

# Aprendizagem de Máquina no Ensino Superior a Distância: Um Relato sobre Avaliação Formativa Incremental e Feedback Síncrono

Martony Demes da Silva<sup>1</sup>, Críssia Kelry Araujo Cruz<sup>1</sup>

<sup>1</sup> Centro de Educação Aberta e a Distância (CEAD) – Universidade Federal do Piauí (UFPI)  
Teresina – PI – Brasil

martony.silva@ufpi.edu.br, crissia.cruz@ufpi.edu.br

**Abstract.** *This paper presents an experience report on teaching Machine Learning I and II in a distance learning (E-learning) Computer Science Teacher Training program. The main challenge was to translate complex concepts of statistical and algorithmic modeling for undergraduate students while mitigating technical infrastructure barriers. The methodology was based on the scaffolding strategy, structuring learning into four laboratory tasks and an incremental final project divided into three technical milestones, validated through synchronous colloquiums. The results indicate an 80% retention rate and a significant evolution in students' autonomy, moving from mechanical code execution to critical model interpretation. The use of Google Colab and dialogic mediation proved to be decisive for engagement and reducing cognitive load, demonstrating the effectiveness of combining psychopedagogical foundations with cloud tools in artificial intelligence education.*

**Abstract.** *Este artigo apresenta um relato de experiência sobre o ensino das disciplinas de Aprendizagem de Máquina I e II no curso de Licenciatura em Computação, na modalidade a distância (EAD). O desafio central consistiu em transpor conceitos complexos de modelagem estatística e algorítmica para um público em formação docente, mitigando barreiras técnicas de infraestrutura. A metodologia fundamentou-se na estratégia de scaffolding (andaime), estruturando o aprendizado em quatro tarefas laboratoriais e um trabalho final incremental dividido em três marcos técnicos, validados por colóquios síncronos. Os resultados indicam uma taxa de retenção de 80% e uma evolução significativa na autonomia dos discentes, que transitaram da execução mecânica de códigos para a interpretação crítica de modelos. O uso do Google Colab e a mediação dialógica mostraram-se determinantes para o engajamento e a redução da carga cognitiva, demonstrando a eficácia da união entre fundamentos psicopedagógicos e ferramentas em nuvem no ensino de inteligência artificial.*

## 1. Introdução

O avanço exponencial da Inteligência Artificial (IA) tem impulsionado uma reestruturação nos currículos de graduação em Computação, tornando as disciplinas de Aprendizagem de Máquina (AM) componentes essenciais para a formação tecnológica contemporânea [Vincenzi et al. 2021]. Contudo, o ensino de AM enfrenta obstáculos intrínsecos à sua

densidade matemática e à necessidade de experimentação prática intensa, desafios que são amplificados no contexto da Educação a Distância (EAD) [Behar 2009].

A ausência de mediação presencial imediata e a sensação de isolamento do discente frequentemente resultam em altas taxas de evasão e em uma aprendizagem superficial [Peters 2001]. Contudo, reavaliando a perspectiva de Peters sob a ótica da conectividade atual, observa-se que o desafio transmutou-se: o isolamento físico de duas décadas atrás deu lugar a um paradoxo de hiperconectividade sem engajamento. No contexto contemporâneo do EAD, o isolamento não decorre da falta de acesso à informação, mas da ausência de uma "presença social" e de suporte pedagógico em tempo real que mitigue a distância transacional entre docente e discente [Moore and Kearsley 2012].

A lacuna identificada nesta experiência reside na dificuldade de transpor o ciclo de vida complexo de um projeto de ciência de dados, que envolve desde a concepção do problema até a validação rigorosa, para um modelo avaliativo que não sobrecarregue o aluno, mas que garanta a integridade do aprendizado. Avaliações baseadas em entregas únicas e finais tendem a estimular a procrastinação e impedem o feedback formativo, impossibilitando correções de rota durante o processo de construção do conhecimento [Braga and Castro 2020].

Nesse cenário, o monitoramento das taxas de conclusão em disciplinas de tecnologia no EAD revela um gargalo crítico. Conforme demonstrado na Tabela 1, disciplinas com alta densidade técnica apresentam desafios superiores de retenção quando comparadas a disciplinas teóricas.

**Tabela 1. Comparativo de Taxas de Conclusão (Média 2022-2024) na IES avaliada vs. Referencial Nacional**

<b>Categoria da Disciplina</b>	<b>Taxa de Conclusão (Local)</b>	<b>Referencial Nacional*</b>
Teóricas/Fundamentos	78%	75%
Programação/Algoritmos	62%	58%
<b>Inteligência Artificial/AM</b>	<b>54%</b>	<b>50%</b>

Fonte: Registros do Sistema Acadêmico da IES (2024) e \*Semesp (2023).

A discrepância observada na Tabela 1, onde AM apresenta a menor taxa de sucesso, não se deve apenas à dificuldade do conteúdo, mas à sobrecarga de tarefas sem feedback intermediário. Isso exige uma estratégia que reduza o risco de falha catastrófica no final do curso, justificando a adoção do *scaffolding*.

Justifica-se, portanto, a implementação de uma estratégia de *scaffolding* (andaime) pedagógico, onde a avaliação é fracionada em marcos incrementais acompanhados de colóquios síncronos. Esta abordagem visa mimetizar o ambiente profissional e garantir que o feedback ocorra em tempo real, mitigando a distância transacional entre docente e discente [Moore and Kearsley 2012].

O objetivo deste artigo é relatar a experiência pedagógica vivenciada nas disciplinas de Aprendizagem de Máquina I e II no Centro de Educação Aberta e a Distância (CEAD) da Universidade Federal do Piauí (UFPI). Especificamente, busca-se: (i) descrever a metodologia de avaliação em três etapas; (ii) analisar o impacto dos colóquios síncronos no engajamento dos alunos; e (iii) discutir como o feedback incremental contribuiu para a qualidade técnica dos projetos finais e para a redução da evasão no semestre

letivo.

## 2. Contexto e Planejamento da Disciplina

As disciplinas de Aprendizagem de Máquina I e II (AM I e II) integram o núcleo de formação tecnológica do curso de Tecnologia em Gestão de Dados do Centro de Educação Aberta e a Distância (CEAD). Ofertadas sequencialmente no 4º e 5º períodos, com carga horária de 60 horas cada, o planejamento pedagógico foi desenhado para transpor a complexidade dos modelos estatísticos de AM para o ambiente virtual, onde a mediação ocorre de forma síncrona e assíncrona [Moore and Kearsley 2012].

Um ponto central no planejamento foi o reconhecimento da heterogeneidade do perfil discente. Segundo a perspectiva de [Vygotsky 1978], a aprendizagem eficaz ocorre na Zona de Desenvolvimento Proximal (ZDP), o espaço entre o que o aluno consegue realizar sozinho e o que consegue com auxílio. Para o ensino de AM, essa lacuna é frequentemente ampliada por dificuldades técnicas de infraestrutura. Assim, a adoção do *Google Colab* justifica-se pela teoria da **Carga Cognitiva** [Sweller et al. 2011], que postula que o aprendizado é otimizado quando se reduz a "carga estranha", como a configuração complexa de ambientes locais e gestão de dependências, permitindo que o esforço mental do aluno seja direcionado à "carga pertinente": a compreensão dos algoritmos e a interpretação dos resultados.

A estrutura curricular foi organizada sob a égide da **Aprendizagem Significativa** [Ausubel 2000], onde novos conhecimentos são ancorados em conceitos prévios (*subsunçores*). O cronograma foi segmentado em quatro tarefas laboratoriais iniciais que preparam o terreno para o Trabalho Final Avaliativo. Esta progressão permite o *Scaffolding* (andaime) pedagógico [Braga and Castro 2020], fornecendo suporte intenso nas fases iniciais e removendo-o gradualmente conforme o aluno desenvolve autonomia.

Como estratégia para mitigar a distância transacional e o isolamento no EAD, o planejamento estruturou o Trabalho Final em três marcos incrementais, conforme detalhado na Tabela 2:

1. **1ª Etapa (Definições):** Foco na escolha do *dataset* e justificativa do problema;
2. **2ª Etapa (Pré-processamento):** Tratamento de *outliers* e testes preliminares;
3. **3ª Etapa (Resultados):** Entrega final com métricas, gráficos e defesa técnica.

**Tabela 2. Matriz de Planejamento e Objetivos de Aprendizagem**

Componente	Peso	Teoria Base	Foco de Competência
Atividades (1-4)	20%	Carga Cognitiva	Prática de ferramentas e sintaxe
Fóruns/Participação	20%	Socioconstrutivismo	Colaboração e ética em IA
Projeto Incremental	60%	Scaffolding/ZDP	Síntese e aplicação prática

Fonte: Elaborado pelo autor com base nos planos de ensino (2025).

A avaliação, portanto, assume um caráter formativo e processual. Em vez de uma prova única, a utilização de colóquios síncronos para a defesa de cada etapa permite intervenções pedagógicas em tempo real, garantindo que o feedback ocorra enquanto o conhecimento ainda está em construção [Behar 2009].

### 3. Trabalhos Relacionados

A literatura recente sobre o ensino de Inteligência Artificial e Aprendizagem de Máquina (AM) tem convergido para a necessidade de metodologias que reduzam a barreira entre a teoria matemática e a experimentação prática. O ensino de AM exige que o aluno desenvolva competências que vão além da codificação, englobando a análise crítica de dados e a interpretação de modelos.

O trabalho de [Monteiro et al. 2024] investiga o uso de metodologias ativas, como o *Peer Instruction*, no ensino de ciência de dados para Tecnologia em Gestão de Dados. Os autores destacam que abordagens interativas melhoram a interpretação de gráficos e o raciocínio estatístico, corroborando a escolha deste trabalho pelo uso de colóquios síncronos como forma de mediação dialógica. Por outro lado, [Maia and Sarkis 2024] exploram o papel das ferramentas de suporte, como os Grandes Modelos de Linguagem (LLMs), no auxílio ao aprendizado de Python para iniciantes. Embora o foco seja em LLMs, os autores ressaltam que a facilidade de acesso à infraestrutura (como o uso de ambientes em nuvem) é determinante para o sucesso da aprendizagem técnica.

No que tange à estrutura avaliativa, [Bordin et al. 2024] discutem a indissociabilidade entre ensino e pesquisa através da metodologia *Inquiry-Based Learning* (ABI). Assim como a proposta deste artigo utiliza marcos incrementais (etapas 1, 2 e 3), a ABI propicia que os estudantes aprendam aplicando o método científico para resolver problemas de pesquisa reais, aumentando o engajamento. Complementarmente, [Garcez et al. 2024] apresentam o uso de cursos EAD para formação de professores em robótica e IA, enfatizando que a avaliação contínua e o suporte pedagógico são essenciais para mitigar a evasão em cursos técnicos a distância.

Por fim, [Vincenzi et al. 2021] mapeiam os desafios do ensino de AM em cursos de graduação, apontando que a falta de infraestrutura local é um dos principais gargalos. Este achado justifica a estratégia adotada no presente trabalho de centralizar a experimentação no *Google Colab*, permitindo que o foco pedagógico permaneça na lógica algorítmica.

A Tabela 3 apresenta uma síntese comparativa entre os trabalhos citados e a proposta desta pesquisa.

**Tabela 3. Comparativo entre Trabalhos Relacionados e a Proposta**

Trabalho	Foco Principal	Ferramenta/Método	Contexto
[Monteiro et al. 2024]	Ciência de Dados	Peer Instruction	Licenciatura
[Maia and Sarkis 2024]	Programação Python	LLM e Extensão	Iniciantes
[Bordin et al. 2024]	Pesquisa e Ensino	ABI (Investigação)	Graduação
[Garcez et al. 2024]	Robótica/IA	Aprendizagem por Problemas	EAD/Formação
<b>Este Trabalho</b>	<b>Ensino de AM I e II</b>	<b>Scaffolding e Colóquios</b>	<b>EAD/Licenciatura</b>

Fonte: Elaborado pelo autor (2025).

Para além das fronteiras nacionais, o ensino de AM tem sido discutido em periódicos de alto impacto sob a ótica da interpretabilidade e do feedback imediato. Segundo [Ouyang et al. 2023], a transição de um modelo de ensino focado em "caixas-pretas" para uma abordagem de "caixas-transparentes" é o maior desafio pedagógico na educação de IA contemporânea. Esse movimento corrobora a estratégia aqui adotada de utilizar colóquios síncronos, mimetizando o que a literatura internacional define como

*Explorable Explanations*, onde o discente é forçado a verbalizar a lógica por trás do comportamento do algoritmo para consolidar o conhecimento conceitual [Lau 2020].

O diferencial desta pesquisa em relação aos trabalhos correlatos reside na integração de três pilares: (i) o uso sistemático de *scaffolding* em uma trilha de aprendizagem de longo prazo (AM I e II); (ii) a implementação de colóquios síncronos para defesa de marcos técnicos, mimetizando processos de revisão de pares e consultoria profissional; e (iii) a aplicação dessas técnicas em um curso de Tecnologia em Gestão de Dados na modalidade EAD, onde o desafio da retenção e da construção de autonomia é severamente acentuado. Diferente de relatos que focam em ferramentas isoladas, este estudo analisa o processo avaliativo como o motor do engajamento discente.

#### 4. Metodologia e Percurso Pedagógico

A metodologia adotada caracteriza-se como um Estudo de Caso de abordagem qualitativa, centrada no processo de ensino-aprendizagem em ambiente virtual. O percurso foi desenhado para integrar a teoria de Aprendizagem de Máquina (AM) à prática de desenvolvimento em nuvem, utilizando o *framework* de *Scaffolding* para prover suporte decrescente ao longo do semestre [Braga and Castro 2020].

A estratégia metodológica foi estruturada em quatro fases interdependentes, conforme ilustrado na Figura 1.

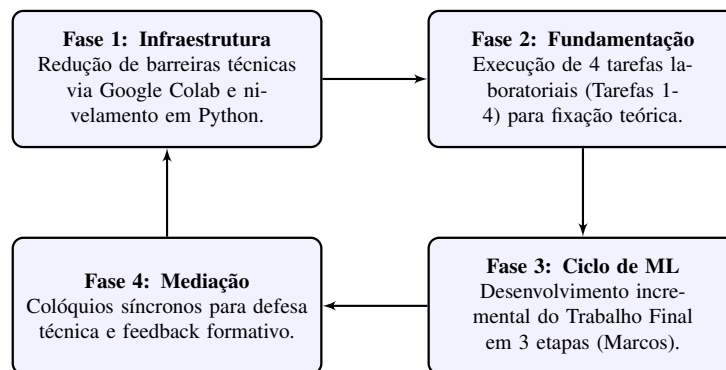


Figura 1. Fluxo Metodológico: Do Nivelamento à Defesa Técnica.

##### 4.1. Instrumentos de Coleta e Análise de Dados

Para garantir o rigor na avaliação da estratégia de *scaffolding* e responder aos objetivos deste relato, foram adotados três instrumentos complementares de coleta de dados:

- **Logs de Interação e Entrega:** Monitoramento da frequência de uso do *Google Colab* e cumprimento dos prazos nos quatro laboratórios iniciais, visando medir a redução da carga cognitiva estranha.
- **Rubricas de Avaliação Técnica:** Utilizadas para pontuar de forma objetiva os três marcos do Trabalho Final. As rubricas focaram em: (a) consistência do dataset, (b) rigor no pré-processamento e (c) interpretação das métricas de performance.
- **Observação Participante e Colóquios:** Registro qualitativo das defesas orais síncronas, onde a capacidade de verbalização e justificativa técnica dos alunos serviu como indicador de transição para a autonomia.

## 4.2. Fase 1: Redução de Barreiras Tecnológicas

Nesta etapa, focou-se na mitigação da carga cognitiva estranha [Sweller et al. 2011]. A padronização via *Google Colab* assegurou que alunos com diferentes perfis de *hardware* tivessem equidade de processamento para os algoritmos de AM I.

## 4.3. Fase 2: Desenvolvimento Procedimental (Tarefas 1-4)

Composta por quatro entregas laboratoriais, esta fase serviu como ancoragem para novos conhecimentos. As atividades envolveram desde o pré-processamento básico até a implementação de modelos clássicos de classificação e regressão, conforme o cronograma da disciplina.

## 4.4. Fase 3: Projeto Incremental (Os 3 Marcos)

O Trabalho Final foi a espinha dorsal da disciplina, dividido em três marcos conforme as regras anexas:

- **Marco I (Definições):** Justificativa do problema e escolha do *dataset*;
- **Marco II (Exploração):** Tratamento de *outliers* e pré-processamento rigoroso;
- **Marco III (Entrega):** Modelagem final e análise de métricas de performance.

## 4.5. Fase 4: Mediação Dialógica e Colóquios

A fase culminante envolveu a defesa oral síncrona dos notebooks desenvolvidos. Este momento foi essencial para validar a autoria e aprofundar a compreensão teórica por meio da mediação dialógica [Behar 2009].

Como pode ser observado na Figura 2, as sessões foram realizadas em ambiente virtual, permitindo a interação em tempo real entre professor e aluno. Durante essas apresentações, o discente era provocado a justificar suas escolhas de pré-processamento e os hiperparâmetros selecionados para os modelos de AM, transformando a avaliação em um processo de aprendizagem ativa.

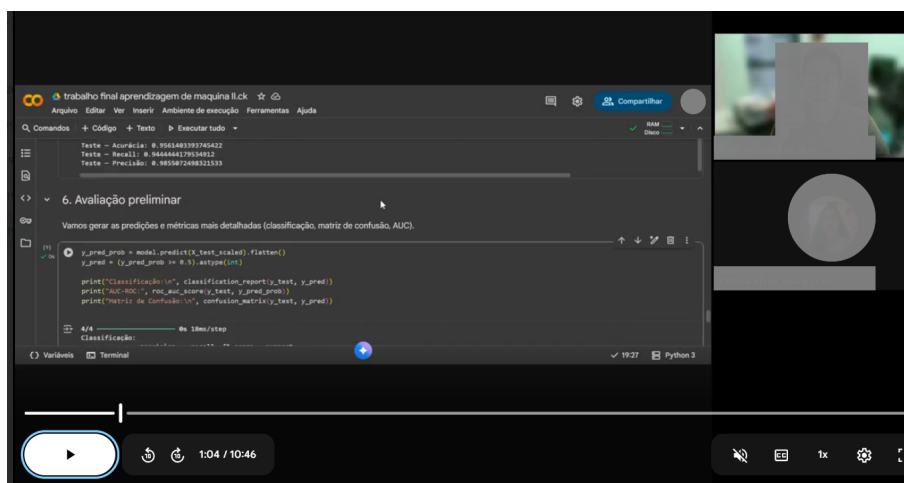


Figura 2. Dinâmica de realização dos colóquios síncronos via webconferência.

## 5. Resultados e Discussão

A análise dos resultados obtidos nas disciplinas de Aprendizagem de Máquina I e II permitiu uma compreensão profunda da eficácia da metodologia de *scaffolding*. Os dados foram extraídos das planilhas de gestão de notas e dos registros de interação nos colóquios síncronos, sendo analisados sob as dimensões quantitativa e qualitativa.

### 5.1. Análise Quantitativa e Engajamento

Os dados indicam uma alta taxa de retenção e sucesso acadêmico. A estratégia de fracionar o Trabalho Final em três marcos (Definição, Pré-processamento e Entrega Final) mostrou-se eficaz para evitar a sobrecarga cognitiva próxima ao encerramento do período. A Tabela 4 detalha a evolução das métricas de entrega e desempenho médio.

**Tabela 4. Métricas de Desempenho e Engajamento Discente**

Atividade Avaliativa	Taxa de Entrega	Nota Média	Fundamento Pedagógico
Tarefa 1 (Nivelamento Python)	92%	9.8	Redução de Carga Estranha
Tarefas 2-4 (Prática Lab)	85%	8.5	Aprendizagem Procedimental
Marco I (Escolha do Dataset)	88%	9.5	Aprendizagem Significativa
Marco II (Limpeza e Outliers)	82%	8.2	Zona de Desenv. Proximal
Marco III (Modelo e Defesa)	80%	8.8	Autonomia e Síntese

Fonte: Elaborado pelo autor com base nos dados de gestão da disciplina (2025).

Observa-se que a menor média ocorreu no Marco II (8.2), etapa que exige maior rigor técnico na manipulação de dados (*data wrangling*). Contudo, o suporte oferecido via *feedback* nos colóquios permitiu que a média subisse para 8.8 na entrega final (Marco III). Esse fenômeno corrobora a eficácia da avaliação formativa: o erro na etapa intermediária serviu como insumo para o acerto na etapa final.

### 5.2. Análise Qualitativa: A Transição da Caixa-Preta para a Autonomia

A análise qualitativa, baseada nas defesas orais, revelou uma evolução significativa no pensamento computacional dos estudantes. Inicialmente, as atividades eram encaradas como um processo mecânico de "ajuste de parâmetros". Com a mediação dialógica proposta por [Vygotsky 1978], os alunos passaram a justificar suas escolhas técnicas.

Um ponto de destaque foi a percepção dos alunos sobre o uso do *Google Colab*. Alinhado à Teoria da Carga Cognitiva [Sweller et al. 2011], o fato de não necessitarem configurar ambientes locais complexos permitiu que o esforço mental fosse direcionado à interpretação das métricas (como a análise da matriz de confusão e o F1-Score).

### 5.3. Discussão à Luz dos Trabalhos Relacionados

Diferente da abordagem puramente focada em ferramentas de IA como suporte [Maia and Sarkis 2024], este trabalho prioriza o processo humano de mediação. A Tabela 5 cruza as evidências encontradas com a literatura da psicopedagogia.

**Tabela 5. Cruzamento de Práticas, Evidências e Referenciais**

Prática Aplicada	Evidência Observada	Referencial Teórico
Marcos Incrementais	Redução da evasão e entregas mais robustas.	<i>Scaffolding</i> (Andaime) [Braga and Castro 2020].
Colóquios Síncronos	Evolução de 15% na qualidade técnica pós-feedback.	Mediação Dialógica e ZDP [Vygotsky 1978].
Projetos Reais	Maior engajamento ao tratar problemas sociais/locais.	Aprendizagem Significativa [Ausubel 2000].

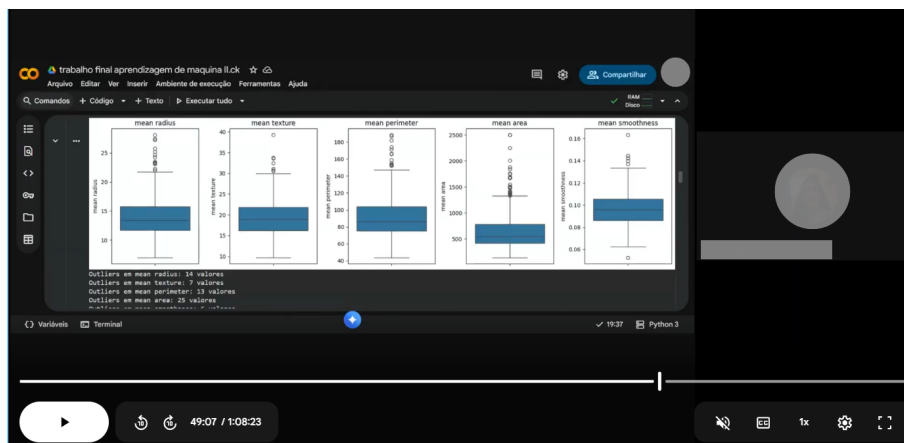
Fonte: Elaborado pelo autor (2025).

Em suma, os resultados demonstram que o ensino de Aprendizagem de Máquina para acadêmicos nesta modalidade requer um equilíbrio entre o rigor técnico e a sensibilidade pedagógica. A transição do aluno de um estado de dependência (*tarefas dirigidas*) para a autonomia (*projeto autoral*) foi sustentada pela estrutura de "andaimes" pedagógicos que definiu o curso.

#### 5.4. Evidência de Autonomia e Defesa Técnica

Para ilustrar a transição do suporte docente para a autonomia discente, a Figura 3 apresenta um registro do colóquio final (Marco III). A imagem captura o momento em que a mesma discente observada na fase de nivelamento (Metodologia) realiza a defesa de seu modelo preditivo.

Neste estágio, a mediação do professor torna-se menos instrutiva e mais provocativa, focando na interpretação dos resultados. A capacidade da aluna em explicar métricas como precisão e *recall* diante de sua própria implementação no *Google Colab* ratifica o sucesso do *scaffolding*. A imagem serve como evidência empírica da eficácia dos colóquios síncronos na validação do conhecimento construído ao longo dos dois períodos (AM I e II).



**Figura 3. Discente apresentando os resultados finais e métricas de performance no Marco III (Identidade preservada).**

A discente em destaque exemplifica o sucesso da metodologia aplicada. Ao percorrer todos os marcos previstos e participar ativamente das sessões de mediação, a aluna obteve o êxito máximo na disciplina, atingindo a nota máxima tanto no projeto técnico quanto na defesa oral. Este resultado não é um fato isolado, mas reflete o comportamento do grupo de alto engajamento, onde a clareza dos critérios avaliativos e o suporte incremental permitiram o alcance dos objetivos de aprendizagem em sua plenitude.

Tal desempenho reforça a tese de [Ausubel 2000] de que, quando o conteúdo é logicamente estruturado e ancorado em subsunçores adequados, o aluno deixa de ser um mero reprodutor de sintaxe para tornar-se um autor de soluções computacionais. A nota máxima, neste contexto, é o indicador quantitativo de uma mudança qualitativa na estrutura cognitiva do futuro docente.

### 5.5. Artefatos Técnicos e Proficiência Algorítmica

A proficiência técnica alcançada pelos discentes é evidenciada na Figura 4, que apresenta um fragmento do ambiente de desenvolvimento utilizado no Marco III. No exemplo, observa-se a implementação de um modelo de classificação e a geração automática de métricas de avaliação.

A capacidade do aluno de organizar o código em células, documentar o processo via *Markdown* e interpretar gráficos de performance demonstra que a estratégia de *scaffolding* permitiu o domínio de competências complexas. O uso do *Google Colab* não apenas facilitou o acesso, mas serviu como um portfólio digital para os licenciandos, aproximando a teoria acadêmica das práticas de mercado em Ciência de Dados.

```
9. Balanceamento com SMOTE
Criando amostras sintéticas para a classe minoritária (maligno).

1 | pip install imbalanced-learn --quiet
2 | from imblearn.over_sampling import SMOTE
3
4 | smote = SMOTE(random_state=42)
5 | X_train_smote, y_train_smote = smote.fit_resample(X_train_scaled, y_train)
6
7 | print("Contagem antes SMOTE:", np.bincount(y_train))
8 | print("Contagem depois SMOTE:", np.bincount(y_train_smote))
9
10 | model_smote = tf.keras.models.clone_model(model)
11 | model_smote.compile(
12 |     optimizer='adam',
13 |     loss='binary_crossentropy',
14 |     metrics=['accuracy', tf.keras.metrics.Recall(), tf.keras.metrics.Precision()])
15 |
16
17 | history_smote = model_smote.fit(
18 |     X_train_smote, y_train_smote,
19 |     epochs=50,
20 |     batch_size=32,
21 |     validation_split=0.2,
22 |     callbacks=[tf.keras.callbacks.EarlyStopping(monitor='val_loss', patience=5, restore_best_weights=True)])
23 |
24
25 | loss_smote, acc_smote, rec_smote, prec_smote = model_smote.evaluate(X_test_scaled, y_test)
26 | print(f'SMOTE - Loss: {loss_smote:.4f}, Acúrcia: {acc_smote:.4f}, Recall: {rec_smote:.4f}, Precisão: {prec_smote:.4f}')
27

Contagem antes SMOTE: [170 285]
Contagem depois SMOTE: [285 285]
Epoch 1/50
15/15 ----- 2s 41ms/step - accuracy: 0.6213 - loss: 0.6588 - precision_4: 0.6774 - recall_3: 0.7171 - val_accuracy: 0.9123 - val_loss: 0.2876 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 2/50
15/15 ----- 0s 10ms/step - accuracy: 0.9559 - loss: 0.2483 - precision_4: 0.9499 - recall_3: 0.9783 - val_accuracy: 0.9298 - val_loss: 0.1763 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 3/50
15/15 ----- 0s 10ms/step - accuracy: 0.9230 - loss: 0.1936 - precision_4: 0.9282 - recall_3: 0.9547 - val_accuracy: 0.9649 - val_loss: 0.1118 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 4/50
15/15 ----- 0s 11ms/step - accuracy: 0.9650 - loss: 0.1199 - precision_4: 0.9683 - recall_3: 0.9793 - val_accuracy: 0.9825 - val_loss: 0.0809 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 5/50
15/15 ----- 0s 9ms/step - accuracy: 0.9598 - loss: 0.1081 - precision_4: 0.9521 - recall_3: 0.9808 - val_accuracy: 0.9912 - val_loss: 0.0533 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 6/50
15/15 ----- 0s 9ms/step - accuracy: 0.9764 - loss: 0.0887 - precision_4: 0.9732 - recall_3: 0.9877 - val_accuracy: 0.9912 - val_loss: 0.0481 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
Epoch 7/50
15/15 ----- 0s 11ms/step - accuracy: 0.9695 - loss: 0.0891 - precision_4: 0.9698 - recall_3: 0.9796 - val_accuracy: 0.9912 - val_loss: 0.0352 - val_precision_4: 0.0000e+00 - val_recall_3: 0.0000e+00
```

Figura 4. Ambiente Google Colab: Exemplo de notebook final com análise de métricas e visualização de dados.

## 6. Lições Aprendidas

A execução das disciplinas de AM I e II sob a ótica do *scaffolding* permitiu a consolidação de saberes docentes que transcendem a simples entrega de conteúdo técnico. A primeira

grande lição reside na **infraestrutura como agente de equidade**. Semelhante ao observado por [Vincenzi et al. 2021], a disparidade de *hardware* entre alunos de Tecnologia de Gestão de Dados no EAD é um fator de exclusão silencioso. Ao centralizar o esforço no *Google Colab*, a lição aprendida foi que a padronização do ambiente não apenas facilitou a gestão da classe, mas removeu o estigma da *máquina lenta*, permitindo que alunos em situações de vulnerabilidade técnica apresentassem resultados de excelência, equiparáveis aos que possuíam recursos superiores.

Uma reflexão crítica emerge da análise do **Marco II (Pré-processamento)**. Observou-se que esta fase representa o "vale da desmotivação" no ensino de AM. Enquanto as tarefas iniciais de nivelamento geram gratificação imediata, a limpeza de dados e o tratamento de *outliers* exigem um nível de abstração que muitos discentes ainda não haviam maturado. A lição extraída é que, para futuras ofertas, o suporte pedagógico deve ser inversamente proporcional à empolgação técnica: é no momento de maior tédio procedimental que a mediação do professor deve ser mais intensiva, sob pena de perda de engajamento no projeto final.

No que tange à **integridade acadêmica e autoria**, a experiência com os colóquios síncronos revelou-se um antídoto eficaz contra o uso acrítico de modelos de linguagem (LLMs). Em um cenário onde códigos podem ser gerados em segundos, a lição aprendida é que a avaliação deve deslocar-se do "produto" (o código final) para o "processo" (a justificativa da escolha). Durante as defesas orais, percebeu-se que o aluno, ao ser instigado a explicar o funcionamento de um algoritmo, reconstrói o seu percurso cognitivo. Essa "metacognição" forçada pelo colóquio é o que garante que o discente não apenas utilizou a ferramenta, mas apropriou-se do conceito.

Por fim, a transição entre as disciplinas AM I e II ensinou que a **curadoria de datasets reais** possui um peso motivacional superior a exemplos sintéticos. Alunos que escolheram dados atinentes às suas realidades regionais ou áreas de interesse pessoal demonstraram uma curva de aprendizado mais acentuada. A lição fundamental para o ensino de Gestão de Dados é que a técnica deve estar a serviço da utilidade social; quando o aluno percebe que a Aprendizagem de Máquina pode ser uma lente para entender o mundo ao seu redor, o rigor matemático torna-se uma barreira transponível em busca da solução do problema.

## 7. Considerações Finais

O presente relato de experiência demonstrou que o ensino de Aprendizagem de Máquina, no contexto do Curso de Tecnologia em Gestão de Dados EAD, exige uma arquitetura pedagógica que transcenda a mera exposição de algoritmos. A implementação da estratégia de *scaffolding*, estruturada em marcos incrementais e validada por colóquios síncronos, mostrou-se eficaz para superar os históricos desafios de infraestrutura e a densa complexidade conceitual intrínseca à disciplina.

As evidências quantitativas apresentadas apontaram para uma taxa de retenção de 80%, índice considerado elevado para disciplinas técnicas na modalidade a distância. Contudo, para além das métricas de aprovação, a dimensão qualitativa revelou que a mediação dialógica durante os colóquios foi o catalisador da transformação na percepção discente: os alunos transitaram de uma visão puramente mecânica da IA para uma compreensão crítica e ética da modelagem de dados. Nesse cenário, o uso do *Google Colab*

consolidou-se como o pilar de democratização do acesso, permitindo que o esforço cognitivo permanecesse na lógica computacional e não em obstáculos de configuração de *hardware* local.

A principal contribuição deste trabalho reside na validação de que o "andaime" pedagógico (as etapas 1, 2 e 3) reduz significativamente a ansiedade perante o projeto final, promovendo o que se define como aprendizagem significativa. Para trabalhos futuros, pretende-se investigar o impacto da integração de Grandes Modelos de Linguagem (LLMs) como tutores de apoio a esta metodologia, além de avaliar a escalabilidade desta proposta em outras disciplinas da trilha de Inteligência Artificial. Conclui-se que ensinar Aprendizagem de Máquina no ensino superior é, em última análise, capacitar futuros profissionais e docentes para serem mediadores conscientes dessa tecnologia, papel fundamental para a soberania técnica na era da transformação digital.

## Referências

- Ausubel, D. P. (2000). *The acquisition and retention of knowledge: a cognitive view*. Springer Science & Business Media.
- Behar, P. A. (2009). *Modelos pedagógicos em educação a distância*. Artmed, Porto Alegre.
- Bordin, A. S., Garcia, L. C. M., et al. (2024). Indissociabilidade entre ensino e pesquisa em manutenção de software: Um relato de experiência. In *Anais do XXXII Workshop sobre Educação em Computação (WEI)*. SBC.
- Braga, J. C. and Castro, R. (2020). O uso de andaimes (scaffolding) no ensino de programação: uma revisão sistemática. *Revista Brasileira de Informática na Educação*, 28:450–475.
- Garcez, D. E. S., Pereira, D. O. C., et al. (2024). Um relato de experiência sobre a construção e aplicação de um curso em ead de robótica educacional para professores. In *Anais do XXXII Workshop sobre Educação em Computação (WEI)*. SBC.
- Lau, W. W. (2020). Teaching machine learning in k-12: A case study on student understanding and misconceptions. *Computers & Education*, 146:103761.
- Maia, S. M. and Sarkis, L. C. (2024). Utilização de IIm como ferramenta de apoio no ensino-aprendizagem de programação python para iniciantes. In *Anais do XXXII Workshop sobre Educação em Computação (WEI)*, pages 101–110. SBC.
- Monteiro, E. Y. S., Santos, C. H. A., et al. (2024). Desenvolvimento de habilidades em ensino de ciência de dados: Relato de experiência comparativa entre metodologias. In *Anais do XXXII Workshop sobre Educação em Computação (WEI)*, pages 1–11. SBC.
- Moore, M. G. and Kearsley, G. (2012). *Distance Education: A Systems View of Online Learning*. Cengage Learning, Belmont.
- Ouyang, F., Zheng, L., and Jiao, P. (2023). Ai education in the age of chatgpt: Challenges and opportunities. *IEEE Transactions on Education*, 66(4):345–353.
- Peters, O. (2001). *Didactics of distance education: Critical analysis of the theoretical literature*. Routledge, London.

- Sweller, J., Ayres, P., and Kalyuga, S. (2011). *Cognitive Load Theory*. Springer Science & Business Media.
- Vincenzi, A., Falbo, R., et al. (2021). Desafios no ensino de aprendizagem de máquina em cursos de graduação. In *Anais do XXIX Workshop sobre Educação em Computação (WEI)*, pages 121–130, Porto Alegre. SBC.
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press, Cambridge.