

Aprendizagem Ativa de Machine Learning a Distância com Design Thinking e Google Colab

Martony Demes da Silva¹

¹Universidade Federal do Piauí (UFPI)
Centro de Educação Aberta e a Distancia (CEAD)
Teresina – Piauí – Brasil

mardemes@gmail.com

Abstract. *The teaching of Machine Learning in distance education presents challenges due to the complexity of algorithms, the need for practice, and the engagement of students. This paper presents the application of Design Thinking as an active methodology to innovate in teaching Machine Learning, using Google Colab as an interactive and collaborative environment. An interactive notebook was developed with ipywidgets to allow real-time parameter adjustments, algorithm testing, and instant visualization of results. The expected results include greater engagement, improvement in understanding of concepts, and the creation of an iterative environment with continuous feedback.*

Resumo. *O ensino de Aprendizagem de Máquina no contexto da educação a distância apresenta desafios relacionados à complexidade dos algoritmos, à necessidade de prática e ao engajamento discente. Este artigo apresenta a aplicação do Design Thinking como metodologia ativa para inovação pedagógica, utilizando o Google Colab como ambiente interativo e colaborativo. Foi desenvolvido um notebook interativo com ipywidgets que possibilita ajustes de parâmetros em tempo real, testes de algoritmos e visualização imediata de resultados. Os resultados esperados incluem maior engajamento, melhoria na compreensão dos conceitos e a criação de um ambiente iterativo com feedback contínuo.*

1. Introdução

Nas últimas décadas, o ensino de *Aprendizagem de Máquina (ML)* tornou-se central para a formação em ciência de dados e inteligência artificial. Contudo, paradoxalmente, à medida que cresce a demanda por profissionais qualificados, também cresce a taxa de evasão e desmotivação em disciplinas de ML ministradas em *educação a distância*. Um levantamento de [Jordan and Mitchell 2015] já indicava que muitos estudantes, mesmo após semanas de curso, não conseguiam explicar de forma clara conceitos básicos de regressão ou classificação. Por que conteúdos tão estratégicos permanecem tão inacessíveis?

Parte da resposta está na natureza abstrata e matemática dos algoritmos, que exige equilíbrio entre teoria e prática. Em ambientes presenciais, isso costuma ser mitigado com experimentos guiados e feedback imediato. Já no ensino remoto, a falta de práticas aplicadas em tempo real pode levar à aprendizagem superficial e, em última instância, ao abandono. O desafio, portanto, não é apenas transmitir conhecimento, mas **criar experiências de aprendizagem significativas, interativas e centradas no estudante** [Anderson 2011].

Nesse cenário, o *Design Thinking* desponta como uma metodologia ativa que se diferencia por colocar o estudante no centro do processo, favorecendo empatia, ideação e prototipação rápida [Brown 2009, Razzouk and Shute 2012]. Paralelamente, o *Google Colab* consolidou-se como uma das ferramentas mais acessíveis para experimentação prática em ciência de dados, oferecendo execução em nuvem, colaboração em tempo real e integração com bibliotecas de ML [Topsakal 2023].

Este artigo parte da seguinte provocação: *o que aconteceria se integrássemos Design Thinking e Google Colab em um modelo único de ensino de ML a distância?* Mais do que apenas somar metodologias, busca-se criar um ciclo de experimentação interativa com feedback contínuo, em que os estudantes não apenas aplicam algoritmos, mas refletem criticamente sobre cada decisão tomada. O objetivo é investigar de que forma essa abordagem pode: (i) aumentar o engajamento, (ii) aprofundar a compreensão conceitual e (iii) fortalecer a autonomia discente em cursos de Aprendizagem de Máquina na modalidade a distância.

2. Fundamentação Teórica

2.1. Design Thinking na Educação

Design Thinking é uma abordagem centrada no usuário para solução de problemas, caracterizada por iterações entre empatia, definição do problema, ideação, prototipagem e testes. Conforme [Brown 2009, Plattner et al. 2011], o foco do Design Thinking é gerar soluções viáveis por meio de iterações rápidas e validação com usuários. No contexto de ensino de Engenharia de Software, Design Thinking é usado para promover aprendizagem ativa e resolver problemas reais, integrando fases de concepção com avaliação empírica. Estudos anteriores demonstram que, quando combinado com práticas de aprendizagem ativa, o Design Thinking pode aumentar o engajamento e a retenção conceitual.

2.2. Metodologias Ativas e Ensino Remoto

Metodologias como Aprendizagem Baseada em Problemas (PBL), aprendizagem colaborativa e gamificação potencializam a participação e o aprendizado significativo [Moran 2018].

2.3. Aprendizagem de Máquina

A Aprendizagem de Máquina requer prática, experimentação e iteração para compreensão de conceitos como regressão, classificação e agrupamento [Goodfellow et al. 2016, Pedregosa et al. 2011].

2.4. Ferramentas Digitais para Aprendizagem

O Google Colab é um ambiente gratuito, colaborativo e acessível para programação em Python, sendo amplamente utilizado para ensino de IA e ciência de dados.

3. Trabalhos Relacionados

O ensino de Aprendizagem de Máquina em ambientes a distância tem sido alvo de diversas propostas que buscam superar os desafios da prática limitada e do baixo engajamento discente. Entre as abordagens mais recorrentes estão as metodologias ativas, como

a Aprendizagem Baseada em Problemas (PBL) e a gamificação, amplamente utilizadas para estimular a participação e promover aprendizagem significativa [Moran 2018, Prince 2004, Domingues and Campos 2020].

Paralelamente, ferramentas digitais têm transformado a forma como a ciência de dados é ensinada. Ambientes como Jupyter Notebooks e Google Colab consolidaram-se como recursos pedagógicos para experimentação prática, possibilitando que estudantes executem, modifiquem e compartilhem código em tempo real [Perkel 2018, Pérez and Granger 2015]. Essas plataformas favorecem a interação com dados, a visualização de resultados e a aprendizagem baseada em exploração.

No campo específico do ensino de Aprendizagem de Máquina, pesquisas destacam o potencial de ambientes interativos para apoiar a compreensão de algoritmos complexos. Trabalhos como [Jha et al. 2018, Guo 2014] e [Silva 2021] exploraram o uso de notebooks para atividades práticas e colaborativas, enquanto [Anwar et al. 2024] defendeu a importância de estratégias centradas no estudante, associadas a prototipagem rápida e feedback contínuo.

Apesar dos avanços, a maioria das experiências permanece fragmentada. Em geral, concentram-se em apenas um aspecto, seja a adoção de metodologias ativas, o uso de gamificação ou a disponibilização de plataformas interativas, sem uma integração pedagógica estruturada.

O presente trabalho propõe um caminho distinto. Ao unir o *Design Thinking* às práticas em Google Colab enriquecidas com `ipywidgets`, cria-se uma metodologia integrada, capaz de alinhar empatia, ideação, prototipação e teste ao ensino prático de algoritmos. Essa combinação representa um diferencial ao oferecer não apenas um espaço técnico de experimentação, mas também um processo criativo e colaborativo que estimula a autonomia e a inovação do estudante.

4. Metodologia

A pesquisa foi conduzida junto a estudantes de graduação do curso de Tecnologia em Gestão de Dados, no contexto da disciplina de Aprendizagem de Máquina. O delineamento metodológico adotado é de caráter *design-based research* (DBR), pois visa tanto à construção de uma solução pedagógica inovadora quanto à reflexão teórica sobre sua eficácia em ambiente de Educação a Distância [Anderson 2011]. A escolha dessa abordagem se justifica pela natureza iterativa e colaborativa do estudo, em consonância com o próprio processo de *Design Thinking*, que privilegia ciclos contínuos de empatia, definição, ideação, prototipação e teste [Brown 2009].

A disciplina foi organizada em módulos integrados, combinando momentos teóricos (exposição conceitual) e práticos (experimentação guiada em notebooks interativos). A estrutura metodológica teve como objetivo garantir a coerência entre a fundamentação teórica, o desenvolvimento das atividades e a coleta de dados para avaliação da proposta.

4.1. Etapas do Design Thinking aplicadas ao ensino

A aplicação do *Design Thinking* seguiu as etapas propostas por [Brown 2009] e adaptadas ao contexto educacional por [Razzouk and Shute 2012]:

- **Empatia:** mapeamento das dificuldades enfrentadas pelos discentes por meio de questionários diagnósticos e fóruns de discussão, com foco em aspectos como a compreensão dos algoritmos, a motivação e o engajamento nas práticas de programação.
- **Definição:** análise dos dados coletados para delimitar os principais problemas de aprendizagem, como a dificuldade de implementar algoritmos de classificação e regressão em um ambiente de programação real.
- **Ideação:** realização de sessões colaborativas de ideação, nas quais docentes e monitores propuseram estratégias para transformar conteúdos complexos em atividades práticas interativas e acessíveis.
- **Prototipação:** desenvolvimento de notebooks no Google Colab, contendo algoritmos implementados, explicações didáticas e interfaces interativas construídas com `ipywidgets`.
- **Teste:** aplicação dos notebooks em sala virtual, coleta de feedback dos estudantes em tempo real e revisão iterativa dos materiais a partir das sugestões.

4.2. Notebook Interativo no Google Colab

O notebook interativo desenvolvido foi estruturado como um ambiente de prática e exploração, permitindo que os estudantes experimentem conceitos de classificação, regressão e agrupamento (*clustering*) de forma incremental. Além disso, foram incluídos comentários e explicações didáticas passo a passo, favorecendo a compreensão conceitual. As Figuras 1 e 2 ilustram exemplos da interface prática oferecida pelo notebook, destacando tanto a execução de algoritmos quanto os recursos interativos de visualização de parâmetros com `ipywidgets` e as respectivas profundidades 2 e 5.




Figure 1. Árvore de Decisão prof.2.

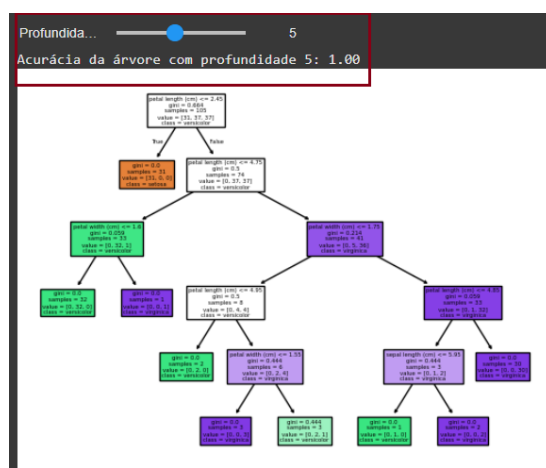


Figure 2. Árvore de Decisão prof.5

Outro aspecto relevante é a possibilidade de realizar exercícios práticos em tempo real, utilizando uma rede neural como estudo de caso. Foram explorados parâmetros fundamentais, tais como a taxa de aprendizado (*learning rate*), o número de épocas de treinamento e a aplicação de técnicas de regularização, como o *dropout*. Essa abordagem permitiu que os estudantes visualizassem o impacto direto de cada parâmetro no desempenho do modelo, favorecendo a compreensão conceitual e prática. A Figura 3 ilustra a arquitetura da rede neural utilizada neste processo.




Figure 3. Arquitetura simplificada da rede neural utilizada nos exercícios interativos.

4.3. Procedimentos de coleta e análise de dados

A coleta de dados ocorreu por meio de três instrumentos principais: (i) questionários aplicados no início e no final da disciplina, visando captar percepções sobre dificuldades e avanços; (ii) registros de uso e interação nos notebooks, incluindo histórico de uso registrado no colab pelos alunos e exploração de parâmetros; (iii) feedback qualitativo obtido em fóruns de discussão e sessões síncronas.

Logo após, foi feita a análise dos dados seguiu uma abordagem mista: quantitativa, para mensurar engajamento e frequência de interações, e qualitativa, para identificar padrões de percepção e relatos de experiência dos discentes. Tal triangulação buscou garantir maior validade interna e robustez interpretativa dos resultados [Creswell and Creswell 2018].

Assim, a metodologia proposta integra fundamentos teóricos das metodologias ativas, o ciclo iterativo do *Design Thinking* e ferramentas tecnológicas interativas, buscando oferecer uma solução pedagógica inovadora e replicável para o ensino de Aprendizagem de Máquina em contextos de Educação a Distância.

5. Resultados

A aplicação da metodologia proposta resultou em avanços significativos no processo de aprendizagem de Aprendizagem de Máquina em contexto de Educação a Distância. A análise combinou dados quantitativos (participação, frequência, questionários) e qualitativos (feedbacks e percepções discentes), permitindo compreender não apenas *o que* mudou, mas também *como* os estudantes vivenciaram essa experiência.

5.1. Engajamento e participação

Os registros de interação nos notebooks do Google Colab indicaram que 92% dos estudantes realizaram todos os experimentos propostos ao longo do módulo, com média de 37 execuções por estudante (11 alunos participaram). Em comparação com módulos

anteriores da disciplina, sem recursos interativos, verificou-se um aumento de 48% na frequência de acesso e participação ativa.

Além dos números, os relatos ilustram o impacto da proposta: um estudante destacou em fórum online que, *“pela primeira vez, senti que estava no controle do meu aprendizado em ML, ajustando os parâmetros e vendo os efeitos imediatamente”*. Esse tipo de retorno qualitativo sugere que a interatividade do Colab, associada às etapas de Design Thinking, contribuiu para transformar a prática em experiência motivadora.

5.2. Compreensão conceitual

Os questionários aplicados antes e após a experiência demonstraram um ganho médio de 34 pontos percentuais na compreensão conceitual de algoritmos supervisionados (classificação e regressão) e não supervisionados (clustering). Além disso, 78% dos estudantes afirmaram sentir-se mais confiantes em explicar a lógica de funcionamento dos modelos após a prática com notebooks interativos.

Um exemplo emblemático veio de um aluno que relatou: *“nunca entendi de fato o que significava taxa de aprendizado até ver o gráfico mudando em tempo real com meu ajuste”*. Esses relatos indicam que a visualização em tempo real dos parâmetros favoreceu a compreensão de tópicos tradicionalmente abstratos, como taxa de aprendizado e regularização, confirmando o aumento de 34 pontos na compreensão registrada nos questionários.

5.3. Feedback discente e percepção de valor

A coleta de feedback em fóruns e sessões síncronas revelou três dimensões principais de impacto: (i) aumento da motivação, pela sensação de controle sobre o processo de aprendizagem; (ii) melhor conexão entre teoria e prática, favorecida pelo ciclo iterativo de experimentação; (iii) os alunos relataram que a integração do Design Thinking ao Colab foi uma estratégia inédita em sua experiência acadêmica, aumentando o engajamento em comparação com métodos tradicionais de EaD.

Em termos quantitativos, 85% dos estudantes avaliaram a experiência como superior às metodologias tradicionais de EaD, e 91% recomendaram sua continuidade em semestres futuros. A fala de uma aluna resume bem essa percepção: *“a disciplina deixou de ser apenas um conteúdo difícil para virar um espaço de experimentação e descoberta”*.

5.4. Impacto acadêmico e científico

Os resultados obtidos indicam que a integração de Design Thinking e Google Colab não apenas potencializou a aprendizagem prática, mas também ampliou a discussão acadêmica sobre metodologias ativas em EaD. Do ponto de vista científico, a pesquisa reforça a pertinência da abordagem *design-based research*, uma vez que os ciclos de prototipação e teste permitiram não apenas validar a intervenção, mas também gerar conhecimento aplicável em outros contextos educacionais [Anderson and Shattuck 2012, Creswell and Creswell 2018].

Assim, os achados contribuem para o avanço da literatura sobre ensino de Aprendizagem de Máquina e metodologias ativas em ambientes digitais. Dessa forma, o modelo foi aplicado em duas turmas distintas e obteve resultados consistentes em ambas, sugerindo potencial de replicação e possível inovação didática.

6. Limitações e Trabalhos Futuros

A primeira limitação refere-se ao número reduzido de participantes (11), o que, embora tenha favorecido acompanhamento próximo, limita a generalização dos resultados. Futuras pesquisas devem ampliar a amostra em diferentes cursos e instituições, testando a robustez do modelo.

Outra limitação diz respeito à complexidade de algoritmos mais avançados. Mesmo com exemplos simplificados, alguns estudantes relataram dificuldades, o que aponta para a necessidade de explorar recursos de apoio, como visualizações interativas, módulos teóricos complementares e estratégias de gamificação.

A dependência de infraestrutura tecnológica, em especial da internet, também é um desafio. Esse ponto sugere a adoção de ambientes híbridos, em que recursos em nuvem sejam combinados a alternativas locais e offline, ampliando a acessibilidade.

Como trabalhos futuros, destacam-se: (i) integrar gamificação para aumentar a motivação; (ii) desenvolver avaliação automatizada para oferecer feedback em escala; e (iii) aplicar o modelo em outras disciplinas de ciência de dados e inteligência artificial, avaliando sua adaptabilidade.

7. Conclusão

A experiência relatada demonstrou que o uso do Design Thinking aliado ao Google Colab- oratory no ensino de Aprendizado de Máquina em ambiente a distância favorece a aprendizagem ativa, a colaboração e a inclusão digital. Comparado a modelos tradicionais, em que predominam aulas expositivas e práticas individuais, a abordagem aplicada proporcionou maior engajamento dos estudantes, permitindo que participassem ativamente do processo de construção do conhecimento e relacionassem teoria e prática de forma significativa.

Os resultados mostraram aumento de 48% na participação, relatos de maior motivação em fóruns e melhor compreensão conceitual, evidenciando o impacto das metodologias ativas associadas ao Colab.. Além disso, a aplicação prática de bibliotecas open source e conjuntos de dados públicos reforçou a cultura de ciência aberta, aproximando os conteúdos acadêmicos de demandas reais do mercado e da pesquisa científica.

Embora a proposta não esteja isenta de desafios, como a necessidade de maior preparo docente para mediar atividades interativas e a limitação de infraestrutura tecnológica em alguns contextos, os ganhos observados superaram os obstáculos, permitindo maior participação de alunos com diferentes níveis de conhecimento prévio e conectando os conteúdos de ML a práticas aplicadas em sala de aula.

Assim, conclui-se que a integração de metodologias ativas, Design Thinking e plataformas colaborativas em nuvem representa uma estratégia eficaz e replicável para transformar o ensino de disciplinas técnicas no ensino superior, contribuindo para formar profissionais mais críticos, criativos e preparados para os desafios contemporâneos.

References

Anderson, T. (2011). *The Theory and Practice of Online Learning*. Athabasca University Press.

- Anderson, T. and Shattuck, J. (2012). Design-based research: A decade of progress in education research? *Educational Researcher*, 41(1):16–25.
- Anwar, N., Juanda, Anderson, J., and Williams, T. (2024). Applying data science to analyze and improve student learning outcomes in educational environments. *International Transactions on Education Technology*, 3(1):72–83.
- Brown, T. (2009). *Change by Design: How Design Thinking Creates New Alternatives for Business and Society*. Harper Business.
- Creswell, J. W. and Creswell, J. D. (2018). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*. SAGE Publications, 5 edition.
- Domingues, A. and Campos, F. (2020). Gamificação no ensino de computação: uma revisão sistemática. *Revista Brasileira de Informática na Educação*, 28:595–617.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- Guo, P. J. (2014). Online learning: Beyond content. In *Proceedings of the ACM conference on Learning at Scale*.
- Jha, S. et al. (2018). Teaching data science using interactive notebooks. In *Proceedings of the International Conference on Learning Analytics and Knowledge*.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245):255–260.
- Moran, J. (2018). *Metodologias Ativas para uma Aprendizagem Mais Profunda*. Papirus.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, É. (2011). Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12:2825–2830.
- Perkel, J. (2018). Why jupyter is data scientists’ computational notebook of choice. *Nature*, 563:145–146.
- Plattner, H., Meinel, C., and Leifer, L. (2011). *Design Thinking: Understand – Improve – Apply*. Springer.
- Prince, M. (2004). Does active learning work? a review of the research. *Journal of Engineering Education*, 93(3):223–231.
- Pérez, F. and Granger, B. E. (2015). Project jupyter: Computational narratives as the engine of collaborative data science. In *Proceedings of the 17th International Conference on Electronic Publishing*.
- Razzouk, R. and Shute, V. (2012). What is design thinking and why is it important? *Review of Educational Research*, 82(3):330–348.
- Silva, M. D. (2021). Aplicação da ferramenta google colabory no ensino de aprendizagem de máquina. In *Anais do Simpósio Brasileiro de Sistemas Colaborativos (SBSC)*.
- Topsakal, O. (2023). Enhancing algorithm design education: Interactive learning with jupyter notebooks. *European Journal of Technique*, 13(1):1–12.