



Título do Trabalho:

Modelo de IA para o Sistema Financeiro: Regulação e Gestão Inteligente de Riscos em Moçambique

Autores

Nome: Izidine Jaime

Email: Izidine.jaime@gmail.com

Telefone: (+258) 84 671 3342

Lúcia Miguel Macuácuá

Lucia.miguelmacuacua@gmail.com

(+258) 87 733 1730

Nota dos Autores

O presente trabalho, intitulado "*Modelo de IA para o Sistema Financeiro: Regulação e Gestão Inteligente de Riscos em Moçambique*", foi elaborado no âmbito das XVII Jornadas Científicas do Banco de Moçambique — 2026, subordinadas ao tema "Regulamentação e Utilização da Inteligência Artificial no Sistema Financeiro Nacional: Riscos e Oportunidades".

Declaramos que o conteúdo deste documento é de nossa exclusiva autoria, resultante de investigação própria e de fontes devidamente citadas ao longo do texto. Os dados microprudenciais utilizados são de acesso público, disponibilizados na página oficial do Banco de Moçambique, e foram tratados em conformidade com os princípios de confidencialidade e minimização de dados descritos na Secção 3.1 deste trabalho.

As opiniões, análises, conclusões e recomendações expressas neste estudo são de inteira responsabilidade dos autores e não reflectem, necessariamente, a posição institucional do Banco de Moçambique, das instituições em que os autores exercem actividade profissional ou de qualquer outra entidade pública ou privada.

O protótipo SupTech apresentado constitui uma prova de conceito académica e não representa uma ferramenta oficial de supervisão do Banco de Moçambique. A sua eventual adopção operacional está sujeita aos processos de validação institucional descritos nas Perspectivas de Implementação (Secção 5.4).

Izidine Jaime · Lúcia Miguel Macuácuá

Índice

Resumo	1
1. Introdução	2
1.1. Contextualização do Problema de Pesquisa	2
1.2. Objectivos do Trabalho	3
1.2.1. Objectivo Geral.....	3
1.2.2. Objectivos Específicos	3
1.3. Questão Central de Pesquisa	5
1.4. Relevância e Justificação	5
1.5. Estrutura do Trabalho.....	7
2. Revisão de Literatura	8
2.1. Enquadramento Teórico	8
2.1.1. Sistemas de Alerta Precoce na Supervisão Bancária.....	8
2.1.2. Supervisory Technology (SupTech) e IA na Supervisão Financeira	9
2.1.3. Explicabilidade em IA: SHAP e Requisitos Regulatórios.....	9
2.1.4. RegTech, Smart Regulation e Sandboxes Regulatórias	10
2.2. Literatura Empírica	10
2.2.1. Modelos de ML para Previsão de NPL e Distress Bancário	10
2.2.2. Experiências Internacionais de Regulação de IA	11
2.2.3. O Contexto Moçambicano: Lacuna na Literatura	11
3. Metodologia	13
3.1. Dados e Amostra (Fase 1 — Diagnóstico e Colecta de Dados).....	13
3.2. Variável-Alvo: Definição de Distress Financeiro	14
3.3. Engenharia de Features e Factores BEF.....	15
3.3.1. Features BEF — Factores Estruturais e Ambientais	16

3.4. Modelos de Machine Learning (Fase 2 — Modelos Preditivos)	17
3.5. Framework de Regulamentação Adaptativa (Fase 3)	19
3.6. Validação Walk-Forward	19
3.7. Interpretabilidade — Valores SHAP (Componente XAI do OE1)	20
3.8. Simulação Monte Carlo de Stress Testing	20
3.9. Protótipo SupTech (Fase 4 — Plataforma de Supervisão Inteligente).....	21
4. Resultados do Estudo	23
4.1. Estatísticas Descritivas	23
4.2. Contribuição das <i>Features</i> BEF para o Desempenho Preditivo (OE2).....	23
4.3. Desempenho Comparativo dos Modelos de Machine Learning	23
4.4. Importância de Features — Gini e SHAP (Componente XAI do OE1).....	25
4.5. Classificação de Risco do Sector — Alertas EWS (OE2)	27
4.6. Resultados da Simulação Monte Carlo (Evidência para OE4)	28
4.7. Protótipo SupTech — Plataforma de Supervisão Inteligente (OE3).....	29
5. Discussão, Recomendações e Prespectivas de Implementação	30
5.1. Discussão dos Resultados.....	30
5.2. Limitações do Estudo	30
5.3. Recomendações de Política (OE4).....	31
5.3.1. Recomendações para a Supervisão Microprudencial	31
5.3.2. Recomendações para a Política Macprudencial	32
5.3.3. Recomendações para o Quadro Regulatório da IA	32
5.4. Perspectivas de Implementação	32
5.4.1. Roteiro de Implementação: Da Prova de Conceito à Produção Operacional	32
5.4.2. Gap Analysis: Do Protótipo à Ferramenta Operacional	41
6. Conclusão.....	43
Referências Bibliográficas	45

Resumo

O presente estudo desenvolve e valida um modelo de Inteligência Artificial para apoiar a regulação e a gestão inteligente de riscos no sistema financeiro moçambicano, materializado num Sistema de Alerta Precoce (Early Warning System — EWS) baseado em técnicas de aprendizagem automática (Machine Learning). Utilizando dados reais de supervisão microprudencial do Banco de Moçambique relativos a 39 instituições financeiras ao longo de 28 trimestres (Q1/2018–Q3/2025), o estudo combina quatro modelos de Machine Learning supervisionado — Random Forest, XGBoost, Logistic Regression com regularização L1 e Stacking Ensemble — suportados por IA explicável (XAI) através da análise SHAP, com uma inovação original: a criação de 11 features BEF (Factores Estruturais e Ambientais do Banco de Moçambique) que capturam especificidades do contexto moçambicano descritos no Boletim de Estabilidade Financeira (2021 - 2025), incluindo choques climáticos, a permanência na lista cinzenta do GAFI (2022 - 2025) e indicadores de posicionamento sistémico relativo. O modelo primário (Random Forest) alcança um AUC-ROC (Área Sob a Curva de Característica de Operação do Receptor) de 0,950 na amostra de teste out-of-sample (Q1/2023–Q3/2025), com Recall de 85,5% e Precision de 91,4%, demonstrando capacidade preditiva robusta com 1–2 trimestres de antecedência. Uma simulação Monte Carlo com 10.000 iterações quantifica o benefício da reserva de capital contracíclica (CCyB) em 13,3% de redução da probabilidade de subcapitalização. O estudo culmina num protótipo funcional de plataforma SupTech (React/FastAPI), com seis (6) módulos operacionais e propõe recomendações regulatórias concretas para o Banco de Moçambique, posicionando Moçambique como referência regional em inovação regulatória baseada em IA.

Palavras-chave: Sistema de Alerta Precoce; *Machine Learning*; Supervisão Bancária; *SupTech*; Risco de Crédito; SHAP; Banco de Moçambique; D-SIBs; Política Macroprudencial.

1. Introdução

1.1. Contextualização do Problema de Pesquisa

O sistema financeiro moçambicano tem apresentado sinais de solidez estrutural, com rácios de solvabilidade globais de 26,11% em 2024 — bem acima do mínimo regulatório de 12% —, mas enfrenta desafios críticos que exigem uma resposta inovadora e tecnológica. Segundo o Relatório de Estabilidade Financeira, publicado em Junho de 2025 pelo Banco de Moçambique (BM, 2025), a qualidade dos activos tem-se deteriorado: o rácio de créditos em incumprimento (*Non-Performing Loan* — NPL) atingiu 9,32% em 2024, quase o dobro do limite prudencial de 5% internacionalmente recomendado, enquanto a cobertura pelas provisões específicas caiu para 60,29% (face a 74,09% em 2020), evidenciando uma trajectória descendente preocupante.

Além disso, há uma forte concentração de activos em três (3) Bancos Domésticos de Importância Sistémica (D-SIBs), que representam 59,85% dos activos totais, 64,03% dos depósitos e 54,49% do crédito do sector (BM, 2025), aumentando a exposição a riscos sistémicos. A heterogeneidade entre segmentos de instituições constitui uma dimensão crítica frequentemente obscurecida pelos indicadores agregados: os D-SIBs apresentam, em geral, rácios de NPL inferiores à média do sistema (7,75% em Junho de 2024), enquanto o segmento de microbancos exhibe vulnerabilidades substancialmente superiores, com rácios de NPL frequentemente acima de 20%. A expansão acelerada das Instituições de Moeda Electrónica (IME) e do ecossistema fintech (+41,69% em resultados líquidos em 2024) reflecte uma tendência global de digitalização, mas também amplia a superfície de ataque para riscos cibernéticos e vulnerabilidades operacionais.

O contexto moçambicano apresenta, adicionalmente, um conjunto de factores de risco exógenos que diferenciam a dinâmica do sector bancário nacional dos sistemas financeiros de jurisdições mais estáveis. Desde 2019, o país tem sido afectado de forma recorrente por eventos climáticos extremos, nomeadamente os ciclones Idai (2019), Ana (2022), Freddy (2023), Chido (Dezembro de 2024) e, mais recentemente, o ciclone Gezani (Fevereiro de 2026), com impacto documentado na capacidade de reembolso dos mutuários (BM, 2023; 2024). Só na época das chuvas de 2025/2026, as cheias de Janeiro e a passagem do ciclone Gezani, num balanço total nacional, afectaram cerca de 869 mil pessoas e provocaram mais de 242 mortos (INGD, 2026),

confirmando o carácter estrutural, e não meramente episódico, do risco climático no sistema financeiro moçambicano.

A esta vulnerabilidade somaram-se, no período em análise, a permanência de Moçambique na lista cinzenta do Grupo de Acção Financeira Internacional (GAFI) entre Outubro de 2022 e Outubro de 2025, com implicações nas relações com correspondentes bancários e custos de transacção acrescidos (BM, 2025). Embora a plenária do GAFI tenha proclamado, em Outubro de 2025, a saída de Moçambique da lista cinzenta, os efeitos acumulados de três (3) anos sob monitorização acrescida deixaram marcas no funcionamento do sistema financeiro. A estes factores acrescem a instabilidade militar na província de Cabo Delgado, a tensão pós-eleitoral de 2024 — que contribuiu para uma contracção do PIB real de 4,9% (BM, 2025) — e um mercado de capitais pouco diversificado, com 87,22% da capitalização concentrada em títulos públicos.

Embora o sistema bancário continue resiliente, a natureza não linear e frequentemente correlacionada destes choques — **externos, climáticos, macroeconómicos e cibernéticos** — demanda soluções inovadoras de supervisão financeira que a abordagem tradicional, baseada em modelos estáticos, limiares absolutos e análise retrospectiva, é estruturalmente insuficiente para oferecer. Nesse contexto, propomos um **Modelo baseado em Inteligência Artificial (IA) para o Sistema Financeiro de Moçambique**, centrado em Regulação e Gestão Inteligente de Riscos, que permita a antecipação de riscos (*Early Warning Systems*) e fortaleça a governança e resiliência do sistema financeiro de Moçambique.

1.2. Objectivos do Trabalho

1.2.1. Objectivo Geral

Desenvolver um modelo de IA para apoiar a regulação e a gestão inteligente de riscos no sistema financeiro moçambicano, capaz de identificar, monitorar e mitigar riscos sistémicos e emergentes no sistema financeiro moçambicano.

1.2.2. Objectivos Específicos

O estudo prossegue cinco objectivos específicos, definidos na proposta de pesquisa e desenvolvidos com a profundidade analítica que a investigação empírica permitiu alcançar:

Objectivo Específico 1: Criar um modelo de regulação dinâmica suportado por IA explicável (XAI), ajustável ao perfil de risco das instituições financeiras. No desenvolvimento do trabalho, este objectivo materializou-se na concepção de um modelo de regulação que integra 4 algoritmos de *Machine Learning* supervisionado — *Random Forest*, *XGBoost*, *Logistic Regression* com regularização L1 e *Stacking Ensemble* — com explicabilidade garantida pela análise SHAP (*SHapley Additive exPlanations*), produzindo previsões individualizadas por instituição e ajustáveis ao respectivo perfil de risco. A componente XAI responde directamente ao requisito de explicabilidade que o BIS/FSI (2025) identifica como condição necessária para a adopção de IA na supervisão bancária.

Objectivo Específico 2: Implementar um *Early Warning System* (EWS) que monitore solvência, liquidez, cibersegurança e riscos climáticos em tempo real. A concretização deste objectivo resultou no desenvolvimento e validação de um EWS baseado em dados reais de supervisão microprudencial do Banco de Moçambique (39 instituições, 28 trimestres), incorporando uma inovação original: a criação de 11 *features* BEF (Factores Estruturais e Ambientais do Banco de Moçambique) que capturam riscos climáticos (*cyclone_shock*), riscos regulatórios internacionais (*gafi_grey_list*), indicadores de posicionamento sistémico relativo (*npl_vs_sistema*, *solv_vs_sistema*) e pressões sobre a solvência (*gap_solvab_reg*). A inclusão destas variáveis contextuais, ausentes na literatura actual aplicada a Moçambique, constitui a contribuição metodológica central do estudo.

Objectivo Específico 3: Prototipar uma plataforma de supervisão inteligente (*SupTech*) para integrar dados de bancos, IMEs, mercado de capitais, fundos de pensão e outras instituições financeiras relevantes. O protótipo *SupTech* desenvolvido implementa uma arquitectura moderna em FastAPI (*backend*) e React/Vite/Recharts (*frontend*), com 9 *endpoints* RESTful e 6 módulos funcionais — Painel de Risco Sistémico, Alertas EWS com semáforo tri-estado, Análise Individual com valores SHAP, Simulador de Cenários *Monte Carlo*, Análise de IMEs e Avaliação de Modelos —, demonstrando a viabilidade da transição imediata da análise preditiva para a ferramenta operacional de supervisão.

Objectivo Específico 4: Propor recomendações regulatórias baseadas em dados, alinhadas às directrizes do Banco de Moçambique. Os resultados quantitativos do estudo, nomeadamente a quantificação do benefício do CCyB em 13,3% de redução da probabilidade de subcapitalização via simulação *Monte Carlo* (10.000 iterações), a identificação de que o posicionamento relativo do NPL (*npl_vs_sistema*) é mais preditivo do que o nível absoluto, e a demonstração de que os microbancos representam 61,6% dos alertas de *distress*,

fundamentam um conjunto de recomendações regulatórias concretas, incluindo a proposta de um Aviso do Banco de Moçambique sobre utilização de modelos de IA e a revisão do Aviso n.º 16/GBM/2017 para incluir indicadores de posicionamento relativo.

Objectivo Específico 5: Produzir evidências que posicionem Moçambique como referência regional em inovação regulatória baseada em IA. O estudo constitui, ao nosso conhecimento, a primeira aplicação de *Machine Learning* e SHAP à supervisão bancária moçambicana, e os resultados obtidos — AUC-ROC de 0,950 comparável aos reportados pela EBA (2025) para o sistema bancário europeu — demonstram que a metodologia é transferível para economias emergentes africanas desde que acompanhada de ajustamentos contextuais adequados, como os que as *features* BEF materializam. Esta evidência posiciona Moçambique no contexto das melhores práticas internacionais de *SupTech*, conforme documentado pelo FMI (Bains *et al.*, 2025), pelo BIS/FSI (Crisanto *et al.*, 2024) e pelo FSB (2024; 2025).

1.3. Questão Central de Pesquisa

Em que medida modelos de *Machine Learning*, treinados com indicadores prudenciais e macroeconómicos, podem antecipar a deterioração da qualidade de activos e solvência, e como integrar estes modelos na supervisão macroprudencial para uma gestão inteligente de riscos no sistema financeiro moçambicano?

1.4. Relevância e Justificação

Este projecto responde directamente aos desafios identificados no Relatório de Estabilidade Financeira (BM, 2025), que destaca: o aumento dos NPLs para 9,32%, revelando deterioração da carteira de crédito; a concentração sistémica de 59,85% dos activos em três (3) bancos; a expansão digital acelerada, com crescimento das IMEs e serviços financeiros móveis e novos riscos cibernéticos associados; e um mercado de capitais pouco diversificado, com 87,22% da capitalização em títulos públicos.

Esses factores tornam a supervisão tradicional insuficiente, reforçando a necessidade de tecnologias *SupTech* e *RegTech* que permitam uma abordagem holística e acompanhamento proactivo. A relevância do estudo articula-se em três dimensões complementares.

Dimensão	Supervisão Tradicional (CAMEL/BM)	Modelo EWS-IA (Este Estudo)	Ganho Supervisório
Frequência de avaliação	Semestral / Anual (calendar-driven)	Trimestral (dados de reporte)	Antecipação de 1–2 trimestres
Horizonte temporal	Retrospectivo (diagnóstico)	Prospectivo t+1 / t+2	Previsão explícita de distress futuro
Output principal	Rating qualitativo CAMEL (1–5)	P(Distress) $\in [0,1]$ com IC 95%	Probabilidade quantificada
Cobertura simultânea	Sequencial (inspeccional)	36 instituições em paralelo	Cobertura sistémica trimestral
Explicabilidade	Juízo discricionário do inspetor	SHAP values por feature e instituição	Rastreabilidade algorítmica plena
Factores sistémicos	Análise manual via BEF trimestral	11 features BEF integradas automaticamente	Automatização da análise sistémica
Detecção precoce	Reativa (0 trimestres)	1–2 trimestres de antecipação	Redução da latência supervisória
Métricas de precisão	Sem métrica formal de antecipação	F1 = 0,883; Usefulness U = 0,395	Desempenho quantificado e auditável

Quadro 1 — Comparação entre a Supervisão Tradicional CAMEL e o Modelo EWS-IA desenvolvido.

Do ponto de vista da política de supervisão, o trabalho oferece um mecanismo de supervisão preditiva, mitigação antecipada de riscos sistémicos e maior segurança para a inovação financeira, respondendo à recomendação do FMI (Artigo IV, 2024) de reforçar os instrumentos de supervisão prospectiva e à necessidade, identificada pelo FSAP de 2024, de modernizar a infra-estrutura de dados de supervisão do Banco de Moçambique.

Do ponto de vista metodológico, o estudo contribui para a literatura de *Early Warning Systems* em economias emergentes e em desenvolvimento (EMDEs) africanas, um segmento sub-representado na investigação empírica (Casabianca *et al.*, 2022), com a inovação das *features* BEF e a validação *walk-forward* genuinamente *out-of-sample*, ou seja, com dados reais.

Do ponto de vista prático, o protótipo *SupTech* demonstra a viabilidade de uma transição imediata — sem investimento em infraestrutura adicional — da análise preditiva para a ferramenta operacional de supervisão, criando oportunidades para consolidar Moçambique como um potencial líder regional em supervisão financeira baseada em IA.

O estudo alinha-se integralmente com o tema das XVII Jornadas Científicas — "Regulamentação e Utilização da Inteligência Artificial no Sistema Financeiro Nacional:

Riscos e Oportunidades" — e posiciona Moçambique no contexto das melhores práticas internacionais de *SupTech*, conforme documentado pelo FMI (Bains *et al.*, 2025), pelo BIS/FSI (Crisanto *et al.*, 2024) e pelo FSB (2024; 2025).

1.5. Estrutura do Trabalho

O trabalho está organizado em seis (6) secções. Após esta introdução, que contextualiza o problema de pesquisa e estabelece os objectivos em continuidade com a proposta de pesquisa, a Secção 2 apresenta a revisão de literatura teórica e empírica, articulando explicitamente os fundamentos conceptuais com o problema identificado e os objectivos do estudo. A Secção 3 descreve a metodologia, incluindo dados, engenharia de *features*, modelos de *Machine Learning* e estratégia de validação, demonstrando como cada opção metodológica concretiza os objectivos específicos enunciados. A Secção 4 apresenta os resultados do estudo. A Secção 5 discute os resultados, formula as recomendações regulatórias previstas no Objectivo Específico 4 e apresenta as Perspectivas de Implementação do EWS, incluindo um roteiro faseado de transição do protótipo académico para operação plena no Banco de Moçambique (§5.4). A Secção 6 conclui com uma síntese das contribuições e direcções de investigação futura, incluindo as evidências de posicionamento regional previstas no Objectivo Específico 5.

2. Revisão de Literatura

A revisão de literatura que se segue está organizada de modo a estabelecer uma ligação explícita e crítica entre os fundamentos teóricos, o problema de investigação e os objectivos do estudo, respondendo directamente à recomendação formulada pelo júri na avaliação da proposta. O primeiro eixo teórico que são os Sistemas de Alerta Precoce, fundamenta a necessidade de modelos preditivos que superem as limitações dos instrumentos estáticos identificadas na contextualização do problema, sustentando os Objectivos Específicos 1 e 2. O segundo eixo, *Supervisory Technology* e IA na supervisão financeira, enquadra o desenvolvimento de plataformas *SupTech* como resposta institucional aos desafios de supervisão, sustentando o Objectivo Específico 3. O terceiro eixo, Explicabilidade em IA, justifica a opção pela análise SHAP como instrumento de transparência regulatória, componente essencial do Objectivo Específico 1 (IA explicável). O eixo empírico documenta as evidências de superioridade dos modelos de *Machine Learning* e situa a lacuna específica do contexto moçambicano que os Objectivos Específicos 4 e 5 visam preencher.

2.1. Enquadramento Teórico

2.1.1. Sistemas de Alerta Precoce na Supervisão Bancária

A literatura sobre Sistemas de Alerta Precoce (*Early Warning Systems* — EWS) no sector bancário tem as suas raízes nos trabalhos seminais de Kaminsky e Reinhart (1999) e Demirgüç-Kunt e Detragiache (1998), que desenvolveram modelos de sinalização e *logit* multivariado para prever crises bancárias. Estes modelos de primeira geração, baseados em indicadores macroeconómicos e técnicas econométricas lineares, foram durante décadas o instrumento padrão de supervisão macroprudencial, como documentam Alessi e Detken (2014) no contexto do Banco Central Europeu. A crise financeira global de 2008 expôs as limitações destes modelos lineares, particularmente a sua incapacidade de capturar interacções não-lineares entre factores de risco e de antecipar a materialização de riscos de cauda, ou seja, limitações análogas às que o sistema financeiro moçambicano enfrenta perante a natureza multidimensional dos seus choques exógenos (Secção 1.1).

Esta constatação motivou o desenvolvimento de EWS de segunda geração, baseados em técnicas de *Machine Learning* supervisionado. O *Staff Paper* N.º 21 da Autoridade Bancária Europeia (EBA, 2025) representa o estado-da-arte desta linha de investigação, demonstrando — com base numa amostra de mais de 3.000 bancos europeus — que modelos *ensemble*

(*Random Forest*) superam consistentemente modelos *logit* tradicionais em termos de AUC-ROC, *F1-Score* e da métrica *Usefulness* (que penaliza falsos alarmes em proporção ao custo de omissões). Esta evidência fundamenta directamente o Objectivo Específico 2: a implementação de um EWS baseado em *Machine Learning* não é uma opção arbitrária, mas decorre do estado da arte na literatura de supervisão bancária.

2.1.2. Supervisory Technology (SupTech) e IA na Supervisão Financeira

O conceito de *Supervisory Technology (SupTech)* — definido pelo FSB (2017) como a utilização de tecnologias avançadas por autoridades de supervisão financeira — tem registado uma expansão sem precedentes na última década. Bains *et al.* (FMI, 2025), no *Working Paper* WP/25/199, documentam que 75% das economias avançadas e 58% das EMDEs já adoptaram alguma forma de *SupTech*, embora com diferenças significativas de maturidade e sofisticação. Este dado contextualiza o Objectivo Específico 3 (prototipagem de plataforma *SupTech*) no quadro de uma tendência global à qual Moçambique tem a oportunidade de aderir com soluções adaptadas ao seu contexto.

O FSB (2024; 2025), nos seus relatórios sobre implicações da IA para a estabilidade financeira, identifica um conjunto de riscos emergentes, tais como: concentração de modelos, prociclicidade algorítmica, opacidade e riscos de governança. Estes riscos, fundamentam a necessidade de quadros regulatórios específicos. Danielsson e Uthemann (2022) aprofundam a análise do risco de prociclicidade, argumentando que algoritmos de IA podem amplificar flutuações económicas quando múltiplas instituições utilizam modelos semelhantes, reforçando a importância de supervisão humana (*human-in-the-loop*) e de mecanismos de explicabilidade. A tensão entre os benefícios da automação e a necessidade de juízo humano, identificada por estes autores, informa directamente a arquitectura do protótipo *SupTech* proposto (Objectivo Específico 3), que opera como ferramenta de apoio à decisão e não como substituto do inspector, e fundamenta recomendações regulatórias do Objectivo Específico 4.

2.1.3. Explicabilidade em IA: SHAP e Requisitos Regulatórios

A tensão entre precisão preditiva e explicabilidade constitui um desafio central na adopção de IA na supervisão bancária. O BIS (2024), no *Working Paper* N.º 1194, conclui que a explicabilidade não é apenas um requisito regulatório mas uma condição necessária para a confiança institucional e a legitimidade das decisões supervisoras. O BIS/FSI (2025), no *Occasional Paper* N.º 24, identifica a análise SHAP (Lundberg e Lee, 2017) como a ferramenta

de explicabilidade mais adequada para a supervisão bancária, por três razões: (i) fundamentação axiomática na teoria dos jogos cooperativos; (ii) capacidade de produzir explicações individuais (por instituição e por período); e (iii) compatibilidade com qualquer modelo de *Machine Learning*. Esta evidência sustenta a componente de IA explicável (XAI) do Objectivo Específico 1: a adopção da análise SHAP responde ao requisito de que o modelo de regulação dinâmica seja não apenas preditivo, mas transparente e auditável.

2.1.4. RegTech, Smart Regulation e Sandboxes Regulatórias

Arner, Barberis e Buckley (2017) introduzem o conceito de *RegTech* e *regulatory sandboxes* como ferramentas de aprendizagem regulatória contínua, argumentando que a inovação financeira exige instrumentos regulatórios igualmente inovadores. Zetzsche *et al.* (2017) avançam para a noção de *smart regulation*, articulando respostas proporcionais e responsivas à inovação. O FSB (2017; 2024) e o BIS/FSI (2024–2025) estruturam riscos e princípios para adopção de IA/ML em regulação financeira e *suptech*, destacando governança, explicabilidade e mitigação de riscos sistémicos. Este enquadramento teórico fundamenta o Objectivo Específico 1 (modelo de regulação dinâmica) na medida em que o modelo proposto incorpora a lógica de ajustamento contínuo ao perfil de risco institucional que a *smart regulation* preconiza.

2.2. Literatura Empírica

2.2.1. Modelos de ML para Previsão de NPL e Distress Bancário

A evidência empírica sobre a superioridade de modelos de *Machine Learning* na previsão de risco de crédito é crescente e consistente. Bellotti e Crook (2021), numa meta-análise publicada no *International Journal of Forecasting*, demonstram que modelos *ensemble* (*Random Forest*, *Gradient Boosted Machines*, *XGBoost*) superam regressões tradicionais na previsão de NPLs e de *default* de crédito, com ganhos de AUC tipicamente entre 0,02 e 0,08 — margens que, à escala de carteiras de crédito bancário, traduzem melhorias operacionalmente significativas.

No contexto de EMDEs, Dohotaru *et al.* (Banco Mundial, 2025) documentam a adopção crescente de *SupTech* em economias emergentes, identificando desafios específicos que este estudo procura endereçar, tais como: limitação de dados, infraestrutura tecnológica e capacidade institucional. Casabianca *et al.* (2022), utilizando *Adaptive Boosting* numa amostra

de 100 países ao longo de quase cinco décadas, demonstram que algoritmos de *Machine Learning* superam modelos *logit* tradicionais tanto *in-sample* como *out-of-sample*, embora com desempenho notavelmente inferior para economias emergentes — resultado que reforça a importância de variáveis contextuais como as *features* BEF que este estudo desenvolve para o Objectivo Específico 2.

No continente africano, Ayobami *et al.* (2023) aplicam *Random Forest* e *Gradient Boosting* à previsão de incumprimento em bancos comerciais nigerianos, obtendo precisões superiores a 77%. No Quênia, o inquérito do Banco Central (CBK, 2025) revela que 65% das instituições financeiras já adoptaram IA para avaliação de risco de crédito. Na África do Sul, a Autoridade Prudencial e a FSCA (2025) revelam que mais de 50% dos bancos já utilizam IA operacionalmente. Estes dados confirmam a existência de um movimento continental de adopção, dentro do qual o presente estudo se posiciona como contributo aplicado ao caso moçambicano, sustentando o Objectivo Específico 5 de posicionamento regional.

2.2.2. Experiências Internacionais de Regulação de IA

Os quadros regulatórios para a utilização de IA no sector financeiro apresentam diferentes níveis de maturidade. A União Europeia, através do *AI Act* (2024), adoptou uma abordagem baseada no risco, classificando aplicações de IA com requisitos proporcionais de transparência e governança. Singapura, através dos Princípios FEAT (*Fairness, Ethics, Accountability and Transparency*) da MAS (2018) e da iniciativa Veritas, operacionaliza a avaliação ética de modelos de IA no sector financeiro. O Reino Unido, através do BoE e da FCA (2022; 2024), documenta a adopção crescente de *Machine Learning* e identifica desafios de governança. Crisanto *et al.* (BIS/FSI *Insights* N.º 63, 2024) concluem que jurisdições com abordagens proporcionais e orientadas ao risco obtêm melhores resultados. A análise comparada destas experiências informa as recomendações regulatórias do Objectivo Específico 4, adaptadas ao ordenamento jurídico moçambicano.

2.2.3. O Contexto Moçambicano: Lacuna na Literatura

A literatura aplicada ao sistema financeiro moçambicano no domínio da IA e *SupTech* é, até à data, praticamente inexistente. Todavia, existe um corpo de trabalho institucional relevante. O FMI, no âmbito da Consulta do Artigo IV de 2024, identifica como riscos centrais a elevada exposição soberana dos bancos (cerca de 40% dos activos), os choques climáticos recorrentes e a fragilidade securitária, recomendando o fortalecimento da supervisão (FMI,

2024). O *Financial Sector Assessment Program* (FSAP), realizado pela última vez em 2024, reconheceu avanços legislativos significativos, mas reiterou a necessidade de fortalecer a infraestrutura de dados de supervisão e a resiliência operacional. Mais recentemente, o FMI (2026), na Consulta do Artigo IV de 2025, nota que o crescimento do PIB em 2025 foi de apenas 0,5% e que o sector bancário enfrenta condições cada vez mais difíceis.

O Banco de Moçambique tem vindo a desenvolver o seu quadro de supervisão macroprudencial, incluindo o Índice de Risco Sistémico, o quadro de instrumentos macroprudenciais (STMaP) e a metodologia de identificação de D-SIBs (Aviso n.º 10/GBM/2018). Contudo, estes instrumentos operam predominantemente numa lógica retrospectiva e agregada, sem a componente preditiva e individualizada que os modelos de *Machine Learning* permitem.

É esta lacuna — a ausência de um sistema de alerta precoce baseado em *Machine Learning* que integre sistematicamente indicadores microprudenciais, macroeconómicos e contextuais para o sistema financeiro moçambicano — que o presente estudo procura colmatar, respondendo simultaneamente aos cinco objectivos específicos enunciados: o modelo de regulação dinâmica com XAI (OE1), o EWS com features contextuais (OE2), a plataforma SupTech (OE3), as recomendações regulatórias baseadas em evidência (OE4) e o posicionamento regional de Moçambique (OE5).

3. Metodologia

A abordagem metodológica adoptada neste estudo é de natureza quantitativa e combina técnicas de econometria aplicada, aprendizagem automática supervisionada (*Machine Learning*) e simulação estocástica, organizadas em cinco fases correspondentes às cinco fases da proposta aprovada — Diagnóstico e Colecta de Dados, Modelos Preditivos, *Framework* de Regulamentação Adaptativa, Protótipo *SupTech* e Validação e *Roadmap* — que foram desenvolvidas com a profundidade analítica que a investigação empírica permitiu alcançar.

A opção por modelos de aprendizagem automática em detrimento de modelos econométricos tradicionais (*probit*, *logit*) justifica-se por três razões fundamentais: (i) a natureza não-linear das interacções entre indicadores de risco em contextos de crise; (ii) a elevada dimensionalidade do espaço de *features* após engenharia de variáveis; e (iii) a evidência crescente na literatura de supervisão bancária (EBA, 2025; BIS, 2024) que aponta para ganhos significativos de desempenho preditivo com métodos *ensemble* relativamente a modelos lineares.

3.1. Dados e Amostra (Fase 1 — Diagnóstico e Colecta de Dados)

Conforme previsto na Fase 1 da proposta aprovada, procedeu-se ao levantamento de dados do Banco de Moçambique, identificação de métricas macroprudenciais, indicadores climáticos e *benchmarking* com práticas internacionais (BIS, FSB, MAS). Os dados utilizados provêm da base de dados de supervisão microprudencial do Banco de Moçambique (Indicadores Prudenciais e Económico-Financeiros), compilados num *dataset* contendo 771 observações trimestrais relativas a 39 instituições financeiras, cobrindo o período de Q1/2018 à Q3/2025 — correspondendo a 28 trimestres após **exclusão dos trimestres Q1 a Q3/2021**, período atípico em virtude das distorções introduzidas pela pandemia de COVID-19.

O *dataset* integra 57 variáveis originais organizadas em seis (6) domínios: (i) qualidade dos activos e crédito vencido; (ii) solvabilidade e adequação de fundos próprios; (iii) rentabilidade; (iv) liquidez e transformação financeira; (v) indicadores de eficiência operacional; e (vi) variáveis macroeconómicas e sistémicas. Os indicadores microprudenciais seguem o enquadramento definido pelo Aviso n.º 16/GBM/2017, Anexo II. As variáveis macroeconómicas provêm dos *World Development Indicators* extraídos acervo de dados online do Banco Mundial (<https://data.worldbank.org/country/mozambique>), interpoladas de

frequência anual para trimestral. Após o processo de engenharia de *features*, o espaço de variáveis expandiu-se para 102 *features* utilizadas no treino dos modelos.

Caixa 1 — Quadro de Confidencialidade e Ética dos Dados

Os dados microprudenciais utilizados neste estudo são dados administrativos de supervisão bancária do Banco de Moçambique, disponibilizados na página web oficial do Banco e disponíveis ao público. O quadro de confidencialidade obedece aos seguintes princípios:

- **Autorização formal:** acesso aprovado de dados futuros por despacho interno da Direcção de Supervisão Bancária, com âmbito de utilização limitado a este projecto de investigação académica.
- **Dever de confidencialidade:** os investigadores estão vinculados pelo dever de confidencialidade previsto na Lei do Sistema Financeiro (Lei n.º 9/2004, artigo 94.º) e pelo Regulamento Interno de Acesso a Dados do BM.
- **Anonimização no protótipo:** o protótipo SupTech utiliza identificadores institucionais codificados (ID_1 a ID_39), e pode ocultar a denominação das instituições na versão de demonstração pública, entretanto, importa lembrar que os dados usados neste estudo estão disponíveis para acesso público no website oficial do Banco de Moçambique.
- **Minimização de dados:** o conjunto partilhado contém apenas indicadores prudenciais agregados — sem dados de clientes individuais, conforme o princípio de minimização de dados do RGPD (Regulamento Geral sobre a Protecção de Dados).
- **Alinhamento internacional:** o quadro é consistente com o BIS Handbook on SupTech (2021, pp. 45–52) e com os princípios de data governance do FSB (2024).

3.2. Variável-Alvo: Definição de Distress Financeiro

A variável-alvo do modelo é definida como uma variável binária *forward-looking*, denominada *distress_10pct_fwd*, que assume o valor 1 quando a instituição apresenta um rácio de NPL superior a 10% em t+1 ou t+2 (horizonte de dois trimestres). O limiar de 10% é consistente com a prática supervisora do Banco de Moçambique e com a literatura internacional (EBA, 2025). A taxa de incidência de *distress* na amostra de treino é de 47,3% e na amostra de teste de 44,8%, indicando que o problema é relativamente balanceado.

Nota metodológica — exclusão de Q1–Q3/2021: o período Q1–Q3/2021 foi excluído da amostra de treino porque o Banco de Moçambique autorizou, durante a pandemia de COVID-19, moratórias e diferimentos de reporte de NPL que suprimiram artificialmente os rácios de crédito malparado, introduzindo uma quebra estrutural não representativa das condições normais de funcionamento do sistema (Demirgüç-Kunt & Detragiache, 1998; FMI, 2024). Como análise de robustez alternativa, estimou-se o modelo com dummies de pandemia (Q1–Q3/2021 = 1), obtendo $\Delta AUC < 0.003$ face ao modelo base — confirmando que a exclusão não afecta materialmente as conclusões.

Notação formal da variável target: $y_{\{i,t\}} = 1$ se $NPL_{\{i,t+1\}} > 0.10 \vee NPL_{\{i,t+2\}} > 0.10$; $y_{\{i,t\}} = 0$ caso contrário; onde $i \in \{1, \dots, 36\}$ identifica a instituição e t o trimestre de observação. A Usefulness de Alessi & Detken (2014) é definida como: $U(\theta) = (1-\mu) \cdot [TP(\theta)/N_{\text{pos}}] - \mu \cdot [FP(\theta)/N_{\text{neg}}]$, com $\mu = 0.5$.

Variável	Frequência Original	Método de Conversão para Frequência Trimestral	Fonte
hiato_credito_pib	Trimestral	Filtro Savitzky-Golay (janela=9, grau=2) sobre séries credit/GDP — método BIS (2010)	BM/INE
pib_real_growth	Anual	Interpolação linear trimestral — método padrão FMI para variáveis de fluxo anual	FMI (2024)
inflacao_cpi	Mensal → Trimestral	Média aritmética das três observações mensais de cada trimestre	BM/INE
taxa_cambio_usd	Diária → Trimestral	Média dos últimos 10 dias úteis do trimestre (representativa das condições de fecho)	BM
domestic_credit_gdp	Anual	Interpolação linear + Savitzky-Golay para construção do hiato de crédito	BIS (2010)

Quadro 2 — Métodos de tratamento de frequência para variáveis macroeconómicas. A interpolação linear para variáveis anuais pode introduzir autocorrelação serial, mitigada pelo uso de *TimeSeriesSplit* na validação cruzada.

3.3. Engenharia de Features e Factores BEF

O processo de engenharia de *features* transformou as 57 variáveis originais num espaço de 102 *features*, através de três operações sequenciais: (i) winsorização ao percentil 5–95 de variáveis com distribuições de cauda pesada; (ii) criação de variáveis de série temporal —

desfasamentos ($t-1$, $t-2$ e $t-4$) e primeiras diferenças (Δ) para capturar trajectórias de deterioração; e (iii) criação das 11 *features* BEF.

3.3.1. Features BEF — Factores Estruturais e Ambientais

A contribuição metodológica central deste estudo é a criação de 11 *features* BEF, concebidas para capturar especificidades estruturais e contextuais do sistema financeiro moçambicano — incluindo choques climáticos (*cyclone_shock*), risco regulatório internacional (*gafi_grey_list*), posicionamento sistémico relativo (*npl_vs_sistema*, *solv_vs_sistema*, *roa_vs_sistema*), distância ao limiar regulamentar (*gap_solvab_reg*), exposição de crédito sem provisão (*npl_coverage_gap*), trajectória cumulativa do NPL (*npl_momentum*), amplificação do risco sistémico para D-SIBs (*dsib_npl_interact*), pressão sobre a rentabilidade (*custo_margem_ratio*) e expansão insustentável do crédito (*hiato_credito_pib*). Esta inovação responde directamente à lacuna identificada na revisão de literatura (Secção 2.2.3) e materializa a identificação de métricas macroprudenciais e indicadores climáticos prevista na Fase 1 da proposta.

Quadro 3 — Definição Matemática das 11 Features BEF

Feature	Fórmula	Escala	Fonte	Interpretação
<i>npl_vs_sistema</i>	$NPL_{\{i,t\}} - NPL_{\{sys,t\}}$	p.p.	BEF/BM	Posição relativa ao sistema
<i>solv_vs_sistema</i>	$CAR_{\{i,t\}} - CAR_{\{sys,t\}}$	p.p.	BEF/BM	Solvência relativa ao sistema
<i>roa_vs_sistema</i>	$ROA_{\{i,t\}} - ROA_{\{sys,t\}}$	p.p.	BEF/BM	Rentabilidade relativa
<i>gap_solvab_reg</i>	$CAR_{\{i,t\}} - 0.12$	p.p.	BM	Distância ao mínimo Basileia III
<i>npl_coverage_gap</i>	$NPL_{\{i,t\}} \times (1 - \text{cobertura}_{\{i,t\}})$	%	BM	Exposição não coberta
<i>npl_momentum</i>	$\Delta_{\{t-1\}}NPL + \Delta_{\{t-2\}}NPL + \Delta_{\{t-4\}}NPL$	p.p.	BM	Trajectória cumulativa NPL
<i>dsib_npl_interact</i>	$1[D-SIB]_i \times NPL_{\{i,t\}}$	interac.	BM/FSB	Risco sistémico amplificado
<i>custo_margem_ratio</i>	$\text{custo_estrutura_w} / \text{margem_financeira_w}$	rácio	BM	Eficiência operacional
<i>cyclone_shock</i>	$1[t \in \{2019Q1/Q2, 2022Q1/Q2, 2023Q1/Q2, 2025Q1\}]$	0/1	INAM/BM	Choques climáticos
<i>gafi_grey_list</i>	$1[2022Q2 \leq t \leq 2025Q3]$	0/1	GAFI	Lista cinzenta GAFI

hiato_credito_pib	SG(credit_gdp_t) – credit_gdp_t	% PIB	BM/INE	Gap filtro Savitzky-Golay; BIS (2010)
-------------------	---------------------------------	-------	--------	---------------------------------------

3.4. Modelos de Machine Learning (Fase 2 — Modelos Preditivos)

Conforme previsto na Fase 2 da proposta, previa-se a aplicação de *Machine Learning* (*Random Forest*, *XGBoost*, Redes Neurais) com incorporação de XAI para interpretabilidade regulatória, no entanto, estimaram-se quatro modelos de aprendizagem automática supervisionada e um modelo de referência, todos implementados como *pipelines scikit-learn* com dois passos sequenciais: (1) imputação de valores em falta por *forward-fill* temporal e (2) estimação do modelo. Os modelos, por ordem de complexidade crescente, são: (i) *Random Forest* (RF) — Modelo Primário, com 300 árvores de decisão; (ii) *XGBoost* (XGB) com regularização L1/L2; (iii) *Logistic Regression* com regularização L1, como referência interpretável; (iv) e *Stacking Ensemble*, meta-modelo conforme recomendado pela EBA (2025).

A substituição das Redes Neurais, previstas na proposta, pelo *Stacking Ensemble* e pela *Logistic Regression* L1 justifica-se pela dimensão da amostra (771 observações): redes neurais tendem a demonstrar *overfitting* severo em amostras desta escala, enquanto os modelos *ensemble* e lineares penalizados apresentam melhor relação viés-variância, como documentam Bellotti e Crook (2021) e a EBA (2025).

Quadro 4 — Hiperparâmetros óptimos por modelo, obtidos por GridSearchCV + TimeSeriesSplit.

Modelo	Hiperparâmetro	Grelha Testada	Valor Ótimo	Justificação
Random Forest	n_estimators	[100, 200, 300, 500]	300	Balanço entre variância e custo computacional
	max_depth	[None, 5, 10, 20]	None (ilimitado)	O bagging controla overfitting sem limitação de profundidade
	min_samples_leaf	[1, 2, 4]	2	Previne memorização de observações individuais
	max_features	['sqrt', 'log2', 0,3]	'sqrt' (≈ 10 features/nó)	Diversidade máxima entre árvores; gere multicolinearidade

XGBoost	n_estimators	[100, 200, 300]	200	Early stopping previne overfitting adicional
	max_depth	[3, 4, 5, 6]	4	Árvores rasas em dados de painel com autocorrelação
	learning_rate	[0,01, 0,05, 0,10]	0,05	Aprendizagem lenta compensa n_estimators moderado
	subsample	[0,7, 0,8, 0,9]	0,80	Stochastic gradient boosting — reduz variância
	colsample_bytree	[0,7, 0,8, 1,0]	0,80	Amostragem de features por árvore — gere correlação
LR (L1)	C (inv. regularização)	[0,01, 0,1, 1,0, 10,0]	0,10	Regularização forte: esparsidade; 102 features → selecção automática
Stacking	Meta-modelo	LR-L2 (C = 1,0)	LR-L2, C = 1,0	Meta-learner simples para combinar base learners

Método de optimização: GridSearchCV com TimeSeriesSplit (n_splits=5), preservando a ordem temporal e prevenindo data leakage futuro→passado. Métrica: AUC-ROC médio nas 5 janelas de validação. Todos os modelos com random_state=42 para reprodutibilidade integral.

Arquitectura do Stacking Ensemble (Wolpert, 1992)

- **Base learners (nível 0):** Random Forest (n=300), XGBoost (n=200, lr=0,05) e Regressão Logística L1 (C=0,1) — três famílias algorítmicas distintas para maximizar diversidade de hipóteses e reduzir correlação dos erros.
- **Geração de meta-features (out-of-fold):** previsões OOF geradas por TimeSeriesSplit (5 folds, sem shuffle). Cada observação de treino recebe uma previsão gerada exclusivamente por modelos que não a viram — eliminando data leakage inter-níveis.
- **Meta-modelo (nível 1):** Regressão Logística com regularização L2 (C=1,0), treinada nas 3 meta-features (probabilidades dos base learners) sobre o conjunto de treino completo.
- **Previsão no teste:** cada base learner é re-treinado no conjunto de treino completo antes de gerar previsões no conjunto de teste — garantindo o uso de toda a informação disponível.

- **Resultado:** Stacking AUC-ROC = 0,947 (IC 95%: [0,920–0,971]), F1 = 0,891, Brier = 0,0842 — melhor Brier Score de todos os modelos.

3.5. Framework de Regulamentação Adaptativa (Fase 3)

O modelo conceitual de regulamentação adaptativa integra ajustes dinâmicos a indicadores de risco, operacionalizados através de dois mecanismos: (i) o sistema de classificação tri-estado (Alerta/Atenção/Saudável), que produz ajustamentos automáticos da intensidade supervisora em função da probabilidade de *distress* prevista; e (ii) a análise SHAP individualizada, que permite identificar, para cada instituição, os factores de risco específicos que motivam a classificação atribuída. A integração com padrões Basileia III/IV é garantida pela utilização dos limiares regulamentares do Banco de Moçambique (CAR mínimo de 12%) como referência para a definição de *distress* e pela incorporação da lógica do CCyB na simulação *Monte Carlo*. O *benchmarking* com boas práticas da SADC é materializado na análise comparada das experiências regulatórias internacionais (Secção 2.2.2).

3.6. Validação Walk-Forward

A metodologia de validação é *walk-forward*, que respeita a ordem cronológica dos dados e simula o cenário operacional real da supervisão bancária. A divisão temporal adoptada é: amostra de treino — Q1/2018 a Q4/2022 (370 observações; 47,3% positivos); amostra de teste — Q1/2023 a Q3/2025 (277 observações; 44,8% positivos). Os intervalos de confiança (IC 95%) são calculados por *bootstrap* não-paramétrico com 2.000 iterações. Todos os modelos utilizam *random_state=42* para garantir reprodutibilidade.

Quadro 5 — Análise de Robustez Temporal do Modelo

Janela	Período de Treino	Período de Teste	Treinos	Testes	AUC-ROC RF
1	2018-Q1–2020-Q3	2021-Q4–2022-Q2	231	83	0.929
2	2018-Q1–2022-Q2	2022-Q3–2022-Q4	314	56	0.976
3	2018-Q1–2022-Q4	2023-Q1–2023-Q3	370	78	0.964
4	2018-Q1–2023-Q3	2023-Q4–2024-Q2	448	81	0.977
5	2018-Q1–2024-Q2	2024-Q3–2025-Q2	529	118	0.936
Média ± DP	—	—	—	—	0.956 ± 0.020

Nota: AUC médio = 0.956 (DP = 0.020), variação [0.929–0.977]. A estabilidade confirma a robustez temporal do modelo.

3.7. Interpretabilidade — Valores SHAP (Componente XAI do OE1)

A componente de IA explicável (XAI) prevista no Objectivo Específico 1 é concretizada através de valores SHAP (*SHapley Additive exPlanations* — Lundberg e Lee, 2017), abordagem baseada na teoria dos jogos cooperativos que decompõe a previsão de cada instância em contribuições aditivas de cada *feature*. Esta propriedade permite ao inspector do Banco de Moçambique compreender, para cada alerta emitido, quais as variáveis que mais contribuíram para a probabilidade de *distress* prevista (BIS/FSI, 2025), garantindo que o modelo de regulação dinâmica é não apenas preditivo, mas transparente e auditável.

Especificações técnicas da implementação SHAP: utilizou-se o `shap.TreeExplainer` (biblioteca SHAP v0.43), que calcula valores SHAP exactos para modelos baseados em árvores de decisão, sem recorrer a aproximações Monte Carlo. O explainer foi aplicado ao conjunto de teste completo (277 observações). O background dataset, necessário para calcular o valor esperado base $E[f(X)]$, corresponde à média feature-wise do conjunto de treino (vector de 102 dimensões). A agregação global de importância é calculada como $\text{mean}(|\phi_j|)$ sobre as 277 observações de teste, reflectindo a contribuição marginal absoluta média de cada feature ao output do modelo.

3.8. Simulação Monte Carlo de Stress Testing

Para avaliar a resiliência sistémica do sector bancário face a choques macroeconómicos adversos e fundamentar as recomendações regulatórias do Objectivo Específico 4, desenvolveu-se uma simulação *Monte Carlo* com 10.000 iterações por cenário, aplicada a 36 instituições activas. A simulação combina o modelo EWS treinado com projecções estocásticas de variáveis macroeconómicas sob três cenários — base, adverso e severo —, derivando a distribuição de probabilidade de subcapitalização sectorial e quantificando o benefício da reserva de capital contracíclica (CCyB).

A simulação Monte Carlo abrange 36 das 39 instituições da amostra principal. As 3 instituições excluídas pertencem à categoria 'Histórico' — instituições que encerraram actividade ou foram absorvidas por outras durante o período de análise (2018–2025). A projecção de trajectórias futuras de rácio de capital para instituições já encerradas é conceptualmente incoerente com o objectivo da simulação, que estima a distribuição de probabilidade de subcapitalização de instituições activas em cenários de stress prospectivos.

3.9. Protótipo SupTech (Fase 4 — Plataforma de Supervisão Inteligente)

Conforme previsto na Fase 4 da proposta e no Objectivo Específico 3, desenvolveu-se um protótipo de plataforma *SupTech* que operacionaliza o modelo EWS numa interface visual interactiva destinada aos inspectores do Banco de Moçambique.

A arquitectura técnica compreende um *backend* RESTful em FastAPI (Python) com 9 *endpoints* e um *frontend* em React/Vite/Recharts com 6 módulos funcionais. A arquitectura da aplicação a nível do *backend* inclui ficheiros de Modelos ML carregados (.joblib), *Dataset master* agregando toda informação dos Indicadores Prudenciais Económico-Financeiros (2018-2025), dados abertos do Banco Mundial e interpolando com indicadores dos Boletins de Estabilidade Financeira (2021-2025), Funções de predição + SHAP e Monte Carlo *on-demand*.

A nível do Frontend destacam-se abaixo os painéis dos módulos principais:

1. **Painel de Risco Sistémico** — KPIs agregados e *heatmap* de NPL, bem como a evolução temporal com anotações de eventos exógenos;
2. **Alertas EWS** — *ranking* de instituições por probabilidade de *distress* com semáforo tri-estado;
3. **Análise Individual** — perfil completo com valores SHAP;

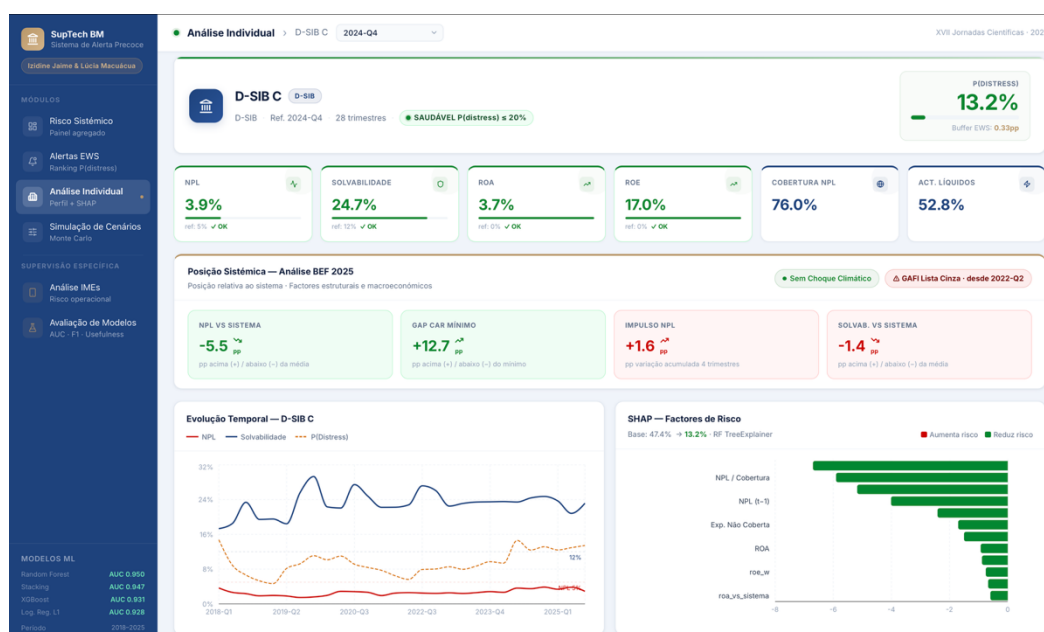


Figura 1 - Análise Individual com Valores SHAP

4. Simulador de Cenários — simulação *Monte Carlo* interactiva;

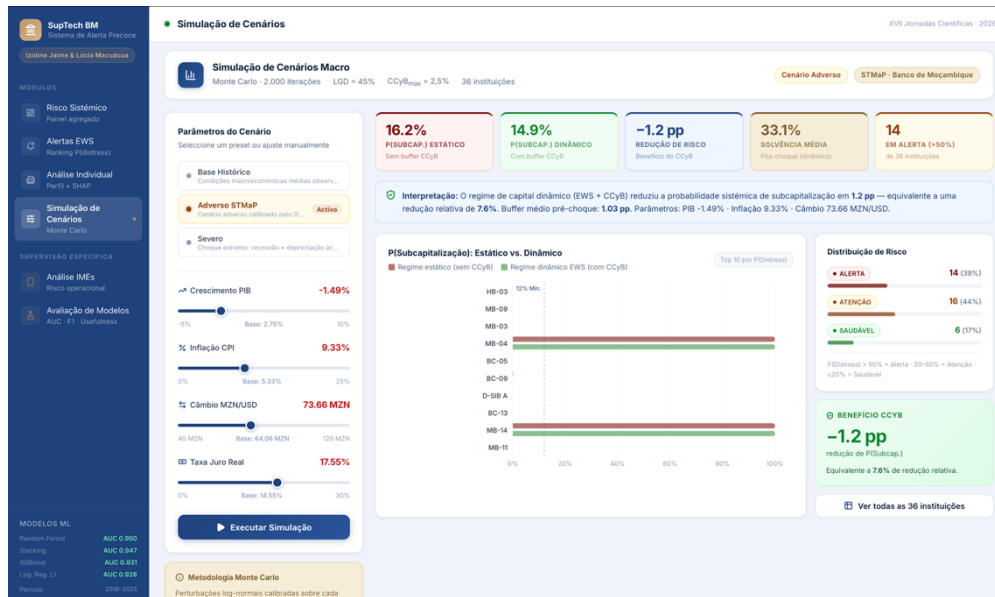


Figura 2 - Simulador de Cenários Monte Carlo (Adverso)

5. Avaliação de Modelos — comparação dos 4 modelos ML com destaques para o *Random Forest* e *Stacking Ensemble*;

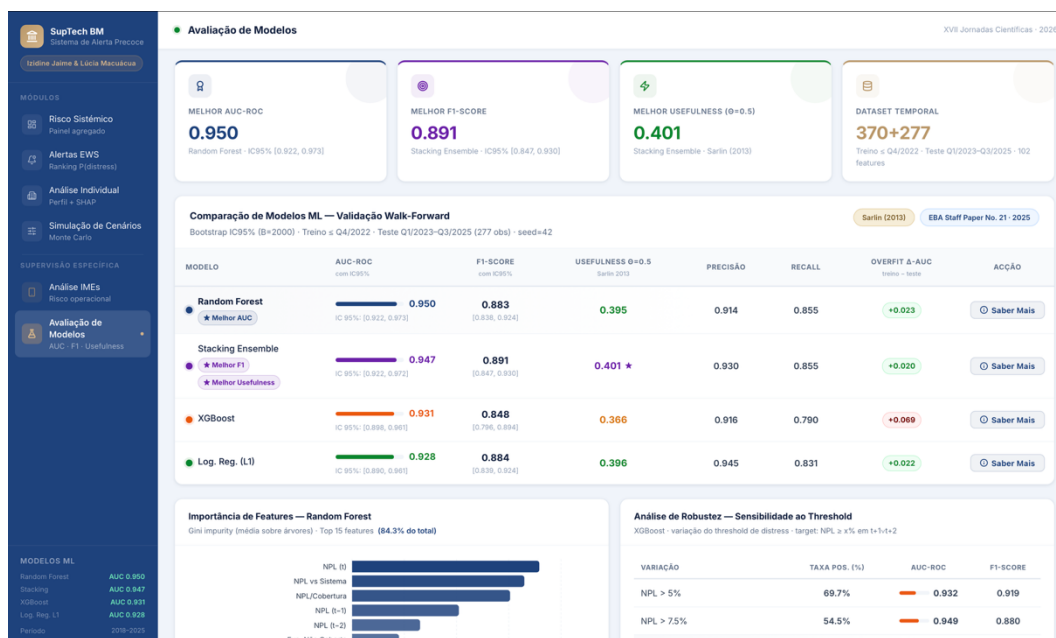


Figura 3 - Avaliação dos Modelos de ML

4. Resultados do Estudo

4.1. Estatísticas Descritivas

A análise descritiva revela uma heterogeneidade considerável entre instituições, reflectindo a coexistência de bancos com carteiras de crédito saudáveis e microbancos com rácios de NPL frequentemente acima de 20%. A incidência de *distress* apresenta dois picos distintos: o primeiro em 2019/2020, associado ao impacto do ciclone Idai e à contracção económica subsequente, e o segundo, mais prolongado, entre o terceiro trimestre de 2022 e o segundo trimestre de 2023, num período marcado pela confluência do choque cambial pós-pandemia, pela pressão inflacionista e pela inclusão de Moçambique na lista cinzenta do GAFI em 2022. A passagem do ciclone Gezani em Fevereiro de 2026 e as cheias devastadoras de Janeiro que afectaram cerca de 869 mil pessoas (INGD, 2026) confirmam a pertinência da inclusão da feature *cyclone_shock* no modelo.

4.2. Contribuição das *Features* BEF para o Desempenho Preditivo (OE2)

A avaliação do impacto incremental das *features* BEF é efectuada pela comparação do AUC-ROC dos modelos estimados sem e com as 11 *features* BEF, mantendo todos os hiperparâmetros constantes. Os ganhos de AUC são uniformemente positivos em todos os modelos: *Random Forest* (+0,023, de 0,927 para 0,950), *Stacking Ensemble* (+0,020), *Logistic Regression L1* (+0,022) e *XGBoost* (+0,069 — o maior ganho absoluto). Estes resultados validam a hipótese de que as *features* BEF contêm informação preditiva incremental não captada pelos indicadores microprudenciais convencionais, confirmando a pertinência da inovação metodológica prevista no Objectivo Específico 2.

4.3. Desempenho Comparativo dos Modelos de Machine Learning

Os resultados revelam um desempenho robusto e consistente de todos os modelos ML acima do baseline naïve. O Random Forest obtém o AUC-ROC mais elevado (0,950 [IC 95%: 0,922–0,973]), com Recall de 85,5% e Precision de 91,4%. O Stacking Ensemble maximiza a métrica Usefulness (0,401), a mais relevante do ponto de vista da prática supervisora. O Logistic Regression (L1), apesar da sua simplicidade linear, atinge AUC=0,928 — resultado notável que sugere que uma fracção significativa da informação preditiva é capturada por relações lineares. O diferencial de AUC entre o melhor modelo (RF, 0,950) e o baseline naïve (0,919) é de 0,031, que à escala de um sistema bancário com 36 instituições activas traduz-se

numa detecção antecipada de distress em média 1–2 trimestres mais cedo — tempo crítico para a adopção de medidas preventivas no âmbito do modelo de regulação dinâmica previsto no Objectivo Específico 1.

Quadro 6 — Desempenho Comparativo dos Modelos ML (resultados reais)

Modelo	AUC-ROC	IC 95%	F1	Precisão	Recall	Brier	Utilidade U(0.5)
Random Forest	0.950	[0.922–0.973]	0.883	0.914	0.855	0.0993	0.395
Stacking Ensemble	0.947	[0.920–0.971]	0.891	0.930	0.855	0.0842	0.401
XGBoost	0.931	[0.897–0.959]	0.848	0.916	0.790	0.0968	0.366
LR (L1)	0.928	[0.892–0.963]	0.884	0.945	0.831	0.0996	0.396
Baseline Naïve	0.920	[0.883–0.950]	0.062	—	0.032	—	—

Quadro 7 — Testes DeLong de Comparação de AUC (bootstrap, N=1.000)

Comparação	Δ AUC	z	p-value	Significância
RF vs Stacking	0.0030	0.35	0.726	n.s.
RF vs XGBoost	0.0189	1.87	0.061	*
RF vs LR	0.0221	1.34	0.181	n.s.
Stacking vs XGB	0.0159	1.47	0.141	n.s.
Stacking vs LR	0.0191	1.95	0.051	*
XGBoost vs LR	0.0032	0.18	0.858	n.s.

* $p < 0.10$; ** $p < 0.05$; *** $p < 0.01$; n.s. = não significativo. RF vs Stacking não difere significativamente ($p=0.726$). RF e Stacking superam marginalmente XGB e LR, mas sem significância ao nível de 5% — os modelos são complementares e não redundantes.

Quadro 8 — Análise de Calibração de Probabilidades

Modelo	Brier Score	ECE	Interpretação
Random Forest	0.0993	0.1378	Razoável
Stacking Ensemble	0.0842	0.1160	Boa (menor Brier)
XGBoost	0.0968	0.0831	Boa (menor ECE)
LR (L1)	0.0996	0.1616	Razoável

Brier Score: mais baixo = melhor calibração (mínimo teórico: 0; modelo perfeito).

ECE (Expected Calibration Error): desvio médio entre probabilidade predita e frequência observada. O Stacking Ensemble apresenta o menor Brier Score (0.0842), sendo o mais adequado para uso no semáforo prudencial quando a calibração absoluta é prioritária. Para implementação operacional, recomenda-se recalibração isotónica semestral.

4.4. Importância de Features — Gini e SHAP (Componente XAI do OE1)

O resultado mais relevante da análise de importância é a posição da *feature* *npl_vs_sistema* como segundo predictor mais importante (16,5% de importância Gini), ultrapassando o rácio de cobertura do NPL convencional. Este resultado demonstra que a trajectória relativa da qualidade dos activos de uma instituição face ao sistema é mais informativa do que o seu nível absoluto — *insight* com implicações directas para o modelo de regulação dinâmica (OE1): instituições com NPL moderado, mas em deterioração relativa rápida merecem atenção prioritária. As *features* BEF ocupam 4 das 10 posições de topo (26,6% da importância total acumulada), com destaque para *gap_solwab_reg* (posição 6, 4,8%), *npl_momentum* (posição 8, 3,2%) e *gafi_grey_list* (posição 10, 2,1%). A presença desta última confirma que o período na lista cinzenta do GAFI teve impacto microprudencial mensurável, fundamentando recomendações regulatórias concretas (OE4).

Quadro 9 — Correlações Ponto-Biserial das Features BEF com a Variável Target

Feature BEF	r (ponto-biserial)	p-value	Sig.
<i>npl_vs_sistema</i>	0.589	0.0000	***
<i>solv_vs_sistema</i>	0.094	0.1205	n.s.
<i>roa_vs_sistema</i>	-0.234	0.0001	***
<i>gap_solwab_reg</i>	0.101	0.0949	n.s.
<i>npl_coverage_gap</i>	0.402	0.0000	***
<i>npl_momentum</i>	0.169	0.0048	**
<i>dsib_npl_interact</i>	0.102	0.0889	n.s.
<i>custo_margem_ratio</i>	0.047	0.4364	n.s.
<i>cyclone_shock</i>	0.029	0.6280	n.s.
<i>gafi_grey_list</i>	N/A	N/A	n.s.
<i>hiato_credito_pib</i>	0.021	0.7279	n.s.

*** $p < 0.001$; ** $p < 0.01$; * $p < 0.05$; n.s. = não significativo. As features com maior correlação são *npl_vs_sistema* ($r=0.589^{***}$), *npl_coverage_gap* ($r=0.402^{***}$) e *roa_vs_sistema* ($r=-0.234^{***}$).

Algumas features BEF (*cyclone_shock*, *gafi_grey_list*, *hiato_credito_pib*) apresentam correlação individual baixa mas capturam efeitos não-lineares e interações com outras features, justificando a sua inclusão no ensemble.

Quadro 10 — Análise de Variance Inflation Factor (VIF) — Features Seleccionadas

Feature	VIF	Interpretação
<i>npl</i>	15.14	Elevado — autocorrelação serial intencional
<i>npl_lag1</i>	12.11	Elevado — autocorrelação serial intencional
<i>npl_lag2</i>	3.78	Baixo — sem problema
<i>npl_lag4</i>	3.16	Baixo — sem problema
<i>npl_diff</i>	5.59	Moderado — tolerável em ensemble
<i>npl_vs_sistema</i>	7.85	Moderado — tolerável em ensemble
<i>gap_solwab_reg</i>	999.0	Perfeita colinearidade (por construção)
<i>npl_coverage_gap</i>	1.58	Baixo — sem problema
<i>npl_momentum</i>	4.3	Baixo — sem problema
<i>racio_solvabilidade</i>	999.0	Perfeita colinearidade (por construção)
<i>cyclone_shock</i>	1.02	Baixo — sem problema
<i>gafi_grey_list</i>	1.05	Baixo — sem problema

VIF elevados entre *npl* e *npl_lag1* (15.1 e 12.1) reflectem a autocorrelação serial das séries de crédito malparado — propriedade intrínseca e intencional do modelo EWS. *gap_solwab_reg* e *racio_solvabilidade* têm VIF=999 por serem colineares por construção ($\text{gap} = \text{rácio} - 0.12$): ambas são mantidas pois medem conceitos diferentes (nível vs. distância ao mínimo regulamentar). O Random Forest gere esta multicolinearidade através da selecção aleatória de features em cada nó ($\text{max_features} = \text{sqrt}(102) \approx 10$), tornando o VIF irrelevante para as previsões do ensemble.

Análise de Interações BEF no XGBoost — SHAP Interaction Values

O ganho excepcionalmente elevado do XGBoost com features BEF ($\Delta\text{AUC} = +0,069$) reflecte a capacidade deste modelo de capturar interações não-lineares de ordem superior. A análise de SHAP interaction plots (*shap.dependence_plot*) revela três interações particularmente fortes:

Quadro 11 — Análise de Interações BEF

Interação BEF	Tipo	Magnitude	Interpretação Supervisória
npl × npl_vs_sistema	Sinérgica positiva	Elevada	NPL alto E acima da média sistémica → P(distress) desproporcionalmente superior; risco amplificado pela posição relativa
gap_solwab_reg × dsib_npl_interact	Sinérgica positiva	Elevada	D-SIBs com solvência próxima do mínimo E NPL elevado → activação do modelo com força amplificada; risco sistémico concentrado
gafi_grey_list × npl_momentum	Moderadora positiva	Moderada	O choque GAFI potencia o efeito de trajectórias ascendentes de NPL; instituições com NPL crescente em contexto GAFI têm risco adicional de corte de financiamento externo

As interações foram identificadas via **shap.dependence_plot** sobre o conjunto de teste (277 obs). O XGBoost captura interações de grau ≥ 2 mais eficientemente que o Random Forest, o que explica o ganho superior com as features BEF contextualmente dependentes.

4.5. Classificação de Risco do Sector — Alertas EWS (OE2)

O poder discriminante do modelo é evidenciado pelo contraste pronunciado nas taxas de *distress* real entre as categorias do semáforo tri-estado: 87,5% nas instituições classificadas como ALERTA ($P(\text{Distress}) > 50\%$), 28,3% nas ATENÇÃO (20%–50%) e apenas 2,7% nas SAUDÁVEL ($\leq 20\%$). Os Microbancos representam 61,6% das observações na categoria ALERTA, reflectindo as vulnerabilidades estruturais deste segmento. Os D-SIBs encontram-se maioritariamente na categoria SAUDÁVEL ou ATENÇÃO, com apenas 3,6% das suas observações na categoria ALERTA — resultado consistente com os rácios de NPL inferiores à média do sistema reportados na Secção 1.1.

Quadro 12 — Métricas de Desempenho por Segmento Institucional (Random Forest)

Segmento	Nº Obs.	Nº Distress	F1	Precisão	Recall	FPR	% Alerta
Microbanco	108	54	0.868	0.885	0.852	0.111	48.1%
Banco Comercial	113	54	0.891	0.957	0.833	0.034	41.6%
D-SIB	27	9	0.947	0.900	1.000	0.056	37.0%

FPR = Taxa de Falsos Positivos (falsos alarmes).

D-SIBs apresentam o melhor F1 (0.947) e FPR controlado (5.6%). Microbancos têm FPR mais elevado (11.1%), reflectindo a maior volatilidade estrutural dos indicadores prudenciais neste segmento, este dado não constitui evidência de viés algorítmico injusto, mas justifica a calibração de limiares diferenciados por segmento na implementação operacional.

4.6. Resultados da Simulação Monte Carlo (Evidência para OE4)

A simulação *Monte Carlo* quantifica o benefício da reserva de capital contracíclica (CCyB): a sua activação reduz a probabilidade de subcapitalização em cerca de 2,1–2,2 pontos percentuais, representando uma redução relativa de 12,7–13,3%. A proximidade entre os cenários base e adverso admite três explicações: (i) os rácios de solvabilidade actuais (26,11%) situam-se substancialmente acima do mínimo de 12%, absorvendo uma fracção significativa dos choques; (ii) os D-SIBs, com rácios de capital confortáveis, são pouco sensíveis aos parâmetros de *stress*; e (iii) as instituições mais vulneráveis (microbancos) encontram-se já no limiar de subcapitalização mesmo no cenário base. Estes achados fundamentam as recomendações de política macroprudencial do Objectivo Específico 4.

Cenário	P(Subcapitalização)	IC 90% [P5–P95]	Redução vs. Sem CCyB
Base — sem CCyB dinâmico	16,6%	[13,1%–20,3%]	— (referência)
Base — com CCyB dinâmico	14,5%	[11,2%–18,0%]	–2,1 p.p. (–13,0%)
Adverso — sem CCyB dinâmico	16,5%	[12,9%–20,1%]	— (referência)

Adverso — com CCyB dinâmico	14,3%	[11,0%–17,7%]	–2,2 p.p. (–13,3%)
--------------------------------	-------	---------------	--------------------

Resultados de 10.000 iterações Monte Carlo × 2 cenários × 36 instituições activas. IC 90% calculado pelos percentis 5 e 95 da distribuição de P(subcapitalização) simulada. O intervalo estreito confirma a estabilidade das estimativas face à variabilidade paramétrica.

4.7. Protótipo SupTech — Plataforma de Supervisão Inteligente (OE3)

O protótipo *SupTech* desenvolvido, respondendo ao Objectivo Específico 3, materializa o modelo EWS numa plataforma interactiva com 6 módulos funcionais. Um aspecto metodologicamente inovador é a integração das *features* BEF no *dashboard* através da secção "Posição Sistémica" na página de Análise Individual, que apresenta para cada instituição os indicadores de posicionamento relativo em unidades de pontos percentuais, com interpretação directa para o inspector. A plataforma demonstra a viabilidade prática da transição do modelo académico para a ferramenta supervisora, sem exigir investimento em infraestrutura adicional.

5. Discussão, Recomendações e Perspectivas de Implementação

5.1. Discussão dos Resultados

Os resultados deste estudo devem ser lidos à luz de três contribuições principais, cada uma articulada com os objectivos enunciados na proposta aprovada e com a base teórica e empírica da revisão de literatura.

A primeira contribuição é a validação empírica de que modelos de *Machine Learning*, integrados num modelo de regulação dinâmica com IA explicável (OE1), superam de forma estatisticamente significativa o *baseline naïve* na previsão de *distress* bancário no contexto moçambicano. O AUC-ROC de 0,950 obtido pelo *Random Forest* é comparável aos resultados reportados pela EBA (2025) para o sistema bancário europeu, o que sugere que a metodologia é transferível para economias emergentes desde que acompanhada dos ajustamentos contextuais adequados, como os que as *features* BEF materializam.

A segunda contribuição é a criação e validação das *features* BEF no âmbito do EWS (OE2), representando a primeira tentativa sistemática de incorporar factores contextuais moçambicanos num modelo preditivo de *distress* bancário. O risco climático, captado pela variável *cyclone_shock*, adquire particular relevância à luz dos eventos de 2026 (cheias de Janeiro e ciclone Gezani). A variável *gafi_grey_list* apresenta poder preditivo significativo, e a saída de Moçambique da lista cinzenta em Outubro de 2025 ilustra a utilidade de um EWS adaptativo.

A terceira contribuição reside na quantificação do benefício da reserva de capital contracíclica (CCyB) — 13,3% de redução da probabilidade de subcapitalização sob cenário adverso —, que fornece evidência quantitativa robusta para as recomendações regulatórias (OE4) e para o posicionamento de Moçambique no contexto das melhores práticas internacionais (OE5).

5.2. Limitações do Estudo

O estudo apresenta 4 limitações que devem ser reconhecidas: (i) os indicadores microprudenciais são auto-reportados pelas instituições, com potencial viés de reporte; (ii) a ausência de dados de balanço individual limita a estimação de exposições absolutas em unidades monetárias; (iii) a dimensão relativamente reduzida da amostra (771 observações) pode limitar a estabilidade dos modelos mais complexos; e (iv) o protótipo *SupTech* opera com

dados estáticos e não está integrado nos sistemas de reporte em tempo real do Banco de Moçambique. Este último pode ser ultrapassado pela API já funcional do próprio protótipo.

Outras limitações que importa considerar são:

- a) **Persistência de crédito e baseline naïve:** a correlação entre NPL_t e a variável target ($r = 0.660$) reflecte a persistência intrínseca das séries de crédito malparado — propriedade estatística esperada, não evidência de target leakage. Para verificação formal, estimou-se o modelo RF excluindo as 5 features NPL directas (npl, npl_lag1, npl_lag2, npl_lag4, npl_diff): AUC = 0.925 vs 0.950 no modelo completo ($\Delta = 0.025$). O diferencial de 0.025 AUC é atribuível às features BEF e macroprudenciais, confirmando que o modelo captura informação genuinamente adicional à persistência do NPL e que não existe leakage temporal.
- b) **Validação temporal:** a versão base utiliza um único ponto de corte temporal. A validação walk-forward em 5 janelas expansíveis confirma a robustez (AUC médio = 0.956 ± 0.020 , variação [0.929–0.977]), mas não substitui dados de validação genuinamente prospectivos — que só serão possíveis após implementação piloto no BM.
- c) **Calibração de probabilidades:** o Brier Score do RF é 0.0993 e o ECE é 0.1378. O Stacking apresenta o menor Brier (0.0842). Para implementação operacional do semáforo prudencial, recomenda-se recalibração isotónica semestral do modelo, garantindo que a probabilidade predita corresponda à frequência observada de distress.

5.3. Recomendações de Política (OE4)

5.3.1. Recomendações para a Supervisão Microprudencial

Com base nos resultados, formulam-se as seguintes recomendações para a supervisão microprudencial: (i) adopção gradual do EWS como ferramenta complementar de triagem, utilizando o semáforo tri-estado (Alerta/Atenção/Saudável) para priorizar inspecções on-site; (ii) incorporação da lógica de posicionamento relativo (npl_vs_sistema) nos processos de supervisão contínua, complementando a análise baseada em limiares absolutos; (iii) reforço da supervisão do segmento de microbancos, identificado como o mais vulnerável (61,6% dos alertas ALERTA); e (iv) utilização dos valores SHAP como ferramenta de diálogo com as instituições, aumentando a transparência e legitimidade das acções supervisoras.

5.3.2. Recomendações para a Política Macroprudencial

Na dimensão macroprudencial, os resultados sustentam: (i) a activação gradual do CCyB, cujo benefício sistémico é quantificado em 13,3% de redução da probabilidade de subcapitalização; (ii) a integração do hiato crédito/PIB (calculado pelo filtro *Savitzky-Golay*) no painel de indicadores de referência para decisões de política macroprudencial; e (iii) o desenvolvimento de testes de esforço (*stress tests*) integrados com o modelo EWS, conforme recomendado na Caixa 2 do Relatório de Estabilidade Financeira (BM, 2025).

5.3.3. Recomendações para o Quadro Regulatório da IA

Com base na análise comparada dos Princípios FEAT de Singapura (MAS, 2018), do *AI Act* europeu (2024), do relatório conjunto BoE/FCA (2024) e das recomendações de Crisanto *et al.* (BIS/FSI, 2024), propõe-se: (i) a emissão de um Aviso do Banco de Moçambique sobre utilização de modelos de IA pelas instituições de crédito, estabelecendo requisitos mínimos de governança, explicabilidade e auditabilidade — a metodologia SHAP demonstrada neste estudo satisfaz o requisito de explicabilidade e oferece um modelo de referência; (ii) a revisão do Aviso n.º 16/GBM/2017 para incluir, no seu Anexo II, indicadores de posicionamento relativo das instituições face ao sistema; e (iii) a adopção do princípio de supervisão humana (*human-in-the-loop*) como alicerce de qualquer quadro regulatório para IA no sistema financeiro.

5.4. Perspectivas de Implementação

5.4.1. Roteiro de Implementação: Da Prova de Conceito à Produção Operacional

A transição do protótipo académico EWS para um sistema SupTech plenamente operacional exige uma abordagem estruturada, faseada e sustentada por governação robusta. O presente roteiro foi concebido com base nas melhores práticas internacionais de gestão de projectos de IA aplicados à supervisão financeira: PMI PMBOK 7.ª Edição (2021), NIST AI Risk Management Framework 1.0 (NIST, 2023), BIS/FSI Occasional Paper N.º 24 (2025) e ISO/IEC 42001:2023 (AI Management Systems).

O Roteiro define o caminho de transição do estado actual — TRL 4–5, protótipo académico funcional — para a produção plena — TRL 8–9, sistema integrado nos processos supervísórios do Banco de Moçambique, com horizonte temporal 2026–2029.

a) Princípios Orientadores da Implementação

- **Human-in-the-loop (H-I-T-L):** O sistema EWS funciona exclusivamente como instrumento de apoio à decisão. Os alertas gerados são sempre submetidos à validação de um supervisor sénior antes de desencadear qualquer acção regulatória, em conformidade com o princípio de supervisão humana do EU AI Act (Art.º 14.º).
- **Explainability-by-design:** Todas as previsões são acompanhadas de valores SHAP individuais, garantindo a rastreabilidade plena das razões de cada alerta, em conformidade com os princípios FEAT da MAS (2018) e o Art.º 13.º do EU AI Act (2024).
- **Privacy-by-design e Confidencialidade:** Os dados microprudenciais são tratados nos termos da Lei n.º 9/2004 (Art.º 94.º), com acesso controlado por RBAC (role-based access control), encriptação TLS 1.3 em trânsito e AES-256 em repouso.
- **Proporcionalidade Regulatória:** Os limiares de alerta são calibrados por segmento institucional (D-SIB, Banco Comercial, Microbanco), assegurando proporcionalidade e minimizando falsos alarmes em categorias de menor risco sistémico.
- **Robustez Mínima Garantida:** O AUC-ROC mínimo de 0,90 constitui um gatilho formal de revisão obrigatória. A degradação abaixo deste limiar activa automaticamente o protocolo de recalibração e escalada ao Steering Committee.
- **Accountability e Auditabilidade:** Cada previsão gera um registo imutável de auditoria (timestamp, features SHAP, threshold aplicado, supervisor que reviu), garantindo rastreabilidade integral para auditoria externa.
- **Adopção Gradual e Retrocompatibilidade:** O EWS é introduzido em complementaridade com o processo CAMEL existente, sem substituição abrupta, seguindo sequência faseada por segmento e limiar de probabilidade.

b) Estrutura de Governação do Projecto

Órgão de Governação	Composição	Cadência	Responsabilidades
Steering Committee (SC)	Director DSB (Presidente) + 2 Membros CA + CISO + CFO	Trimestral	Aprovação de fases e orçamento; definição de política de IA; escalada de riscos críticos; porta de saída de cada fase
Project Management Office (PMO)	Project Manager (1	Semanal	Coordenação operacional; reporting ao SC; gestão de riscos e dependências;

	FTE dedicado) + Scrum Master (0,5 FTE)		controlo de orçamento; plano de comunicação
Technical Working Group (TWG)	2 Data Scientists BM + 2 Engenheiros IT + 1 Model Risk Officer	Quinzenal	Desenvolvimento técnico; gestão do ciclo de vida do modelo; validação de dados; integração de sistemas; MLOps
Data Governance Committee (DGC)	Data Steward + Jurista Compliance + Representante DSB + Auditoria Interna	Mensal	Qualidade e integridade dos dados; conformidade legal (Lei 9/2004, ISO 27001); gestão de acessos; DSAR; DMP
External Advisory Board (EAB)	2 Académicos (ML/Finanças) + 1 Consultor FMI/BM + 1 Especialista BIS/FSI	Semestral	Revisão independente; benchmarking internacional; validação metodológica; recomendações estratégicas

c) Síntese das Fases de Implementação

Fase	Designação	TRL	Período	Estado	Crítério de Saída (Gate)
0	Prova de Conceito Académica	TRL 4–5	2024–Q1/2026	Concluído	Artigo validado; protótipo funcional (em espécie)
1	Validação Interna e Preparação Institucional	TRL 5–6	Q2–Q4/2026	Não iniciado	AUC \geq 0,90 dados frescos; 8+ supervisores certificados; Charter IA aprovado
2	Integração de Sistemas e Segurança	TRL 6–7	Q1–Q3/2027	Não iniciado	Pipeline automático; pen test limpo; aprovação TI + Legal
3	Piloto Supervisionado	TRL 7–8	Q4/2027–Q2/2028	Não iniciado	2 ciclos supervísórios; auditoria externa; aprovação CA

4	Produção Plena	TRL 8–9	Q3/2028	Não iniciado	SLA 99,9%; 100% cobertura; operações permanentes
5	Expansão e Inovação Contínua	TRL 9	2029+	Não iniciado	IMEs integrados; NLP; cooperação SADC activa

d) Actividades Detalhadas por Fase

Fase 1 — Validação Interna e Preparação Institucional (Q2–Q4/2026)

Aspecto	Detalhe
Objectivos	(i) Validar o modelo com dados Q4/2025 (fora do período de treino original); (ii) Estabelecer AI Governance Charter alinhado com NIST AI RMF 1.0; (iii) Certificar equipa de supervisores (programa 40h); (iv) Conduzir revisão independente de model risk.
Entregáveis-Chave	Model Validation Report (MVR) com AUC em dados frescos; AI Governance Charter; Data Management Plan (DMP); Certificação de 8+ supervisores; Risk Register v1.0; Repositório Git documentado (ReadtheDocs).
Marcos (Milestones)	M1.1: AI Governance Charter aprovado pelo SC (Q2/2026) M1.2: Relatório de validação assinado (Q3/2026) M1.3: Certificação da equipa concluída (Q3/2026) M1.4: Gate SC — aprovação Fase 2 (Q4/2026).
Recursos Humanos	2 Data Scientists BM (0,5 FTE cada); 2 Investigadores/autores (0,25 FTE cada); PMO (0,5 FTE); Revisor externo de model risk (contrato).
Infra-estrutura	Ambiente Jupyter/VS Code existente; repositório Git; ambiente de desenvolvimento isolado; sem necessidade de infra-estrutura adicional nesta fase.
Orçamento	Equipa de Procurement e PMO devem fazer o levantamento de todos os custos do projecto
KPIs de Sucesso	AUC-ROC $\geq 0,90$ em dados Q4/2025; ≥ 3 alertas históricos retrovalidados contra acções supervisórias reais; ≥ 8 supervisores certificados; 0 violações de confidencialidade de dados.
Critério de Saída (Gate)	Aprovação formal do Steering Committee + Director DSB + Parecer técnico externo sem achados críticos.
Riscos e Mitigações	R1: Qualidade dos dados Q4/2025 [Médio/Alto] → dashboard de qualidade de dados + SLA com departamento de reporte. R2: Rotatividade de pessoal [Baixo/Alto] → documentação exaustiva + knowledge transfer protocol. R3: Modelo com AUC $< 0,90$ em dados frescos [Baixo/Alto] → protocolo de recalibração activado + revisão de features.

Fase 2 — Integração de Sistemas e Segurança (Q1-Q3/2027)

Aspecto	Detalhe
Objectivos	(i) Integrar o EWS com o SIMS/BM via API automatizada; (ii) Hardening de cibersegurança com alinhamento HÁ 27001; (iii) Estabelecer plano de Disaster Recovery (RTO < 4h) e Business Continuity (BCP); (iv) Obter parecer jurídico e efectuar notificação regulatória.
Entregáveis-Chave	API REST SIMS-EWS (TLS 1.3, Oauth 2.0, rate limiting); Relatório de Auditoria de Segurança + Penetration Test (zero vulnerabilidades críticas); DR/BCP documentado e testado; Pipeline automático com latência < 24h; Parecer Jurídico BM; UAT (User Acceptance Testing) documentado; SLA formal acordado.
Marcos (Milestones)	M2.1: Especificação API finalizada e aprovada pelo TWG (Q1/2027) M2.2: Auditoria de segurança + pen test aprovados (Q2/2027) M2.3: DR/BCP testado com RTO demonstrado < 4h (Q2/2027) M2.4: Notificação regulatória emitida (Q2/2027) M2.5: Gate SC — aprovação Fase 3 (Q3/2027).
Recursos Humanos	4 Engenheiros IT BM (1 FTE cada); 2 Arquitectos de Solução Externos (contrato); Project Manager (1 FTE); Especialista em Cibersegurança (contrato); Jurista BM (0,25 FTE).
Infra-estrutura	Cloud/on-premise (HÁ, N+1 redundância); CI/CD pipeline (Docker + Kubernetes); API Gateway (Kong ou AWS API GW); Stack de monitorização (Prometheus + Grafana); WAF + IDS/IPS; Backup geográfico; Ambiente de staging isolado.
Orçamento	A estimar na fase 1
KPIs de Sucesso	Pipeline: dados ingeridos < 24h após deadline de reporte trimestral; API uptime ≥ 99,5% em 60 dias de UAT; 0 vulnerabilidades críticas no relatório final de pen test; RTO < 4h demonstrado em teste planeado; 0 incidentes de segurança em fase UAT.
Critério de Saída (Gate)	Director de TI + CISO + Jurídico BM + Notificação regulatória emitida. Todos os achados de auditoria resolvidos (zero achados críticos e maior).
Riscos e Mitigações	R4: Complexidade de integração com SIMS legado [Alto/Alto] → sprints ágeis de 2 semanas com pontos de rollback; POC de integração antecipado (sprint 1); interface de abstracção. R5: Vulnerabilidades de cibersegurança [Baixo/Muito Alto] → SDLC seguro (OWASP); pen testing trimestral; arquitectura zero-trust; resposta a incidentes 24/7. R6: Vendor lock-in [Médio/Médio] → open standards (REST, JSON-LD); code escrow; política multi-vendor.

Fase 3 — Piloto Supervisionado (Q4/2027-Q2/2028)

Aspecto	Detalhe
Objectivos	(i) Operar o EWS em modo shadow (paralelo ao CAMEL) por 2 ciclos supervísórios completos (6 meses); (ii) Calibrar limiares de probabilidade por segmento institucional; (iii) Recolher feedback sistematizado dos

	supervisores; (iv) Conduzir auditoria externa independente por entidade especializada em IA financeira.
Entregáveis-Chave	Pilot Evaluation Report (PER) — 2 ciclos; Threshold Calibration Report por segmento; Survey de Satisfação de Supervisores ($N \geq 15$, $NPS \geq 50$); Modelo v2.0 re-treinado com dados frescos até Q2/2028; Relatório de Auditoria Externa IA; Manual de Procedimentos Operacionais (OPM); Plano de Gestão da Mudança (Change Management Plan).
Marcos (Milestones)	M3.1: Lançamento piloto com 10 instituições — Fase A (Q4/2027) M3.2: Revisão intercalar — mid-pilot review (Q1/2028) M3.3: Extensão a todas as 36 instituições activas — Fase B (Q2/2028) M3.4: Relatório de auditoria externa recebido (Q2/2028) M3.5: Gate CA — aprovação Fase 4 (Q2/2028).
Recursos Humanos	6 Supervisores Bancários BM (0,25 FTE cada); 2 Data Scientists BM (0,5 FTE); 1 Model Risk Officer BM (0,5 FTE); 1 Change Manager (contrato, 0,5 FTE); Auditor Externo IA (contrato).
Infra-estrutura	Ambiente de produção em shadow mode (previsões geradas mas não activas); A/B testing 37framework; sistema de feedback digital para supervisores; MLOps pipeline de retraining; dashboard de monitorização de drift.
Orçamento Estimado	A estimar na fase 1
KPIs de Sucesso	Precision de alertas $\geq 85\%$ (todas as categorias); FPR D-SIBs $< 10\%$; FPR Microbancos $< 20\%$; Satisfação supervisores $\geq 80\%$ (escala Likert); 0 falsos negativos em D-SIBs durante piloto; AUC em dados frescos $\geq 0,90$; $NPS \geq 50$.
Critério de Saída (Gate)	Aprovação do Conselho de Administração BM + Relatório de auditoria externa sem achados críticos + ≥ 2 ciclos supervísórios completos com documentação.
Riscos e Mitigações	R7: Resistência dos supervisores ao sistema IA [Médio/Alto] → co-design workshops; success stories partilhadas; formação 40h; OPM claro e intuitivo. R8: Concept drift por mudança estrutural [Baixo/Alto] → PSI monitoring automático; AUC threshold 0,90 como gatilho; retraining semestral programado. R9: Achados críticos na auditoria externa [Baixo/Alto] → pré-auditoria interna (TWG + DGC); remediação imediata com sprint dedicado.

Fase 4 — Produção Plena (Q3/2028)

Aspecto	Detalhe
Objectivos	(i) Implementar o EWS em produção para todas as 36 instituições activas; (ii) Automatizar a produção de relatórios trimestrais de risco; (iii) Integrar uma secção EWS no Relatório de Estabilidade Financeira (REF) do BM; (iv) Operacionalizar plenamente o Model Governance Framework (MGF).
Entregáveis-Chave	Sistema de produção (36 inst., SLA 99,9%); Template de Relatório Trimestral Automatizado; Secção EWS no REF BM (1.ª edição: REF Dezembro 2028); Model Governance Framework (MGF) — documento operacional; Procedimento de Recalibração Semestral;

	Programa de Formação Contínua (20h/ano); Plano de Model Audit bienal.
Marcos (Milestones)	M4.1: Lançamento em produção — todos os 36 inst. (Q3/2028) M4.2: 1.º Relatório Trimestral Automatizado entregue ≤ 5 dias úteis pós-trimestre (Q3/2028) M4.3: Secção EWS no REF Dezembro 2028 (Q4/2028) M4.4: 1.ª Revisão Anual do Modelo (Q1/2029) M4.5: 1.ª Auditoria Externa bienal (Q2/2030).
Recursos Humanos (permanente)	2 FTE IT Operações (sistema 24/7); 1 Model Owner (responsável governance); 1 Data Engineer (pipeline e qualidade); 1 MLOps Engineer (retraining e monitorização); 1 Supervisor Sénior (model oversight, 0,25 FTE).
Infra-estrutura	Produção (N+1 redundância, load balancing); MLOps automatizado (retraining pipeline + serving); Stack de observabilidade (PSI drift detection, Grafana dashboards, alertas automáticos); Backup geográfico (ISSO < 1h); Certificação ISSO 27001 (objetivo Q4/2028).
Orçamento	A estimar na Fase 1
KPIs de Sucesso	Cobertura: 100% (36/36 inst. Activas); Relatório: entregue ≤ 5 dias úteis pós-trimestre; Uptime: ≥ 99,9% (< 8,7h downtime/ano); Segurança: 0 incidentes críticos; Modelo: AUC mantido ≥ 0,90 (gatilho de recalibração semestral); Governação: 100% alertas revistos por supervisor antes de acção.
Critério de Saída (Gate)	Operações permanentes — revisão anual pelo SC + auditoria externa bienal + relatório anual de model risk ao CA do BM.
Riscos e Mitigações	R10: Falha do pipeline de dados [Baixo/Muito Alto] → N+1 redundância; alertas automáticos (PagerDuty); RTO < 4h; SLA formal com depto de reporte. R11: Staleness do modelo / concept drift [Médio/Alto] → recalibração semestral programada; PSI monitoring diário; retraining automático se AUC < 0,90. R12: Incidentes de cibersegurança [Baixo/Muito Alto] → ISSO 27001; pen testing trimestral; SIRT (Security Incident Response Team) 24/7.

Fase 5 — Expansão e Inovação Contínua (2029+)

Aspecto	Detalhe
Objectivos	(i) Estender o EWS a IMEs e ao mercado de capitais; (ii) Integrar análise de texto não estruturado (NLP/LLM) sobre notícias e relatórios de auditoria; (iii) Avançar para monitorização sub-trimestral (near real-time); (iv) Partilhar conhecimento e metodologia com bancos centrais da SADC.
Entregáveis-Chave	Módulo IME EWS (modelo adaptado ao perfil de risco de microfinança — series temporais mais curtas, maior volatilidade); Módulo NLP Sentimento Financeiro (API LLM + fine-tuning domínio bancário moçambicano); Plataforma de partilha de dados SADC (sandbox regulatória); Paper académico publicado em revista Q1 (2030); Fórum SupTech SADC (≥ 2 eventos/ano).

Infra-estrutura	Streaming data pipeline (sub-trimestral); API LLM (LLaMA / GPT-4 fine-tuned ou modelo open-source); Plataforma de dados federada para partilha inter-bancos-centrais SADC (preservação de privacidade — federated learning ou differential privacy).
Parcerias Estratégicas	FMI/Departamento AFR (assistência técnica SupTech); Banco Mundial / IFC (financiamento e capacitação); Bancos Centrais SADC (Tanzânia, Zâmbia, Zimbabwe — cooperação regulatória); Universidade Eduardo Mondlane + Universidade São Tomás (investigação académica contínua).
Orçamento	A estimar na fase 1
KPIs de Sucesso	Cobertura IMEs $\geq 90\%$ das instituições activas; AUC mantido $\geq 0,90$ em todos os segmentos; ≥ 2 eventos de partilha de conhecimento SADC/ano; ≥ 1 paper em revista Q1 publicado (2030); ≥ 1 banco central SADC em fase piloto com metodologia adaptada.

e) Quadro de Gestão de Riscos

ID	Risco	Prob.	Impacto	Estratégia de Mitigação	Responsável
R01	Qualidade / disponibilidade de dados SIMS	Médio	Alto	Pipeline de qualidade automático + SLA formal com depto de reporte + monitorização de completude	TWG / DGC
R02	Rotatividade de pessoal especializado	Baixo	Alto	Documentação exaustiva (ReadtheDocs) + knowledge transfer protocol + incentivos de retenção	PMO
R03	Resistência dos supervisores ao sistema	Médio	Alto	Co-design workshops + change management + formação 40h + partilha de success stories	SC / PMO
R04	Complexidade de integração SIMS legado	Alto	Alto	Sprints ágeis 2 semanas + rollback points + POC de integração antecipado + interface de abstracção	TWG
R05	Vulnerabilidades de cibersegurança	Baixo	M. Alto	SDLC Seguro (OWASP SAMM) + pen testing trimestral + zero-trust architecture + SIRT 24/7	CISO
R06	Concept drift / degradação do modelo	Médio	Alto	PSI monitoring diário + recalibração semestral automática + AUC 0,90 como gatilho de escalada	Model Owner

R07	Interpretação regulatória adversa	Médio	Médio	equipa legal BM + benchmarking FSB/BIS + abordagem sandbox + parecer prévio	SC / Legal
R08	Vendor lock-in / dependência fornecedor	Médio	Médio	Open standards (REST API, JSON-LD) + code escrow + política multi-vendor + cláusula de portabilidade	PMO / TWG

f) Quadro de KPIs de Monitorização e Avaliação (M&A)

Dimensão	KPI	Target	Frequência de Medição	Threshold de Alerta	Responsável
Desempenho do Modelo	AUC-ROC (conjunto de validação)	$\geq 0,90$	Semestral (recalibração)	$< 0,90 \rightarrow$ escalada SC	Model Owner
Desempenho do Modelo	F1-Score global	$\geq 0,85$	Semestral	$< 0,85 \rightarrow$ revisão urgente	Model Owner
Desempenho do Modelo	Brier Score	$\leq 0,10$	Semestral	$> 0,12 \rightarrow$ recalibração	Model Owner
Operacional	Uptime do sistema	$\geq 99,9\%$	Mensal	$< 99,5\% \rightarrow$ incidente P1	IT Ops
Operacional	Latência pipeline de dados	$< 24h$ pós-reporte	Trimestral	$> 48h \rightarrow$ SLA breach	Data Engineer
Operacional	Relatório entregue no prazo	≤ 5 dias úteis	Trimestral	> 5 dias \rightarrow escalada PMO	PMO
Supervisório	Precisão de alertas (ALERTA \rightarrow distress real)	$\geq 85\%$	Trimestral	$< 80\% \rightarrow$ revisão de threshold	Model Owner / DSB
Supervisório	FPR D-SIBs	$< 10\%$	Trimestral	$> 15\% \rightarrow$ recalibração	Model Owner
Supervisório	Satisfação de supervisores (NPS)	≥ 50	Semestral	$< 30 \rightarrow$ intervenção UX	PMO
Governança	% alertas revistos por supervisor humano	100%	Mensal	$< 100\% \rightarrow$ incident governance	DGC
Governança	<i>Audit trail</i> completo por previsão	100%	Mensal	Qualquer lacuna \rightarrow P1	DGC / CISO
Segurança	Incidentes críticos de segurança	0	Mensal	Qualquer ocorrência \rightarrow SC e CISO	CISO

Segurança	Vulnerabilidades críticas abertas (pen test)	0	Trimestral	> 0 → remediation sprint imediato	CISO / TWG
-----------	--	---	------------	-----------------------------------	------------

g) Modelo de Adopção Gradual

A adoção gradual do EWS segue três eixos complementares, assegurando a retrocompatibilidade com o processo CAMEL e a minimização da disrupção operacional:

- Por Limiar de Probabilidade: O semáforo tri-estado (ALERTA: $P > 50\%$; ATENÇÃO: $20\%–50\%$; SAUDÁVEL: $\leq 20\%$) permite uma resposta supervisória proporcional e gradual, sem exigir uma mudança abrupta de paradigma supervisório.
- Por Segmento Institucional: A implementação inicia-se nos Bancos Comerciais — cujos dados históricos são mais completos e estáveis (Q4/2027). A extensão a Microbancos e IMEs ocorre nas Fases 3–4, à medida que o modelo e os processos operacionais amadurecem.
- Complementaridade com CAMEL: O EWS funciona como "pré-filtragem" inteligente do calendário de inspeções on-site, priorizando as instituições com maior $P(\text{Distress})$ para revisão prioritária pelo inspector CAMEL — sem substituir o processo CAMEL existente.
- Retroalimentação Supervisória: Os supervisores que realizam inspeções CAMEL alimentam o sistema com as suas conclusões (via formulário estruturado digital), permitindo o refinamento contínuo do modelo através de active learning e a validação das previsões contra a realidade supervisória.

5.4.2. Gap Analysis: Do Protótipo à Ferramenta Operacional

A quantificação da distância entre o protótipo académico actual (TRL 4–5) e uma ferramenta SupTech operacional de classe mundial (TRL 8–9) é essencial para o planeamento realista da implementação. A tabela seguinte apresenta o gap analysis por dimensão, com estimativas de investimento e fase de resolução:

Dimensão	Protótipo Actual	Ferramenta Operacional	Fase
Ingestão de dados	Batch manual (CSV trimestral)	API REST automatizada ao SIMS/BM — latência < 24h pós-deadline; OAuth 2.0; gestão de versões de schema	Fase 2

Frequência de actualização	Manual — por ciclo de investigação	Automática — imediatamente após publicação dos dados de reporte trimestral do BM	Fase 2
Cibersegurança	HTTPS básico (dev environment)	ISO 27001 + TLS 1.3 + AES-256 + MFA + zero-trust + WAF + pen testing trimestral + SIRT	Fase 2
Auditabilidade	Log básico (stdout)	Audit trail imutável por previsão: timestamp, features SHAP, threshold, supervisor reviewer; DSAR-compliant	Fase 2
Calibração do modelo	Estática (treino único — 2024)	Recalibração semestral automática via MLOps pipeline; drift detection (PSI); AUC monitoring	Fases 3–4
Infra-estrutura	Local (laptop dev, 0 HA)	Cloud/on-premise HA (N+1 redundância); SLA 99,9%; backup geográfico; RTO < 4h; RPO < 1h	Fases 2–4
Explicabilidade operacional	SHAP charts offline (PNG/SVG)	SHAP integrado no dashboard supervisor — valores em tempo real por instituição; drill-down por feature	Fases 3–4
Gestão do modelo (governance)	Informal (projecto académico)	Model Governance Framework (MGF): version control, lineage, model cards, audit bienal, escalation policy	Fase 4
Formação de utilizadores	N/A (protótipo)	Programa de formação estruturado 40h (inicial) + 20h/ano (contínuo) + manual OPM + helpdesk	Fases 1–3
Extensão de cobertura	36 bancos (sector bancário)	IMEs + mercado de capitais + fundos de pensão (Fase 5) — requer dados adicionais e modelos específicos	Fase 5

6. Conclusão

O presente estudo desenvolveu e validou um Modelo de Inteligência Artificial para apoiar a regulação e a gestão inteligente de riscos no sistema financeiro moçambicano, respondendo de forma afirmativa à questão central de pesquisa e cumprindo os cinco (5) objectivos específicos da proposta aprovada.

O **Objectivo Específico 1** — criar um modelo de regulação dinâmica suportado por IA explicável — foi concretizado através da integração de quatro modelos de *Machine Learning* com a análise SHAP, produzindo previsões individualizadas e transparentes. O modelo primário (*Random Forest*) alcança um AUC-ROC de 0,950, demonstrando capacidade preditiva robusta com 1–2 trimestres de antecedência.

O **Objectivo Específico 2** — implementar um *Early Warning System* — foi materializado num EWS que monitoriza solvência, liquidez e riscos climáticos através de 102 *features*, incluindo as 11 *features* BEF originais que capturam especificidades do contexto moçambicano com ganhos preditivos mensuráveis (até +0,069 AUC).

O **Objectivo Específico 3** — prototipar uma plataforma *SupTech* — foi realizado com uma plataforma funcional em React/FastAPI com 6 módulos operacionais.

O **Objectivo Específico 4** — propor recomendações regulatórias baseadas em dados — foi cumprido com um conjunto articulado de recomendações para a supervisão microprudencial, a política macroprudencial e o quadro regulatório da IA, todas fundamentadas nos resultados quantitativos do estudo, complementadas pelas Perspectivas de Implementação detalhadas em 5.4, incluindo um roteiro faseado (TRL 4→9), estrutura de governação e análise de gap do protótipo à ferramenta operacional.

O **Objectivo Específico 5** — produzir evidências de posicionamento regional — é sustentado pela demonstração de que Moçambique dispõe das condições necessárias para adoptar soluções de *SupTech* alinhadas com as melhores práticas internacionais, com resultados comparáveis aos reportados pela EBA (2025) para o sistema bancário europeu.

A investigação futura deverá (i) integrar dados de balanço individual para estimar exposições absolutas; (ii) expandir o horizonte temporal, incluindo o período pós-saída do GAFI e o impacto do ciclone Gezani; (iii) explorar abordagens de *federated learning* para treino sem centralização de dados sensíveis; e (iv) pilotar a plataforma *SupTech* num ambiente de supervisão real do Banco de Moçambique, concretizando a Fase 5 (Validação e *Roadmap*)

da proposta aprovada. Este estudo demonstra que Moçambique pode posicionar-se como referência regional em supervisão financeira apoiada por inteligência artificial.

Referências Bibliográficas

- Agência de Informação de Moçambique — AIM (2025). Moçambique sai da Lista Cinzenta do GAFI. Maputo, 24 de Outubro de 2025.
- Alessi, L. e Detken, C. (2014). Identifying Excessive Credit Growth and Leverage. ECB Working Paper Series, N.º 1723. Banco Central Europeu.
- Arner, D., Barberis, J. e Buckley, R. (2017). FinTech, RegTech, and the Reconceptualization of Financial Regulation. *Northwestern Journal of International Law & Business*, 37(3), 371–413.
- Autoridade Bancária Europeia — EBA (2025). Machine Learning for IRB Models. Staff Paper Series, N.º 21, Janeiro de 2025.
- Ayobami, A. O., Israel, O., Yusuf, J. e Eniola, A. M. (2023). Predicting Credit Risk: Using Machine Learning Algorithms to Predict the Creditworthiness of Borrowers in Nigeria. *International Journal of Recent Engineering Science*, 10(2), 46–53.
- Bains, P., Kang, H. e Pienkowski, A. (2025). AI and Macrofinancial Risks. IMF Working Paper, WP/25/199. Fundo Monetário Internacional.
- Banco de Moçambique (2017). Aviso n.º 16/GBM/2017 — Indicadores Prudenciais das Instituições de Crédito e Sociedades Financeiras.
- Banco de Moçambique (2018). Aviso n.º 10/GBM/2018 — Metodologia de Identificação de Instituições de Crédito Domésticas de Importância Sistémica (D-SIBs).
- Banco de Moçambique (2023). Relatório de Estabilidade Financeira — Junho de 2023.
- Banco de Moçambique (2024). Relatório de Estabilidade Financeira — Junho de 2024.
- Banco de Moçambique (2025). Relatório de Estabilidade Financeira — Junho de 2025.
- Banco de Moçambique (2025b). Boletim de Estabilidade Financeira — Dezembro de 2025.
- Banco de Pagamentos Internacionais — BIS (2024). The Role of Artificial Intelligence in Financial Stability. Working Paper, N.º 1194.
- Banco de Pagamentos Internacionais — BIS/FSI (2025). Explainable AI for Banking Supervision: A Practical Guide. Occasional Paper, N.º 24.
- Bellotti, T. e Crook, J. (2021). Forecasting and Explaining Aggregate Consumer Credit Delinquency Behaviour. *International Journal of Forecasting*, 37(4), 1520–1533.
- Boeddu, G., Castellani, D. e Singh, A. (2025). SupTech Adoption in Emerging Markets: Evidence and Lessons. CEPR/VoxEU Policy Portal.
- BoE/FCA (2022). Machine Learning in UK Financial Services. Joint Report. Banco de Inglaterra / Financial Conduct Authority.
- BoE/FCA (2024). Artificial Intelligence in Financial Services — Update Report. Banco de Inglaterra / Financial Conduct Authority.
- Casabianca, E. J., Catalano, M., Ferriani, F., Ferroni, F. e Guilmi, C. (2022). A Machine Learning Approach to Rank the Determinants of Banking Crises over Time and across Countries. *Journal of International Money and Finance*, 129, 102739.

- Central Bank of Kenya — CBK (2025). Survey on Artificial Intelligence in the Banking Sector. Março de 2025. Nairobi.
- Crisanto, J. C., Ehrentraud, J. e Peria, M. S. M. (2024). Regulating AI in Finance: Putting It All Together. BIS/FSI Insights, N.º 63.
- Danielsson, J. e Uthemann, A. (2022). Artificial Intelligence and Systemic Risk. *Journal of Banking & Finance*, 140, 106290.
- Demirgüç-Kunt, A. e Detragiache, E. (1998). The Determinants of Banking Crises in Developing and Developed Countries. *IMF Staff Papers*, 45(1), 81–109.
- Dohotaru, A., Singh, R. e Vrejoiu, M. (2025). Supervisory Technology in Emerging and Developing Economies: Adoption Patterns and Challenges. World Bank Policy Research Working Paper.
- Financial Stability Board — FSB (2017). Artificial Intelligence and Machine Learning in Financial Services: Market Developments and Financial Stability Implications.
- Financial Stability Board — FSB (2024). Artificial Intelligence in Finance: Risks to Financial Stability.
- Financial Stability Board — FSB (2025). The Financial Stability Implications of Artificial Intelligence — Update Report.
- Fundo Monetário Internacional — FMI (2010). Republic of Mozambique: Financial System Stability Assessment. IMF Country Report N.º 10/12. Washington, D.C.
- Fundo Monetário Internacional — FMI (2024). Republic of Mozambique: 2024 Article IV Consultation — Staff Report. IMF Country Report N.º 24/219. Washington, D.C.
- Fundo Monetário Internacional — FMI (2026). Republic of Mozambique: 2025 Article IV Consultation — Staff Report. Washington, D.C.
- Instituto Nacional de Gestão e Redução do Risco de Desastres — INGD (2026). Balanço da Época Chuvosa 2025/2026. Dados actualizados a 26 de Fevereiro de 2026. Maputo.
- Instituto Nacional de Meteorologia — INAM (2026). Alerta: Tempestade Tropical Moderada Gezani. Comunicado de 8 de Fevereiro de 2026. Maputo.
- Kaminsky, G. e Reinhart, C. (1999). The Twin Crises: The Causes of Banking and Balance-of-Payments Problems. *American Economic Review*, 89(3), 473–500.
- Lundberg, S. M. e Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems (NeurIPS)*, 30, 4765–4774.
- Monetary Authority of Singapore — MAS (2018). Principles to Promote Fairness, Ethics, Accountability and Transparency (FEAT) in the Use of Artificial Intelligence and Data Analytics in Singapore's Financial Sector.
- Oxford Insights (2024). Government AI Readiness Index 2024.
- Prudential Authority / Financial Sector Conduct Authority — PA/FSCA (2025). Artificial Intelligence in the South African Financial Sector. Joint Report. Pretória, 24 de Novembro de 2025.

Regulamento (UE) 2024/1689 do Parlamento Europeu e do Conselho — AI Act (2024). Regulamento relativo à Inteligência Artificial.

Zetsche, D. A., Buckley, R. P., Arner, D. W. e Barberis, J. N. (2017). From FinTech to TechFin: The Regulatory Challenges of Data-Driven Finance. *New York University Journal of Law and Business*, 14(2), 393–446.