



**INSTITUTO
FEDERAL**

Paraíba

Instituto Federal da Paraíba

Campus João Pessoa

Programa de Pós-Graduação em Tecnologia da Informação

Nível Mestrado Profissional

RAYLLON SOARES PESSOA

**ENSINO DE APRENDIZAGEM DE MÁQUINA EM UM
CURSO TÉCNICO: UMA INTERVENÇÃO PEDAGÓGICA
COM APRENDIZAGEM BASEADA EM PROBLEMAS**

DEFESA DE MESTRADO

JOÃO PESSOA – PB

julho - 2025

RAYLLON SOARES PESSOA

**ENSINO DE APRENDIZAGEM DE MÁQUINA EM UM
CURSO TÉCNICO: UMA INTERVENÇÃO PEDAGÓGICA
COM APRENDIZAGEM BASEADA EM PROBLEMAS**

Qualificação de Mestrado apresentada como requisito parcial para obtenção do título de Mestre em Tecnologia da Informação pelo Programa de Pós-Graduação em Tecnologia da Informação (PPGTI) do Instituto Federal da Paraíba – IFPB.

Orientador: Prof. Dr. Lafayette Batista Melo

João Pessoa – PB

Julho - 2026

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Nilo Peçanha - *campus* João Pessoa, PB.

P475e Pessoa, Rayllon Soares.

Ensino de aprendizagem de máquina em um curso técnico :
uma intervenção pedagógica com a aprendizagem baseada em
problemas / Rayllon Soares Pessoa. – 2026.

150 f. : il.

Dissertação (Mestrado em Tecnologia da Informação) – Institu-
to Federal de Educação da Paraíba / Programa de Pós-Graduação
em Tecnologia da Informação (PPGTI), 2026.

Orientação: Prof. Dr. Lafayette Batista Melo.

1. Aprendizagem baseada em problemas (ABP). 2. Inteligência
artificial. 3. *Machine learning (ML)*. 4. Ensino técnico. 5. Meto-
dologias ativas. I. Título.

CDU 004.8:37.015.3(043)

RAYLLON SOARES PESSOA

**ENSINO DE APRENDIZAGEM DE MÁQUINA EM UM CURSO TÉCNICO: UMA INTERVENÇÃO
PEDAGÓGICA COM APRENDIZAGEM BASEADA EM PROBLEMAS**

DISSERTAÇÃO submetida Programa de Pós- Graduação em Tecnologia da Informação do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba - IFPB, Campus João Pessoa, como requisito para obtenção do título de **Mestre em Tecnologia da Informação**.

Aprovado em 17/03/2026.

Membros da Banca Examinadora:

Prof. Dr. LAFAYETTE BATISTA MELO

Instituto Federal da Paraíba (IFPB)

Orientador

Prof. Dr. FRANCISCO PETRÔNIO ALENCAR DE MEDEIROS

Instituto Federal da Paraíba (IFPB)

Examinador

Profa. Dra. LAUDELINA BRAGA

Instituto Federal de Goiás (IFG)

Examinadora

Documento assinado eletronicamente por:

- **Lafayette Batista Melo, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 01/04/2026 15:10:39.
- **Francisco Petronio Alencar de Medeiros, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 06/04/2026 17:47:28.
- **LAUDELINA BRAGA, PRESTADOR DE SERVIÇO**, em 13/04/2026 14:50:13.

Este documento foi emitido pelo SUAP em 02/03/2026. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 842353
Verificador: 75d8a8ded9
Código de Autenticação:



Este trabalho é dedicado à minha companheira, Renata, que com seu apoio constante e motivação incansável, sempre me encorajou a seguir em frente, mesmo diante dos desafios.

AGRADECIMENTOS

Em primeiro lugar, minha gratidão a Deus, por iluminar meu caminho e me conceder força e sabedoria para seguir adiante.

À minha família, por seu apoio inabalável, por cada palavra de encorajamento e por acreditar em mim mesmo nos momentos mais desafiadores.

Aos meus amigos, que com seu incentivo e companheirismo, tornaram esta jornada mais leve e significativa.

Ao meu orientador, Lafayette Batista Melo, cuja orientação, dedicação e apoio foram fundamentais para a realização deste trabalho.

RESUMO

Esta dissertação investiga os impactos da Aprendizagem Baseada em Problemas (ABP) no ensino de aprendizagem de máquina no ensino técnico no contexto do ensino médio técnico em Informática. O estudo foi desenvolvido em uma escola pública estadual da Paraíba, no âmbito de uma intervenção pedagógica realizada ao longo de um semestre letivo, envolvendo planejamento, implementação, coleta e análise de dados. A proposta foi organizada em ciclos temáticos orientados por problemas contextualizados, com produção de artefatos pelos estudantes, como implementações em linguagem de programação, registros técnicos, mapas conceituais e apresentações. O processo foi apoiado por recursos e plataformas digitais, incluindo ambiente virtual de aprendizagem e ferramentas voltadas à análise e experimentação em Ciência de Dados. A avaliação integrou evidências teóricas individuais, produções práticas em grupo e instrumentos de autoavaliação e feedback discente. Os resultados indicam fortalecimento da compreensão conceitual e melhor desempenho nas atividades práticas, associado a elevada percepção de autenticidade, relevância e conexão com situações reais. Também se observou aceitação consistente do método e intenção favorável de continuidade, embora tenham sido identificados desafios operacionais relacionados à disponibilidade de tempo, recursos, infraestrutura tecnológica, heterogeneidade de conhecimentos prévios e exigências de acompanhamento docente. Conclui-se que a ABP, quando adaptada ao ensino técnico, é viável e tende a favorecer aprendizagem aplicada e engajamento, desde que acompanhada de ajustes de cronograma, suporte pedagógico e condições tecnológicas adequadas.

Palavras-chaves: Aprendizagem Baseada em Problemas (ABP); Inteligência Artificial (IA); Machine Learning (ML); Ensino Técnico; Metodologias Ativas.

ABSTRACT

This dissertation examines the impacts of Problem-Based Learning (PBL) on the teaching of Artificial Intelligence (AI) and Machine Learning (ML) in the context of technical secondary education in Informatics. The study was conducted in a public state school in Paraíba through a semester-long pedagogical intervention encompassing planning, implementation, data collection, and analysis. The proposal was organized into thematic cycles driven by contextualized problems and by the production of student artifacts such as programming implementations, technical records, concept maps, and presentations. The process was supported by digital platforms and tools for learning management and data experimentation. Assessment combined individual theoretical evidence, group-based practical deliverables, and student self-assessment and feedback instruments. The findings suggest strengthened conceptual understanding and improved performance in practical tasks, alongside a high perception of authenticity, relevance, and connection to real-world contexts. Students also demonstrated consistent acceptance of the approach and a positive intention to continue with similar experiences. However, operational challenges were identified, including time constraints, limited resources, technological infrastructure issues, heterogeneous prior knowledge, and increased demands for ongoing tutoring and feedback. Overall, results support the feasibility of an adapted PBL approach in technical education to foster applied learning and engagement, provided that scheduling, pedagogical support, and technological conditions are strengthened.

Keywords: Problem-Based Learning (PBL); Artificial Intelligence (AI); Machine Learning (ML); Technical Education; Active Learning.

LISTA DE FIGURAS

Figura 1- Habilidades do ser humano versus máquina.	29
Figura 2– Etapas da Revisão Sistemática	41
Figura 3 - String de busca	42
Figura 4 - Localização da escola.....	47
Figura 5 - Fluxograma da aplicação do PBL no componente de Inteligência Artificial	50
Figura 6 - Palestra promovida por profissionais da SNN Tecnologia - O Futuro da Programação Frente à Inteligência Artificial	54
Figura 7 - Localização de rotas na Romênia, usando heurística.....	55
Figura 8 - Modelagem de Risco de Crédito	58
Figura 9 - Fluxos de trabalho no Orange Data Mining para os algoritmos de classificação	59
Figura 10 - Visualização da base Automobile no Orange com os resultados da Regressão Linear	63
Figura 11 - Espécies de Íris no Conjunto de Dados Iris	65
Figura 12 - Dispersão das Espécies de Íris	66
Figura 13 - Protótipo do Projeto 1: visualização de horários por turma e professor.	77
Figura 14 - Protótipo do Projeto 2: interface de consulta climática	78
Figura 15 - Protótipo do Projeto 3: tela de consulta/emissão e geração do boletim em PDF	80
Figura 16 - Média por critério (1–3) e % do critério	83

LISTA DE TABELAS E GRÁFICOS

Tabela 1 - Trabalhos Seleccionados, Incluídos e excluídos	43
Tabela 2 - Cronograma da intervenção pedagógica baseada em ABP/PBL	53
Tabela 3 - Matriz de evidências do ciclo ABP (7 etapas).....	73
Tabela 4 - Percepções dos estudantes sobre a intervenção ABP/PBL	87
Gráfico 1 - Distribuição de ferramentas.....	76
Gráfico 2 - Médias por projeto e classificação	82
Gráfico 3 - Desempenho consolidado no Google Classroom por grupo (avaliações teóricas e práticas).	84
Gráfico 4 - Média de desempenho por ciclo de conteúdo no Google Classroom (C1–C4).	86
Gráfico 5 - Distribuição do feedback dos estudantes por dimensão	89

LISTA DE ABREVIATURAS E SIGLAS

ABP	Aprendizagem Baseada em Problemas
CA	Classification Accuracy
ECI	Escolas Cidadãs Integrais
ECIS	Escolas Cidadãs Integrais Socioeducativas
ECIT	Escolas Cidadãs Integrais Técnicas
EPA	Estudos, Planejamento e Atendimento
FBT	Formação Básica para o Trabalho
FGB	Formação Geral Básica
FPE	Formação Profissional Específica
GEECT	Gerência Executiva de Educação das Escolas Cidadãs Técnicas
IA	Inteligência Artificial
IF	Itinerário Formativo
IFPB	Instituto Federal da Paraíba
LDB	Lei de Diretrizes e Bases da Educação Nacional
ML	Machine Learning
PPGTI	Programa de Pós-Graduação em Tecnologia da Informação
RSL	Revisão Sistemática da Literatura
SENAC	Serviço Nacional de Aprendizagem Comercial
SENAI	Serviço Nacional de Aprendizagem Industrial
TAE	Teoria da Aprendizagem Experiencial

SUMÁRIO

1. INTRODUÇÃO	13
1.1. Motivação e Definição do Problema	13
1.2. Objetivos.....	15
2. FUNDAMENTAÇÃO TEÓRICA.....	16
2.1. Educação Profissional Técnica em Tempo Integral	17
2.1.1. Histórico e Evolução da Educação Profissional Técnica no Brasil	17
2.1.2. Educação Integral e Ensino Técnico na Paraíba: Avanços e Desafios	19
2.1.3. Curso Técnico de Informática na Rede Estadual da Paraíba	20
2.2. Aprendizagem Baseado em Problemas	21
2.2.1. Fundamentação conceitual e origens do ABP	22
2.2.2. O processo clássico do ABP segundo Barrows e Woods.....	23
2.2.3. Aplicações do ABP em Computação e Engenharia.....	25
2.2.4. A experiência do ABP em cursos técnicos integrados	26
2.2.5. Principais desafios e papel do docente na implementação	26
2.3. Ensino de Inteligência Artificial	27
2.3.1. Fundamentos da Inteligência Artificial	27
2.3.2. Aprendizado Supervisionado e Não Supervisionado	30
2.3.3. IA no Contexto Educacional.....	31
2.3.4. Aplicação do PBL e Desafios no Ensino de IA e Machine Learning.....	33
2.4. Trabalhos Relacionados.....	34
2.4.1. PBL no ensino de Computação e Programação	34
2.4.2. PBL no ensino técnico integrado.....	36
2.4.3. Metodologias ativas no ensino de IA e ML.....	37
3. METODOLOGIA DE PESQUISA E APLICAÇÃO DO PBL.....	39
3.1. Revisão Sistemática Da Literatura	40
3.1.1. Introdução a revisão sistemática da literatura.....	40
3.1.2. Objetivos e Perguntas de Pesquisa da Revisão Sistemática	41

3.1.3. Estratégia de busca	41
3.1.4. Coletas dos trabalhos e fontes de busca	42
3.1.5. Critérios de Inclusão e Exclusão	43
3.2. Metodologia da Pesquisa	44
3.3. Universo da Pesquisa – Curso de Inteligência Artificial	46
3.4. Contexto e Participantes	48
3.5. Estrutura da intervenção	48
3.5 Aplicação do estudo.....	51
3.5.1. Desenvolvimento da proposta do PBL para o ensino de algoritmos iniciais	52
3.6. Instrumentos de Coleta e Critérios de Avaliação	68
4.7. Procedimentos de análise.....	69
4. RESULTADOS	72
4.1. Resultados da implementação da intervenção	72
4.1.1. Estrutura do ciclo ABP adotado (as 7 etapas adaptadas) e produtos gerados.	72
4.1.2. Síntese dos quatro ciclos e do fluxo Planejamento–Execução–Avaliação.....	74
4.1.3. Culminância e projeto integrador	76
4.2. Aplicação conceitual e desempenho.....	84
4.3. Percepções dos estudantes	87
4.3.1. Distribuição das percepções	89
4.3.2. Categorias emergentes.....	90
4.4. Potencialidades, limitações e recomendações	92
5. CONSIDERAÇÕES FINAIS.....	95
REFERÊNCIAS BIBLIOGRÁFICAS	96
APÊNDICE A - MATRIZ CURRICULAR DO CURSO TÉCNICO EM INFORMÁTICA INTEGRADO AO ENSINO MÉDIO	101
APÊNDICE B – RELATÓRIO DE CONSULTAS DE AGREGAÇÃO MONGODB	102
APÊNDICE C – LEVANTAMENTOS DE TRABALHOS	104
APÊNDICE D– DIVISÃO DO CLASSROOM – ALGORITMO DE BUSCA	108
APÊNDICE E – MATERIAL EM SLIDES - ALGORITMO DE BUSCA.....	110

APÊNDICE F – CÓDIGO DA ATIVIDADE PRÁTICA COM ALGORITMO DE BUSCA	111
APÊNDICE G – FORMULÁRIO AVALIATIVO ALGORITMO DE BUSCA	112
APÊNDICE H – DIVISÃO DO CLASSROOM – ALGORITMO CLASSIFICAÇÃO.....	118
APÊNDICE I – MATERIAL EM SLIDE DE ALGORITMO DE CLASSIFICAÇÃO	120
APÊNDICE J – CONJUNTO DE DADOS PARA ATIVIDADES PRÁTICAS – ALGORITMO CLASSIFICAÇÃO.....	122
APÊNDICE K – BASES DE DADOS ELABORADAS PELOS ESTUDANTES PARA AVALIAÇÃO DE ALGORITMOS DE CLASSIFICAÇÃO	123
APÊNDICE L – FORMULÁRIO AVALIATIVO ALGORITMO DE CLASSIFICAÇÃO .	128
APÊNDICE M – DIVISÃO DO CLASSROOM – ALGORITMO DE REGRESSÃO LINEAR	132
APÊNDICE N – MATERIAL EM SLIDE – ALGORITMO DE REGRESSÃO LINEAR .	133
APÊNDICE O – CONJUNTO DE DADOS PARA ATIVIDADES PRÁTICAS – ALGORITMO REGRESSÃO LINEAR	134
APÊNDICE P –ATIVIDADE PRÁTICA - ALGORITMO REGRESSÃO LINEAR.....	135
APÊNDICE Q –FORMULARIO AVAL - ALGORITMO REGRESSÃO LINEAR.....	136
APÊNDICE R – ESTRUTURA DO CLASSROOM- ALGORITMO DE AGRUPAMENTO	141
APÊNDICE S – BASE ÍRIS	142
APÊNDICE T – MATERIAL EM SLIDE- ALGORITMO DE AGRUPAMENTO.....	143
APÊNDICE U –FORMULARIO AVALIATIVO - ALGORITMO DE AGRUPAMENTO	144
APÊNDICE V – PLATAFORMA DE SIMULAÇÃO - ALGORITMO DE AGRUPAMENTO	146
APÊNDICE W - PLATAFORMA OPENWEATHERMAP UTILIZADA COMO FONTE DE DADOS (API) NO PROJETO DE ANÁLISE CLIMÁTICA POR REGRESSÃO	147
APÊNDICE X – DISTRIBUIÇÃO DO USO DE FERRAMENTAS DIGITAIS POR FASE DA INTERVENÇÃO	148
APÊNDICE XA - RUBRICA DE AVALIAÇÃO DA INTERVENÇÃO BASEADA EM ABP	149

1. INTRODUÇÃO

Nos últimos anos, a inteligência artificial tem se tornado um fator crucial no avanço de tecnologias em diferentes setores, incluindo automação, análise de dados e personalização de serviços, desempenhando um papel cada vez mais relevante na transformação digital global (Russell; Norvig, 2021). A crescente demanda por profissionais qualificados nesta área ressalta a necessidade de métodos educacionais adequados para transmitir esses conhecimentos complexos de maneira prática e atrativa.

O ensino tradicional de IA e ML frequentemente enfrenta desafios, como baixo engajamento dos alunos, dificuldades em aplicar conhecimentos teóricos a problemas práticos, e uma carência de habilidades críticas necessárias para resolver problemas em situações reais. Apesar do avanço nas tecnologias educacionais, existem lacunas, entre elas, destaca-se a falta de foco em habilidades práticas e métodos ativos no ensino de IA e ML (SU; NG; CHU, 2023). Desta forma a pesquisa parte da seguinte hipótese: a utilização da metodologia de Aprendizagem Baseada em Problemas (ABP) no ensino de Inteligência Artificial pode auxiliar na superação das principais dificuldades do processo de aprendizagem, oferecendo uma abordagem mais dinâmica e centrada no aluno, que favoreça tanto a compreensão dos conceitos quanto a sua aplicação prática.

Aprendizagem Baseada em Problemas (ABP) é uma metodologia que vem ganhando destaque em diversos campos da educação por sua capacidade de fomentar habilidades críticas e práticas nos alunos. A ABP promove um ambiente de aprendizado ativo, onde os estudantes são incentivados a resolver problemas reais, colaborando em grupos e aplicando teorias na prática (DELISLE, 1997). Desse modo, a ABP contrasta com os métodos tradicionais de ensino, que são frequentemente baseados em exposições teóricas e exercícios descontextualizados, resultando em uma compreensão limitada e com pouca aplicação prática dos conceitos.

1.1. Motivação e Definição do Problema

A motivação deste estudo nasce da necessidade de qualificar o ensino de Inteligência Artificial (IA) e Aprendizado de Máquina (ML) no contexto da educação técnica em computação. Em cursos técnicos, especialmente na rede pública, esses conteúdos costumam ser percebidos pelos estudantes como difíceis, por envolverem bases matemáticas, lógica e programação. Muitos alunos já chegam ao ensino técnico com lacunas importantes em matemática e raciocínio lógico, o que gera insegurança e, em diversos casos, uma resistência inicial em relação aos componentes ligados à computação avançada, como IA e ML. Nessas

condições, os conteúdos tendem a ser trabalhados de forma fragmentada e pouco conectada ao cotidiano, reforçando a sensação de abstração excessiva e dificultando sua aplicação em situações reais.

O problema central desta pesquisa consiste na dificuldade dos estudantes em mobilizar os conhecimentos de programação e algoritmos para resolver problemas reais, seja no contexto escolar, seja em situações do cotidiano. Apesar de frequentarem um curso técnico em Desenvolvimento de Sistemas, muitos não conseguem transferir o que aprendem em sala para a construção de soluções computacionais que otimizem processos ou atendam demandas concretas, revelando um distanciamento entre o ensino de código e a aplicação prática em cenários significativos.

Dessa forma, a pergunta que orienta esta pesquisa pode ser formulada da seguinte maneira: **De que maneira a implementação da Aprendizagem Baseada em Problemas no componente de Inteligência Artificial de um curso técnico integrado em Desenvolvimento de Sistemas contribui para promover novas experiências de aprendizagem e favorecer a reflexão crítica dos estudantes na elaboração de soluções computacionais para problemas reais?** Mais especificamente, investiga-se se a utilização da Aprendizagem Baseada em Problemas (ABP), articulada a estratégias computacionais, pode contribuir para tornar esses conteúdos mais acessíveis, significativos e próximos da realidade dos estudantes, aproximando teoria e prática por meio de problemas concretos e contextualizados.

No âmbito educacional, este estudo busca oferecer evidências sobre o potencial da ABP como alternativa metodológica para o ensino de disciplinas técnicas de computação que exigem forte base matemática e lógica, como IA e ML. Ao analisar seus efeitos no engajamento, na compreensão conceitual e na capacidade de aplicar os conteúdos em situações reais, a pesquisa pretende subsidiar a revisão de currículos e práticas pedagógicas, incentivando a adoção de metodologias ativas que coloquem o estudante em posição mais protagonista no processo de aprendizagem.

Do ponto de vista científico-tecnológico, a investigação contribui ao examinar de forma sistemática os impactos da ABP, em conjunto com o uso de softwares e recursos digitais, no desempenho dos alunos e na qualidade da aprendizagem em IA e ML. Os dados produzidos podem servir de referência para futuros estudos sobre metodologias ativas no ensino técnico, bem como para o desenvolvimento de materiais, atividades e ferramentas educacionais específicas para o trabalho com conceitos que articulam matemática, lógica, programação e inteligência artificial.

Por fim, em uma perspectiva social e profissional, ao colaborar para a melhoria da formação em IA e ML na educação técnica, este estudo auxilia na preparação de profissionais mais críticos, autônomos e capazes de atuar em um mercado de trabalho cada vez mais digital e orientado por dados. Ao favorecer a superação das dificuldades iniciais relacionadas à matemática e à lógica e ao aproximar os conteúdos de situações concretas, a pesquisa contribui para formar estudantes que compreendem tanto a dimensão teórica quanto as implicações práticas da IA, o que é essencial para a inovação tecnológica, o desenvolvimento regional e a inserção qualificada desses sujeitos no mundo do trabalho.

1.2. Objetivos

Objetivo geral

Analisar de que maneira a implementação da Aprendizagem Baseada em Problemas no componente de Inteligência Artificial contribui para que os estudantes utilizem programação e algoritmos, de forma crítica, na construção de soluções computacionais para problemas reais.

Objetivos específicos

- Descrever o planejamento e a implementação da intervenção didática baseada em ABP no componente de Inteligência Artificial, explicitando os problemas propostos, as etapas do ciclo e as atividades desenvolvidas com os estudantes.
- Analisar em que medida os estudantes apresentam conhecimentos de programação, algoritmos e conceitos introdutórios de IA/ML para propor e desenvolver soluções computacionais voltadas a problemas reais.
- Investigar as percepções dos estudantes sobre o uso da ABP no componente de Inteligência Artificial, com foco na reflexão crítica, no engajamento e na relação entre as atividades e situações reais do seu contexto.
- Identificar potencialidades e limitações da ABP/ no contexto investigado, apontando recomendações para o aperfeiçoamento de futuras práticas de ensino que articulem programação, IA/ML e solução de problemas reais.

2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta o referencial teórico que sustenta a pesquisa e fundamenta a interpretação dos resultados da intervenção pedagógica com Aprendizagem Baseada em Problemas (ABP/PBL) no ensino de Inteligência Artificial (IA) e Machine Learning (ML) no ensino médio técnico. A fundamentação é organizada para articular três dimensões centrais do estudo: (i) o contexto político-pedagógico da Educação Profissional Técnica em regime integral, (ii) os pressupostos conceituais e operacionais do PBL como metodologia ativa, e (iii) os fundamentos do ensino de IA e suas implicações formativas no currículo técnico.

No plano macro, a Educação Profissional e Tecnológica (EPT) no Brasil é marcada por sucessivas reformas e reconfigurações legais, desde as primeiras iniciativas de institucionalização da formação profissional no início do século XX até os marcos contemporâneos que reforçam a integração entre ensino médio e formação técnica (BRASIL, 1909; BRASIL, 2008). Mais recentemente, a reorganização do ensino médio e a inclusão dos itinerários formativos, entre eles a Formação Técnica e Profissional, reforçam a necessidade de práticas pedagógicas que promovam aprendizagem significativa, protagonismo discente e resolução de problemas contextualizados (BRASIL, 2017).

No plano meso, a política de educação integral na Paraíba constitui o cenário institucional desta investigação, ao estabelecer o Programa de Educação Integral e formalizar a estrutura organizacional das escolas integrais e técnicas, bem como orientações operacionais e curriculares associadas ao modelo (PARAÍBA, 2018; PARAÍBA, 2024). Nesse contexto, a ABP/PBL é discutida como abordagem coerente com a formação técnica por competências, pois desloca o foco da reprodução de conteúdos para a mobilização de conhecimentos, investigação, colaboração e produção de soluções — dimensões que dialogam diretamente com as exigências formativas de IA/ML no nível médio técnico.

Por fim, ao tratar especificamente do ensino de IA, o capítulo delimita conceitos essenciais e explicita por que a aprendizagem dessa área demanda estratégias que conciliem fundamentação teórica, experimentação e interpretação crítica de resultados, considerando o impacto social e técnico das decisões algorítmicas. Assim, a fundamentação teórica cumpre o papel de explicitar o marco legal e curricular, o modelo didático-metodológico e o campo técnico que convergem no desenho da intervenção e na análise do fenômeno investigado.

2.1. Educação Profissional Técnica em Tempo Integral

Este tópico apresenta a Educação Profissional Técnica em Tempo Integral como base estruturante do contexto em que a pesquisa se insere. Discute-se a evolução histórica e normativa da educação profissional no Brasil, evidenciando como reformas e marcos legais consolidaram essa modalidade como estratégia de qualificação e inserção social. Em seguida, o texto situa a política de Educação Integral na Paraíba, destacando avanços e desafios das ECIs/ECITs na organização curricular, na gestão do tempo pedagógico e nas condições de implementação. Por fim, caracteriza-se o Curso Técnico em Informática na rede estadual, com sua estrutura curricular, organização por módulos e potencial formativo para desenvolver competências digitais e profissionais alinhadas às demandas contemporâneas.

2.1.1. Histórico e Evolução da Educação Profissional Técnica no Brasil¹

A educação profissional e técnica no Brasil tem suas raízes no início do século XX, sendo impulsionada por diversas reformas e decretos que visaram adaptar a formação dos trabalhadores às demandas industriais e econômicas do país.

A origem da educação profissional no Brasil remonta ao ano de 1909, quando o presidente Nilo Peçanha assinou o Decreto nº 7.566, em 23 de setembro, criando 19 Escolas de Aprendizes e Artífices. Essas escolas foram estabelecidas com o intuito de fornecer formação técnica e profissional básica aos jovens, preparando-os para o mercado de trabalho. Esse movimento inicial marcou o começo da formalização da educação profissional no país.

Em 1927, o Decreto nº 5.241, de 27 de agosto, tornou obrigatório o ensino profissional nas escolas primárias subvencionadas ou mantidas pela União. Esse decreto refletia a necessidade crescente de mão-de-obra qualificada para acompanhar a industrialização do país. A Constituição de 1937, promulgada durante o governo de Getúlio Vargas, enfatizou ainda mais a importância da educação profissional e industrial, estabelecendo que indústrias e sindicatos econômicos deveriam criar escolas de aprendizes especializadas.

O Decreto-Lei nº 4.073, de 30 de janeiro de 1942, conhecido como Lei Orgânica do Ensino Industrial, estruturou o ensino industrial em dois ciclos: o primeiro abrangia o ensino básico, de mestria, artesanal e de aprendizagem, enquanto o segundo ciclo compreendia o ensino técnico e pedagógico. Nesse mesmo ano, o Decreto-Lei nº 4.048 criou o Serviço

¹ As informações de ordem evolutiva sobre a educação profissional e técnica no Brasil apresentadas nesse subtópico têm como base de referência o site do Ministério da Educação. Disponível em: <http://portal.mec.gov.br/publicacoes-para-professores/30000-uncategorised/68731-historico-da-educacao-profissional-e-tecnologica-no-brasil>. Acesso em: 14 de julho de 2024.

Nacional de Aprendizagem Industrial (SENAI), responsável por organizar e promover a educação profissional industrial.

A década de 1940 foi marcada por importantes avanços na educação profissional. Em 1946, o Decreto-Lei nº 9.613, conhecido como Lei Orgânica do Ensino Agrícola, tratou dos estabelecimentos de ensino agrícola federais, e o Serviço Nacional de Aprendizagem Comercial (SENAC) foi criado pelo Decreto-Lei nº 8.621. Essas iniciativas diversificaram a oferta de formação profissional, abrangendo não apenas o setor industrial, mas também o agrícola e comercial.

Em 1959, as escolas técnicas federais foram instituídas como autarquias, ampliando a rede de instituições dedicadas à educação profissional. Em 1968, a Lei Federal nº 5.540 permitiu a oferta de cursos superiores destinados à formação de tecnólogos, reconhecendo a importância da educação técnica de nível superior.

A Lei nº 4.024, de 20 de dezembro de 1961, foi a primeira Lei de Diretrizes e Bases da Educação Nacional (LDB), permitindo que concluintes de cursos de educação profissional pudessem continuar estudos no ensino superior. A Lei nº 5.692, de 1971, determinou que todo o ensino de segundo grau deveria conduzir o educando à conclusão de uma habilitação profissional técnica ou, ao menos, de auxiliar técnico.

A segunda LDB, promulgada em 20 de dezembro de 1996, dedicou um capítulo à educação profissional, posteriormente atualizado pela Lei nº 11.741/2008, que incluiu uma seção específica sobre a educação profissional técnica de nível médio. A reforma educacional introduzida pela Lei nº 13.415/2017, atualizou a LDB, incluindo o itinerário formativo "Formação Técnica e Profissional" no ensino médio, reforçando a importância da formação técnica e profissional como parte integral do currículo escolar.

A educação profissional e técnica desempenha um papel crucial na preparação dos jovens para o mercado de trabalho, especialmente no ensino médio. Ela oferece uma formação prática e teórica, conectando os estudantes às demandas do setor produtivo e proporcionando-lhes habilidades e conhecimentos específicos para diversas áreas profissionais. O itinerário formativo "Formação Técnica e Profissional" introduzido pela Lei nº 13.415/2017 destaca a importância de experiências práticas de trabalho e a possibilidade de obtenção de certificados intermediários, ampliando as oportunidades de inserção no mercado de trabalho.

O histórico da educação profissional e técnica no Brasil demonstra uma evolução contínua e adaptativa, alinhada às transformações econômicas e sociais do país. Desde a criação das primeiras escolas de aprendizes até as recentes reformas educacionais, essa modalidade de

ensino tem se mostrado essencial para o desenvolvimento de uma mão-de-obra qualificada e para a promoção de oportunidades educacionais e profissionais para os jovens brasileiros.

2.1.2. Educação Integral e Ensino Técnico na Paraíba: Avanços e Desafios

A Lei nº 11.100, de 06 de abril de 2018, representa um marco significativo para a educação na Paraíba, instituindo o Programa de Educação Integral no Estado. Este programa abrange três tipos de escolas: Escolas Cidadãs Integrais (ECI), Escolas Cidadãs Integrais Técnicas (ECIT) e Escolas Cidadãs Integrais Socioeducativas (ECIS). Sob a gestão da Secretaria de Estado da Educação, o objetivo principal é planejar e implementar ações inovadoras em conteúdo, método e gestão, visando melhorar a oferta e a qualidade do ensino na rede pública estadual (PARAÍBA, 2018).²

As Escolas Cidadãs Integrais são estabelecimentos de Ensino Médio e Fundamental II que operam em período integral. Elas se destacam por um método didático e administrativo específico, focado na formação de indivíduos protagonistas e conscientes de seus valores sociais, promovendo o pleno exercício da cidadania. O currículo dessas escolas é desenhado para fomentar uma educação abrangente, que vai além do conhecimento acadêmico tradicional, englobando também o desenvolvimento de habilidades sociais e emocionais dos alunos. (DIRETRIZES OPERACIONAIS, 2024).

As Escolas Cidadãs Integrais Técnicas (ECIT), por outro lado, são voltadas para o Ensino Médio profissionalizante, também em período integral. O objetivo dessas instituições é formar profissionais qualificados, capazes de influenciar positivamente o mercado de trabalho e atuar com protagonismo em suas vidas profissionais e sociais. A carga horária dos cursos técnicos nas ECITs é de 40 horas semanais, seguindo o Regime de Dedicção Docente Integral (RDDI). Esta carga horária é cuidadosamente dividida para garantir um equilíbrio entre as atividades em sala de aula e as atividades de planejamento, estudos e atendimento (PARAÍBA, 2018).

Especificamente, a divisão da carga horária dos professores nas ECITs é de 28 horas semanais em sala de aula, incluindo atividades multidisciplinares, e 12 horas semanais dedicadas a Estudos, Planejamento e Atendimento (EPA). De acordo com a Lei Nº 11.100, 06 de abril de 2018, essas 12 horas podem ser realizadas no ambiente escolar ou em atividades pedagógicas planejadas pela escola em ambientes didáticos específicos. Além disso, essas horas estão disponíveis para substituição de outros professores ausentes, quando necessário. Essa

² PARAÍBA. Lei Nº 11.100, 06 de abril de 2018. Diário Oficial do Estado da Paraíba, João Pessoa, 12 abril 2018. Nº 7.532, p. 1-6.

estrutura visa proporcionar uma formação integral e de qualidade aos estudantes, preparando-os para atuar de forma competente e protagonista no mercado de trabalho.

As Escolas Cidadãs Integrals Técnicas desempenham um papel fundamental no desenvolvimento de processos formativos que fomentem o protagonismo juvenil e a formação de cidadãos solidários e socialmente ativos. Elas buscam desenvolver as aptidões individuais dos estudantes, conscientizando-os sobre suas responsabilidades e incentivando uma postura ativa e crítica frente aos desafios da sociedade contemporânea.

A implementação dessas escolas integrais e técnicas no Estado da Paraíba está alinhada com uma visão moderna de educação, que reconhece a necessidade de preparar os jovens não apenas academicamente, mas também para a vida profissional e social. As ECITs, em particular, estão comprometidas com a formação de profissionais que possam atuar com eficiência e responsabilidade no mercado de trabalho, trazendo inovação e dinamismo para suas áreas de atuação (DIRETRIZES OPERACIONAIS, 2024).

2.1.3. Curso Técnico de Informática na Rede Estadual da Paraíba

A Secretaria de Estado da Educação, por meio da Gerência Executiva de Educação das Escolas Cidadãs Técnicas (GEECT), propõe o Curso Técnico em Informática integrado ao Ensino Médio, pertencente ao eixo tecnológico de Informação e Comunicação. Este curso é uma iniciativa que busca aliar a formação geral básica à formação técnica, proporcionando aos estudantes uma educação completa e alinhada às demandas contemporâneas do mercado de trabalho. Com uma carga horária total de 4500 horas, o curso é estruturado em diversos componentes que compõem a Formação Geral Básica (FGB) com 1800 horas, e o Itinerário Formativo (IF) com 2700 horas que é dividido em Formação Básica para o Trabalho (FBT) e Formação Profissional Específica (FPE).

De acordo com a Matriz Curricular de 2024, a Formação Profissional Específica em Informática está organizada em cinco módulos, totalizando 1000 horas e abordando habilidades e conhecimentos específicos dentro da área de informática. O Módulo I, Operador de Computador, foca nas operações básicas de informática e uso de software de produtividade; o Módulo II, Montador e Reparador de Computadores, ensina os alunos a montar, reparar e realizar manutenção em equipamentos de hardware; o Módulo III, Programador WEB, é dedicado ao desenvolvimento de páginas e aplicações web, cobrindo linguagens de programação e design; o Módulo IV, Programador de Sistemas, aprofunda-se na programação de software e sistemas, abordando algoritmos e estruturas de dados; e o Módulo V,

Desenvolvedor de Sistemas de Tecnologia da Informação, prepara os alunos para desenvolver sistemas complexos, integrando diversas tecnologias e plataformas.

Em 2023, a Secretaria de Estado da Educação conta com 153 escolas voltadas para a formação profissional e técnica, incluindo as ECITs. Isso reflete o crescente acesso da população paraibana a uma área crucial para o mercado de trabalho. No entanto, esse crescimento exige a organização das políticas educacionais técnicas, garantindo uma distribuição mais equilibrada dos cursos pelo estado, ampliando oportunidades educacionais e profissionais de forma mais estratégica e equitativa.

A expansão e a redistribuição dos cursos técnicos em Informática pelo estado da Paraíba são passos fundamentais para democratizar o acesso à educação técnica e atender às demandas do mercado de trabalho de forma mais inclusiva. Promover uma distribuição mais equitativa desses cursos não só potencializa a formação de profissionais qualificados em diversas regiões, mas também contribui para o desenvolvimento socioeconômico local, reduzindo as desigualdades educacionais e oferecendo oportunidades para jovens de áreas menos favorecidas. Com uma estratégia de espacialização mais bem planejada, a Secretaria de Estado da Educação pode garantir que todos os alunos, independentemente de sua localização geográfica, tenham acesso à educação de qualidade e possam contribuir efetivamente para o avanço tecnológico e econômico da Paraíba.

2.2. Aprendizagem Baseado em Problemas

Este tópico apresenta e discute estudos empíricos e experiências aplicadas que dialogam diretamente com o objeto desta pesquisa: o uso da Aprendizagem Baseada em Problemas no ensino de Computação, Programação e Aprendizagem de Máquina. Diferentemente do capítulo anterior, que reúne fundamentos conceituais e teóricos sobre metodologias ativas, ABP, Inteligência Artificial e Aprendizagem de Máquina, este capítulo concentra-se em pesquisas que descrevem aplicações, experiências pedagógicas, modelos de intervenção ou análises de práticas educacionais em contextos próximos ao investigado nesta dissertação.

A seleção dos trabalhos relacionados foi orientada por três critérios principais. O primeiro foi a aproximação temática com a Aprendizagem Baseada em Problemas no ensino de Computação e Programação. O segundo foi a relação com o ensino técnico integrado ou com a formação profissional em informática. O terceiro foi a presença de experiências envolvendo Inteligência Artificial, Aprendizagem de Máquina, projetos computacionais ou metodologias

ativas aplicadas a conteúdos tecnológicos. Dessa forma, foram priorizados estudos que permitissem comparar contexto educacional, público participante, metodologia adotada, tipo de intervenção, instrumentos de avaliação e contribuições para o ensino de Computação.

Inicialmente, são apresentados trabalhos que aplicam a ABP no ensino de programação, destacando contribuições para a aprendizagem significativa, o desenvolvimento de competências e os desafios recorrentes de implementação. Em seguida, são discutidos estudos relacionados ao ensino técnico integrado, com ênfase na articulação entre teoria, prática, formação profissional e desenvolvimento de competências. Por fim, são analisadas experiências que aproximam metodologias ativas do ensino de Inteligência Artificial e Aprendizagem de Máquina. Ao final do capítulo, apresenta-se uma síntese comparativa dos trabalhos relacionados, evidenciando as lacunas identificadas na literatura e explicitando como esta dissertação avança em relação aos estudos analisados.

2.2.1. Fundamentação conceitual e origens do ABP

A Aprendizagem Baseada em Problemas (ABP), conhecida internacionalmente como *Problem-Based Learning* (PBL), é uma metodologia ativa que reorganiza o processo ensino-aprendizagem ao deslocar o centro do ensino do professor para o estudante. Surgiu nos anos 1960, na escola de Medicina da Universidade de McMaster, no Canadá, sob liderança de Howard S. Barrows, como resposta à necessidade de formar médicos capazes de lidar com problemas complexos e situações incertas da prática profissional. Barrows (1986) descreveu o PBL como um método no qual o aprendizado ocorre mediante o engajamento direto do aluno na análise e solução de problemas reais ou simulados, aproximando-se assim de situações profissionais autênticas.

Na concepção de Barrows (1986), o problema não é apresentado como um exercício isolado ou apenas ilustrativo do conteúdo, mas sim como o ponto de partida do processo de aprendizagem. Esse cenário obriga os estudantes a levantarem hipóteses, identificarem o que já sabem e o que precisam aprender, buscando assim conhecimentos de maneira autodirigida. O professor, por sua vez, atua como tutor ou facilitador, não como a fonte principal do saber, incentivando questionamentos e reflexões.

Essa proposta foi posteriormente sistematizada por Woods (1994) ao ser levada para a Engenharia, consolidando o ABP como um processo construtivista, que se alinha às teorias de Piaget e Vygotsky, na medida em que o conhecimento é construído ativamente a partir da resolução de problemas contextualizados e mediados socialmente.

2.2.2. O processo clássico do ABP segundo Barrows e Woods

O processo da Aprendizagem Baseada em Problemas, conforme estruturado por Howard S. Barrows (1986) e posteriormente aprofundado por Donald R. Woods (1994), é amplamente reconhecido como um dos avanços mais significativos da pedagogia universitária no século XX. Não obstante, ele não deve ser compreendido apenas como um roteiro técnico, mas antes como um dispositivo formativo que reconfigura radicalmente as dinâmicas cognitivas, sociais e metacognitivas do aprender. Seu desenho revela uma pedagogia ancorada no construtivismo e no princípio de que o conhecimento se constrói na ação reflexiva diante de situações complexas, e não apenas pela assimilação passiva de conteúdos prontos.

O ciclo do ABP inicia-se com a necessidade de compreender coletivamente o problema proposto. Esse primeiro momento, que Barrows (1986) denomina clarificação dos termos e Woods (1994) detalha como “interpretação partilhada do enunciado”, não é trivial: nele já se instala uma tensão epistemológica, pois os estudantes devem abandonar a expectativa de um problema perfeitamente delimitado e aceitar a ambiguidade como parte inerente do processo. Problemas bem elaborados, conforme defendem esses autores, são propositadamente abertos, exigindo dos estudantes a construção do próprio entendimento do fenômeno em análise. Esse enfrentamento inicial do incerto constitui o primeiro deslocamento cognitivo relevante do ABP.

Em seguida, o grupo empenha-se em definir o cerne do problema — ou seja, explicitar qual questão busca responder ou qual fenômeno precisa explicar ou intervir. Esse passo, que parece evidente à primeira vista, revela um dos pontos de maior complexidade do método: frequentemente, estudantes são formados em modelos pedagógicos que premiam respostas rápidas e superficiais, habituados a identificar problemas apenas no nível mais imediato. A ABP, por sua vez, demanda uma problematização aprofundada, que transcenda sintomas e alcance causas, relações e variáveis subjacentes. Aqui, o tutor cumpre o papel crucial de questionar e tensionar diagnósticos apressados, deslocando o estudante do conforto das primeiras impressões.

Segue-se então a etapa de análise do problema à luz do repertório prévio dos estudantes. Trata-se de um momento profundamente metacognitivo, pois exige mobilizar, reorganizar e até contestar conhecimentos anteriores. Barrows (1986) considera essa etapa o ponto de partida para o verdadeiro aprendizado significativo, já que o confronto entre o conhecido e o novo promove reestruturações cognitivas. Todavia, é também aqui que surgem riscos: grupos podem

apoiar-se excessivamente em conhecimentos fragmentários ou mesmo em concepções equivocadas não explicitadas, perpetuando erros. O tutor, atento, deve então provocar o exame crítico: “Em que baseiam essa suposição? Quais evidências sustentam essa relação causal que estão propondo?”

Uma das etapas mais sensíveis do ciclo é o reconhecimento do que precisa ser aprendido — aquilo que Woods (1994) chama de “identificação das lacunas conceituais”. Esse exercício explicitamente metacognitivo obriga o estudante a confrontar sua ignorância, algo que não é trivial nem psicologicamente confortável. Em contextos educacionais tradicionais, onde o fracasso é penalizado, admitir desconhecimento pode ser interpretado como fragilidade. O ABP, nesse sentido, é contracultural: valoriza o reconhecimento da ignorância como motor da aprendizagem. Contudo, nem todos os grupos conseguem naturalmente construir essa disposição. Sem a mediação habilidosa do tutor, pode-se cair em zonas de conforto onde lacunas relevantes são ignoradas.

Uma vez identificadas as necessidades de estudo, o grupo estabelece metas de aprendizagem — individuais e coletivas. Esse momento carrega implicações éticas e pedagógicas importantes: em muitos relatos (SANTOS; ANGELO, 2008), observa-se que grupos mais experientes distribuem tarefas equilibrando competências e desafios, enquanto grupos inseguros podem centralizar tópicos complexos nos mesmos membros, minando o desenvolvimento equitativo. Aqui emerge o delicado papel do tutor não como distribuidor autoritário, mas como catalisador de uma divisão solidária e formativa do trabalho.

O estudo autodirigido que se segue constitui talvez o núcleo mais distintivo da ABP em relação a métodos tradicionais. Barrows (1986) enfatiza que nesse momento o estudante aprende não apenas conteúdos, mas sobretudo competências epistemológicas: localizar fontes, avaliar confiabilidade, integrar dados díspares. É a prática da autonomia intelectual, da investigação disciplinada. No entanto, a literatura aponta limites: estudantes pouco familiarizados com leitura crítica podem buscar fontes superficiais, confirmar vieses, reproduzir respostas prontas encontradas em tutoriais online. O tutor, ciente desse risco, deve questionar: “Por que essa fonte merece credibilidade? Há evidências contrárias que consideraram?”

Ao regressar ao grupo, o estudante socializa o que aprendeu. É nesse compartilhar crítico que as aprendizagens individuais se transformam em saber coletivo, por meio de debates, confrontos argumentativos e revisões sucessivas das hipóteses. Woods (1994) nota que grupos imaturos tendem a evitar divergências, buscando consensos fáceis, o que enfraquece a

elaboração conceitual. Por isso, o tutor deve incentivar o confronto respeitoso de ideias, não apenas tolerar o dissenso, mas instigá-lo, pois é nele que se aprofundam as explicações.

Esse ciclo — clarificar, definir, analisar, identificar lacunas, estabelecer metas, estudar, compartilhar — não é linear nem perfeitamente simétrico. Problemas complexos demandam idas e vindas, revisões contínuas, reelaborações conceituais. E isso é intencional. O ABP foi concebido para simular o modo como problemas surgem na prática profissional: de forma não linear, ambígua, multifacetada. Aceitar a iteratividade como parte natural do processo é, portanto, não um fracasso metodológico, mas precisamente o que lhe confere realismo e potência formativa.

Sob essa perspectiva, o papel do tutor é extraordinariamente sofisticado: ele não é um simples mediador de reuniões ou avaliador de relatórios, mas o guardião epistemológico do processo. Deve estimular a curiosidade, provocar raciocínios, sustentar o desconforto cognitivo, mas ao mesmo tempo garantir um ambiente seguro onde o erro não seja penalizado, e sim entendido como oportunidade. Não raro, como apontam Barrows (1986) e Woods (1994), tutores mal preparados acabam por “ensinar no lugar do estudante”, rompendo o ciclo investigativo e retornando a um modelo instrucionista, esvaziando o sentido do ABP.

Dessa forma, o processo clássico do ABP se revela não apenas como um conjunto de passos didáticos, mas como um dispositivo pedagógico crítico que desafia concepções tradicionais de ensino. Ao colocar o estudante diante do incerto, obrigando-o a reconhecer o que não sabe, a investigar, a dialogar criticamente e a reconstruir hipóteses sucessivas, o ABP cultiva não só conhecimentos disciplinares, mas sobretudo atitudes intelectuais de humildade epistêmica, rigor investigativo e abertura ao diálogo. É precisamente por isso que sua implementação bem-sucedida demanda não apenas roteiros ou planilhas, mas uma profunda transformação cultural no modo de conceber o aprender — por parte dos estudantes, dos professores e das próprias instituições.

2.2.3. Aplicações do ABP em Computação e Engenharia

A aplicação prática do ABP em cursos de Computação e Engenharia no Brasil tem demonstrado grande potencial para aproximar o ensino das demandas do mercado e para promover o desenvolvimento simultâneo de competências técnicas e socioemocionais. Bittencourt, Rodrigues e Cruz (2012) relataram uma experiência no curso de Engenharia de Computação da Universidade Estadual de Feira de Santana (UEFS), que integrou as disciplinas de Programação Orientada a Objetos, Estruturas de Dados e Projeto de Sistemas por meio do

ABP. Os estudantes, organizados em grupos, enfrentaram desafios como o desenvolvimento de sistemas para clínicas odontológicas, redes sociais simuladas e sistemas de leilões, articulando teoria e prática ao longo de ciclos que duravam de três a seis semanas, sempre supervisionados por tutores que acompanhavam o raciocínio dos grupos e o progresso técnico.

Santos e Angelo (2008), ao analisar os problemas propostos nesses estudos integrados, destacaram a importância de estruturar desafios que demandassem competências cognitivas superiores, conforme a Taxonomia de Bloom (BLOOM et al., 1976; ANDERSON; KRATHWOHL, 2001), incentivando a análise crítica, a síntese e a avaliação, e não apenas a memorização.

2.2.4. A experiência do ABP em cursos técnicos integrados

No contexto do ensino técnico integrado ao médio, Pontes et al. (2022) relataram a aplicação do ABP em cursos técnicos de informática no IFTO, destacando como os professores atuaram como tutores em projetos interdisciplinares que integravam conhecimentos técnicos e competências cidadãos. Os estudantes foram guiados desde a identificação de problemas reais, passando pela construção colaborativa de soluções, até a apresentação dos resultados em feiras de empreendedorismo. Esse modelo favoreceu o desenvolvimento da autonomia, da criatividade e da capacidade de trabalho em equipe.

Barros et al. (2023) apresentaram ainda uma experiência no ensino de Inteligência Artificial, em que a ABP foi combinada com metodologias ágeis e Scrum, envolvendo a divisão dos projetos em sprints e a entrega incremental de artefatos. Esse arranjo intensificou a necessidade de acompanhamento por parte dos professores, que desempenharam múltiplos papéis: de tutores do conhecimento, facilitadores metodológicos e interlocutores entre demandas externas (clientes) e o progresso acadêmico dos estudantes.

2.2.5. Principais desafios e papel do docente na implementação

Apesar de seus benefícios, a implementação da ABP encontra desafios importantes. Ribeiro e Lima (2025), em estudo sobre o uso do ABP no ensino de programação em turma heterogênea, observaram que diferenças nos conhecimentos prévios dos estudantes impactaram o ritmo do aprendizado e exigiram uma mediação intensiva por parte dos professores para nivelar a turma e manter o engajamento. Além disso, o PBL demanda alto investimento de tempo para o planejamento dos problemas, o acompanhamento constante dos grupos, o fornecimento de feedbacks individuais e coletivos e a avaliação processual.

Barrows (1986) já ressaltava que o sucesso da metodologia depende fortemente da formação do professor como tutor. Não se trata apenas de conhecer o conteúdo, mas de saber guiar o estudante por meio de perguntas, estimular o pensamento crítico, desafiar hipóteses frágeis e apoiar o desenvolvimento de competências colaborativas. Esse perfil contrasta com o do professor tradicional, centrado na exposição do conteúdo, exigindo competências pedagógicas que vão além da expertise técnica.

Em síntese, a ABP, conforme delineada por Barrows (1986) e Woods (1994), revela-se uma metodologia robusta para articular conhecimentos interdisciplinares, promover o pensamento crítico, desenvolver autonomia e fortalecer habilidades colaborativas. Sua efetividade, porém, está condicionada à qualidade do desenho dos problemas, à competência do docente como tutor e à construção gradual da capacidade de autoaprendizagem pelo estudante. Essa abordagem desafia não apenas os alunos, mas também as instituições e os professores, demandando uma cultura educacional que valorize o erro e a reflexão como partes legítimas do processo de aprender.

2.3. Ensino de Inteligência Artificial

Este tópico apresenta os fundamentos do ensino de Inteligência Artificial (IA) e *Machine Learning* no contexto educacional e técnico, delimitando conceitos essenciais, origens do campo e aplicações atuais. Discute-se a IA como área multidisciplinar e estratégica para a formação de jovens em um cenário de transformação digital, destacando princípios como representação do conhecimento, aprendizagem e tomada de decisão por sistemas computacionais. Em seguida, são caracterizados os paradigmas de aprendizado supervisionado e não supervisionado, com foco em suas finalidades e potencial de uso em atividades formativas com dados. Por fim, o texto aborda a IA no contexto educacional, discutindo implicações curriculares, desafios pedagógicos (como lacunas em matemática e programação) e a pertinência de metodologias ativas — especialmente o PBL — para tornar o aprendizado mais significativo, aplicado e conectado a problemas reais.

2.3.1. Fundamentos da Inteligência Artificial

A área de Inteligência Artificial (IA) na ciência da computação dedica-se ao desenvolvimento de sistemas capazes de executar tarefas que usualmente necessitam da inteligência humana (RUSSELL; NORVIG, 2016). Esses sistemas são projetados para aprender, raciocinar e tomar decisões, com aplicações que vão desde o reconhecimento de fala

e imagem até a condução autônoma e a assistência médica, transformando diversos setores da sociedade. A origem do termo 'Inteligência Artificial' remonta à conferência de Dartmouth, realizada em 1956, onde John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon delinearam o objetivo de construir 'máquinas que se comportem de maneira que, se um ser humano agisse assim, seria dito que ele é inteligente' (McCarthy et al., 1956).


Os fundamentos da inteligência artificial são construídos sobre princípios que visam replicar aspectos da inteligência humana em sistemas computacionais. Segundo Nilsson (1982), esses princípios incluem a representação do conhecimento, a resolução de problemas e a aprendizagem. A IA busca desenvolver algoritmos que permitam às máquinas processar informações de maneira eficiente, fazer inferências a partir de dados incompletos ou incertos e adaptar-se a novos cenários. A obra de Nilsson destaca a importância de técnicas como redes neurais, lógica de predicados e heurísticas na criação de sistemas capazes de imitar o comportamento humano em tarefas complexas, como o reconhecimento de padrões e a tomada de decisões.

A proposta "A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence" de John McCarthy (1955), articula que aspectos do aprendizado e características da inteligência podem ser descritos com precisão suficiente para serem simulados por máquinas. "Cada aspecto do aprendizado ou qualquer outra característica da inteligência pode, em princípio, ser descrito de forma tão precisa que uma máquina pode ser feita para simulá-lo." (MCCARTHY et al., 1955, p. 2). Essa visão estabeleceu as bases para décadas de pesquisa, impulsionando o desenvolvimento de algoritmos e modelos que buscam reproduzir o raciocínio humano, a tomada de decisões, o aprendizado e outras funções cognitivas, formando uma era de exploração tecnológica e científica que continua a evoluir até hoje.

Segundo Filho (2023), a Inteligência Artificial é descrita como uma ciência multidisciplinar com o objetivo de desenvolver máquinas capazes de realizar tarefas complexas que exigem habilidades tipicamente humanas, como inteligência, criatividade, atenção e perseverança. essa área busca replicar características humanas por meio de sistemas artificiais, destacando a importância da precisão, rapidez e capacidade de armazenamento de dados em suas aplicações. A combinação dessas características permite que a IA não apenas imite o comportamento humano, mas também supere as limitações humanas em várias áreas, impulsionando avanços tecnológicos e transformações sociais significativas. Na Figura 1, observamos o contraste entre as habilidades humanas e maquinas

Figura 1- Habilidades do ser humano versus máquina.

Ser humano × Máquina



Fonte: Inteligência Artificial e Aprendizagem de Máquina (2023)

Essa afirmação lançou as bases para o campo da inteligência artificial, sugerindo que processos cognitivos complexos poderiam ser replicados em sistemas computacionais. A visão do autor foi revolucionária para a época, propondo que a inteligência não era um fenômeno exclusivamente biológico, mas algo que poderia ser formalizado e reproduzido em máquinas. Ele acreditava que, com a abordagem certa, era possível desenvolver sistemas que não apenas realizassem tarefas específicas, mas que também aprendessem e se adaptassem a novas situações, imitando a capacidade humana de raciocínio e resolução de problemas.

John McCarthy e seus colegas previram que o progresso na IA exigiria uma colaboração interdisciplinar, envolvendo matemáticos, engenheiros, psicólogos e especialistas em outras áreas. Eles enxergaram um futuro onde as máquinas poderiam realizar tarefas intelectualmente exigentes, contribuindo significativamente para o avanço da ciência e da tecnologia. A proposta também trouxe à tona importantes questões filosóficas e éticas sobre a natureza da inteligência e a relação entre humanos e máquinas. Sua visão pioneira continua a influenciar o campo da IA inspirando pesquisas que buscam não apenas replicar, mas também expandir as capacidades humanas através da tecnologia.

A Inteligência Artificial (IA) é caracterizada como sistemas que têm a capacidade de mimetizar funções cognitivas associadas a atributos humanos, como aprendizado, raciocínio e resolução de problemas. Essa definição ressalta a crescente capacidade das máquinas de realizar tarefas que tradicionalmente requeriam inteligência humana, refletindo um avanço significativo na tecnologia e suas aplicações em diversos setores (DWIVEDI, 2021).

O aprendizado de máquina é um subcampo da IA focado no desenvolvimento de algoritmos que permitem aos computadores aprender a partir de dados. Existem três tipos

principais de aprendizado de máquina: supervisionado, não supervisionado e por reforço. O aprendizado supervisionado envolve a utilização de um conjunto de dados rotulados para treinar o modelo, enquanto o aprendizado não supervisionado trabalha com dados não rotulados para identificar padrões ocultos (MITCHELL, 1997). O aprendizado por reforço, por sua vez, envolve a aprendizagem através de interações com um ambiente dinâmico, recebendo recompensas ou penalidades com base nas ações tomadas (SUTTON, 2018).

A IA é um campo vasto e em rápida evolução, com aplicações que abrangem diversas áreas do conhecimento e setores da indústria. Desde os algoritmos de aprendizado de máquina até o processamento de linguagem natural, as inovações em IA continuam a transformar a maneira como interagimos com a tecnologia. Com a contínua pesquisa e desenvolvimento, a IA promete oferecer soluções inovadoras para desafios complexos, melhorando a eficiência e a eficácia de diversos sistemas e processos (HAENLEIN; KAPLAN, 2019).

2.3.2. Aprendizado Supervisionado e Não Supervisionado

O aprendizado supervisionado fundamenta-se no uso de dados rotulados para treinar modelos que realizam tarefas de classificação ou regressão (MITCHELL, 1997; HAENLEIN; KAPLAN, 2019). Em um curso técnico, isso pode ser explorado com exemplos práticos como filtragem de spam, classificação de imagens ou previsão de falhas em equipamentos. Atividades voltadas ao ciclo completo de desenvolvimento de modelos — coleta, pré-processamento, validação e avaliação — são essenciais para fortalecer a formação analítica e pró-ativa.

Contrariamente, o aprendizado não supervisionado opera sobre dados não rotulados, buscando identificar padrões, clusters e relações implícitas (JORDAN; BISHOP, 2020). Ferramentas como k-means e PCA podem ser exploradas com bases reais — logs de acesso, dados de sensores ou transações — incentivando a análise crítica e a curiosidade investigativa dos estudantes. Essa abordagem favorece uma formação orientada a insights e descoberta, competências fundamentais no perfil de egressos do curso.

A literatura confirma que a aplicabilidade dessas técnicas em cenários educativos é eficaz. Barros et al. (2023) utilizaram aprendizado supervisionado em diagnóstico médico com Random Forest, KNN e SVM, enquanto ambientes exploratórios com aprendizado não supervisionado incentivam a reflexão estatística e investigativa. Além disso, plataformas no-code (MIT Professional Education, 2024) demonstram que é possível ensinar ML com foco em aplicação prática, mesmo em contexto técnico inicial.

No curso, é importante construir um fluxo de aprendizagem integrando ambas técnicas, por exemplo: iniciando com um problema de classificação (supervisionado) e evoluindo para exploração de dados não estruturados (não supervisionado). Isso promove aprendizado holístico e reforça habilidades de modelagem, análise crítica e interpretação de resultados.

Portanto, os conteúdos de aprendizado supervisionado e não supervisionado complementam-se, fornecendo ao aluno uma visão abrangente das principais técnicas de IA/ML, ao mesmo tempo em que são integrados ao currículo por meio de atividades aplicadas e contextualizadas no desenvolvimento de sistemas técnicos.

2.3.3. IA no Contexto Educacional

A inserção da Inteligência Artificial (IA) no currículo escolar está rapidamente se tornando uma prioridade em sistemas educacionais ao redor do mundo. Com a crescente presença da IA em diversos aspectos da vida cotidiana e no mercado de trabalho, educadores e formuladores de políticas compreendem a urgência de preparar as novas gerações para lidar com essa tecnologia. Não se trata apenas de ensinar conceitos técnicos, como aprendizado de máquina e redes neurais, mas também de aproveitar as ferramentas de IA para melhorar práticas pedagógicas e processos de ensino, proporcionando uma educação que acompanhe a evolução tecnológica.

A necessidade de abordagens pedagógicas inovadoras, como a Aprendizagem Baseada em Problemas (ABP), torna-se evidente à medida que o ensino de Inteligência Artificial (IA) avança no ambiente escolar. Conforme Shen et al. (2010) sugerem, o ensino tradicional, que frequentemente se apoia na simples transmissão de conhecimento teórico, pode não ser suficiente para preparar os alunos para os desafios práticos e interdisciplinares que enfrentarão no mercado de trabalho. Metodologias ativas, como o ABP, incentivam uma aprendizagem mais envolvida, com foco na colaboração, na busca independente por informações e na aplicação prática dos conceitos teóricos. Esse tipo de abordagem não só aprimora a compreensão dos conteúdos, mas também fomenta o desenvolvimento de habilidades críticas, como o pensamento analítico, a resolução de problemas e a capacidade de trabalhar em equipe.

Os desafios no ensino de IA, como a complexidade dos conceitos e a variação no nível de conhecimento dos estudantes, refletem a necessidade de adaptar o currículo e as metodologias de ensino a um público diversificado. Allen, McGough e Devlin (2021) apontam que, em muitos casos, a falta de uma base sólida em áreas como matemática e programação

contribui para uma curva de aprendizado mais acentuada. Dessa forma, torna-se essencial que os professores adotem estratégias que considerem essas lacunas no conhecimento prévio dos alunos, utilizando abordagens mais flexíveis e acessíveis que atendam diferentes perfis de aprendizagem. A introdução gradual de conceitos fundamentais e o reforço contínuo por meio de exemplos práticos são algumas das recomendações que podem ajudar a mitigar essas dificuldades.

Além disso, a pesquisa realizada por Allen et al. (2021) também destaca a importância de recursos complementares no processo de aprendizagem. O uso de materiais online, sessões de revisão e exercícios práticos contribui para a consolidação dos conceitos, oferecendo aos alunos múltiplas oportunidades de revisão e prática. Essas ferramentas desempenham um papel importante ao permitir que os alunos reforcem seu entendimento fora da sala de aula tradicional, promovendo um aprendizado mais autônomo e direcionado às suas necessidades individuais. Dessa maneira, essas estratégias não apenas facilitam a compreensão de conteúdos complexos, mas também proporcionam um ambiente de aprendizagem mais dinâmico e inclusivo, que se ajusta às demandas de um ensino de IA em constante evolução.

A incorporação da IA no currículo escolar pode ser vista em várias iniciativas e programas ao redor do mundo. Um exemplo é o programa "AI for K-12" nos Estados Unidos, que visa criar um quadro curricular para o ensino de IA desde o jardim de infância até o ensino médio. Este programa, liderado por especialistas como David Touretzky (2019), tem como objetivo de desenvolver diretrizes, recursos e materiais pedagógicos que ajudem professores a ensinar conceitos de IA de forma acessível e apropriada para estudantes.

No Reino Unido, o projeto "AI in Schools" está sendo implementado para equipar os alunos com habilidades de IA desde cedo. Este projeto inclui o desenvolvimento de materiais didáticos específicos, como módulos sobre aprendizado de máquina e robótica, além de workshops para professores, a fim de capacitá-los a ensinar esses tópicos de maneira eficaz (LUCKIN, 2016).

Diversos programas e projetos educacionais exemplificam como a IA está sendo integrada ao currículo escolar. Na China, por exemplo, o governo lançou uma série de iniciativas para promover o ensino de IA nas escolas, incluindo a introdução de livros didáticos específicos sobre IA para alunos do ensino fundamental e médio (KNOX, 2020). Esses livros cobrem tópicos como algoritmos de aprendizado de máquina, visão computacional e processamento de linguagem natural, preparando os alunos para um futuro onde essas habilidades serão essenciais para sociedade.

Além disso, plataformas de aprendizado online como a *Khan Academy*³ estão utilizando IA para oferecer experiências de aprendizado personalizadas. Através da análise de dados de desempenho dos alunos, essas plataformas podem ajustar o conteúdo e o ritmo das aulas para melhor atender às necessidades individuais de cada estudante (NGUYEN et al., 2016).

Com iniciativas em diversas partes do mundo, é evidente que a integração da IA na educação tem um potencial transformador. Seja por meio de currículos estruturados ou plataformas de aprendizado online, essas práticas estão gradualmente moldando o futuro da educação. No entanto, o sucesso dessa integração dependerá da capacidade das escolas e professores em adaptar essas tecnologias às necessidades e realidades dos alunos, criando um ambiente em que o aprendizado seja impulsionado pelo uso inteligente de IA, sem perder de vista a essência da formação humana.

2.3.4. Aplicação do PBL e Desafios no Ensino de IA e Machine Learning

O Problem-Based Learning (PBL) é uma metodologia centrada no aluno, onde problemas autênticos servem de ponto de partida para investigação, aprendizagem e desenvolvimento de soluções (WOOD, 2024). Originalmente utilizada na formação médica, sua expansão para cursos técnicos de computação tem se mostrado promissora, pois estimula autonomia, colaboração, literacia científica e pensamento crítico.

No contexto do ensino técnico de IA, o PBL pode ser aplicado por meio de projetos reais — como detecção de fraudes bancárias, classificação de imagens industriais, análise de churn ou recomendações de consumo. Cada projeto pode ser dividido em etapas: definição do problema, levantamento de dados, escolha de modelo (supervisionado ou não supervisionado), desenvolvimento e avaliação dos resultados. A ênfase recai sobre a pesquisa ativa, colaboração em equipes e integração dos componentes éticos de IA, comuns à ementa do curso.

Estudos contemporâneos corroboram essa estratégia. Gan & Ouh (2021) demonstraram os benefícios da integração entre PBL e metodologias ágeis (Scrum) no ensino de IA — melhorando habilidades técnicas e socioemocionais. Além disso, Zheng et al. (2024) identificaram que o uso de AI-PBL — projetos que refletem sobre o uso da própria IA — oferece dados para avaliação autêntica das competências desenvolvidas dos alunos, ampliando sua capacidade de metacognição e autorregulação.

³ Khan Academy é uma organização sem fins lucrativos fundada por Salman Khan. Com a missão de proporcionar uma educação gratuita e de alta qualidade para todos, em qualquer lugar. Disponível em: <https://pt.khanacademy.org/>

Entretanto, a aplicação do PBL enfrenta desafios significativos. Primeiramente, a heterogeneidade de conhecimentos prévios — especialmente em matemática, programação e estatística — pode gerar lacunas e insegurança, exigindo um suporte adaptativo (scaffolding) do docente. Em segundo lugar, a sobrecarga cognitiva é mencionada por estudantes que precisam lidar simultaneamente com programação, análise estatística, engenharia de dados e interpretação crítica (WOOD, 2024; DEGREE et al., 2021).

Além disso, implementar PBL exige infraestrutura — plataformas de ML, ambientes de desenvolvimento, conjuntos de dados reais — e maior carga de tutoria docente. Conforme Owoc et al. (2021), essas demandas elevam os custos pedagógicos e organizacionais, exigindo planejamento institucional. Há também dimensões éticas: o uso de dados sensíveis, viés nos modelos e explicabilidade (XAI) precisam ser tratados explicitamente durante os projetos (PORAYSKA-POMSTA et al., 2024).

Por fim, deve-se atenção à avaliação. O PBL exige instrumentos que considerem tanto os processos quanto os resultados — avaliação formativa, peer review, diários de bordo e dashboards de progresso. Zheng et al. (2024) recomendam o uso de técnicas de co-design com os alunos para incluir métricas de uso da IA, promovendo reflexões autênticas e autoavaliação das competências.

2.4. Trabalhos Relacionados

Este capítulo sistematiza os principais estudos e experiências que embasam a presente pesquisa, com foco no uso do Problem-Based Learning (PBL) e de metodologias ativas no ensino de Computação, Programação e Machine Learning. Inicialmente, são discutidos trabalhos que aplicam o PBL em contextos de ensino de programação, destacando contribuições para aprendizagem significativa, desenvolvimento de competências e desafios recorrentes na implementação. Em seguida, são apresentados estudos voltados ao ensino técnico integrado, evidenciando como o PBL tem sido empregado para aproximar teoria e prática e fortalecer a formação profissional e cidadã. Por fim, o capítulo aborda pesquisas sobre metodologias ativas no ensino de IA e ML, incluindo abordagens híbridas (como PBL associado a frameworks ágeis e estratégias colaborativas), apontando tendências, limitações e implicações pedagógicas para a formação em áreas tecnológicas. Ao final, busca-se explicitar as convergências da literatura e situar o diferencial desta pesquisa no cenário investigado.

2.4.1. PBL no ensino de Computação e Programação

O uso do PBL em cursos de Computação e Engenharia, sobretudo no ensino de programação, tem sido explorado como alternativa às abordagens tradicionais centradas no professor. Uma das experiências pioneiras no Brasil foi relatada por Bittencourt, Rodrigues e Cruz (2012), que descreveram a integração de disciplinas como Programação Orientada a Objetos, Estruturas de Dados e Projeto de Sistemas em um curso de Engenharia de Computação. O estudo destacou o potencial do PBL para articular conteúdos de diferentes áreas e desenvolver competências críticas e criativas, embora tenha apontado desafios, como a sobrecarga cognitiva e a dificuldade na evolução de software quando problemas não são devidamente escalonados.

Ampliando essa perspectiva, Santos e Angelo (2008) realizaram uma análise aprofundada dos problemas propostos em um estudo integrado de programação utilizando PBL, mapeando-os segundo a Taxonomia de Bloom revisada. A pesquisa mostrou como o desenho cuidadoso dos problemas é determinante para estimular níveis cognitivos mais elevados, desde a aplicação até a análise, avaliação e criação, indo além da simples memorização.

Ribeiro e Lima (2025) também investigaram o PBL aplicado ao ensino de programação, mas em um contexto de turma heterogênea, analisando aspectos como o problema, ambiente, conteúdo, capital humano e avaliação. Os resultados indicaram ganhos em retenção de conhecimento e habilidades colaborativas, mas revelaram que as diferenças no nível prévio de conhecimento exigiram uma mediação intensiva dos professores para manter o engajamento e assegurar um aprendizado equitativo.

No contexto internacional, Barros et al. (2023) descreveram a aplicação combinada do PBL com Scrum em um curso de graduação em Computação para ensinar IA, envolvendo o desenvolvimento de modelos preditivos por meio de sprints iterativos. A experiência não apenas aproximou o ensino de práticas profissionais ágeis, como também reforçou competências de análise crítica e trabalho em equipe. Esse estudo é particularmente relevante por ilustrar como o PBL pode ser enriquecido por frameworks oriundos do mercado de software.

Finalmente, outro exemplo notável é o trabalho de Santos et al. (2007), que relatou experiências anteriores em um mesmo curso de Engenharia de Computação, empregando o PBL em projetos interdisciplinares de programação. O estudo mostrou como ciclos sucessivos de problemas, com feedbacks e tutoriais semanais, consolidaram habilidades técnicas e metacognitivas nos estudantes, alinhadas a um perfil de formação mais investigativo e autônomo.

Dessa forma, observa-se que o uso do PBL no ensino de programação vai além de propiciar o domínio de sintaxe ou algoritmos, pois constrói um espaço para o desenvolvimento de competências analíticas, criativas e colaborativas essenciais à formação de profissionais em Computação.

2.4.2. PBL no ensino técnico integrado

No ensino técnico integrado, o PBL tem sido explorado como estratégia para superar o distanciamento entre teoria e prática e favorecer aprendizagens contextualizadas. Pontes et al. (2022) analisaram o currículo do ensino médio integrado ao curso técnico em Informática do Instituto Federal do Tocantins, evidenciando como o Projeto Pedagógico Curricular (PPC) está alinhado com metodologias ativas, em especial o PBL e a aprendizagem colaborativa. O estudo mostrou que tais metodologias potencializam o desenvolvimento de competências para o mundo do trabalho e para o exercício da cidadania, aspectos centrais na BNCC.

Complementando essa visão, um estudo qualitativo conduzido por Fernando et al. (2021) explorou a percepção de professores e alunos do ensino médio integrado ao técnico sobre o PBL, apontando que a metodologia é reconhecida como diferencial para enfrentar as exigências do mercado competitivo. O PBL foi considerado capaz de fomentar a autonomia, a interdisciplinaridade e o pensamento crítico, elementos essenciais para um egresso mais preparado para desafios complexos.

Ademais, o estudo de Ribeiro e Lima (2025), embora focado em ensino superior, oferece contribuições que dialogam com o ensino técnico ao expor como heterogeneidades entre estudantes podem impactar o sucesso do PBL, algo comum em turmas do ensino médio integrado que congregam alunos com formações muito distintas.

Em síntese, a literatura converge ao apontar a ABP como uma abordagem promissora para a Educação Profissional e Tecnológica, por articular teoria e prática, apoiar o desenvolvimento de competências técnicas e transversais e aproximar o estudante de situações autênticas de trabalho. Ao mesmo tempo, os estudos analisados ainda apresentam lacunas quanto à descrição detalhada de intervenções aplicadas, à sistematização dos ciclos de aprendizagem, aos instrumentos de acompanhamento e à produção de evidências em contextos de ensino técnico integrado. Diante disso, esta pesquisa avança ao propor, implementar e analisar uma intervenção pedagógica baseada em ABP para o ensino de Aprendizagem de Máquina em uma turma do curso técnico integrado em Informática, organizada em ciclos

temáticos progressivos e vinculada a problemas contextualizados da realidade escolar e profissional.

2.4.3. Metodologias ativas no ensino de IA e ML

Nos últimos anos, o ensino de Inteligência Artificial e Machine Learning tem demandado abordagens que transcendam o ensino meramente expositivo, dada a complexidade e o dinamismo desses campos. As metodologias ativas, especialmente o PBL, o Peer Instruction, o modelo 4C/ID e frameworks ágeis, têm ganhado espaço para suprir essa lacuna.

Uma linha de estudos tem estruturado o ensino de Inteligência Artificial e Aprendizagem de Máquina por meio de projetos e problemas, com organização do trabalho em ciclos curtos, entregas parciais e acompanhamento sistemático. Barros, Paiva e Hayashi (2023), por exemplo, relatam uma experiência que combina PBL, Scrum e práticas ágeis no ensino de Inteligência Artificial em um curso superior de Computação, envolvendo estudantes de graduação no desenvolvimento de modelos preditivos para um problema real.

Embora esse estudo apresente forte aproximação com esta dissertação, especialmente por articular PBL, Inteligência Artificial e desenvolvimento de modelos de Aprendizagem de Máquina, há diferenças importantes. A experiência de Barros, Paiva e Hayashi (2023) foi realizada no ensino superior, em um curso de graduação em Computação, com estrutura curricular, maturidade acadêmica e condições institucionais distintas das encontradas no ensino médio técnico integrado. Esta dissertação avança ao adaptar a ABP para estudantes da educação profissional técnica de nível médio, em uma escola pública estadual, trabalhando conteúdos de Aprendizagem de Máquina de forma progressiva, por meio de ciclos temáticos que envolvem busca heurística, classificação, regressão e agrupamento. Além disso, o presente estudo analisa a aplicação da metodologia em um contexto profissionalizante, com estudantes em formação inicial na área de informática, o que amplia a discussão sobre a viabilidade da ABP para o ensino de temas avançados de Computação antes da graduação.

No mesmo sentido, Loguercio et al. (2022) apresentaram o AgroCATIVO, uma plataforma educacional para o ensino no agronegócio que combina o PBL, Peer Instruction e o 4C/ID. Embora não aplicada especificamente a IA, a plataforma demonstra como o design instrucional estruturado e adaptado ao perfil do aluno, aliado a problemas contextualizados, pode melhorar significativamente a experiência de aprendizagem em conteúdos complexos.

Além do PBL, metodologias como a aprendizagem colaborativa destacada por Pontes et al. (2022) e abordagens mistas (projetos interdisciplinares com ciclos tutorados) relatadas por Santos et al. (2008) evidenciam que o ensino de temas avançados em Computação, como IA e ML, requer múltiplas estratégias ativas. Tais estratégias incluem desde discussões guiadas e resolução coletiva de problemas até prototipagem iterativa com uso de softwares específicos.

Um ponto relevante é que plataformas digitais vêm sendo cada vez mais empregadas como suporte a essas metodologias. O AgroCATIVO, por exemplo, ajusta a entrega de materiais conforme o estilo de aprendizagem do estudante, enquanto o uso de repositórios GitHub e ferramentas como Slack, descritos por Barros et al. (2023), reforçam o protagonismo do aluno no processo de aprendizagem e simula o ecossistema profissional.

Portanto, a literatura indica que, embora o PBL seja uma das metodologias mais exploradas no ensino de IA e ML, estratégias híbridas que combinam o PBL com frameworks ágeis, aprendizagem colaborativa, Peer Instruction e suporte em plataformas adaptativas têm se mostrado ainda mais eficazes para desenvolver o pensamento crítico, a resolução criativa de problemas e a autonomia intelectual — competências indispensáveis no campo da Computação.

A revisão apresentada demonstra que o campo do ensino de Computação, sobretudo em áreas como programação e IA/ML, tem recorrido a metodologias ativas para superar limitações do ensino tradicional e aproximar o aprendizado das práticas profissionais. O PBL destaca-se como estratégia central, mas não isolada: tem sido complementado por Scrum, Peer Instruction, aprendizagem colaborativa e recursos adaptativos em plataformas digitais. Essas abordagens revelam não apenas ganhos técnicos, mas também formativos, preparando estudantes para lidar com problemas complexos de maneira autônoma e colaborativa.

Nesse cenário, esta dissertação avança ao descrever uma intervenção pedagógica estruturada em ciclos de ABP aplicados ao ensino de Aprendizagem de Máquina no ensino técnico integrado. A pesquisa não se limita a discutir a pertinência da metodologia, mas apresenta sua operacionalização em sala de aula, os conteúdos trabalhados, as etapas do processo, os instrumentos de acompanhamento e as percepções dos estudantes. Com isso, contribui para tornar mais visível e replicável uma proposta de ensino de Aprendizagem de Máquina em cursos técnicos, especialmente em instituições públicas que buscam integrar formação profissional, resolução de problemas e desenvolvimento de competências computacionais.

3. METODOLOGIA DE PESQUISA E APLICAÇÃO DO PBL

Este capítulo descreve, de forma sistemática, o percurso metodológico da pesquisa, contemplando a Revisão Sistemática da Literatura (RSL), a caracterização do estudo e a operacionalização da intervenção pedagógica baseada na Aprendizagem Baseada em Problemas (PBL) no componente curricular de Inteligência Artificial (IA) e Machine Learning (ML), em um curso técnico integrado ao ensino médio da rede estadual da Paraíba. O foco central é explicitar como a investigação foi planejada, fundamentada, executada e analisada, assegurando coerência entre o problema de pesquisa, os objetivos, as escolhas metodológicas, o levantamento dos trabalhos relacionados e os procedimentos adotados em sala de aula.

Inicialmente, apresenta-se a Revisão Sistemática da Literatura, conduzida com o objetivo de mapear estudos recentes sobre a aplicação da ABP/PBL e de metodologias ativas no ensino de Computação, Inteligência Artificial e Machine Learning, com ênfase em contextos de formação técnica e profissional. Nessa etapa, são descritos o recorte temporal da revisão, as bases de dados consultadas, a estratégia de busca, os critérios de inclusão e exclusão, bem como os procedimentos de coleta, organização, filtragem e seleção dos trabalhos.

Em seguida, apresenta-se a caracterização da pesquisa como estudo aplicado, de abordagem qualitativa exploratória, com elementos quantitativos complementares, estruturado sob a estratégia de pesquisa-ação. Essa escolha metodológica justifica-se pelo fato de o pesquisador atuar diretamente no contexto investigado, articulando intervenção pedagógica e produção de conhecimento. Na sequência, detalha-se o referencial metodológico que orienta o modelo de PBL adotado, com base em Barrows e em desdobramentos posteriores da metodologia, justificando as adaptações realizadas em função do contexto do ensino técnico, do tempo disponível e do nível de experiência prévia dos estudantes com IA/ML.

Posteriormente, o capítulo contextualiza o universo da pesquisa, descrevendo a instituição, o componente curricular, as competências previstas, o perfil dos participantes, a organização em grupos e o papel dos docentes-tutores e colaboradores externos. Em seguida, apresenta-se a estrutura da intervenção pedagógica, explicitando sua lógica de planejamento, execução e avaliação, organizada em ciclos temáticos de busca heurística, classificação, regressão e agrupamento, culminando em um projeto integrador. Também são descritas as ferramentas digitais utilizadas, os produtos gerados pelos estudantes e as evidências de aprendizagem coletadas ao longo do processo.


Por fim, são apresentados os instrumentos de coleta de dados, os critérios avaliativos aplicados durante a intervenção e os procedimentos de análise, combinando indicadores quantitativos de desempenho e participação com análises qualitativas baseadas em registros, autoavaliações, formulários de percepção e evidências produzidas pelos grupos. Dessa forma, o capítulo estabelece as bases necessárias para que o leitor compreenda, com clareza e rastreabilidade, tanto o percurso metodológico da revisão quanto a forma como a intervenção pedagógica foi planejada, executada e analisada, sustentando a interpretação dos resultados apresentados no capítulo seguinte.

3.1. Revisão Sistemática Da Literatura

Este tópico apresenta a Revisão Sistemática da Literatura (RSL) conduzida para fundamentar, com evidências recentes e rastreáveis, o estado da arte sobre a aplicação da Aprendizagem Baseada em Problemas (ABP/PBL) no ensino de Inteligência Artificial (IA) e Machine Learning (ML), com ênfase em contextos de formação técnica e profissional. A RSL cumpre a função de mapear como a metodologia vem sendo operacionalizada, quais estratégias avaliativas têm sido utilizadas para mensurar aprendizagem e desempenho, e quais efeitos são reportados sobre engajamento e motivação discente — elementos diretamente relacionados ao problema de pesquisa e às decisões metodológicas da intervenção implementada nesta dissertação.

3.1.1. Introdução a revisão sistemática da literatura

A revisão sistemática de literatura é um método rigoroso e estruturado para sintetizar evidências sobre um tópico de pesquisa específico. Esse processo proporciona uma abordagem abrangente para identificar lacunas no conhecimento, sintetizar evidências de forma imparcial e fundamentar futuras pesquisas. Ele permite que os pesquisadores obtenham uma visão ampla do estado atual do conhecimento em uma área, identifiquem tendências e contribuições significativas, e embasem suas investigações em uma base sólida de evidências. As principais etapas desse processo incluem o planejamento da revisão, a condução da busca e seleção dos estudos, e a elaboração do relatório final com os resultados, conforme a figura 2 (TORRES-CARRIÓN et al., 2018).

Figura 2– Etapas da Revisão Sistemática

Fonte: Adaptado de Torres-Carrión et al. (2018)

3.1.2. Objetivos e Perguntas de Pesquisa da Revisão Sistemática

Este trabalho tem como objetivo investigar a aplicação da metodologia ativa de Aprendizagem Baseada em Problemas (ABP) no ensino de Inteligência Artificial (IA) e Machine Learning (ML) no contexto do ensino médio técnico em informática. Para isso, foram definidas as seguintes questões: Q1: Como a ABP vem sendo integrada no currículo de IA e ML em instituições de ensino básico profissional? Q2: Quais são os métodos avaliativos para mensurar o desempenho dos alunos no ensino de IA e ML com a ABP? Q3: Como a ABP impacta no engajamento e na motivação dos alunos no aprendizado de IA e ML?

Essas questões são necessárias para compreender como a ABP pode ser incorporada de maneira prática e benéfica no currículo de IA e ML. O foco está em identificar os métodos de avaliação que melhor capturam o desempenho dos estudantes e analisar o impacto da ABP no engajamento e motivação dos alunos.

3.1.3. Estratégia de busca

Para a construção da *string* de busca, foram identificados os principais conceitos relacionados ao tema de pesquisa: "Aprendizagem Baseada em Problemas" (ABP), "Inteligência Artificial" (IA), "*Machine Learning*" (ML), e "Educação". Os termos-chave foram selecionados para garantir a abrangência e relevância dos resultados. Esta combinação permite capturar estudos que abordam a ABP em contextos de IA e ML, focando em aplicações

educacionais e pedagógicas. A escolha dos termos foi feita para incluir variações e sinônimos comuns, aumentando a probabilidade de encontrar um conjunto diversificado e abrangente de pesquisas relevantes ao estudo.

Figura 3 - String de busca

("Problem-Based Learning" OR "PBL" OR "Active Learning") AND ("Artificial Intelligence" OR "AI" OR "Machine Learning") AND ("Education" OR "Pedagogy" OR "Teaching")

Fonte: Elaborado pelo autor (2024).

3.1.4. Coletas dos trabalhos e fontes de busca

A coleta dos trabalhos foi realizada a partir da string de busca previamente definida, aplicada nas bases ERIC, IEEE Xplore, Scopus e ACM Digital Library. A escolha dessas bases justifica-se por sua abrangência nas áreas de Educação, Computação, Engenharia, Tecnologias Educacionais e Educação Profissional, permitindo recuperar estudos nacionais e internacionais relacionados à Aprendizagem Baseada em Problemas, metodologias ativas, ensino de Inteligência Artificial e Machine Learning.

A busca foi delimitada ao período de 2019 a 2024, com o objetivo de priorizar publicações recentes e alinhadas às discussões contemporâneas sobre metodologias ativas e ensino de conteúdos tecnológicos. Como resultado inicial, foram retornados 107 artigos na ERIC, 16 artigos na IEEE Xplore, 354 artigos na Scopus e 998 artigos na ACM Digital Library, totalizando 1.475 registros após a consolidação das bases.

Os registros foram inicialmente organizados na plataforma *Mendeley*, utilizada para reunir as referências em um único ambiente e remover duplicatas. Após essa etapa, os dados foram exportados e importados para o *MongoDB Compass*, utilizado como ferramenta de apoio à organização, consulta e filtragem dos metadados (Apêndice B). O uso do Banco de dados permitiu manipular o conjunto de registros de forma mais eficiente, especialmente em razão do volume inicial de artigos recuperados.

É importante destacar que o *MongoDB Compass* não foi utilizado como critério único de seleção dos trabalhos, mas como instrumento de apoio para organizar e localizar registros potencialmente aderentes à pesquisa. Após a filtragem automatizada, os artigos resultantes foram submetidos à leitura dos títulos e resumos, observando critérios de inclusão e exclusão previamente definidos. Foram incluídos estudos que abordavam o uso da ABP/PBL ou de

metodologias ativas no ensino de Computação, Programação, Inteligência Artificial, *Machine Learning* ou em contextos de formação técnica e profissional. Foram excluídos trabalhos que, embora mencionassem algum dos termos da busca, não tratavam de práticas pedagógicas, não apresentavam relação com ensino/aprendizagem, estavam fora do escopo da Computação ou não disponibilizavam informações suficientes para análise.

Esse procedimento buscou reduzir o risco de exclusão de trabalhos relevantes, combinando busca em bases reconhecidas, uso de string estruturada, remoção de duplicatas, filtragem por metadados e triagem manual por aderência temática. Assim, a seleção dos 36 artigos não decorreu apenas da presença de palavras nos títulos ou resumos, mas da verificação de sua relação direta com os objetivos da revisão e com o problema investigado nesta dissertação.

Tabela 1 - Trabalhos Selecionados, Incluídos e excluídos

<i>Fontes de busca</i>	Selecionados	Incluídos	Excluídos
<i>ERIC</i>	107	10	97
<i>IEEE Xplore</i>	16	3	13
<i>Scopus</i>	354	11	343
<i>ACM Digital Library</i>	998	12	986
Total	1475	36	1439

Fonte: Elaborado pelo autor (2024).

3.1.5. Critérios de Inclusão e Exclusão

Para a inclusão dos trabalhos na pesquisa, foram determinados critérios para garantir a relevância e a qualidade dos artigos selecionados. Os critérios de inclusão foram: (CI1) Aplicação da metodologia ativa no ensino de Inteligência Artificial; (CI2) Publicação recente, selecionando artigos publicados nos últimos 5 anos para garantir a atualidade dos estudos e (CI3) Resultados empíricos, considerando trabalhos que incluem resultados empíricos demonstrando a aplicação e os efeitos da ABP no contexto da educação.

Excluimos trabalhos considerando os seguintes critérios de exclusão: (CE1) Trabalhos incompletos; (CE2) Trabalhos duplicados; (CE3) Trabalhos em idiomas diferentes do inglês; (CE4) trabalhos que não fornecem indicações de como a metodologia ativa de aprendizagem

ABP é aplicada no contexto da educação a distância ou híbrida e (CE5) trabalhos que não são estudos primários.

Após a aplicação dos critérios de exclusão por meio da separação sistematizada dos títulos, palavras-chave e resumos dos 1.475 trabalhos retornados na busca realizada, 36 artigos foram considerados relevantes para o tema e incluídos na etapa de extração de dados. Esses 36 artigos passaram por leituras sistematizadas para garantir a precisão e a relevância da seleção (Apêndice C). Para que o estudo fosse concluído, foram necessários dois avaliadores para analisar artigos, Paulo Ricardo Barbosa da Silva e Rayllon Soares Pessoa. Caso houvesse discordância, um terceiro pesquisador atuaria como árbitro.

3.2. Metodologia da Pesquisa

A presente pesquisa caracteriza-se como um estudo aplicado, pois se propõe a planejar, implementar e analisar uma intervenção pedagógica baseada na Aprendizagem Baseada em Problemas para o ensino de Inteligência Artificial (IA) e Machine Learning (ML) em uma escola integral técnica da rede pública estadual da Paraíba. Nessa perspectiva, o estudo busca responder a um problema concreto da prática docente, a dificuldade de inserir conteúdos de IA/ML de forma significativa no ensino médio técnico, por meio do desenho de uma proposta que possa ser replicada e adaptada em contextos educacionais semelhantes. De acordo com Gil (2019), a pesquisa aplicada orienta-se para a geração de conhecimentos diretamente voltados à solução de problemas específicos, articulando reflexão teórica e intervenção na realidade.

Quanto à abordagem, trata-se de uma pesquisa qualitativa de natureza exploratória, com elementos quantitativos complementares. A vertente qualitativa permite compreender em profundidade as percepções, experiências e interações dos estudantes e do professor durante a aplicação do PBL, bem como os significados atribuídos ao uso de IA/ML no componente curricular, em consonância com a perspectiva de investigação qualitativa em educação discutida por Creswell (2014) e Minayo (2014).

Os dados quantitativos – como desempenho em atividades avaliativas e resultados de instrumentos padronizados – são utilizados de forma complementar, favorecendo a identificação de tendências e padrões mensuráveis. A combinação de abordagens qualitativa e quantitativa, articulada por meio da triangulação dos dados, é apontada por Flick (2009) como estratégia importante em pesquisas educacionais que investigam inovações metodológicas, pois amplia a validade dos achados e permite múltiplos olhares sobre o fenômeno estudado.

A estratégia de investigação adotada é a pesquisa-ação, adequada a estudos em que o pesquisador participa ativamente do contexto e busca transformar a prática por meio de ciclos sucessivos de planejamento, ação, observação e reflexão. Conforme Thiollent (2011), a pesquisa-ação caracteriza-se pela estreita articulação entre produção de conhecimento e intervenção, envolvendo a colaboração entre pesquisador e participantes na identificação de problemas, na implementação de mudanças e na análise dos resultados.

No presente trabalho, essa opção metodológica se justifica pela natureza interventiva do estudo: ao propor um modelo pedagógico pautado no PBL para o ensino de IA/ML, pretende-se não apenas descrever a realidade de uma turma do ensino médio técnico, mas contribuir para ressignificar práticas de ensino e aprendizagem mediadas por tecnologias digitais, em consonância com a perspectiva de metodologias ativas discutida por Moran, Masetto e Behrens (2013).

4.1.3. Metodologia Utilizada no Modelo por Howard S. Barrows

No modelo originalmente sistematizado por Howard S. Barrows, a Aprendizagem Baseada em Problemas (ABP/PBL) não deve ser compreendida como uma “técnica genérica” aplicada de forma indistinta, mas como um processo didático estruturado, cujo núcleo é a aprendizagem desencadeada por um problema e sustentada por práticas de tutoria e estudo autodirigido. O próprio Barrows alerta que o termo PBL passou a ser utilizado de maneiras diversas, pois “problem-based learning” pode assumir significados distintos conforme o desenho do método e as competências pedagógicas do professor, resultando em variações relevantes de qualidade e de objetivos educacionais alcançados.

Nesse sentido, Barrows propõe uma taxonomia de métodos PBL para tornar explícitas as diferenças entre abordagens que se autodenominam PBL e, sobretudo, para apoiar a escolha do formato mais adequado ao público e aos resultados de aprendizagem pretendidos. A implicação prática dessa proposta é que a operacionalização do PBL depende de decisões didáticas concretas — por exemplo: o grau de abertura/autenticidade do problema, a centralidade do estudante no planejamento, a intensidade do trabalho em pequenos grupos, o papel do tutor como facilitador e a ênfase na integração entre conhecimentos e raciocínio aplicado.

Na formulação clássica apresentada por Barrows e Tamblyn, o PBL é definido como aprendizagem que emerge do esforço de compreender e/ou resolver um problema, e o problema é introduzido no início do processo, funcionando como estímulo para mobilização de raciocínio

e busca de conhecimentos. Em termos de definição, os autores sintetizam: “the learning that results from the process of working toward the understanding or resolution of a problem”.

A operacionalização defendida por Barrows pressupõe, portanto, que o problema não é um exemplo ilustrativo após a exposição teórica; ao contrário, ele é o elemento que organiza o percurso de aprendizagem, levando o estudante a: (i) analisar a situação-problema, (ii) explicitar o que já sabe e o que precisa aprender, (iii) levantar hipóteses iniciais e caminhos de investigação, (iv) buscar e estudar informações relevantes de modo autodirigido, e (v) retornar ao grupo para refinar explicações, justificar decisões e propor soluções. Essa lógica é apresentada como alternativa à aprendizagem centrada na memorização, pois prioriza construção de conhecimento utilizável e transferência para situações reais.


Outro ponto central do modelo é o papel do docente/tutor. Em Barrows, o tutor atua principalmente como facilitador do processo, orientando a qualidade do questionamento, do raciocínio e da autorregulação do grupo, em vez de fornecer respostas prontas. Assim, a efetividade do PBL não depende apenas da existência de um problema, mas da qualidade da facilitação, do desenho do problema e do acompanhamento do processo de aprendizagem.

Por fim, ao caracterizar o que considera um PBL autêntico, Barrows associa a metodologia a um conjunto de finalidades educacionais: construção de conhecimento profundo, desenvolvimento de competências de resolução de problemas e formação para aprendizagem contínua/autodirigida. Essa visão reforça que o PBL, no modelo de Barrows, é simultaneamente uma estratégia de ensino e uma arquitetura de aprendizagem voltada à autonomia, à integração de saberes e ao raciocínio aplicado.

3.3. Universo da Pesquisa – Curso de Inteligência Artificial

A pesquisa foi realizada na Escola Cidadã Integral Técnica (ECIT) Luiz Gonzaga de Albuquerque Burity, instituição pública estadual localizada no município de João Pessoa, Paraíba, atendendo aproximadamente 260 estudantes do ensino médio integrado ao curso técnico em Informática. A escola dispõe de infraestrutura adequada para o desenvolvimento de atividades tecnológicas, incluindo laboratórios de informática equipados com computadores suficientes para todos os alunos, salas de aula climatizadas, projetores multimídia e acesso à internet para fins pedagógicos. Na imagem 4 podemos visualizar a localização da escola.

Figura 4 - Localização da escola



Fonte: Rodrigues Neta, Edith, 2023.

Embora os estudantes já tivessem tido contato prévio com metodologias ativas, o uso do PBL em projetos de tecnologia havia ocorrido apenas de forma pontual e em menor escala. A proposta desta pesquisa implementou a Aprendizagem Baseada em Problemas em um módulo completo, ao longo de um semestre, permitindo um acompanhamento contínuo das etapas do método e do desenvolvimento das competências dos alunos (BARROWS, 1986; WOODS, 1994).

O componente curricular de Inteligência Artificial, ofertado no primeiro semestre do terceiro ano do curso técnico, possui carga horária de 33 horas e está alinhado às competências previstas na matriz curricular do itinerário formativo de Informática, conforme (Apêndice A). Entre seus principais objetivos, destacam-se: i) avaliar a precisão de modelos e ferramentas de IA, analisando resultados confiáveis e aplicáveis a situações do mundo real; ii) avaliar a eficiência de diferentes algoritmos de aprendizagem de máquina utilizando métricas de desempenho básicas, como acurácia e precisão; e iii) utilizar algoritmos de aprendizagem supervisionada para resolver problemas de classificação e regressão em conjuntos de dados estruturados. Essas competências estão em consonância com as orientações da Base Nacional Comum Curricular para a Educação Profissional e Tecnológica, que reforça a importância do

desenvolvimento de habilidades analíticas, resolução de problemas e uso crítico de tecnologias digitais (BRASIL, 2018).

A oferta de um curso técnico integrado com ênfase em computação e, em particular, em Inteligência Artificial possui relevância social direta, por ampliar o acesso de jovens a competências que hoje estruturam a vida econômica, os serviços públicos e a cultura digital. Ao desenvolver raciocínio lógico, análise de dados, programação e pensamento crítico sobre tecnologias, a escola contribui tanto para a inserção qualificada no mundo do trabalho quanto para a formação cidadã, reduzindo a distância entre estudantes da rede pública e oportunidades formativas historicamente concentradas em contextos de maior capital tecnológico. Nesse sentido, fortalecer a educação computacional no ensino técnico significa também fortalecer a capacidade de participação social desses sujeitos em uma sociedade orientada por dados, automação e decisões mediadas por algoritmos

3.4. Contexto e Participantes

Participaram do estudo 33 estudantes com idades entre 16 e 18 anos, todos com conhecimentos prévios em lógica e linguagens de programação adquiridos em módulos cursados nos anos anteriores, mas sem experiência prática com Inteligência Artificial ou Machine Learning. Os alunos foram organizados em três grupos formados por afinidade, buscando facilitar a colaboração e o gerenciamento da tutoria. O ciclo PBL foi conduzido em sete etapas, desde a apresentação do problema até a elaboração de soluções aplicadas, utilizando softwares como Orange Data Mining e ambientes de programação Python. Dois docentes atuaram como tutores durante todo o processo, mediando discussões e incentivando a autonomia dos estudantes sem fornecer respostas diretas. Ao longo das etapas, contamos com a participação de profissionais externos, representantes de uma empresa de tecnologia, que ministraram uma palestra sobre o uso de IA no mercado de trabalho, além disso, na avaliação final dos projetos, os professores da BNCC, em articulação com a área técnica, atuaram como avaliadores e, portanto, também como participantes da pesquisa.

3.5. Estrutura da intervenção

A intervenção pedagógica foi desenvolvida ao longo de quatro meses, com duas aulas semanais, totalizando aproximadamente 33 horas dedicadas ao componente de Inteligência Artificial (IA). Todo o percurso foi organizado em um fluxo metodológico de três fases interdependentes: Planejamento, Execução e Avaliação que podem ser representadas na Figura 5. Esse fluxo se ancora na metodologia PBL, na qual o conhecimento é construído pela

resolução de desafios progressivamente mais complexos, com espaço para ajustes ao longo do caminho. Assim, ainda que houvesse uma sequência previamente planejada, foram realizados rearranjos durante a aplicação, sobretudo para retomar e reforçar conceitos teóricos que se mostraram mais desafiadores, em consonância com a ideia de flexibilidade defendida por Delisle (1997) no contexto do PBL.

Planejamento. Na primeira fase, concentrou-se a preparação do ambiente de aprendizagem e a definição do escopo da intervenção. Inicialmente, foram estabelecidos os objetivos pedagógicos e os conteúdos de IA a serem trabalhados (1.1), contemplando algoritmos de busca heurística (Busca Gulosa e A*), técnicas de classificação (Naïve Bayes, Árvore de Decisão, Regras e kNN), regressão linear e agrupamento (k-means).


Em seguida, utilizou-se um problema disparador, complementado por palestra de profissionais de uma empresa da área de desenvolvimento de sistemas (1.2), para contextualizar a relevância do tema no mercado de trabalho e motivar os estudantes antes do aprofundamento técnico. Por fim, as turmas foram organizadas no Google Classroom (1.3), que passou a funcionar como repositório central de materiais de apoio, datasets, roteiros de atividades e avisos, além de canal oficial para entrega de tarefas e devolutivas.

Execução. O núcleo da intervenção foi estruturado em quatro eixos temáticos progressivos: Algoritmos de Busca, Classificação, Regressão e Agrupamento, cada um deles organizado em um ciclo PBL padronizado, conforme a parte central da Figura 5: problema → conteúdo → prática guiada → desafio prático. Em cada eixo, os estudantes eram inicialmente confrontados com um problema realista, formulado a partir de situações ligadas à área de computação e ciência de dados. Na sequência, ocorria a explanação teórica dos conceitos necessários à resolução do problema, seguida de práticas guiadas com exemplos passo a passo.

Para os algoritmos de busca, utilizou-se principalmente o Visual Studio Code com Python; para classificação, regressão e agrupamento, empregou-se o Orange Data Mining, explorando visualmente pipelines de Machine Learning; o Google Colab foi acionado como ambiente colaborativo de programação e experimentação. Em cada ciclo, o percurso era concluído por um desafio prático em que os estudantes, com maior autonomia, precisavam aplicar os conceitos estudados a um problema contextualizado, produzindo protótipos de soluções em código ou fluxos no Orange. Ao longo da execução, o Google Classroom centralizava orientações e devolutivas, enquanto o Google Slides apoiava a preparação de apresentações intermediárias e finais.

Avaliação. A terceira fase, consolidou o processo de ensino-aprendizagem por meio de um conjunto articulado de procedimentos avaliativos. Em cada eixo temático, foram realizadas avaliações formativas, principalmente via Google Forms, para monitorar a compreensão conceitual em tempo hábil e orientar retomadas de conteúdo quando necessário. Paralelamente, a produção de artefatos digitais (notebooks no Google Colab, fluxos no Orange e códigos em Python) constituiu evidência central de aprendizagem prática e foi utilizada tanto para feedback qualitativo quanto para registro de progresso. Ao final do percurso, os grupos elaboraram uma prova/apresentação final, em que expuseram os problemas tratados, as estratégias de modelagem adotadas e os resultados alcançados, utilizando Google Slides como apoio visual. Cabe destacar que, embora esta seção apresente a Avaliação como parte integrante do fluxo incluindo momentos formativos, artefatos e prova final, os critérios detalhados, instrumentos, rubricas e análises dos resultados avaliativos serão discutidos em profundidade na seção específica de Avaliação do trabalho.

Figura 5 - Fluxograma da aplicação do PBL no componente de Inteligência Artificial



Fonte: Elaborado pelo Autor (2025).

A aplicação do PBL seguiu um ciclo adaptado de sete etapas: (i) apresentação do problema, contextualizado com situações do cotidiano ou demandas reais do mercado de tecnologia; (ii) discussão inicial e levantamento de hipóteses pelos grupos; (iii) pesquisa

autônoma e coleta de informações relevantes; (iv) planejamento e proposta de solução com base nos algoritmos de IA estudados; (v) prototipagem e implementação computacional da solução; (vi) apresentação dos resultados e debate coletivo; e (vii) avaliação formativa, autoavaliação e feedback dos pares. Cada etapa foi acompanhada de produtos específicos, como mapas conceituais, códigos executáveis, relatórios técnicos e apresentações orais. O processo foi mediado por dois professores-tutores, cujo papel foi orientar e questionar os grupos, evitando fornecer respostas diretas, conforme recomendações de Barrows (1986) e Woods (1994). A avaliação final integrou critérios técnicos (funcionalidade dos algoritmos, acurácia e coerência da solução) e competências socioemocionais (colaboração, comunicação, autonomia e raciocínio crítico), de acordo com os referenciais da BNCC para a Educação Profissional e Tecnológica (BRASIL, 2018).

3.5 Aplicação do estudo

A implementação da Aprendizagem Baseada em Problemas (PBL) no componente de Inteligência Artificial foi estruturada em ciclos voltados à aplicação prática dos algoritmos de busca heurística, classificação, regressão e agrupamento. Cada ciclo seguiu as principais etapas do PBL propostas por Barrows (1986) e Woods (1994) – apresentação do problema, análise inicial, investigação e pesquisa, proposta de solução, prototipagem e avaliação –, adaptadas para o contexto do ensino médio técnico em informática. A aplicação foi organizada de modo que cada algoritmo tivesse um ciclo próprio, permitindo que os estudantes desenvolvessem progressivamente competências de programação, análise de dados e uso de ferramentas computacionais, finalizando com um projeto integrador mais robusto, no qual os grupos criaram soluções para problemáticas reais do ambiente escolar, utilizando os conhecimentos adquiridos.

Esse modelo remete ao clássico método de Barrows que consistiu em um foco mais prático e otimização das etapas, visando atender às características da turma e às limitações de tempo e recursos. A etapa inicial de definição de objetivos e organização do conhecimento prévio, tradicionalmente prevista no PBL, foi simplificada, priorizando a compreensão prática dos algoritmos a partir de exemplos, simulações e exercícios guiados. Essa decisão foi motivada pela percepção de que os estudantes apresentaram maior autonomia, domínio dos conteúdos e motivação quando colocados diante de atividades de “mão na massa”, como a implementação de códigos e testes com datasets reais, favorecendo o aprendizado ativo (SAVERY, 2015).

Assim, os ciclos foram reduzidos sem burocracia, mantendo o caráter investigativo e colaborativo, mas com maior ênfase no desenvolvimento técnico.

Em cada ciclo, os grupos de alunos receberam problemas contextualizados para investigação, elaboraram hipóteses, buscaram informações teóricas e propuseram soluções computacionais. As entregas incluíram códigos funcionais, relatórios técnicos, mapas conceituais e apresentações parciais dos resultados, sempre com prazos e instruções organizados no Google Classroom. A prototipagem consistiu na implementação dos algoritmos em Python (para busca heurística) e no uso do Orange Data Mining (para classificação, regressão e agrupamento), complementados por análises de métricas como acurácia e precisão. A avaliação foi realizada de forma formativa, combinando questionários teóricos individuais, análise qualitativa das soluções pelos tutores e autoavaliação dos estudantes. A etapa final do semestre culminou no projeto integrador, um ciclo ampliado em que cada grupo escolheu um problema real da escola e desenvolveu uma solução baseada em um dos algoritmos estudados, apresentando relatório detalhado, protótipo funcional e justificativa técnica.

O ciclo adaptado do PBL, portanto, diferenciou-se do modelo clássico por: i) otimização das etapas para permitir aplicação completa em quatro algoritmos no período de um semestre; ii) enfoque prático, reduzindo atividades conceituais extensas e priorizando a experimentação e prototipagem; iii) uso de ferramentas tecnológicas centralizadas (Google Classroom, Python, Orange) para organizar materiais, prazos e entregas; e iv) projeto integrador final, elaborado como uma síntese do aprendizado técnico e investigativo, proporcionando aos alunos experiência próxima à prática profissional da ciência de dados. Essa adaptação demonstra que o PBL pode ser ajustado para cursos técnicos, garantindo engajamento e aprendizagem ativa, mesmo diante de limitações estruturais e lacunas de conhecimento prévio (DE BARROS; PAIVA; HAYASHI, 2023; SAVERY, 2015).

3.5.1. Desenvolvimento da proposta do PBL para o ensino de algoritmos iniciais

Ao longo do semestre, foram trabalhados exemplos práticos, exercícios em grupo e o manuseio de ferramentas para facilitar a assimilação dos conteúdos. Essa estratégia permite que os alunos desenvolvam habilidades necessárias para a ABP, como raciocínio crítico e resolução colaborativa de problemas. Cada etapa da sequência, desde a apresentação teórica até as atividades de desempenho, foi estruturada para promover uma aprendizagem ativa, criando um ambiente propício para a preparação dos alunos em IA e ML. Podemos visualizar na tabela 2 a

sequência estratégica de aprendizagem adotada, que orienta o desenvolvimento dessas competências e prepara os estudantes para enfrentar os desafios do ABP.

Tabela 2 - Cronograma da intervenção pedagógica baseada em ABP/PBL

Fase	Período	CH	Atividade principal	Tópicos abordados	Passos do PBL
Abertura da intervenção	20/fev	2h	Palestra “Inteligência Artificial no mercado” com empresa parceira e apresentação do método PBL aos estudantes.	Todas as trilhas (introdução geral ao componente).	Contextualização e problema disparador geral (Passos 1–2).
Ciclo 1 – Algoritmos de busca heurística	26/02 a 15/03	7h	Resolução de problemas de roteamento e caminho mínimo, com implementação em Python.	Busca Gulosa e A*.	Aplicação integral dos sete passos do PBL (1 a 7) – do problema inicial à avaliação formativa.
Ciclo 2 – Classificação	18/03 a 05/04	7h	Modelagem de problemas de decisão e construção de modelos de classificação em Orange.	Naïve Bayes, Árvore de Decisão, Regras, kNN.	Aplicação integral dos sete passos do PBL (1 a 7) em nova trilha de problemas.
Ciclo 3 – Regressão	08/04 a 26/04	7h	Problemas de previsão de valores contínuos e experimentos de regressão linear em Orange.	Regressão linear.	Aplicação integral dos sete passos do PBL (1 a 7) focada em problemas de previsão.
Ciclo 4 – Agrupamento (k-means)	29/04 a 17/05	7h	Organização de dados em grupos e experimentos com k-means (ex.: conjunto Iris).	Agrupamento k-means.	Aplicação integral dos sete passos do PBL (1 a 7), enfatizando descoberta de padrões.
Culminância – Projeto integrador	20/mai	3h	Apresentação dos projetos finais, socialização dos resultados e discussão coletiva sobre o percurso formativo.	Integra todas as trilhas de algoritmos.	Socialização ampliada e avaliação final (Passo 7, com autoavaliação e feedback dos pares).

Fonte: Elaborado pelo Autor (2025).

Na fase de **abertura da intervenção**, o componente de Inteligência Artificial foi iniciado com uma palestra da empresa parceira SNN Tecnologia, intitulada “O Futuro da Programação Frente à Inteligência Artificial”. Nessa exposição, os profissionais convidados apresentaram o cenário atual da IA no mercado de trabalho, destacando o impacto nas profissões de desenvolvimento de software, a necessidade de adaptação constante e as possibilidades de ingresso na área, com exemplos de aplicação da IA em problemas reais.

Em seguida, o professor conduziu um momento de diálogo com a turma para esclarecimento de dúvidas e levantamento de percepções dos estudantes sobre os desafios da IA na sociedade. Esse espaço foi utilizado também para explicar, de forma introdutória, a metodologia de aprendizagem baseada em problemas, indicando como os sete passos seriam vivenciados ao longo do semestre. Na mesma ocasião, foi apresentado o plano de ensino do componente de Inteligência Artificial, com os ciclos temáticos, critérios de avaliação e organização das atividades no Google Classroom, estabelecendo o vínculo dessa fase com a etapa de planejamento representada no esquema de Planejamento, Execução e Avaliação do projeto. Essa fase inicial foi fundamental para motivar os alunos e alinhar expectativas, funcionando como momento de contextualização e definição do problema geral que orientou os ciclos seguintes do PBL. Conforme a imagem 6.

Figura 6 - Palestra promovida por profissionais da SNN Tecnologia - O Futuro da Programação Frente à Inteligência Artificial




Fonte: Elaborado pelo Autor, 2024.

No primeiro ciclo da intervenção, dedicado aos **algoritmos de busca heurística**, os estudantes foram introduzidos aos conceitos de teoria de buscas, estados, espaço de estados e funções heurísticas. Esse conteúdo foi organizado na seção “Algoritmos de busca” do Google Classroom (Apêndice D), onde o professor disponibilizou a apresentação “Algoritmos Inteligentes de Busca”, utilizada para contextualizar o problema de encontrar rotas em grafos, exemplificado pelas rotas da Romênia, pelo jogo das peças (8-puzzle) e pelo jogo da velha, configurando a **etapa 1** do fluxo de PBL (apresentação do problema).

A partir desse material, o problema de ir da cidade de Arad até Bucharest, conforme figura 7, onde foi retomado como situação disparadora do ciclo. Em pequenos grupos, os estudantes discutiram diferentes caminhos possíveis, identificando estado inicial, estado objetivo, ações e trajetórias intermediárias, bem como levantando hipóteses sobre quais rotas seriam mais promissoras a partir das distâncias apresentadas e das funções heurísticas, caracterizando a **etapa 2** (discussão inicial e levantamento de hipóteses). Na sequência, foi proposto que os alunos retomassem os materiais disponibilizados no Classroom e buscassem, em outras fontes digitais de livre acesso (vídeos, livros didáticos e tutoriais on-line), exemplos e explicações complementares sobre algoritmos de busca em grafos, registrando dúvidas e anotações para socializar com o grupo, o que correspondeu à **etapa 3**, pesquisa autônoma e coleta de informações.

Figura 7 - Localização de rotas na Romênia, usando heurística



Fonte: Adaptador do livro Stuart Russell e Peter Norvig (2013).

Em seguida, foram apresentados dois materiais específicos: os slides “Grafo – Busca Gulosa” e “Grafo – Busca A* Estrela” (Apêndice E), que mostram o mapa de cidades, a tabela de distâncias em linha reta e as árvores de expansão geradas por cada algoritmo, permitindo visualizar o percurso escolhido e o custo acumulado em cada passo. A análise desses materiais e a organização das ideias sobre como traduzir o problema em estruturas de dados e procedimentos computacionais configuraram a **etapa 4** (planejamento e proposta de solução), na qual os grupos delinearam, junto ao professor, o caminho a ser seguido na implementação.

Na etapa de prática guiada, relativa à **etapa 5**, prototipagem e implementação computacional, esse mesmo problema foi transposto para o ambiente de programação Python no Google Colab (Apêndice F). Na etapa de prática guiada, relativa à etapa 5, prototipagem e implementação computacional, esse mesmo problema foi transposto para o ambiente de programação Python no Google Colab (Apêndice F). A turma foi organizada em sete grupos de trabalho, mantendo a mesma divisão utilizada nos ciclos da intervenção, com dois computadores disponíveis para cada grupo. Dessa forma, os estudantes não foram separados por algoritmo, mas trabalharam colaborativamente no interior de seus grupos, alternando funções de leitura, análise, codificação, execução e discussão dos resultados nos notebooks. Os grupos acessaram dois notebooks: um dedicado à busca gulosa e outro à busca A estrela. Em ambos, o código foi organizado em blocos sucessivos, começando pela definição do grafo, estrutura de dados com os vértices e arestas, passando pela construção de um vetor ordenado que prioriza os nós de acordo com a heurística, e culminando na função que implementa o algoritmo de busca e imprime o caminho encontrado. As capturas de tela dos notebooks evidenciam essa estrutura em seções, como “Grafo”, “Vetor ordenado” e “Busca gulosa” ou “Busca A estrela”, permitindo que os estudantes acompanhassem cada parte da solução antes de executá-la integralmente.

Depois de compreenderem o funcionamento dos algoritmos no exemplo da Romênia, os estudantes foram desafiados a resolver um novo problema de roteamento, apresentado no material de atividade “Atividade 01”. Esse documento traz um mapa com as distâncias entre cidades do Paraná e uma tabela com as distâncias em linha reta até o objetivo, definindo a tarefa de encontrar a melhor rota de Porto União até Curitiba. Em grupos, os alunos reutilizaram os notebooks da busca gulosa e da busca A estrela, adaptando o grafo e os vetores heurísticos ao novo conjunto de cidades e comparando o custo total das rotas obtidas por cada algoritmo. Ao final, os grupos registraram suas soluções no Google Classroom e apresentaram, em plenária, os caminhos encontrados, justificando as escolhas e debatendo as diferenças entre os resultados

obtidos pelos dois algoritmos, o que tornou explícita a etapa 6 de apresentação dos resultados e debate coletivo.

Para concluir o ciclo de algoritmos de busca, foi aplicado um formulário avaliativo online, elaborado no Google Forms e intitulado “Avaliação – Algoritmo de Busca Gulosa e Busca A*” (Apêndice G). O instrumento foi organizado em cinco seções: identificação dos estudantes, questões de múltipla escolha sobre os conceitos teóricos de busca gulosa e busca A estrela, itens voltados à implementação dos algoritmos em Python, autoavaliação da compreensão e do nível de confiança para programar essas rotinas e, por fim, um bloco de avaliação e feedback sobre os recursos didáticos utilizados. As respostas permitiram verificar o domínio conceitual e procedimental dos alunos, ao mesmo tempo em que ofereceram indícios sobre quais estratégias de ensino foram mais eficazes e quais aspectos poderiam ser aprimorados. Esses dados foram considerados como insumo para o planejamento do ciclo seguinte, dedicado aos algoritmos de classificação, caracterizando a **etapa 7** de avaliação formativa, autoavaliação e feedback dos pares, no fluxo do PBL, por meio do uso sistemático do Google Forms.

Algoritmos de classificação. Entre o período 18/03 a 05/04, foi desenvolvido o segundo ciclo da intervenção, dedicado aos algoritmos de classificação. Assim como no ciclo anterior, a organização das atividades seguiu o fluxo em sete etapas do PBL, articulando explanação teórica, exploração guiada de exemplos e resolução de problemas com dados reais. A situação disparadora desse ciclo foi um problema de modelagem de risco de crédito, apresentado por meio de uma tabela com registros de clientes contendo histórico de crédito, nível de dívida, garantias e renda anual, associada à classe-alvo “risco de crédito” (alto, moderado ou baixo), conforme a Figura 8, bem como divisão dos materiais no Google Classroom (Apêndice H). A discussão inicial sobre quais características seriam mais determinantes para o risco de crédito, e como essas variáveis poderiam ser combinadas para emitir uma decisão, configurou a **etapa 1** do PBL de apresentação do problema e contexto.

Figura 8 - Modelagem de Risco de Crédito

História do crédito	Dívida	Garantias	Renda anual	Risco
Ruim	Alta	Nenhuma	< 15.000	Alto
Desconhecida	Alta	Nenhuma	≥ 15.000 a ≤ 35.000 ≥ 15.000 a	Alto
Desconhecida	Baixa	Nenhuma	≤ 35.000 < 15.000	Moderado
Desconhecida	Baixa	Nenhuma	> 35.000	Alto
Desconhecida	Baixa	Nenhuma	> 35.000	Baixo
Desconhecida	Baixa	Adequada	< 15.000	Baixo
Ruim	Baixa	Nenhuma	> 35.000	Alto
Ruim	Baixa	Adequada	> 35.000	Moderado
Boa	Baixa	Nenhuma	> 35.000	Baixo
Boa	Alta	Adequada	< 15.000	Baixo
Boa	Alta	Nenhuma	≥ 15.000 a ≤ 35.000 > 35.0000	Alto
Boa	Alta	Nenhuma	≥ 15.000 a ≤ 35.000	Moderado
Boa	Alta	Nenhuma		Baixo
Ruim	Alta	Nenhuma		Alto

 Conjunto de Treinamento (80%)
Usado para treinar o modelo

História do crédito	Dívida	Garantias	Renda anual
Ruim	Alta	Adequada	< 15.000
Desconhecida	Alta	Adequada	< 15.000
Desconhecida	Baixa	Nenhuma	> 35.000
Boa	Alta	Adequada	≥ 15.000 a ≤ 35.000

Conjunto de Teste (20%)

Usado para testar o desempenho do modelo.

Fonte: Adaptado de Jones Granatyr (2023)

Em seguida, os estudantes foram convidados a analisar a tabela em grupos, discutindo hipóteses sobre o comportamento esperado dos algoritmos: por exemplo, se a presença de garantias ou a faixa de renda teria maior peso na decisão, ou se diferentes algoritmos tenderiam a classificar os mesmos casos da mesma forma. Essa discussão, mediada pelo professor, correspondeu à **etapa 2** de discussão inicial e levantamento de hipóteses. Paralelamente, os alunos retomaram anotações e materiais de apoio no Google Classroom e consultaram breves referências indicadas em textos e vídeos introdutórios, buscando compreender em que situações algoritmos como Naïve Bayes, Árvore de Decisão, Aprendizagem por Regras e kNN costumam apresentar melhor desempenho. Os principais slides utilizados para sistematizar esses conteúdos estão organizados no (Apêndice I), assim esse movimento de estudo dirigido caracterizou a **etapa 3** de pesquisa autônoma e coleta de informações.


Com base nessas discussões, o professor sistematizou, por meio dos slides “Algoritmo de Treinamento”, a lógica de funcionamento de cada algoritmo, fazendo a ponte entre a tabela de risco de crédito e as operações matemáticas envolvidas. Para o Naïve Bayes, por exemplo, foram detalhados os cálculos de probabilidade condicional a partir das frequências da base; para a Árvore de Decisão, a estrutura hierárquica de decisões; para a Aprendizagem por Regras, a indução de regras “SE... ENTÃO...”; e, para o kNN, o cálculo de distâncias entre instâncias usando a métrica euclidiana. A análise conjunta desses exemplos, discutindo como transformar atributos categóricos em decisões classificatórias e como dividir a base em conjuntos de treino

(80%) e teste (20%), compôs a **etapa 4** de planejamento e proposta de solução, na qual os estudantes observaram como esses algoritmos poderiam ser implementados em um fluxo de mineração de dados.

Na **etapa 5** de prototipagem e implementação computacional, as aulas práticas passaram a ser conduzidas no software *Orange Data Mining*⁴, escolhido por sua interface visual baseada em blocos (“widgets”), que facilita a construção de fluxos de trabalho e a interpretação de métricas como acurácia, matriz de confusão e curva ROC. Inicialmente, foi utilizada uma base de dados fornecida pelo próprio Orange, o dataset “Zoo”, que classifica diferentes animais a partir de 16 características categóricas, como presença de pelos, número de pernas, se põe ovos, entre outras, com sete classes de animais. O conjunto de dados Zoo, bem como a forma como foi organizado para as atividades práticas, está descrito no (Apêndice J). Nessa fase, os estudantes montaram, em conjunto com o professor, fluxos contendo os widgets de carregamento de dados, divisão treino-teste, aplicação dos algoritmos de classificação e visualização dos resultados, o que lhes permitiu observar de forma comparativa o comportamento de cada modelo. Os fluxos de classificação implementados no Orange são apresentados na Figura 9.

Figura 9 - Fluxos de trabalho no Orange Data Mining para os algoritmos de classificação

⁴ <https://orangedatamining.com/>



Fonte: Arquivo pessoal do autor (2024).

Após essa etapa de familiarização, os estudantes foram desafiados a construir seus próprios conjuntos de dados categóricos. Em grupos, definiram um tema de interesse (por exemplo, risco de reprovação no ENEM, ansiedade em relação ao TCC, probabilidade de bom desempenho na redação ou engajamento nos estudos), elaboraram questionários on-line, coletaram respostas da turma e organizaram as bases em planilhas, posteriormente importadas para o Orange. Cada grupo planejou o fluxo de análise, escolhendo quais atributos seriam usados como preditores e qual variável funcionaria como classe-alvo (como “risco”, “desempenho” ou “média total”), aplicando na sequência os quatro algoritmos estudados. A descrição sintética dessas bases, com seus temas, variáveis e classes, encontra-se no (Apêndice K), consolidando o ciclo de planejamento aplicado (etapa 4) e implementação prática (etapa 5) com dados construídos pelos próprios estudantes.

Em um momento seguinte, cada grupo executou os fluxos de treinamento e teste, registrando os valores de acurácia (CA – accuracy), as matrizes de confusão e outros indicadores disponíveis no Orange para os quatro algoritmos, a partir de sua própria base de dados. Os grupos sintetizaram os resultados em quadros comparativos, indicando qual modelo obteve melhor desempenho e discutindo possíveis motivos para as diferenças observadas — por exemplo, a sensibilidade da Árvore de Decisão a determinados atributos ou a robustez do

Naïve Bayes quando havia muitas categorias. Esses resultados foram apresentados à turma e discutidos em plenária, o que configurou a **etapa 6** de apresentação dos resultados e debate coletivo, reforçando a ideia de que a escolha do algoritmo depende das características do problema e dos dados disponíveis.

Para concluir o ciclo, foi aplicado o “Formulário Avaliativo: Algoritmo de Classificação – CA (Acurácia – Accuracy)”, elaborado no Google Forms e apresentado integralmente no (Apêndice L). O instrumento foi organizado em seções que contemplavam: (i) identificação básica dos estudantes e da turma; (ii) questões de múltipla escolha sobre os conceitos de acurácia e sobre o funcionamento dos algoritmos de classificação trabalhados; (iii) itens específicos sobre a leitura dos resultados no Orange (por exemplo, interpretação de valores de CA e de matrizes de confusão); e (iv) um conjunto de questões voltadas à autoavaliação e à percepção de aprendizagem, indagando se o aluno se sentia capaz de construir uma base de dados, escolher um algoritmo adequado, compreender a diferença entre os modelos e avaliar seus próprios avanços. Ao final, havia ainda um espaço para comentários abertos sobre as dificuldades enfrentadas e sugestões de melhoria para as atividades práticas. As respostas a esse formulário alimentaram o planejamento do ciclo seguinte e foram utilizadas como avaliação formativa da **etapa 7** do PBL, integrando avaliação, autoavaliação e feedback, permitindo ajustar o ritmo e o nível de aprofundamento dos conteúdos de aprendizagem de máquina.

Todos os fluxos construídos no Orange, bem como as bases de dados elaboradas em grupo e os registros dos resultados dos algoritmos, foram organizados e compartilhados no Google Classroom, assegurando a rastreabilidade do processo e constituindo um repositório de evidências da aprendizagem dos estudantes.

Algoritmos de Regressão. O terceiro ciclo da intervenção foi dedicado aos algoritmos de regressão, com foco na regressão linear e em problemas de previsão de valores contínuos. A situação disparadora foi a comparação entre tarefas de classificação e regressão, destacando que, neste último caso, o objetivo é prever um valor numérico (como preço ou custo) a partir de um conjunto de variáveis independentes. Essa discussão foi introduzida por meio dos slides (Apêndice N). “Algoritmo de Regressão”, que apresentavam exemplos de situações reais (gastos de propaganda e vendas, fatores climáticos e velocidade do vento, características de produtos e preço), além da representação no plano cartesiano e da equação da reta. Essa etapa correspondeu à apresentação do problema (**etapa 1** do PBL).

$$\hat{y} = \beta_0 + \beta_1 X$$

(equação 1)

Em pequenos grupos, os estudantes discutiram quais atributos tenderiam a influenciar mais o valor de uma variável-alvo em um cenário de regressão, por exemplo, potência do motor, quilometragem e idade no caso de carros, ou área construída e número de quartos no caso de casas. A partir dos gráficos de dispersão apresentados em sala, os alunos levantaram hipóteses sobre como a linha de regressão deveria se ajustar aos pontos e por que alguns pontos ficariam mais distantes da linha (resíduos), caracterizando a **etapa 2** (discussão inicial e levantamento de hipóteses). Em seguida, retomaram os materiais disponibilizados no Google Classroom (Apêndice M) na seção “04 – Algoritmos de regressão” (introdução conceitual, exemplo de regressão com o dataset Automóvel 1985 (Apêndice M) e a própria atividade avaliativa o que configurou a **etapa 3** de pesquisa autônoma e estudo guiado.

A partir desses materiais, o professor sistematizou a função de custo da regressão linear, explicando que o modelo busca minimizar a soma dos quadrados dos resíduos, isto é, das diferenças entre os valores observados e os valores previstos pela reta de regressão. Os slides enfatizavam que os parâmetros b_0 e b_1 determinam a posição e a inclinação da linha, bem como que um bom modelo é aquele cujo erro médio é reduzido. Nessa etapa, foram definidos, em conjunto com os estudantes, os fluxos de trabalho que seriam utilizados no Orange Data Mining: seleção da variável alvo, escolha dos atributos preditores, divisão da base em conjuntos de treinamento e teste (80%/20%) por meio do widget Data Sampler e uso do módulo Test & Score para avaliação do modelo. Esse momento compôs a **etapa 4** de planejamento e proposta de solução.

Nas aulas práticas, correspondentes à etapa 5 de prototipagem e implementação computacional, os estudantes implementaram esse plano no Orange utilizando inicialmente o dataset Automóvel 1985, que contém 205 instâncias e 25 atributos referentes a especificações de automóveis e seus preços. Nesses fluxos, os alunos conectaram os widgets File, Select Columns, Data Sampler, Linear Regression e Test & Score, visualizando ao final uma tabela com o preço real, o preço previsto e o erro de cada previsão. A estrutura e as principais características desse conjunto de dados são apresentadas no (Apêndice O).

Figura 10 - Visualização da base Automobile no Orange com os resultados da Regressão Linear

	price	Linear Regression	Linear Regression (error)	symboling	normalized-losses	make	fuel-type
1	13495	15197.2	1702.18	3	?	alfa-romero	gas
2	16500	15197.2	-1302.82	3	?	alfa-romero	gas
3	16500	16100.6	-399.369	1	?	alfa-romero	gas
4	13950	13421.1	-528.941	2	164	audi	gas
5	17450	17295.6	-154.369	2	164	audi	gas
6	15250	15397.3	147.267	?	?	audi	gas
7	17710	19204.4	1494.42	1	158	audi	gas
8	18920	19884.4	964.373	1	?	audi	gas
9	23875	21952.3	-1922.75	1	158	audi	gas
10	?	24580.5	?	0	?	audi	gas
11	16430	18183.6	1753.64	2	192	bmw	gas
12	16925	19405.9	2480.89	0	192	bmw	gas
13	20970	22683.9	1713.9	0	188	bmw	gas
14	21105	22881.4	1776.37	0	188	bmw	gas
15	24565	24241.5	-323.46	1	?	bmw	gas
16	30760	31926.7	1166.72	0	?	bmw	gas
17	41315	33697.8	-7617.16	0	?	bmw	gas
18	36880	35929.1	-950.892	0	?	bmw	gas
19	5151	5151	-2.50293e-09	2	121	chevrolet	gas
20	6295	6065.76	-229.243	1	98	chevrolet	gas

Fonte: Arquivo pessoal do autor (2024).

Em seguida, foi proposta uma atividade comparativa com o dataset house prices, que reúne atributos de casas com número de quartos, banheiros, área total, idade do imóvel, entre outros e o respectivo preço. Em ambos os casos, os estudantes aplicaram o mesmo fluxo de regressão linear, de modo a comparar a capacidade do modelo em contextos distintos (preço de carros e de casas).

Após a implementação, cada grupo analisou os resultados no Test & Score e no Data Table, identificando os valores de erro médio e a diferença entre preço real e preço previsto em cada instância. A partir dessas informações, discutiram coletivamente em que situações o modelo conseguia se aproximar bem dos dados e quando produzia erros maiores, relacionando essas diferenças às características dos atributos selecionados e à própria dispersão dos pontos no gráfico. Esse momento de socialização dos resultados e debate sobre a qualidade das previsões caracterizou a **etapa 6** da apresentação dos resultados e debate coletivo.

Por fim, a **etapa 7** de avaliação formativa, autoavaliação e feedback foi operacionalizada por meio do formulário on-line “Exercício – Algoritmo de Regressão”, elaborado no Google Forms e apresentado integralmente no (Apêndice Q). O instrumento foi organizado em cinco seções: identificação dos estudantes e da turma; questões de múltipla escolha sobre conceitos teóricos de regressão (objetivo do algoritmo, função de custo, significado dos pontos e da linha de regressão); questões sobre a implementação prática no Orange (tipo de dados utilizados, função dos widgets Data Table, Select Columns e Test &

Score, proporção de dados destinada ao treino e ao teste); itens de interpretação do dataset house prices (variável alvo, percentual de acerto obtido pelo modelo) e de autoavaliação (dificuldade percebida, nível de participação nas aulas); e, por fim, um bloco para upload de capturas de tela do modelo implementado e dos resultados obtidos. As respostas permitiram avaliar o domínio conceitual e procedimental dos estudantes, bem como seu nível de confiança na utilização do Orange para problemas de regressão, fornecendo subsídios para ajustes nas etapas seguintes da intervenção.

Algoritmos de agrupamento. O quarto ciclo da intervenção foi dedicado aos algoritmos de agrupamento, com foco no K-means. Diferentemente dos ciclos anteriores, baseados em tarefas supervisionadas (classificação e regressão), aqui o objetivo foi trabalhar com aprendizado não supervisionado, em que o modelo procura descobrir estruturas em dados sem rótulos prévios. A situação disparadora foi construída a partir de exemplos visuais presentes nos slides “Algoritmo de agrupamento K-means” e em uma simulação interativa do algoritmo, que mostravam nuvens de pontos sendo separadas em regiões de cor diferente à medida que os centróides se deslocavam, conforme apresentado no (Apêndice V). Essa combinação de materiais permitiu contextualizar aplicações como segmentação de mercado, perfis de clientes em serviços de streaming e análise de redes sociais, configurando a **etapa 1** do PBL de apresentação do problema e contexto.


Em seguida, os estudantes foram convidados a discutir, em grupos, como diferentes situações do cotidiano poderiam ser representadas como problemas de agrupamento, por exemplo, separar visitantes de um site por tipo de dispositivo, agrupar clientes de cartão de crédito por padrão de gasto ou identificar grupos de flores com características semelhantes. A partir dos gráficos de dispersão apresentados nos slides (combinações de salário e idade, por exemplo), os alunos levantaram hipóteses sobre quantos grupos poderiam existir, onde os centróides tenderiam a ficar e como a posição de um ponto mudaria de cluster ao longo das iterações, caracterizando a **etapa 2** (discussão inicial e levantamento de hipóteses). Na sequência, retomaram os materiais da seção “05 – Algoritmo de agrupamento” no Google Classroom, cuja organização está descrita no (Apêndice R), compondo a **etapa 3** (pesquisa autônoma e coleta de informações).

A partir desses materiais, o professor detalhou o funcionamento do algoritmo K-means, explorando a sequência: escolha do número de clusters k , inicialização aleatória dos centróides, atribuição de cada ponto ao centróide mais próximo, recálculo dos centróides como média dos pontos de cada grupo e repetição do processo até a estabilização. Os slides ilustravam

essa dinâmica com exemplos bidimensionais e com o fluxo de trabalho proposto para o Orange, com os widgets Datasets, Data Table, k-Means e Scatter Plot, o que permitiu definir, em conjunto com a turma, quais atributos seriam usados, qual valor de k seria testado inicialmente e como os resultados seriam visualizados. Esse momento constituiu a **etapa 4** (planejamento e proposta de solução).


Nas aulas práticas, correspondentes à **etapa 5** (prototipagem e implementação), os estudantes implementaram esse plano no Orange utilizando inicialmente o clássico dataset Iris, que contém 150 instâncias de flores com medições de sépalas e pétalas para três espécies diferentes. A Figura 14 apresenta imagens das três espécies do conjunto de dados Iris, enquanto a Figura 15 mostra a dispersão dessas instâncias no Scatter Plot do Orange, com cada espécie representada por uma cor distinta. Com base nessas representações, os alunos aplicaram o algoritmo K-means com diferentes valores de k e analisaram os agrupamentos gerados, comparando a separação obtida com o conhecimento prévio sobre as três espécies.

Figura 11 - Espécies de Íris no Conjunto de Dados Iris



Fonte: The Elements of Statistical Learning (2006).

Figura 12 - Dispersão das Espécies de Íris



Fonte: Arquivo pessoal do autor (2024).

Em seguida, foi proposta a atividade prática principal, baseada no dataset `credit_card_clients.csv`, disponibilizado no Google Classroom. Essa base reúne informações de clientes de cartão de crédito, incluindo limite disponível, valores de fatura e outros indicadores de uso do cartão. O objetivo do exercício era agrupar os clientes de acordo com seus padrões de gasto e de utilização do limite. Cada grupo de alunos baixou o arquivo, importou-o no Orange, selecionou os atributos mais relevantes (como limite do cartão e valores de gastos em diferentes meses), definiu um valor de k e aplicou o K-means, visualizando os resultados em gráficos de dispersão e tabelas de dados. A partir desses resultados, discutiram quais perfis de clientes emergiam em cada cluster (por exemplo, clientes com limite alto e baixo uso, clientes com gastos próximos ou acima do limite), socializando suas visualizações e interpretações com a turma, o que compôs a **etapa 6** (apresentação dos resultados e debate coletivo).

A **etapa 7** (avaliação formativa, autoavaliação e feedback) foi operacionalizada por meio do formulário on-line “Avaliação – Algoritmo de Agrupamento”, elaborado no Google Forms e apresentado integralmente no (Apêndice U). O instrumento continha uma primeira seção de identificação (nome e turma) e uma seção de questões de múltipla escolha sobre: o objetivo principal de um algoritmo de agrupamento, o reconhecimento do K-means como

exemplo de clustering, a definição de centróides e o processo de atualização desses centróides a cada iteração. Ao final, havia um item que solicitava o envio de um print do agrupamento gerado a partir da base `credit_card_clients.csv`, comprovando a realização da atividade prática no Orange. As respostas permitiram verificar a compreensão conceitual e procedimental dos estudantes, além de indicar dificuldades específicas, orientando o fechamento da intervenção.

A culminância dos projetos integradores ocorreu em 20/05, em um encontro de aproximadamente três horas, dedicado à apresentação pública dos projetos finais desenvolvidos pelos estudantes. Após vivenciarem os quatro ciclos de aprendizagem baseados em problemas – algoritmos de busca heurística, classificação, regressão e agrupamento, os discentes foram organizados em grupos, que tiveram liberdade para definir a composição das equipes. Cada grupo ficou responsável pela elaboração de um artigo e pelo desenvolvimento de um sistema web, articulando as trilhas de conteúdo trabalhadas ao longo da disciplina.

Os projetos tiveram como eixo comum a solução de problemas reais do contexto escolar, o que reforçou o vínculo entre o componente de Inteligência Artificial e as demandas do cotidiano dos estudantes. As aplicações contemplaram, por exemplo a proposta de um sistema de boletins escolares automatizado, uma plataforma para análise climática com regressão linear e uma ferramenta online de visualização de horários por turma e por professor. Todos os sistemas foram desenvolvidos a partir de uma combinação de linguagens e tecnologias como Python, HTML, CSS e JavaScript, e um dos grupos avançou e entregou um sistema completo com uso de técnicas de IA ao empregar regressão linear (Apêndice W), via API, para realizar previsões a partir de dados coletados.

Para a apresentação dos projetos, constituiu-se uma banca avaliadora multidisciplinar, composta por docentes das áreas de Exatas, Ciências da Natureza, Linguagens e da Formação Técnica, o que permitiu múltiplos olhares sobre as propostas. Cada grupo dispôs de cerca de 20 minutos para exposição do trabalho, seguida de aproximadamente 10 minutos destinados a perguntas, comentários e considerações da banca. A dinâmica contemplou, assim, tanto a explicação técnica do sistema e das escolhas metodológicas descritas no artigo, quanto a discussão sobre a relevância dos problemas selecionados e o potencial de aplicação das soluções no ambiente escolar.

De maneira geral, os estudantes demonstraram domínio dos projetos e segurança ao explicar o processo de desenvolvimento, a coleta e o tratamento dos dados e as decisões tomadas durante a implementação. As apresentações evidenciaram também a divisão de responsabilidades entre membros da equipe, com papéis distribuídos entre desenvolvimento,

documentação e apresentação oral. Ao final da sessão, os discentes responderam a um formulário de avaliação e feedback, no qual puderam refletir sobre a experiência com o método PBL, sobre o desenvolvimento dos projetos e sobre a própria apresentação.

Esse momento configurou-se como etapa de socialização ampliada e avaliação final do percurso, em consonância com os passos 6 e 7 do PBL (avaliação e reflexão), permitindo não apenas a síntese dos conhecimentos construídos, mas também a ressignificação das experiências vividas ao longo da intervenção.

3.6. Instrumentos de Coleta e Critérios de Avaliação

A avaliação da intervenção pedagógica foi conduzida por meio de instrumentos variados, contemplando tanto aspectos quantitativos quanto qualitativos, com foco na compreensão da aprendizagem, no desempenho técnico dos estudantes e no impacto da aplicação do PBL. Durante os ciclos de aplicação dos algoritmos, foram utilizados questionários, provas teóricas, exercícios práticos, observações diretas e registros no Google Classroom. As avaliações teóricas tiveram como objetivo aferir o domínio conceitual dos estudantes sobre os algoritmos estudados, enquanto as práticas focaram na capacidade de resolução de problemas por meio da implementação computacional. Além disso, foram realizadas autoavaliações ao final de cada ciclo, por meio de formulários digitais, com questões voltadas à percepção dos alunos sobre o nível de engajamento, dificuldade do conteúdo, motivação para resolução de problemas e segurança no uso dos algoritmos.

Com base nos princípios do PBL (SAVERY, 2015; WOODS, 1994), os instrumentos foram aplicados de forma distribuída ao longo do semestre, compondo uma estrutura avaliativa em três momentos: (i) avaliações teóricas e práticas dentro dos ciclos de cada algoritmo; (ii) autoavaliações qualitativas por ciclo; e (iii) avaliação final do projeto integrador. A parte teórica, ainda que estruturada como aula expositiva, integrava-se ao ciclo do PBL por ser diretamente vinculada à investigação e compreensão do problema. Já a avaliação prática era claramente situada dentro do ciclo investigativo, permitindo que os estudantes aplicassem os conteúdos em contextos reais e propusessem soluções computacionais. A análise qualitativa das autoavaliações incluiu perguntas como: “Você se sentiu mais motivado a aprender após esse ciclo?”, “Seu grupo demonstrou mais organização ou dificuldade ao trabalhar com esse algoritmo?”, e “Você acredita ter compreendido suficientemente a lógica por trás desse modelo de IA?”, o que proporcionou uma visão ampla da experiência dos alunos em cada etapa

A avaliação do projeto integrador foi realizada em um evento especial, com participação de uma banca composta por dois professores da área técnica e cinco professores da BNCC. Os estudantes apresentaram publicamente suas soluções e entregaram previamente um projeto escrito para análise. A avaliação foi guiada por duas fichas distintas, elaboradas conforme as competências específicas de cada área. Os docentes técnicos avaliaram critérios como: domínio técnico dos algoritmos, funcionalidade do código, originalidade computacional e uso apropriado de métricas (como acurácia e precisão). Já os professores da BNCC analisaram aspectos como clareza da apresentação, coerência do relatório, argumentação, organização textual e relevância social da proposta. Ambos os instrumentos seguiram uma escala de pontuação com pesos diferenciados.

As competências socioemocionais – como autonomia, colaboração, responsabilidade e criatividade – também foram avaliadas, ainda que com peso reduzido, especialmente pelos professores da BNCC. Os feedbacks dos avaliadores foram registrados por escrito nos próprios projetos e posteriormente discutidos com os tutores, que também forneceram orientações para ajustes. Apesar de não ter havido nova apresentação formal após o feedback, os grupos receberam prazo para realizar as correções sugeridas. Ao final do processo, os projetos foram organizados em um repositório público da escola, tornando-se referência para futuras turmas e contribuindo para a consolidação de uma cultura de aprendizagem investigativa e colaborativa no ambiente escolar (RIBEIRO; LIMA, 2020).

4.7. Procedimentos de análise

A análise dos dados obtidos ao longo da intervenção pedagógica foi conduzida por meio de uma abordagem mista, combinando procedimentos quantitativos e qualitativos. Essa combinação foi fundamental para compreender, de maneira abrangente, os efeitos da aplicação da metodologia de Aprendizagem Baseada em Problemas (PBL) no ensino técnico de Inteligência Artificial, especialmente no desenvolvimento das competências técnicas dos estudantes e no impacto do processo formativo em termos de engajamento, autonomia e apropriação dos conteúdos.

Do ponto de vista quantitativo, os dados analisados foram oriundos de múltiplas fontes: i) questionários teóricos aplicados após o ensino de cada algoritmo; ii) atividades práticas de resolução de problemas computacionais; iii) projetos desenvolvidos ao longo da intervenção; e iv) dados de participação e desempenho registrados no Google Classroom. Além disso, os questionários de autoavaliação forneceram informações quantitativas sobre o nível de

dificuldade percebido em cada algoritmo. Esses dados foram organizados no Google Sheets, plataforma vinculada ao Google Forms, utilizada para estruturar os questionários aplicados. A partir dessa organização, foi possível identificar padrões de desempenho dos estudantes, observar o rendimento por ciclo e comparar o grau de eficácia dos modelos implementados com base em métricas como acurácia, funcionamento do código e entrega de relatórios técnicos

A análise qualitativa foi conduzida com base em três principais fontes: as autoavaliações respondidas pelos estudantes ao final de cada ciclo, os relatórios elaborados pelos tutores e os comentários da banca avaliadora no momento da apresentação final do projeto integrador. Utilizou-se a técnica de análise de conteúdo, conforme Bardin (2016), a fim de identificar categorias temáticas emergentes nos discursos analisados. Entre as categorias mais recorrentes destacaram-se: motivação, engajamento, dificuldades conceituais (especialmente relacionadas à matemática), domínio das ferramentas tecnológicas, confiança no uso dos algoritmos e criatividade nas soluções propostas. Essas categorias possibilitaram compreender de forma mais sensível a experiência dos estudantes, extrapolando os limites da mensuração objetiva e permitindo identificar aspectos subjetivos que impactaram no processo de aprendizagem.

As questões abertas dos questionários de autoavaliação foram fundamentais para a construção dessa análise. Os estudantes puderam expressar, de forma anônima, suas percepções sobre a experiência de aprendizagem, apontando aspectos positivos, dificuldades enfrentadas, sugestões de melhoria e reflexões sobre a utilização da metodologia PBL. Essa liberdade de expressão forneceu uma base rica de dados que fortaleceu a compreensão sobre o impacto formativo da intervenção.

Para garantir a validade e a confiabilidade das análises, foi realizada triangulação entre os dados quantitativos, qualitativos e observacionais. As avaliações teóricas e práticas foram confrontadas com as autoavaliações dos estudantes e os registros dos tutores, permitindo uma visão integrada e consistente dos resultados. Além disso, os dois professores tutores da base técnica realizaram revisões cruzadas de suas análises e avaliações, promovendo uma conferência por pares que buscou reduzir vieses individuais e ampliar a precisão interpretativa.

A organização dos resultados será apresentada por ciclo de algoritmo (busca, classificação, regressão e agrupamento), e também pelo projeto integrador, considerado um ciclo final mais robusto. Os principais indicadores de análise utilizados foram: (i) aplicabilidade dos algoritmos na resolução de problemas reais; (ii) evolução no desempenho acadêmico em relação aos anos anteriores; (iii) engajamento dos grupos em cada etapa do ciclo PBL; (iv)

qualidade técnica dos artefatos computacionais desenvolvidos; e (v) originalidade, criatividade e relevância das soluções propostas.

Embora a análise não tenha utilizado critérios de classificação formal por níveis de aprendizagem (como níveis de proficiência), reconhece-se a importância de avançar, futuramente, para um modelo mais estruturado nesse sentido. A limitação no número de professores-tutores disponíveis e o caráter pioneiro da aplicação restringiram esse aprofundamento. No entanto, os dados analisados demonstraram potencial para o aprimoramento contínuo do modelo, que poderá ser replicado com melhorias em futuras intervenções.

Por fim, destaca-se que os resultados serão acompanhados de tabelas e gráficos explicativos no capítulo seguinte, permitindo a visualização clara das tendências observadas e a construção de uma leitura crítica sobre a eficácia da metodologia aplicada.

4. RESULTADOS

Este capítulo sintetiza os achados da pesquisa a partir de duas fontes: (i) a Revisão Sistemática da Literatura, que mostra como a ABP vem sendo aplicada no ensino de IA/ML, quais formas de avaliação são usadas e quais impactos são relatados em engajamento; e (ii) os resultados da intervenção realizada no ensino técnico, analisando a execução do ciclo ABP em quatro ciclos temáticos.

Em seguida, são apresentados os resultados de implementação (fidelidade das 7 etapas, produtos gerados e uso de ferramentas), os dados da culminância/projeto integrador (entregas e avaliação por banca), o desempenho dos grupos no Google Classroom (por grupo e por ciclo) e as percepções dos estudantes (autoavaliações, dificuldades, participação e confiança).

Por fim, o capítulo consolida potencialidades, limitações e recomendações para aprimorar e replicar a proposta, articulando evidências quantitativas e qualitativas.

4.1. Resultados da implementação da intervenção

Este tópico apresenta os resultados relacionados à implementação da intervenção pedagógica baseada em ABP, com ênfase na fidelidade de execução, na organização do percurso e nas evidências produzidas ao longo dos quatro ciclos temáticos. Diferentemente do capítulo metodológico, o foco aqui é demonstrar, a partir de registros e entregas, como o ciclo ABP se materializou na prática e como o desenho respondeu ao aumento progressivo de complexidade dos conteúdos.

4.1.1. Estrutura do ciclo ABP adotado (as 7 etapas adaptadas) e produtos gerados.

A intervenção foi operacionalizada por um ciclo ABP adaptado em sete etapas, repetido em quatro ciclos temáticos: Busca heurística, Classificação, Regressão e Agrupamento. A Tabela 3 sintetiza a execução desse ciclo por meio de uma pontuação atribuída a cada etapa, indicando o grau de evidência observado nas produções e nos registros dos grupos.

A avaliação apresentada na Tabela 3 foi realizada pelo pesquisador após a execução de cada ciclo, com base na análise dos registros de acompanhamento, das entregas realizadas pelos grupos, dos materiais disponibilizados nas plataformas digitais, das observações em sala de aula e dos produtos gerados em cada etapa do ciclo ABP. Assim, a pontuação não correspondeu a uma avaliação individual dos estudantes, mas a uma análise da implementação do processo pedagógico e do grau de evidência das etapas nas produções coletivas.

Para padronizar essa análise, adotou-se uma escala de três níveis, variando de 0 a 2 pontos por etapa. A pontuação final de cada ciclo correspondeu à soma das sete etapas, com valor máximo de 14 pontos. Dessa forma, a Tabela 3 deve ser compreendida como uma síntese avaliativa do desenvolvimento dos ciclos ABP, elaborada pelo pesquisador a partir da análise conjunta de registros, observações e produções dos grupos.

A escala utilizada na Tabela 3 varia de 0 a 2 pontos por etapa do ciclo ABP. O valor 0 representa ausência de evidências da etapa; o valor 1 indica evidência parcial, com registros ou entregas incompletas; e o valor 2 corresponde à evidência plena, quando há registros rastreáveis, produto ou entrega associada e socialização ou discussão da atividade. O total do ciclo resulta da soma das sete etapas, com pontuação máxima de 14 pontos.

Tabela 3 - Matriz de evidências do ciclo ABP (7 etapas)

Etapa ABP	Evidências-chave esperadas	Ciclo 1 – Busca heurística	Ciclo 2 – Classificação	Ciclo 3 – Regressão	Ciclo 4 – Agrupamento	Leitura analítica da etapa
 1. Contextualização + apresentação do problema	Enunciado, dataset e objetivos	2	2	2	2	Etapa plenamente consolidada em todos os ciclos, indicando padronização do desenho didático e clareza inicial dos problemas.
 2. Discussão inicial + hipóteses	Registro de hipóteses do grupo	1	1	1	1	Evidência parcial recorrente: houve discussão, porém com fragilidade de formalização e registro sistemático.
 3. Pesquisa / estudo orientado	Síntese, dúvidas e consulta a materiais	2	2	2	2	Etapa bem estruturada em todos os ciclos, demonstrando consistência no apoio teórico e na mediação docente.
 4. Planejamento da solução	Pipeline (variáveis, algoritmo, métricas)	2	1	2	1	Queda nos ciclos 2 e 4 indica maior complexidade conceitual na modelagem e seleção de métricas.
 5. Implementação / prototipagem	Código, fluxos e outputs	2	2	1	1	Redução progressiva evidencia aumento da dificuldade técnica, sobretudo nos modelos de regressão e agrupamento.
 6. Socialização + debate	Slides, discussão e devolutiva	2	2	1	1	Diminuição da evidência aponta menor aprofundamento reflexivo nos ciclos mais avançados.
 7. Avaliação + feedback	Formulários e síntese avaliativa	2	2	2	2	Avaliação manteve-se plenamente evidenciada, assegurando fechamento pedagógico em todos os ciclos.
Total do ciclo (máx. 14)	Soma das etapas	13	12	11	10	Tendência decrescente associada ao aumento da complexidade dos conteúdos de IA/ML.
IFC (%)	(Total ÷ 14) x 100	93%	86%	79%	71%	Redução gradual do índice indica menor fidelidade metodológica nos ciclos finais, sem ruptura do método.

Fonte: Elaborado pelo autor (2025).

De forma geral, observa-se a manutenção de um núcleo operacional estável ao longo de todos os ciclos. Três etapas permaneceram consistentemente registradas: (1) contextualização do problema, (3) pesquisa/estudo orientado e (7) avaliação/feedback. Esse comportamento indica que a intervenção preservou elementos estruturantes do método — problema explicitado,

estudo sustentado e fechamento formativo — assegurando continuidade pedagógica entre os ciclos.

Em contrapartida, identifica-se fragilidade recorrente na etapa 2 (discussão inicial e formulação de hipóteses). Embora essa etapa tenha ocorrido em sala, os registros associados foram limitados, reduzindo a rastreabilidade do raciocínio inicial dos grupos e dificultando a documentação das decisões tomadas no início do processo.

As maiores oscilações concentram-se nas etapas 4 a 6, diretamente relacionadas ao nível de exigência técnica dos conteúdos: planejamento da solução, implementação e socialização/debate. A etapa 4 alterna entre maior e menor evidência entre os ciclos, sugerindo que a estruturação do “pipeline” (planejar e documentar etapas, parâmetros e decisões) se torna mais desafiadora quando há maior demanda de modelagem e ajustes finos, especialmente em tarefas típicas de classificação e agrupamento. Já as etapas 5 e 6 apresentam redução de consistência nos ciclos finais, indicando que, à medida que a complexidade aumenta, torna-se mais difícil manter entregas e discussões com o mesmo grau de documentação, robustez e sistematização.

Essa tendência é sintetizada pelo Índice de Fidelidade do Ciclo (IFC), que decresce do primeiro ao último ciclo. Essa queda não caracteriza abandono do método, mas sinaliza um efeito de complexidade e de custo didático: conteúdos mais avançados demandam mais tempo, maior domínio técnico e maior capacidade de registro para sustentar plenamente etapas como planejamento detalhado, prototipagem e socialização. Em termos pedagógicos, o achado aponta para a necessidade de reforçar estratégias de formalização (registros mínimos por etapa) e mecanismos de acompanhamento (checkpoints e devolutivas intermediárias), especialmente nos ciclos finais.

4.1.2. Síntese dos quatro ciclos e do fluxo Planejamento–Execução–Avaliação


A implementação da intervenção foi organizada em um fluxo macro Planejamento–Execução–Avaliação, de modo a garantir previsibilidade do percurso, rastreabilidade das evidências e consistência entre os quatro ciclos ABP. Essa organização permitiu que o planejamento (definição de problemas, materiais e instrumentos), a execução (vivência dos ciclos e produção de artefatos) e a avaliação (verificação formativa e devolutivas) funcionassem como etapas integradas, com registros contínuos em ambiente digital e entregas progressivas ao longo do semestre.

No Planejamento, observou-se a centralização da gestão didática e da comunicação no Google Classroom, usado para estruturar trilhas, disponibilizar materiais, orientar prazos e organizar evidências. Em termos de implementação, isso se refletiu na padronização de abertura dos ciclos (problema, insumos e objetivos) e na manutenção de um repositório único de acompanhamento, reduzindo dispersão de materiais e favorecendo continuidade entre ciclos.

Na Execução, os quatro ciclos se diferenciaram principalmente pelo tipo de tarefa técnica e pelas ferramentas predominantes: o Ciclo 1 (Busca heurística) concentrou práticas em ambiente de programação (com uso específico de Google Colab, coerente com sua participação percentual menor), enquanto os ciclos de Classificação, Regressão e Agrupamento migraram para uma dinâmica de modelagem e experimentação em Orange Data Mining, evidenciando a ampliação de práticas de ciência de dados e análise de resultados ao longo do percurso. Essa transição é consistente com a progressão de complexidade: do desenvolvimento de algoritmos e raciocínio de busca para a construção, comparação e interpretação de modelos de ML.

Na Avaliação, o uso do Google Forms sustentou um padrão de verificação formativa por ciclo, associado a feedback e fechamento pedagógico, enquanto o Classroom continuou como registro e controle de entregas. A culminância, por sua vez, agregou ferramentas voltadas à produção e apresentação de projetos (por exemplo, Visual Studio Code e ferramentas de autoria), o que se alinha à etapa integradora e à entrega de artefatos finais.

Essa leitura é reforçada pelo consolidado de uso de ferramentas apresentado na Figura 5, extraída da análise sistematizada no Apêndice A – Distribuição do uso de ferramentas digitais por fase da intervenção. O gráfico evidencia uma arquitetura instrumental coerente com o fluxo Planejamento–Execução–Avaliação: Google Slides aparece como ferramenta mais frequente (23%), indicando centralidade de momentos de mediação, socialização e apresentações ao longo dos ciclos; Google Classroom (16%) confirma a função de organização, acompanhamento e registro; Orange Data Mining (15%) e Google Sheets (15%) sinalizam o predomínio de atividades práticas com dados (modelagem/experimentação e preparação/organização de bases e resultados); e Google Forms (13%) confirma a presença contínua de avaliação formativa e coleta de feedback. Ferramentas com menor participação — como Google Colab (5%) e Visual Studio Code (8%) — aparecem associadas a usos mais específicos, respectivamente concentrados no ciclo de busca/programação e no desenvolvimento de protótipos e entregas integradoras.

Gráfico 1 - Distribuição de ferramentas

Fonte: Elaboração própria (2025).

Em síntese, a distribuição de ferramentas não apenas descreve um “ecossistema digital”, mas evidencia um resultado de implementação: a intervenção foi executada com instrumentação consistente, na qual as ferramentas se alinham funcionalmente às fases do processo (organização e gestão no AVA, execução prática em ambientes de modelagem/programação e avaliação formativa por formulários), com variações explicadas pela natureza técnica de cada ciclo. O detalhamento operacional (prints do Classroom, roteiros completos, formulários na íntegra e bases/datasets) permanece reunido nos apêndices/anexos, enquanto esta seção apresenta a síntese e as evidências-chave articuladas ao fluxograma do processo.

4.1.3. Culminância e projeto integrador

A culminância ocorreu em 20/05 e consolidou a intervenção por meio do projeto integrador, funcionando como evidência final de implementação ao materializar produtos verificáveis (documento escrito, slides e protótipo) e submetê-los à validação de banca multidisciplinar. Para manter a objetividade do capítulo de resultados, os materiais completos de cada equipe (documentação, apresentações e registros detalhados do desenvolvimento) foram organizados em apêndices, enquanto nesta seção são apresentadas apenas sínteses,

evidências-chave e o espaço para inserção das imagens dos protótipos, seguido do consolidado quantitativo da avaliação docente.

No Projeto 1, Sistema online para visualização de horários escolares por turma e professor, o grupo partiu de um problema operacional recorrente nas escolas integrais: a consulta de horários em formatos tradicionais gerando confusão, erros de sala/disciplina e conflitos logísticos. A equipe buscou sustentar essa demanda com evidências, realizando levantamento de necessidades junto ao público-alvo antes da prototipagem. No instrumento aplicado, com 22 respostas, a percepção de desorientação durante trocas de aula apareceu como recorrente: somando “sempre”, “frequentemente” e “às vezes”, a maioria relatou vivenciar o problema em algum grau, indicando que a dor não era pontual e justificava a intervenção tecnológica. Em seguida, o grupo levantou preferências de funcionalidades e priorizou requisitos alinhados à usabilidade: “visualização clara e organizada” foi a opção mais assinalada (16/22; 72,7%), seguida por “notificações” (12/22; 54,5%), enquanto itens como integração com calendários e informações extracurriculares apareceram como demandas secundárias, úteis para evolução futura do sistema. Com isso, o desenvolvimento foi estruturado para entregar um protótipo objetivo, centrado em dois fluxos principais (consulta por turma e consulta por professor), buscando reduzir o custo cognitivo de localizar aulas e tornar o acesso mais imediato em comparação ao modelo anterior.

Figura 13 - Protótipo do Projeto 1: visualização de horários por turma e professor.

Horarios

sexta-feira, 18 de outubro de 2024 às 08:59

Horários por Turma

Selecione a Turma:

Turma A


Turma A


Horário	Segunda	Terça	Quarta	Quinta	Sexta
08:00 - 09:30	Matemática	Português	História	Geografia	Ciências
09:45 - 11:15	Português	História	Geografia	Ciências	Matemática
11:30 - 13:00	História	Geografia	Ciências	Matemática	Português
14:00 - 15:30	Geografia	Ciências	Matemática	Português	História
15:45 - 17:15	Ciências	Matemática	Português	História	Geografia

Fonte: Arquivo própria (2025).

O Projeto 2 (Análise climática inteligente com regressão) se destacou por mobilizar de forma direta o eixo de IA/ML trabalhado no componente, especialmente o ciclo de Regressão, ao integrar obtenção de dados, análise e visualização em um único produto. A equipe desenvolveu uma plataforma web para consulta de dados climáticos de diferentes cidades (temperatura, pressão atmosférica, umidade e vento), com integração a dados em tempo real por meio da API *OpenWeatherMap*. A partir dessa coleta, o sistema organiza as variáveis e gera uma visualização analítica baseada em regressão (por exemplo, pressão $\times$ temperatura), permitindo comparar padrões e tendências nos dados obtidos. Do ponto de vista de resultado da culminância, esse desenho é relevante porque não se limita à exibição de informações: ele explicita um procedimento típico de modelagem — aquisição de dados via API, preparação para análise e comunicação gráfica do resultado — reforçando a transferência de aprendizagem dos ciclos ABP para um artefato aplicado e comunicável.

Figura 14 - Protótipo do Projeto 2: interface de consulta climática





Fonte: Arquivo própria (2025).

No Projeto 3, Sistema de boletins escolares automatizado, a equipe partiu da observação de um problema recorrente no cotidiano escolar: o processo de consolidação e emissão de boletins tende a ser trabalhoso, repetitivo e sujeito a atrasos, exigindo esforço operacional significativo, especialmente dos professores e da secretaria, na organização de notas, conferência e geração do documento final. A partir desse diagnóstico, o grupo propôs automatizar o fluxo de emissão, estruturando uma solução capaz de centralizar o armazenamento das notas em banco de dados (incluindo MongoDB, conforme descrito) e gerar boletins de forma automática, com disponibilização para acesso e download em PDF. No levantamento apresentado (13 respostas), 92,3% indicaram recebimento do boletim em papel e apenas 7,7% relataram algum acesso por sistema; quanto à adequação do formato atual, 53,8% consideraram “adequado, mas precisa de melhorias” e 30,8% preferem outro formato, apontando espaço para inovação incremental. Ainda mais relevante para análise, a pergunta de melhorias gerou um ranking de funcionalidades desejadas (respostas múltiplas), com destaque para “um sistema online” (16 marcações), “sistema de notificações” (7), “download em PDF” (6) e “receber por e-mail” (5), o que reforça que a solução proposta conversa com demanda percebida. Assim, o projeto evidencia competência de desenvolvimento de sistemas (modelagem de dados, perfis de acesso, geração de relatórios/PDF) e, ao mesmo tempo, fundamenta a solução em dados do contexto.

Figura 15 - Protótipo do Projeto 3: tela de consulta/emissão e geração do boletim em PDF

Boletim Escolar

Turma 1A ▼

Buscar

Alany Cardoso Medeiros de Araujo

Disciplina	1º BIM	2º BIM	3º BIM	4º BIM	MÉDIA
Matemática	10.0	8.7	9.7	9.3	9.4
Biologia	10.0	8.1	9.5	9.5	9.3
Física	9.7	8.6	10.0	9.3	9.4
Química	8.7	9.0	8.0	9	8.7
História	9.5	9.0	10.0	10	9.6
Geografia	9.3	8	10	9.6	9.2
Sociologia	10	10	10	10	10
Filosofia	10	10	10	10	10
Língua Portuguesa	10	10	10	10	10
Educação Física	9	8.5	8	10	8.9
Língua Inglesa	10	10	10	10	10
Espanhol	9.5	8	10	10	9.4
Arte	9	9	9	9	9

[Baixar em PDF](#)

Fonte:

Arquivo própria (2025).

No Projeto 4 (Sistema de declaração automatizado), a proposta buscou endereçar três problemas explicitados na documentação do grupo: dificuldades/atrasos na emissão, burocracia e uso excessivo de papel, com implicações ambientais e operacionais. A solução concebida previa a emissão online com controle de acesso por atores escolares (secretaria, responsáveis e estudantes) e disponibilização digital (com envio por e-mail), reduzindo deslocamentos e etapas presenciais. Entretanto, apesar do registro documental da proposta e do escopo funcional, o projeto não foi apresentado na culminância porque a equipe se desfez no período final e não conseguiu concluir o protótipo e a apresentação, o que o excluiu da avaliação por banca e reduziu a taxa de fechamento do projeto integrador. Esse resultado precisa ser registrado como evidência de implementação: a culminância não foi apenas um momento “avaliativo”, mas um teste de sustentabilidade do trabalho em equipe até o final do percurso; a não conclusão sinaliza a necessidade de mecanismos de mitigação em futuras aplicações


Na culminância, os projetos foram avaliados por banca com quatro avaliadores (Exatas, Ciências da Natureza, Linguagens e Base Técnica), utilizando rubrica em escala 1–3 por critério e consolidação em pontuação total (0–57) e percentual, com classificação em três faixas:

Atingiu plenamente (80%–100%), Atingiu parcialmente (60%–79%) e Não atingiu (<60%). Os resultados agregados por projeto, por critério e por área de avaliador permitem interpretar, de forma objetiva, tanto a qualidade final dos produtos quanto as dimensões do processo que se mostraram mais consolidadas ou mais frágeis no encerramento da intervenção.

A análise das médias por projeto evidencia diferenças nítidas de desempenho e de conclusão. O Projeto 2 (Análise climática – Regressão) obteve a maior pontuação média (52 pontos; 91,2%), sendo classificado como “Atingiu plenamente”. Esse resultado é coerente com a natureza do projeto, que operacionalizou diretamente competências previstas na intervenção, ao articular coleta de dados, tratamento e análise por regressão, configurando um produto com evidência clara de transferência de aprendizagem do ciclo de Regressão para a culminância. Em contraste, o Projeto 1 (Horários escolares) e o Projeto 3 (Boletins automatizados) apresentaram desempenho semelhante, com 40 pontos (70,2%) e 40,25 pontos (70,6%), respectivamente, ambos classificados como “Atingiu parcialmente”. Esses valores sugerem que as equipes atingiram um patamar consistente de entrega e apresentação, mas com lacunas em dimensões específicas da rubrica (especialmente em critérios ligados a conceitos técnicos e validação sistemática, conforme detalhamento por critério).

Por fim, O Projeto 4, “Declaração automatizada”, obteve 0 ponto, correspondente a 0% de aproveitamento, e foi classificado como “Não atingiu”. Essa classificação decorreu da não conclusão do produto e da ausência de apresentação na culminância, o que impossibilitou a atribuição de pontuação nos critérios relacionados ao produto final, à análise dos resultados e à comunicação da solução. Portanto, o grupo foi mantido na análise da pesquisa, pois sua não conclusão também constitui evidência relevante sobre os limites da implementação da ABP, especialmente quanto à organização do trabalho coletivo, à gestão do tempo e ao cumprimento das entregas. No âmbito avaliativo da disciplina, a situação foi tratada conforme os procedimentos pedagógicos previstos pela escola e pelo professor responsável, podendo envolver atividade complementar dentro processo de recuperação, quando aplicável.

Gráfico 2 - Médias por projeto e classificação



Fonte: Arquivo própria (2025).

Ao observar a média por critério na Figura 16, considerando apenas os projetos apresentados, nota-se que os maiores percentuais estão relacionados à autonomia, execução do artefato e comunicação da solução. Destacam-se os critérios Protagonismo/autonomia coletiva (97,2%), Implementa corretamente o que foi proposto (91,7%), Reconhece limites e propõe melhorias (91,7%), Justifica as decisões técnicas tomadas (86,1%) e Apresenta a solução com clareza e organização (83,3%). Esses resultados indicam que os grupos demonstraram boa organização, autoria, capacidade de execução e clareza na apresentação dos produtos.


Os menores percentuais concentram-se em aspectos ligados ao uso técnico de IA/ML, à validação e à formulação inicial da solução. O critério Utiliza conceitos técnicos corretamente (IA/ML) apresentou o menor resultado, com 15,0%, seguido de Realiza testes, valida e corrige erros (63,9%), Formula hipóteses ou caminhos iniciais coerentes (66,7%), Identifica corretamente as informações relevantes do problema (69,4%) e Demonstra autonomia para buscar informações (69,4%). Esses dados indicam que, embora os estudantes tenham conseguido propor e apresentar soluções tecnológicas, ainda houve dificuldade para incorporar conceitos de IA/ML de forma consistente nos projetos finais.

Essa diferença pode ser explicada pelo próprio formato do projeto integrador. Nos ciclos de ABP, os estudantes seguiam um percurso mais orientado, com problema, algoritmo, ferramenta e etapas previamente definidos. Na culminância, precisaram identificar uma

demanda real, transformá-la em problema computacional, pensar nos dados necessários e avaliar se o uso de IA/ML era adequado. Essa mudança exigiu maior autonomia e tornou a aplicação de IA mais desafiadora.

Assim, os resultados indicam que a aplicação plena de IA em soluções reais ainda requer mais tempo de prática, aprofundamento conceitual e segurança técnica. A incorporação de IA foi incentivada, mas, em parte dos projetos, permaneceu como possibilidade de aprimoramento futuro. O projeto de análise climática com regressão foi o que apresentou aplicação mais direta de IA/ML, enquanto os demais se aproximaram de soluções de automação, organização de informações e apoio à gestão escolar.

Figura 16 - Média por critério (1–3) e % do critério



Fonte: Arquivo própria (2025).

Em síntese, os resultados da culminância mostram um quadro de entregas majoritariamente concluídas e avaliadas, com desempenho elevado no projeto que incorporou de modo mais direto técnicas de IA/ML (Projeto 2) e desempenho intermediário nos projetos de caráter administrativo-escolar (Projetos 1 e 3), além do registro de um projeto não concluído (Projeto 4), que deve ser tratado como evidência de limitação de implementação no encerramento. Nos critérios, o padrão sugere força em autonomia, implementação e comunicação, e fragilidade relativa em rigor conceitual de IA/ML e validação/testes, oferecendo um direcionamento claro para ajustes em futuras aplicações: ampliar mecanismos


de formalização de hipóteses, reforçar rotinas de validação (testes e métricas) e promover estratégias de suporte à consistência técnica nos ciclos finais.

4.2. Aplicação conceitual e desempenho

Nesta seção, analisam-se dois indicadores extraídos dos registros do Google Classroom ao longo da intervenção. O primeiro refere-se à participação consolidada dos grupos na plataforma, considerando aspectos como frequência de acesso, leitura dos materiais, acompanhamento das orientações, realização das atividades propostas e conclusão das entregas registradas no ambiente virtual. Esse indicador não deve ser interpretado exclusivamente como nota de desempenho conceitual, mas como uma medida de participação e engajamento dos grupos nas atividades mediadas pelo Google Classroom.

O segundo indicador refere-se à média de desempenho por ciclo de conteúdo, considerando as atividades teóricas e práticas vinculadas aos algoritmos trabalhados ao longo da intervenção: busca heurística, classificação, regressão e agrupamento. Nesse caso, o resultado expressa o desempenho geral dos estudantes em cada ciclo, contemplando a compreensão dos conceitos, a resolução das atividades, a aplicação dos algoritmos e a qualidade das entregas realizadas.

Gráfico 3 - Participação consolidada no Google Classroom por grupo




Fonte: Arquivo própria (2025).

Conforme o Gráfico 4, observa-se variação na participação dos sete grupos no Google Classroom. O Grupo 1 apresentou o maior percentual de participação, com 92,5%, seguido do Grupo 6, com 82,6%. Esses resultados indicam maior regularidade no acesso à plataforma, na leitura dos materiais, no acompanhamento das orientações e na conclusão das atividades propostas. Em um patamar intermediário, situam-se o Grupo 2, com 76,8%, e o Grupo 5, com 74,6%, demonstrando participação satisfatória no conjunto das atividades registradas.

Por outro lado, os menores percentuais foram observados no Grupo 4, com 62,3%, no Grupo 3, com 65,8%, e no Grupo 7, com 68,8%. Esses dados sugerem menor regularidade de participação na plataforma, o que pode estar relacionado a dificuldades de organização do grupo, frequência de acesso, cumprimento de prazos, leitura dos materiais ou conclusão das atividades propostas. Assim, o Gráfico 4 deve ser compreendido como um indicador de engajamento e acompanhamento das atividades no ambiente virtual, e não como uma medida isolada de aprendizagem conceitual ou domínio técnico dos conteúdos.

Do ponto de vista interpretativo, a variação entre os grupos reforça que a participação em metodologias ativas depende não apenas do interesse individual dos estudantes, mas também da capacidade de organização coletiva, da distribuição de responsabilidades, da frequência de acompanhamento das orientações e da continuidade das entregas. Nesse sentido, os dados indicam que os grupos com maior participação na plataforma tenderam a manter maior regularidade no percurso da intervenção, enquanto os grupos com menor participação demandaram maior mediação e acompanhamento docente.

Gráfico 4 - Média de desempenho por ciclo de conteúdo no Google Classroom

Fonte: Arquivo própria (2025).

O Gráfico 5 apresenta a média de desempenho por ciclo de conteúdo, considerando as atividades avaliativas relacionadas aos algoritmos trabalhados durante a intervenção. Diferentemente do Gráfico 4, que sintetiza a participação dos grupos na plataforma, este indicador está associado ao desempenho geral nas atividades teóricas e práticas de cada ciclo.

Observa-se um desempenho relativamente estável ao longo dos quatro ciclos: C1 – Buscas heurísticas, com média 7,08; C2 – Classificação, com média 7,68; C3 – Regressão, com média 7,53; e C4 – Agrupamento, com média 7,61. O menor valor ocorreu no Ciclo 1, o que pode ser interpretado como reflexo do período inicial de adaptação ao método, às rotinas do Google Classroom, à organização dos grupos e à lógica de resolução de problemas proposta pela ABP.

A partir do Ciclo 2, observa-se aumento e manutenção do desempenho em patamar superior, sugerindo maior familiaridade dos estudantes com a dinâmica da intervenção e com as atividades envolvendo algoritmos de Aprendizagem de Máquina. Esse comportamento indica que, após o ciclo inicial, os grupos passaram a compreender melhor a estrutura das tarefas, os procedimentos de entrega e a relação entre os conceitos estudados e sua aplicação prática.

Assim, a média por ciclo permite observar o desempenho geral da turma em relação aos conteúdos trabalhados, enquanto a participação por grupo permite compreender o grau de

envolvimento dos estudantes no ambiente virtual. A leitura conjunta dos dois indicadores sugere que a aprendizagem ao longo da intervenção foi influenciada tanto pela participação contínua nas atividades do Google Classroom quanto pela capacidade dos grupos de aplicar os conceitos e algoritmos propostos em cada ciclo.

4.3. Percepções dos estudantes

Para analisar as percepções dos estudantes sobre a intervenção baseada em ABP/PBL, foi aplicado, ao final dos ciclos, um instrumento de feedback e autoavaliação composto por itens organizados em três eixos: compreensão do problema e clareza do percurso, contribuição para a aprendizagem e relação com IA/ML, e condições de implementação e engajamento. As respostas foram registradas em escala do tipo Likert e, para fins de síntese, os níveis foram agregados em três categorias: concordância (concordo + concordo totalmente), neutro (nem concordo nem discordo) e discordância (discordo + discordo totalmente). O Quadro/Tabela X apresenta a distribuição das respostas por item, permitindo identificar, de forma comparativa, os aspectos mais consolidados na experiência dos estudantes e aqueles que concentraram maior divergência, subsidiando a interpretação dos fatores pedagógicos e operacionais associados à implementação.

Tabela 4 - Percepções dos estudantes sobre a intervenção ABP/PBL

Item	Foco avaliado/Pergunta	Concordância (C+CT)	Neutro	Discordância (DT+D)
Q1	Compreensão do problema	27 (90,0%)	1 (3,3%)	2 (6,7%)
Q2	Clareza das etapas ABP/PBL	27 (90,0%)	2 (6,7%)	1 (3,3%)
Q3	Contribuição das atividades para aprender	25 (83,3%)	0 (0,0%)	5 (16,7%)
Q4	Relação IA/ML com o projeto	23 (76,7%)	5 (16,7%)	2 (6,7%)
Q5	Conexão com situações reais do contexto	30 (100,0%)	0 (0,0%)	0 (0,0%)

Q6	Contribuição do trabalho em grupo	16 (53,3%)	4 (13,3%)	10 (33,3%)
Q7	Engajamento com ABP/PBL	17 (56,7%)	10 (33,3%)	3 (10,0%)
Q8	Tempo e recursos suficientes	11 (36,7%)	1 (3,3%)	18 (60,0%)
Q9	Participaria novamente nesse formato	22 (73,3%)	0 (0,0%)	8 (26,7%)

Fonte: Arquivo própria (2025).

Os resultados indicam alta aceitação do método e do desenho didático: os estudantes afirmaram compreender o problema e as etapas da ABP/PBL (Q1 e Q2 com 90% de concordância) e reconheceram contribuição das atividades para sua aprendizagem (Q3 com 83,3%). Destaca-se, sobretudo, a percepção de autenticidade e contextualização, uma vez que 100% concordaram que o projeto se conectou com situações reais do seu contexto (Q5), evidenciando aderência do percurso formativo ao propósito de aproximar teoria e prática.

Quanto ao domínio conceitual associado à IA/ML, observa-se concordância majoritária (Q4 com 76,7%), porém com parcela neutra relevante (16,7%), o que sinaliza que parte dos estudantes percebe a relação entre conceitos e projeto, mas ainda em consolidação — aspecto coerente com intervenções que exigem articulação entre modelagem, dados e implementação.


Em contraste, emergem tensões operacionais: o item Q8 apresenta predominância de discordância (60%), sugerindo que tempo e recursos foram percebidos como insuficientes para o nível de exigência das entregas e/ou para o aprofundamento desejado. Além disso, os itens de colaboração e engajamento (Q6 e Q7) aparecem com concordância moderada (53,3% e 56,7%), indicando heterogeneidade na experiência de trabalho em equipe e na vivência do método, com potencial impacto na distribuição de participação e na autorregulação dos grupos.

Apesar desses desafios, a intenção de continuidade é positiva: 73,3% afirmam que participariam novamente (Q9), o que reforça que as dificuldades relatadas parecem estar mais relacionadas a condições de implementação (tempo/recursos/organização) do que à rejeição do método em si.

4.3.1. Distribuição das percepções

O Gráfico 3 sintetiza a distribuição das percepções dos estudantes em três dimensões avaliadas por escala ordinal de cinco níveis (Nível 1 a Nível 5): (i) dificuldade em analisar dados com Orange; (ii) nível de participação semestral; e (iii) confiança em implementar soluções em Python. Para garantir a leitura adequada do gráfico, ressalta-se que a direção semântica da escala varia conforme a dimensão: na dimensão dificuldade, níveis mais altos indicam maior dificuldade; já nas dimensões participação e confiança, níveis mais altos indicam maior intensidade positiva (maior participação e maior confiança).

Gráfico 5 - Distribuição do feedback dos estudantes por dimensão



Fonte: Arquivo própria (2025).

Na dimensão dificuldade em analisar dados com Orange, observa-se concentração nos níveis intermediários e baixos: 40,0% dos estudantes situaram-se no Nível 2 e 40,0% no Nível 3, totalizando 80,0% de respostas entre “pouca” e “dificuldade moderada”. Além disso, 14,3% registraram Nível 4 (maior dificuldade) e 5,7% situaram-se no Nível 1 (menor dificuldade), sem ocorrência no Nível 5. Esse padrão indica que, embora a maioria consiga utilizar a ferramenta no desenvolvimento das atividades, parte do grupo ainda demanda suporte pedagógico para avançar em autonomia, especialmente nas etapas de preparação, exploração e interpretação de dados.

Em relação ao nível de participação semestral, predomina o Nível 3 (45,7%), seguido do Nível 2 (25,7%). As respostas nos níveis mais altos somam 28,6% (Nível 4 = 20,0%; Nível 5 = 8,6%), enquanto o Nível 1 não apresentou registros (0%). A concentração no nível intermediário sugere participação consistente, porém não plenamente homogênea, o que é compatível com atividades em grupo, nas quais a distribuição de tarefas e o protagonismo tendem a variar entre os estudantes ao longo dos ciclos.

Quanto à confiança em implementar soluções em Python, verifica-se predominância no Nível 3 (48,6%), com parcela expressiva no Nível 2 (34,3%) e 11,4% no Nível 1. No extremo superior, registra-se 5,7% no Nível 5 e ausência de respostas no Nível 4. Esses achados sugerem que a autopercepção de competência para implementação em Python permanece majoritariamente em patamar intermediário, com presença de estudantes que ainda se sentem pouco seguros para codificar soluções de forma autônoma. Em termos pedagógicos, esse resultado reforça a importância de estratégias de andamiaje (exemplos guiados, roteiros de implementação, checkpoints e feedback incremental), especialmente para apoiar a transição entre modelagem/experimentos e codificação.

De forma integrada, o Gráfico 3 revela um cenário no qual as percepções se concentram no nível intermediário (Nível 3) nas três dimensões, indicando que os estudantes participaram de modo relevante e avançaram em repertório técnico, porém com limitações de autonomia plena, sobretudo na implementação em Python e em aspectos do uso de ferramentas de análise de dados. Esses resultados dialogam com o Objetivo específico 3 ao evidenciar que o engajamento e a relação com a prática ocorreram, mas acompanhados de desafios operacionais e formativos típicos de processos de aprendizagem ativa, nos quais o estudante assume maior responsabilidade pela construção de soluções e pelo desenvolvimento progressivo de competências técnicas.

4.3.2. Categorias emergentes

As respostas abertas do formulário (Q10 e Q11) foram analisadas por análise de conteúdo e agrupadas em seis categorias (Quadro X), organizadas em evidências positivas e evidências construtivas. Em síntese, os estudantes destacaram que o projeto favoreceu aprendizagem aplicada, com maior sentido prático para programação e IA, ao “aprender fazendo” e percebendo utilidade real das atividades. Também emergiram percepções de avanço na compreensão de IA/algoritmos, incluindo a ideia de que a IA é “possível” e depende de

prática, teste e tomada de decisão, indicando redução de barreiras iniciais e maior familiaridade com o tema.

No campo da programação, os relatos apontam melhoria em lógica, organização do código e documentação, além da valorização do ciclo completo problema → solução → teste, no qual o erro e a depuração aparecem como parte do processo de aprendizagem. Como pontos de melhoria, os estudantes enfatizaram a necessidade de mais tempo e cronograma mais claro e visual, além de feedback/checkpoints mais frequentes para orientar o andamento das entregas. Também surgiram sugestões relativas ao trabalho em grupo, como redução do tamanho dos grupos e melhor divisão de tarefas para ampliar a participação.

Por fim, a categoria de organização e suporte mostrou avaliação positiva do Google Classroom como apoio para materiais e entregas, ao mesmo tempo em que foram apontadas limitações de infraestrutura (internet e laboratório). Em conjunto, o quadro indica uma experiência percebida como relevante e engajadora, com recomendações objetivas de ajuste operacional para fortalecer as próximas edições.

Tabela 5 - Feedback discente sobre aprendizagem, participação e organização do projeto

Categoria	Evidências positivas (o que funcionou)	Evidências construtivas (o que melhorar)	Excertos representativos (estudantes)
1) Aprendizagem aplicada e problemas reais	Relataram que aprenderam “fazendo algo útil”, com sentido prático.	Pedem mais tempo para aprofundar o projeto e melhorar entregas.	“Aprendi mais sobre programação em algo real.” “Foi o primeiro projeto que me fez sentir que programei algo útil.” “Ter mais tempo pra desenvolver o projeto.”
2) Compreensão de IA/algoritmos e tomada de decisão	Perceberam IA como algo “possível”, ligado à decisão, teste e prática.	Solicitaram reforço de conceitos difíceis antes da prática e mais exemplos guiados.	“Agora entendo como os modelos de IA tomam decisões.” “IA não é bicho de sete cabeças.” “Explicar de novo os conceitos mais difíceis.”

3) Desenvolvimento em programação (lógica, código e organização)	Indicaram melhora na lógica, no cuidado com o código e na documentação.	Pediram mais acompanhamento na parte do código e momentos de teste.	“Me ajudou a pensar mais antes de escrever o código.” “Aprendi a comentar o código e documentar.” “Ter momentos só pra testar o código.”
4) Aprender com erro e ciclo completo (problema→solução→teste)	Valorizaram a experiência de errar, corrigir e validar resultados.	Pediram feedback após entregas e checkpoints para não “se perder”.	“Quando dá erro, eu entendi melhor.” “Problema → solução → teste.” “Checkpoints semanais pra gente não se perder.”
5) Trabalho em grupo e participação	Alguns relataram colaboração e divisão de código como aprendizagem.	Sugeriram grupos menores e melhor divisão de tarefas para evitar sobrecarga.	“Dividir o código entre nós ajudou.” “Reduzir o tamanho dos grupos.” “Ajudar mais na divisão de tarefas.”
6) Organização, cronograma e infraestrutura	O Google Classroom aparece como suporte de organização e acesso a materiais/entregas.	Solicitaram cronograma mais visual, prazos antecipados e melhorias de internet/laboratório.	“O classroom facilitou demais os estudos.” “Deixar o cronograma mais simples e visual.” “Melhorar a internet e os computadores.”

Fonte: Arquivo própria (2025).

4.4. Potencialidades, limitações e recomendações

Esta seção sintetiza os principais achados do capítulo, com foco em identificar potencialidades e limitações da intervenção baseada em ABP/PBL no ensino de IA e, a partir disso, apontar recomendações para aprimoramento e replicação em ofertas futuras. A análise articula os resultados de desempenho (avaliativos) e as percepções dos estudantes (quantitativas e qualitativas), destacando fatores pedagógicos, operacionais e contextuais.

Um primeiro aspecto de destaque foi a aproximação efetiva dos estudantes com a Inteligência Artificial em um formato de vivência que dificilmente ocorreria em um plano de aula tradicional. Por se tratar de um projeto estruturado dentro do componente de IA, os estudantes tiveram a oportunidade de experimentar uma aprendizagem mais consistente e prolongada, com continuidade entre teoria, prática e produção. Isso contribuiu para que a IA deixasse de ser percebida apenas como conteúdo abstrato e passasse a ser vivenciada como prática: modelar, testar, revisar e justificar decisões. Esse tipo de experiência tende a ser

decisivo no ensino técnico, pois permite ao estudante enxergar o componente como parte de um repertório profissional.

A intervenção também se mostrou potente por ter promovido a aprendizagem aplicada, com foco em situações reais e soluções possíveis, reduzindo a lógica de “fazer por nota” e aproximando o processo de um cenário autêntico de desenvolvimento. Os estudantes indicaram que compreenderam melhor a utilidade da programação e dos algoritmos quando perceberam que estavam construindo algo que poderia ser uma solução concreta. Essa característica é central no uso da ABP/PBL, pois desloca a aprendizagem do domínio meramente reprodutivo para um domínio mais significativo e funcional: entender, propor, testar e melhorar.

Outro ponto relevante foi a organização do percurso e o uso de tecnologias educacionais como suporte do processo. O projeto operou com uma estrutura que facilitou o acompanhamento das etapas e das entregas, com destaque para o *Google Classroom* como ambiente de apoio (materiais, registros, prazos e organização das atividades). Esse arranjo não apenas favoreceu o fluxo de trabalho como também contribuiu para que os estudantes tivessem referência do que precisava ser feito e do que estava em andamento, o que é crucial quando se trabalha com projetos mais longos.

Além disso, a dinâmica do trabalho em grupo apresentou potencialidades importantes. Embora não isenta de desafios, a colaboração permitiu que os estudantes experimentassem divisão de tarefas, negociação de soluções, socialização de decisões e produção coletiva — elementos alinhados à prática profissional na área de computação. Em um componente como IA, em que a aprendizagem envolve múltiplos passos (dados, implementação, testes e interpretação), a colaboração tende a ampliar repertórios e favorecer a construção conjunta.

Por fim, destaca-se o valor do projeto como contribuição para um campo ainda pouco explorado no contexto do ensino técnico público, especialmente no recorte local. A experiência sinaliza um caminho possível para fortalecer a educação computacional no ensino médio técnico, oferecendo aos estudantes um primeiro contato mais sólido, capaz de despertar interesse e reduzir a possibilidade de desestímulo. Nesse sentido, o projeto não apenas ensinou conteúdos, mas também favoreceu uma experiência formativa que pode impactar expectativas, identidade acadêmica e trajetória profissional dos estudantes.

6.6.2 Limitações e pontos que exigem ajustes

A principal limitação identificada foi o tempo didático e a necessidade recorrente de readaptação do planejamento. No contexto do ensino integral técnico, mudanças institucionais

e demandas escolares não previstas interferem diretamente no cronograma. Por ser uma intervenção semestral, houve necessidade de ajustes ao longo do percurso, o que é esperado em projetos complexos, mas também gerou impactos na execução e na profundidade de algumas etapas. Em intervenções desse tipo, o tempo é um recurso crítico: não apenas para desenvolver e entregar, mas para testar, depurar, refletir e consolidar aprendizagens.

Uma segunda limitação esteve relacionada à familiaridade inicial dos estudantes com a metodologia. Como a experiência foi, para muitos, o primeiro contato com um modelo estruturado de ABP/PBL ao longo de um componente inteiro, houve um período de adaptação. Apesar do interesse e da boa receptividade posterior, parte dos estudantes demorou a compreender plenamente a dinâmica, o papel do protagonismo e as expectativas de produção, o que exigiu “quebra de paradigmas” frente ao modelo tradicional de aula. Isso ajuda a explicar por que o engajamento se consolidou com mais força na metade final do processo, quando os estudantes passaram a entender melhor as regras do jogo pedagógico.

Também se destacam limitações ligadas à infraestrutura (computadores, internet e condições do laboratório). Em atividades de programação, análise de dados e uso de ferramentas digitais, instabilidades e insuficiências tecnológicas não são apenas desconfortos: elas afetam diretamente a continuidade do trabalho, o ritmo das equipes e a possibilidade de experimentação. Esse fator torna-se ainda mais sensível em projetos, nos quais cada interrupção compromete etapas sequenciais.

Outra limitação relevante diz respeito ao nível de conhecimento prévio e às dificuldades de base, especialmente em lógica e matemática. Mesmo com estudantes que já tiveram contato com programação, observaram-se casos em que foi necessário retomar conceitos várias vezes. Essa necessidade de revisões sucessivas, embora pedagógica e esperada em certa medida, impacta o tempo destinado à execução prática e reduz a velocidade de avanço do projeto. Em um componente como IA, no qual conceitos matemáticos e de raciocínio lógico são estruturantes, lacunas de base tendem a se manifestar com mais intensidade.

Por fim, a própria natureza do projeto ampliou a carga de trabalho do professor, uma vez que, além de ensinar, o docente assume funções simultâneas de planejamento, mediação, acompanhamento de grupos, monitoramento, avaliação e feedback. Quando a intervenção ocorre durante um semestre inteiro, e não como um evento curto, o custo de gestão pedagógica aumenta e pode limitar a frequência do acompanhamento individualizado, apesar de seu alto valor formativo.

5. CONSIDERAÇÕES FINAIS

Esta dissertação teve como objetivo investigar a aplicação da Aprendizagem Baseada em Problemas (ABP) no ensino de Inteligência Artificial e Machine Learning em um curso técnico, analisando seus efeitos no desempenho e no engajamento discente. A intervenção, implementada ao longo de um semestre com 33 estudantes, estruturou-se em ciclos de aprendizagem orientados por problemas contextualizados, com produção de artefatos e avaliação combinando dimensões teóricas e práticas.

Os resultados sustentam que a ABP, em formato adaptado ao ensino técnico, favorece aprendizagem aplicada e aproximação entre teoria e prática. Destacam-se a elevada compreensão do problema e das etapas do percurso (90% de concordância) e, principalmente, a percepção de conexão com situações reais (100%), além da intenção de continuidade por parte de parcela expressiva da turma (73,3%). Tais achados reforçam o potencial da ABP para conteúdos complexos, ao induzir protagonismo, colaboração e tomada de decisão baseada em evidências produzidas pelos próprios estudantes.

Por outro lado, a experiência evidenciou limitações típicas do contexto escolar: restrições de tempo didático e recursos, infraestrutura tecnológica instável, heterogeneidade de conhecimentos prévios e aumento da carga de planejamento, acompanhamento e feedback do professor. Assim, recomenda-se, para futuras ofertas: (i) cronograma mais visual e com checkpoints de acompanhamento; (ii) estratégias de nivelamento para lacunas de base; (iii) reforço de infraestrutura e organização de laboratório; e (iv) instrumentos de avaliação que capturem processo e produto, reduzindo assimetrias no trabalho em grupo.

Como trabalhos futuros, sugere-se ampliar o estudo para outras turmas e escolas, com desenho comparativo mais robusto e indicadores longitudinais, bem como aprofundar a análise da qualidade técnica dos artefatos e das competências desenvolvidas ao longo dos ciclos, de modo a consolidar evidências para escalabilidade e institucionalização da proposta.

REFERÊNCIAS BIBLIOGRÁFICAS

BARR, V.; STEPHENSON, C. **Bringing computational thinking to K-12: What is Involved and what is the role of the computer science education community?** ACM inroads, v. 2, n. 1, p. 48–54, 2011.

BARROWS, H. S. **A taxonomy of problem-based learning methods.** Medical education, v. 20, n. 6, p. 481–486, 1986.

BARROWS, H. S.; ROBYN M. TAMBLYN, B. **Problem-based learning: An approach to medical education.** [s.l.] Springer Publishing Company, 1980.

BEHREND, Danielle Monteiro; DA SILVA COUSIN, Cláudia; DO CARMO GALIAZZI, Maria. **Base nacional comum curricular: o que se mostra de referência à educação ambiental?** Ambiente & Educação: Revista de Educação Ambiental, v. 23, n. 2, p. 74-89, 2018. Disponível em: <<https://periodicos.furg.br/ambeduc/article/view/8425>>. Acesso em: 26 jun. 2024.

BOUD, D.; FELETTI, G. **The challenge of problem-based learning.** Londres, England: Routledge, 2013.

CHEN, L.; CHEN, P.; LIN, Z. **Artificial intelligence in education: A review.** IEEE access: practical innovations, open solutions, v. 8, p. 75264–75278, 2020.

CHRIS, Beaumont; SACKVILLE, Andrew; CHEW SWEE, Cheng. **Identifying Good Practice in the use of PBL to teach computing.** Innovation in Teaching and Learning in Information and Computer Sciences , v. 3, n. 1, p. 1-19, 2004.

DE BARROS, Vitor Augusto Menten; PAIVA, Henrique Mohallem; HAYASHI, Victor Takashi. **Using pbl and agile to teach artificial intelligence to undergraduate computing students.** IEEE Access, 2023.

DELISLE, R.; ASSOCIATION FOR SUPERVISION AND CURRICULUM DEVELOPMENT. **How to use problem-based learning in the classroom.** [s.l.] ASCD, 1997.

DEMŠAR, J. et al. **Orange: data mining toolbox in python.** Journal of machine learning research: JMLR, v. 14, n. 1, p. 2349–2353, 2013.

DIRETRIZES OPERACIONAIS 2024. Disponível em: <<https://paraiba.pb.gov.br/diretas/secretaria-da-educacao/consultas/diretrizes-operacionais-2024/view>>. Acesso em: 23 jun. 2024.

DWIVEDI, Y. K. et al. **Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy.** International journal of information management, v. 57, n. 101994, p. 101994, 2021.

Ensino Integral Técnico na Paraíba. Disponível em: <<https://paraiba.pb.gov.br/noticias/governo-lanca-coletanea-sobre-o-ensino-integral-tecnico-na-paraiba>>. Acesso em: 23 jun. 2024.

FILHO, O. G. **Inteligência Artificial e Aprendizagem de Máquina: Aspectos Teóricos e Aplicações**. 1. ed. [s.l.] Blucher, 2023.

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, n. 5, p. 5733–5778, 2021.

GROVER, S.; PEA, R. **Computational thinking in K–12: A review of the state of the field**. Educational researcher (Washington, D.C.: 1972), v. 42, n. 1, p. 38–43, 2013.

HMELO-SILVER, C. E. **Problem-based learning: What and how do students learn?** Educational psychology review, v. 16, n. 3, p. 235–266, 2004.

KAY, J. **AI and Education: Grand Challenges**. IEEE intelligent systems, v. 27, n. 5, p. 66–69, Sep-Oct 2012.

KEK, M. Y. C. A.; HUIJSER, H. **The power of problem-based learning in developing critical thinking skills: preparing students for tomorrow's digital futures in today's classrooms**. Higher education research & development, v. 30, n. 3, p. 329–341, 2011.

LOYENS, S. M. M.; MAGDA, J.; RIKERS, R. M. J. P. **Self-directed learning in problem-based learning and its relationships with self-regulated learning**. Educational psychology review, v. 20, n. 4, p. 411–427, 2008.

MCCARTHY, J. **A proposal for the Dartmouth summer research project on artificial intelligence**. Disponível em: <<http://jmc.stanford.edu/articles/dartmouth.html>>. Acesso em: 3 ago. 2024.

NILSSON, N. J. **Principles of Artificial Intelligence**. [s.l.] Springer Berlin Heidelberg, 1982.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence : a modern approach**. Upper Saddle River, NJ, USA: Pearson, 2016.

TORRES-CARRION, P. V. et al. **Methodology for systematic literature review applied to engineering and education**. 2018 IEEE Global Engineering Education Conference (EDUCON). Anais...IEEE, 2018.

WALKER, A. E. et al. SAVERY, John R. **Overview of problem-based learning: Definitions and distinctions**. Essential readings in problem-based learning: Exploring and extending the legacy of Howard S. Barrows, v. 9, n. 2, p. 5-15, 2015. Indiana, PA, USA: Purdue University Press, 15 janeiro 2015.

WALKER, A. E. et al. WALKER, Andrew; LEARY, Heather. **A problem based learning meta analysis: Differences across problem types, implementation types, disciplines, and assessment levels**. Interdisciplinary journal of problem-based learning, v. 3, n. 1, p. 6, 2009. Indiana, PA, USA: Purdue University Press, 2015.

WING, J. M. **Computational thinking**. Communications of the ACM, v. 49, n. 3, p. 33–35, 2006.

SAVERY, John R. **Visão geral da aprendizagem baseada em problemas: Definições e distinções**. Leituras essenciais em aprendizagem baseada em problemas: Explorando e estendendo o legado de Howard S. Barrows , v. 9, n. 2, p. 5-15, 2015.

YIM, I. H. Y.; SU, J. Artificial intelligence (AI) learning tools in K-12 education: A scoping review. *Journal of computers in education*, 2024.

SU, Jiahong; NG, Davy Tsz Kit; CHU, Samuel Kai Wah. **Alfabetização em inteligência artificial (IA) na educação infantil: os desafios e as oportunidades**. *Computadores e educação: inteligência artificial* , v. 4, p. 100124, 2023.

MITCHELL, Tom M. **O aprendizado de máquina realmente funciona?**. *Revista AI* , v. 18, n. 3, p. 11-11, 1997.

SUTTON, Richard S. **Aprendizagem por reforço: Uma introdução**. A Bradford Book , 2018.

HAENLEIN, Michael; KAPLAN, Andreas. **Uma breve história da inteligência artificial: Sobre o passado, presente e futuro da inteligência artificial**. *California management review* , v. 61, n. 4, p. 5-14, 2019.

TOURETZKY, David et al. **Envisioning AI for K-12: O que toda criança deve saber sobre IA?**. Em: *Anais da conferência AAAI sobre inteligência artificial* . 2019. p. 9795-9799.

LUCKIN, Rose; HOLMES, Wayne. **Inteligência liberada: Um argumento para IA na educação**. 2016.

KNOX, Jeremy. Inteligência artificial e educação na China. **Aprendizagem, Mídia e Tecnologia** , v. 45, n. 3, p. 298-311, 2020.

NGUYEN, Andy; GARDNER, Lesley A.; SHERIDAN, Don. **Uma taxonomia multicamadas de aplicações de análise de aprendizagem**. 2017.

SHEN, Victor RL et al. **Uma abordagem especial para ensinar inteligência artificial**. *International Journal of Engineering Education* , v. 26, n. 6, p. 1414, 2010.

ALLEN, Becky; MCGOUGH, Andrew Stephen; DEVLIN, Marie. **Rumo a uma estrutura para o ensino de inteligência artificial para um público de ensino superior**. *ACM Transactions on Computing Education (TOCE)* , v. 22, n. 2, p. 1-29, 2021.

BARROS, et al. Aplicação de aprendizado supervisionado em diagnóstico médico utilizando Random Forest, KNN e SVM: um estudo prático com estudantes. *Revista Brasileira de Educação em Computação*, 2023.

GAN, B.; OUH, ... Problem-based learning applied to the artificial intelligence course. *Computer Applications in Engineering Education*, v.24, n.3, p.388-399, 2021.

HAENLEIN, M.; KAPLAN, A. A brief history of artificial intelligence. *Business Horizons*, 2019.

MCCARTHY, J. et al. A proposal for the Dartmouth Summer Research Project on Artificial Intelligence. 1955.

MITCHELL, T. *Machine Learning*. McGraw-Hill, 1997.

NILSSON, N. *Artificial Intelligence: A New Synthesis*. Morgan Kaufmann, 1982.

OWOC, M. L. et al. Artificial Intelligence Technologies in Education: Benefits, Challenges and Strategies of Implementation. *arXiv*, 2021.

PORAYSKA-POMSTA, K. et al. The Ethics of AI in Education. *arXiv*, 2024.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. Pearson, 2016.

WOOD, D. *Problem-Based Learning*. BMJ, 2003 (atualizado 2024).

ZHENG, C. et al. Charting the Future of AI in Project-Based Learning: A Co-Design Exploration with Students. *arXiv*, 2024.

CRESWELL, John W. **Investigação qualitativa e projeto de pesquisa: escolhendo entre cinco abordagens**. 3. ed. Porto Alegre: Penso, 2014.

FLICK, Uwe. **Introdução à pesquisa qualitativa**. 5. ed. Porto Alegre: Penso, 2018.

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. 7. ed. São Paulo: Atlas, 2019.

MORAN, José Manuel; MASETTO, Marcos T.; BEHRENS, Marilda Aparecida. **Novas tecnologias e mediação pedagógica**. 21. ed. Campinas: Papirus, 2013.

THIOLLENT, Michel. **Metodologia da pesquisa-ação**. 18. ed. São Paulo: Cortez, 2011.

APÊNDICES

APÊNDICE A - MATRIZ CURRICULAR DO CURSO TÉCNICO EM INFORMÁTICA INTEGRADO AO ENSINO MÉDIO

Este anexo apresenta a matriz curricular do Curso Técnico em Informática integrado ao Ensino Médio, organizada por semestre (1º ao 6º), contemplando os componentes da Formação Geral, Parte Diversificada e do Itinerário de Educação Profissional. A distribuição abaixo explicita a carga horária semanal por semestre e a carga horária total acumulada ao longo do curso.

QUADRO – ITINERÁRIO DE EDUCAÇÃO PROFISSIONAL

		COMPONENTES CURRICULARES	1ª Sem	2ª Sem	3ªSem	4ªSem	5ªSem	6ªSem	1ª Sem	2ª Sem	3ªSem	4ªSem	5ªSem	6ªSem
Itinerário de Educação Profissional		Eletiva	2	2	2	2	2		33	33	33	33	33	
		Total Eletiva	2	2	2	2	2		33	33	33	33	33	
		Projeto de vida	2	2	2	2	2	2	33	33	33	33	33	33
		Total PV	2	2	2	2	2	2	33	33	33	33	33	33
	Formação Básica para o Trabalho	COMPONENTES CURRICULARES	1ª Sem	2ª Sem	3ªSem	4ªSem	5ªSem	6ªSem	1ª Sem	2ª Sem	3ªSem	4ªSem	5ªSem	6ªSem
		Educação Tecnológica e Midiática	2	2	2	2	2		33	33	33	33	33	0
		Intervenção Comunitária		2					0	33	0	0	0	0
		Inovação Social e Científica				2			0	0	0	33	0	0
		Empresa Pedagógica					2		0	0	0	0	33	0
		Higiene e Segurança do Trabalho	2						33	0	0	0	0	0
		Total FBT	4	4	2	4	4	0	67	67	33	67	67	0
	Formação Profissional Específica	Introdução a Lógica de Programação	2						33	0	0	0	0	0
		Arquitetura de Hardware	2						33	0	0	0	0	0
		Sistemas Operacionais	2						33	0	0	0	0	0
		Linguagem de Programação		2					0	33	0	0	0	0
		Redes e Conectividade		2					0	33	0	0	0	0
		Manutenção de Computadores		2					0	33	0	0	0	0
		Desenvolvimento Web			2				0	0	33	0	0	0
		Banco de Dados I			2				0	0	33	0	0	0
		Estrutura de Dados			2				0	0	33	0	0	0
		Planejamento e Projeto de Redes de Computadores			2				0	0	33	0	0	0
		Banco de Dados II				2			0	0	0	33	0	0
		Engenharia de Software				2			0	0	0	33	0	0
		Computação Gráfica				2			0	0	0	33	0	0
		Segurança da Informação					2		0	0	0	0	33	0
		Programação Orientada a Objetos					2		0	0	0	0	33	0
		Inteligência Artificial					2		0	0	0	0	33	0
		Execução de Projetos					2		0	0	0	0	33	0
		Projeto Integrador					2		0	0	0	0	33	0
		Total FPE	6	6	8	6	10	0	100	100	133	100	167	0

Fonte: Secretaria de Estado da Educação da Paraíba (SEE-PB). Matriz curricular do Curso Técnico em Informática

APÊNDICE B – RELATÓRIO DE CONSULTAS DE AGREGAÇÃO MONGODB

RELATÓRIO COM AGREGAÇÃO MONGODB

Etapa 1: Contar o Número Total de Artigos

Objetivo: Contar o número total de artigos armazenados na coleção `collection_Artigos`.

```
[
  {
    "$count": "total_articles"
  }
]
```

Explicação: Esta etapa agrega todos os documentos na coleção e retorna o número total de artigos com o campo `total_articles`.

Etapa 2: Filtrar Artigos a Partir de 2019

Objetivo: Filtrar todos os artigos cuja data de publicação é igual ou superior a 2019.

```
[
  {
    "$match": {
      "publicationDate": { "$gte": ISODate("2019-01-01T00:00:00Z") }
    },
    {
      "$count": "total_articles_after_2019"
    }
]
```

Explicação: O primeiro estágio usa `$match` para filtrar artigos cuja data de publicação (`publicationDate`) seja maior ou igual a 1º de janeiro de 2019. O segundo estágio conta o número de artigos que atendem a esse critério.

Etapa 3: Seleção de Artigos Mais Relevantes para a Pesquisa

Objetivo: Selecionar artigos que correspondam aos três conjuntos de palavras-chave principais da pesquisa:

1. Problem-Based Learning (PBL), Active Learning
2. Artificial Intelligence (AI), Machine Learning
3. Education, Pedagogy, Teaching

```
[
  {
    "$match": {
      "$and": [
        {
          "$or": [
            { "abstract": { "$regex": "(Problem-Based Learning|PBL|Active Learning)", "$options": "i" } },
            { "titles/title": { "$regex": "(Problem-Based Learning|PBL|Active Learning)", "$options": "i" } },

```

```

        { "keywords/keyword": { "$regex": "(Problem-Based
Learning|PBL|Active Learning)", "$options": "i" } }
    ],
    {
        "$or": [
            { "abstract": { "$regex": "(Artificial
Intelligence|AI|Machine Learning)", "$options": "i" } },
            { "titles/title": { "$regex": "(Artificial
Intelligence|AI|Machine Learning)", "$options": "i" } },
            { "keywords/keyword": { "$regex": "(Artificial
Intelligence|AI|Machine Learning)", "$options": "i" } }
        ]
    },
    {
        "$or": [
            { "abstract": { "$regex":
"(Education|Pedagogy|Teaching)", "$options": "i" } },
            { "titles/title": { "$regex":
"(Education|Pedagogy|Teaching)", "$options": "i" } },
            { "keywords/keyword": { "$regex":
"(Education|Pedagogy|Teaching)", "$options": "i" } }
        ]
    }
    ]
},
{
    "$count": "relevant_articles"
}
]

```

Explicação: Esta consulta filtra artigos que correspondem a três diferentes grupos de palavras-chave. O uso de `$and` assegura que os artigos tenham uma relação com **PBL ou Active Learning**, **AI ou Machine Learning**, e **Educação ou Pedagogia**. O estágio final conta o número de artigos que atendem a esses critérios.

Relatório Final Consolidado

1. Contagem Total de Artigos:

- O total de artigos disponíveis na coleção foi consultado usando a etapa `$count`. O valor é retornado como `total_articles`.

2. Contagem de Artigos a Partir de 2019:

- A consulta retornou os artigos com data de publicação igual ou superior a 2019, e o resultado foi contado na etapa final como `total_articles_after_2019`.

3. Seleção de Artigos Mais Relevantes:

- A terceira etapa selecionou artigos que envolvem **aprendizagem ativa e baseada em problemas (PBL)**, **inteligência artificial (AI)** e **educação/pedagogia**. Os artigos correspondentes foram filtrados e contados como `relevant_articles`.

APÊNDICE C – LEVANTAMENTOS DE TRABALHOS



RELATÓRIO DE TRABALHOS

Orientador: Lafayette Batista Melo

Mestrando: Rayllon Soares Pessoa

INTRODUÇÃO

Este relatório tem como objetivo apresentar uma revisão detalhada sobre a aplicação da Aprendizagem Baseada em Problemas (PBL) no ensino de Inteligência Artificial, destacando seus impactos e benefícios pedagógicos. Para garantir a abrangência da pesquisa, utilizamos como fontes as plataformas ERIC, Scopus, ACM e IEEE, que resultaram em 1.475 artigos. Todos os artigos foram armazenados em um banco de dados MongoDB, facilitando a manipulação e análise direcionada dos dados. Após a aplicação dos critérios de inclusão e exclusão, 36 artigos foram selecionados, passando pela avaliação de três revisores para garantir a relevância e a qualidade dos estudos.

LEVANTAMENTO DOS ARTIGOS

Sobre a validação dos artigos, inicialmente analisando os títulos e resumos para garantir que estivessem alinhados com o tema proposto. Nos casos em que havia dúvidas sobre a abordagem do artigo, as conclusões também foram lidas para assegurar sua relevância. Esse processo permitiu uma triagem mais precisa, evitando a inclusão de artigos que não contribuísssem significativamente para a pesquisa. Abaixo, apresentamos a tabela de validação dos artigos.

Título	Avaliador	Parecer	Objetivo da pesquisa
Lab4CE: A Remote Laboratory for Computer Education	REVISOR - 1	Reprovado -	Desenvolver e implementar o Lab4CE, um laboratório remoto para a educação em ciência da computação.
E-Learning – Evolution, Trends, Methods, Examples, Experience	REVISOR - 1	Reprovado -	Apresentar aspectos teóricos e práticos do uso do e-learning no ensino superior, baseados na experiência da autora.
Research on the online pbl education system using ai	REVISOR - 1	Reprovado -	Documento não encontrado
PBL: A Teaching and Learning Concept Is Facing Artificial Intelligence	REVISOR - 1	Reprovado -	O objetivo da pesquisa é examinar a evolução e as tendências do e-learning, identificando métodos eficazes e exemplos práticos de sua implementação, fornecendo informações sobre como o e-learning pode ser aprimorado e aplicado de maneira eficiente em diversas maneiras.
Teaching Development of Distributed Software during COVID-19: An experience report in Brazil	REVISOR - 1	Parcialmente -	O objetivo da pesquisa é relatar a experiência do ensino de desenvolvimento de software distribuído no Brasil durante a pandemia, destacando os desafios e soluções adotadas.
Application of PBL Teaching Mode in the Course of "Ultrasonic	REVISOR - 2	Parcialmente -	Integrar PBL para melhorar habilidades de pensamento, inovação e cooperação dos alunos.

Diagnosis Equipment and Maintenance" under the Background of New Engineering			
Empirical Research on PBL Teaching Method of Design Innovation Curriculum	REVISOR - 1	Parcialmente	O objetivo da pesquisa é investigar empiricamente como o método de ensino PBL pode ser aplicado no currículo de design de inovação, avaliando sua eficácia e impacto nos resultados dos alunos.
Student Modeling for Individuals and Groups: The BioWorld and HOWARD Platforms	REVISOR - 1	Reprovado	Documento não encontrado
The Dilemmas of Teaching Dilemmas in a Foreign Language Classroom	REVISOR - 2	Parcialmente	Descrever o design e a implementação de uma unidade PBL de chinês em uma escola dos EUA.
Poster: Lesson Effects of PBL Education Promoted the Use of AI	REVISOR - 2	Aprovado	Investigar os efeitos da educação baseada em PBL na promoção do uso de IA.
Lightening Up a New AI Cognitions and Performances for Engineering Students' Problem-Based Learning in Nature General Education Programs	REVISOR - 2	Aprovado	Explorar como a aprendizagem baseada em problemas (PBL) pode ser aprimorada para melhorar as habilidades cognitivas e o desempenho dos alunos em engenharia, integrando conceitos de IA.
THE ONLINE PBL (PROJECT-BASED LEARNING) EDUCATION SYSTEM USING AI (ARTIFICIAL INTELLIGENCE)	REVISOR - 2	Aprovado	Investigar os efeitos da utilização de IA na educação baseada em projetos online.
GROUP ACTIVITIES WITH AI TEACHER SUPPORT IN PBL EDUCATION	REVISOR - 1	Reprovado	Documento não encontrado
GROUP ACTIVITIES WITH AI TEACHER SUPPORT IN PBL EDUCATION	REVISOR - 1	Reprovado	Documento não encontrado
PBL Cultivation Mode of Innovative Thinking Ability Based on the Data of WTMF and TCT	REVISOR - 3	Reprovado	Estabelecer um modo de ensino baseado nos dados do WTMF (Williams Innovative Thinking Ability Tendency Measurement Form) e TCT (Test of Creative Thinking).
Application and Practice of C-PBL mixed teaching in the Course of Career Planning for College Students	REVISOR - 3	Reprovado	Explorar a aplicação prática do ensino misto C-PBL em cursos de planejamento de carreira.
Teaching Exploratory Tests through PBL and JITT: an experience report in a context of distributed teams	REVISOR - 3	Parcialmente	Investigar as contribuições e limitações da adoção de PBL e Just-in-Time Teaching (JITT) no ensino-aprendizagem de ET.
Implementation of Innovative Artificial Intelligence Cognitions with Problem-Based Learning Guided Tasks to Enhance Students' Performance in Science	REVISOR - 2	Aprovado	Integrar o aprendizado de vida com IA (reconhecimento facial, direção autônoma, questões situacionais de robôs) ao PBL em ciências naturais.
Research on PBL-Based Maker Teaching Mode Supported by AI Algorithm Platform——Take the teaching of "Face Recognition Access Control System" as an example	REVISOR - 1	Aprovado	Investigar a eficácia do modo de ensino Maker baseado em PBL suportado por uma plataforma de algoritmos de IA, usando o ensino de um "Sistema de Controle de Acesso por Reconhecimento Facial" como exemplo.
Dynamic Education Background: Procure the Maximum Initiation from PBL for Education Naïve Bayes Algorithm for Machine Learning	REVISOR - 3	Aprovado	Explorar como o PBL pode ser utilizado para otimizar o ensino do algoritmo Naïve Bayes no contexto de machine learning.
Monitoring Students' Professional Competencies in PBL: A Proposal Founded on Constructive Alignment and Supported by AI Technologies	REVISOR - 3	Parcialmente	Propor um método para monitorar as competências profissionais dos alunos em PBL baseado em alinhamento construtivo e suporte de tecnologias de IA.

Blended Practical Teaching of Object Oriented Programming Based on PBL and Task Driven	REVISOR - 2	Parcialmente -	Desenvolver um modo de ensino prático combinado com PBL, sala de aula invertida, e avaliação online para melhorar as habilidades de pensamento computacional dos alunos.
Design of an Integrated Project-Based Learning Curriculum: Analysis through Fink's Taxonomy of Significant Learning	REVISOR - 1	Parcialmente -	Discutir o design e a implementação de um currículo integrado de PBL, chamado Integrated Learning Stream (ILS), e como isso promove a aprendizagem significativa.
Co-Designing a Classroom Orchestration Assistant for Game-Based PBL Environments	REVISOR - 1	Parcialmente -	Explorar as necessidades dos professores para apoiar a orquestração em ambientes de PBL baseados em jogos e identificar áreas de tensão entre objetivos de professores e designers através de um processo de co-design.
Case Study: The Impact of Emerging Technologies on Cybersecurity Education and Workforces	REVISOR - 2	Parcialmente -	Entender os passos necessários para preparar a força de trabalho em cibersegurança para trabalhar com tecnologias emergentes e identificar áreas de melhoria na educação e treinamento em cibersegurança.
The Impact of an Artificial Intelligence (AI) Project-Based Learning (PBL) Course on Middle-School Students' Interest, Knowledge, and Career Aspiration in the AI Field	REVISOR - 3	Aprovado -	Avaliar como um curso de PBL em IA afeta o interesse dos alunos, o conhecimento sobre IA e as aspirações de carreira.
Using PBL and Agile to Teach Artificial Intelligence to Undergraduate Computing Students	REVISOR - 3	Aprovado -	Apresentar um estudo de caso sobre a implementação bem-sucedida de PBL com Scrum e Agile para o ensino de IA e como isso contribui para a pesquisa limitada sobre Scrum na educação e ensino de IA.
A Study of A Growing Problem-based Teaching Model for the Development of Information-based Teaching Design Ability of Normal University Students under the Concept of Wisdom Education: -Taking Modern Educational Technology public course as an example	REVISOR - 3	Parcialmente -	Desenvolver um novo modelo de ensino baseado em PBL para aprimorar a capacidade de design de ensino de tecnologia da informação entre alunos de universidades normais.
Building Students' Digital Footprints with Blockchain in PBL Activities	REVISOR - 2	Parcialmente -	Propor um modelo de PBL que utiliza blockchain para criar um sistema de certificados digitais que compila dados pessoais e competências dos alunos.
Improving the PBL method with experiential learning theory in software engineering teaching	REVISOR - 2	Aprovado -	Investigar os impactos da inclusão da fase de experimentação ativa na metodologia PBL para melhorar os resultados de aprendizado em engenharia de software.
Application of case-based PBL teaching method in the teaching of Network and Service Engineering	REVISOR - 2	Parcialmente -	Estabelecer um modelo de ensino baseado em PBL com foco em casos, criando uma organização curricular e um sistema de avaliação diversificado para melhorar a capacidade de inovação científica e tecnológica dos alunos.
Leading Teachers' Perspective on Teacher-AI Collaboration in Education	REVISOR - 1	Parcialmente -	Identificar as necessidades curriculares, interações professor-IA, e ambientes de aprendizagem para uma colaboração eficaz entre professores e IA, e como essa colaboração evoluiria.
Convergence between Emerging Technologies and Active Methodologies in the University	REVISOR - 1	Aprovado -	Explorar como a combinação de tecnologias emergentes (IA, VR, aprendizado de máquina) e metodologias ativas (PBL, aprendizado colaborativo, sala de aula invertida) pode criar experiências de aprendizagem personalizadas e imersivas.
Research on Construction Experimental Teaching Model of Artificial Intelligence in High School Based on PBL	REVISOR - 3	Aprovado -	Desenvolver e avaliar um modelo de ensino experimental de IA para o ensino médio utilizando PBL.
Introducing AI applications in engineering education (PBL): An implementation of power generation at minimum wind velocity and	REVISOR - 2	Aprovado -	Implementar aplicações de IA em PBL para ensinar geração de energia em baixas velocidades de vento e classificação de falhas em turbinas.



turbine faults classification using AI			
Exploration of a Learner-centered Education Model: the Integration of PBL and FET	REVISOR - 2	Parcialmente -	Investigar a eficácia do uso da técnica de elementos finitos (FET) em PBL para melhorar a compreensão dos alunos e motivá-los a aprender.

CONCLUSÃO

Embora diversos estudos incluam metodologias de Aprendizagem Baseada em Problemas (PBL) em combinação com inteligência artificial e machine learning, tivemos dificuldade em encontrar trabalhos que direcionem essa abordagem especificamente para o ensino ou aplicação pedagógica desses componentes. A maioria dos artigos revisados explora a PBL como uma estratégia de ensino em contextos amplos de educação tecnológica, mas poucos focam na integração estruturada da PBL no ensino de IA e ML.

APÊNDICE D– DIVISÃO DO CLASSROOM – ALGORITMO DE BUSCA



Sala de Aula > 3ª Série B
inteligência artificial




Mural
 Atividades
 Pessoas
 Notas




Filtro de tópicos

Seção 02 - Algoritmos de busca

Seção 02 - Algoritmos de busca



Rayllon Soares postou um novo material: 1. Introdução teórica e análise crítica

Item postado: 12 de mai. de 2024 (editado: 22 de jul. de 2024)

Estudaremos teoria de buscas, heurística e a criação de mapas de cidades. Vamos aprender sobre algoritmos de busca, técnicas heurísticas e como aplicá-las na resolução de problemas práticos, como encontrar rotas ótimas em mapas de cidades.

- Teoria de buscas
- Heurística
- Criação do mapa das cidades

Introdução Teoria de b...
PDF



Adicionar comentário


Rayllon Soares postou um novo material: 2. Algoritmo busca gulosa

Item postado: 12 de mai. de 2024 (editado: 12 de mai. de 2024)

Na busca gulosa, também conhecida como **busca heurística**, o algoritmo escolhe o próximo passo com base em uma heurística ou função de avaliação que estima qual a melhor direção a tomar. A ideia é selecionar a opção que parece ser a mais promissora no momento, sem levar em conta o futuro. Portanto, a busca gulosa é uma estratégia de decisão gananciosa, pois sempre escolhe a alternativa que parece ser a melhor localmente. No entanto, essa abordagem não garante a melhor solução global, pois pode acabar ficando presa em mínimos locais ou subótimos.

"heurística é um método prático, baseado em experiência ou intuição, usado para resolver problemas ou tomar decisões de forma mais rápida, embora não garanta a melhor solução".

grafo_busca_gulosa.pdf
PDF



Grafo Busca Gulosa.ipyn...
<https://colab.research.google.com>



Adicionar comentário



Rayllon Soares postou um novo material: 3. Algoritmo busca A* A Estrela)



Item postado: 13 de mai. de 2024

A principal ideia por trás do A* é a combinação de um custo real do caminho percorrido até o momento (custo g) e uma estimativa do custo do caminho restante até o objetivo (heurística h). Ele usa essa combinação para guiar a busca em direção ao objetivo de uma forma eficiente, explorando primeiro as áreas mais promissoras do espaço de busca. Isso o torna muito eficiente para encontrar o caminho mais curto em grafos e em muitos outros tipos de problemas de otimização.

[Busca_estrela.pdf](#)
PDF



[Grafo Busca A Estrela.i...](#)
<https://colab.research.google>



[Adicionar comentário](#)



Rayllon Soares postou uma nova atividade: 4.E...Data de entrega: 21 de mai. de 2024



Item postado: 13 de mai. de 2024 (editado: 23 de out. de 2024)

O objetivo desta tarefa é utilizar o mesmo código fonte das aulas anteriores para construir o exemplo abaixo. A cidade de origem é **Porto União** e a cidade de destino é **Curitiba**. No mapa abaixo você pode visualizar as distâncias pela estrada entre cada uma das cidades

0

Entregue

0

Pendentes

20

Com nota

[Atividade01.pdf](#)
PDF



[Apresentação sem título](#)
Google Slides

Algoritmo de busca

[Adicionar comentário](#)



APÊNDICE E – MATERIAL EM SLIDES - ALGORITMO DE BUSCA

INTRODUÇÃO A ALGORITMO DE BUSCA

TERMINOLOGIA INTELIGÊNCIA ARTIFICIAL

TERMINOLOGIA INTELIGÊNCIA ARTIFICIAL

Terminologia em inteligência artificial (IA) refere-se ao vocabulário específico usado para descrever conceitos, técnicas e processos relacionados à IA. Aqui estão alguns termos:

Algoritmos de Busca: São algoritmos usados para encontrar a solução para problemas representados como grafos de estados. Eles são amplamente utilizados em inteligência artificial, especialmente em jogos de computador.

Lógica Fuzzy (Fuzzy): É uma lógica que permite lidar com incertezas e imprecisões em sistemas baseados em regras. Ela permite a representação de conceitos vagos e a tomada de decisões baseadas em graus de pertinência.

Redes Neurais Baseadas em Casos: É uma abordagem de IA que utiliza redes neurais para aprender com experiências passadas e aplicar esse conhecimento para resolver problemas semelhantes.

Sistemas Multiagentes: São sistemas compostos por múltiplos agentes computacionais autônomos que interagem entre si para resolver problemas complexos. Eles são usados em aplicações como simulação social, robótica cooperativa e jogos.

Computação Evolutiva: É uma área da IA que utiliza algoritmos inspirados na evolução natural para resolver problemas complexos. Ela é usada para otimização, aprendizado de máquina e design de sistemas.

Processamento de Linguagem Natural (PLN): É uma subárea da inteligência artificial que se concentra na interação entre computadores e humanos através da linguagem natural. Envolve a compreensão, interpretação e geração de texto.

ALGORITMOS INTELIGENTES DE BUSCA

- Definição de problemas e soluções
- Mapa das cidades
- Heurísticas
- Busca Gulosa
- Busca A* (A Estrela)
- Aulas adicionais sobre Estrutura de Dados (vetores)

COMPONENTES DE UM PROBLEMA

1. Estado inicial
2. Estado final (objetivo)
3. Espaço de estados
4. Ações para passar de um estado para outro
5. Solução (caminho que leva do estado inicial ao estado final)

PROBLEMA: IR DE ARAD ATÉ BUCHAREST

PROBLEMA: JOGO DAS PEÇAS (8-PUZZLE)

PROBLEMA: JOGO DA VELHA

HEURÍSTICAS

- Escolher a melhor jogada no xadrez
- 1056-1 seguido de 56 zeros
- Superior ao número de elétrons no universo
- Maneira para resolver um problema
- Indicam escolhas que a máquina deve priorizar
- Técnicas de ajuda a descoberta
- Quente ou frio

HEURÍSTICAS

HEURÍSTICAS

GRAFO - BUSCA A* ESTRELA

GRAFO - BUSCA GULOSA

MATERIA DA ATIVIDADE PROPOSTA

Linha reta entre todas as cidades e o objetivo

Cidade	Distância (milhas)	Objetivo
Porto União	272	203
Paulo Frontin	272	203
Canoinhas	241	203
Três Barras	231	203
São Mateus do Sul	223	203
Imbu	139	203
Curitiba	0	203
Palmeira	58	203
Mafra	94	203
Campo Largo	27	203
Balsa Nova	41	203
Lapa	74	203
Tijucas do Sul	56	203
Aracatuba	23	203
São José dos Pinhais	23	203
Concórdia	38	203

APÊNDICE F – CÓDIGO DA ATIVIDADE PRÁTICA COM ALGORITMO DE BUSCA

O código completo deste trabalho está disponível nos seguintes links:

Grafo - Busca gulosa

```
class Vertice:
    def __init__(self, rotulo, rotulo, distancia_objetivo):
        self.rotulo = rotulo
        self.visitado = False
        self.distancia_objetivo = distancia_objetivo
        self.adjacentes = []

    def adiciona_adjacente(self, adjacente):
        self.adjacentes.append(adjacente)

    def mostra_adjacentes(self):
        for i in self.adjacentes:
            print(i.vertice.rotulo, i.custo)

class Adjacente:
    def __init__(self, vertice, vertice, custo):
        self.vertice = vertice
        self.custo = custo

class Grafo:
    arad = Vertice('Arad', 366)
    zerind = Vertice('Zerind', 374)
    oradea = Vertice('Oradea', 380)
    sibiu = Vertice('Sibiu', 253)
    timisoara = Vertice('Timisoara', 329)
    lugoj = Vertice('Lugoj', 244)
    mehadia = Vertice('Mehadia', 241)

busca_gulosa = Gulosa(grafo.bucharest)
busca_gulosa.buscar(grafo.arad)

...
Atual: Arad
0 - Sibiu - 253
1 - Timisoara - 329
2 - Zerind - 374
-----
Atual: Sibiu
0 - Fagaras - 178
1 - Rimnicu - 193
2 - Oradea - 380
-----
Atual: Fagaras
0 - Bucharest - 0
-----
Atual: Bucharest
```

Grafo - Busca A Estrela (A*)

```
class Vertice:
    def __init__(self, rotulo, rotulo, distancia_objetivo):
        self.rotulo = rotulo
        self.visitado = False
        self.distancia_objetivo = distancia_objetivo
        self.adjacentes = []

    def adiciona_adjacente(self, adjacente):
        self.adjacentes.append(adjacente)

    def mostra_adjacentes(self):
        for i in self.adjacentes:
            print(i.vertice.rotulo, i.custo)

class Adjacente:
    def __init__(self, vertice, vertice, custo):
        self.vertice = vertice
        self.custo = custo

    # novo atributo
    self.distancia_astrela = vertice.distancia_objetivo + self.custo

class Grafo:
    arad = Vertice('Arad', 366)
    zerind = Vertice('Zerind', 374)
    oradea = Vertice('Oradea', 380)
    sibiu = Vertice('Sibiu', 253)

busca_astrela = AEstrela(grafo.bucharest)
busca_astrela.buscar(grafo.arad)

...
Atual: Arad
0 - Sibiu - 140 - 253 - 393
1 - Timisoara - 118 - 329 - 447
2 - Zerind - 75 - 374 - 449
-----
Atual: Sibiu
0 - Rimnicu - 80 - 193 - 273
1 - Fagaras - 99 - 178 - 277
2 - Oradea - 151 - 380 - 531
-----
Atual: Rimnicu
0 - Pitesti - 97 - 98 - 195
1 - Craiova - 146 - 160 - 306
-----
Atual: Pitesti
0 - Bucharest - 101 - 0 - 101
-----
Atual: Bucharest
```

Busca Gulosa:

<https://colab.research.google.com/drive/1vnwUWnO8Jt0nze3oDVmDQh3e5cukSyLp?usp=sharing>

Busca A*:

https://colab.research.google.com/drive/1HMw_gonGvvZaUBKcedSf9GphclqVfSIT?usp=sharing

APÊNDICE G – FORMULÁRIO AVALIATIVO ALGORITMO DE BUSCA

Avaliação - Algoritmo de Bu: ☆

🔖

💬

👁

↶

↷

Enviar

⋮

Perguntas

Respostas 33

Configurações

Total de pontos: 15

Seção 1 de 5

Formulário Avaliativo: Algoritmo de Busca Gulosa e Busca A*

Descrição do formulário

Nome do Estudante *

Texto de resposta curta

Turma *

☐ 3ªA

☐ 3ªB

Após a seção 1

Continuar para a próxima seção

Seção 2 de 5

Seção 2: Conhecimento Teórico - Algoritmo de Busca Gulosa

Descrição (opcional)

Qual é o princípio básico do algoritmo de busca gulosa? *

☐ a) Seleciona o próximo nó com base na menor distância acumulada desde o início.

☐ b) Seleciona o próximo nó com base na estimativa mais baixa de custo total.

☐ c) Seleciona o próximo nó com base na heurística que parece mais promissora.

☐ d) Seleciona o próximo nó aleatoriamente.

☐ e) Seleciona o próximo nó com base na maior distância acumulada desde o início.

Qual é uma vantagem do algoritmo de busca gulosa? *

☐ a) Garante encontrar o caminho mais curto.

?

☐ b) É rápido e eficiente em tempo de execução.

☐ c) Não requer uma função heurística.

☐ d) Sempre encontra uma solução.

☐ e) É fácil de implementar sem nenhuma heurística.

?

Qual é uma desvantagem do algoritmo de busca gulosa? *

☐ a) Pode não encontrar uma solução.

☐ b) Pode ser lento e ineficiente.

☐ c) Não utiliza nenhuma heurística.

☐ d) Pode encontrar caminhos não tão eficiente.

☐ e) Requer muita memória para executar.

?

Qual é a diferença entre busca gulosa e busca A*? *

☐ a) Busca A* utiliza apenas a heurística.

☐ b) Busca gulosa considera o custo total do caminho.

☐ c) Busca A* considera tanto o custo acumulado quanto a heurística.

☐ d) Não há diferença significativa.

☐ e) Busca gulosa não utiliza heurísticas.

?

Quando é preferível usar a busca A* em comparação com a busca gulosa?* *

☐ a) Quando a rapidez é mais importante que a precisão.

☐ b) Quando o objetivo é garantir o caminho mais curto.

☐ c) Quando não há uma heurística disponível.

☐ d) Quando se lida com problemas não estruturados.

☐ e) Quando há muitas soluções possíveis.

?

Após a seção 2 Continuar para a próxima seção

▼

Seção 3 de 5

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

Seção 3: Aplicação Prática - Implementação em Python

Descrição (opcional)

?

Qual função é crucial para a busca gulosa em Python? *

☐ a) A função de custo acumulado.

☐ b) A função heurística.

☐ c) A função de busca em profundidade.

☐ d) A função de busca em largura.

☐ e) A função de busca bidirecional.

?

Qual função é crucial para a busca A* em Python? *

☐ a) A função de custo acumulado.

☐ b) A função heurística.

☐ c) A função de busca em profundidade.

☐ d) A função de busca em largura.

☐ e) A função de backtracking.

?

Ao usar a busca gulosa, qual nó é selecionado a seguir? *

☐ a) O nó com o menor custo acumulado.

☐ b) O nó com a menor estimativa de custo total.

☐ c) O nó com a menor valor heurística.

☐ d) O nó aleatório.

☐ e) O nó com o maior custo acumulado.

?

Ao usar a busca A*, qual nó é selecionado a seguir? *

☐ a) O nó com o menor custo acumulado.

☐ b) O nó com a menor estimativa de custo total.

☐ c) O nó com a menor heurística.

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

Tt

🖼️

▶

≡

- ☐ d) O nó aleatório.
- ☐ e) O nó com o maior custo total estimado.

?

Qual algoritmo é mais provável de encontrar o caminho mais eficiente em um gráfico bem definido? *

- ☐ a) Busca Gulosa
- ☐ b) Busca A*
- ☐ c) Ambos são igualmente eficazes
- ☐ d) Nenhum dos dois
- ☐ e) Depende do tamanho do gráfico

?

Qual é a principal vantagem de usar a busca A* em comparação com a busca gulosa? *

- ☐ a) A busca A* é mais rápida.
- ☐ b) A busca A* sempre encontra o caminho mais curto.
- ☐ c) A busca A* não requer uma função heurística.
- ☐ d) A busca A* usa menos memória.
- ☐ e) A busca A* é mais fácil de implementar.

?

Após a seção 3 Continuar para a próxima seção

Seção 4 de 5

?

Seção 4: Reflexão Crítica

Descrição (opcional)

?

Como você avalia sua compreensão da busca gulosa? *

- ☐ Insignificante
- ☐ Baixo
- ☐ Moderado
- ☐ Alto
- ☐ Significativo

?

Como você avalia sua compreensão da busca A?* *

☐ Insignificante

☐ Baixo

☐ Moderado

☐ Alto

☐ Significativo

Tt







?

Quão confiante você está em implementar a busca gulosa em Python? *

☐ Sem Confiança

☐ Pouco Confiante

☐ Moderadamente Confiante

☐ Confiante

☐ Muito Confiante

Tt







?

Quão confiante você está em implementar a busca A* em Python? *

☐ Sem Confiança

☐ Pouco Confiante

☐ Moderadamente Confiante

☐ Confiante

☐ Muito Confiante

Tt







?

Após a seção 4 Continuar para a próxima seção ▼

Seção 5 de 5

Seção 5: Avaliação e Feedback

Descrição (opcional)

Tt







?

Qual foi o recurso mais útil para aprender sobre esses algoritmos? *

Tt





?

☐ Aulas teóricas

☐ Exercícios práticos

☐ Vídeos tutoriais

☐ Livros didáticos

☐ Discussões em grupo

☐ Material online (artigos, blogs, etc.)

☐ Laboratórios de programação

☐ Sessões de mentoria ou tutoria

?

Qual aspecto do ensino desses algoritmos você acha que poderia ser melhorado? *

☐ Explicação teórica

☐ Exemplos práticos

☐ Suporte e feedback do professor

☐ Recursos de estudo (livros, artigos, tutoriais)

☐ Tempo dedicado às atividades práticas

☐ Ferramentas e ambientes de programação utilizados

☐ Discussões e interações em grupo

☐ Sessões de revisão e reforço

?

Tt

Tt

Tt

APÊNDICE H – DIVISÃO DO CLASSROOM – ALGORITMO CLASSIFICAÇÃO

Sala de Aula > 3ª Série B

inteligência artificial

Mural

Atividades

Pessoas

Notas

Filtro de tópicos

Seção - 03 Algoritmos de classifica... ▾

Seção - 03 Algoritmos de classificação

Rayllon Soares postou um novo material: 1. Introdução aos Algoritmos de Classificaç...

Item postado: 8 de jul. de 2024 (editado: 8 de jul. de 2024)

Os algoritmos de classificação são técnicas fundamentais em aprendizado de máquina que visam categorizar dados em classes predefinidas. Eles são amplamente utilizados para prever categorias a partir de características dos dados e são essenciais em diversas aplicações, desde a detecção de fraudes até a análise de sentimentos.

O material anexado fornece uma visão geral abrangente sobre algoritmos de classificação, detalhando seus princípios de funcionamento, tipos principais e exemplos de aplicação. Esta introdução serve como um ponto de partida para entender como esses algoritmos podem ser aplicados para resolver problemas de classificação e melhorar a tomada de decisões baseada em dados.

Introdução aos Algoritmo...

PDF

Adicionar comentário

Rayllon Soares postou um novo material: 2. Algoritmo de Treinamento

Item postado: 8 de jul. de 2024 (editado: 9 de jul. de 2024)

O material anexado oferece uma visão detalhada sobre o funcionamento dos algoritmos de treinamento, tanto na teoria quanto na prática com o uso do Orange. Ele inclui a estrutura de como aplicar cada algoritmo e orientações sobre a análise dos resultados.

Esse conhecimento será essencial para as atividades futuras, garantindo uma compreensão sólida e prática dos algoritmos de treinamento.

Algoritmo de Treinamento...

PDF

Adicionar comentário

Rayllon Soares postou uma nova atividade: 2 Exercici...Data de entrega: 10 de jul. de 2024

Item postado: 8 de jul. de 2024 (editado: 22 de jul. de 2024)

Calcular a acurácia (Accuracy) de diferentes algoritmos aplicados à base de dados criada anteriormente para prever o nível do estudante na redação do ENEM e a produção do TCC (Trabalho de Conclusão de Curso).

0

Entregue

0

Pendentes

20

Com nota

- Utilizem os algoritmos que estudamos em aula para treinar e testar o desempenho sobre a base de dados que vocês criaram.
- Certifiquem-se de medir a acurácia (Accuracy) de cada algoritmo utilizado.

Criação dos Gráficos:

- Para cada algoritmo, gerem um gráfico que ilustre a performance do algoritmo em relação à acurácia obtida.

Seleção do Melhor Algoritmo:

- Identifiquem qual algoritmo obteve a maior acurácia (Accuracy)

Envio dos Resultados:

- Preencham o formulário fornecido com as seguintes informações:
- Nome do Algoritmo que obteve a maior acurácia.
- Valor da acurácia obtida.

Anexem no formulário:

- Um print do gráfico do algoritmo com a maior acurácia.
- O dataset em formato CSV que foi utilizado.
- Certifiquem-se de preencher todos os campos obrigatórios.
- Adicionem o print do gráfico e o dataset em CSV nos respectivos campos de upload.
- Correção na aplicação dos algoritmos.
- Precisão na medição da acurácia.
- Clareza e qualidade dos gráficos apresentados.
- Completeness e organização do dataset em CSV.

Algoritmo de Classificaçã...

Google Formulários

Adicionar comentário



MACHINE LEARNING

Classificação

- Naïvebayes
- árvore de decisão
- Aprendizagem por regras,
- Aprendizagem baseado em instâncias

CLASSIFICAÇÃO

ÁRVORE DE DECISÃO COM ORANGE

The screenshot shows the Orange3 software interface. On the left, there is a sidebar with a 'Data' section containing various data file formats (CSV, JSON, XML, etc.) and a 'Transform' section containing various data transformation widgets. The main workspace displays a workflow titled 'Árvore de Decisão'. The workflow starts with a 'File' widget connected to a 'Data' widget, which is then connected to a 'File' widget, then a 'File' widget, and finally a 'File' widget. The central node is a 'Decision Tree' widget, which is highlighted with a red circle. It is connected to a 'File' widget, then a 'File' widget, then a 'File' widget, and finally a 'File' widget. The workflow is titled 'Árvore de Decisão'.

[illegible]

APRENDIZAGEM BASEADA EM INSTÂNCIAS - K-NN

Conjunto de Treinamento

Amostra	Classe	X1	X2	X3	X4
A	neg	-1.0	0.0	-1.0	0.0
B	neg	-0.5	0.0	-1.0	0.0
C	neg	-0.5	0.0	-1.0	0.0
D	neg	-0.5	0.0	-1.0	0.0
E	neg	-0.5	0.0	-1.0	0.0
F	neg	-0.5	0.0	-1.0	0.0
G	neg	-0.5	0.0	-1.0	0.0
H	neg	-0.5	0.0	-1.0	0.0
I	neg	-0.5	0.0	-1.0	0.0
J	neg	-0.5	0.0	-1.0	0.0

Conjunto de Teste

Amostra	Classe	X1	X2	X3	X4
A	neg	-1.0	0.0	-1.0	0.0
B	neg	-0.5	0.0	-1.0	0.0
C	neg	-0.5	0.0	-1.0	0.0
D	neg	-0.5	0.0	-1.0	0.0
E	neg	-0.5	0.0	-1.0	0.0
F	neg	-0.5	0.0	-1.0	0.0
G	neg	-0.5	0.0	-1.0	0.0
H	neg	-0.5	0.0	-1.0	0.0
I	neg	-0.5	0.0	-1.0	0.0
J	neg	-0.5	0.0	-1.0	0.0

Resultado da Aprendizagem

Amostra	Classe	X1	X2	X3	X4	Resultado
A	neg	-1.0	0.0	-1.0	0.0	neg
B	neg	-0.5	0.0	-1.0	0.0	neg
C	neg	-0.5	0.0	-1.0	0.0	neg
D	neg	-0.5	0.0	-1.0	0.0	neg
E	neg	-0.5	0.0	-1.0	0.0	neg
F	neg	-0.5	0.0	-1.0	0.0	neg
G	neg	-0.5	0.0	-1.0	0.0	neg
H	neg	-0.5	0.0	-1.0	0.0	neg
I	neg	-0.5	0.0	-1.0	0.0	neg
J	neg	-0.5	0.0	-1.0	0.0	neg

Exemplo de Cálculo de Distância

Amostra A: $X_1 = -1.0, X_2 = 0.0, X_3 = -1.0, X_4 = 0.0$

Amostra B: $X_1 = -0.5, X_2 = 0.0, X_3 = -1.0, X_4 = 0.0$

Distância entre A e B: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e C: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e D: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e E: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e F: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$


Distância entre A e G: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e H: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e I: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Distância entre A e J: $\sqrt{(-1.0 + 0.5)^2 + (0.0 - 0.0)^2 + (-1.0 + 1.0)^2 + (0.0 - 0.0)^2} = \sqrt{0.25} = 0.5$

Resultado: A amostra A é classificada como "neg" (negativo) porque a maioria dos vizinhos (K=5) é "neg".



APRENDIZAGEM BASEADA EM INSTÂNCIAS -kNN COM ORAGNE

id	class	predicted class	accuracy	distance
1	1	1	1	0.0
2	2	2	1	0.0
3	1	1	1	0.0
4	2	2	1	0.0
5	1	1	1	0.0

APÊNDICE J – CONJUNTO DE DADOS PARA ATIVIDADES PRÁTICAS – ALGORITMO CLASSIFICAÇÃO

Conjunto de dados - Jardim zoológico


[Conjuntos de dados](#)
[Contribuir com o conjunto de dados](#)
[Sobre nós](#)

[Conecte-se](#)



Jardim zoológico

Doador em 14/05/1990

[DOWNLOAD \(2,4 KB \)](#)
[IMPORTAR EM PYTHON](#)
[CITAR](#)

29 citações
66315 visualizações

Palavras-chave

ecologia

Criadores

Ricardo Forsyth

DOI

10.24432/CSR59V

Licença

Este conjunto de dados está licenciado sob uma licença **Creative Commons Atribuição 4.0 Internacional** (CC BY 4.0).

Isso permite o compartilhamento e a adaptação dos conjuntos de dados para qualquer finalidade, desde que os devidos créditos sejam atribuídos.

Características do conjunto de dados Multivariado	Área temática Biologia	Tarefas Associadas Classificação
Tipo de recurso Categórico, Inteiro	# Instâncias 101	# Características 16

[Informações do conjunto de dados](#)
[Tabela de variáveis](#)
[Informações adicionais sobre variáveis](#)
[Desempenho do modelo de referência](#)
[Arquivos de conjunto de dados](#)
[Artigos que citam este conjunto de dados](#)



O PROJETO

Sobre nós
LMC
Fundação Nacional de Ciência

NAVEGAÇÃO

Lar
Visualizar conjuntos de dados
Doe um conjunto de dados

LOGÍSTICA

Contato
Aviso de Privacidade
Solicitação de recurso ou relatório de erro

Fonte: <https://archive.ics.uci.edu/dataset/111/zoo>

APÊNDICE K – BASES DE DADOS ELABORADAS PELOS ESTUDANTES PARA AVALIAÇÃO DE ALGORITMOS DE CLASSIFICAÇÃO

Como parte das atividades do ciclo dedicado aos algoritmos de classificação, os estudantes, organizados em cinco grupos, construíram bases de dados próprias a partir de questionários on-line. Cada grupo definiu um tema, elaborou variáveis preditoras em formato de questões fechadas e escolheu uma variável-alvo categórica a ser prevista (risco, desempenho ou resultado geral). Essas bases foram posteriormente utilizadas para treinar e comparar diferentes algoritmos de classificação, no contexto da intervenção pedagógica.

Base 1 – Autoavaliação de competências acadêmicas (Grupo 1)

Tema geral: percepção dos estudantes sobre suas competências acadêmicas e científicas.
Tamanho da base: 56 registros (linhas) e 11 atributos (10 preditores + 1 variável-alvo).
Variáveis preditoras (exemplos de perguntas):

1. “Como você avalia sua pesquisa?”
2. “Como você avalia sua redação acadêmica?”
3. “Como você avalia sua organização?”
4. “Como você avalia seu pensamento crítico?”
5. “Como você avalia sua metodologia?”
6. “Como você avalia sua comunicação oral?”
7. “Como você avalia seu gerenciamento de estresse?”
8. “Como você avalia sua ética acadêmica?”
9. “Como você avalia sua análise crítica?”
10. “Como você avalia sua argumentação?”

Tipo de opções de resposta:

Escala ordinal de três níveis, em formato de alternativa fechada, com variações de escrita, por exemplo:

- A) Boa
- B) Moderada
- C) Baixa

Variável-alvo (classe prevista):

RESULTADO – síntese global da autoavaliação, com categorias como:

- Boa
- Moderada / Moderado
- Baixa

Base 2 – Perfil emocional em relação ao TCC (Grupo 2)

Tema geral: ansiedade, motivação e percepção de risco em relação ao Trabalho de Conclusão de Curso (TCC).

Tamanho da base: 20 registros e 6 atributos (5 preditores + 1 variável-alvo).

Variáveis preditoras (exemplos de perguntas):

1. “Você se considera uma pessoa ansioso(a)?”
2. “Você se sente motivado(a) em relação ao TCC?”
3. “Sua autoconfiança é afetada na realização do TCC?”
4. “Você gerencia o estresse que pode surgir ao lidar com a complexidade do seu tema de pesquisa?”
5. “Você tem grandes medos ou preocupações em relação ao seu TCC?”

Tipo de opções de resposta:

Questões fechadas com três categorias principais:

- Sim
- Não
- Talvez

Variável-alvo (classe prevista):

RISCO – nível de risco associado à situação do estudante frente ao TCC, com categorias como:

- Boa (baixo risco)
- Moderada
- Ruim (alto risco)

Essa base permitiu treinar modelos para estimar o nível de risco do estudante em relação ao TCC, combinando informações sobre ansiedade, motivação, autoconfiança e estresse.

Base 3 – Condições de acesso, apoio e risco de reprovação no ENEM (Grupo 3)

Tema geral: condições materiais, sociais e emocionais de preparação para o ENEM e o risco percebido de reprovação.

Tamanho da base: 59 registros e 28 atributos (27 preditores + 1 variável-alvo).

Variáveis preditoras (exemplos de perguntas):

1. “Você possui acesso a materiais de estudo para se preparar para o Enem?”
2. “Você tem acesso a um local tranquilo para estudar?”
3. “Você recebe apoio de familiares ou amigos na sua preparação para o Enem?”
4. “Você possui recursos financeiros para investir em materiais de estudo adicionais?”
5. “Você tem acesso à internet para buscar informações e materiais de estudo?”
6. “Você consegue dedicar tempo diariamente à preparação para o Enem?”
7. “Você se sente motivado(a) e confiante em relação aos seus estudos para o Enem?”
8. “Você já participou de algum curso preparatório para o Enem?”
9. “Você recebe suporte emocional e psicológico durante sua preparação para o Enem?”
10. “Você consegue conciliar seus estudos para o Enem com outras responsabilidades, como trabalho ou cuidados familiares?”
11. “Você participa de grupos de estudo ou atividades coletivas relacionadas à preparação do Enem?”
12. “Você consegue manter uma alimentação saudável e equilibrada enquanto se prepara para o Enem?”
13. “Você acha que as condições da sua moradia influenciam na sua preparação para o Enem?”

Tipo de opções de resposta:

Predominantemente questões fechadas com três categorias:

- A) Sim B) Não C) Às vezes

Todas tratadas como categorias nominais ao alimentar os algoritmos de classificação.

Variável-alvo (classe prevista):

RISCO DE REPROVAÇÃO, com categorias como:

- Baixo
- Mediano (com variações de digitação, como MEDINO, MEDAINO, etc.)
- Alto

Nessa base, os modelos de classificação foram treinados para prever o risco de reprovação no ENEM a partir de diferentes condições de acesso a recursos, apoio social e rotina de estudos.

Base 4 – Ansiedade, apoio e probabilidade de desempenho na redação do ENEM (Grupo 4)

Tema geral: aspectos emocionais, apoio social e ambiente de estudo relacionados à redação do ENEM.

Tamanho da base: 30 registros e 17 atributos (16 preditores + 1 variável-alvo).

Variáveis preditoras (exemplos de perguntas):

1. “Você se sente ansioso(a) antes ou durante a redação do ENEM?”
2. “Em uma escala de 1 a 10, como você classificaria seu nível de ansiedade?”
3. “Como você avalia suas habilidades de escrita?”
4. “Você se sente confiante ao escrever uma redação?”
5. “Você já recebeu feedback positivo sobre suas redações?”
6. “Com que frequência você pratica a escrita de redações?”
7. “Você sente que está bem preparado(a) para a redação do ENEM?”
8. “Quem são as pessoas que mais te apoiam durante a preparação para o ENEM? (Marque todas que se aplicam)”
9. “Você sente que há muita pressão para obter uma boa nota na redação do ENEM?”
10. “Você já teve alguma experiência negativa em redações anteriores?”
11. “Como é o ambiente onde você costuma estudar?”
12. “Você acha que seu ambiente de estudo impacta sua capacidade de concentração e calma?”

Tipo de opções de resposta:

Combina diferentes formatos de resposta categórica:

Frequência: Sempre, Frequentemente, Às vezes, Raramente, Nunca;

Escala agrupada de ansiedade (1 a 10):

1–2 (baixo), 3–4 (moderado), 5–6 (médio), 7–8 (alto), 9–10 (muito alto);

Avaliação de habilidades: Ruim, Regular, Boa, Muito ruim;

Apoio social: categorias como Pais, Amigos, Professores, e combinações (p.ex., “Pais e Professores”);

Descrições de ambiente: “Tranquilo e organizado”, “Pouco tranquilo e desorganizado”, etc.

Variável-alvo (classe prevista):

Probabilidade de desempenho na redação, com três classes principais:

- Alto
- Moderado
- Baixo

Essa base favoreceu a discussão sobre como fatores emocionais e contextuais podem estar associados à probabilidade de um bom desempenho na redação.

Base 5 – Engajamento, organização e expectativa de desempenho no ENEM (Grupo 5)

Tema geral: consistência nos estudos, motivação, organização do tempo e expectativa de desempenho na prova.

Tamanho da base: 10 registros e 11 atributos (10 preditores + 1 variável-alvo).

Variáveis preditoras (exemplos de perguntas):

1. “Como você avalia sua consistência nos estudos até agora?”
2. “Quanto você tem revisado os conteúdos aprendidos?”
3. “Como você se sente em relação à sua preparação para as questões específicas da prova?”
4. “Qual é o seu nível de confiança em relação à prova de redação?”
5. “Como você lida com o estresse antes das provas?”
6. “Como você avalia sua participação em simulados e testes práticos?”
7. “Como você se sente em relação ao seu progresso desde o início da preparação?”
8. “Qual é o seu nível de motivação para estudar atualmente?”
9. “Como você avalia sua organização de tempo para os estudos?”
10. “Qual é a sua expectativa de desempenho na prova?”

Tipo de opções de resposta:

Predominância de escalas qualitativas do tipo:

- Boa, Mediana, Ruim
- Bem preparado(a), Mais ou menos preparado(a), Mal preparado(a);
- Confio plenamente, Um pouco inseguro(a), Não estou confiante;
- Controlando bem o estresse, Às vezes me afeta, Fico muito nervoso(a);
- Participação em simulados: “Fiz muitos e me saí bem”, “Fiz alguns, mas poderia ter feito mais”, “Não fiz ou fiz poucos”;
- Motivação: “Muito motivado(a)”, “Às vezes motivado(a)”, “Pouco ou nada motivado(a)”;
- Organização do tempo: “Muito bem organizado(a)”, “Mais ou menos organizado(a)”, “Desorganizado(a)”.

Variável-alvo (classe prevista):

MÉDIA TOTAL, categorizada em:

- Boa
- Mediana
- Ruim

Essa base foi usada para treinar modelos que relacionam engajamento e organização de estudos com uma síntese categórica do desempenho esperado.

Links das bases de dados elaboradas pelos estudantes

Bases:

<https://docs.google.com/spreadsheets/d/1sZw4voJt0Jx70DFWXx16J4Oxl8UUQYSH8WnBowVM3ZM/edit?usp=sharing>

APÊNDICE L – FORMULÁRIO AVALIATIVO ALGORITMO DE CLASSIFICAÇÃO

Formulário Avaliativo: Algoritmo de Classificação

Todas as alterações foram salvas no Google Drive

Enviar

25

Configurações

Total de pontos: 19

Seção 1 de 3

Formulário Avaliativo: Algoritmo de Classificação - CA (Acurácia - Accuracy)

Descrição do formulário

Nome completo

Texto de resposta curta

Turma *

☐ 3A

☐ 3B

Após a seção 1

Continuar para a próxima seção

Seção 2 de 3

Informações do Algoritmo e Base de Dados

Descrição (opcional)

1. Qual previsão você fez? (Nome do seu Dataset) *

Texto de resposta curta

2. Sua base de dados é com dados reais ou fictícios? *

☐ Dados reais

☐ Dados fictícios

3. Anexe sua base de dados no formato CSV. *

Adicionar arquivo

Ver pasta

4. Qual foi a acurácia (AC) do algoritmo Naïve Bayes? *

Texto de resposta curta

?

5. Qual foi a acurácia (AC) da árvore de decisão? *

Texto de resposta curta

?

6. Qual foi a acurácia (AC) do algoritmo de Aprendizagem por Regras? *

Texto de resposta curta

?

7. Qual foi a acurácia (AC) do algoritmo de Aprendizagem Baseada em Instâncias? *

Texto de resposta curta

?

8. Anexe os resultados em formato de print de tabelas ou gráficos do melhor desempenho que obteve. *

Adicionar arquivo

Ver pasta

Após a seção 2

Continuar para a próxima seção

Seção 3 de 3

Feedback sobre o Formulário Avaliativo

Por favor, responda às seguintes perguntas sobre a experiência com o exercício, utilizando a escala de concordância: **Discordo totalmente**, **Discordo**, **Concordo parcialmente**, **Concordo**, **Concordo plenamente**.

?

1. O Programa Orange não ajudou a entender os algoritmos *

☐ Discordo totalmente

☐ Discordo

☐ Concordo parcialmente

☐ Concordo

☐ Concordo plenamente

?

2. Todos do meu grupo estavam engajados na realização da atividade *

☐ Discordo totalmente

☐ Discordo

☐ Concordo parcialmente

☐ Concordo

☐ Concordo plenamente

?

3. Todos do seu grupo contribuíram nessa atividade? *

☐ Discordo totalmente

☐ Discordo

☐ Concordo parcialmente

☐ Concordo

☐ Concordo plenamente

?	4. Você entendeu o assunto ao ponto de conseguir analisar uma base de dados com Orange * ☐ Discordo totalmente ☐ Discordo ☐ Concordo parcialmente ☐ Concordo ☐ Concordo plenamente	Tt   
?	5. Usei o celular durante as aulas, porque não estava entendendo nada * ☐ Discordo totalmente ☐ Discordo ☐ Concordo parcialmente ☐ Concordo ☐ Concordo plenamente	Tt   
?	6. Na sua futura carreira profissional, você acredita que vai precisar resolver problemas semelhantes a este? * ☐ Discordo totalmente ☐ Discordo ☐ Concordo parcialmente ☐ Concordo ☐ Concordo plenamente	Tt   
?	7. Quanto por cento você se considera interessado neste componente curricular? * ☐ 0% a 20% ☐ 21% a 40% ☐ 41% a 60% ☐ 61% a 80% ☐ 81% a 100%	Tt   

?

8. Quanto por cento você se considera participativo nas atividades de sala de aula? *

☐ 0% a 20%

☐ 21% a 40%

☐ 41% a 60%

☐ 61% a 80%

☐ 81% a 100%

?

9. Quantas vezes você tirou dúvidas sobre algoritmos de classificação com o professor? *

☐ 0 vezes

☐ 1 a 2 vezes

☐ 3 a 5 vezes

☐ 6 a 10 vezes

☐ Mais de 10 vezes

?

10. Você considera que este assunto é tão difícil que vai além dos seus conhecimentos atuais? *

☐ Discordo totalmente

☐ Discordo

☐ Concordo parcialmente

☐ Concordo

☐ Concordo plenamente

?

Tt







Tt







Tt







Tt

Tt







Filtro de tópicos

Seção - 04 Algoritmos de regressão


⋮




APÊNDICE N – MATERIAL EM SLIDE – ALGORITMO DE REGRESSÃO LINEAR

REGRESSÃO

- Gastos propaganda (x) -> valor de venda (y)
- Temperatura, umidade e pressão do ar (x) -> velocidade do vento (y)
- Fatores externos (x) -> valor do dólar (y)
- Resultados do exame (x) -> probabilidade de um paciente sobreviver
- (y) Risco de investimento
- Gastos no cartão de crédito, histórico (x) -> limite (y)
- Valores anteriores (x) -> valores de produtos (y)



REGRESSÃO LINEAR



APÊNDICE O – CONJUNTO DE DADOS PARA ATIVIDADES PRÁTICAS – ALGORITMO REGRESSÃO LINEAR

Conjunto de dados - Automóvel


[Conjuntos de dados](#)
[Contribuir com o conjunto de dados](#)
[Sobre nós](#)

[Conecte-se](#)



Automóvel

Doador em 18/05/1987

Do anuário automotivo de Ward de 1985.

Características do conjunto de dados	Área temática	Tarefas associadas
Multivariado	Outro	Regressão
Tipo de recurso	# Instâncias	# Características
Catégorico, Inteiro, Real	205	25

Informações do conjunto de dados

Informações adicionais
Este conjunto de dados consiste em três tipos de entidades: (a) a especificação de um automóvel em termos de várias características, (b) sua classificação de risco de seguro atribuída e (c) suas perdas normalizadas em uso em comparação com outros carros. A segunda classificação corresponde ao grau em que o automóvel é mais arriscado do que seu preço indica. Os...

[MOSTRAR MAIS](#)

Possui valores ausentes?
Sim

Tabela de variáveis

Informações adicionais sobre variáveis

Desempenho do modelo de referência

Arquivos de conjunto de dados

Artigos que citam este conjunto de dados

[DOWNLOAD \(8,3 KB \)](#)
[IMPORTAR EM PYTHON](#)
[CITAR](#)

8 citações
203270 visualizações

Palavras-chave
automóvel

Criadores
Jeffrey Schlimmer

DOI
10.24432/C5801C

Licença
Este conjunto de dados está licenciado sob uma licença **Creative Commons Atribuição 4.0 Internacional** (CC BY 4.0).
Isso permite o compartilhamento e a adaptação dos conjuntos de dados para qualquer finalidade, desde que os devidos créditos sejam atribuídos.



O PROJETO
Sobre nós
LMC
Fundação Nacional de Ciência

NAVEGAÇÃO
Lar
Visualizar conjuntos de dados
Doe um conjunto de dados

LOGÍSTICA
Contato
Aviso de Privacidade
Solicitação de recurso ou relatório de erro

Fonte: <https://archive.ics.uci.edu/dataset/10/automobile>

APÊNDICE P –ATIVIDADE PRÁTICA - ALGORITMO REGRESSÃO LINEAR

Atividade Avaliativa - Regressão: Previsão de Preços de Casas no Orange

Objetivo: Usar uma base real de dados sobre casas para treinar um modelo de regressão no Orange e prever o preço dos imóveis, entendendo:

- como separar dados em treino e teste;
- como configurar um algoritmo de regressão;
- como ler as métricas de desempenho.

Base de dados: Arquivo house_prices.csv, com informações como:

- número de quartos e banheiros;
- metragem da casa e do terreno;
- idade do imóvel;
- outros atributos numéricos.

A coluna alvo (target) é o preço da casa.

Ferramenta

- Software: Orange Data Mining
- Widget para dividir treino/teste: Data Sampler documentação:
<https://docs.biolab.si/3/visual-programming/widgets/data/datasampler.html>

Roteiro da atividade

1. Carregar e visualizar os dados
 - Use o widget File para abrir house_prices.csv.
 - Conecte a um Data Table e confira as colunas e a coluna de preço.
2. Separar em treino e teste
 - Insira o Data Sampler após o File.
 - Defina, por exemplo, 70% treino e 30% teste.
3. Montar o modelo
 - Escolha um regressor (Linear Regression).
 - Monte o fluxo: File, Data Sampler, Regressor e Test & Score.
 - Deixe preço como Target.
4. Avaliar o desempenho
 - No Test & Score, observe: MAE, RMSE e R^2 .

Entrega

Responda às questões da atividade no Google Forms anexado no Google Classroom

APÊNDICE Q –FORMULARIO AVAL - ALGORITMO REGRESSÃO LINEAR

Exercício - Algoritmo de Re:

Enviar

Perguntas Respostas 35 Configurações

Total de pontos: 17

Seção 1 de 5

Exercício - Algoritmo de Regressão

B *I* U

Descrição do formulário

Nome completo

Resposta curta

Texto de resposta curta

☒ Respostas corretas (1 ponto)

Obrigatória ☒

Turma *

☐ 3A

☐ 3B

Após a seção 1 Continuar para a próxima seção

Seção 2 de 5

Conceitos Teóricos de Algoritmo de Regressão

Descrição (opcional)

1. Qual é o objetivo do algoritmo de regressão? *

☐ a) Classificar dados em diferentes categorias

☐ b) Encontrar padrões de associação entre variáveis

☐ c) Prever valores contínuos com base em variáveis independentes

☐ d) Agrupar dados em clusters semelhantes

☐ e) Reduzir a dimensionalidade dos dados

?

2. Qual função é utilizada no algoritmo de regressão? *

☐ a) Função sigmoide

☐ b) Função de custo

☐ c) Função linear

☐ d) Função de ativação

☐ e) Função de perda

?

3. Os pontos no gráfico de regressão significam o que? *

☐ a) Os erros do modelo

☐ b) Os valores dos dados reais

☐ c) As variáveis independentes

☐ d) As previsões do modelo

☐ e) Os resíduos do modelo

?

4. Os pontos mais próximos da linha de regressão linear significam o que? *

☐ a) Dados menos importantes

☐ b) Previsões com maior erro

☐ c) Valores que foram ignorados no modelo

☐ d) Valores que se ajustam melhor ao modelo

☐ e) Valores fora da amostra de treinamento

?

Após a seção 2 Continuar para a próxima seção

Seção 3 de 5

Implementação Prática com Orange

Descrição (opcional)

?

1. O arquivo recebido para esta atividade contém que tipo de dados? *

☐ a) Dados de vendas de carros

Tt

Tt

Tt

Tt

Tt

[illegible]

4. Qual foi o nível de participação que teve nas aulas de algoritmo de regressão?

☐ a) Nenhuma participação

☐ b) Pouca participação

☐ c) Participação moderada

☐ d) Muita participação

☐ e) Participação total

Após a seção 4 Continuar para a próxima seção

Seção 5 de 5

Desempenho do Algoritmo na Base de Dados (house_prices.csv)

Descrição (opcional)

1. Envie um print do modelo com o algoritmo de regressão aplicado à base de dados.

Adicionar arquivo

Ver pasta

2. Envie um print do resultado da aprendizagem de máquina do algoritmo de regressão.

Adicionar arquivo

Ver pasta

APÊNDICE R – ESTRUTURA DO CLASSROOM- ALGORITMO DE AGRUPAMENTO

Sala de Aula

>

3ª Série B

inteligência artificial

Mural

Atividades

Pessoas

Notas

Filtro de tópicos

Seção 05 - Algoritmo de agrupame...

Seção 05 - Algoritmo de agrupamento

Rayllon Soares postou um novo material: 1 - Introdução a algoritmo K-means

Item postado: 16 de jul. de 2024 (editado: 20 de jul. de 2024)

Introdução a algoritmo K-...

PDF

Adicionar comentário

Rayllon Soares postou uma nova atividade: 2. Exercíc... Data de entrega: 19 de jul. de 2024

Item postado: 16 de jul. de 2024 (editado: 23 de out. de 2024)

O objetivo desta tarefa é utilizar a base de dados sobre cartão de crédito (credit_card_clients.csv) para agrupar os gastos das pessoas no cartão de crédito (fatura do cartão) com o limite disponibilizado pelo banco.

0

Entregue

0

Pendentes

20

Com nota

Exercício de Agrupamento

Google Formulários

credit_card_clients.csv

CSV

Adicionar comentário

APÊNDICE S – BASE ÍRIS


Conjuntos de dados Contribuir com o conjunto de dados Sobre nós  [Conecte-se](#)


Íris
Doado em 30/06/1988

 **DOWNLOAD** (3,7 KB)

 **IMPORTAR EM PYTHON**

CITAR

352 citações
1203021 visualizações

Palavras-chave
ecologia

Características do conjunto de dados
Tabular

Área temática
Biologia

Tarefas associadas
Classificação

Tipo de recurso
Real

Instâncias
150

Características
4

Informações do conjunto de dados

O que representam as instâncias neste conjunto de dados?
Cada instância é uma planta.

Informações adicionais
Este é um dos primeiros conjuntos de dados usados na literatura sobre métodos de classificação e amplamente utilizado em estatística e aprendizado de máquina. O conjunto de dados contém 3 classes com 50 instâncias cada, onde cada classe se refere a um tipo de planta de íris. Uma classe é linearmente separável das outras duas; estas últimas não são ...
MOSTRAR MAIS

Possui valores ausentes?
Não

Criadores
RA Fisher

DOI
10.24432/CS6C76

Licença
Este conjunto de dados está licenciado sob uma licença **Creative Commons Atribuição 4.0 Internacional** (CC BY 4.0).
Isso permite o compartilhamento e a adaptação dos conjuntos de dados para qualquer finalidade, desde que os devidos créditos sejam atribuídos.

Artigo introdutório

Tabela de variáveis

Desempenho do modelo de referência

Arquivos de conjunto de dados

Artigos que citam este conjunto de dados


O PROJETO
Sobre nós
LMC
Fundação Nacional de Ciência

NAVEGAÇÃO
Lar
Visualizar conjuntos de dados
Doe um conjunto de dados

LOGÍSTICA
Contato
Aviso de Privacidade
Solicitação de recurso ou relatório de erro

<https://archive.ics.uci.edu/dataset/53/iris>









APÊNDICE T – MATERIAL EM SLIDE- ALGORITMO DE AGRUPAMENTO

AGRUPAMENTO

O objetivo do algoritmo de agrupamento (ou clustering) é **identificar e agrupar subconjuntos de dados em grupos ou clusters**, onde os objetos dentro de um mesmo grupo são mais semelhantes entre si do que com os objetos de outros grupos.

AGRUPAMENTO

- Segmentação de mercado
- Encontrar grupos de clientes que irão comprar um produto (mala direta)
- Agrupamento de documentos/notícias
- Agrupamento de produtos similares
- Perfis de clientes (Netflix)
- Análise de redes sociais





AGRUPAMENTO COM K-MEANS

iris 4.118 150 3 categorical k-means



Iris Versicolor Iris Setosa Iris Virginica



APÊNDICE U – FORMULÁRIO AVALIATIVO - ALGORITMO DE AGRUPAMENTO

Avaliação: AlgoritmoAgrupamento

Todas as alterações foram salvas no Google Drive

Enviar

Perguntas

Respostas 26

Configurações

Total de pontos: 7

Seção 1 de 2

Avaliação: Algoritmo de Agrupamento

Descrição do formulário

Nome

Texto de resposta curta

Turma

☐ 3A

☐ 3B

Após a seção 1

Continuar para a próxima seção

Seção 2 de 2

Exercício de Agrupamento

Descrição (opcional)

1. Qual é o objetivo principal de um algoritmo de agrupamento?

☐ A) Classificar dados em categorias predefinidas.

☐ B) Prever valores futuros com base em dados históricos.

☐ C) Agrupar dados em subconjuntos onde os itens dentro de cada grupo são mais semelhantes entre si.

☐ D) Melhorar a precisão de um modelo de aprendizado supervisionado.


2. Qual dos seguintes algoritmos é um exemplo de algoritmo de agrupamento?

☐ A) Regressão Linear

☐ B) K-means

☐ C) Algoritmo de Floresta Aleatória

APÊNDICE V – PLATAFORMA DE SIMULAÇÃO - ALGORITMO DE AGRUPAMENTO




[Blog](#)
[Sobre](#)
[Contato](#)
[Estou me sentindo com sorte.](#)

Visualizando o agrupamento K-Means

19 de janeiro de 2014

Imagine que você plotasse a largura e a altura da tela de todos os dispositivos que acessam este site. Provavelmente, você descobriria que os pontos formam três grupos: um com dimensões pequenas (smartphones), um com dimensões moderadas (tablets) e um com dimensões grandes (laptops e desktops). Fazer um algoritmo reconhecer esses grupos de pontos sem ajuda é chamado de *agrupamento (clustering)*. Para entender melhor como as técnicas comuns de agrupamento funcionam (e como não funcionam), criei algumas visualizações que ilustram três abordagens fundamentalmente diferentes. Esta publicação, a primeira desta série de três, aborda o algoritmo k-means. Para começar, clique em uma estratégia de inicialização abaixo:



[Reiniciar](#)
[Adicionar Centroide](#)


[Reassign Points](#)

Algoritmo K-Means

O algoritmo k-means baseia-se na ideia de que cada ponto em um cluster deve estar próximo ao centro desse cluster. Ele funciona assim: primeiro, escolhemos k, o número de clusters que queremos encontrar nos dados. Em seguida, os centros desses k clusters, chamados *centroides*, são inicializados de alguma forma (discutida posteriormente).

APÊNDICE W - PLATAFORMA OPENWEATHERMAP UTILIZADA COMO FONTE DE DADOS (API) NO PROJETO DE ANÁLISE CLIMÁTICA POR REGRESSÃO

Este apêndice apresenta a plataforma OpenWeatherMap, utilizada como fonte de dados meteorológicos por meio de sua API no projeto que envolveu análise climática com modelagem por regressão (Ciclo 3 – Regressão). A partir das requisições à API, foram obtidas informações em formato estruturado (ex.: JSON), contemplando variáveis como temperatura, pressão atmosférica, umidade, vento e precipitação, as quais foram tratadas e organizadas em dataset para subsidiar as etapas de seleção de atributos, definição de variáveis dependente/independentes e ajuste do modelo de regressão. A plataforma também foi utilizada para consulta e verificação das condições meteorológicas por localidade, apoiando a consistência dos dados empregados na análise.



Fonte: <https://openweathermap.org/>

APÊNDICE X – DISTRIBUIÇÃO DO USO DE FERRAMENTAS DIGITAIS POR FASE DA INTERVENÇÃO

Este apêndice apresenta a frequência de utilização das ferramentas digitais empregadas ao longo das fases da intervenção didática, considerando a intensidade de uso por etapa (Abertura, Ciclos 1 a 4 e Culminância). A pontuação segue a escala: 0 (Nenhuma), 1 (Baixo), 2 (Moderado), 3 (Alto).

Tabela - Frequência de uso das ferramentas digitais por fase da intervenção

	Google Classroom	Google Slides	Google Forms	Google Colab	Orange Data Mining	Visual Studio Code	Google Sheets	Google Docs
Abertura	0	3	1	0	0	0	0	0
Ciclo 1 Busca heurística	2	2	1	3	0	2	0	0
Ciclo 2 Classificação	3	2	2	0	3	0	2	0
Ciclo 3 Regressão	2	2	1	0	3	0	2	0
Ciclo 4 Agrupamento	2	3	1	0	3	0	2	0
Culminância	1	2	2	0	0	3	3	3
Soma	10	14	8	3	9	5	9	3
%	16,40%	23%	13,10%	4,90%	14,80%	8,20%	14,80%	4,90%

0 - Nenhuma
1 - Baixo
2 - Moderado
3 - Alto

Fonte: Elaboração própria (2025).