos de *overfitting*, *underfitting* e ajuste equilibrado das previsões.




Figura 6. Casos de *underfitting*, ajuste equilibrado e *overfitting*. Fonte: O autor.

Por meio do ajuste de hiperparâmetros em um modelo de AM, é possível melhorar seu desempenho. Isso ocorre porque diferentes configurações de

hiperparâmetros podem resultar em modelos com desempenhos substancialmente diferentes, mesmo quando treinados no mesmo conjunto de dados (WANG; GONG, 2018).

Apesar de sua importância, não há regras rígidas que garantam o melhor resultado para qualquer conjunto de dados (RASCHKA, 2018). Para selecionar os hiperparâmetros apropriados para um *dataset* específico, os usuários podem recorrer a diferentes opções, como: utilizar os valores padrão de hiperparâmetros previamente especificados nas bibliotecas de AM; configurar os hiperparâmetros manualmente com base em recomendações da literatura; ou recorrer à experiência ou à tentativa e erro (PROBST *et al.*, 2019). Além disso, podem ser utilizadas estratégias de otimização, como os tipos de busca manual, em grade e aleatória, bem como técnicas como a otimização bayesiana (MARCO; AHMAD; AHMAD, 2022).

Dentre as técnicas de otimização existentes, considera-se que a mais amplamente utilizada para explorar os efeitos de diferentes combinações de hiperparâmetros é a busca em grade (também conhecida como *grid search*). A busca em grade pode ser descrita como uma exploração exaustiva que testa todas as combinações de hiperparâmetros fornecidas pelo usuário ao modelo (BELETE; HUCHAIAH, 2022).

Outro método amplamente utilizado na seleção de modelos é a validação cruzada, que pode atuar não apenas no ajuste de hiperparâmetros, mas também no treinamento e na avaliação de modelos (BERRAR, 2019; SRINIVASAN *et al.*, 2019). O tipo de validação cruzada conhecido como *k-fold* é um método utilizado para avaliar como modelos de AM se comportam em dados não vistos (SOPER, 2021). No caso da utilização da validação cruzada *k-fold* para seleção de modelos, é preciso manter um conjunto de dados de teste independente, que não deve ser utilizado durante o treinamento e a seleção do modelo, evitando que informações do conjunto de teste influenciem a fase de treinamento (RASCHKA, 2018). O processo começa com a divisão dos dados em K subconjuntos, de modo que K-1 sejam

utilizados como conjuntos de treinamento, enquanto o subconjunto restante é utilizado como conjunto de validação, empregado em uma avaliação inicial do modelo (SOPER, 2021). A criação de um conjunto de validação é necessária porque ajustes de hiperparâmetros com base nos dados de treinamento podem levar a problemas de *overfitting* (RASCHKA, 2018).

Após a divisão dos dados em um subconjunto para validação e o restante para treinamento, avalia-se o desempenho do modelo, e o processo é repetido até que todos os subconjuntos tenham sido utilizados como conjunto de validação, realizando K iterações. Por fim, o desempenho geral do modelo é calculado como a média dos resultados de cada iteração (SOPER, 2021).

A Figura 7 ilustra o processo de validação cruzada *k-fold*, com divisão dos dados em conjuntos de treinamento, validação e teste.



Figura 7. Validação cruzada *k-fold*. Fonte: O autor.

As técnicas de busca em grade e de validação cruzada podem ser combinadas para facilitar a otimização de parâmetros. Com a busca em grade, constroem-se várias versões de modelos, utilizando diversas combinações de hiperparâmetros. Dessa forma, aplica-se a técnica de validação cruzada para a avaliação de cada combinação de hiperparâmetros, permitindo a seleção do modelo

que apresenta o melhor desempenho entre todos os concorrentes (SUKAMTO *et al.*, 2023).

Por fim, o modelo construído com os melhores parâmetros pode ser submetido à avaliação final na etapa de testes, utilizando o conjunto de dados previamente separado como conjunto de testes (RASCHKA, 2018).

2.7 Métricas para avaliação de modelos de AM

Nesta seção, são apresentadas métricas comumente utilizadas nas etapas que envolvem avaliação de modelos de AM, tais como treinamentos com validação cruzada e avaliações finais com dados de teste.

2.7.1 Métricas para classificação

As métricas apresentadas a seguir são consideradas, por Herrero e Zorrila (2022), entre as mais comumente utilizadas em problemas de classificação: acurácia, F1-Score, sensibilidade (também conhecida como *recall*) e especificidade.

Antes de apresentar as equações matemáticas que permitem calcular métricas para problemas de classificação de amostras, serão discutidos alguns conceitos importantes para seu entendimento. Seguindo os critérios de Müller e Guido (2016), os resultados de classificações binárias de amostras podem ser descritos da seguinte forma:

- Verdadeiros positivos (VP), que representam amostras corretamente classificadas como pertencentes a uma classe positiva;
- Verdadeiros negativos (VN), que representam amostras corretamente classificadas como pertencentes a uma classe negativa;

- Falsos positivos (FP), que representam amostras erroneamente classificadas como pertencentes a uma classe positiva;
- Falsos negativos (FN), que representam amostras erroneamente classificadas como pertencentes a uma classe negativa.

Com base nos termos de classificação binária descritos, apresentam-se, no Quadro 1, as equações matemáticas que permitem o cálculo de importantes métricas de classificação binária.

Quadro 1. Métricas de classificação binária. Fonte: YILMAZ *et al.* (2020).

Métrica	Equação
Acurácia	$\frac{VP + VN}{VP + VN + FP + FN}$
<i>Recall</i>	$\frac{VP}{VP + FN}$
Especificidade	$\frac{VN}{VN + FP}$
Precisão	$\frac{VP}{VP + FP}$
<i>F1-Score</i>	$\frac{2 \cdot \text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}}$

As fórmulas matemáticas evidenciam as principais características das métricas: a acurácia representa a fração de amostras corretamente classificadas entre todas as amostras; o *recall* retrata a fração de amostras positivas classificadas corretamente (VP) em relação ao número verdadeiro de amostras positivas (VP + FN); a especificidade representa a proporção de amostras negativas corretamente classificadas (VN) em relação ao número verdadeiro de amostras negativas (VN + FP); a precisão é a fração de amostras positivas corretamente classificadas (VP) em relação a todas as amostras previstas como positivas (VP + FP); e o *F1-Score* é a média harmônica entre precisão e *recall* (YILMAZ *et al.*, 2020).

Por meio de técnicas como “Um-contra-Todos” (OvA, sigla do termo em inglês “*One-versus-All*”) e “Um-contra-Um” (OvO, sigla do termo em inglês “*One-versus-One*”), problemas de classificação multiclasse podem ser decompostos

em múltiplos subproblemas binários, permitindo estender princípios de classificação binária ao contexto multiclasse (FERNÁNDEZ *et al.*, 2013).

Uma visão mais concisa dos resultados de classificação pode ser obtida por meio de uma matriz de confusão, uma matriz bidimensional na qual os rótulos verdadeiros são representados nas linhas e os rótulos previstos nas colunas. Ela resume, de forma clara, a distribuição das previsões em todas as classes, permitindo avaliar não apenas a proporção de previsões verdadeiras e falsas, mas também compreender o tamanho de cada classe, especialmente em conjuntos de dados desbalanceados (HEYDARIAN *et al.*, 2022). O Quadro 2 apresenta um exemplo de matriz de confusão para classificação binária.

Quadro 2. Exemplo de matriz de confusão. Fonte: Adaptação de HERRERO; ZORRILLA (2022) e HEYDARIAN *et al.* (2022).

		Classes previstas	
		Classe positiva	Classe negativa
Classes verdadeiras	Classe positiva	VP	FN
	Classe negativa	FP	VN

Outra forma de avaliação de resultados é a análise da curva ROC (do inglês, *Receiver Operating Characteristic*), que utiliza a relação entre a sensibilidade (*recall*) e a especificidade de um classificador binário (FLACH, 2016). No contexto da análise ROC, a sensibilidade é usualmente referida como “taxa de verdadeiros positivos”, enquanto o complemento da especificidade, em relação a 1, é chamado de “taxa de falsos positivos” (ou seja, $1 - \text{especificidade} = \text{taxa de falsos positivos}$) (FLACH, 2016; MCBEE; PETERS; MILLER, 2016).

Para produzir uma curva ROC, plota-se a taxa de verdadeiros positivos em função da taxa de falsos positivos para diferentes valores de ponto de corte (também chamados de *thresholds*). Cada ponto de corte estabelece o limiar a partir do qual uma instância passa a ser considerada positiva pelo modelo, resultando em diferentes combinações de taxas de verdadeiros e falsos positivos que compõem a curva (FLACH, 2016; HOO; CANDLISH; TEARE, 2017).

Já a área sob a curva ROC, chamada de AUC (do inglês, *Area Under the Curve*), é uma medida da capacidade que o classificador tem de distinguir entre classes positivas e negativas. Um valor de AUC igual a 0,5 provém de uma curva ROC que segue a linha diagonal $y=x$, o que indica que o teste tem desempenho equivalente ao acaso, não apresentando nenhuma capacidade discriminativa. Por outro lado, um valor de AUC igual a 1,0 indica um teste com discriminação perfeita (HOO; CANDLISH; TEARE, 2017).

A Figura 8 ilustra um exemplo de curva ROC e sua área AUC correspondente. A linha diagonal representa o desempenho de um teste em que as classificações são feitas aleatoriamente, produzindo resultados verdadeiros positivos na mesma taxa que falsos positivos. Quanto mais a curva ROC se afastar da linha diagonal na direção superior, melhores serão os resultados de classificação (MCBEE; PETERS; MILLER, 2016).




Figura 8. Exemplo de curva ROC. Fonte: O autor.

2.7.2 Métricas para regressão

Quanto aos métodos de avaliação de modelos utilizados em problemas de regressão, métricas como o coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE, abreviação de “*Root Mean Squared Error*”), erro absoluto médio (MAE, sigla para o termo “*Mean Absolute Error*”) e o erro percentual absoluto médio (MAPE, sigla de “*Mean Absolute Percentage Error*”) são comumente utilizadas na literatura (AYKO; KESER, 2021).

Conveniente para comparar diferentes problemas de regressão, o coeficiente de determinação (R^2) indica a capacidade de uma equação de explicar a variável dependente, com valor máximo de 1. Valores próximos de 1 indicam que o modelo se adapta bem aos dados do problema, enquanto valores próximos de 0 indicam baixa adequação (KABAS; KAYAKUS; MOICEANU, 2023). É importante destacar que o coeficiente de determinação também pode ser negativo em alguns casos, o que indica que o modelo é menos informativo do que a média da variável dependente, sugerindo problemas como *overfitting*, treinamento inadequado ou desajuste na complexidade do modelo (M’HAMDI *et al.*, 2024).

Enquanto o R^2 indica o quão bem um modelo se ajusta em termos relativos à variabilidade dos dados, a raiz do erro quadrático médio (RMSE) costuma ser interpretada como o desvio padrão da variância não explicada. Além disso, essa métrica é absoluta (na mesma unidade da variável de resposta) e indica o quão próximos os valores previstos estão dos valores observados, de modo que valores menores de RMSE indicam ajustes melhores (KHAN; NOOR, 2019).

Outra métrica comumente utilizada é o erro absoluto médio (MAE), que avalia a proximidade entre uma curva de regressão e uma série de pontos de dados por meio do cálculo da média dos erros absolutos (distâncias entre valores reais e valores preditos pelo modelo), sendo que valores de MAE mais baixos associam-se a melhores desempenhos (KABAS; KAYAKUS; MOICEANU, 2023). Já o MAPE é

uma variante do MAE, cujo valor refere-se ao erro percentual, o que torna essa métrica mais útil quando as variações relativas têm maior impacto na tarefa de regressão do que as variações dos valores absolutos (CHICCO; WARRENS; JURMAN, 2021).

As equações matemáticas que permitem obter os valores para as métricas de regressão descritas são apresentadas no Quadro 3, no qual se considera que N é o número de amostras, y_i são os valores reais, $\hat{y}_i$ são os valores previstos e $\bar{y}$ é a média dos valores reais (AYKO; KESER, 2021).

Quadro 3. Métricas para regressão. Fonte: AYKO; KESER (2021).

Métrica	Equação
Coeficiente de determinação (R^2)	$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$
Erro quadrático médio (RMSE)	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$
Erro absoluto médio (MAE)	$MAE = \frac{1}{N} \sum_{i=1}^N y_i - \hat{y}_i $
Erro percentual absoluto médio (MAPE)	$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{ y_i - \hat{y}_i }{y_i} \cdot 100\%$

2.8 Ferramentas e recursos para AM

Nesta subseção, serão abordados alguns recursos utilizados no estudo e na prática de AM.

2.8.1 Linguagem *Python*

No contexto do desenvolvimento de *software*, a escolha de uma linguagem de programação apropriada é um passo crucial, no qual devem ser considerados os pontos fortes e fracos da linguagem em relação à abordagem do problema de interesse (CAGNONI *et al.*, 2020).

Quanto à popularidade, *Python* é considerada a linguagem de programação mais utilizada em AM e dispõe de diversas bibliotecas de código aberto que fornecem ferramentas acessíveis e reutilizáveis para análise de dados, sendo, por isso, amplamente utilizada em aplicações de AM (KERZEL; KÖNIG-RIES; SHEEBA, 2023; MATSUOKA *et al.*, 2023). A linguagem *Python* também permite a apresentação de cálculos e gráficos estatísticos por meio de diversas bibliotecas desenvolvidas para esse propósito, sendo uma ferramenta útil, eficaz e versátil, que proporciona uma curva de aprendizagem fácil e rápida (DAZA *et al.*, 2023).

De acordo com Raschka e Mirjalili (2019), algumas das bibliotecas *Python* mais utilizadas em AM são:

- *NumPy*: utilizada para manipulação de matrizes multidimensionais;
- *Pandas*: feita com base no *NumPy*, essa biblioteca fornece ferramentas adicionais de manipulação de dados em um nível mais alto e torna mais conveniente trabalhar com dados tabulares;
- *Scikit-Learn*: oferece grande variedade de algoritmos de AM e funções convenientes para o pré-processamento de dados, otimização e avaliação de modelos de AM;
- *Matplotlib*: biblioteca para visualização gráfica de dados quantitativos.

Vale destacar que a linguagem *Python* possui sua própria versão do *framework TensorFlow*, uma biblioteca especializada no treinamento de modelos de redes neurais profundas (RASCHKA; MIRJALILI, 2019). Devido à curva de aprendizagem íngreme do *TensorFlow*, a API *Keras* pode ser utilizada como

alternativa para o desenvolvimento de modelos de DL, pois oferece uma interface de alto nível que executa de forma eficiente sobre o *TensorFlow*. Isso significa que, com sua interface mais simples e intuitiva, o *Keras* facilita o uso das capacidades do *TensorFlow*, reduzindo a complexidade do desenvolvimento de redes neurais e permitindo uma prototipagem rápida (BENBRAHIM; HACHIMI; AMINE, 2020; VADAR *et al.*, 2024). Outro *framework* que tem ganhado popularidade como alternativa para facilitar o desenvolvimento de modelos de DL é o *PyTorch*, conhecido por sua codificação simplificada e pelo suporte a gráficos dinâmicos, que proporcionam flexibilidade e permitem experimentações rápidas, além de uma prototipagem eficiente (VADAR *et al.*, 2024; ZHANG; ZHANG; LU, 2021).

Visando à simplificação do processamento de modelos de AM, também podem ser usadas ferramentas de baixa codificação (também conhecidas como “*low-code*”), como o *framework PyCaret*, projetado para facilitar o desenvolvimento e a implementação de modelos de AM com pouca codificação, permitindo sua utilização por pessoas com pouca experiência na área (SARANGPURE *et al.*, 2023).

2.8.2 Ferramentas interativas para estudo e prática de AM

Uma ferramenta muito utilizada em cursos de IA e AM é o *Jupyter Notebook*, que suporta mais de 40 linguagens de programação, como *Python* e R (AMOUDI; TBAISHAT, 2023; KERZEL; KÖNIG-RIES; SHEEBA, 2023). Sendo amplamente utilizado na educação, nas pesquisas e na indústria, o *Jupyter Notebook* é uma ferramenta *open-source* com arquitetura cliente-servidor que pode conter código, texto, equações, imagens e vídeos. Assim, simplifica-se a criação de documentos (também chamados de *notebooks*) que permitem aos estudantes resolver tarefas, escrever código e realizar pesquisas em um único documento (AMOUDI; TBAISHAT, 2023).

Apesar de sua praticidade, alguns ambientes de programação interativa mais recentes têm se afastado do paradigma de *notebooks*, como é o caso da plataforma *Streamlit*, focada no *design* de aplicações *web* que renderizam componentes interativos por meio da execução de *scripts* em *Python* (BÄUERLE *et al.*, 2022).

2.8.3 Ferramentas visuais *web*

Como a aplicação de modelos de AM ainda é bastante desafiadora para pessoas sem experiência em ciência de dados, faz-se necessária a introdução de ferramentas amigáveis ao usuário. Essas ferramentas devem permitir que não especialistas construam seus próprios modelos, o que pode ampliar o impacto das técnicas de AM no mundo real (BAIER; JÖHREN; SEEBACHER, 2019).

Ao contrário das aplicações nativas a determinados sistemas operacionais, as aplicações *web* podem ser implantadas independentemente do *hardware* ou do sistema operacional subjacente (GOH *et al.*, 2023). Também contribuem para a popularidade das aplicações *web* as inovações e os aprimoramentos dos componentes *web* em geral e do *JavaScript*, uma das linguagens mais populares para a construção desse tipo de aplicação. Em decorrência desses fatores, as aplicações *web* se tornaram úteis para diversas finalidades, como, por exemplo, permitir que o usuário final realize cálculos científicos específicos ou exiba conteúdos de maneira informativa, completa, versátil e interativa (ABRIATA, 2017).

Há um número crescente de ferramentas de visualização que auxiliam os profissionais a compreender modelos e sistemas modernos de AM (BÄUERLE *et al.*, 2022). Em alguns casos, também objetiva-se facilitar o acesso a modelos de AM, como o *software* desenvolvido por Ferdous *et al.* (2023) na forma de uma aplicação *web*, com o intuito de permitir que químicos e biólogos, independentemente de seus níveis de conhecimento em computação, apliquem seus modelos de previsão em suas pesquisas.

Diante desse quadro e da complexidade associada ao uso de AM, verificou-se a importância de identificar e analisar ferramentas *web* que facilitem o estudo de AM no contexto do ensino superior. Essa abordagem será explorada na próxima seção por meio da análise do estado da arte.

Embora ofereçam cursos e treinamentos relacionados a AM, algumas plataformas oferecidas por grandes empresas de tecnologia, como *Google Cloud Training*, *AWS Educate*, *Microsoft Learn* e *Huawei Cloud Academy*, são, em sua maioria, voltadas para capacitação técnica geral e profissional, podendo abranger diversos temas além do AM, como computação em nuvem, *big data* e segurança da informação (ABELL; HUSAR; MAY-ANN, 2021; MEYER JR.; BILLIONNIERE, 2021; SANG *et al.*, 2023), fugindo, assim, ao escopo específico deste estudo.

2.9 Estado da arte

Com o propósito de identificar o estado da arte no uso de ferramentas visuais *web* para facilitar o estudo de AM, da Silva, Barbosa e Seabra (2024) conduziram um estudo de mapeamento sistemático para complementar esta dissertação, destacando a existência de oito ferramentas classificadas como efetivamente relevantes para esse contexto.

Foi adotado um protocolo de pesquisa que baseou-se em buscas nos repositórios *ACM Digital Library*, *ERIC – Education Resource Information Center*, *IEEE Xplore*, *ScienceDirect*, *Springer Link* e *Wiley Online Library*, sendo utilizada uma *string* de busca baseada nos seguintes termos e operações lógicas: ("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"). Dessa forma, a pesquisa inicial retornou 884 artefatos.

Posteriormente, foram aplicados critérios de inclusão e exclusão às publicações, reduzindo o número de publicações potencialmente relevantes (para uma investigação mais aprofundada) para 22. Após essa etapa, foram reanalisadas, de forma mais aprofundada, as publicações restantes para remover resultados não relevantes, restando apenas duas publicações sobre trabalhos pertinentes ao contexto deste estudo. Além disso, esta etapa também contou com a realização de um processo de *snowballing*, que levou à obtenção de mais seis artigos relevantes, totalizando oito publicações para a análise e o detalhamento das ferramentas visuais *web* para o estudo de AM existentes.

Devido à quantidade inexpressiva de publicações aprovadas pelos critérios de inclusão, justifica-se a motivação para a realização de investimentos em recursos e esforços que visem o desenvolvimento de ferramentas visuais *web* direcionadas ao estudo de AM, sendo essa uma área que parece ter sido pouco explorada por pesquisadores.

No histograma da Figura 9, apresentam-se os anos de lançamento das publicações relevantes identificadas.




Figura 9. Anos de lançamento das publicações utilizadas como referências. Fonte: DA SILVA; BARBOSA; SEABRA (2024).

Embora não tenha sido definido um intervalo de tempo dentro do qual as publicações deveriam ter sido lançadas para constarem como resultados relevantes para o mapeamento sistemático, os dados mostrados na Figura 10 revelam que todas as publicações relevantes para o contexto deste estudo foram lançadas entre os anos de 2015 e 2020, o que pode sugerir um aumento recente da atenção direcionada para essa área de pesquisa.

No Quadro 4, são registradas as caracterizações das ferramentas relevantes com relação aos seus nomes, descrições e referências para a identificação de seus autores. Para denominar as ferramentas cujos nomes não foram especificados, realizaram-se identificações genéricas com base nos sobrenomes dos autores de suas respectivas publicações.

Após a análise dos resultados do mapeamento sistemático, concluiu-se que o algoritmo de AM mais comumente utilizado pelas ferramentas é o das redes neurais. Com relação às tarefas de AM, observou-se maior frequência de aparições das tarefas de classificação de imagens. Quanto aos recursos mais comumente utilizados para a disponibilização de interfaces gráficas, observou-se que a maioria das ferramentas recorre, para isso, a bibliotecas de *JavaScript*. Para simplificar a execução do processamento de modelos de AM, constatou-se que os botões são o principal recurso disponibilizado pelas ferramentas. Outro ponto de destaque é que a maioria das publicações (lançadas pelos próprios autores das ferramentas) utilizadas como referências não apresenta detalhes sobre as metodologias empregadas na avaliação de suas ferramentas visuais. Além disso, os resultados desse mapeamento sistemático sugerem que ainda são poucos os projetos que visam à construção de ferramentas *web* visuais propícias ao estudo de AM para alunos iniciantes. Cabe destacar, contudo, que a seleção das bases científicas consultadas e os critérios adotados na condução do mapeamento podem ter limitado a identificação de outros trabalhos relacionados ao tema, embora as buscas tenham sido planejadas de forma sistemática.

Quadro 4. Descrição das ferramentas. Fonte: DA SILVA; BARBOSA; SEABRA. (2024).

Identificação da ferramenta	Descrição	Referência
Aplicação de Harley	Uma ferramenta para explorar redes neurais convolucionais (CNNs) treinadas para reconhecer dígitos manuscritos.	Harley (2015)
Aplicação de Schultze, Gruenefeld e Boll.	Uma aplicação baseada em classificação de imagens que permite aos usuários a criação de modelos personalizados.	Schultze; Gruenefeld; Boll (2020)
Biblioteca <i>Snap!</i> de Kahn <i>et al.</i>	Uma biblioteca de AM para a plataforma <i>Snap!</i> , que consiste num 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> (2021)
<i>GAN Lab</i>	Uma aplicação para facilitar o entendimento de GANs (Redes Generativas Adversariais), modelos complexos de aprendizado profundo.	Kahng <i>et al.</i> (2019)
<i>Script Scratch</i> de Estevez <i>et al.</i>	Um script 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 com base em imagens e sons.	Carney <i>et al.</i> (2020)
<i>TensorFlow Playground</i>	Uma aplicação cujo principal objetivo é ajudar os usuários a entender o funcionamento de redes neurais.	Smilkov <i>et al.</i> (2017)

Com base nos resultados obtidos, esta pesquisa busca preencher a lacuna quanto à escassez de ferramentas visuais *web* voltadas ao estudo de AM no ensino superior. Para essa finalidade, objetiva-se desenvolver uma ferramenta que facilite o estudo de AM por meio de recursos visuais e interativos que orientem o processamento de modelos, como botões e menus *dropdown* (também chamados de “menus suspensos”). Diferentemente de abordagens voltadas a atividades

isoladas — como ferramentas que abordam apenas redes neurais para classificação, por exemplo —, busca-se integrar, em um único ambiente *web* interativo e *no-code*, diferentes atividades que contemplem as múltiplas etapas do processamento de modelos de aprendizado supervisionado e não supervisionado. Desse modo, propõe-se o desenvolvimento de uma ferramenta intuitiva que possibilite explorar ativamente técnicas e algoritmos de AM, contribuindo para a capacitação de estudantes do ensino superior no estudo de fundamentos desta área emergente.

2.10 Estudo de Aprendizado de Máquina

Nesta seção, serão discutidos alguns aspectos que podem tornar o campo do AM desafiador para discentes e docentes. Além disso, serão abordados aspectos que podem contribuir para democratizar o AM e permitir que mais pessoas se beneficiem dessa tecnologia.

2.10.1 Desafios para discentes

A falta de compreensão dos princípios fundamentais de AM pode resultar em uma curva de aprendizado íngreme, especialmente para não cientistas da computação (ASKITAS, 2024). Para compreender os princípios por trás dos algoritmos de AM, é preciso dominar diversos conhecimentos fundamentais, como linguagens de programação, ferramentas de análise de dados, além de matemática e estatística, que servem de base para o AM (DEISENROTH; FAISAL; ONG, 2020). Além disso, para aplicar e utilizar algoritmos de AM, recomenda-se ter

conhecimentos em subáreas da ciência da computação, como bancos de dados e engenharia de *software* (HAGEN *et al.*, 2020).

Ademais, segundo Deisenroth, Faisal e Ong (2020), muitas pessoas interessadas em fundamentos de métodos básicos de AM enfrentam dificuldades devido à falta de conhecimentos matemáticos necessários para compreender os livros didáticos da área. Os autores também relatam que suas experiências em cursos de graduação e pós-graduação revelam uma grande diferença entre a matemática do ensino médio e o nível exigido nos livros sobre AM, o que é significativo para muitos estudantes.

O entendimento das decisões tomadas por modelos de AM também pode ser complicado, pois muitos sistemas de suporte à decisão são considerados “caixas-pretas”, uma vez que sua lógica interna e seu funcionamento são ocultos ao usuário, dificultando até mesmo que especialistas compreendam a lógica por trás de suas previsões (CARVALHO; PEREIRA; CARDOSO, 2019).

Adicionalmente, a seleção de modelos e hiperparâmetros, como discutido nas subseções anteriores, pode representar um desafio considerável, especialmente para iniciantes em AM. Dado que a relação entre a escolha dos hiperparâmetros e o desempenho dos algoritmos é, muitas vezes, obscura, treinar e comparar vários modelos com diferentes combinações de hiperparâmetros é uma tarefa que exige conhecimento aprofundado e experiência prática, o que dificulta sua aplicação por estudantes inexperientes (WU *et al.*, 2019).

2.10.2 Desafios para docentes

Devido à escassez de publicações que discutam formas de ensinar AM, há uma compreensão limitada acerca do tipo de Conhecimento Pedagógico do Conteúdo (cuja sigla é PCK, do termo inglês *Pedagogical Content Knowledge*) nesta área. Com base em um PCK que incorpore estratégias como ilustrações, analogias

e demonstrações eficazes, além da compreensão dos aspectos que tornam determinados conceitos fáceis ou difíceis, professores poderiam alcançar maior sucesso em seus ensinamentos no campo do AM (FIEBRINK, 2019).

Além disso, como o AM vem se tornando uma tecnologia importante na sociedade atual, atingindo um público mais amplo do que as tradicionais comunidades de computação e estatística, educadores dessa área tendem a precisar não apenas de conhecimentos em AM, mas também da habilidade de se comunicar e de trabalhar com pessoas de fora dessas áreas (SULMONT *et al.*, 2019).

Segundo Jiang e Li (2021), outro tipo de problema que educadores do ramo de AM podem enfrentar é a necessidade de cumprir um cronograma de aulas, o que pode levá-los a negligenciar as dificuldades específicas dos alunos no aprendizado. Além disso, a utilização de abordagens de ensino centradas no professor ou que recorram apenas a materiais tradicionais, como livros didáticos focados em teorias e temas pré-estabelecidos, pode levar os alunos a se desmotivarem e a se engajarem menos no curso. Para superar esses obstáculos, recomenda-se o uso de estratégias como estimular a comunicação entre os alunos, adaptar o ensino ao nível de cada um, promover a iniciativa para solucionar problemas, utilizar recursos *online* diversificados, aumentar a prática em sala de aula e conectar os estudantes às tendências do mercado na área de AM.

2.10.3 Democratização do AM

O AM vem sendo rapidamente integrado à sociedade e à vida diária das pessoas. Porém, ainda é difícil prever como essa tecnologia será utilizada quando atingir o estágio de "atividade natural" da democratização, como ocorreu com as câmeras fotográficas, atualmente acessíveis e utilizadas de forma intuitiva por quase toda a população (LAO, 2020).

Segundo Thin-Yin e Jonathan (2020), o AM poderia se tornar mais amplamente utilizado se executivos de negócios, alunos de graduação em áreas não técnicas e até mesmo estudantes do ensino médio pudessem entender seus conceitos com mais facilidade, sem necessidade de compreender conceitos complexos. Para isso, seria conveniente que os aprendizes interagissem diretamente com o AM, começando pela construção de modelos simples, em vez de apenas aplicar técnicas de AM sem a devida compreensão, o que é uma abordagem comum no ensino de programação e de AM.

Capacitar estudantes não especialistas em computação com habilidades em AM, combinando-as com seu conhecimento de domínio, pode melhorar as aplicações atuais de AM e auxiliar no desenvolvimento de novas aplicações em diferentes áreas. Além disso, esse perfil de estudante também pode aliar noções de AM a conhecimentos pertinentes às suas áreas de estudo para opinar sobre as implicações que as soluções de AM podem trazer à sociedade (SULMONT *et al.*, 2019).

Outro aspecto importante é a computação em nuvem, que atua como um pilar de democratização ao mitigar as barreiras decorrentes do alto custo dos recursos computacionais. O acesso a plataformas em nuvem — como o *Google Colab*, que fornece gratuitamente recursos de *hardware* poderosos, como GPUs (sigla do termo em inglês *Graphics Processing Units*) e TPUs (sigla do termo em inglês *Tensor Processing Units*) — permite que estudantes e pesquisadores executem modelos complexos de AM, sem a necessidade de investimentos vultosos em infraestrutura local (BAGANE, 2024).

Por fim, ressalta-se também a necessidade de educar o público em geral, de modo a proporcionar o conhecimento necessário para compreender o funcionamento dos produtos e serviços de AM, cada vez mais integrados à vida diária. Ademais, é importante educar a população para que os cidadãos se tornem conscientes e aptos a participar de discussões sobre políticas e regulamentações relacionadas ao contexto do AM (LAO, 2020).

Capítulo 3

MÉTODO

A partir do estudo de mapeamento sistemático realizado como um dos objetivos específicos desta pesquisa, foram identificados elementos importantes que um sistema visual e interativo de suporte ao estudo de AM deve possuir para alcançar seus objetivos de forma mais eficiente. Além disso, verificou-se a necessidade de propor uma abordagem diferente daquelas que já foram colocadas em prática por outros autores (CARNEY *et al.*, 2020; ESTEVEZ *et al.*, 2019; HARLEY, 2015; KAHN *et al.*, 2020; KAHNG *et al.*, 2019; SCHULTZE; GRUENEFELD; BOLL, 2020; SMILKOV *et al.*, 2017; WANG *et al.*, 2021) para que a aplicação desenvolvida a partir deste estudo tenha diferenciais em relação às outras já existentes. Este capítulo tem como objetivo apresentar as funcionalidades da ferramenta desenvolvida, as tecnologias empregadas em seu desenvolvimento e os métodos adotados em sua avaliação.

Quanto à sua natureza, esta pesquisa caracteriza-se como aplicada, uma vez que busca desenvolver uma solução computacional voltada à mitigação de dificuldades relacionadas ao estudo de AM. Em relação aos objetivos, possui caráter exploratório e descritivo, considerando a investigação de requisitos para a construção da ferramenta e a análise das percepções dos participantes sobre sua utilização. Quanto à abordagem, combina elementos qualitativos e quantitativos para a realização de análises descritivas, interpretação de respostas discursivas e quantificação exploratória dos dados coletados.

Por se tratar de uma ferramenta para o estudo de AM por meio de recursos visuais, esta foi nomeada Visual-AM, termo que será amplamente utilizado ao longo deste trabalho.

3.1 Aplicação da DSRM à pesquisa

Conforme apresentado na Subseção 1.2, a condução deste estudo seguiu a metodologia DSRM (*Design Science Research Methodology*), proposta por Peffers *et al.* (2007). Nesta subseção, detalham-se as etapas previstas pela metodologia e descreve-se como cada uma delas foi empregada no desenvolvimento do artefato Visual-AM. Para fins de organização, cada etapa é apresentada nos parágrafos seguintes, evidenciando as ações, decisões e justificativas que nortearam o processo de desenvolvimento da ferramenta.

No primeiro passo, denominado “identificação do problema e motivação”, identificou-se que iniciantes em AM enfrentam dificuldades decorrentes da presença de pré-requisitos técnicos e da escassez de ferramentas visuais e interativas que ofereçam atividades pedagogicamente orientadas. Esse cenário, confirmado pelo estudo de mapeamento sistemático realizado nesta pesquisa, motivou o desenvolvimento da Visual-AM, uma ferramenta que visa facilitar a compreensão de conceitos fundamentais de AM de forma intuitiva.

Em seguida, na etapa de “definição dos objetivos da solução”, estabeleceu-se que o principal objetivo da Visual-AM seria oferecer um ambiente visual, interativo e acessível via navegador, apoiando iniciantes no estudo de conceitos fundamentais de AM. Para isso, definiu-se que o artefato deveria atender a requisitos funcionais, como a visualização gráfica dos dados, a execução de algoritmos diretamente no navegador, a possibilidade de ajuste de hiperparâmetros e o *feedback* imediato sobre os resultados. Também se prezou por requisitos não funcionais, como garantir boas condições de usabilidade, responsividade, acessibilidade sem instalação e design pedagógico. A definição desses requisitos foi orientada pela revisão da literatura sobre AM e por discussões realizadas ao longo da pesquisa com o coorientador deste trabalho, docente com experiência no ensino de conteúdos relacionados ao AM.

O passo seguinte, caracterizado como “*design* e desenvolvimento do artefato”, foi guiado pelos objetivos definidos na etapa anterior, priorizando a criação de um ambiente visual, interativo e acessível para iniciantes em AM, permitindo ao usuário transitar progressivamente por conceitos introdutórios e por atividades práticas. Para isso, foram utilizados recursos da linguagem *Python* para construir uma ferramenta *web* de perfil “*no-code*”, possibilitando a experimentação direta de algoritmos e a visualização dos resultados sem necessidade de codificação.

A etapa de “demonstração” do Visual-AM ocorreu por meio de sua utilização por estudantes de graduação, permitindo verificar se o artefato atendia aos objetivos definidos anteriormente. Os participantes acessaram a página da ferramenta diretamente por meio de navegadores *web* e realizaram as atividades propostas, explorando seus recursos de forma autônoma. Essa etapa permitiu observar o funcionamento do artefato em um cenário autêntico e forneceu subsídios para a avaliação da Visual-AM.

O passo seguinte foi a “avaliação”, que buscou avaliar a eficácia pedagógica da ferramenta e a experiência de uso proporcionada aos usuários. Para esse fim, foram aplicados questionários que permitiram coletar percepções sobre diversos aspectos, como a clareza dos conteúdos e a adequação dos recursos visuais, o que possibilitou identificar pontos fortes e oportunidades de melhoria.

Por fim, na etapa de “comunicação”, buscou-se disseminar o artefato e os resultados obtidos, a fim de garantir que a solução desenvolvida fosse conhecida e utilizada pela comunidade acadêmica. Esta dissertação desempenha um papel central nessa etapa, ao registrar, de forma sistemática, o processo de desenvolvimento, a fundamentação teórica, a avaliação empírica e as implicações pedagógicas do artefato, disponibilizando o conhecimento produzido para futuras pesquisas e aplicações educacionais.

Embora as etapas da DSRM tenham sido conduzidas predominantemente de forma sequencial, o desenvolvimento da Visual-AM envolveu refinamentos incrementais ao longo do processo. Inicialmente, as etapas de “identificação do

problema e motivação” (I), “definição dos objetivos da solução” (II) e “*design* e desenvolvimento do artefato” (III) foram conduzidas de forma sequencial. Após a consolidação de uma versão estável da ferramenta ao final da III, procedeu-se às etapas de “demonstração” (IV) e “avaliação” (V), nas quais todos os participantes utilizaram o mesmo artefato sob condições equivalentes. Concluída a etapa V, houve um retorno à etapa III para realizar ajustes pontuais na ferramenta, especialmente voltados a atualizações de bibliotecas e a erros de digitação. Após a conclusão dos ajustes, prosseguiu-se à etapa de “comunicação” (VI). A dinâmica de execução das etapas da DSRM nesta pesquisa pode ser visualizada na Figura 10.




Figura 10. Fluxograma representativo da aplicação da DSRM no desenvolvimento da Visual-AM.
Fonte: O autor.

3.2 Desenvolvimento da ferramenta Visual-AM

Nos tópicos seguintes, serão detalhadas as características da ferramenta, suas principais funcionalidades e os recursos em que se baseia para seu funcionamento.

3.2.1 Descrição da ferramenta

A Visual-AM é responsiva e acessível em diferentes dispositivos, como computadores e *smartphones*, e permite o estudo de AM por meio de lições teóricas, atividades práticas e *quizzes*. A ferramenta encontra-se disponível no seguinte *link*: <https://visual-am.streamlit.app/>.

Para tornar o conteúdo acessível a usuários iniciantes, optou-se por apresentar um número reduzido de técnicas representativas de alguns dos principais tipos de AM. Com relação ao tipo de aprendizado supervisionado, foram desenvolvidos tópicos para o estudo de atividades de classificação e de regressão. Quanto ao tipo de aprendizado não supervisionado, foram criados tópicos para o estudo de técnicas de clusterização e de redução de dimensionalidade. As escolhas das técnicas utilizadas em cada tópico foram realizadas com base em sua popularidade, aplicabilidade e facilidade de visualização dos resultados.

O conteúdo foi organizado em módulos sequenciais, acessíveis por meio de uma barra lateral, que permite ao usuário navegar entre tópicos de introdução à ferramenta, conceitos de AM, práticas guiadas para a construção de modelos de AM e *quizzes* interativos. Na Figura 11 podem ser visualizadas partes do *menu* lateral de tópicos e da página de introdução da ferramenta Visual-AM.




Figura 11. Menu lateral e página de introdução. Fonte: O autor.

A estratégia pedagógica adotada para a elaboração da ferramenta baseia-se nos conceitos de aprendizagem ativa e metacognição discutidos por Bransford *et al.* (2000). Com base nesses princípios, o usuário é conduzido por meio de instruções apresentadas em sequência e toma decisões por meio de recursos visuais, como *menus* suspensos, controles deslizantes e botões. Em alguns tópicos, a ferramenta oferece *feedback* imediato, como nos *quizzes* e nas etapas de avaliação de modelos supervisionados. Em outros momentos, utilizam-se visualizações em gráficos e demonstrações numéricas dos resultados para estimular a reflexão do usuário sobre as escolhas feitas durante a execução das atividades. Essa abordagem tem como objetivo promover a construção do conhecimento por meio da experimentação e da análise crítica dos resultados, visando uma compreensão mais profunda dos fundamentos e das implicações práticas do AM.

Devido ao caráter *web* e à possibilidade de uso autônomo da ferramenta em diferentes dispositivos, a Visual-AM também pode ser empregada como recurso complementar em estratégias pedagógicas baseadas em sala de aula invertida, de modo que discentes possam explorar o conteúdo de AM abordado na ferramenta de forma assíncrona e fora do ambiente de sala de aula. Nesse contexto, encontros presenciais podem ser voltados para discussões, resolução de problemas e

atividades práticas relacionadas aos conteúdos previamente explorados pelos estudantes.

As subseções a seguir apresentam, em mais detalhes, os temas abordados nas atividades da Visual-AM, bem como os recursos técnicos e visuais utilizados para facilitar o estudo de AM por meio da ferramenta.

3.2.2 Implementação

A Visual-AM foi desenvolvida em *Python*, utilizando o *framework Streamlit* para criar um aplicativo *web* facilmente acessível. Sua hospedagem no ambiente de nuvem *Streamlit Community Cloud* faz com que o esforço computacional decorrente do processamento de modelos de AM seja executado em um servidor remoto, o que favorece a acessibilidade da ferramenta em dispositivos com recursos de *hardware* limitados.

Com relação à arquitetura da ferramenta, o *Streamlit* atua como uma camada de interface *web* interativa, permitindo que o usuário a utilize por meio de recursos visuais, sem necessidade de programação textual. As ações realizadas pelo usuário acionam uma camada de processamento implementada em *Python*, que utiliza bibliotecas específicas para processamento de modelos de AM (*Scikit-learn*), manipulação de dados tabulares e numéricos (*Pandas* e *NumPy*) e geração de visualizações gráficas (*Matplotlib*, *Seaborn* e *Plotly*). A arquitetura simplificada da Visual-AM é apresentada na Figura 12.

Para a organização do conteúdo a ser estudado na ferramenta, foram tomadas como referências as metodologias descritas pelos autores Kontsewaya *et al.* (2021) e Wulff, Kubsch e Krist (2025) para atividades de AM supervisionado e não supervisionado, respectivamente. Dessa forma, os tópicos destinados ao estudo de aprendizado supervisionado foram divididos em etapas baseadas nas fases de análise, treinamento, teste e predição com dados novos. Já os tópicos destinados ao

estudo de aprendizado não supervisionado foram projetados para serem incluídos em três etapas principais na ferramenta desenvolvida: uma etapa inicial de exploração e preparação dos dados, seguida da aplicação dos algoritmos e finalizada com a análise dos resultados.




Figura 12. Arquitetura simplificada da Visual-AM. Fonte: O autor.

3.2.3 Recursos visuais utilizados

Após a investigação de outras ferramentas visuais para o estudo de AM, com base no mapeamento sistemático descrito na Subseção 2.9, considerou-se imprescindível o uso de botões como principal recurso para promover a intuitividade da ferramenta. Isso se deve, principalmente, ao fato de que esse artifício permite que o usuário interaja com o processo sem a necessidade de escrever linhas de código. Dessa forma, espera-se que o usuário tenha maior foco na compreensão das explicações fornecidas em cada etapa do processamento de modelos de AM do que nos pormenores inerentes às linguagens de programação. Por meio dos botões, o usuário pode, por exemplo, confirmar suas escolhas, avançar entre etapas e exibir explicações adicionais (ou escondê-las para economizar espaço na tela). Além do uso de botões, a ferramenta também disponibiliza outros elementos visuais, como mostrado no Quadro 5, que especifica os recursos e apresenta exemplos de uso.

Alguns desses recursos podem ser visualizados na Figura 13, que ilustra parte da página inicial da ferramenta, destacando um trecho do *menu* expansível intitulado “Demonstração de elementos visuais e interativos oferecidos por esta ferramenta”. Nele, um estudo de caso sobre produtos de origem animal em uma fazenda fictícia é utilizado para exemplificar os recursos visuais e interativos oferecidos pela Visual-AM.

3.2.4 Funcionalidades da ferramenta

As funcionalidades oferecidas pela Visual-AM foram planejadas com base nas observações realizadas após o estudo de mapeamento sistemático, bem como nas experiências do autor desta pesquisa em seus primeiros contatos com a área do AM.

Para a evolução gradual da complexidade dos temas abordados, o conteúdo a ser estudado, por meio da ferramenta, foi dividido em tópicos distintos. Dessa forma, objetiva-se que o usuário seja introduzido a conceitos importantes no contexto do AM antes de avançar para as lições práticas. No Quadro 6, apresentam-se os resumos dos tópicos que compõem o conteúdo abordado pela aplicação.

Quadro 5. Outros recursos visuais utilizados. Fonte: O autor.

Recurso	Exemplo de utilização
Caixas de seleção	Seleção dos algoritmos de AM a serem utilizados no treinamento de modelos
<i>Menus de dropdown</i> (ou menus suspensos)	Seleção do tipo do <i>dataset</i> a ser utilizado
<i>Menus expansíveis</i>	Agrupamento de conteúdos explicativos que podem ser exibidos ou ocultos conforme a conveniência do usuário, a fim de manter a organização e evitar a poluição visual da página
Controles deslizantes (<i>sliders</i>)	Escolha da porcentagem de dados a serem utilizados para compor conjuntos de testes
Textos com diferentes formatações	Caixas de texto verdes para bons resultados, amarelas para pontos que merecem atenção e vermelhas para respostas erradas nos <i>quizzes</i>
Gráficos	Demonstração dos números de instâncias que compõem cada classe dos <i>datasets</i> utilizados nas atividades de classificação
Imagens estáticas	Diagrama de Venn para demonstração da relação entre IA, AM e DL
Imagens dinâmicas (ou GIFs, sigla do termo da língua inglesa <i>Graphics Interchange Format</i>)	Animação utilizada para exemplificar o processo de validação cruzada <i>k-fold</i>

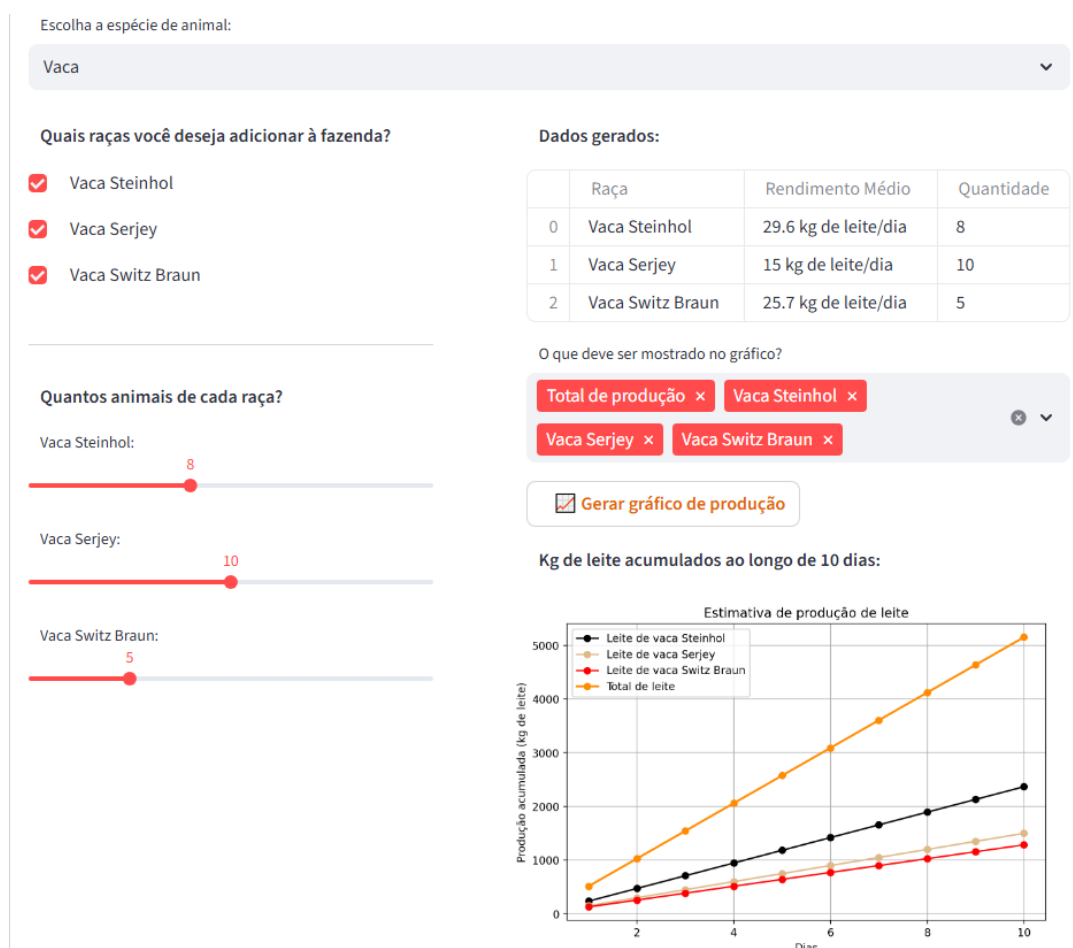


Figura 13. Demonstração de elementos visuais e interativos na página inicial. Fonte: O autor.

3.2.5 Relação entre os desafios e as soluções pedagógicas encontradas

Com base nos desafios apresentados na seção 2.10 e nos objetivos específicos deste trabalho, fundamentados na metodologia DSRM, a ferramenta Visual-AM foi projetada para estabelecer um vínculo direto entre as dificuldades comumente associadas ao estudo de AM e as soluções práticas concebidas pelos

autores. O Quadro 7 relaciona os desafios, os procedimentos pedagógicos e exemplos de funcionalidades da ferramenta, propostos com base nesses aspectos.

Quadro 6. Resumo dos tópicos disponíveis na ferramenta Visual-AM. Fonte: O autor.

Tópico	Descrição
Página inicial	Apresenta a ferramenta, seu propósito, recursos visuais e instruções para personalizar a interface do usuário.
Introdução: conceitos básicos	Fornece conceitos básicos sobre AM, IA, DL e os tipos de aprendizado supervisionado e não supervisionado.
Próximos passos: mãos à obra	Explica como os conceitos introdutórios serão aplicados nas práticas interativas, mencionando a progressão guiada e as influências das decisões do usuário.
Aprendizado supervisionado: classificação	Permite treinar e testar modelos de classificação em diferentes <i>datasets</i> , com apresentação de conceitos, separação do <i>dataset</i> em conjuntos de treino e teste, escolha de algoritmos, ajuste de hiperparâmetros, avaliação de desempenho e utilização do modelo para novas predições.
Aprendizado supervisionado: regressão	Similar ao tópico de classificação, mas focado na predição de valores contínuos, com algoritmos, gráficos e métricas apropriados para atividades de regressão.
Quiz sobre aprendizado supervisionado	Quiz com perguntas sobre classificação e regressão, com <i>feedback</i> imediato e sorteio de questões.
Aprendizado não supervisionado: clusterização	Apresenta conceitos de clusterização e permite personalizar algoritmos antes do treinamento para formar agrupamentos de dados a partir do <i>dataset</i> escolhido, além de oferecer visualização gráfica dos resultados.
Aprendizado não supervisionado: redução de dimensionalidade	Demonstra o funcionamento do PCA na redução da dimensionalidade do <i>dataset</i> escolhido, utilizando imagens estáticas e dinâmicas (GIFs) para apresentar conceitos importantes, como a variância e os componentes principais. Por fim, os resultados obtidos com a redução de dimensionalidade são apresentados em gráficos.
Quiz sobre aprendizado não supervisionado	Quiz com perguntas sobre clusterização e redução de dimensionalidade, com resultados imediatos e sorteio de questões.

Quadro 7. Desafios, procedimentos pedagógicos e exemplos de funcionalidades da Visual-AM (continua). Fonte: O autor.

Desafio	Procedimento Pedagógico	Exemplo de abordagem na Visual-AM
Dificuldade de compreensão dos conceitos fundamentais de AM	Introdução progressiva com apoio multimídia	Tópico de Introdução: uso de textos, imagens, GIFs e tabelas para a apresentação gradual dos conceitos básicos de AM, IA, DL e dos tipos de AM.
Complexidade na configuração de hiperparâmetros e visualização de seus efeitos	Exploração visual interativa	Tópicos de aprendizado supervisionado e não supervisionado: <i>sliders</i> e caixas de seleção para ajuste de hiperparâmetros por meio de cliques simples, com gráficos e atualização de métricas em tabelas.
Dificuldade em compreender algoritmos de forma conceitual	Animações e visualização de processos internos	Tópico de redução de dimensionalidade: demonstração do processo por meio de GIFs que ilustram a técnica de padronização e a busca por componentes principais.
Dificuldade em conectar teoria à prática	Estudo baseado em experimentação	Tópico de clusterização: os algoritmos K-Means e Agrupamento Aglomerativo Hierárquico são apresentados, juntamente com recursos teóricos que embasam a tomada de decisão, como o método <i>Elbow</i> ou dendrogramas, a fim de auxiliar na escolha do número de clusters (K). Após o treino, gráficos permitem ao usuário avaliar criticamente os agrupamentos formados para auxiliar a tomada de decisão quanto à necessidade de ajuste de K ou outros hiperparâmetros para melhora dos resultados.

Dificuldade de engajamento	Desafios interativos	<i>Quizzes</i> sobre aprendizado supervisionado e não supervisionado: possibilidade de refazer testes ilimitadas vezes, com questões aleatórias e <i>feedback</i> imediato. Tópicos de regressão: mensagens de orientação e <i>feedback</i> ao longo do processo para obter modelos melhores.
Dificuldade em comparar abordagens e métodos	Comparação integrada de modelos e métricas	Tópicos de aprendizado supervisionado: visualização de tabelas que comparam os resultados do treinamento de múltiplos modelos.
Falta de proficiência em matemática e programação	Minimização da carga cognitiva e uso de recursos multimodais	Tópicos de aprendizado supervisionado: interface <i>no-code</i> focada em explicações textuais simplificadas e recursos visuais complementares. Fórmulas matemáticas são mostradas apenas como explicações extras para usuários que queiram se aprofundar no tema.

Ao conectar cada funcionalidade a um desafio específico, a ferramenta demonstra seu caráter pedagógico, utilizando recursos como exploração visual interativa, execução de processos passo a passo e comparações integradas para superar obstáculos técnicos e conceituais relacionados ao estudo da ciência do AM.

3.2.6 *Datasets* disponibilizados

A ferramenta possui dez opções de *datasets* que podem ser utilizadas conforme o tipo de tarefa. No Quadro 8, são apresentados os nomes, as descrições e as origens dos *datasets* disponibilizados.

Quadro 8. Apresentação dos *datasets* incorporados à Visual-AM (continua). Fonte: O autor.

Nome	Descrição	Procedência
<i>Pima Indians Diabetes</i> (balanceado)	Contém dados médicos coletados de mulheres da população indígena nativo-americana Pima. Seu objetivo é classificar pacientes como diabéticos ou não.	O <i>dataset</i> “ <i>Pima Indians Diabetes</i> ”, originalmente coletado pelo NIDDK (<i>National Institute of Diabetes and Digestive and Kidney Diseases</i>), foi disponibilizado pelo perfil <i>UCI Machine Learning Repository</i> na plataforma <i>Kaggle</i> (<i>UCI MACHINE LEARNING REPOSITORY</i> , 2016). Previamente à sua incorporação à Visual-AM o <i>dataset</i> original foi submetido a um balanceamento de classes e sua versão balanceada foi disponibilizada pelo autor em um repositório do <i>GitHub</i> (DA SILVA, 2025).
Autenticação de cédulas	Contém estatísticas numéricas extraídas de imagens digitalizadas de notas bancárias, obtidas por meio de um <i>scanner</i> , e tem como objetivo classificar notas como autênticas ou falsificadas.	Esse conjunto de dados foi criado com base no <i>dataset</i> “ <i>Banknote Authentication</i> ”, disponibilizado no <i>UCI Machine Learning Repository</i> (LOHWEG, 2013). Previamente à sua incorporação à Visual-AM, o <i>dataset</i> original foi reescalonado, teve suas classes balanceadas e suas colunas traduzidas, o que deu origem ao <i>dataset</i> “Autenticação de cédulas”, disponibilizado pelo autor em um repositório no <i>GitHub</i> (DA SILVA, 2025).

<i>Iris</i>	Contém medidas de comprimento e largura de pétalas e sépalas de três diferentes espécies de flores do gênero iris para classificá-las como setosa, versicolor ou virginica.	<i>Dataset</i> originalmente coletado por Fisher (1936) e disponibilizado pela biblioteca <i>Scikit-learn</i> (PEDREGOSA <i>et al.</i> , 2011).
<i>Seeds</i>	Dispõe de medidas físicas (como área, perímetro, compacidade e simetria do grão) de amostras de três tipos diferentes de grãos de trigo para classificá-las como kama, rosa e canadian.	<i>Dataset</i> disponibilizado no <i>UCI Machine Learning Repository</i> (CHARYTANOWICZ <i>et al.</i> , 2012).
Uvas <i>Phomtsen</i>	Contém dados sobre a variedade fictícia de uvas Phomtsen, dispondo de características físico-químicas: peso, teor de açúcar e acidez, que podem ser utilizados para prever o valor numérico da coluna-alvo, que é o índice de qualidade, representado por uma nota de 0 a 10.	Esse <i>dataset</i> foi criado sinteticamente pelo autor e disponibilizado em um repositório do <i>GitHub</i> (DA SILVA, 2025).
Aluguéis Ijabatá	Contém dados sobre apartamentos da cidade fictícia de Ijabatá, incluindo características dos imóveis, como o número de quartos e banheiros, que podem ser usados para estimar o valor mensal do aluguel.	Esse <i>dataset</i> foi criado sinteticamente pelo autor e disponibilizado em um repositório do <i>GitHub</i> (DA SILVA, 2025).
<i>Mall Customers</i>	Dispondo de dados sobre clientes de <i>shopping</i> , como idade e renda anual, esse <i>dataset</i> pode ser utilizado para agrupar clientes com base em suas características demográficas e hábitos de consumo.	<i>Dataset</i> disponibilizado na plataforma <i>Kaggle</i> (2017).

<i>Wine</i>	Contém características químicas de vinhos, como teor alcoólico, intensidade de cor e concentração de prolina, por exemplo. Embora esse <i>dataset</i> originalmente contenha rótulos que indicam a classe de cada vinho, eles não são utilizados na atividade de clusterização da ferramenta, já que o objetivo é utilizá-lo para uma análise de agrupamentos não supervisionados.	<i>Dataset</i> doado por Aeberhard e Forina ao <i>UCI Machine Learning Repository</i> (1991) e disponibilizado pela biblioteca <i>Scikit-learn</i> (PEDREGOSA et al., 2011)
Frutas	Contém dados sobre variedades fictícias de maçãs, peras e pêssegos, sendo seu objetivo demonstrar a redução de dimensionalidade com base nas características físico-químicas de massa, teor de açúcar e acidez.	Esse <i>dataset</i> foi criado sinteticamente pelo autor e disponibilizado em um repositório do <i>GitHub</i> (DA SILVA, 2025).
Animais	Contém dados sintéticos sobre aves, mamíferos, répteis e insetos. Seu objetivo é demonstrar a redução de dimensionalidade com base nas características fisiológicas: massa corporal, frequência cardíaca e temperatura corporal.	Esse <i>dataset</i> foi criado sinteticamente pelo autor e disponibilizado em um repositório do <i>GitHub</i> (DA SILVA, 2025).

3.3 Tópicos de estudo presentes na ferramenta

Nas subseções a seguir, são apresentadas, de forma mais detalhada, as descrições dos tópicos que compõem o conteúdo abordado pela Visual-AM.

3.3.1 Página inicial

Descreve a ferramenta e o porquê de sua criação. Além disso, demonstra, por meio de um estudo de caso, os recursos visuais e interativos oferecidos pela Visual-AM. Também são apresentadas algumas das principais bibliotecas *Python* utilizadas para o seu funcionamento e, por fim, são fornecidas instruções para personalizar a aparência da interface gráfica.

A Figura 14 mostra a página inicial com seus *menus* expansíveis recolhidos.




Figura 14. Página inicial da Visual-AM. Fonte: O autor.

3.3.2 Introdução: conceitos básicos

Inclui imagens, GIFs, textos e tabelas que introduzem o usuário a conceitos importantes relacionados ao AM e aos tipos de dados que serão trabalhados ao longo do uso da aplicação. Entre os temas abordados, estão: uma explicação do que

é o AM; suas relações com a IA e o DL; uma introdução aos tipos de AM supervisionado e não supervisionado; e as etapas nas quais se divide o processamento de modelos.

A Figura 15 apresenta uma parte do tópico de introdução da Visual-AM. Nela, está aberto apenas o menu expansível “Tipos de AM”, que dispõe de botões para mostrar ou esconder explicações sobre os tipos de AM supervisionado e não supervisionado.




Figura 15. Tópico de introdução da Visual-AM. Fonte: O autor.

3.3.3 Próximos passos: mãos à obra!

Essa seção indica ao usuário que os conceitos abordados na introdução servirão de fundamento para a compreensão das atividades práticas a serem realizadas nas seções seguintes. Nessa parte, informa-se que explicações sobre as técnicas utilizadas no processamento de modelos de AM serão fornecidas gradualmente, à medida que o usuário confirmar que deseja prosseguir com o

processamento dos modelos de AM. Também é informado que, durante esses processos, será permitido ao usuário tomar decisões que impactarão diretamente os resultados obtidos pelos modelos de AM desenvolvidos.

A Figura 16 apresenta uma captura de tela do tópico “Próximos passos: mãos à obra!”.



Figura 16. Tópico “Próximos passos: mãos à obra!”. Fonte: O autor.

3.3.4 Aprendizado supervisionado: classificação

Nessa seção, são abordadas técnicas de aprendizado supervisionado para tarefas de classificação. Os objetos de estudo utilizados nesta parte são quatro *datasets* com múltiplas colunas: dois para tarefas de classificação binária e outros dois para tarefas de classificação multiclasse. A escolha do *dataset* a ser utilizado fica a cargo do usuário, mas recomenda-se que todos sejam utilizados para aprimorar a prática e consolidar os conhecimentos. Após a visualização do *dataset*

para entendimento do contexto do problema, realiza-se a etapa de análise, na qual se verifica a possibilidade de os conjuntos apresentarem dados faltantes, dividem-se os dados em entradas e saídas e separa-se o conjunto em dados de treino e de teste. A Figura 17 ilustra o estágio do processo em que os dados são divididos em conjuntos de treino e de teste.




Figura 17. Divisão dos dados em conjuntos de treino e de teste. Fonte: O autor.

Em seguida, realiza-se a etapa de treinamento, na qual, após receber explicações que embasam a tomada de decisão, o usuário especifica os algoritmos e os hiperparâmetros a serem utilizados na construção de modelos. O treinamento é realizado com validação cruzada para obter valores de métricas de classificação que permitem avaliar o desempenho dos modelos treinados, com base na métrica de desempenho selecionada pelo usuário.

A Figura 18 apresenta a seleção dos algoritmos a serem utilizados, realizada por meio de caixas de seleção. A Figura 19 mostra os recursos visuais que controlam o número de subconjuntos (*folds*) do processo de validação cruzada e a métrica a ser utilizada para validar os modelos.

Escolha abaixo os algoritmos que deseja utilizar:

- ☒ Logistic Regression (Regressão logística)
- ☐ K-Nearest Neighbors (K-vizinhos próximos)
- ☒ Decision Tree (Árvore de decisão)
- ☐ MLP Classifier (Multilayer Perceptron)
- ☒ SVC (Support Vector Machine para classificação)

Figura 18. Escolha dos algoritmos de classificação. Fonte: O autor.

Opcionalmente, você pode clicar no botão abaixo para mostrar/esconder explicações a das métricas de avaliação para problemas de classificação.

 Explicação sobre métricas de avaliação para problemas de classificação

Marque abaixo a métrica que deseja utilizar para escolher o melhor modelo:

Acurácia 

Escolha um valor de K (número de folds) para realizar a validação cruzada:



Com base nas opções selecionadas, o botão abaixo iniciará a execução do treinamento (com validação cruzada de 5 folds) para a obtenção de um modelo que apresente um maior valor de Acurácia entre os modelos instanciados acima.

 Executar treinamento

Figura 19. Configurações de treinamento no tópico de classificação. Fonte: O autor.

Ainda na etapa de treinamento, o modelo que mais se destaca entre todos os treinados é submetido a um processo de busca em grade, no qual o usuário pode escolher diferentes hiperparâmetros para tentar obter um modelo com desempenho

superior ao do melhor da etapa anterior (utilizando o mesmo algoritmo). A Figura 20 ilustra o momento de escolha dos hiperparâmetros a serem testados na busca em grade.

Seleção de hiperparâmetros para o Multi-layer Perceptron (MLP)

solver

lbfgs

adam

☒ Selecionar todos (solver)

hidden_layer_sizes (1ª)

100 ×

☐ Selecionar todos (hidden_layer_sizes (1ª))

hidden_layer_sizes (2ª)

100 × 0 ×

☐ Selecionar todos (hidden_layer_sizes (2ª))

max_iter

200 ×

☐ Selecionar todos (max_iter)

Clique no botão abaixo caso deseje mostrar/esconder explicações a respeito dos hiperparâmetros desse algoritmo.

+/- Explicações dos hiperparâmetros do Multi-layer Perceptron (MLP)

Figura 20. Escolha dos hiperparâmetros antes da busca em grade. Fonte: O autor.

Após a execução da busca em grade, o modelo com melhor desempenho (melhor modelo) é salvo e levado para a fase de testes, na qual se utiliza o conjunto previamente separado para testes para avaliar o desempenho do modelo em dados não vistos, permitindo a visualização de matrizes de confusão e de métricas de classificação. Caso o usuário tenha escolhido algum dos *datasets* de classificação binária, também é explicado o passo a passo para a obtenção da curva ROC e da área AUC, visualizadas em gráficos. Ao final da seção, é permitido que o usuário forneça novos dados ao melhor modelo para a predição de uma classe com base nos dados de entrada, como mostrado na Figura 21, que representa a etapa de aplicação do modelo para predições.

No Apêndice E, as Figuras 62, 63 e 64 apresentam os diagramas de atividades UML correspondentes à implementação do tópico de classificação da Visual-AM.

Forneça nos campos abaixo as especificações da flor de íris.

Escolha um valor para `sepal length (cm)` :

6.70

Escolha um valor para `sepal width (cm)` :

3.20

Escolha um valor para `petal length (cm)` :

3.97

Escolha um valor para `petal width (cm)` :

1.60

Realizar predição!

De acordo com o modelo que treinamos, a flor de íris com essas características provavelmente é da espécie:

versicolor (1)

Confiança do modelo nesta predição: 97.91%

Figura 21. Predição de classe com novos dados. Fonte: O autor.

3.3.5 Aprendizado supervisionado: regressão

De forma semelhante à descrita na seção anterior, o tópico de regressão aborda conceitos e técnicas de aprendizado supervisionado aplicados a tarefas de

regressão. Os objetos de estudo utilizados nessa parte são dois *datasets* que contêm múltiplas colunas, utilizadas para a predição de valores numéricos referentes aos seus atributos de saída. A escolha do *dataset* a ser utilizado também fica a cargo do usuário, mas recomenda-se que ambos sejam utilizados para aprimorar a prática e consolidar melhor os conhecimentos. Após a visualização do *dataset* para o entendimento do contexto do problema, realiza-se a etapa de análise, na qual se verifica a possibilidade de haver dados faltantes nos conjuntos, se dividem os dados em entradas e saídas e se realiza a separação do conjunto em dados de treino e dados de teste. Em seguida, realiza-se o treinamento, etapa iniciada pela especificação dos algoritmos e dos hiperparâmetros a serem utilizados na construção de modelos. Após a definição das condições de treinamento, realiza-se a validação cruzada para obter valores de métricas de classificação que permitem avaliar o desempenho dos modelos treinados, tendo como base a métrica de desempenho selecionada pelo usuário.

A seleção de configurações para o treinamento com validação cruzada é ilustrada na Figura 22.

Marque abaixo a métrica que deseja utilizar para escolher o melhor modelo:

- R^2
- MAPE (%)
- MAE
- RMSE

MAE

Escolha um valor de K (número de folds) para realizar a validação cruzada:

5

Figura 22. Seleção de configurações para o treinamento de algoritmos de regressão. Fonte: O autor.

Ainda na etapa de treinamento, o modelo que mais se destaca em relação aos demais é submetido ao processo de busca em grade, no qual o usuário pode escolher diferentes hiperparâmetros para tentar obter um modelo com desempenho superior ao anterior (novamente, utilizando o mesmo algoritmo). Após a busca em grade, o melhor modelo é salvo e exibe-se um gráfico interativo de superfície de resposta, comparando os dados de treino com as previsões do modelo para esses mesmos dados durante o treinamento, como mostrado na Figura 23. Duas das dimensões desse gráfico tridimensional são utilizadas para mostrar os dados de entrada do *dataset* utilizado, enquanto a terceira dimensão (eixo z) representa os valores de saída. Como não é possível plotar todos os atributos (ou colunas) dos *datasets* em gráficos tridimensionais, as colunas restantes são parcialmente fixadas, mas controles deslizantes permitem variar seus valores. Em caso de alterações nesses valores, a Visual-AM realiza automaticamente uma nova plotagem do gráfico de superfície de resposta.




Figura 23. Gráfico de superfície de resposta. Fonte: O autor.

Em seguida, o melhor modelo é levado para a fase de testes, na qual se utiliza o conjunto previamente separado para avaliar o desempenho do modelo em dados não vistos. Para esse propósito, realizam-se testes e os resultados são apresentados por meio de métricas de regressão e de um gráfico de dispersão que relaciona valores reais e valores preditos, como mostrado na Figura 24.




Figura 24. Exemplo de gráfico de valores previstos *versus* valores reais. Fonte: O autor.

Ao final do tópico, o usuário pode fornecer novos dados ao modelo de melhor desempenho, o que representa a etapa de aplicação, na qual o modelo é utilizado para prever valores de saída estimados com base nos dados de entrada.

No Apêndice E, as Figuras 65, 66 e 67 apresentam os diagramas de atividades UML correspondentes à implementação do tópico de regressão da Visual-AM.

3.3.6 Quiz sobre aprendizado supervisionado

Este tópico consiste em um *quiz* com cinco perguntas de múltipla escolha sobre aprendizado supervisionado, mais especificamente sobre técnicas de classificação e regressão. Cada uma das cinco perguntas tem cinco alternativas de resposta para que o usuário marque a opção correta. Ao final das perguntas, é exibido o resultado do *quiz*, com a nota do usuário e as respostas corretas. O teste pode ser refeito um número ilimitado de vezes e os resultados não são salvos. Além disso, um vasto banco de perguntas permite que apenas algumas sejam sorteadas a cada execução do *quiz*, tornando, portanto, aleatória a escolha das questões exibidas ao usuário.

A Figura 25 mostra uma captura de tela do tópico “Quiz sobre aprendizado supervisionado”, obtida após a simulação de uma resposta incorreta.

Pergunta 1: Qual é um exemplo de tarefa de aprendizado supervisionado?

Selecione a opção correta

- ☐ Agrupamento de clientes
- ☐ Redução de dimensionalidade
- ☐ Agrupamento de vinhos de acordo com sua característica físico-químicas
- ☐ Classificação de espécies de vegetal a partir de suas medidas
- ☒ Aprendizagem reforçada por recompensas por acertos

Incorreto! A resposta correta é: Classificação de espécies de vegetal a partir de suas medidas

Próxima Pergunta

Os resultados não serão salvos e você pode refazer este quiz quantas vezes quiser

Figura 25. Pergunta do tópico “Quiz sobre aprendizado supervisionado”. Fonte: O autor.

3.3.7 Aprendizado não supervisionado: clusterização

Neste tópico, o usuário poderá escolher entre dois *datasets* para a clusterização. Em ambos os casos, são utilizadas apenas três colunas de dados para alimentar os algoritmos de treinamento, visando utilizar um gráfico 3D interativo para facilitar a compreensão da influência de cada atributo sobre os agrupamentos formados ao final do processo.

O primeiro passo desse tópico é a escolha do *dataset* pelo usuário, seguida de sua contextualização. Em seguida, são apresentados os dois algoritmos de clusterização disponíveis para o treinamento. Após a escolha do algoritmo a ser utilizado, o usuário deve definir seus hiperparâmetros para a execução do treinamento, conforme ilustrado na Figura 26.

Você quer executar o KMeans com seus hiperparâmetros padrão ou prefere personalizá-los?

Personalizar

Configure os hiperparâmetros desejados:

n_clusters	init	n_init	max_iter
4	k-means++	10	10

Combinação selecionada: `KMeans(n_clusters=4, init='k-means++', n_init=10, max_iter=10)`

Executar treinamento

Figura 26. Definição dos hiperparâmetros de um algoritmo de clusterização. Fonte: O autor.

Em seguida, podem ser visualizados os resultados por meio do gráfico 3D supracitado e também de gráficos 2D que relacionam cada par de características utilizadas no treinamento. A Figura 27 mostra os agrupamentos obtidos a partir de uma das possíveis combinações de hiperparâmetros de um dos algoritmos de clusterização.




Figura 27. Agrupamentos formados por meio de um dos algoritmos de clusterização. Fonte: O autor.

Além disso, apresenta-se uma tabela que indica quais amostras são contempladas por cada agrupamento e também são citados exemplos de finalidades para as quais os agrupamentos formados poderiam ser utilizados.

No Apêndice E, a Figura 68 apresenta o diagrama de atividades UML correspondente à implementação do tópico de clusterização da Visual-AM.

3.3.8 Aprendizado não supervisionado: redução de dimensionalidade

Nesta seção, o usuário será introduzido aos conceitos de redução de dimensionalidade por meio do algoritmo PCA. Para uma visualização clara do processo, serão utilizados apenas *datasets* com três colunas, permitindo a visualização das etapas em gráficos 3D. Este tópico se inicia com breves introduções à técnica de redução de dimensionalidade e ao algoritmo PCA. Em seguida, é permitido ao usuário escolher um *dataset* para utilizar. Como uma boa prática prévia à utilização do PCA é a padronização dos dados, essa técnica também é apresentada ao usuário, que pode visualizar a transformação dos dados por meio de GIFs que representam os gráficos tridimensionais dos dados originais e dos dados padronizados. Em seguida, são apresentados os conceitos de “variância” e “componentes principais”, essenciais ao funcionamento do PCA. Então, o usuário comanda a execução do algoritmo PCA e são mostrados, um por um, GIFs que ilustram a busca do algoritmo pelas direções nas quais os dados apresentam maior variância, para assim formar os componentes principais, utilizados para permitir a redução de dimensionalidade. A Figura 28 apresenta diferentes *frames* (quadros) da imagem dinâmica que ilustram a formação do primeiro componente principal obtido pelo PCA. Já a Figura 29 apresenta *frames* de outras imagens dinâmicas que ilustram o processo de formação dos demais componentes principais do PCA.

Na etapa seguinte, são apresentados tabelas e gráficos que ilustram como os dados podem ser projetados em novos eixos (formados pelos componentes principais), como se vê na Figura 30, que representa a projeção dos dados nos componentes principais 1 e 2. Para melhorar a visualização, apenas algumas amostras foram indicadas no gráfico, com seus respectivos índices, que correspondem à ordem de aparição das linhas de cada amostra no *dataset*.




Figura 28. Formação do primeiro componente principal. Fonte: O autor.




Figura 29. Formação de outros componentes principais. Fonte: O autor.




Figura 30. Formação de outros componentes principais. Fonte: O autor.

Em seguida, por meio de gráficos de *biplot*, são apresentadas explicações sobre como cada variável original contribui para os novos eixos. A Figura 31 mostra o *biplot* resultante de uma das combinações de componentes principais de um dos *datasets* utilizados.




Figura 31. *Biplot* de uma combinação de componentes principais. Fonte: O autor.

Por fim, demonstra-se que é possível reverter parcialmente a transformação dos dados, adaptando-os novamente ao número original de dimensões. Para isso, utiliza-se um gráfico 3D interativo que compara os dados originais aos resultantes da reconstrução por PCA após a redução, como mostrado na Figura 32.




Figura 32. Reconstrução dos dados. Fonte: O autor.

No Apêndice E, a Figura 69 apresenta o diagrama de atividades UML correspondente à implementação do tópico de redução de dimensionalidade da Visual-AM.

3.3.9 Quiz sobre aprendizado não supervisionado

Esse tópico consiste em um *quiz* com cinco perguntas de múltipla escolha sobre aprendizado não supervisionado, mais especificamente sobre técnicas de clusterização e de redução de dimensionalidade com PCA. Assim como no *quiz* de aprendizado supervisionado, cada uma das cinco perguntas desse tópico apresenta

cinco alternativas de resposta para que o usuário marque a opção correta. Ao final das perguntas, é revelado o resultado do *quiz*, mostrando a nota do usuário e as respostas corretas às perguntas. Esse teste também tem perguntas sortidas, podendo ser refeito um número ilimitado de vezes, e os resultados não são salvos. Na Figura 33, é mostrada uma parte do *feedback* gerado pela ferramenta após a finalização do *quiz*, simulando um caso em que o usuário teve desempenho mediano.

Quiz sobre aprendizado não supervisionado
Responda às questões e verifique as respostas corretas antes de avançar

Quiz finalizado! Sua pontuação: 3/5

Pergunta 1: Quais são algumas aplicações comuns do aprendizado não supervisionado?

Sua resposta: Todas as anteriores

Correto!

Resposta correta: Todas as anteriores

Pergunta 2: Qual é a diferença entre clusterização e classificação?

Sua resposta: Clusterização é não supervisionada, enquanto classificação é supervisionada.

Figura 33. Quiz de aprendizado não supervisionado. Fonte: O autor.

Capítulo 4

AVALIAÇÃO DA FERRAMENTA

Este capítulo é dedicado à caracterização do método de avaliação da ferramenta desenvolvida nesta pesquisa, bem como à descrição dos participantes do estudo e de suas opiniões a respeito dela.

4.1 Metodologia de avaliação

Considerando o caráter exploratório desta pesquisa e sua aplicação em um contexto interdisciplinar, a avaliação da ferramenta foi conduzida com um grupo reduzido de participantes estrategicamente selecionados. Os resultados obtidos não têm finalidade de generalização estatística, mas sim de fornecer evidências exploratórias acerca da percepção discente sobre o uso da ferramenta. Após o desenvolvimento da ferramenta, 10 discentes do curso de Engenharia de Bioprocessos, matriculados na disciplina optativa “Introdução à Ciência de Dados” — ofertada no segundo semestre de 2025 pelo Instituto de Recursos Naturais da UNIFEI, campus Itajubá (ementa detalhada no Apêndice A) — foram convidados a utilizá-la voluntariamente, de forma autônoma e remota, fora do ambiente de sala de aula, e, posteriormente, avaliá-la. A escolha por este grupo específico de discentes foi motivada por três fatores estratégicos:

- Perfil de usuário final ideal: O estudo visava avaliar a eficácia da ferramenta para usuários que não fossem especialistas em computação, mas que tivessem necessidades de análise de dados. Os alunos de Introdução à Ciência de Dados personificavam esse perfil por possuírem maturidade

técnica (advinda dos pré-requisitos das disciplinas “Introdução à Engenharia de Bioprocessos”, “Fundamentos de Programação” e “Bioinformática”), porém não possuíam o viés de formação profunda em algoritmos que as turmas de cursos como Ciência da Computação tradicionalmente possuem.

- Natureza da disciplina: Por ser uma disciplina optativa e interdisciplinar, o quórum tende a ser naturalmente reduzido, mas composto por alunos que demonstram interesse específico pela temática da ferramenta, o que qualifica o *feedback* coletado.
- Viabilidade e engajamento: O recrutamento foi viabilizado pelo fato de a disciplina ser ministrada pelo coorientador deste trabalho. Essa proximidade permitiu uma comunicação direta sobre o convite voluntário, garantindo que os participantes compreendessem o propósito acadêmico da avaliação.

Aos alunos voluntários participantes desta pesquisa foi fornecido o Termo de Consentimento Livre e Esclarecido (Apêndice B), documento no qual foram descritos o propósito da pesquisa e a forma como os dados seriam tratados, de maneira confidencial. Por meio dele, os participantes foram informados sobre: a natureza voluntária do estudo, a garantia de anonimato dos dados coletados e a ausência de consequências caso decidissem interromper sua participação.

Após o preenchimento do Termo de Consentimento Livre e Esclarecido, os participantes deveriam se identificar e realizar autoavaliações (por exemplo, informar seus níveis de proficiência em AM e seu interesse em ferramentas visuais para estudos) antes de utilizar a ferramenta. Após o uso, eles deveriam descrever suas experiências pessoais com a Visual-AM, considerando aspectos como a facilidade de uso, a compreensão dos temas abordados e a adequação da apresentação do conteúdo. Para viabilizar a coleta dessas informações, optou-se pela elaboração de questionários que permitissem obter respostas pertinentes ao objetivo da pesquisa.

Devido à escassez literária de questionários com perguntas padronizadas para a avaliação de ferramentas visuais que facilitem estudos na área da computação, considerou-se adequada a utilização dos questionários desenvolvidos

por Pereira e Seabra (2023), aplicados na avaliação da ferramenta REA-LP, que consiste em um Recurso Educacional Aberto (REA) para estudos relacionados à disciplina de Lógica de Programação. Esses questionários investigam o perfil dos respondentes e suas reações ao uso e à aceitação da ferramenta, visando avaliar suas características pedagógicas de acordo com a Teoria do Aprendizado Construtivista de Gama (2007) e a Teoria Cognitiva da Aprendizagem Multimídia de Mayer (2005). Como o REA-LP é semelhante à ferramenta Visual-AM, no sentido de objetivar a facilitação dos estudos e a retenção do conhecimento em uma área da ciência da computação, e também dispõe de recursos visuais para essa finalidade, uma parte considerável dos questionários elaborados por Pereira e Seabra (2023) foi utilizada nesta pesquisa. Dessa forma, foi necessário realizar apenas ajustes pontuais para adaptar os questionários ao contexto de avaliação da ferramenta Visual-AM. Como resultados dessa adaptação, foram elaborados o Questionário de Identificação do Perfil do Respondente (Apêndice C) e o Questionário de Reação ao Uso e Aceitação da Ferramenta (Apêndice D). Para facilitar sua distribuição e aplicação, os questionários foram disponibilizados aos participantes pela plataforma *Jotform*, que permitiu que respondessem remotamente e no momento de sua preferência.

Para permitir uma interpretação conjunta dos resultados, as perguntas do Questionário de Reação ao Uso e Aceitação da Ferramenta foram organizadas em dimensões avaliativas propostas pelo autor desta dissertação, agrupando questões que abordam aspectos semelhantes. Cabe destacar que essas dimensões referem-se à percepção discente acerca da utilização e da aceitação da ferramenta, por meio de aspectos subjetivos, não contemplando mensurações objetivas de desempenho ou de ganho de aprendizagem. Desse modo, os dados foram distribuídos nas dimensões: “Fluidez Informacional”, que abrange questões sobre clareza e adequação do conteúdo para evitar dificuldades desnecessárias no estudo; “Facilidade de Uso”, voltada a avaliar o quão intuitiva foi a interação dos usuários com a ferramenta; “Contribuição dos Recursos Visuais”, que avalia a

eficácia dos recursos visuais em representar os conceitos de AM e facilitar o entendimento do conteúdo; “Sensação de Progresso”, que avalia a autopercepção do discente em relação ao avanço percebido em seus estudos; e “Engajamento”, que investiga o envolvimento e o interesse gerados pela utilização da Visual-AM.

4.2 Caráter da pesquisa

Este trabalho adotou uma abordagem de pesquisa que buscou explorar os perfis, as experiências e as percepções dos usuários quanto ao uso da ferramenta desenvolvida no estudo de AM. Para isso, previamente à utilização da ferramenta, os respondentes foram orientados a preencher o Questionário de Identificação do Perfil, cujo objetivo era mapear os perfis dos participantes, coletando informações sobre o acesso à tecnologia, a familiaridade com ferramentas educacionais e a experiência prévia com o conteúdo de AM. Já o Questionário de Reação e Aceitação foi aplicado após a realização dos estudos propostos pela ferramenta, com o intuito de avaliar as reações dos discentes e coletar suas opiniões sobre aspectos como a percepção de uso da Visual-AM, a clareza do conteúdo de AM e a eficácia da ferramenta em promover, possivelmente, o aprendizado.

Para alcançar esses objetivos, os questionários elaborados adotam uma abordagem quali-quantitativa, permitindo respostas baseadas em uma escala Likert de cinco pontos na maioria das questões e o compartilhamento de percepções qualitativas sobre suas experiências em todas as questões, as quais também dispõem de campos para respostas abertas.

De acordo com Johnson e Onwuegbuzie (2004), a combinação de técnicas quantitativas e qualitativas em uma mesma abordagem permite integrar as forças de ambas as metodologias, constituindo um método misto, que proporciona uma visão mais abrangente da experiência dos usuários. Por conseguinte, no contexto da avaliação da ferramenta Visual-AM, essa abordagem baseada em métodos mistos

permitiu coletar tanto dados estruturados sobre a percepção de uso quanto dados qualitativos provenientes de observações adicionais realizadas pelos respondentes, promovendo uma análise mais completa da ferramenta educacional.

Ademais, como esta pesquisa busca não apenas descrever as características da ferramenta Visual-AM, mas também fazer julgamentos sobre sua eficácia e utilidade como ferramenta educacional, ela também pode ser considerada como uma pesquisa avaliativa, conforme os conceitos propostos por Bassey (1999).

Portanto, este estudo caracteriza-se como uma pesquisa avaliativa de caráter misto, cujo foco é compreender como a ferramenta Visual-AM contribui para o estudo de conceitos de AM, avaliando aspectos como a percepção de uso, a clareza do conteúdo e o impacto no estudo, segundo as opiniões de discentes voluntários.

4.3 Execução da pesquisa

Durante os meses de outubro e novembro de 2025, foram enviados convites aos discentes da disciplina “Introdução à Ciência de Dados” da UNIFEI para participarem voluntariamente no estudo. Além de enviar convites, o coorientador desta dissertação, docente responsável pela disciplina, manteve contato frequente com os alunos para que permanecessem engajados no estudo.

O intervalo de tempo no qual foram registradas respostas aos questionários de avaliação da ferramenta teve início em 24 de outubro de 2025 e término em 16 de dezembro de 2025. Durante esse período, todos os discentes da disciplina preencheram o Questionário de Identificação do Perfil do Respondente e o Questionário de Reação ao Uso e Aceitação da Ferramenta.

Para mitigar o risco de ocorrência de problemas que pudessem prejudicar a utilização da ferramenta ou o preenchimento dos questionários, os contatos pessoais do autor e dos orientadores desta pesquisa foram disponibilizados para que os participantes do estudo pudessem relatar eventuais problemas técnicos.

Entretanto, nenhum incidente foi relatado pelos respondentes durante a condução deste estudo.

Capítulo 5

RESULTADOS

Este capítulo é dedicado à apresentação dos resultados da pesquisa de avaliação da ferramenta. Inicialmente, as respostas individuais dos participantes foram examinadas de forma descritiva. Em seguida, procedeu-se à quantificação dos dados, o que permitiu a realização de investigações exploratórias e a obtenção de evidências preliminares acerca da percepção discente quanto à utilização e à aceitação da ferramenta. As análises incluíram a identificação de possíveis correlações e a organização dos itens dos questionários em dimensões avaliativas para a síntese dos resultados.

5.1 Análise descritiva das respostas aos questionários

Inicialmente, foi realizada uma análise descritiva das respostas a cada questão dos questionários, por meio de gráficos e discussões individuais.

5.1.1 Perfil dos participantes

Por meio do Questionário de Identificação de Perfil, foi possível caracterizar a amostra de participantes quanto a aspectos gerais, como a familiaridade com tecnologias e o conhecimento prévio em AM.

Para preservar a natureza sigilosa deste estudo, os nomes dos participantes foram substituídos nesta dissertação por identificações genéricas correspondentes à ordem de preenchimento dos questionários. A título de exemplo, o primeiro participante registrado foi nomeado como “Respondente#01” e o último como “Respondente#10”.

Após fornecerem seus nomes para identificação interna, os participantes foram solicitados a informar o gênero com que se identificavam na Questão 1.1, podendo escolher entre “Masculino”, “Feminino” ou as opções “Outro” e “Prefiro não informar”, destinadas a participantes que não se identificavam com as categorias apresentadas ou preferiram não declarar seu gênero. As respostas a essa pergunta são apresentadas na Figura 34.




Figura 34. Distribuição de gênero dos participantes. Fonte: O autor.

Conforme observado no gráfico de distribuição de gênero, a amostra apresentou equilíbrio entre os gêneros masculino e feminino, com 50% dos participantes em cada categoria, o que contribuiu para evitar predominância de respostas associadas a grupos com maior representatividade. Nenhum participante selecionou opções não binárias.

Por meio da Questão 1.2, verificou-se que todos os respondentes possuíam acesso à *internet* em casa, conforme mostrado no gráfico da Figura 35.




Figura 35. Condições de acesso à *internet*. Fonte: O autor.

Os dispositivos por meio dos quais os respondentes se conectavam à *internet* foram revelados na Questão 1.3, cujas respostas são apresentadas na Figura 36.

O diagrama da Figura 36 mostra que todos os participantes do estudo possuíam pelo menos um *smartphone* para se conectar à *internet*. Além disso, também nota-se que todos eles possuíam algum tipo de computador, entre *notebooks (laptops)* ou computadores de mesa (*desktops*).

As Questões 1.4 e 1.5 foram utilizadas para mensurar os níveis de familiaridade dos respondentes com AM antes do contato com a Visual-AM e suas respostas são apresentadas nas Figuras 37 e 38.

A Questão 1.4 revelou que a maioria dos respondentes nunca havia utilizado qualquer tipo de ferramenta visual para o estudo de AM antes deste estudo. Na Questão 1.5, verificou-se que a maioria dos participantes considerava seu nível de conhecimento em AM como “regular”, “ruim” ou “péssimo”. As respostas a ambas as questões condizem com o nível de *expertise* esperado para a amostra de participantes, já que estes cursavam uma graduação com pouca ênfase em áreas como IA ou AM.

Questão 1.3: Quais dos dispositivos eletrônicos que se conectam à internet você possui?




Figura 36. Dispositivos que se conectam à *internet*. Fonte: O autor.

Questão 1.4: Você já teve a oportunidade de utilizar uma ferramenta visual web para estudo de aprendizado de máquina antes desta pesquisa?




Figura 37. Contato prévio com ferramentas visuais para estudo de AM. Fonte: O autor.

Questão 1.5: No momento de realização desta pesquisa, como você considera seu conhecimento sobre aprendizado de máquina?




Figura 38. Níveis prévios de conhecimento em AM. Fonte: O autor.

Por meio da Questão 1.6, mensurou-se a frequência com que os respondentes utilizavam a *internet* para estudos. As respostas quantitativas a essa questão são apresentadas no gráfico da Figura 39, que indica que a grande maioria dos participantes utilizava a *internet* diariamente para esse fim.

Questão 1.6: Você usa frequentemente a Internet para os estudos?




Figura 39. Utilização da *internet* para estudos. Fonte: O autor.

O único respondente que não marcou a opção “Sim, diariamente” fez o seguinte comentário:

- **Respondente#01:** *“Ultimamente reduzi um pouco a frequência, mas há pouco tempo utilizava diariamente. É a principal ferramenta de estudo que utilizo”.*

A Questão 1.7 foi utilizada para mensurar o nível de interesse dos respondentes em acessar gratuitamente uma ferramenta visual *web* para o estudo de AM a qualquer momento. As respostas objetivas a essa questão são apresentadas na Figura 40.

Questão 1.7: Gosta da ideia de poder acessar em casa uma ferramenta visual *web* para estudo de aprendizado de máquina a qualquer hora, quando precisar e sem custo?




Figura 40. Opiniões sobre a oportunidade de utilizar uma ferramenta visual *web* gratuitamente. Fonte: O autor.

Quase todos os participantes manifestaram total concordância com essa ideia. Sobre essa questão, um dos participantes fez o seguinte comentário:

- **Respondente#05:** *“Sim, pois facilita o aprendizado, permitindo estudar no meu próprio ritmo, em qualquer momento e sem custos adicionais.”*

Com base nas respostas obtidas, é possível inferir a existência de demanda por ferramentas como o Visual-AM.

As perguntas e respostas objetivas ao Questionário de Identificação do Perfil podem ser resumidas na Figura 41.




Figura 41. Resumo das questões e respostas ao Questionário de Identificação de Perfil. Fonte: O autor.

5.1.2 Reação ao uso e aceitação da ferramenta

Por meio do Questionário de Reação ao Uso e Aceitação da Ferramenta, foi possível obter as opiniões dos respondentes sobre a Visual-AM, o que permitiu uma análise sistemática dos pontos fortes e fracos da ferramenta.

Como os dois questionários do presente estudo foram concebidos para serem respondidos em momentos distintos, foi solicitado aos participantes que fornecessem novamente seus nomes para identificação interna. Assim como no Questionário de Identificação do Perfil, os nomes foram substituídos por identificações genéricas, mantendo-se a ordenação, de modo que o “Respondente#01” do Questionário de Reação ao Uso e Aceitação da Ferramenta corresponde ao mesmo indivíduo identificado como “Respondente#01” no Questionário de Identificação do Perfil; e o mesmo vale para todos os outros respondentes.

Após a identificação para a unificação dos questionários, foram iniciadas as perguntas sobre a experiência com a ferramenta, começando pela Questão 2.01, que avaliou o nível de compreensibilidade e facilidade de manuseio da ferramenta. As respostas quantitativas a essa questão são apresentadas na Figura 42.




Figura 42. Compreensibilidade e facilidade de manuseio. Fonte: O autor.

Todos os respondentes concordaram que a ferramenta é compreensível e de fácil manuseio, sendo maioria a parcela que opinou como “concordo totalmente”. Também foram registradas as seguintes opiniões qualitativas nessa questão:

- **Respondente#03:** “*Bem didático, explicações simples e ótimos exemplos.*”
- **Respondente#10:** “*A Visual-AM é bem organizada e intuitiva. O menu lateral facilita encontrar os tópicos, e os conteúdos em seções ajudam a acompanhar sem se perder. Em geral, consegui navegar e entender o fluxo sem dificuldades.*”

Na Questão 2.02, perguntou-se aos usuários se a Visual-AM despertou o interesse pelos conteúdos de AM. As respostas objetivas a essa pergunta podem ser visualizadas na Figura 43.




Figura 43. Interesse despertado por conteúdos de AM. Fonte: O autor.

A maioria dos participantes considerou que a Visual-AM despertou interesse pelos conteúdos de AM. Um dos participantes expressou a seguinte opinião sobre essa questão:

- **Respondente#10:** *“A forma como o conteúdo é apresentado, com organização por tópicos e uma abordagem mais visual/guia, despertou meu interesse em aprender mais sobre os conceitos de aprendizado de máquina e explorar os próximos módulos.”*

Na Questão 2.03, perguntou-se se os participantes consideraram que a Visual-AM auxiliou no entendimento dos conceitos de AM. As respostas quantitativas a essa pergunta são apresentadas na Figura 44.

Questão 2.03: O uso da Visual-AM auxiliou o entendimento de conceitos de aprendizado de máquina?




Figura 44. Entendimento de conceitos de AM. Fonte: O autor.

Todos os participantes concordaram que a Visual-AM auxiliou na compreensão dos conceitos de AM, com 80% expressando concordância total. O seguinte comentário foi feito nessa questão:

- **Respondente#10:** *“A organização por tópicos e a explicação passo a passo facilitaram a compreensão dos conceitos apresentados. A estrutura da aplicação ajudou a consolidar ideias-chave e a relacionar teoria com exemplos.”*

Na Questão 2.04, foi perguntado aos participantes se eles se sentiam confiantes ao utilizar a Visual-AM. As respostas objetivas a essa questão são apresentadas na Figura 45.


Questão 2.04: Você se sente confiante ao utilizar a Visual-AM?

Figura 45. Autoconfiança ao utilizar a Visual-AM. Fonte: O autor.

As respostas mostraram que a maioria dos usuários se sentiu confiante ao utilizar a ferramenta. Foram registradas duas respostas discursivas para essa pergunta, ambas feitas por participantes que responderam “concordo totalmente”:

- **Respondente#01:** *“Me sinto confiante ao usar a ferramenta, no entanto, por ser um conteúdo introdutório, não diria que, após estudar pelo Visual-AM, domino o assunto. Mesmo assim, é uma excelente maneira de explicar/introduzir conceitos.”*
- **Respondente#10:** *“A navegação é clara e a estrutura por tópicos facilita encontrar o que preciso. Senti segurança para explorar as seções e acompanhar o conteúdo sem dificuldade.”*

A Questão 2.05 perguntou aos participantes se acreditavam saber aplicar os conhecimentos transmitidos pela ferramenta em futuras experiências com AM. As respostas quantitativas a essa questão são apresentadas na Figura 46.

Questão 2.05: Você acredita que saberá usar o conhecimento adquirido por meio da Visual-AM em futuras práticas?




Figura 46. Expectativas de reaproveitar o conhecimento. Fonte: O autor.

A maioria dos respondentes manifestou acreditar que saberia aplicar os conhecimentos adquiridos por meio da Visual-AM em práticas futuras. Dois comentários discursivos foram manifestados sobre essa questão:

- **Respondente#01:** *“Sinto que eventualmente precisaria rever parte do conteúdo. A estrutura da aplicação (dividida em capítulos e tópicos) facilita essa revisão.”*
- **Respondente#10:** *“Os conteúdos apresentados fornecem uma base sólida e aplicável, e acredito que conseguirei utilizar os conceitos em atividades futuras, como interpretação de resultados, escolha de modelos e boas práticas iniciais de ML.”*

Diferentemente da Questão 2.04, que trata dos conceitos que fundamentam o estudo de AM, a Questão 2.06 perguntou aos participantes se sentiam que seus conhecimentos, em geral, sobre AM foram aprofundados por meio da Visual-AM. As respostas objetivas a essa questão são apresentadas na Figura 47.

Questão 2.06: Após utilizar a Visual-AM, você sente que aprofundou seus conhecimentos sobre aprendizado de máquina?




Figura 47. Aprofundamento de conhecimentos de AM. Fonte: O autor.

Todos os respondentes afirmaram ter aprofundado seus conhecimentos ao utilizar a ferramenta, e a maioria selecionou a opção “concordo totalmente”. Os seguintes comentários foram manifestados sobre essa questão:

- **Respondente#01:** “Já havia ouvido falar de alguns conceitos, mas o Visual-AM trouxe novos conteúdos. Os tópicos explicativos (optativos) contribuem nesse aprofundamento.”
- **Respondente#10:** “Concordo totalmente. A Visual-AM contribuiu para aprofundar meu entendimento, pois apresenta os conteúdos de forma organizada e progressiva, facilitando a consolidação dos conceitos e a conexão entre teoria e exemplos.”

Na Questão 2.07, foram coletadas as opiniões dos participantes sobre os recursos visuais disponibilizados pela Visual-AM. As respostas quantitativas a essa questão são apresentadas na Figura 48.




Figura 48. Opiniões sobre os recursos visuais. Fonte: O autor.

A maioria dos respondentes (70%) classificou os recursos visuais da ferramenta como “bons” e os 30% restantes como “excelentes”. Os seguintes comentários foram feitos sobre essa questão:

- **Respondente#01:** *“Uma sugestão seria disponibilizar a opção de pausar alguns dos GIFs, isso poderia contribuir para o entendimento/análise.”*
- **Respondente#04:** *“Algumas imagens estavam grandes demais para a tela, o que dificultou avaliar a imagem em conjunto com o texto que vinha antes.”*
- **Respondente#10:** *“Os recursos visuais são muito bons. As cores e a identidade visual são consistentes, o layout é agradável e bem organizado, e o tamanho do texto favorece a leitura. Os elementos visuais (imagens/GIFs e botões) ajudam a manter o conteúdo mais leve e fácil de acompanhar.”*

Essas respostas indicam que alguns recursos visuais ainda poderiam ser aprimorados, apesar de bem avaliados, no geral.

A avaliação dos recursos visuais continuou por meio da Questão 2.08, que perguntou se gráficos, imagens, GIFs e tabelas facilitaram o estudo na ferramenta. As respostas objetivas a essa questão são apresentadas na Figura 49.

Questão 2.08: Os gráficos, imagens, GIFs e tabelas presentes na Visual-AM facilitaram seu estudo?




Figura 49. Recursos visuais para facilitação dos estudos. Fonte: O autor.

Todos os participantes indicaram que os recursos visuais facilitaram o estudo, tendo apenas um deles marcado a opção “concordo parcialmente”. Apenas um dos participantes fez comentários sobre essa questão:

- **Respondente#10:** “Concordo totalmente. Os recursos visuais (gráficos, imagens, GIFs e tabelas) facilitaram o entendimento dos conceitos e tornaram o estudo mais dinâmico. Eles ajudam a visualizar ideias que seriam mais difíceis apenas com texto, além de apoiar a comparação de resultados e a fixação do conteúdo.”

A Questão 2.09 obteve opiniões sobre a hipótese de a ferramenta provocar sobrecarga cognitiva devido ao excesso de informações. As respostas quantitativas a essa pergunta são apresentadas na Figura 50.




Figura 50. Sobrecarga cognitiva enfrentada pelos participantes. Fonte: O autor.

As respostas a essa questão indicaram que as informações apresentadas pela ferramenta não provocaram altos níveis de sobrecarga cognitiva, visto que 80% dos participantes responderam com as opções “discordo parcialmente” ou “discordo totalmente”. Apenas a seguinte resposta discursiva foi registrada:

- **Respondente#10:** *“Discordo parcialmente. Em geral, a apresentação é equilibrada e não sobrecarrega. Apenas em alguns momentos, quando há mais conteúdo na mesma seção, um maior espaçamento ou divisão em etapas poderia melhorar ainda mais a experiência.”*

Na Questão 2.10, perguntou-se aos participantes se as imagens dinâmicas (GIFs) facilitaram o estudo. As respostas objetivas a essa questão são apresentadas na Figura 51.

Questão 2.10: As imagens dinâmicas (GIFs), presentes na Visual-AM, facilitaram o estudo sobre conceitos de aprendizado de máquina?




Figura 51. Sobrecarga enfrentada pelos participantes. Fonte: O autor.

Todos os participantes responderam que os estudos foram facilitados pela presença de imagens dinâmicas nas explicações da ferramenta. Os seguintes comentários foram feitos sobre essa questão:

- **Respondente#01:** “Sem dúvidas contribuíram. Sugiro apenas a possibilidade de pausar esses vídeos/GIFs.”
- **Respondente#06:** “Introdução: Os GIFs ajudam bastante. Aprendizado Não Supervisionado: Redução de Dimensionalidade: A animação que ilustra a padronização e a que mostra a busca pela direção de maior variância estão muito boas, auxiliam bastante o conceito.”
- **Respondente#10:** “Concordo totalmente. Os GIFs ajudaram a visualizar processos e mudanças ao longo do tempo, tornando a explicação mais intuitiva e facilitando a compreensão de conceitos que seriam mais abstratos apenas com texto.”

A Questão 2.11 perguntou aos participantes se a forma como os conteúdos são apresentados e, posteriormente, detalhados na ferramenta é adequada. As respostas quantitativas a essa questão são apresentadas na Figura 52.

Questão 2.11: A forma com que os conteúdos presentes na Visual-AM são apresentados e, posteriormente, detalhados é adequada?




Figura 52. Adequação da apresentação e do detalhamento do conteúdo. Fonte: O autor.

Todos os participantes concordaram que a forma de apresentação e o detalhamento dos conteúdos são adequados, com 70% tendo opinado “concordo totalmente”. Os seguintes comentários foram realizados a respeito dessa questão:

- **Respondente#01:** “Em alguns momentos, o bloqueio das etapas e a obrigatoriedade de concluir as etapas anteriores para liberá-las pode atrapalhar a navegação. Principalmente se o usuário acessar o Visual-AM para revisão de conteúdo, por exemplo.”
- **Respondente#03:** “A opção de expandir ou não os conceitos utilizando o botão +/- foi uma excelente adição.”
- **Respondente#06:** “Introdução: Gostei. As explicações estão informativas e os exemplos (SPAM e valores imobiliários) ficaram didáticos.”

- **Respondente#10:** *“Concordo totalmente. A apresentação é bem estruturada: os conteúdos são introduzidos de forma clara e, em seguida, aprofundados gradualmente, o que facilita acompanhar o raciocínio e consolidar os conceitos.”*

A Questão 2.12 perguntou aos participantes se a Visual-AM apresenta informações, imagens ou palavras irrelevantes para o estudo dos conceitos de AM. As respostas objetivas a essa pergunta são apresentadas na Figura 53.

Questão 2.12: A Visual-AM apresenta palavras, imagens ou informações irrelevantes para o estudo dos conceitos de aprendizado de máquina?




Figura 53. Irrelevância do conteúdo. Fonte: O autor.

Todos os participantes discordaram de que a Visual-AM contenha informações irrelevantes, o que indica adequação do conteúdo à proposta da ferramenta. Apenas um comentário foi feito a respeito dessa questão:

- **Respondente#10:** *“Discordo parcialmente. Em geral, as informações são relevantes e alinhadas ao objetivo do estudo. Eventualmente, alguns elementos poderiam ser mais diretamente conectados ao conceito explicado, mas isso não compromete a experiência.”*

A Questão 2.13 perguntou aos participantes se acreditavam que o conteúdo da ferramenta apresentava repetições excessivas de informações. As respostas quantitativas a essa questão são apresentadas na Figura 54.




Figura 54. Repetição de informações. Fonte: O autor.

A maioria dos participantes discordou de que as informações apresentadas na ferramenta fossem repetidas excessivamente. Os seguintes comentários foram feitos sobre essa questão:

- **Respondente#02:** *“Têm algumas repetições de conteúdos mas não atrapalha e também não é excessivo”*
- **Respondente#10:** *“Discordo parcialmente. Em geral, o conteúdo é objetivo e bem distribuído. Há algumas retomadas de conceitos, mas entendo como reforço pedagógico; ainda assim, pequenas sínteses poderiam substituir repetições em alguns trechos.”*

A Questão 2.14 investigou quais dispositivos os participantes utilizaram para acessar a Visual-AM. As respostas objetivas a essa pergunta são apresentadas na Figura 55, por meio da qual se observa que quase todos os participantes utilizaram o computador para se conectar à Visual-AM, 30% utilizaram a ferramenta tanto no *smartphone* quanto no computador, e apenas uma pessoa utilizou o *smartphone*.

Questão 2.14: Quais dos dispositivos eletrônicos que se conectam à Internet você utilizou para acessar a Visual-AM?




Figura 55. Dispositivos utilizados pelos participantes para acessar a Visual-AM. Fonte: O autor.

Na Questão 2.15, perguntou-se aos participantes se utilizariam a ferramenta novamente. As respostas quantitativas a essa questão são apresentadas na Figura 56.

Questão 2.15: Você usaria a Visual-AM novamente?




Figura 56. Propensão a utilizar a ferramenta novamente. Fonte: O autor.

A maioria dos participantes respondeu que usaria a Visual-AM novamente. Apenas um comentário foi feito sobre essa questão:

- **Respondente#10:** *“Concordo totalmente. Eu usaria a Visual-AM novamente como apoio para revisar conceitos e aprofundar conteúdos, pois a ferramenta é bem organizada, clara e facilita o estudo de forma progressiva.”*

A Questão 2.16 perguntou aos participantes se gostariam que outras disciplinas utilizassem ferramentas semelhantes à Visual-AM para estudar e reforçar os conteúdos aprendidos em sala de aula. As respostas objetivas a essa questão são apresentadas na Figura 57.




Figura 57. Interesse por ferramentas similares em outras disciplinas. Fonte: O autor.

A maioria dos usuários manifestou-se favorável ao uso de ferramentas semelhantes à Visual-AM no estudo de outras disciplinas. Os seguintes comentários foram realizados sobre essa questão:

- **Respondente#01:** *“Ainda mais se as seções de exercícios forem adaptadas/desenvolvidas para cada disciplina. A adição de videoaulas também parece interessante.”*
- **Respondente#10:** *“Concordo totalmente. Ferramentas desse tipo ajudam a reforçar o conteúdo visto em sala, tornam o estudo mais dinâmico e favorecem a aprendizagem autônoma. Em outras disciplinas, recursos visuais e interativos também poderiam melhorar a compreensão e a fixação.”*

Na Questão 2.17, perguntou-se se os usuários gostariam de fazer algum comentário adicional sobre a Visual-AM. As respostas quantitativas a essa questão são apresentadas na Figura 58.

Questão 2.17: Gostaria de fazer algum comentário geral sobre o uso da Visual-AM?




Figura 58. Intenção de fazer comentários sobre a ferramenta. Fonte: O autor.

Quatro participantes decidiram fazer comentários adicionais sobre a ferramenta:

- **Respondente#01:** *“A aplicação é muito interessante e facilita o aprendizado, revisão e consolidação dos conteúdos. As representações visuais contribuem no entendimento dos conceitos e a linguagem simples atrai usuários leigos e/ou iniciantes. Ferramentas como essa têm grande potencial de aplicação em outras disciplinas, igualmente complexas, ministradas em cursos da UNIFEI.”*
- **Respondente#02:** *“Excelente trabalho! Acredito que essa ferramenta tem um grande potencial para auxiliar estudantes que estão começando a ter contato com o aprendizado de máquina. Além disso, ela é uma ótima aliada na assimilação dos conteúdos vistos em sala de aula. Outro ponto importante é que, para alunos com um perfil de aprendizado mais visual, o Visual-AM pode contribuir significativamente para a consolidação do que foi aprendido.”*
- **Respondente#09:** *“A ferramenta é prática e intuitiva, as seções são bem divididas e com o conteúdo teórico e prático bem distribuídos, sem deixar os tópicos maçantes.”*
- **Respondente#10:** *“De forma geral, a Visual-AM é uma ferramenta bem organizada, visualmente agradável e útil para reforçar os conceitos de aprendizado de máquina. A navegação é intuitiva e o conteúdo é apresentado de maneira progressiva. Como melhoria, incluir mais exercícios e demonstrações interativas ajudaria a consolidar ainda mais o aprendizado.”*

A Questão 2.18 perguntou aos participantes se identificaram alguma inconveniência ou possibilidade de melhoria na ferramenta. As respostas objetivas a essa questão são apresentadas na Figura 59.

Questão 2.18: Você identificou alguma inconveniência ou gostaria de sugerir melhorias para a Visual-AM?




Figura 59. Possibilidades de melhorias. Fonte: O autor.

Metade dos participantes fez comentários sobre instabilidades momentâneas ou sugestões de novas funcionalidades:

- **Respondente#03:** *“Ao entrar pela primeira vez no link fornecido, a aplicação não havia iniciado. Foi necessário recarregar a página. Fora isso, tudo certo”*
- **Respondente#06:** *“Se possível, acredito que seria interessante aprimorar a funcionalidade de retorno à página, permitindo que o usuário volte exatamente ao ponto onde parou”*
- **Respondente#08:** *“Explorar outras vertentes para a mesma ferramenta”*
- **Respondente#09:** *“Se cabível, opções de áudio descrição de imagens e acessibilidade para baixa visão (ajuste das fontes).”*
- **Respondente#10:** *“Como melhoria, incluir mais exercícios e demonstrações interativas ajudaria a consolidar ainda mais o aprendizado.”*

As perguntas e respostas objetivas ao Questionário de Reação e Aceitação ao Uso da Ferramenta podem ser resumidas na Figura 60.




Figura 60. Resumo das questões e respostas ao Questionário de Reação ao Uso e Aceitação da Ferramenta. Fonte: O autor.

5.2 Quantificação de respostas

Esta subseção descreve o procedimento adotado para atribuir valores numéricos às respostas dos questionários, visando à análise quantitativa dos dados coletados.

5.2.1 Codificação de respostas ao Questionário de Reação ao Uso e Aceitação da Ferramenta

De modo a quantificar os resultados do questionário de Reação ao Uso e Aceitação da Ferramenta, foram atribuídos valores numéricos de 1 a 5 às suas respostas objetivas, conforme discutido nos próximos parágrafos.

Dado que, nas Questões 2.09, 2.12 e 2.13, foi perguntado aos participantes se havia aspectos que indicavam pontos positivos quando minimizados, as respostas a essas questões foram quantificadas, conforme mostrado no Quadro 9.

Quadro 9. Codificação das respostas das Questões 2.09, 2.12 e 2.13. Fonte: O autor.

Concordo totalmente	Concordo parcialmente	Não concordo nem discordo	Discordo parcialmente	Discordo totalmente
1	2	3	4	5

Esse procedimento de “*reverse scoring*” foi adotado para que todos os itens do questionário apresentassem a mesma direção semântica, com valores mais altos indicando percepções mais favoráveis em relação à ferramenta, o que facilita a interpretação dos resultados.

Como na Questão 2.07 a qualidade dos recursos visuais foi investigada por meio de adjetivos, suas respostas foram quantificadas conforme mostrado no Quadro 10.

Quadro 10. Codificação das respostas da Questão 2.07. Fonte: O autor.

Péssimos	Ruins	Regulares	Bons	Excelentes
1	2	3	4	5

As Questões 2.01 a 2.08, 2.10, 2.11, 2.15 e 2.16, cujas respostas de concordância indicaram uma avaliação favorável ao sistema, foram quantificadas conforme mostrado no Quadro 11.

Quadro 11. Codificação das respostas às Questões 2.01 a 2.08, 2.10, 2.11, 2.15 e 2.16. Fonte: O autor.

Concordo totalmente	Concordo parcialmente	Não concordo nem discordo	Discordo parcialmente	Discordo totalmente
5	4	3	2	1

As questões restantes (2.14, 2.17 e 2.18) foram tratadas apenas de forma descritiva, sem atribuição de valores às respostas, uma vez que a Questão 2.14 permitiu que os participantes indicassem mais de um dispositivo utilizado para acessar a ferramenta, e as Questões 2.17 e 2.18 solicitaram comentários gerais ou sugestões sobre a Visual-AM, servindo para complementar a interpretação das respostas às demais questões.

5.2.2 Codificação de respostas ao Questionário de Identificação do Perfil

Diferentemente do Questionário de Reação ao Uso e Aceitação da Ferramenta, no qual todas as questões poderiam ser respondidas por meio de uma escala Likert de cinco pontos, considerou-se que as respostas a algumas questões do Questionário de Identificação do Perfil apresentaram natureza dicotômica. Um desses casos é a Questão 1.4, que investigava quais discentes já haviam utilizado

ferramentas visuais para o estudo de AM anteriormente, permitindo apenas “Sim” ou “Não” como resposta. Já as Questões 1.1 (“Qual é o seu gênero?”) e 1.2 (“Você tem acesso à Internet em casa?”) previam, em sua formulação original, mais de duas alternativas de resposta. Entretanto, em ambos os casos, as opções não binárias não foram selecionadas por nenhum participante, de modo que as respostas observadas restringiram-se a apenas duas categorias. Desse modo, para fins de análise, as Questões 1.1, 1.2 e 1.4 foram tratadas como dicotômicas e codificadas numericamente como 0 ou 1, conforme mostrado no Quadro 12.

Quadro 12. Codificação das respostas às Questões 1.1, 1.2 e 1.4. Fonte: O autor.

	0	1
Opções da Questão 1.1	Masculino	Feminino
Opções das Questões 1.2 e 1.4	Não	Sim

Já as Questões 1.5 e 1.6 são variáveis ordinais organizadas em cinco níveis crescentes, representando, respectivamente, o conhecimento prévio em AM (de “Péssimo” a “Muito bom”) e a frequência de uso da internet (de “Não utilizo” a “Sim, Diariamente”). Portanto, essas questões foram codificadas conforme mostrado no Quadro 13.

Quadro 13. Codificação das respostas das Questões 1.5 e 1.6. Fonte: O autor.

	5	4	3	2	1
Questão 1.5	Péssimo	Ruim	Regular	Bom	Muito bom
Questão 1.6	Sim, diariamente	Mais de três vezes por semana	Três vezes por semana	Menos que três vezes por semana	Não utilizo

5.3 Correlações

Possíveis correlações entre as respostas às questões dos formulários foram analisadas por meio do coeficiente de correlação de Spearman (ρ_s). Esse método é adequado para a identificação de relações monotônicas não-lineares e dispensa a premissa de normalidade bivariada, sendo validado para amostras reduzidas por meio do uso de tabelas de valores críticos para avaliar a significância das correlações (ARTUSI; VERDERIO; MARUBINI, 2002).

Com relação à codificação das respostas para a análise de correlações, ressalta-se que o coeficiente de Spearman é particularmente indicado para variáveis ordinais ou dicotômicas, uma vez que se baseia na ordenação (em *ranks*) dos dados e permite avaliar associações monotônicas, independentemente da suposição de intervalos equidistantes entre as categorias (SULLIVAN; ARTINO JR., 2013).

Porém, antes de realizar análises de correlação, examinou-se a distribuição das respostas individuais às perguntas dos questionários para mitigar a ocorrência de correlações espúrias. Segundo a recomendação de Clark e Watson (1995) para avaliações psicométricas, itens com distribuições altamente desequilibradas e baixas variabilidades tendem a gerar correlações instáveis, que não devem ser consideradas. Em escalas Likert, esses itens caracterizam-se por questões às quais quase todos os participantes respondem da mesma forma. No caso dos questionários desta pesquisa, que contou com uma amostra pequena ($n = 10$), as questões nas quais nove de 10 participantes assinalaram a mesma opção fazem com que as correlações de Spearman calculadas com base nessas questões sejam artificialmente elevadas ou altamente sensíveis às únicas respostas diferentes das demais. Por esse motivo, itens com variabilidade insuficiente nas respostas foram desconsiderados da análise de correlação. Dessa forma, foram desconsideradas nas análises de correlações as Questões 1.2, 1.6, 1.7, 2.08 e 2.10, todas com 90% ou mais de respostas iguais. Também não foram consideradas, nessa análise, as

questões 1.3, 2.14, 2.17 e 2.18, que fornecem apenas dados contextuais e qualitativos.

Por fim, como $n = 10$ e adotando-se o nível de significância de 5% ($\alpha = 0,05$), apenas as correlações com ρ_s iguais ou superiores a 0,648 foram consideradas significativas (ARTUSI; VERDERIO; MARUBINI, 2002). Os resultados obtidos são apresentados no Quadro 14, no qual são mostradas as correlações de Spearman entre todas as questões consideradas na análise e destacadas as mais significativas.

Quadro 14. Correlações entre as questões. Fonte: O autor.

	Q1.1	Q1.4	Q1.5	Q2.1	Q2.2	Q2.3	Q2.4	Q2.5	Q2.6	Q2.7	Q2.9	Q2.11	Q2.12	Q2.13	Q2.15	Q2.16
Q1.1																
Q1.4	0,218															
Q1.5	0,075	0,694														
Q2.1	0,000	0,327	0,374													
Q2.2	0,129	0,423	0,616	0,323												
Q2.3	0,000	0,327	0,701	0,375	0,807											
Q2.4	-0,039	0,172	0,125	0,640	0,572	0,246										
Q2.5	0,080	0,130	0,186	0,050	0,450	0,050	0,675									
Q2.6	-0,500	-0,218	0,047	0,375	0,323	0,375	0,640	0,498								
Q2.7	0,655	0,524	0,408	0,327	0,423	0,327	0,172	0,130	-0,218							
Q2.9	-0,339	-0,205	0,120	0,188	0,365	0,188	0,260	0,113	0,188	0,123						
Q2.11	0,218	0,429	0,163	0,218	-0,423	-0,327	-0,172	-0,130	-0,327	0,429	-0,288					
Q2.12	0,500	-0,218	-0,093	-0,250	0,161	0,375	-0,394	-0,398	-0,250	0,327	-0,094	-0,327				
Q2.13	0,129	-0,563	-0,374	-0,323	-0,042	-0,323	-0,089	-0,013	-0,323	-0,141	0,559	-0,423	0,161			
Q2.15	-0,050	0,325	0,418	0,994	0,385	0,435	0,660	0,094	0,435	0,325	0,253	0,163	-0,248	-0,321		
Q2.16	-0,050	0,325	0,418	0,994	0,385	0,435	0,660	0,094	0,435	0,325	0,253	0,163	-0,248	-0,321	1,000	

As questões cujas correlações foram consideradas significativas são discutidas no Quadro 15.

Quadro 15. Correlações significativas entre questões (continua). Fonte: O autor.

Questão	Questão correlacionada	ρ_s	p-valor	Possível interpretação
Questão 1.4: Você já teve a oportunidade de utilizar uma ferramenta visual web para estudo de aprendizado de máquina antes desta pesquisa?	Questão 1.5: No momento de realização desta pesquisa, como você considera seu conhecimento sobre aprendizado de máquina?	0,694	0,0261	Discentes que já tiveram contato prévio com ferramentas visuais web para o estudo de AM tendem a considerar seu conhecimento mais avançado.
Questão 1.5: No momento de realização desta pesquisa, como você considera seu conhecimento sobre aprendizado de máquina?	Questão 2.03: O uso da Visual-AM auxiliou o entendimento de conceitos de aprendizado de máquina?	0,701	0,0239	Usuários com maior nível de conhecimento tendem a tirar mais proveito das explicações fornecidas pela Visual-AM.
Questão 2.01: A Visual-AM é compreensível e de fácil manuseio?	Questão 2.15: Você usaria a Visual-AM novamente?	0,994	$p < 0,001$	Discentes que consideraram a utilização da ferramenta mais intuitiva demonstraram maior intenção de utilizá-la novamente.
Questão 2.01: A Visual-AM é compreensível e de fácil manuseio?	Questão 2.16: Você gostaria que outras disciplinas explorassem ferramentas similares para o estudo e reforço dos conteúdos aprendidos em sala de aula?	0,994	$p < 0,001$	Discentes que consideraram intuitiva a utilização da Visual-AM também demonstraram maior desejo em utilizar ferramentas semelhantes em outras disciplinas.
Questão 2.02: Na sua opinião, o uso da Visual-AM despertou seu interesse sobre os conteúdos de aprendizado de máquina nele abordados?	Questão 2.03: O uso da Visual-AM auxiliou o entendimento de conceitos de aprendizado de máquina?	0,807	0,0048	O interesse despertado pela ferramenta parece ter auxiliado o entendimento de conceitos de AM.

Questão 2.04: Você se sente confiante ao utilizar a Visual-AM?	Questão 2.05: Você acredita que saberá usar o conhecimento adquirido por meio da Visual-AM em futuras práticas?	0,675	0,0324	A confiança ao utilizar a ferramenta tende a acompanhar a crença de que os conhecimentos adquiridos poderão ser aplicados em práticas futuras.
Questão 2.04: Você se sente confiante ao utilizar a Visual-AM?	Questão 2.15: Você usaria a Visual-AM novamente?	0,660	0,0377	Usuários mais confiantes no uso da ferramenta tendem a querer utilizá-la novamente.
Questão 2.04: Você se sente confiante ao utilizar a Visual-AM?	Questão 2.16: Você gostaria que outras disciplinas explorassem ferramentas similares para o estudo e reforço dos conteúdos aprendidos em sala de aula?	0,660	0,0377	Usuários mais confiantes no uso da Visual-AM também tendem a demonstrar maior interesse em utilizar ferramentas semelhantes em outras disciplinas.
Questão 2.15: Você usaria a Visual-AM novamente?	Questão 2.16: Você gostaria que outras disciplinas explorassem ferramentas similares para o estudo e reforço dos conteúdos aprendidos em sala de aula?	1	$p < 0,001$	Os níveis de interesse demonstrados pelos discentes na Visual-AM foram os mesmos que na possibilidade de utilizar ferramentas semelhantes em estudos de outras disciplinas.

5.4 Resultados por dimensões avaliativas

Nesta subseção, apresentam-se os procedimentos adotados para o tratamento das respostas ao Questionário de Reação ao Uso e Aceitação da Ferramenta. Inicialmente, os itens foram agrupados em dimensões avaliativas (construtos), com base em critérios definidos pelo autor desta dissertação, a fim de possibilitar uma interpretação integrada dos resultados. Em seguida, as respostas foram quantificadas para síntese e análise exploratória, permitindo o cálculo de

indicadores numéricos que refletem a avaliação dos participantes em cada dimensão.

5.4.1 Organização das questões em dimensões

Para complementar a interpretação dos resultados, as perguntas do Questionário de Reação ao Uso e Aceitação da Ferramenta foram agrupadas em cinco dimensões avaliativas, permitindo analisar como a Visual-AM e seus recursos interativos influenciaram a experiência de estudo dos participantes.

As Questões 2.09, 2.11, 2.12 e 2.13 foram categorizadas na dimensão “Fluidez Informacional”, uma vez que buscaram identificar se a apresentação das informações na ferramenta favoreceu uma navegação tranquila, sem sobrecarga ou dificuldades desnecessárias durante o estudo.

As Questões 2.07, 2.08 e 2.10 compõem a dimensão “Contribuição dos Recursos Visuais”, avaliando a eficácia dos elementos visuais da ferramenta (como gráficos, tabelas e GIFs) no apoio à compreensão dos conteúdos.

As Questões 2.03, 2.05 e 2.06 foram agrupadas na dimensão “Sensação de Progresso”, considerando a percepção dos discentes sobre o avanço no estudo dos conteúdos e a autopercepção de evolução após o uso da Visual-AM.

As Questões 2.01 e 2.04 foram categorizadas na dimensão “Facilidade de Uso”, avaliando a percepção de simplicidade, clareza e segurança ao interagir com a ferramenta.

As Questões 2.02, 2.15 e 2.16 foram agrupadas na dimensão “Engajamento”, pois avaliam o interesse despertado pela ferramenta, bem como a disposição dos participantes para reutilizá-la e adotar recursos semelhantes em estudos de outras disciplinas.

As demais questões relacionadas ao contexto de acesso ou a informações qualitativas complementares desse questionário (2.14, 2.17 e 2.18) foram mantidas

como uma categoria extra, intitulada “Dados Contextuais e Qualitativos”, fornecendo informações sobre o ambiente e a experiência de uso que auxiliam na interpretação das dimensões anteriores.

5.4.2 Quantificação dos resultados por dimensões

Para sintetizar os resultados obtidos a partir do Questionário de Reação ao Uso e Aceitação da Ferramenta, foi realizada uma análise exploratória das respostas às questões das categorias “Fluidez Informacional”, “Sensação de Progresso”, “Facilidade de Uso”, “Engajamento” e “Contribuição dos Recursos Visuais”. Conforme discutido por Norman (2010), embora itens Likert isolados possam ser considerados ordinais, o agrupamento desses itens permite tratá-los como variáveis intervalares, o que fundamenta a aplicação de estatísticas paramétricas. Desse modo, foram calculadas as médias de avaliação apresentadas no Quadro 16.

Quadro 16. Médias de respostas por participante, por dimensão. Fonte: O autor.

Participante	Facilidade de Uso	Engajamento	Sensação de Evolução	Contribuição dos Recursos Visuais	Fluidez Informacional
Respondente#10	5	5	5	4,67	4,25
Respondente#09	5	5	5	5	4
Respondente#08	5	4,67	4,67	4,67	4,75
Respondente#07	3	3	4	4,33	4,25
Respondente#06	5	5	5	4,67	4,50
Respondente#05	4,5	5	4,33	5	5
Respondente#04	4	4	5	4,67	4,75
Respondente#03	5	5	5	5	5
Respondente#02	4	4,67	4,33	4,67	4,5
Respondente#01	5	5	4,67	4,33	4,75

Sendo o limite máximo definido em 5, os dados indicam que a maioria dos respondentes apresentou reações positivas ao uso da ferramenta.

Para agregar aos resultados uma escala mais interpretável, os valores provenientes das respostas em escala Likert (de 1 a 5) foram convertidos para o intervalo de 0 a 10. Essa normalização, denominada “Índice de Eficácia Percebida”, foi calculada por meio da transformação linear apresentada na Equação 1, e sua aplicação prática aos limites desta pesquisa foi demonstrada na Equação 2.

$$\text{Índice de Eficácia Percebida}_{0-10} = \frac{\text{Valor da resposta}_{\text{Likert}} - \text{Limite inferior}}{\text{Limite superior} - \text{Limite inferior}} \quad (1)$$

$$\text{Índice de Eficácia Percebida}_{0-10} = \frac{\text{Valor da resposta}_{\text{Likert}} - 1}{5 - 1} \quad (2)$$

Visando à síntese dos resultados, foram calculados os valores médios e os desvios-padrão para cada dimensão avaliativa, conforme mostrado no Quadro 17.

Quadro 17. Síntese dos resultados em cada dimensão avaliativa. Fonte: O autor.

Dimensão avaliativa	Média_{Likert}	Desvio Padrão_{Likert}	Média do Índice de Eficácia Percebida₀₋₁₀
Facilidade de Uso	4,55	0,69	8,88
Engajamento	4,67	0,63	9,17
Sensação de Progresso	4,70	0,37	9,25
Contribuição dos Recursos Visuais	4,70	0,25	9,25
Fluidez Informacional	4,58	0,33	8,94

Esses resultados também podem ser ilustrados de forma gráfica, como mostrado na Figura 61, na qual cada dimensão avaliativa é representada por um setor circular de 72° cujo raio é proporcional à avaliação média de sua respectiva dimensão.




Figura 61. Representação gráfica das dimensões avaliativas. Fonte: O autor.

Os resultados apresentados no Quadro 17 e na Figura 61 mostram que a maioria das avaliações foi positiva, visto que os resultados médios em todas as cinco dimensões ficaram próximos do valor máximo de 5. Esse desempenho também é evidenciado pelo Índice de Eficácia Percebida, cuja escala normalizada de 0 a 10 apresenta médias próximas de 9 em todas as dimensões.

5.5 Discussão

Para a discussão dos resultados desta pesquisa, faz-se necessário retomar o objetivo central delineado na Introdução, que consistiu em propor uma ferramenta *web* interativa para o estudo de AM, com a finalidade de tornar o estudo dos fundamentos inerentes a essa área mais intuitivo. A partir dos resultados obtidos por meio do Questionário de Identificação do Perfil e do Questionário de Reação ao Uso e Aceitação da Ferramenta, bem como das análises correlacionais realizadas, considerou-se que a Visual-AM atingiu satisfatoriamente seu objetivo. Sob a perspectiva metodológica, a pesquisa atendeu aos objetivos específicos definidos conforme os preceitos da metodologia DSRM, validando a viabilidade técnica da ferramenta e fornecendo evidências preliminares de sua contribuição como recurso de apoio didático.

Cabe reiterar, entretanto, que os resultados obtidos devem ser interpretados no contexto de uma avaliação exploratória baseada na percepção dos participantes acerca da utilização da ferramenta, não constituindo evidência direta de ganho objetivo de aprendizagem. Além disso, a utilização da Visual-AM ocorreu de forma autônoma, remota e pontual, sem acompanhamento contínuo em contexto formal de sala de aula, aspecto que também deve ser considerado na interpretação dos resultados.

No que se refere à utilização de recursos visuais para apoiar o estudo de AM, a alta média obtida na dimensão avaliativa “Contribuição dos Recursos Visuais”, aliada aos comentários discursivos dos participantes do estudo, sugere que elementos gráficos, como imagens, botões e GIFs, desempenharam um papel importante no apoio à assimilação dos fundamentos de AM. Quanto à contribuição da ferramenta para a percepção de evolução nos estudos, as avaliações da dimensão “Sensação de Progresso” indicaram que os discentes consideraram que a Visual-AM colaborou efetivamente para o aprofundamento dos estudos na área. No

tocante ao nível de dificuldade na operação da ferramenta, as avaliações da dimensão “Facilidade de Uso” indicaram que a navegação na Visual-AM foi intuitiva, o que permitiu ao usuário sentir confiança ao explorar suas funcionalidades. Com relação aos níveis de sobrecarga associados aos estudos mediados pela ferramenta, as avaliações da dimensão “Fluidez Informacional” indicaram que o conteúdo abordado pela Visual-AM foi apresentado de forma clara e gradual, minimizando a sobrecarga cognitiva associada ao estudo. No que se refere ao interesse despertado pela ferramenta, as avaliações positivas da dimensão “Engajamento” indicaram que a Visual-AM se mostrou capaz não apenas de motivar seus usuários a utilizá-la novamente, mas também de despertar o interesse pelo uso de ferramentas semelhantes em outras disciplinas.

Os resultados dos questionários também sugeriram interesse dos discentes na disponibilização de ferramentas visuais *web* gratuitas para o estudo de AM e até para outras disciplinas, o que dialoga com a proposta da Visual-AM no contexto investigado. Esse achado reforça a coerência entre a concepção do artefato e as demandas percebidas pelos participantes, indicando sua relevância potencial como recurso de apoio didático.

Um achado particularmente interessante, advindo da análise de correlações entre as respostas às questões, refere-se à correlação positiva entre o conhecimento prévio em AM e a percepção de que a Visual-AM auxiliou a assimilação de conceitos de AM ($\rho_s = 0,701$; $p\text{-valor} = 0,0239$). Este resultado indica que, embora a ferramenta tenha sido concebida para atender até mesmo iniciantes na área de AM, usuários com base conceitual prévia tendem a extrair maior profundidade das lições disponibilizadas.

No que diz respeito às limitações técnicas da ferramenta apontadas pelos respondentes, destaca-se a ausência de persistência de progresso entre sessões, o que torna necessária a reexecução dos processos caso o usuário deseje voltar à etapa em que se encontrava antes de encerrar a sessão. Outras sugestões relevantes feitas pelos participantes evidenciam possibilidades de aprimoramento

futuro, incluindo a adição de novas funcionalidades relacionadas à acessibilidade e a expansão do conteúdo para permitir um número maior de exercícios e demonstrações interativas, ampliando as oportunidades de prática e de consolidação dos conceitos abordados.

Também vale ressaltar que a Visual-AM não foi concebida para substituir o ensino baseado em linguagens de programação textuais, tampouco para conferir domínio pleno do campo do AM. Seu escopo está delimitado ao AM clássico, abrangendo algoritmos supervisionados e não supervisionados específicos, não contemplando áreas como aprendizado por reforço ou abordagens semi-supervisionadas. Dessa forma, a ferramenta deve ser compreendida como recurso complementar, destinado a reduzir barreiras iniciais associadas a conceitos técnicos de áreas como matemática e programação, favorecendo a compreensão estruturada dos fundamentos conceituais de AM.

Por fim, cabe observar que, embora o tamanho da amostra ($n = 10$) limite a generalização estatística dos resultados, o tamanho mostra-se compatível com as recomendações de Faulkner (2003) e Macefield (2009), que indicam que amostras desse porte são capazes de revelar a maior parte dos padrões de interação e das dificuldades encontradas pelos usuários durante a utilização de um artefato. Nesse sentido, a predominância de avaliações positivas nas dimensões analisadas sugere boa aceitação da ferramenta pelos participantes e indica seu potencial como recurso de apoio ao estudo de AM. Investigações futuras poderão ampliar o número de participantes, explorar o uso longitudinal da Visual-AM e avaliar sua aplicação em diferentes contextos educacionais.

Capítulo 6

CONSIDERAÇÕES FINAIS

Este capítulo apresenta as considerações finais desta pesquisa. Inicialmente, retomam-se o objetivo central do estudo, suas principais contribuições e os achados decorrentes da avaliação da ferramenta proposta. Em seguida, são discutidas as limitações identificadas ao longo da pesquisa, bem como as possibilidades de trabalhos futuros que possam ampliar e aprofundar os resultados apresentados neste estudo.

6.1 Conclusão

A motivação científica desta pesquisa centrou-se no desafio de tornar mais acessível e intuitivo o estudo dos fundamentos de AM, especialmente para estudantes em fase inicial de contato com a área. Diante das barreiras cognitivas de entrada frequentemente associadas ao conhecimento de matemática e programação, buscou-se desenvolver uma ferramenta *web* interativa que favorecesse a compreensão conceitual por meio de recursos visuais e de um fluxo de estudo guiado.

Como principal contribuição deste estudo, foi proposta e desenvolvida a Visual-AM, uma ferramenta educacional baseada em uma abordagem visual e interativa para exploração de tópicos de AM clássico. A ferramenta organiza conteúdos em módulos independentes, com etapas progressivas que conduzem o usuário desde a análise inicial até aplicações práticas de modelos de forma

simplificada, permitindo experimentação estruturada, sem a necessidade de domínio prévio de linguagens de programação textual.

Utilizada como base teórica para o desenvolvimento da Visual-AM, a revisão bibliográfica desta pesquisa abrangeu os conceitos centrais de AM, incluindo seus tipos, etapas de processamento de modelos, métricas de avaliação e técnicas de otimização de hiperparâmetros. Além disso, foram discutidos recursos relevantes para a área, como a linguagem *Python* e outras ferramentas interativas e visuais para o estudo de AM, bem como os desafios enfrentados por discentes e docentes na área. Esses estudos foram importantes para orientar a definição da arquitetura modular da ferramenta, o fluxo progressivo das etapas do processamento de modelos e a escolha dos recursos visuais empregados, visando assegurar a coerência entre os referenciais conceituais e a solução prática proposta.

Além da influência dos conceitos teóricos de AM, os estágios da concepção da Visual-AM foram pautados pelos preceitos da metodologia DSRM, possibilitando não apenas o desenvolvimento do artefato, mas também sua avaliação em contexto real de uso, junto a estudantes da disciplina de Introdução à Ciência de Dados do curso de Engenharia de Bioprocessos da UNIFEI. Os resultados dessa avaliação indicaram reações amplamente positivas em todas as dimensões avaliadas: “Contribuição dos Recursos Visuais”, “Sensação de Progresso”, “Facilidade de Uso”, “Fluidez Informacional” e “Engajamento”.

Embora a pesquisa não tenha mensurado ganho de aprendizagem por meio de instrumentos objetivos de desempenho, as evidências obtidas sugerem que a Visual-AM cumpre seu propósito como ferramenta de apoio didático. Nesse sentido, o estudo apresenta dois resultados principais: o desenvolvimento de um artefato funcional voltado ao apoio ao estudo de AM e a obtenção de evidências exploratórias sobre o potencial de ferramentas visuais interativas nesse contexto educacional.

6.2 Limitações

Algumas limitações devem ser consideradas na interpretação dos resultados desta pesquisa:

- O tamanho reduzido da amostra ($n = 10$) limita a generalização estatística dos achados;
- A avaliação concentrou-se na percepção dos participantes quanto ao uso da ferramenta, não incluindo medidas objetivas de desempenho ou testes pré e pós-intervenção que permitissem mensurar ganho real de aprendizagem;
- A ferramenta foi desenvolvida utilizando a plataforma de hospedagem *Streamlit Community Cloud*, o que a sujeita a restrições operacionais observadas à época da realização desta pesquisa, como ausência de mecanismos nativos de persistência de progresso entre sessões (à época da realização desta pesquisa) e dependência de atualizações da plataforma, que podem afetar sua estabilidade ao longo do tempo;
- O escopo da Visual-AM está restrito a tópicos específicos de AM clássico, não contemplando abordagens como aprendizado profundo, bem como tipos de aprendizado por reforço e semi-supervisionado.

Essas limitações não invalidam os resultados obtidos, mas delimitam o alcance das conclusões apresentadas.

6.3 Trabalhos futuros

Com base nos resultados e limitações identificadas, algumas possibilidades de trabalhos futuros são sugeridas:

-
- Realizar estudos com amostras ampliadas e em diferentes contextos acadêmicos, a fim de possibilitar análises estatísticas mais robustas e investigar o uso da ferramenta em perfis mais diversos de estudantes;
 - Implementar mecanismos de persistência de sessões e de registro das interações dos usuários com a ferramenta, possibilitando não apenas a personalização da experiência de uso, mas também a investigação de padrões de comportamento por meio de analítica da aprendizagem (*learning analytics*) e mineração de dados educacionais (*educational data mining*);
 - Explorar a integração com recursos baseados em inteligência artificial que permitam a geração de *feedback* explicativo personalizado, mais adaptado às interações do usuário com a ferramenta;
 - Conduzir experimentos controlados com aplicação de testes pré e pós-intervenção, visando avaliar objetivamente os ganhos de aprendizagem dos estudantes, decorrentes do uso da ferramenta;
 - Expandir o escopo da ferramenta para incluir novos algoritmos e abordagens de AM, como técnicas baseadas em aprendizado profundo, ou para contemplar outros tipos de AM, a exemplo de aprendizado por reforço e aprendizado semi-supervisionado;
 - Investigar a aplicação da abordagem visual e interativa adotada pela Visual-AM no desenvolvimento de ferramentas educacionais voltadas a outras disciplinas — especialmente em contextos que envolvam conteúdos técnicos complexos ou elevada carga cognitiva —, considerando o interesse manifestado pelos participantes em utilizar recursos semelhantes em diferentes contextos de estudo.

REFERÊNCIAS

ABBASI, H. *et al.* Automatic brain ischemic stroke segmentation with deep learning: a review. **Neuroscience Informatics**, v. 3, n. 4, 100145, 2023. DOI: [10.1016/j.neuri.2023.100145](https://doi.org/10.1016/j.neuri.2023.100145).

ABD RAHMAN, A. S. *et al.* Rapid software framework for the implementation of machine learning classification models. **International Journal of Emerging Technology and Advanced Engineering**, v. 11, n. 8, p. 8-18, 2021. DOI: [10.46338/ijetae0821_02](https://doi.org/10.46338/ijetae0821_02).

ABELL, T.; HUSAR, A.; MAY-ANN, L. **Cloud computing as a key enabler for tech start-ups across Asia and the Pacific**. Manila: Asian Development Bank, 2021. 38 p. (ADB Sustainable Development Working Paper Series, n. 79).

ABRIATA, L. A. Web apps come of age for molecular sciences. **Informatics**, v. 4, n. 3, 28, 2017. DOI: [10.3390/informatics4030028](https://doi.org/10.3390/informatics4030028).

ACADEMIA BRASILEIRA DE CIÊNCIAS. **Recomendações para o avanço da inteligência artificial no Brasil**. 2. ed. Rio de Janeiro: Academia Brasileira de Ciências, 2024. Disponível em: <https://www.abc.org.br/wp-content/uploads/2024/05/recomendacoes-para-o-avanco-da-inteligencia-artificial-no-brasil-abc-novembro-GT-IA-24.pdf>. Acesso em: 23 set. 2024.

ADEGBOYE, A. Fundamental concepts and algorithms in machine learning. *In*: SOOFASTAEI, A. (ed.). **Advanced virtual assistants: a window to the virtual future**. IntechOpen, 2024. DOI: [10.5772/intechopen.1001886](https://doi.org/10.5772/intechopen.1001886).

AEBERHARD, S.; FORINA, M. **Wine**. UCI Machine Learning Repository, 1991. Disponível em: <https://archive.ics.uci.edu/dataset/109/wine>. Acesso em: 27 nov. 2025.

ALI, P. J. M.; FARAJ, R. H. Data normalization and standardization: a technical report. **Machine Learning Technical Reports**, v. 1, n. 1, p. 1-6, 2014.

ALSHAIKH, O.; PARKINSON, S.; KHAN, S. On the variability in the application and measurement of supervised machine learning in cyber security. *In*: WANG, G.; CHOO, K. K. R.; WU, J.; DAMIANI, E. (eds.). **Ubiquitous Security**. Cham: Springer, 2023. p. 545-555. (Communications in Computer and Information Science, v. 1768). DOI: [10.1007/978-981-99-0272-9_38](https://doi.org/10.1007/978-981-99-0272-9_38).

ALZUBI, J.; NAYYAR, A.; KUMAR, A. Machine learning from theory to algorithms: an overview. **Journal of Physics: Conference Series**, v. 1142, 012012, 2018. DOI: [10.1088/1742-6596/1142/1/012012](https://doi.org/10.1088/1742-6596/1142/1/012012).

AMOUDI, G.; TBAISHAT, D. Interactive notebooks for achieving learning outcomes in a graduate course: a pedagogical approach. **Education and Information Technologies**, v. 28, n. 12, p. 16669-16704, 2023. DOI: [10.1007/s10639-023-11854-x](https://doi.org/10.1007/s10639-023-11854-x).

ARTUSI, R.; VERDERIO, P.; MARUBINI, E. Bravais-Pearson and Spearman correlation coefficients: meaning, test of hypothesis and confidence interval. **The International Journal of Biological Markers**, v. 17, n. 2, p. 148-151, 2002. DOI: [10.1177/172460080201700213](https://doi.org/10.1177/172460080201700213).

ASKITAS, N. **A hands-on machine learning primer for social scientists: math, algorithms and code**. Bonn: Institute of Labor Economics (IZA), 2024. (IZA Discussion Paper Series, n. 17014).

ATMAJA, B. T.; AKAGI, M. Evaluation of error- and correlation-based loss functions for multitask learning dimensional speech emotion recognition. **Journal of Physics: Conference Series**, v. 1896, 012004, 2021. DOI: [10.1088/1742-6596/1896/1/012004](https://doi.org/10.1088/1742-6596/1896/1/012004).

AUGER, S. D. *et al.* Big data, machine learning and artificial intelligence: a neurologist's guide. **Practical Neurology**, v. 21, n. 1, p. 4-11, 2021. DOI: [10.1136/practneurol-2020-002688](https://doi.org/10.1136/practneurol-2020-002688).

AYKO, O.; KESER, S. B. A comparison of machine learning algorithms for forecasting solar irradiance in Eskişehir, Turkey. **International Journal of Applied Mathematics Electronics and Computers**, v. 9, n. 4, p. 103-109, 2021. DOI: [10.18100/ijamec.995506](https://doi.org/10.18100/ijamec.995506).

AYTAÇ, E. Unsupervised learning approach in defining the similarity of catchments: hydrological response unit based *k*-means clustering, a demonstration on Western Black Sea Region of Turkey. **International Soil and Water Conservation Research**, v. 8, n. 3, p. 321-331, 2020. DOI: [10.1016/j.iswcr.2020.05.002](https://doi.org/10.1016/j.iswcr.2020.05.002).

BAGANE, M. Google Colab: the free cloud platform powering machine learning. **International Journal of Science, Engineering and Technology**, v. 12, n. 1, p. 1-6, 2024.

BAIER, L.; JÖHREN, F.; SEEBACHER, S. Challenges in the deployment and operation of machine learning in practice. *In: EUROPEAN CONFERENCE ON INFORMATION SYSTEMS (ECIS)*, 27., 2019, Stockholm; Uppsala. **Proceedings [...]**. Atlanta: Association for Information Systems, 2019.

BALADRAM, M. S. *et al.* Introduction to supervised machine learning for data science. **Interdisciplinary Information Sciences**, v. 26, n. 1, p. 87-121, 2020. DOI: [10.4036/iis.2020.A.03](https://doi.org/10.4036/iis.2020.A.03).

BALYEN, L.; PETO, T. Promising artificial intelligence-machine learning-deep learning algorithms in ophthalmology. **Asia-Pacific Journal of Ophthalmology**, v. 8, n. 3, p. 264-272, 2019. DOI: [10.22608/APO.2018479](https://doi.org/10.22608/APO.2018479).

BASSEY, M. **Case study research in educational settings**. Buckingham: Open University Press, 1999.

BÄUERLE, A. *et al.* Symphony: composing interactive interfaces for machine learning. *In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS*, 2022, New Orleans. **Proceedings [...]**. New York: Association for Computing Machinery, 2022. p. 1-14. DOI: [10.1145/3491102.3502102](https://doi.org/10.1145/3491102.3502102).

BELETE, D. M.; HUCHAIAH, M. D. Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results. **International Journal of Computers and Applications**, v. 44, n. 9, p. 875-886, 2022. DOI: [10.1080/1206212X.2021.1974663](https://doi.org/10.1080/1206212X.2021.1974663).

BENBRAHIM, H.; HACHIMI, H.; AMINE, A. Deep convolutional neural network with tensorflow and keras to classify skin cancer images. **Scalable Computing: Practice and Experience**, v. 21, n. 3, p. 379-389, 2020. DOI: [10.12694/scpe.v21i3.1725](https://doi.org/10.12694/scpe.v21i3.1725).

BERRAR, D. Cross-validation. **Encyclopedia of Bioinformatics and Computational Biology**, v. 1, p. 542-545, 2019.

BHATT, H. *et al.* State-of-the-art machine learning techniques for melanoma skin cancer detection and classification: a comprehensive review. **Intelligent Medicine**, v. 3, n. 3, p. 180-190, 2023. DOI: [10.1016/j.imed.2022.08.004](https://doi.org/10.1016/j.imed.2022.08.004).

BRANSFORD, J. D. *et al.* (eds.). **How people learn: brain, mind, experience, and school**. Expanded ed. Washington, D.C.: National Academy Press, 2000.

ÇAĞLAYAN, C. Comparison of the code-based or tool-based teaching of the machine learning algorithm for the first-time learners. *In*: INTERNATIONAL INFORMATICS AND SOFTWARE ENGINEERING CONFERENCE (UBMYK), 1., 2019, Ankara. **Proceedings [...]**. Piscataway: IEEE, 2019. p. 1-3. DOI: [10.1109/UBMYK48245.2019.8965519](https://doi.org/10.1109/UBMYK48245.2019.8965519).

CAGNONI, S. *et al.* Emotion-based analysis of programming languages on Stack Overflow. **ICT Express**, v. 6, n. 3, p. 238-242, 2020. DOI: [10.1016/j.icte.2020.07.002](https://doi.org/10.1016/j.icte.2020.07.002).

CARNEY, M. *et al.* Teachable machine: approachable web-based tool for exploring machine learning classification. *In*: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2020, Honolulu. **Extended abstracts [...]**. New York: Association for Computing Machinery, 2020. p. 1-8. DOI: [10.1145/3334480.3382839](https://doi.org/10.1145/3334480.3382839).

CARVALHO, D. V.; PEREIRA, E. M.; CARDOSO, J. S. Machine learning interpretability: a survey on methods and metrics. **Electronics**, v. 8, n. 8, p. 832, 2019. DOI: [10.3390/electronics8080832](https://doi.org/10.3390/electronics8080832).

CHARYTANOWICZ, M. *et al.* **Seeds**. UCI Machine Learning Repository, 2012. Disponível em: <https://archive.ics.uci.edu/dataset/236/seeds>. Acesso em: 28 mai. 2025.

CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, v. 7, e623, 2021. DOI: [10.7717/peerj-cs.623](https://doi.org/10.7717/peerj-cs.623).

CLARK, L. A.; WATSON, D. Constructing validity: basic issues in objective scale development. **Psychological Assessment**, v. 7, n. 3, p. 309-319, 1995.

CORNETTA, G.; TOUHAFI, A. Design and evaluation of a new machine learning framework for IoT and embedded devices. **Electronics**, v. 10, n. 5, 600, 2021. DOI: [10.3390/electronics10050600](https://doi.org/10.3390/electronics10050600).

DA SILVA, D. W. **Datasets_da_Visual-AM**. GitHub, 2025. Disponível em: https://github.com/da-silva-d-w/Datasets_da_Visual-AM. Acesso em: 27 nov. 2025.

DA SILVA, D. W.; BARBOSA, L. C. B.; SEABRA, R. D. Ferramentas visuais web para o estudo de aprendizado de máquina no ensino superior: um mapeamento sistemático. *In*: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 35., 2024, Rio de Janeiro. **Anais do XXXV Simpósio Brasileiro de Informática na Educação**. Porto Alegre: Sociedade Brasileira de Computação, 2024. p. 264-275. DOI: [10.5753/sbie.2024.242426](https://doi.org/10.5753/sbie.2024.242426).

DAZA, A. *et al.* Systematic review of machine learning techniques to predict anxiety and stress in college students. **Informatics in Medicine Unlocked**, v. 43, 101391, 2023. DOI: [10.1016/j.imu.2023.101391](https://doi.org/10.1016/j.imu.2023.101391).

DEISENROTH, M. P.; FAISAL, A. A.; ONG, C. S. **Mathematics for machine learning**. Cambridge: Cambridge University Press, 2020. DOI: [10.1017/9781108679930](https://doi.org/10.1017/9781108679930).

DIWANJI, P.; HINKELMANN, K.; WITSCHERL, H. F. Enhance classroom preparation for flipped classroom using AI and analytics. *In*: INTERNATIONAL CONFERENCE ON ENTERPRISE INFORMATION SYSTEMS (ICEIS), 20., 2018. **Proceedings [...]**. SCITEPRESS, 2018. p. 477-483.

ESTEVEZ, J. *et al.* **Using Scratch to teach undergraduate students' skills on artificial intelligence**. arXiv:1904.00296, 2019. DOI: [10.48550/arXiv.1904.00296](https://doi.org/10.48550/arXiv.1904.00296).

FAOUZI, J.; COLLIOT, O. Classic machine learning methods. *In*: COLLIOT, O. (ed.). **Machine Learning for Brain Disorders**. New York: Humana, 2023. p. 25-75. DOI: [10.1007/978-1-0716-3195-9_2](https://doi.org/10.1007/978-1-0716-3195-9_2).

FARSHIDI, S. *et al.* A decision model for programming language ecosystem selection: seven industry case studies. **Information and Software Technology**, v. 139, 106640, 2021. DOI: [10.1016/j.infsof.2021.106640](https://doi.org/10.1016/j.infsof.2021.106640).

FAULKNER, L. Beyond the five-user assumption: benefits of increased sample sizes in usability testing. **Behavior Research Methods, Instruments, & Computers**, v. 35, n. 3, p. 379-383, 2003. DOI: [10.3758/BF03195514](https://doi.org/10.3758/BF03195514).

FERDOUS, N. *et al.* M^{pro}pred: A machine learning (ML) driven web-app for bioactivity prediction of SARS-CoV-2 main protease (M^{pro}) antagonists. **PLoS ONE**, v. 18, n. 6, e0287179, 2023. DOI: [10.1371/journal.pone.0287179](https://doi.org/10.1371/journal.pone.0287179).

FERNÁNDEZ, A. *et al.* Analysing the classification of imbalanced data-sets with multiple classes: Binarization techniques and ad-hoc approaches. **Knowledge-Based Systems**, v. 42, p. 97-110, 2013. DOI: [10.1016/j.knsys.2013.01.018](https://doi.org/10.1016/j.knsys.2013.01.018).

FIEBRINK, R. Machine learning education for artists, musicians, and other creative practitioners. **ACM Transactions on Computing Education**, v. 19, n. 4, p. 1-32, 2019. DOI: [10.1145/3294008](https://doi.org/10.1145/3294008).

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of Eugenics**, v. 7, n. 2, p. 179-188, 1936. DOI: [10.1111/j.1469-1809.1936.tb02137.x](https://doi.org/10.1111/j.1469-1809.1936.tb02137.x).

FLACH, P. A. ROC analysis. *In*: SAMMUT, C.; WEBB, G. I. (eds.). **Encyclopedia of Machine Learning and Data Mining**. New York: Springer, 2016. p. 1-8. DOI: [10.1007/978-1-4899-7502-7_739-1](https://doi.org/10.1007/978-1-4899-7502-7_739-1).

FREITAS JUNIOR, V. *et al.* Design Science Research Methodology enquanto estratégia metodológica para a pesquisa tecnológica. **Revista Espacios**, v. 38, n. 6, p. 25-34, 2017.

FRI, C.; ELOUAHBI, R. Machine learning and deep learning applications in e-learning systems: A literature survey using topic modeling approach. *In*: IEEE INTERNATIONAL CONGRESS ON INFORMATION SCIENCE AND TECHNOLOGY (CiSt), 6., 2020, Agadir-Essaouira. **Proceedings [...]**. Piscataway: IEEE, 2021. p. 267-273. DOI: [10.1109/CiSt49399.2021.9357253](https://doi.org/10.1109/CiSt49399.2021.9357253).

GAMA, C. L. G. **Método de construção de objetos de aprendizagem com aplicação em métodos numéricos**. 2007. Tese (Doutorado em Métodos Numéricos em Engenharia) – Setor de Tecnologia, Universidade Federal do Paraná, Curitiba, 2007.

GOH, H. A. *et al.* Front-end deep learning web apps development and deployment: a review. **Applied Intelligence**, v. 53, p. 15923-15945, 2023. DOI: [10.1007/s10489-022-04278-6](https://doi.org/10.1007/s10489-022-04278-6).

GRESSE VON WANGENHEIM, C. *et al.* Visual tools for teaching machine learning in K-12: a ten-year systematic mapping. **Education and Information Technologies**, v. 26, p. 5733-5778, 2021. DOI: [10.1007/s10639-021-10570-8](https://doi.org/10.1007/s10639-021-10570-8).

GROENNER, L. C. *et al.* Um estudo bibliométrico sobre a pesquisa em inteligência artificial no Brasil. **Brazilian Journal of Information Science: Research Trends**, v. 16, e02147, 2022. DOI: [10.36311/1981-1640.2022.v16.e02147](https://doi.org/10.36311/1981-1640.2022.v16.e02147).

GROZAVU, N. *et al.* Feature space transformation for transfer learning. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2012, Brisbane. **Proceedings [...]**. Piscataway: IEEE, 2012. p. 1-6. DOI: [10.1109/IJCNN.2012.6252732](https://doi.org/10.1109/IJCNN.2012.6252732).

HAGEN, T. *et al.* Teaching practical machine learning concepts to professionals and students: an integrated and interdisciplinary qualification project. *In*: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2020, Uppsala. **Proceedings [...]**. Los Alamitos: IEEE Computer Society, 2020. p. 1-8. DOI: [10.1109/FIE44824.2020.9274204](https://doi.org/10.1109/FIE44824.2020.9274204).

HARLEY, A. W. An interactive node-link visualization of convolutional neural networks. *In*: BEBIS, G. *et al.* (ed.). **Advances in visual computing**. Cham: Springer, 2015. p. 867-877. (Lecture Notes in Computer Science, v. 9474). DOI: [10.1007/978-3-319-27857-5_77](https://doi.org/10.1007/978-3-319-27857-5_77).

HERRERO, R. D.; ZORRILLA, M. An I4.0 data intensive platform suitable for the deployment of machine learning models: a predictive maintenance service case study. **Procedia Computer Science**, v. 200, p. 1014-1023, 2022. DOI: [10.1016/j.procs.2022.01.300](https://doi.org/10.1016/j.procs.2022.01.300).

HEYDARIAN, M. *et al.* MLCM: multi-label confusion matrix. **IEEE Access**, v. 10, p. 19083-19095, 2022. DOI: [10.1109/ACCESS.2022.3151048](https://doi.org/10.1109/ACCESS.2022.3151048).

HOO, Z. H.; CANDLISH, J.; TEARE, D. What is an ROC curve? **Emergency Medicine Journal**, v. 34, n. 6, p. 357-359, 2017. DOI: [10.1136/emered-2017-206735](https://doi.org/10.1136/emered-2017-206735).

HSIEH, C. *et al.* MIMIC-Eye: integrating MIMIC datasets with REFLACX and Eye Gaze for multimodal deep learning applications. Version 1.0.0. **PhysioNet**, 2023. RRID:SCR_007345. DOI: [10.13026/pc72-as03](https://doi.org/10.13026/pc72-as03).

JAKHAR, D.; KAUR, I. Artificial intelligence, machine learning and deep learning: definitions and differences. **Clinical and Experimental Dermatology**, v. 45, n. 1, p. 131-132, 2020. DOI: [10.1111/ced.14029](https://doi.org/10.1111/ced.14029).

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, n. 3, p. 685-695, 2021. DOI: [10.1007/s12525-021-00475-2](https://doi.org/10.1007/s12525-021-00475-2).

JIANG, Y. *et al.* Graph4GUI: graph neural networks for representing graphical user interfaces. *In*: PROCEEDINGS OF THE CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2024, Honolulu, HI, USA. **Proceedings [...]**. New York: ACM, 2024. p. 1-18. DOI: [10.1145/3613904.3642822](https://doi.org/10.1145/3613904.3642822).

JIANG, Y.; LI, B. Exploration on the teaching reform measure for machine learning course system of artificial intelligence specialty. **Scientific Programming**, v. 2021, 8971588, 2021. DOI: [10.1155/2021/8971588](https://doi.org/10.1155/2021/8971588).

JOHNSON, R. B.; ONWUEGBUZIE, A. J. Mixed methods research: a research paradigm whose time has come. **Educational Researcher**, v. 33, n. 7, p. 14-26, 2004. DOI: [10.3102/0013189X033007014](https://doi.org/10.3102/0013189X033007014).

JOSEPH, V. R.; VAKAYIL, A. SPliT: An optimal method for data splitting. **Technometrics**, v. 64, n. 2, p. 166-176, 2022. DOI: [10.1080/00401706.2021.1921037](https://doi.org/10.1080/00401706.2021.1921037).

KABAS, O.; KAYAKUS, M.; MOICEANU, G. Nondestructive estimation of hazelnut (*Corylus avellana* L.) terminal velocity and drag coefficient based on some fruit physical properties using machine learning algorithms. **Foods**, v. 12, n. 15, 2879, 2023. DOI: [10.3390/foods12152879](https://doi.org/10.3390/foods12152879).

KAGGLE. **Mall_Customers**. 2017. Disponível em: <https://www.kaggle.com/datasets/shwetabh123/mall-customers>. Acesso em: 23 mar. 2025.

KAHN, K. *et al.* Deep learning programming by all. *In*: CONFERENCE ON CONSTRUCTIONISM, 2020, Dublin. **Proceedings of the 2020 Constructionism Conference**. Dublin: Trinity College Dublin, 2020. p. 274-285.

KAHNG, M. *et al.* 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, 2019. DOI: [10.1109/TVCG.2018.2864500](https://doi.org/10.1109/TVCG.2018.2864500).

KARTHIKEYAN, A.; PRIYAKUMAR, U. D. Artificial intelligence: machine learning for chemical sciences. **Journal of Chemical Sciences**, v. 134, 2, 2022. DOI: [10.1007/s12039-021-01995-2](https://doi.org/10.1007/s12039-021-01995-2).

KATSUMATA, A. Deep learning and artificial intelligence in dental diagnostic imaging. **Japanese Dental Science Review**, v. 59, p. 329-333, 2023. DOI: [10.1016/j.jdsr.2023.09.004](https://doi.org/10.1016/j.jdsr.2023.09.004).

KAUR, G. *et al.* Brief review of various machine learning algorithms. *In*: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON INNOVATIVE COMPUTING & COMMUNICATION (ICICC), 2021. **Proceedings [...]**, 2021. DOI: [10.2139/ssrn.3747597](https://doi.org/10.2139/ssrn.3747597).

KERZEL, D.; KÖNIG-RIES, B.; SHEEBA, S. MLProvLab: provenance management for data science notebooks. *In*: BTW 2023, 2023, Dresden, Germany. **Proceedings [...]**. Bonn: Gesellschaft für Informatik e.V., 2023. p. 965-980. DOI: [10.18420/BTW2023-66](https://doi.org/10.18420/BTW2023-66).

KHALEEL, M.; AHMED, A. A.; ALSHARIF, A. Artificial intelligence in engineering. **Brilliance: Research of Artificial Intelligence**, v. 3, n. 1, p. 32-42, 2023. DOI: [10.47709/brilliance.v3i1.2170](https://doi.org/10.47709/brilliance.v3i1.2170).

KHAN, M.; NOOR, S. Irrigation runoff volume prediction using machine learning algorithms. **European International Journal of Science and Technology**, v. 8, n. 1, p. 1-22, 2019.

KIANI, S. *et al.* WOLF: automated machine learning workflow management framework for malware detection and other applications. *In*: SYMPOSIUM ON HOT TOPICS IN THE SCIENCE OF SECURITY, 7., 2020, Lawrence, Kansas, USA. **Proceedings [...]**. New York: ACM, 2020. p. 1-8. DOI: [10.1145/3384217.3385625](https://doi.org/10.1145/3384217.3385625).

KINGSMORE, K. M. *et al.* An introduction to machine learning and analysis of its use in rheumatic diseases. **Nature Reviews Rheumatology**, v. 17, n. 12, p. 710-730, 2021. DOI: [10.1038/s41584-021-00708-w](https://doi.org/10.1038/s41584-021-00708-w).

KOLLURI, J. *et al.* Reducing overfitting problem in machine learning using novel L1/4 regularization method. *In*: INTERNATIONAL CONFERENCE ON TRENDS IN ELECTRONICS AND INFORMATICS (ICOEI), 4., 2020, Tirunelveli, India. **Proceedings [...]**. New York: IEEE, 2020. p. 934-938. DOI: [10.1109/ICOEI48184.2020.9142992](https://doi.org/10.1109/ICOEI48184.2020.9142992).

KONTSEWAYA, Y. *et al.* Evaluating the effectiveness of machine learning methods for spam detection. **Procedia Computer Science**, v. 190, p. 479-486, 2021. DOI: [10.1016/j.procs.2021.06.056](https://doi.org/10.1016/j.procs.2021.06.056).

KORUS, K.; SALAMAK, M.; JASIŃSKI, M. Optimization of geometric parameters of arch bridges using visual programming FEM components and genetic algorithm. **Engineering Structures**, v. 241, p. 112465, 2021. DOI: [10.1016/j.engstruct.2021.112465](https://doi.org/10.1016/j.engstruct.2021.112465).

KUBAN, M. *et al.* Density-of-states similarity descriptor for unsupervised learning from materials data. **Scientific Data**, v. 9, p. 646, 2022. DOI: [10.1038/s41597-022-01754-z](https://doi.org/10.1038/s41597-022-01754-z).

LAO, N. **Reorienting machine learning education towards tinkerers and ML-engaged citizens**. 2020. Tese (Doutorado em Electrical Engineering and Computer Science) – Massachusetts Institute of Technology, Cambridge, 2020.

LAUPICHLER, M. C. *et al.* Effect of a flipped classroom course to foster medical students' AI literacy with a focus on medical imaging: a single group pre-and post-test study. **BMC Medical Education**, v. 22, p. 803, 2022. DOI: [10.1186/s12909-022-03866-x](https://doi.org/10.1186/s12909-022-03866-x).

LOFTUS, T. J. *et al.* Artificial intelligence and surgical decision-making. **JAMA Surgery**, v. 155, n. 2, p. 148-158, 2020. DOI: [10.1001/jamasurg.2019.4917](https://doi.org/10.1001/jamasurg.2019.4917).

LOHWEG, V. **Banknote authentication**. UCI Machine Learning Repository, 2013. Disponível em: <https://archive.ics.uci.edu/dataset/267/banknote+authentication>. Acesso em: 8 jul. 2025.

LONG, D.; MAGERKO, B. What is AI literacy? Competencies and design considerations. *In*: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2020, Honolulu, HI, USA. **Proceedings [...]**. New York: ACM, 2020. p. 1-16. DOI: [10.1145/3313831.3376727](https://doi.org/10.1145/3313831.3376727).

LU, W.-Y.; FAN, S.-C. Developing a weather prediction project-based machine learning course in facilitating AI learning among high school students. **Computers and Education: Artificial Intelligence**, v. 5, 100154, 2023. DOI: [10.1016/j.caeai.2023.100154](https://doi.org/10.1016/j.caeai.2023.100154).

MACEFIELD, R. How to specify the participant group size for usability studies: a practitioner's guide. **Journal of Usability Studies**, v. 5, n. 1, p. 34-45, 2009.

MALIK, M. A. *et al.* Use of big data and machine learning algorithms to extract possible treatment targets in neurodevelopmental disorders. **Pharmacology & Therapeutics**, v. 250, 108530, 2023. DOI: [10.1016/j.pharmthera.2023.108530](https://doi.org/10.1016/j.pharmthera.2023.108530).

MALTA, D. P. L. N. *et al.* O papel da computação em nuvem na gestão e acessibilidade educacional. **Missioneira**, v. 27, n. 9, p. 409-423, 2025. DOI: [10.46550/scn2eb47](https://doi.org/10.46550/scn2eb47).

MARCO, R.; AHMAD, S. S. S.; AHMAD, S. Bayesian hyperparameter optimization and ensemble learning for machine learning models on software effort estimation. **International Journal of Advanced Computer Science and Applications**, v. 13, n. 3, p. 419-429, 2022. DOI: [10.14569/IJACSA.2022.0130351](https://doi.org/10.14569/IJACSA.2022.0130351).

MATHUR, P. *et al.* Artificial intelligence, machine learning, and cardiovascular disease. **Clinical Medicine Insights: Cardiology**, v. 14, 1179546820927404, 2020. DOI: [10.1177/1179546820927404](https://doi.org/10.1177/1179546820927404).

MATSUOKA, D. *et al.* Tropical cyclone dataset for a high-resolution global nonhydrostatic atmospheric simulation. **Data in Brief**, v. 48, 109135, 2023. DOI: [10.1016/j.dib.2023.109135](https://doi.org/10.1016/j.dib.2023.109135).

MAYER, R. E. (ed.). **The Cambridge handbook of multimedia learning**. New York: Cambridge University Press, 2005.

MCBEE, M. T.; PETERS, S. J.; MILLER, E. M. The impact of the nomination stage on gifted program identification: a comprehensive psychometric analysis. **Gifted Child Quarterly**, v. 60, n. 4, p. 258-278, 2016. DOI: [10.1177/0016986216656256](https://doi.org/10.1177/0016986216656256).

MEYER JR., L.; BILLIONNIERE, E. AWS academy vs Microsoft Learn for educators vs IBM Skills Academy: the educators choice. *In*: SOCIETY FOR INFORMATION TECHNOLOGY & TEACHER EDUCATION INTERNATIONAL CONFERENCE, 2021, Online, United States. **Proceedings** [...]. Waynesville, NC: Association for the Advancement of Computing in Education (AACE), 2021. p. 528-534.

M'HAMDI, O. *et al.* A comparative analysis of XGBoost and neural network models for predicting some tomato fruit quality traits from environmental and meteorological data. **Plants**, v. 13, n. 5, 746, 2024. DOI: [10.3390/plants13050746](https://doi.org/10.3390/plants13050746).

MOHSENI, S. *et al.* Practical solutions for machine learning safety in autonomous vehicles. *In*: WORKSHOP ON ARTIFICIAL INTELLIGENCE SAFETY (SAFEAI), 2., 2020, New York. **Proceedings** [...]. Menlo Park: AAI, 2020. DOI: [10.48550/arXiv.1912.09630](https://doi.org/10.48550/arXiv.1912.09630).

MÜLLER, A. C.; GUIDO, S. **Introduction to machine learning with Python: a guide for data scientists**. Sebastopol: O'Reilly Media, 2016.

MURRAY, J. D. *et al.* Advancing algorithmic drug product development: recommendations for machine learning approaches in drug formulation. **European Journal of Pharmaceutical Sciences**, v. 191, 106562, 2023. DOI: [10.1016/j.ejps.2023.106562](https://doi.org/10.1016/j.ejps.2023.106562).

NDUNG'U, R. N. Data preparation for machine learning modelling. **International Journal of Computer Applications Technology and Research**, v. 11, n. 6, p. 231-235, 2022. DOI: [10.7753/IJCATR1106.1008](https://doi.org/10.7753/IJCATR1106.1008).

NORMAN, G. Likert scales, levels of measurement and the "laws" of statistics. **Advances in Health Sciences Education**, v. 15, n. 5, p. 625-632, 2010. DOI: [10.1007/s10459-010-9222-y](https://doi.org/10.1007/s10459-010-9222-y).

ORTIN, F. *et al.* Analyzing syntactic constructs of Java programs with machine learning. **Expert Systems with Applications**, v. 215, 119398, 2023. DOI: [10.1016/j.eswa.2022.119398](https://doi.org/10.1016/j.eswa.2022.119398).

PAIVA, A. C. R. *et al.* Towards the integration of visual and formal models for GUI testing. **Electronic Notes in Theoretical Computer Science**, v. 190, n. 2, p. 99-111, 2007. DOI: [10.1016/j.entcs.2007.08.010](https://doi.org/10.1016/j.entcs.2007.08.010).

PALEYES, A. *et al.* Challenges in deploying machine learning: a survey of case studies. **ACM Computing Surveys**, v. 55, n. 6, 114, 2022. DOI: [10.1145/3533378](https://doi.org/10.1145/3533378).

PARK, J. *et al.* A novel learning rate schedule in optimization for neural networks and it's convergence. **Symmetry**, v. 12, n. 4, 660, 2020. DOI: [10.3390/sym12040660](https://doi.org/10.3390/sym12040660).

PARKAVI, R. *et al.* Predicting academic performance of learners with the three domains of learning data using neuro-fuzzy model and machine learning algorithms. **Journal of Engineering Research**, v. 12, n. 3, p. 397-411, 2024. DOI: [10.1016/j.jer.2023.09.006](https://doi.org/10.1016/j.jer.2023.09.006).

PEDREGOSA, F. *et al.* Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011.

PEFFERS, K. *et al.* **A Design Science Research Methodology for Information Systems research**. **Journal of Management Information Systems**, v. 24, n. 3, p. 45-77, 2007. DOI: [10.2753/MIS0742-1222240302](https://doi.org/10.2753/MIS0742-1222240302).

PEREIRA, D. E. F.; SEABRA, R. D. Open educational resource for studying algorithms and programming logic: an approach to the technical level integrated with secondary school. **Informatics in Education**, v. 22, n. 3, p. 441-462, 2023. DOI: [10.15388/infedu.2023.17](https://doi.org/10.15388/infedu.2023.17).

PODRZAJ, P. A brief demonstration of some Python GUI libraries. *In: PROCEEDINGS OF THE 8TH INTERNATIONAL CONFERENCE ON INFORMATICS AND APPLICATIONS (ICIA 2019)*. Takamatsu, Japan: SDIWC, 2019. p. 1-6.

PRAJAPATI, A. K.; SINGH, U. K. An optimal solution to the overfitting and underfitting problem of healthcare machine learning models. **Journal of Systems Engineering and Information Technology (JOSEIT)**, v. 2, n. 2, p. 77-84, 2023. DOI: [10.29207/joseit.v2i2.5460](https://doi.org/10.29207/joseit.v2i2.5460).

PROBST, P. *et al.* Tunability: Importance of hyperparameters of machine learning algorithms. **Journal of Machine Learning Research**, v. 20, n. 53, p. 1-32, 2019.

RAFAŁO, M. Cross validation methods: analysis based on diagnostics of thyroid cancer metastasis. **ICT Express**, v. 8, n. 2, p. 183-188, 2022. DOI: [10.1016/j.ict.2021.05.001](https://doi.org/10.1016/j.ict.2021.05.001).

RAFF, E.; AURELIO, J.; NICHOLAS, C. PyLZJD: An easy to use tool for machine learning. *In: PYTHON IN SCIENCE CONFERENCE (SCIPY)*, 18., 2019, Austin. **Proceedings [...]**. Austin: SciPy Society, 2019. p. 97-102. DOI: [10.25080/Majora-7ddc1dd1-00e](https://doi.org/10.25080/Majora-7ddc1dd1-00e).

RASCHKA, S. **Model evaluation, model selection, and algorithm selection in machine learning**. arXiv:1811.12808, 2018. DOI: [10.48550/arXiv.1811.12808](https://doi.org/10.48550/arXiv.1811.12808).

RASCHKA, S.; KAUFMAN, B. Machine learning and AI-based approaches for bioactive ligand discovery and GPCR-ligand recognition. **Methods**, v. 180, p. 89-110, 2020. DOI: [10.1016/j.ymeth.2020.06.016](https://doi.org/10.1016/j.ymeth.2020.06.016).

RASCHKA, S.; MIRJALILI, V. **Python machine learning: machine learning and deep learning with Python, Scikit-learn, and TensorFlow 2**. 3. ed. Birmingham: Packt Publishing, 2019.

RASCHKA, S.; PATTERSON, J.; NOLET, C. Machine learning in Python: main developments and technology trends in data science, machine learning, and artificial intelligence. **Information**, v. 11, n. 4, 193, 2020. DOI: [10.3390/info11040193](https://doi.org/10.3390/info11040193).

SANG, H. *et al.* Analysis of the current situation of big data MOOCs in the intelligent era based on the perspective of improving the mental health of college students. **Information**, v. 14, n. 9, 511, 2023. DOI: [10.3390/info14090511](https://doi.org/10.3390/info14090511).

SARANGPURE, N. *et al.* Automating the machine learning process using PyCaret and Streamlit. *In: INTERNATIONAL CONFERENCE FOR INNOVATION IN TECHNOLOGY (INOCON)*, 2., 2023, Bangalore. **Proceedings [...]**. Piscataway: IEEE, 2023. p. 1-5. DOI: [10.1109/INOCON57975.2023.10101357](https://doi.org/10.1109/INOCON57975.2023.10101357).

SARKER, I. H. Machine learning: algorithms, real-world applications and research directions. **SN Computer Science**, v. 2, 160, 2021. DOI: [10.1007/s42979-021-00592-x](https://doi.org/10.1007/s42979-021-00592-x).

SCHULTZE, S.; GRUENEFELD, U.; BOLL, S. Demystifying deep learning: developing a learning application for beginners to gain practical experience. *In: MENSCH UND COMPUTER WORKSHOPBAND (MUC)*, 2020, Magdeburg. **Proceedings [...]**. Bonn: Gesellschaft für Informatik e.V., 2020. p. 1-7. DOI: [10.18420/muc2020-ws111-334](https://doi.org/10.18420/muc2020-ws111-334).

SCHULZ, A. *et al.* **Utilizing online and open-source machine learning toolkits to leverage the future of sustainable engineering**. arXiv:2304.11175, 2023. DOI: [10.48550/arXiv.2304.11175](https://doi.org/10.48550/arXiv.2304.11175).

SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. **Applied Soft Computing**, v. 97, 105524, 2020. DOI: [10.1016/j.asoc.2019.105524](https://doi.org/10.1016/j.asoc.2019.105524).

SINGLA, A. Machine Learning Operations (MLOps): challenges and strategies. **Journal of Knowledge Learning and Science Technology**, v. 2, n. 3, p. 333-340, 2023. DOI: [10.60087/jklst.vol2.n3.p340](https://doi.org/10.60087/jklst.vol2.n3.p340).

SMILKOV, D. *et al.* **Direct-manipulation visualization of deep networks**. arXiv:1708.03788, 2017. DOI: [10.48550/arXiv.1708.03788](https://doi.org/10.48550/arXiv.1708.03788).

SOMOGYI, Z. Performance evaluation of machine learning models. In: SOMOGYI, Z. **The application of artificial intelligence: step-by-step guide from beginner to expert**. Cham: Springer International Publishing, 2021. p. 87-112. DOI: [10.1007/978-3-030-60032-7_3](https://doi.org/10.1007/978-3-030-60032-7_3).

SOORI, M. *et al.* Artificial intelligence, machine learning and deep learning in advanced robotics, a review. **Cognitive Robotics**, v. 3, p. 54-70, 2023. DOI: [10.1016/j.cogr.2023.04.001](https://doi.org/10.1016/j.cogr.2023.04.001).

SOPER, D. S. Greed is good: rapid hyperparameter optimization and model selection using greedy k-fold cross validation. **Electronics**, v. 10, n. 16, 1973, 2021. DOI: [10.3390/electronics10161973](https://doi.org/10.3390/electronics10161973).

SRINIVASAN, K. *et al.* An efficient implementation of artificial neural networks with *k*-fold cross-validation for process optimization. **Journal of Internet Technology**, v. 20, n. 4, p. 1213-1225, 2019.

SUKAMTO, S. *et al.* KNN optimization using grid search algorithm for preeclampsia imbalance class. In: **E3S Web of Conferences**, v. 448, 02057, 2023. DOI: [10.1051/e3sconf/202344802057](https://doi.org/10.1051/e3sconf/202344802057).

SULLIVAN, G. M.; ARTINO JR., A. R. Analyzing and interpreting data from Likert-type scales. **Journal of Graduate Medical Education**, v. 5, n. 4, p. 541-542, 2013. DOI: [10.4300/JGME-5-4-18](https://doi.org/10.4300/JGME-5-4-18).

SULMONT, E. *et al.* What is hard about teaching machine learning to non-majors? Insights from classifying instructors' learning goals. **ACM Transactions on Computing Education**, v. 19, n. 4, 33, 2019. DOI: [10.1145/3336124](https://doi.org/10.1145/3336124).

SULTAN, N. Cloud computing: A democratizing force? **International Journal of Information Management**, v. 33, n. 5, p. 810-815, 2013. DOI: [10.1016/j.ijinfomgt.2013.05.010](https://doi.org/10.1016/j.ijinfomgt.2013.05.010).

TALUKDER, M. A. *et al.* MLSTL-WSN: machine learning-based intrusion detection using SMOTETomek in WSNs. **International Journal of Information Security**, v. 23, p. 2139-2158, 2024. DOI: [10.1007/s10207-024-00833-z](https://doi.org/10.1007/s10207-024-00833-z).

THIN-YIN, L.; JONATHAN, L. Y. Simpler machine learning using spreadsheets: neural network predict. **European Journal of Engineering and Formal Sciences**, v. 4, n. 1, p. 124-138, 2020.

TIAN, Y. *et al.* Recent advances on loss functions in deep learning for computer vision. **Neurocomputing**, v. 497, p. 129-158, 2022. DOI: [10.1016/j.neucom.2022.04.127](https://doi.org/10.1016/j.neucom.2022.04.127).

TSENG, H.-H. *et al.* Machine learning and imaging informatics in oncology. **Oncology**, v. 98, n. 6, p. 344-362, 2020. DOI: [10.1159/000493575](https://doi.org/10.1159/000493575).

UCI MACHINE LEARNING REPOSITORY. **Pima Indians diabetes database**. Kaggle, 2016. Disponível em: <https://www.kaggle.com/datasets/uciml/pima-indians-diabetes-database>. Acesso em: 13 jun. 2025.

VADAR, P. S. *et al.* A comprehensive comparison of deep learning libraries: TensorFlow, PyTorch, FastAI, Keras, and PyTorch Lightning. **International Journal of Computer Science Engineering Techniques**, v. 8, n. 6, p. 1-11, 2024.

WANG, A.; DURRANT, J. D. Open-source browser-based tools for structure-based computer-aided drug discovery. **Molecules**, v. 27, n. 14, 4623, 2022. DOI: [10.3390/molecules27144623](https://doi.org/10.3390/molecules27144623).

WANG, B.; GONG, N. Z. Stealing hyperparameters in machine learning. In: IEEE SYMPOSIUM ON SECURITY AND PRIVACY (SP), 39., 2018, San Francisco. **Proceedings [...]** Piscataway: IEEE, 2018. p. 36-52. DOI: [10.1109/SP.2018.00038](https://doi.org/10.1109/SP.2018.00038).

WANG, H. *et al.* Scientific discovery in the age of artificial intelligence. **Nature**, v. 620, p. 47-60, 2023. DOI: [10.1038/s41586-023-06221-2](https://doi.org/10.1038/s41586-023-06221-2).

WANG, Z. J. *et al.* CNN explainer: Learning convolutional neural networks with interactive visualization. **IEEE Transactions on Visualization and Computer Graphics**, v. 27, n. 2, p. 1396-1406, 2021. DOI: [10.1109/TVCG.2020.3030418](https://doi.org/10.1109/TVCG.2020.3030418).

WAY, T. *et al.* Machine learning modules for all disciplines. In: ACM CONFERENCE ON INNOVATION AND TECHNOLOGY IN COMPUTER SCIENCE EDUCATION, 2017, Bologna, Italy. **Proceedings [...]**. New York: Association for Computing Machinery, 2017. p. 84-85. DOI: [10.1145/3059009.3072979](https://doi.org/10.1145/3059009.3072979).

WEERTS, H. J. P. *et al.* **Importance of tuning hyperparameters of machine learning algorithms**. arXiv:2007.07588, 2020. DOI: [10.48550/arXiv.2007.07588](https://doi.org/10.48550/arXiv.2007.07588).

WONG, K.; DORNBERGER, R.; HANNE, T. An analysis of weight initialization methods in connection with different activation functions for feedforward neural networks. **Evolutionary Intelligence**, v. 17, p. 2081-2089, 2024. DOI: [10.1007/s12065-022-00795-y](https://doi.org/10.1007/s12065-022-00795-y).

WU, J. *et al.* Hyperparameter optimization for machine learning models based on Bayesian optimization. **Journal of Electronic Science and Technology**, v. 17, n. 1, p. 26-40, 2019. DOI: [10.11989/JEST.1674-862X.80904120](https://doi.org/10.11989/JEST.1674-862X.80904120).

WULFF, P.; KUBSCH, M.; KRIST, C. (ed.). **Applying machine learning in science education research: when, how, and why?** Cham: Springer, 2025. (Springer Texts in Education). DOI: [10.1007/978-3-031-74227-9](https://doi.org/10.1007/978-3-031-74227-9).

YILMAZ, A. *et al.* **Comparison of deep learning and traditional machine learning techniques for classification of pap smear images**. arXiv:2009.06366, 2020. DOI: [10.48550/arXiv.2009.06366](https://doi.org/10.48550/arXiv.2009.06366).

ZHANG, J.; ZHANG, Y.; LU, Y. A comparative study of deep learning frameworks based on short-term power load forecasting experiments. **Journal of Physics: Conference Series**, v. 2005, n. 1, 012070, 2021. DOI: [10.1088/1742-6596/2005/1/012070](https://doi.org/10.1088/1742-6596/2005/1/012070).

ZHUANG, F. *et al.* A comprehensive survey on transfer learning. **IEEE Proceedings**, v. 109, n. 1, p. 43-76, 2021. DOI: [10.1109/JPROC.2020.3004555](https://doi.org/10.1109/JPROC.2020.3004555).

APÊNDICE A:

EMENTA DA DISCIPLINA

DE INTRODUÇÃO À

CIÊNCIA DE DADOS

Este apêndice visa descrever o conteúdo da disciplina de “Introdução à Ciência de Dados”, ofertada pelo Instituto de Recursos Naturais da UNIFEI, campus Itajubá.

INTRODUÇÃO À CIÊNCIA DE DADOS (EBP03A)

Professor: Luiz Carlos Bertucci Barbosa

Objetivos

- *Destacar a importância da extração de conhecimento a partir de dados para a tomada de decisões e auxílio a instituições na detecção de anomalias, monitoramento de indicadores ou melhoria de processos;*
- *Destacar os métodos e ferramentas para a exploração, extração de conhecimento e geração de modelos preditivos a partir de dados brutos.*

Ementa

Dados, informação e tomada de decisão; Coleta de dados na web (web scraping e APIs); Bancos de dados relacionais e não relacionais; Análise descritiva e

visualização de dados; Aprendizado de máquina (Machine Learning); Aprendizado profundo (Deep learning); Linguagem Python como ferramenta para análise e automação em ciências de dados e inteligência artificial.

Programa

1. Dados, informação e tomada de decisão

- a. Dados como geradores de informação e conhecimento;*
- b. Tipos de dados: dados categóricos/qualitativos (nominais e ordinais), dados numéricos/quantitativos (discretos e contínuos) e dados binários;*
- c. Dados estruturados e não estruturados;*
- d. Business Intelligence (BI) e decisões baseadas em dados (data-driven decision);*
- e. Big Data: conceito e sistemas de armazenamento de dados e processamento;*
- f. GPUs (Graphics Processing Unit) e computação em nuvem (cloud computing) como tecnologias facilitadoras da análise de dados.*

2. Coleta de dados na Web

- a. Estrutura básica de páginas Web: HTML, CSS e JavaScript;*
- b. Coleta de dados com Web Scraping;*
- c. APIs (Application Programming Interface): conceito de API e padrões universais de estruturação de dados (XML e JSON) para a integração entre diferentes sistemas;*
- d. APIs web (web services).*

3. Bancos de dados relacionais e não relacionais

- a. Bancos de dados relacional, sistema gestor de bancos de dados (SGBD) e linguagem SQL (Structured Query Language);*
- b. Bancos de dados não relacional (NoSQL): documentos, chave-valor, colunar e grafos.*

4. Análise descritiva e visualização de dados

- a. *Medidas de tendência central, medidas de dispersão, boxplot e detecção de outliers;*
- b. *Visualização de dados, tipos de gráficos e conceito de dashboard;* c. *Storytelling com dados;*
- d. *Gráficos estáticos, gráficos dinâmicos e dashboards em Python.*

5. Aprendizado de máquina (Machine Learning)

- a. *Aprendizado supervisionado:*
 - *Conceitos de parâmetros, hiperparâmetros, sobreajuste (overfitting), subajuste (underfitting), modelos de regressão e classificação.*
 - *Fluxo de trabalho em aprendizado supervisionado: pré-processamento dos dados (separação entre dados de treino, teste e validação, tratamento de dados ausentes e engenharia de recursos); treinamento, validação cruzada (k-fold cross-validation), otimização (grid search) e seleção de modelos preditivos; avaliação da capacidade de generalização de modelos preditivos; deploy de modelos preditivos.*
 - *Algoritmos de aprendizado supervisionado: regressão linear, regressão logística, K-vizinhos mais próximos, árvores de decisão, support vector machines, redes neurais (perceptron multicamadas).*
 - b. *Aprendizado não supervisionado:*
 - *Agrupamento de dados: algoritmos K-means e clustering hierárquico aglomerativo.*
- *Redução de dimensionalidade: algoritmos PCA, t-SNE e UMAP.*

6. Aprendizado profundo (Deep learning)

- a. *Redes neurais e redes neurais profundas;*
- b. *Conceitos de redes neurais convolucionais, redes neurais recorrentes e arquitetura transformers;*

-
- c. Inteligência artificial generativa e grandes modelos de linguagem (Large Language Models - LLMs);*
 - d. Desenvolvimento de aplicações utilizando APIs de LLMs.*

7. Linguagem Python como ferramenta para análise e automação em ciências de dados e inteligência artificial

- a. Linguagem Python e ambientes de desenvolvimento integrado (Jupyter Notebook, Google Colab, PyCharm e Visual Studio Code);*
 - b. Pacotes Python para ciência de dados e inteligência artificial (NumPy, SciPy, Matplotlib, Plotly, Pandas, Scikit-learn, Keras/TensorFlow, Pytorch, Transformers, BeautifulSoup, Selenium, Requests).*
-

APÊNDICE B: TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Estou ciente de que esta pesquisa, vinculada ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação da Universidade Federal de Itajubá, tem como objetivo a proposição de uma ferramenta visual *web* para estudos no contexto de aprendizado de máquina. Minha participação neste estudo consistirá na execução de atividades didáticas sobre aprendizado de máquina em uma ferramenta online e no preenchimento de questionários para avaliar a ferramenta.

Tenho conhecimento de que, sob nenhuma hipótese, os participantes desse estudo terão seus nomes citados em qualquer meio de divulgação desta pesquisa. Os pesquisadores responsáveis garantem o sigilo das informações coletadas que me identifiquem, bem como o uso desses dados apenas em publicações e eventos de natureza científica.

Estou ciente de que minha participação é inteiramente voluntária e gratuita. Não sofrerei qualquer prejuízo ou punição se, mesmo após o início do teste, resolver interromper a atividade.

Por meio deste, declaro que consinto voluntariamente em participar da pesquisa.

Itajubá, _____ de _____ de 2025.

Assinatura do pesquisador responsável

Assinatura do Participante

Agradecemos antecipadamente sua colaboração e nos colocamos à disposição para esclarecer eventuais dúvidas pelos canais de comunicação abaixo.

Autor: Denis Willian da Silva; E-mail: denis.programacoes@gmail.com

Orientador: Rodrigo Duarte Seabra; E-mail: rodrigo@unifei.edu.br

Co-orientador: Luiz Carlos Bertucci Barbosa; E-mail: luizcbb@unifei.edu.br

APÊNDICE C:

QUESTIONÁRIO DE

IDENTIFICAÇÃO DO

PERFIL DO RESPONDENTE

Este questionário tem como objetivo mapear os perfis dos participantes, coletando informações sobre o acesso à tecnologia, a familiaridade com ferramentas educacionais e a experiência prévia com o conteúdo de aprendizado de máquina.

Nome: _____

Questão 1.1: Qual o seu gênero?

- ☐ Masculino
- ☐ Feminino
- ☐ Outro: Especifique _____
- ☐ Prefiro não dizer

Questão 1.2: Você tem acesso à internet em casa?

- ☐ Sim
- ☐ Parcialmente
- ☐ Não

Se preferir, discorra sobre sua resposta:

Questão 1.3: Quais dos dispositivos eletrônicos que se conectam a internet você possui? (pode marcar mais de uma resposta)

- ☐ Smartphone
- ☐ Computador de mesa
- ☐ Notebook
- ☐ Tablet
- ☐ Nenhum
- ☐ Outros: Especifique _____

Questão 1.4: Você já teve a oportunidade de utilizar uma ferramenta visual web para estudo de aprendizado de máquina antes deste experimento?

- ☐ Sim
- ☐ Não

Se preferir, discorra sobre sua resposta:

Questão 1.5: Como você considera seu conhecimento sobre aprendizado de máquina?

- ☐ Muito bom
- ☐ Bom
- ☐ Regular
- ☐ Ruim
- ☐ Péssimo

Se preferir, discorra sobre sua resposta:

Questão 1.6: Você usa frequentemente a Internet para os estudos?

- ☐ Sim, diariamente
- ☐ Mais de três vezes por semana
- ☐ Três vezes por semana
- ☐ Menos de três vezes por semana
- ☐ Não utilizo

Se preferir, discorra sobre sua resposta:

Questão 1.7: Gosta da ideia de poder acessar em casa uma ferramenta visual *web* para estudo de aprendizado de máquina a qualquer hora, quando precisar e sem custo?

- () Concordo totalmente
- () Concordo parcialmente
- () Não concordo nem discordo
- () Discordo parcialmente
- () Discordo totalmente

Se preferir, discorra sobre sua resposta:

APÊNDICE D:

QUESTIONÁRIO DE

REAÇÃO AO USO E

ACEITAÇÃO DA

FERRAMENTA

Este formulário busca explorar as experiências e percepções de usuários sobre o uso da ferramenta Visual-AM, considerando suas opiniões quanto à clareza do conteúdo e à eficácia da ferramenta no apoio ao estudo de aprendizado de máquina.

Nome: _____

Questão 2.01: A Visual-AM é compreensível e de fácil manuseio?

- () Concordo totalmente
- () Concordo parcialmente
- () Não concordo nem discordo
- () Discordo parcialmente
- () Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.02: Na sua opinião, o uso da Visual-AM despertou seu interesse sobre os conteúdos de aprendizado de máquina nela abordados?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.03: O uso da Visual-AM auxiliou o entendimento de conceitos de aprendizado de máquina?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.04: Você se sente confiante ao utilizar a Visual-AM?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.05: Você acredita que saberá usar o conhecimento adquirido por meio da Visual-AM em futuras práticas?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.06: Após utilizar a Visual-AM, você sente que aprofundou seus conhecimentos sobre aprendizado de máquina?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.07: Como você avalia os recursos visuais disponibilizados pela ferramenta (cores, imagens, GIFs, botões, dimensão das telas, tamanho do texto etc.)?

- ☐ Excelentes
- ☐ Bons
- ☐ Regulares
- ☐ Ruins
- ☐ Péssimos

Se preferir, discorra sobre sua opinião:

Questão 2.08: Os gráficos, imagens, GIFs e tabelas presentes na Visual-AM facilitaram seu estudo?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.09: Você se sentiu sobrecarregado pelas informações apresentadas por texto, imagens, GIFs, gráficos e tabelas presentes na Visual-AM?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.10: As imagens dinâmicas (GIFs), presentes na Visual-AM, facilitaram o estudo sobre conceitos de aprendizado de máquina?

- ☐ Concordo totalmente
- ☐ Concordo parcialmente
- ☐ Não concordo nem discordo
- ☐ Discordo parcialmente
- ☐ Discordo totalmente

Discorra sobre sua opinião:

Questão 2.11: A forma com que os conteúdos presentes na Visual-AM são apresentados e, posteriormente, detalhados é adequada?

- () Concordo totalmente
- () Concordo parcialmente
- () Não concordo nem discordo
- () Discordo parcialmente
- () Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.12: A Visual-AM apresenta palavras, imagens ou informações irrelevantes para o estudo dos conceitos de aprendizado de máquina?

- () Concordo totalmente
- () Concordo parcialmente
- () Não concordo nem discordo
- () Discordo parcialmente
- () Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.13: Você acredita que a Visual-AM apresenta conteúdo com repetições excessivas de informações?

- () Concordo totalmente
- () Concordo parcialmente
- () Não concordo nem discordo
- () Discordo parcialmente
- () Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.14: Quais dos dispositivos eletrônicos que se conectam à Internet você utilizou para acessar a Visual-AM? (pode marcar mais de uma resposta)

- ☐ Smartphone
☐ Computador
☐ Tablet
☐ Outros: Especifique _____

Se preferir, discorra sobre sua opinião:

Questão 2.15: Você usaria a Visual-AM novamente?

- ☐ Concordo totalmente
☐ Concordo parcialmente
☐ Não concordo nem discordo
☐ Discordo parcialmente
☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.16: Você gostaria que outras disciplinas explorassem ferramentas similares para o estudo e reforço dos conteúdos aprendidos em sala de aula?

- ☐ Concordo totalmente
☐ Concordo parcialmente
☐ Não concordo nem discordo
☐ Discordo parcialmente
☐ Discordo totalmente

Se preferir, discorra sobre sua opinião:

Questão 2.17: Gostaria de fazer algum comentário geral sobre o uso da Visual-AM?

☐ Não

☐ Sim

Se sim, discorra sobre sua opinião:

Questão 2.18: Você identificou algum defeito e/ou gostaria de sugerir melhorias para a Visual-AM?

☐ Não

☐ Sim

Se sim, discorra sobre sua opinião:

APÊNDICE E:

DIAGRAMAS UML

Este apêndice apresenta os diagramas de atividades UML referentes aos principais tópicos da ferramenta.

As Figuras 62, 63 e 64 apresentam os diagramas de atividades UML correspondentes à implementação do tópico de classificação. Devido à sua extensão, este diagrama foi dividido em três figuras.




Figura 62. Diagrama de atividades UML do tópico de classificação (parte 1 de 3). Fonte: O autor.




Figura 63. Diagrama de atividades UML do tópico de classificação (parte 2 de 3). Fonte: O autor.




Figura 64. Diagrama de atividades UML do tópico de classificação (parte 3 de 3). Fonte: O autor.

As Figuras 65, 66 e 67 apresentam o diagrama de atividades UML referente ao tópico de regressão, dividido em três partes para facilitar a visualização.




Figura 65. Diagrama de atividades UML do tópico de regressão (parte 1 de 3). Fonte: O autor.




Figura 66. Diagrama de atividades UML do tópico de regressão (Parte 2 de 3). Fonte: O autor.




Figura 67. Diagrama de atividades UML do tópico de regressão (parte 3 de 3). Fonte: O autor.

A Figura 68 apresenta o diagrama de atividades UML referente ao tópico de clusterização.




Figura 68. Diagrama de atividades UML do tópico de clusterização. Fonte: O autor.

A Figura 69 apresenta o diagrama de atividades UML referente à redução de dimensionalidade.




Figura 69. Diagrama de atividades UML do tópico de redução de dimensionalidade. Fonte: O autor.