

Ensino de Aprendizagem de Máquina em um Curso Técnico: Uma Intervenção Pedagógica com Aprendizagem Baseada em Problemas

Rayllon S. Pessoa¹, Lafayette B. Melo¹

Programa de Pós-Graduação em Tecnologia da Informação
Instituto Federal da Paraíba (IFPB) - Campus João Pessoa
Av. Primeiro de Maio, 720 – Jaguaribe
João Pessoa – PB – Brasil – CEP 58015-435

rayllon.pessoa@academico.ifpb.edu.br,

lafayette.melo@ifpb.edu.br.

Abstract. *This work investigates the teaching of Machine Learning in Professional and Technological Education through Problem-Based Learning (PBL). The study was conducted in a technical high school course at a public school in Paraíba, Brazil, with an intervention structured in content-based cycles. The results indicate increased student engagement, improved conceptual understanding, and the development of relevant skills. It is concluded that PBL supports a more active and contextualized learning process in Artificial Intelligence education.*

Resumo. *Este trabalho investiga o ensino de Aprendizagem de Máquina na Educação Profissional e Tecnológica por meio da Aprendizagem Baseada em Problemas (ABP). A pesquisa foi realizada em um curso técnico integrado ao ensino médio em uma escola pública da Paraíba, com intervenção estruturada em ciclos de conteúdos. Os resultados indicam maior engajamento, melhoria na compreensão conceitual e desenvolvimento de competências. Conclui-se que a ABP favorece uma aprendizagem mais ativa e contextualizada no ensino de Inteligência Artificial.*

1. Introdução

Nos últimos anos, a Inteligência Artificial (IA) tem assumido papel cada vez mais relevante no avanço de tecnologias aplicadas à automação, à análise de dados e à personalização de serviços, ampliando sua presença em diferentes setores da sociedade e intensificando sua participação na transformação digital contemporânea (RUSSELL; NORVIG, 2016). Nesse cenário, a crescente demanda por profissionais qualificados reforça a necessidade de estratégias educacionais capazes de tornar esses conhecimentos mais acessíveis, práticos e significativos no contexto escolar.

No âmbito da Educação Profissional e Tecnológica, especialmente em cursos técnicos integrados ao ensino médio, o ensino de IA apresenta desafios recorrentes, como baixo engajamento discente, dificuldades na articulação entre teoria e prática e lacunas no desenvolvimento de competências essenciais, a exemplo do pensamento crítico, da tomada de decisão e da resolução de problemas em situações reais. Esses

obstáculos se tornam ainda mais evidentes no ensino de Aprendizagem de Máquina, subárea da IA que exige a mobilização integrada de fundamentos conceituais, interpretação de dados e implementação de modelos computacionais (MITCHELL, 1997; JAMES et al., 2013).

Embora a Aprendizagem de Máquina tenha se tornado uma área estratégica para a formação em computação, seu ensino ainda é frequentemente conduzido sob uma lógica conteudista, pouco conectada a problemas concretos e com uso ainda incipiente de metodologias ativas, inclusive no ensino técnico (BITTENCOURT; RODRIGUES; CRUZ, 2013; PONTES et al., 2022). Diante disso, torna-se pertinente investigar abordagens pedagógicas que favoreçam uma aprendizagem mais aplicada, contextualizada e alinhada às demandas contemporâneas da formação técnica.

Entre essas abordagens, a Aprendizagem Baseada em Problemas (ABP) apresenta-se como uma alternativa promissora por organizar o ensino a partir de situações-problema contextualizadas, deslocando o foco da simples transmissão de conteúdos para a investigação, a colaboração e a construção ativa do conhecimento (BARROWS, 1986; WOODS, 1994). No contexto da computação, essa perspectiva é especialmente relevante, pois permite aproximar os conteúdos técnicos de situações reais de aplicação, favorecendo a compreensão conceitual e o desenvolvimento de soluções com significado.

Assim, discutir o ensino de Aprendizagem de Máquina no ensino técnico também significa refletir sobre como formar estudantes mais críticos, autônomos e aptos a atuar em uma sociedade cada vez mais mediada por sistemas computacionais e decisões baseadas em dados.

Diante desse contexto, este estudo busca responder à seguinte questão de pesquisa: em que medida a Aprendizagem Baseada em Problemas contribui para o ensino de Aprendizagem de Máquina no contexto da Educação Profissional e Tecnológica? Assim, o objetivo deste trabalho é analisar os efeitos da implementação da Aprendizagem Baseada em Problemas no ensino de Aprendizagem de Máquina em um curso técnico integrado ao ensino médio, considerando o engajamento, o desempenho e o desenvolvimento de competências dos estudantes na resolução de problemas contextualizados.

2. Fundamentação Teórica

2.1 Educação Profissional Técnica e formação para a sociedade digital

A Educação Profissional e Tecnológica no Brasil é marcada por um percurso histórico de reformas e reconfigurações legais que reforçam, progressivamente, a integração entre formação geral e formação técnica, especialmente no ensino médio (BRASIL, 2017). Mais recentemente, a consolidação dos itinerários formativos e da Formação Técnica e Profissional evidencia a necessidade de práticas pedagógicas que promovam aprendizagem significativa, protagonismo discente e resolução de problemas contextualizados.

Nesse sentido, formar estudantes em computação, e particularmente em IA, não significa apenas capacitá-los tecnicamente para o mercado, mas também prepará-los para compreender criticamente o papel das tecnologias digitais na sociedade. Assim, o ensino técnico de IA precisa ser pensado não apenas como qualificação profissional,

mas como dimensão formativa vinculada à cidadania digital, à autonomia intelectual e à inserção social qualificada.

2.2 Aprendizagem Baseada em Problemas

A Aprendizagem Baseada em Problemas, ou Problem-Based Learning (PBL), é uma metodologia ativa surgida na década de 1960, na Universidade de McMaster, sob liderança de Howard S. Barrows, inicialmente no campo da formação médica (BARROWS, 1986). Em sua formulação clássica, o problema não é apresentado como exemplo ilustrativo posterior ao conteúdo, mas como ponto de partida do processo de aprendizagem, levando os estudantes a identificar o que já sabem, o que precisam aprender e quais caminhos investigativos devem seguir para compreender e enfrentar a situação proposta.

Posteriormente, Woods (1994) ampliou e sistematizou essa abordagem em áreas como Engenharia, reforçando seu caráter construtivista e colaborativo. Nessa perspectiva, o estudante assume papel ativo na construção do conhecimento, enquanto o professor atua como tutor ou facilitador, orientando o raciocínio, problematizando hipóteses e sustentando o processo investigativo, em vez de simplesmente transmitir respostas prontas.

Na literatura da área, a ABP é frequentemente associada ao desenvolvimento de competências como autonomia, pensamento crítico, trabalho em equipe, tomada de decisão e capacidade de articular teoria e prática em situações autênticas (SAVERY, 2015; DOLMANS et al., 2005; HMELO-SILVER, 2004). Em cursos de Computação e Engenharia, estudos apontam que a abordagem contribui para maior protagonismo discente, integração entre conteúdos e resolução de problemas contextualizados, ainda que sua implementação imponha desafios relacionados ao tempo de planejamento, à mediação docente e à heterogeneidade dos conhecimentos prévios dos estudantes (BITTENCOURT; RODRIGUES; CRUZ, 2013; RIBEIRO; LIMA, 2025).

No ensino técnico integrado, a ABP mostra-se especialmente relevante por favorecer uma formação orientada à mobilização de conhecimentos em contextos concretos, aproximando o estudante de situações semelhantes às que enfrentará na prática profissional e social. Tal característica é coerente com a própria lógica da Educação Profissional e Tecnológica, que exige a articulação entre fundamentos conceituais, competências técnicas e resolução de problemas reais.

2.3 Ensino de Inteligência Artificial e Aprendizagem de Máquina

A Inteligência Artificial pode ser compreendida, em sentido amplo, como a área da Ciência da Computação dedicada ao desenvolvimento de sistemas capazes de executar tarefas tradicionalmente associadas à inteligência humana, como perceber, raciocinar, aprender e decidir (RUSSELL; NORVIG, 2016). Historicamente, a consolidação do campo está associada à proposta de McCarthy et al. (1955), que sustentava a hipótese de que aspectos da inteligência poderiam ser descritos de forma suficientemente precisa para serem simulados por máquinas.

Dentro desse campo, a Aprendizagem de Máquina destaca-se como subárea voltada ao desenvolvimento de algoritmos capazes de aprender padrões a partir de dados. Mitchell (1997) organiza esse domínio em paradigmas clássicos, como aprendizado supervisionado e não supervisionado, enquanto James et al. (2013)

reforçam a importância da modelagem estatística e da interpretação de dados para a compreensão de tarefas como classificação, regressão e agrupamento. Essa delimitação é particularmente importante do ponto de vista didático, pois permite estruturar o ensino a partir de problemas e fluxos de trabalho concretos, e não apenas de definições abstratas.

No contexto educacional, a literatura aponta que o ensino de IA exige adaptações curriculares e metodológicas, sobretudo porque os estudantes apresentam níveis distintos de domínio em matemática, lógica e programação, o que interfere diretamente na apropriação dos conteúdos. Além disso, o ensino tradicional, centrado na exposição de conceitos, tende a ser insuficiente para preparar os estudantes para os desafios práticos e interdisciplinares envolvidos no trabalho com IA (SHEN et al., 2010).

Nesse cenário, a combinação entre IA e metodologias ativas torna-se particularmente relevante. Ao trabalhar com problemas contextualizados, dados reais, escolha de modelos e interpretação de resultados, o ensino de Aprendizagem de Máquina pode favorecer não apenas a compreensão técnica, mas também o desenvolvimento de uma postura mais crítica diante das aplicações da IA.

2.4 Aplicação da ABP no ensino de IA

A aplicação da ABP no ensino de IA é considerada promissora porque aproxima o estudante de um fluxo de trabalho semelhante ao enfrentado em problemas reais: delimitação de objetivos, análise do contexto, interpretação de dados, escolha de modelos, implementação, validação e comunicação dos resultados (SAVERY, 2015). Nesse processo, a aprendizagem deixa de se restringir à memorização de algoritmos e passa a envolver investigação, argumentação e tomada de decisão técnica.

Estudos recentes têm demonstrado essa potencialidade em cursos da área de Computação. De Barros, Paiva e Hayashi (2023), por exemplo, relatam uma experiência em que estudantes desenvolveram modelos de aprendizagem de máquina para um problema real de previsão, articulando ABP e práticas ágeis, com resultados positivos em desempenho e desenvolvimento de competências como resolução de problemas, comunicação e trabalho em equipe. Em linha semelhante, pesquisas em Data Science e alfabetização em IA mostram que a abordagem favorece engajamento e aprendizagem quando os estudantes dispõem de suporte pedagógico, artefatos intermediários e mediação adequada (HUANG; HSU, 2024; SU, 2025).

Apesar desses ganhos, a literatura também alerta que a ABP em IA não pode ser implementada como simples atividade aberta sem orientação. Em conteúdos de maior complexidade, a ausência de mediação e de suportes graduais pode produzir sobrecarga cognitiva e dificultar a aprendizagem, especialmente entre estudantes iniciantes (KIRSCHNER; SWELLER; CLARK, 2006). Por isso, a efetividade da abordagem depende de planejamento cuidadoso, desenho adequado dos problemas, apoio docente e instrumentos de acompanhamento coerentes com o percurso formativo.

3. Metodologia

3.1 Delineamento da pesquisa e abordagem metodológica

Este estudo caracteriza-se como uma pesquisa aplicada, com abordagem qualitativa e apoio de dados quantitativos, desenvolvida no contexto da Educação Profissional e Tecnológica. O delineamento metodológico adotado consiste em uma intervenção pedagógica estruturada com base na Aprendizagem Baseada em Problemas (ABP), visando analisar sua contribuição para o ensino de Aprendizagem de Máquina em um curso técnico integrado ao ensino médio.

A opção por uma abordagem qualitativa justifica-se pela necessidade de compreender o processo de aprendizagem em sua complexidade, considerando aspectos como engajamento, interação e desenvolvimento de competências. Os dados quantitativos, por sua vez, foram utilizados como apoio para análise de desempenho e percepção dos estudantes, permitindo maior robustez interpretativa.

A intervenção foi concebida com base no modelo de ABP proposto por Barrows (1986), que organiza o processo de aprendizagem a partir da resolução de problemas como eixo central, promovendo a construção ativa do conhecimento.

3.2 Contexto, participantes e universo da pesquisa

A pesquisa foi realizada em uma escola pública da rede estadual, no contexto de um curso técnico integrado ao ensino médio, envolvendo uma turma de estudantes. Os participantes são estudantes do ensino médio inseridos em uma proposta de formação que articula conhecimentos gerais e formação técnica.

O contexto institucional caracteriza-se por uma proposta de educação integral, com foco no desenvolvimento de competências acadêmicas, técnicas e socioemocionais. Nesse cenário, o ensino de computação, especialmente conteúdos relacionados à Inteligência Artificial, assume papel relevante na formação dos estudantes.

A escolha desse contexto justifica-se pela necessidade de investigar estratégias pedagógicas que tornem o ensino de Aprendizagem de Máquina mais acessível e significativo em ambientes de ensino técnico, considerando a diversidade de conhecimentos prévios dos estudantes.

3.3 Desenho da intervenção baseada em PBL

A intervenção pedagógica foi estruturada em ciclos de aprendizagem, organizados de forma progressiva, contemplando conceitos fundamentais da Aprendizagem de Máquina. Esses ciclos abordaram conteúdos relacionados à busca heurística, classificação, regressão e agrupamento, permitindo uma evolução gradual da complexidade conceitual.

Cada ciclo foi desenvolvido com base nas etapas da Aprendizagem Baseada em Problemas, conforme descrito por Barrows (1986) e Woods (1994), incluindo a apresentação de um problema inicial, a discussão em grupo, o levantamento de hipóteses, a definição de objetivos de aprendizagem, a investigação orientada e a construção de soluções.

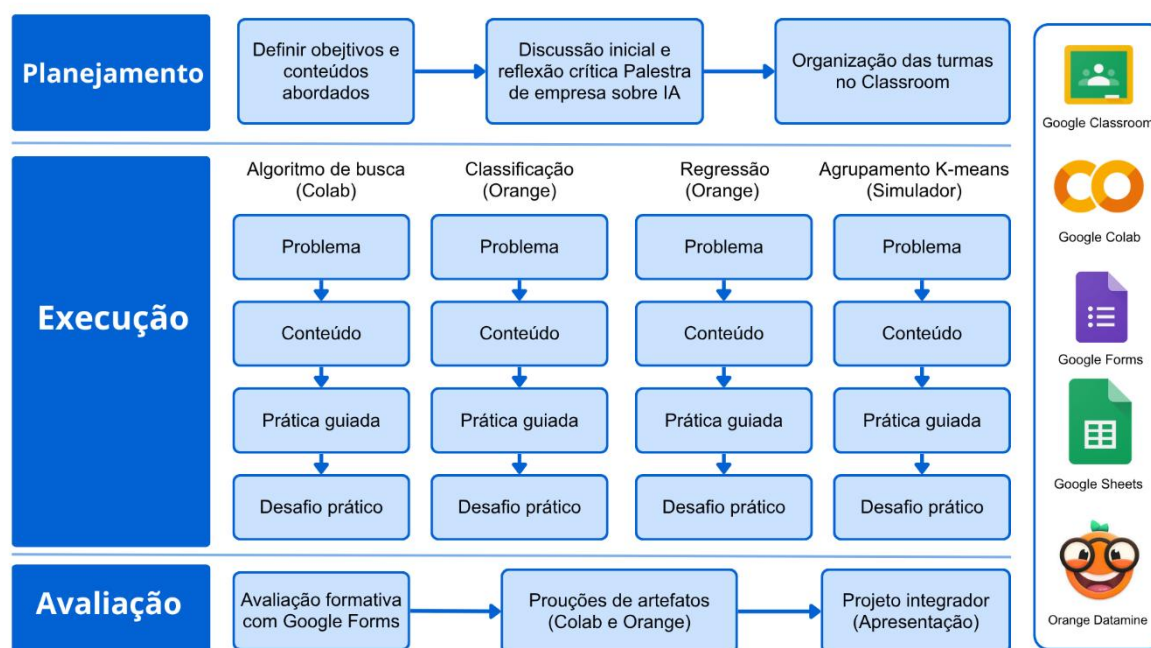


Figura 1 — Estrutura da intervenção

Durante o desenvolvimento das atividades, foram utilizadas diferentes ferramentas computacionais, incluindo a linguagem Python, em ambiente Google Colab, e a ferramenta Orange Data Mining. Essa combinação permitiu articular implementação prática e visualização de modelos, favorecendo a compreensão dos conceitos de Aprendizagem de Máquina.

A escolha das ferramentas considerou a necessidade de reduzir barreiras técnicas iniciais, permitindo que os estudantes se concentrassem na compreensão conceitual e na resolução dos problemas propostos.

3.4 Aplicação do Estudo

A intervenção foi conduzida por meio de uma proposta pedagógica fundamentada na Aprendizagem Baseada em Problemas (ABP), conforme o modelo clássico proposto por Howard S. Barrows, estruturado em sete etapas: apresentação do problema, identificação de conhecimentos prévios, levantamento de hipóteses, definição de objetivos de aprendizagem, estudo autogerido, síntese das informações e avaliação do processo. A intervenção foi organizada em ciclos progressivos, nos quais essas etapas foram operacionalizadas de forma integrada aos conteúdos de Inteligência Artificial e Aprendizagem de Máquina, ao longo do período letivo.

Tabela 1. Cronograma da intervenção pedagógica baseada na Aprendizagem Baseada em Problemas.

Fase	Período	CH	Atividade	Conteúdo
Abertura	20/02	2h	Introdução à IA e apresentação do PBL	Visão geral
Ciclo 1	26/02–15/03	7h	Problemas de roteamento (Python)	Busca heurística
Ciclo 2	18/03–05/04	7h	Modelos de classificação	Classificação

			(Orange)	
Ciclo 3	08/04–26/04	7h	Problemas de previsão (Orange)	Regressão
Ciclo 4	29/04–17/05	7h	Agrupamento de dados (k-means)	Agrupamento
Culminância	20/05	3h	Apresentação dos projetos	Integração

A abertura da intervenção ocorreu com uma atividade de contextualização, incluindo palestra com profissional da área de tecnologia e apresentação da proposta metodológica, buscando engajar os estudantes a partir de problemas reais do mercado. Em seguida, iniciaram-se os ciclos de aprendizagem. No primeiro ciclo, voltado à busca heurística, foram explorados algoritmos como Busca Gulosa e A*, utilizando linguagem Python em ambiente de computação interativa. Os estudantes analisaram problemas de caminho mínimo e tomada de decisão, formulando hipóteses e testando soluções com base em diferentes estratégias de busca.

No segundo ciclo, direcionado à classificação, foram trabalhadas técnicas como Naïve Bayes, Árvore de Decisão, k-Nearest Neighbors e indução de regras, com apoio da ferramenta Orange Data Mining. Os estudantes manipularam bases de dados reais e simuladas, realizando etapas de preparação, treinamento e avaliação de modelos, com ênfase na interpretação de métricas como acurácia e matriz de confusão. As atividades seguiram a lógica da ABP, com investigação orientada e construção coletiva do conhecimento.

O terceiro ciclo abordou problemas de regressão, com foco na regressão linear, também utilizando o ambiente Orange. Os estudantes analisaram relações entre variáveis e construíram modelos preditivos, compreendendo conceitos como tendência, ajuste de curva e erro. Já o quarto ciclo concentrou-se em técnicas de agrupamento, especialmente o algoritmo k-means, explorando a identificação de padrões em dados não rotulados e a segmentação de informações.

Ao longo de todos os ciclos, foram promovidos momentos de discussão, validação de hipóteses e socialização dos resultados, culminando no desenvolvimento de projetos integradores aplicados a problemas reais ou contextualizados. A finalização da intervenção envolveu a apresentação dos projetos e reflexão sobre o processo de aprendizagem, considerando aspectos conceituais, técnicos e colaborativos. A avaliação ocorreu de forma contínua, por meio de instrumentos formativos que contemplaram o desempenho dos estudantes em cada etapa do processo, bem como a participação e a autonomia na construção do conhecimento.

3.5 Instrumentos de Coleta e Procedimentos de Análise

A coleta de dados foi realizada por meio de múltiplos instrumentos, incluindo questionários aplicados via Google Forms, observação das atividades desenvolvidas pelos estudantes, análise das produções elaboradas ao longo da intervenção e registros das interações no ambiente virtual de aprendizagem.

A utilização de diferentes fontes de dados permitiu a triangulação das informações, contribuindo para maior consistência na análise dos resultados. Os questionários foram utilizados para captar a percepção dos estudantes em relação à

experiência, enquanto as produções e observações possibilitaram avaliar o desenvolvimento das atividades e a mobilização dos conhecimentos.

A análise dos dados foi conduzida com base em categorias analíticas previamente definidas, engajamento, compreensão conceitual e desenvolvimento de competências, articulando dados qualitativos (observações, produções e percepções dos estudantes) e quantitativos (desempenho nas atividades). Essa abordagem permitiu interpretar os efeitos da intervenção de forma integrada, considerando tanto os processos quanto os resultados da aprendizagem.

4. Resultados e Discussão

4.1. Resultados da Implementação da Intervenção

A aplicação da intervenção foi estruturada com base em um ciclo de Aprendizagem Baseada em Problemas (ABP) adaptado em sete etapas, operacionalizado ao longo de quatro ciclos temáticos (Busca heurística, Classificação, Regressão e Agrupamento). Como instrumento de acompanhamento da execução, utilizou-se uma matriz de evidências, com pontuação de 0 a 2 por etapa (máximo de 14 por ciclo), permitindo avaliar o nível de materialização do processo. O Índice de Fidelidade do Ciclo (IFC) corresponde à soma das pontuações atribuídas às sete etapas da ABP em cada ciclo, variando de 0 a 14. Esse indicador foi utilizado para avaliar o grau de aderência da implementação ao modelo proposto, considerando a presença e a qualidade de execução de cada etapa do processo.

De modo geral, observou-se a manutenção de um núcleo estável nas etapas de contextualização do problema, estudo orientado e avaliação/feedback, enquanto etapas como formulação de hipóteses e planejamento da solução apresentaram menor consistência. Esse comportamento se reflete na redução progressiva do Índice de Fidelidade do Ciclo (IFC) ao longo dos ciclos, indicando impacto do aumento da complexidade dos conteúdos.

A intervenção foi organizada em um fluxo estruturante de Planejamento, Execução e Avaliação. No planejamento, houve centralização das atividades em ambiente virtual, garantindo padronização e continuidade. Na execução, observou-se a transição de práticas em programação (com uso mais pontual de ferramentas como Google Colab, que representou 5% das atividades mapeadas) para atividades de modelagem e análise de dados, com maior uso de Orange Data Mining (15%) e Google Sheets (15%). Já ferramentas de mediação e organização, como Google Slides (23%) e Google Classroom (16%), apresentaram maior frequência de uso, enquanto instrumentos de avaliação formativa, como Google Forms, representaram 13% das atividades, evidenciando alinhamento entre gestão, execução e avaliação.

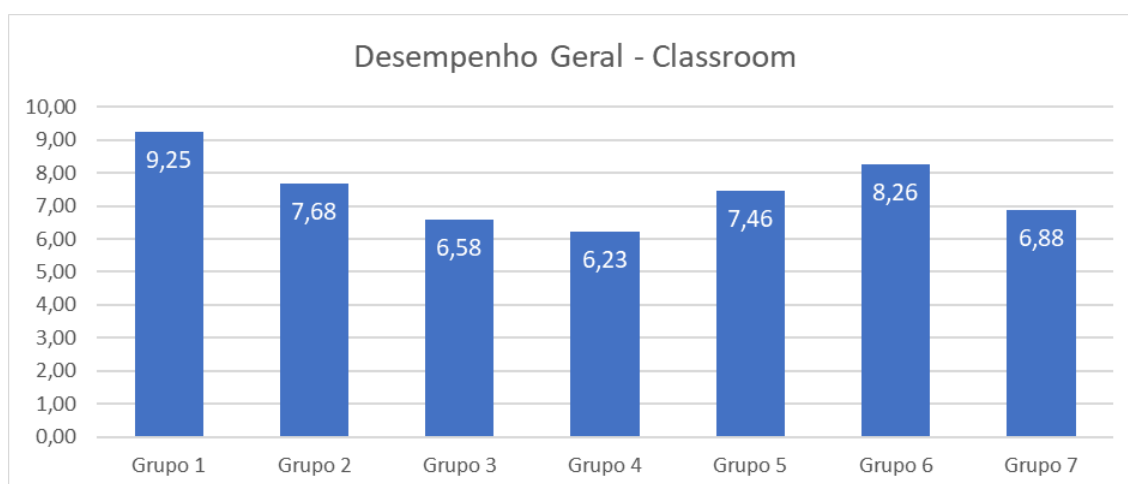
A culminância ocorreu por meio de projetos integradores avaliados por banca multidisciplinar, com pontuação total de 0 a 57 pontos e classificação em três níveis. O Projeto 2, relacionado à análise climática com regressão linear, obteve a maior média (52 pontos; 91,2%), sendo classificado como “atingiu plenamente”. Os Projetos 1 (visualização de horários escolares) e 3 (boletins automatizados) apresentaram desempenho intermediário, com 40 pontos (70,2%) e 40,25 pontos (70,6%), respectivamente, classificados como “atingiu parcialmente”. Já o Projeto 4 não foi concluído (0 pontos), refletindo limitações na continuidade do trabalho em equipe.

Em relação aos critérios avaliativos, destacam-se maiores desempenhos em protagonismo/autonomia (97,2%), implementação da solução (91,7%) e capacidade de propor melhorias (91,7%), além de clareza na apresentação (83,3%). Por outro lado, observam-se fragilidades em aspectos conceituais e técnicos, como uso adequado de conceitos de Aprendizagem de Máquina (55,6%) e validação/testes dos modelos (63,9%), indicando necessidade de reforço nessas dimensões em futuras aplicações.

4.2. Mobilização de Conhecimentos e Desempenho

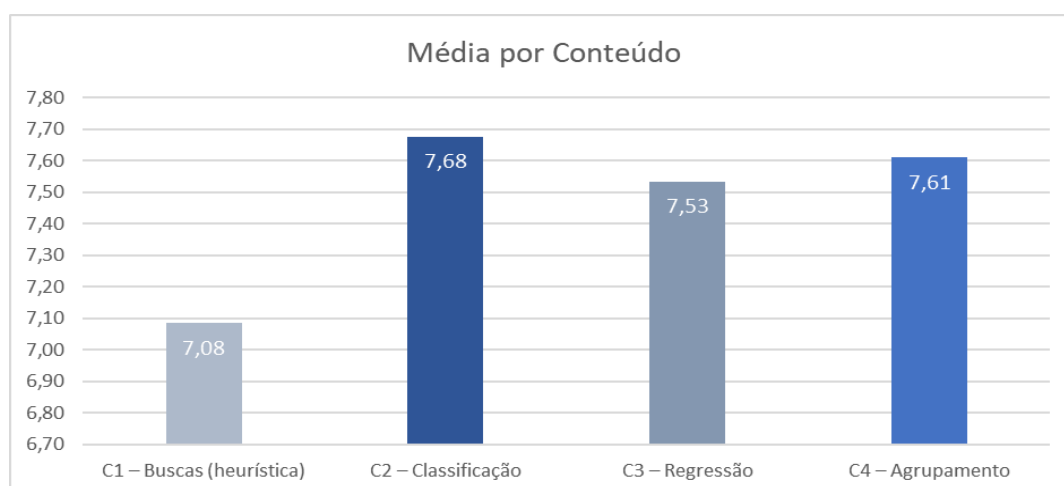
Esta seção analisa o desempenho dos estudantes a partir das avaliações realizadas em grupo no ambiente virtual de aprendizagem, utilizando como base os registros do Google Classroom. O indicador apresentado no Gráfico 1 refere-se ao desempenho consolidado por grupo, integrando atividades teóricas (questionários, estudos dirigidos e justificativas conceituais) e práticas (implementação e experimentação de algoritmos, uso de bases de dados e produção de artefatos). Dessa forma, a métrica expressa a mobilização de conhecimentos de maneira integrada, contemplando tanto a compreensão conceitual quanto a aplicação prática no contexto dos ciclos de aprendizagem.

Gráfico 1 - Desempenho consolidado no Google Classroom por grupo (avaliações teóricas e práticas).



Os resultados evidenciam variação entre os sete grupos, com destaque para o Grupo 1 (9,25) e o Grupo 6 (8,26), que apresentaram maior consistência nas entregas e melhor desempenho global. Em nível intermediário, os Grupos 2 (7,68) e 5 (7,46) demonstraram desempenho próximo à média, enquanto os Grupos 4 (6,23), 3 (6,58) e 7 (6,88) apresentaram menores resultados relativos. Essa distribuição indica que a mobilização de conhecimentos não ocorreu de forma homogênea, refletindo diferenças na organização do trabalho colaborativo, no engajamento e na capacidade de sustentar as atividades ao longo dos ciclos. Em metodologias ativas como a ABP, essa heterogeneidade é esperada, pois o desempenho depende não apenas do domínio técnico, mas também de fatores como autorregulação, divisão de tarefas e qualidade das interações entre os membros do grupo.

Gráfico 2 - Média de desempenho por ciclo de conteúdo no Google Classroom



Complementarmente, o Gráfico 2 apresenta a média de desempenho por ciclo de conteúdo, permitindo analisar a relação entre o desempenho e o contato progressivo com os algoritmos trabalhados na intervenção. Observa-se que o Ciclo 1 – Busca heurística apresentou a menor média (7,08), o que pode ser associado ao período inicial de adaptação à metodologia, às dinâmicas de trabalho em grupo e à própria lógica de resolução de problemas proposta pela ABP. Nos ciclos seguintes, há elevação e estabilização do desempenho: Classificação (7,68), Regressão (7,53) e Agrupamento (7,61), indicando maior familiaridade dos estudantes com o processo e com as ferramentas utilizadas.

Do ponto de vista analítico, esses resultados sugerem que, à medida que os estudantes avançam no contato com algoritmos de Inteligência Artificial e Aprendizagem de Máquina, ocorre uma consolidação da mobilização de conhecimentos, refletida na estabilidade das médias nos ciclos mais avançados. Além disso, o desempenho consolidado no Classroom pode ser compreendido como um indicador robusto de aprendizagem, pois incorpora não apenas a execução técnica, mas também a capacidade de interpretar resultados, justificar decisões e aplicar conceitos em diferentes contextos.

Em síntese, os dados indicam que a intervenção favoreceu a mobilização progressiva de conhecimentos, com melhoria após o ciclo inicial e manutenção de desempenho consistente nos ciclos subsequentes. Ao mesmo tempo, a variabilidade entre grupos evidencia a necessidade de estratégias de acompanhamento mais direcionadas, especialmente para apoiar grupos com menor desempenho na organização do trabalho e no aprofundamento conceitual.

4.3. Percepções dos Estudantes

As percepções dos estudantes foram coletadas por meio de um formulário de feedback e autoavaliação aplicado ao final da intervenção, contemplando aspectos relacionados à compreensão do processo, contribuição para a aprendizagem e condições de implementação. A Tabela 2 sintetiza os resultados em três categorias (concordância, neutro e discordância), permitindo identificar os principais pontos de consolidação e as limitações percebidas pelos participantes.

Tabela 2 - Percepções dos estudantes sobre a intervenção ABP

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 Aprendizagem de Máquina 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%)

De forma geral, observa-se elevada aceitação do método, com destaque para a compreensão do problema e das etapas da ABP (90,0% de concordância em ambos os itens) e para a contribuição das atividades para a aprendizagem (83,3%). Ressalta-se, sobretudo, a forte percepção de conexão com situações reais, com 100,0% de concordância, indicando aderência da proposta ao contexto dos estudantes e reforçando a aproximação entre teoria e prática.

Em relação à articulação com conteúdos de ML, a concordância majoritária (76,7%) sugere que os estudantes reconheceram a aplicação dos conceitos nos projetos, embora a presença de respostas neutras (16,7%) indique que essa relação ainda se encontra em processo de consolidação. Por outro lado, emergem limitações operacionais relevantes: 60,0% dos estudantes discordaram da suficiência de tempo e recursos, evidenciando que a complexidade das atividades exigiu maior suporte estrutural.

Aspectos relacionados ao trabalho em grupo (53,3% de concordância) e ao engajamento (56,7%) apresentaram resultados moderados, indicando heterogeneidade na participação e na dinâmica colaborativa entre os estudantes. Ainda assim, a intenção de continuidade é positiva, com 73,3% afirmando que participariam novamente da experiência, o que sugere que as limitações percebidas estão mais associadas às condições de implementação do que à proposta metodológica em si.

5. Considerações Finais

Este estudo investigou a aplicação da Aprendizagem Baseada em Problemas (ABP) no ensino de Aprendizagem de Máquina em um curso técnico. Os resultados indicam que a ABP contribui positivamente para o ensino de Aprendizagem de Máquina no contexto técnico, especialmente no engajamento dos estudantes, na mobilização de conhecimentos e na articulação entre teoria e prática.

Este estudo explorou a aplicação da Aprendizagem Baseada em Problemas (ABP) no ensino de Aprendizagem de Máquina em um curso técnico, evidenciando que sua adoção, em formato adaptado, favorece a aprendizagem aplicada e a aproximação entre teoria e prática. A intervenção envolveu 33 estudantes, dos quais 30 responderam ao formulário final de percepção e autoavaliação. Os resultados demonstraram aspectos positivos, com elevada compreensão do problema e das etapas do processo (90% de concordância), forte percepção de conexão com situações reais (100%) e intenção de continuidade por parte dos estudantes (73,3%), indicando engajamento e participação ativa. Contudo, também foram identificadas limitações relacionadas ao tempo didático, à infraestrutura, à heterogeneidade dos conhecimentos prévios e à carga de trabalho docente.

Assim, recomenda-se, para futuras aplicações, o aprimoramento do planejamento com checkpoints, estratégias de nivelamento e melhorias nas condições de execução, além da ampliação do estudo para diferentes contextos, visando consolidar evidências sobre a efetividade e escalabilidade da proposta.

Referências

- ALLEN, Becky; MCGOUGH, Andrew Stephen; DEVLIN, Marie. Toward a framework for teaching artificial intelligence to a higher education audience. *ACM Transactions on Computing Education (TOCE)*, v. 22, n. 2, p. 1-29, 2021.
- BARROWS, H. S. A taxonomy of problem-based learning methods. *Medical education*, v. 20, n. 6, p. 481–486, 1986.
- BITTENCOURT, Roberto Almeida; RODRIGUES, Carlos Alberto; CRUZ, Danila S. Santos. Uma experiência integrada de programação orientada a objetos, estruturas de dados e projeto de sistemas com pbl. In: *Workshop sobre Educação em Computação (WEI)*. SBC, 2013. p. 591-600.
- BRASIL. Lei nº 13.415, de 16 de fevereiro de 2017. Altera as diretrizes e bases da educação nacional e institui a Política de Fomento à Implementação de Escolas de Ensino Médio em Tempo Integral. *Diário Oficial da União*, Brasília, DF, 17 fev. 2017.
- 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.
- DOLMANS, D. et al. Problem-based learning: future challenges for educational practice and research. *Medical Education*, 2005.
- HMELO-SILVER, Cindy E. Problem-based learning: What and how do students learn?. *Educational psychology review*, v. 16, n. 3, p. 235-266, 2004.
- HUANG, Shih-Hua; HSU, Ting-Chia. Learning effectiveness and reflections on AI literacy with game-based and problem-based learning. In: *International Conference on Computers in Education*, 2024.
- JAMES, Gareth et al. *An introduction to statistical learning: with applications in R*. New York: springer, 2013.

- KIRSCHNER, Paul; SWELLER, John; CLARK, Richard E. Why unguided learning does not work: An analysis of the failure of discovery learning, problem-based learning, experiential learning and inquiry-based learning. *Educational psychologist*, v. 41, n. 2, p. 75-86, 2006
- MCCARTHY, J. et al. A proposal for the Dartmouth Summer Research Project on Artificial Intelligence. 1955.
- MITCHELL, Tom M. Does machine learning really work?. *AI magazine*, v. 18, n. 3, p. 11-11, 1997.
- PONTES, Paulo Ricardo Da Silva et al. PBL mais aprendizagem colaborativa: práticas metodológicas para o ensino médio integrado. *Revista Brasileira da Educação Profissional e Tecnológica*, v. 2, n. 22, p. e11098-e11098, 2022.
- RIBEIRO, André Luiz Bartolomeu; DOS SANTOS LIMA, Simone Cristiane. Analisando a Efetividade do PBL no Ensino de Programação de Software: Um Estudo Qualitativo em uma Turma Heterogênea. In: *Simpósio Brasileiro de Educação em Computação (EDUCOMP)*. SBC, 2025. p. 191-203.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. Upper Saddle River, NJ, USA: Pearson, 2016.
- SAVERY, John R. Overview of problem-based learning: definitions and distinctions. *Interdisciplinary Journal of Problem-Based Learning*, 2015.
- SHEN, Victor R. L. et al. A special approach to teaching artificial intelligence. *International Journal of Engineering Education*, v. 26, n. 6, p. 1414, 2010.
- WOODS, Donald R. *Problem-based learning: how to gain the most from PBL*. Hamilton: McMaster University, 1994.