

Framework Pedagógico para Machine Learning em Contextos de Baixa Conectividade: Uma Caracterização Empírica em Moçambique

Jean M. John¹, Cecilia Tivir²

¹Faculdade de Engenharia e Ciências Aplicadas
Universidade Metodista Unida de Moçambique – Inhambane, Moçambique

²Laboratoire d'Analyse Numérique et Informatique (LANI)
Gaston Berger University (UGB) BP:234, Saint-Louis, Senegal

jhonjeanmarie@gmail.com, tivir.cecilia-rafael-jose@ugb.edu.sn

Abstract. *This study establishes the baseline for validating the Low-Resource Machine Learning Pedagogical Framework (LR-MLPF) in the Mozambican context, with 75 participants from higher education, divided into two groups: experimental (n=56) and a control (n=19). Although 81.3% own computers, there are structural limitations, such as a lack of home Internet access (26.7%) and weekly power outages (54.7%). Self-efficacy in ML was moderate ($M=3.66$; $SD=0.68$; $\alpha=0.81$), with weaker performance in offline learning ($M=3.21$). Statistical tests confirmed the equivalence of the groups, highlighting the need for adapted pedagogical approaches and providing a foundation for future evaluations of the LR-MLPF's impact.*

Keywords—*Machine Learning, Higher Education, Low-Resource, Mozambique, Self-efficacy, LR-MLPF*

Resumo. *Este estudo estabelece a linha de base para validar o Low-Resource Machine Learning Pedagogical Framework (LR-MLPF) no contexto moçambicano, com 75 participantes do ensino superior, divididos em grupo experimental (n=56) e controle (n=19). Apesar de 81,3% terem computadores, há limitações estruturais, como ausência de Internet em casa (26,7%) e cortes semanais de energia (54,7%). A autoeficácia em ML foi moderada ($M=3,66$; $DP=0,68$; $\alpha=0,81$), com fragilidade na aprendizagem offline ($M=3,21$). Testes estatísticos confirmaram a equivalência dos grupos, evidenciando a necessidade de abordagens pedagógicas adaptadas e fundamentando futuras avaliações do impacto do LR-MLPF.*

Palavras-chave—*Machine Learning, Educação Superior, Recursos Limitados, Moçambique, Autoeficácia, LR-MLPF*

1. Introdução

O Machine Learning (ML) evoluiu de uma disciplina experimental para um motor central de inovação em setores estratégicos como saúde, agricultura, finanças e governação digital. Contudo, a narrativa dominante de que a Inteligência Artificial (IA)

é inerentemente democrática tende a obscurecer as desigualdades infraestruturais que condicionam a sua produção e utilização. Nessa perspectiva, Couldry e Mejias [Couldry and Mejias 2020] argumentam que a dependência de infraestruturas digitais globais consolida novas formas de colonialismo, enquanto Crawford [Crawford 2021] demonstra que estes sistemas dependem de cadeias globais de recursos materiais e infraestruturais desigualmente distribuídos.

No domínio educacional, a hegemonia das plataformas na nuvem (por exemplo, Google Colab, Kaggle) impõe uma arquitetura pedagógica que pressupõe conectividade estável. Contudo, em países da África Subsaariana, onde o acesso à internet permanece significativamente abaixo da média global, esta dependência cria barreiras estruturais ao acesso equitativo à formação em IA. Projetos que ignoram estas restrições materiais correm o risco de falhar ou, pior, de aprofundar as desigualdades já existentes ao excluir aqueles que operam fora dos centros de abundância tecnológica [Schwartz et al. 2020, Matenga and Rodas 2024].

Em Moçambique, estas limitações são agravadas pela instabilidade da rede elétrica, pelos elevados custos de dados móveis e pela obsolescência de equipamentos. Tal cenário pode ser compreendido à luz do que denominamos convergência de precariedade infraestrutural, ou seja, a intersecção entre limitações técnicas, económicas e pedagógicas que condicionam o desenvolvimento de competências digitais avançadas. Simultaneamente, muitos estudantes ingressam no ensino superior com lacunas acumuladas em literacia digital e lógica de programação, o que impacta a sua autoeficácia, conceito fundamental desenvolvido por Bandura [Bandura 1997], e influencia a sua persistência em áreas tecnológicas [Forero-Corba and Bennasar 2024, de Oliveira et al. 2023].

Neste contexto, o presente estudo constitui a fase inaugural do desenvolvimento e validação empírica do *Low-Resource Machine Learning Pedagogical Framework* (LR-MLPF), uma abordagem pedagógica baseada em ambientes de execução locais, datasets contextualizados e modelos de ML interpretáveis. Este artigo foca-se especificamente na caracterização da linha de base da amostra, respondendo à seguinte questão: *Qual é o perfil infraestrutural, de experiência prévia e de autoeficácia em ML dos estudantes e professores moçambicanos do ensino superior antes de qualquer intervenção pedagógica?*

Esta caracterização é uma contribuição original, dado que a literatura sobre ML em contextos africanos carece de dados empíricos de linha de base que possam fundamentar o design de frameworks pedagógicos adaptados [Sanusi et al. 2022].

O restante deste artigo está organizado da seguinte maneira: a Seção 2 revisa a literatura relevante sobre o ensino de ML em contextos de baixa conectividade; a Seção 3 detalha a metodologia do estudo; a Seção 4 apresenta os resultados; a Seção 5 discute os resultados e enumera as limitações do estudo; e a Seção 6 traz as conclusões e as implicações para trabalhos futuros.

2. Revisão da Literatura

A pesquisa sobre o ensino de ML e IA tem se expandido globalmente, mas concentra-se predominantemente em contextos com infraestruturas tecnológicas robustas, negligenciando as especificidades de ambientes com recursos limitados [Sanusi et al. 2023].

Na África, a integração dessas tecnologias à educação é dificultada por infraestruturas digitais frágeis, conectividade instável, escassez de dispositivos e formação insuficiente de professores [Matenga and Rodas 2024, Artur et al. 2024]. Birhane [Birhane 2020] denomina esse cenário de colonização algorítmica, no qual a dependência estrutural de plataformas globais e infraestruturas controladas por entidades estrangeiras consolida assimetrias no controle de dados e riscos de exploração [Couldry and Mejias 2020, Birhane 2020]. A adoção acrítica de soluções baseadas estritamente na nuvem (*cloud-based*), como Google Colab ou Kaggle, pressupõe uma estabilidade técnica inexistente em Moçambique e pode aprofundar as desigualdades educacionais e a dependência tecnológica, em vez de mitigá-las [Schwartz et al. 2020, Artur et al. 2024].

Para superar essas barreiras, surgem abordagens focadas na eficiência e na execução local. O uso de TinyML possibilita a execução de modelos em dispositivos com recursos limitados, reduzindo a dependência da internet, os custos de comunicação e os riscos à privacidade [Sanusi et al. 2022, Chee et al. 2025, Warden and Situnayake 2019]. Tais iniciativas estão alinhadas ao movimento Green AI [Schwartz et al. 2020], que preconiza a eficiência computacional como uma dimensão ética e sustentável do desenvolvimento tecnológico. Ademais, a defesa de Rudin [Rudin 2019] de modelos interpretáveis e transparentes torna-se estratégica em contextos educacionais, pois evita o tecno-solucionismo e garante que o foco pedagógico esteja na compreensão conceitual profunda, e não apenas na execução de processos opacos.

A eficácia dessas ferramentas, no entanto, depende de quadros de competências e de uma base pedagógica sólida. Revisões sistemáticas da literatura indicam que a alfabetização em IA deve abranger desde conhecimentos básicos e ética até a integração interdisciplinar de ML nos currículos [Sanusi et al. 2023]. A fundamentação deste estudo integra o Construtivismo social [Vygotsky 1978], que vê a aprendizagem como um processo mediado por ferramentas culturais, e a teoria da Autoeficácia [Bandura 1997], essencial para compreender como a precariedade material afeta a confiança técnica dos estudantes. Por fim, a Teoria da Autodeterminação [Deci and Ryan 2012] oferece a lente necessária para analisar a motivação intrínseca dos alunos moçambicanos, que, apesar dos obstáculos infraestruturais, frequentemente valorizam a relevância local do ML. Dessa maneira, a união dessas perspectivas fundamenta o design do LR-MLPF como uma resposta situada e soberana aos desafios da desigualdade digital.

3. Metodologia

3.1. Design do Estudo

Este artigo reporta a fase de caracterização da linha de base de um estudo de maior dimensão centrado no desenvolvimento e validação do *Low-Resource Machine Learning Pedagogical Framework*. A amostra foi distribuída em dois grupos: um grupo experimental ($n = 56$), exposto ao LR-MLPF com execução local, e um grupo de controle ($n = 19$), que utiliza plataformas baseadas na nuvem (Google Colab / Kaggle). A linha de base foi coletada através de um inquérito por questionário aplicado antes de qualquer intervenção pedagógica, com o objetivo de descrever empiricamente o perfil infraestrutural, de experiência em programação, de autoeficácia em ML e de motivação percebida dos participantes.

A opção por um estudo de linha de base prévio à intervenção justifica-se pela necessidade de fundamentar empiricamente o design do LR-MLPF em dados contextuais reais, e não em pressupostos importados de contextos tecnologicamente distintos [Sanusi et al. 2022]. Esta fase constitui também uma contribuição metodológica original, dado que estudos sobre o ensino de ML na África raramente incluem instrumentos validados de caracterização prévia [Couldry and Mejias 2020].

3.2. Participantes e Contexto

A amostra é composta por 75 participantes recrutados por conveniência em instituições de ensino superior moçambicanas: 66 estudantes e 9 professores, apresentando uma amplitude etária de 18 a 74 anos ($M = 24,5$; $DP = 7,7$). Os participantes distribuem-se pelas províncias de Maputo Cidade ($n = 25$; 33,3%), Inhambane ($n = 23$; 30,7%), Maputo Província ($n = 18$; 24,0%), Nampula ($n = 2$; 2,7%), Sofala ($n = 2$; 2,7%), Manica ($n = 2$; 2,7%), e ainda Cabo Delgado, Tete e Niassa com um participante cada (1,3%). A distribuição por género é equilibrada: 36 do género masculino (48,0%), 37 do género feminino (49,3%) e 2 que preferiram não indicar (2,7%).

Os critérios de inclusão foram: (i) ser estudante matriculado ou professor ativo numa instituição de ensino superior moçambicana; (ii) ter conhecimentos básicos de lógica de programação ou de ensino de tecnologias; e (iii) assinar o formulário de consentimento informado. Participantes sem contato prévio com ambientes computacionais foram incluídos, dado que a acessibilidade a perfis com diferentes níveis de literacia digital é um dos objetivos do LR-MLPF.

Da base de dados bruta recolhida ($N = 77$), dois registos foram excluídos por inconsistência antes da análise: um participante com idade declarada de 14 anos (abaixo do critério de elegibilidade de ensino superior) e um registo em que o campo idade continha um nome próprio em vez de um valor numérico, ambos indicativos de erro de preenchimento. A amostra analítica final é, portanto, $N = 75$.

3.3. Instrumento de Coleta de Dados

O instrumento de coleta consistiu em um questionário estruturado de pré-teste, organizado em cinco seções fundamentais: (1) perfil sociodemográfico; (2) infraestrutura tecnológica; (3) experiência prévia em programação; (4) autoeficácia em ML, composta por cinco itens em escala de Likert (1 a 5), adaptados da Escala de Eficácia Computacional [Murphy et al. 1989] e dos constructos de Bandura [Bandura 1997]; e (5) motivação e relevância percebida, baseadas na Teoria da Autodeterminação [Deci and Ryan 2012] e em estudos sobre o ensino de ML em contextos africanos.

Para garantir a validade de conteúdo, o questionário foi revisado por dois especialistas em educação tecnológica e submetido a um teste piloto com cinco participantes (não incluídos na amostra final), cujos resultados possibilitaram ajustes na clareza e na formulação dos itens. A aplicação final ocorreu em formato digital, por meio do Google Forms, entre abril e maio de 2026.

3.4. Análise dos Dados

A análise dos dados foi processada no ambiente Python, garantindo a reprodutibilidade do estudo por meio da utilização de bibliotecas padrão da comunidade científica. Para a manipulação, limpeza e estruturação do banco de dados, foi utilizada a biblioteca

Pandas [McKinney et al. 2010]. As operações numéricas foram fundamentadas na biblioteca NumPy [Harris et al. 2020], enquanto as análises estatísticas foram executadas por meio do SciPy.

A escala de autoeficácia apresentou completude total após a limpeza dos dados ($n=75$ em todos os itens). A escala de motivação registou omissões pontuais atribuíveis a uma falha técnica na exportação das respostas do Google Forms, em que um subconjunto de respostas foi gravado com um rótulo de coluna inválido em vez do valor Likert selecionado, afetando entre 10 e 14 respostas por item (13,3% a 18,7% dos casos). Estes casos foram tratados como valores omissos (*missing*) e excluídos de forma *pairwise* no cálculo das médias por item e *listwise* no cálculo do coeficiente alfa de Cronbach da escala de motivação ($n = 50$ casos completos). Em virtude da natureza exploratória desse estágio, a metodologia empregada concentrou-se na estatística descritiva, abrangendo o cálculo de médias, desvios-padrão, frequências e porcentagens. Para a análise quantitativa, as respostas na escala de Likert foram codificadas numericamente de 1 (discordo totalmente) a 5 (concordo totalmente).

Por fim, a confiabilidade e consistência interna das escalas de autoeficácia e motivação foram validadas por meio do coeficiente alfa de Cronbach (α).

3.5. Considerações Éticas

Todos os participantes assinaram um formulário de consentimento informado, com a possibilidade de desistência sem penalização. O formulário de coleta solicitou o endereço de e-mail dos participantes apenas para fins de verificação de consentimento e de contato de acompanhamento; para efeitos de análise e de reporte, os dados foram anonimizados por meio de códigos de participante, e o arquivo de correspondência entre códigos e identidades reais é mantido num sistema protegido por senha, acessível apenas à equipe de investigação.

4. Resultados

4.1. Perfil Sociodemográfico e Infraestrutura Tecnológica

Os dados apresentados na Tabela 1 revelam um cenário de precariedade infraestrutural moderada, o que sustenta a necessidade de soluções offline. Embora a maioria dos participantes possua computador pessoal (81,3%), a eficácia dessa ferramenta é limitada por barreiras estruturais: 26,7% não têm internet residencial, e 54,7% enfrentam cortes de energia recorrentes (de uma a cinco vezes por semana). Esta combinação de posse de hardware com instabilidade de serviços básicos caracteriza o cenário de precariedade infraestrutural [Matenga and Rodas 2024, Artur et al. 2024].

Tabela 1. Perfil de infraestrutura tecnológica dos participantes (N = 75).

Indicador	n	%
Possui computador próprio	61	81,3
Dispositivo principal: portátil pessoal	47	62,7
Dispositivo principal: telemóvel	26	34,7
Dispositivo principal: PC de laboratório	1	1,3
Dispositivo principal: tablet	1	1,3
Sem acesso à Internet em casa	20	26,7
Cortes de eletricidade: nenhum	34	45,3
Cortes de eletricidade: 1 - 2 vezes/semana	38	50,7
Cortes de eletricidade: 3 - 5 vezes/semana	3	4,0

4.2. Experiência Prévia em Programação e ML

A amostra apresenta elevada heterogeneidade técnica, exigindo uma progressão pedagógica cuidadosa no LR-MLPF, 29,3% dos participantes nunca programaram, enquanto 29,3% já realizaram tarefas de ML anteriormente. A utilização de Python é comum entre mais de metade dos participantes (50,7%), o que sugere a existência de uma base de sintaxe lógica que pode ser aproveitada, apesar da escassez de competências específicas em ML. A Tabela 2 apresenta o perfil de experiência em programação dos participantes.

Tabela 2. Experiência prévia em programação e ML (N = 75).

Indicador	n	%
Nunca programou	22	29,3
Menos de 1 ano de experiência	12	16,0
1 - 2 anos de experiência	19	25,3
3 - 5 anos de experiência	17	22,7
Mais de 5 anos de experiência	5	6,7
Já utilizou Python anteriormente	38	50,7
Nunca utilizou Python	37	49,3
Já realizou tarefa de ML anteriormente	22	29,3
Sem experiência prévia em ML	53	70,7

4.3. Autoeficácia em Machine Learning

A autoeficácia global em ML foi avaliada através de cinco itens em escala de Likert (1 - 5), com consistência interna adequada ($\alpha = 0,81$) (com mais detalhes na Tabela 3). O nível médio global de autoeficácia em ML é moderado a bom ($M = 3,66$; $DP = 0,68$; $\alpha = 0,81$). A análise por item revela um ponto crítico para investigação: a confiança para aprender e praticar ML sem acesso à internet ($M = 3,21$) é a dimensão mais baixa, cerca de 0,84 pontos abaixo da dimensão mais alta. Essa fragilidade demonstra que a dependência de plataformas em nuvem (como o Google Colab) torna a competência de execução local menos treinada, deixando os estudantes vulneráveis quando a conectividade falha. Em contrapartida, a maior confiança está na capacidade de aprender de forma independente ($M = 4,05$).

Tabela 3. Autoeficácia em ML por item (N = 75; escala 1 - 5; $\alpha = 0,81$).

Item	M	DP	n
Aprender ML de forma independente	4,05	0,82	75
Escrever código de ML sem assistência constante	3,68	0,96	75
Resolver erros no código de forma autônoma	3,65	0,85	75
Aprender e praticar ML sem acesso à Internet	3,21	0,92	75
Explicar conceitos básicos de ML a outra pessoa	3,69	0,94	75
Média global de autoeficácia	3,66	0,68	75

4.4. Motivação e Relevância Percebida

A motivação dos participantes é o dado mais positivo do estudo, apresentando uma média global $M=3,77$ ($DP=1,11$), ligeiramente superior à autoeficácia técnica percebida, com uma confiabilidade de escala muito elevada ($\alpha = 0,91$). Como descrito na Seção 3.4, os itens de motivação apresentam n variável por item devido a uma falha de exportação do formulário; a Tabela 4 reporta o n efetivo de respostas válidas para cada item.

Os itens com maior pontuação referem-se à importância profissional do ML ($M = 4,07$) e ao seu potencial para o desenvolvimento de Moçambique ($M = 3,95$). Este resultado sugere uma autoeficácia aspiracional: os participantes valorizam o impacto e o prestígio da tecnologia, mesmo enfrentando barreiras materiais severas. A Figura 1 apresenta uma comparação entre as médias de autoeficácia e de motivação, organizadas na mesma ordem de apresentação das Tabelas 2 e 4.

Tabela 4. Motivação e relevância percebidas por item (escala 1 - 5; $\alpha = 0,91$). O α de Cronbach foi calculado sobre os n = 50 casos com resposta completa em todos os itens.

Item	M	DP	n
Aprender ML é importante para a trajetória profissional	4,07	1,22	61
O ML tem potencial para o desenvolvimento de Moçambique	3,95	1,14	62
Estudaria ML fora das aulas se tivesse materiais adequados	3,81	1,32	62
Desenvolver projetos de ML para problemas reais	3,60	1,40	65
Disposto(a) a investir tempo e esforço na aprendizagem	3,50	1,32	64
Média global de motivação	3,77	1,11	75*

*A média global é calculada por participante, com base nos itens efetivamente respondidos.

4.5. Comparação de Equivalência entre Grupos

Dado que a amostra foi distribuída em grupo experimental ($n = 56$) e grupo de controle ($n = 19$), realizou-se uma comparação de equivalência na linha de base por meio de testes t de Welch para amostras independentes. Não foram encontradas diferenças estatisticamente significativas entre os grupos quanto à idade ($M_{\text{exp}} = 24,6$; $M_{\text{ctl}} = 24,1$; $t = 0,35$; $p = 0,727$), à autoeficácia global ($M_{\text{exp}} = 3,61$; $M_{\text{ctl}} = 3,80$; $t = -1,05$; $p = 0,300$) ou à motivação global ($M_{\text{exp}} = 3,76$; $M_{\text{ctl}} = 3,79$; $t = -0,09$; $p = 0,931$). Este resultado sugere que os dois grupos partiam de perfis comparáveis antes da intervenção, o que reforça a validade de futuras comparações de impacto entre eles.




Figura 1. Comparação entre autoeficácia e motivação, por item (N = 75; itens de Motivação com variável).

5. Discussão

Os resultados da caracterização da linha de base fornecem evidências empíricas que fundamentam e legitimam a proposta do LR-MLPF. Três achados principais merecem discussão:

1. A coexistência de uma posse considerável de hardware (81,3%) com a instabilidade energética (54,7% de cortes semanais) e a falta de conectividade (26,7%) configura o que denominamos configuração de precariedade infraestrutural. Tal condição não se caracteriza como uma ausência absoluta de recursos, mas sim como um cenário de acesso instável e imprevisível. Tal realidade demanda soluções pedagógicas que rompam com a dependência da nuvem (*cloud-based*). O LR-MLPF atende a esse perfil ao priorizar ambientes de execução local, assegurando que o processo de aprendizagem não seja interrompido por falhas externas à sala de aula. Dessa forma, promove-se a soberania tecnológica defendida por Couldry e Mejias [Couldry and Mejias 2020].
2. O padrão de autoeficácia observado, com confiança global moderada a boa ($M = 3,66$) mas fragilidade específica para operar em contextos off-line ($M = 3,21$), é consistente com o conceito de autoeficácia aspiracional. A lacuna observada entre o item de maior confiança (aprendizagem independente, $M = 4,05$) e o de menor confiança (prática offline, $M = 3,21$) (vide Figura 1 indica que as plataformas em nuvem tendem a tornar a competência de execução local menos treinada. Consequentemente, o design instrucional do LR-MLPF deve incluir ciclos frequentes de tentativa, erro e correção guiada, transformando o entusiasmo aspiracional em competência técnica consolidada. Conforme postulado por Bandura [Bandura 1997], a crença na própria capacidade constitui um fator motivacional para a persistência. Os dados indicam que a motivação

global ($M = 3,77$) permanece ligeiramente superior à autoeficácia global ($M = 3,66$) [Forero-Corba and Bennasar 2024], uma diferença mais discreta do que inicialmente estimado, mas consistente item a item nas dimensões de execução prática.

3. A elevada percepção de importância do ML para a trajetória profissional ($M = 4,07$) e para o desenvolvimento de Moçambique ($M = 3,95$) revela uma janela motivacional dupla (individual e coletiva). Conforme a Teoria da Autodeterminação [Deci and Ryan 2012], tal motivação intrínseca constitui um recurso valioso, passível de ser ativado por meio da contextualização pedagógica. O uso de datasets moçambicanos no framework não se trata apenas de uma escolha técnica, mas sim de uma estratégia para alinhar o ensino com as aspirações de impacto social dos participantes, reduzindo o risco de tecnosolucionismo estrangeiro.

A comparação de equivalência entre grupos (Seção 4.5) não revelou diferenças significativas na linha de base, o que reforça que eventuais diferenças observadas numa fase futura de avaliação de impacto poderão ser atribuídas com maior confiança à intervenção, e não a diferenças pré-existentes entre os grupos.

A validade interna das escalas foi confirmada por coeficientes de alfa de Cronbach robustos ($\alpha_{AE} = 0,81$ para autoeficácia e $\alpha_{MOT} = 0,91$ para motivação), o que garante a confiabilidade dos instrumentos para medir o impacto futuro da intervenção.

5.1 Limitações

Este estudo apresenta limitações que devem ser explicitamente reconhecidas. A amostra de 75 participantes, recrutada por conveniência, apresenta natureza exploratória e contextual, não permitindo a generalização populacional para todo o ensino superior moçambicano. Em segundo lugar, a representação de professores ($n = 9$) é ainda insuficiente para a realização de análises diferenciais robustas. Ademais, a concentração geográfica em Inhambane e Maputo Cidade pode subestimar as restrições infraestruturais de províncias mais remotas.

A escala de motivação apresentou respostas em falta em vários itens (entre 13,3% e 18,7% por item), decorrentes de uma falha técnica de exportação do formulário e não de recusa dos participantes em responder; ainda assim, isto reduz o n efetivo por item e exige cautela na interpretação das médias e, sobretudo, do coeficiente de alfa de Cronbach da motivação, calculado apenas sobre os 50 casos completos. Esta falha foi identificada e corrigida durante a preparação da presente versão do artigo; estudos futuros devem validar o processo de exportação de dados antes da coleta para evitar recorrência. A amplitude etária da amostra (18 a 74 anos) reflete a diversidade de perfis recrutados, mas introduz heterogeneidade que poderá ser relevante para análises diferenciadas em fases subsequentes.

6. Conclusão e Trabalhos Futuros

Este estudo apresentou a caracterização da linha de base de 75 participantes do ensino superior moçambicano, fornecendo, dessa forma, a fundamentação empírica para o design do framework LR-MLPF. Os resultados obtidos demonstram que o perfil em questão é caracterizado por uma combinação de precariedade infraestrutural, na qual a posse de hardware (81,3%) é mitigada pela instabilidade energética (54,7%) e pela falta

de conectividade (26,7%). Foi identificada uma autoeficácia aspiracional: embora a confiança técnica seja de moderada a boa ($M = 3,66$), a motivação ($M = 3,77$) e o reconhecimento da relevância do ML para o desenvolvimento do país ($M = 3,95$) permanecem, de forma consistente, ligeiramente superiores, constituindo um recurso valioso para intervenções pedagógicas.

Apesar do rigor aplicado na coleta de dados, este estudo apresenta limitações que devem ser consideradas na interpretação dos resultados (Seção 5.1): a natureza exploratória e não probabilística da amostra, a representação ainda insuficiente de professores ($n = 9$), a concentração geográfica em Maputo Cidade e Inhambane, e a heterogeneidade introduzida pelo amplo espectro etário (18 a 74 anos), que poderá demandar análises segmentadas na etapa de avaliação de impacto do framework.

Como trabalhos futuros, a implementação integral da intervenção pedagógica do LR-MLPF é prevista, seguida de uma avaliação de impacto por meio de pós-teste, com o objetivo de medir a evolução da autoeficácia e da motivação nos grupos experimental e de controle já caracterizados como equivalentes na linha de base. Ademais, há a pretensão de ampliar a amostra para outras províncias e desenvolver datasets pedagógicos contextualizados à realidade moçambicana, promovendo a soberania de dados. Em síntese, o escopo da investigação concentrar-se-á na exploração de modelos interpretáveis e técnicas de Green AI, que estejam alinhadas com a necessidade de eficiência computacional e transparência algorítmica em contextos de recursos limitados.

Referências

- Artur, B., Dinga, R. S., and Gonçalves, B. M. F. (2024). Uso de recursos digitais no ambiente escolar moçambicano:: desafios no ensino superior. *Video Journal of Social and Human Research*, 3(1):22–34.
- Bandura, A. (1997). *Self-efficacy: The exercise of control*. Macmillan.
- Birhane, A. (2020). Algorithmic colonization of africa. *SCRIPTed*, 17:389.
- Chee, H., Ahn, S., and Lee, J. (2025). A competency framework for ai literacy: Variations by different learner groups and an implied learning pathway. *British Journal of Educational Technology*, 56(5):2146–2182.
- Couldry, N. and Mejias, U. A. (2020). *The costs of connection: How data is colonizing human life and appropriating it for capitalism*. Stanford University Press.
- Crawford, K. (2021). *Atlas of AI: Power, Politics, and the Planetary Costs of Artificial Intelligence*. Yale University Press, New Haven.
- de Oliveira, L. A., dos Santos, A. M., Martins, R. C. G., and de Oliveira, E. L. (2023). Inteligência artificial na educação: uma revisão integrativa da literatura. *Peer Review*, 5(24):248–268.
- Deci, E. L. and Ryan, R. M. (2012). Self-determination theory. *Handbook of theories of social psychology*, 1(20):416–436.
- Forero-Corba, W. and Bennasar, F. N. (2024). Techniques and applications of machine learning and artificial intelligence in education: a systematic review. *RIED-Revista Iberoamericana de Educaci' on a Distancia*, 27(1).

XXI Latin-American Conference on Learning Technologies (LACLO 2026)

- Harris, C. R., Millman, K. J., Van Der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., et al. (2020). Array programming with numpy. *nature*, 585(7825):357–362.
- Matenga, J. A. M. and Rodas, C. M. (2024). Inteligência artificial e tecnologias: desafios para o desenvolvimento das competências docentes na educação em moçambique. *PerCursos*, 25:e0504–e0504.
- McKinney, W. et al. (2010). Data structures for statistical computing in python. *scipy*, 445(1):51–56.
- Murphy, C. A., Coover, D., and Owen, S. V. (1989). Development and validation of the computer self-efficacy scale. *Educational and Psychological measurement*, 49(4):893–899.
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature machine intelligence*, 1(5):206–215.
- Sanusi, I. T., Oyelere, S. S., and Omidiora, J. O. (2022). Exploring teachers’ preconceptions of teaching machine learning in high school: A preliminary insight from africa. *Computers and Education Open*, 3:100072.
- Sanusi, I. T., Oyelere, S. S., Vartiainen, H., Suhonen, J., and Tukiainen, M. (2023). A systematic review of teaching and learning machine learning in k-12 education. *Education and Information Technologies*, 28(5):5967–5997.
- Schwartz, R., Dodge, J., Smith, N. A., and Etzioni, O. (2020). Green ai. *Commun. ACM*, 63(12):54–63.
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*.
- Warden, P. and Situnayake, D. (2019). *Tinymml: Machine learning with tensorflow lite on arduino and ultra-low-power microcontrollers*. O’Reilly Media.