UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
INSTITUTO DE CIÊNCIAS ECONÔMICAS, ADMINISTRATIVAS E CONTÁBEIS – ICEAC
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO - PPGA
MESTRADO ACADÊMICO EM ADMINISTRAÇÃO

THEODORA LUCAS HOLZ

Inteligência Artificial e Desempenho Bancário: Evidências do Mercado Brasileiro (2013–2023)

RIO GRANDE
2025

THEODORA LUCAS HOLZ

Inteligência Artificial e Desempenho Bancário: Evidências do Mercado Brasileiro (2013–2023)

Dissertação apresentado ao Mestrado Acadêmico em Administração - PPGA da Universidade Federal do Rio Grande como requisito parcial à obtenção do título de Mestre em Administração.

Orientador: Prof. Dr. Ricardo Saraiva Frio

RIO GRANDE
2025

M762i Holz, Theodora Lucas

Inteligência Artificial e Desempenho Bancário: Evidências do Mercado Brasileiro (2013–2023) / Theodora Lucas Holz. – 2025.

76 f.

Dissertação (mestrado) – Universidade Federal do Rio Grande – FURG, Programa de Pós-Graduação em Administração, Rio Grande/RS, 2025.

Orientador: Prof. Dr. Ricardo Saraiva Frio

1.Bancos 2. Retorno Sobre Ativos (ROA) 3. Retorno Sobre o Patrimônio Líquido (ROE). 4. Crescimento real das receitas. Q de Tobin. I. Frio, Ricardo Saraiva II. Título.

CDU: 658.155:004.8

Catalogação na fonte: Bibliotecária Mariana Briese Porto – CRB 10/2665

SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
COORD CUR DE PG EM ADMINISTRAÇÃO

ATA DE REUNIÃO, DE 01 DE DEZEMBRO DE 2025

ATA DE DEFESA DE DISSERTAÇÃO

Aos 04 dias do mês de dezembro de dois mil e vinte e cinco, às 14h, realizou-se a defesa de dissertação do Programa de Pós-Graduação em Administração, nível mestrado, da Universidade Federal do Rio Grande - FURG, no Ambiente Virtual Conferência Web, cuja Banca foi constituída pelos professores: Ricardo Saraiva Frio, Carolina Magda Roma e Marta Olivia Rovedder de Oliveira, para arguir do(a) mestrando(a) **Theodora Lucas Holz**. Após a apresentação da dissertação intitulada *"Inteligência Artificial e o Desempenho Bancário no Brasil: Estudo Longitudinal sobre ROA, ROE, Q de Tobin e Vendas (2013–2023)"* e a arguição dos avaliadores seguida de defesa, a Banca reuniu-se e considerou o trabalho Aprovado, emitindo o parecer a seguir:

Considerar os comentários da banca e realizar uma revisão gramatical e da estrutura do texto.

Nada mais havendo a tratar, lavrou-se a presente Ata que após lida e aprovada será assinada pelos membros componentes da Banca.

gov.br Documento assinado digitalmente
RICARDO SARAIVA FRIO
Data: 04/12/2025 16:01:12-0300
Verifique em https://validar.iti.gov.br

Prof. Ricardo Saraiva Frio
Orientador

gov.br Documento assinado digitalmente
CAROLINA MAGDA DA SILVA ROMA
Data: 29/12/2025 13:07:32-0300
Verifique em https://validar.iti.gov.br

Prof.ª Carolina Magda Roma
(FURG)

gov.br Documento assinado digitalmente
MARTA OLIVIA ROVEDDER DE OLIVEIRA
Data: 28/12/2025 16:39:21-0300
Verifique em https://validar.iti.gov.br

Prof.ª Marta Olivia Rovedder de Oliveira
(UFSM)

AGRADECIMENTOS

Primeiramente agradeço aos pais, Jô e Silvo por terem caminhado ao sol para que eu tivesse a oportunidade de caminhar na sombra. Saibam que meu muito obrigada nunca será suficiente, mas é sincero. A Deus e ao meu anjo protetor que me guiam e me dão forças para seguir, nessa trajetória longa e um pouco árdua. Obrigada aos meus amigos, Celso que me ajudou na elaboração do código python que foi de extrema importância para o uso nesse trabalho. Ao meu avô Ehardt pelas visitas e ajuda. Obrigada ao Kevin por todas as segundas feiras, principalmente por me escutar e me dar conselhos que só um amigo pode dar. Nunca vou esquecer “dá o ultimo gás”. Obrigada a Ediandra que sempre me apoiou e me incentivou e escutou todas as minhas reclamações. Obrigada a Kimberly pela palavra amiga e de conforto em todos os momentos, sempre viu além do que os olhos podem ver. Obrigada ao meu colega amigo Eduardo pelos vinhos, risadas, conversas, desabafos e tudo que uma jornada acadêmica compõe. Obrigada a minha prima Luiza por ter feito eu acordar no meu momento de ilusão. Obrigada ao meu irmão Matheus por ser quem ele é e me mostrar todos os dias pelo que vale a pena e o que temos que deixar ir. Obrigada ao meu primo Gustavo por todas as conversas, risadas, curtidas e tudo. Obrigada a Tina por me puxar e não deixar eu esquecer de coisas importantes. Obrigada a minha psicóloga Julie pelo excelente trabalho, pela ajuda e por me fazer eu me reencontrar todas as vezes que são necessárias. Obrigada a minha tia Claudia por ter me trazido de volta pra casa, essa atitude tornou tudo isso possível. Obrigada a minha prima Nina por ter me ensinado a ter controle emocional, isso me ajuda muito. E um muito obrigada que nenhuma palavra vai conseguir expressar, a minha professora Carol, que além de ter me ajudado com o código R, não largou a minha mão em nenhum momento, uma pessoa que me inspira e me fortalece, além de professora, uma mulher inspiradora e amiga. Obrigada ao meu orientador Ricardo por ter aceitado essa ideia e ter abraçado ela comigo e principalmente por ter me ensinado na prática o que é ser pesquisadora. Obrigada ao professor Lunardi por ter me ensinado muito em todos os momentos desde a graduação. Obrigada ao Enrico Dallas do BC por ter auxiliado na coleta de dados, no qual foi de extrema importância. Obrigada ao Banco central por disponibilizar todas as informações de divulgação pública. Obrigada a FURG pelo ensino e oportunidade.

RESUMO

Esta dissertação investiga o impacto da inteligência artificial (IA) sobre o desempenho financeiro e de mercado das instituições bancárias brasileiras listadas na B3 no período de 2013 a 2023. A pesquisa parte do pressuposto de que a IA representa um dos pilares do foco tecnológica no setor financeiro, embora seus efeitos econômicos ainda sejam incertos em economias emergentes. O estudo tem como objetivo central avaliar se o foco em IA influencia o desempenho empresarial dos bancos, analisando quatro dimensões: eficiência operacional (ROA), rentabilidade (ROE), valor de mercado (Q de Tobin) e crescimento real das receitas (VENDAS). A variável principal foco em IA foi mensurada a partir da frequência de menções em relatórios anuais, conforme metodologia de Mishra, Ewing e Cooper (2022). Adotou-se uma abordagem quantitativa, descritiva e longitudinal, com modelos de dados em painel e efeitos fixos, controlando variáveis estruturais (tamanho, spread, liquidez e eficiência operacional) e macroeconômicas (PIB e Selic). Os resultados indicaram que o foco de IA não exerceu efeito significativo sobre o ROA, ROE e VENDAS, enquanto apresentou impacto negativo marginal sobre o Q de Tobin, sugerindo percepção cautelosa do mercado quanto ao retorno dos investimentos tecnológicos. As conclusões apontam que os efeitos da IA são indiretos e de maturação lenta, dependentes da integração com recursos organizacionais complementares. As principais limitações referem-se à mensuração indireta da variável de IA e à heterogeneidade institucional do setor bancário. Recomenda-se que futuras pesquisas explorem modelos dinâmicos e técnicas de machine learning para capturar efeitos de longo prazo e não lineares do foco tecnológico.

PALAVRAS-CHAVE: BANCOS. RETORNO SOBRE ATIVOS (ROA). RETORNO SOBRE O PATRIMÔNIO LÍQUIDO (ROE). CRESCIMENTO REAL DAS RECEITAS. Q DE TOBIN.

ABSTRACT

This dissertation investigates the impact of artificial intelligence (AI) on the financial and market performance of Brazilian banking institutions listed on B3 over the period from 2013 to 2023. The study is grounded on the assumption that AI represents one of the core pillars of the technological focus in the financial sector, although its economic effects remain uncertain in emerging economies. The main objective is to assess whether a focus on AI influences banks' business performance, analyzing four dimensions: operational efficiency (ROA), profitability (ROE), market value (Tobin's Q), and real revenue growth (SALES). The main explanatory variable, focus on AI, was measured based on the frequency of AI-related mentions in annual reports, following the methodology proposed by Mishra, Ewing, and Cooper (2022). A quantitative, descriptive, and longitudinal approach was adopted, employing panel data models with fixed effects, while controlling for structural variables (size, spread, liquidity, and operational efficiency) and macroeconomic variables (GDP and the Selic interest rate). The results indicate that the focus on AI did not exert a significant effect on ROA, ROE, or SALES, while presenting a marginally negative impact on Tobin's Q, suggesting a cautious market perception regarding the returns on technological investments. The findings suggest that the effects of AI are indirect and slow to mature, depending on their integration with complementary organizational resources. The main limitations relate to the indirect measurement of the AI variable and the institutional heterogeneity of the banking sector. Future research is encouraged to explore dynamic models and machine learning techniques to capture long-term and non-linear effects of technological focus.

KEYWORDS: BANKS. RETURN ON ASSETS (ROA). RETURN ON EQUITY (ROE). REAL REVENUE GROWTH. TOBIN'S Q.

SUMÁRIO

1 INTRODUÇÃO 7

1.1 DELIMITAÇÃO DO TEMA E PROBLEMA DE PESQUISA 10
1.2 OBJETIVOS 10
1.2.1 Objetivo Geral 10
1.2.2 Objetivos Específicos 11
1.3 JUSTIFICATIVA 11
1.4 ESTRUTURA DA DISSERTAÇÃO 12

2 REVISÃO DE LITERATURA 13

2.1 INTELIGÊNCIA ARTIFICIAL NAS ORGANIZAÇÕES 13
2.1.1 Exclusão de Empresas Financeiras em Pesquisas Acadêmicas 13
2.2 INTELIGÊNCIA ARTIFICIAL E EFICIÊNCIA OPERACIONAL (ROA) 14
2.3 INTELIGÊNCIA ARTIFICIAL E RENTABILIDADE FINANCEIRA (ROE) 15
2.4 INTELIGÊNCIA ARTIFICIAL E VALORIZAÇÃO DE MERCADO (Q DE TOBIN) 16
2.5 INTELIGÊNCIA ARTIFICIAL E CRESCIMENTO DE RECEITAS (VENDAS) 17

3. MÉTODO DE PESQUISA 18

3.1 CARACTERIZAÇÃO DA PESQUISA 18
3.2 BASE DE DADOS 19
3.3. AMOSTRA E CRITÉRIOS DE EXCLUSÃO 20
3.3.2 Exclusão de Bancos da Análise 21
3.4 VARIÁVEIS UTILIZADAS 21
3.4.1 Variáveis Dependentes 22
3.4.2 Variável Independente 24
3.4.3 Variáveis de Controle 24
3.5 ANÁLISE DE DADOS 27
3.5.1 Modelo Empírico 29

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS 33

4.1 ANÁLISE DESCRITIVA 33

4.2 REGRESSÕES 35
4.2.1 ROA 35
4.2.2 ROE 36
4.2.3 Q Tobin 39
4.2.4 Vendas 41
4.2.5 Modelos com Defasagem 44
4.2.6 ROE Defasado 46
4.2.7 Tobin Defasado 49
4.2.8 Vendas com Defasagem 51
4.3 DISCUSSÃO DE RESULTADOS 53
4.3.1 Rentabilidade Sobre Ativos (ROA) 53
4.3.2 Rentabilidade Sobre o Patrimônio Líquido 54
4.3.3 Valor de Mercado (Q de Tobin) 56
4.3.4 Efeitos Defasados e Maturidade Tecnológica 57
4.3.5 Crescimento de Receitas (VENDAS) 58
4.3.6 Fatores Estruturais e Macroeconômicos 59

5 CONCLUSÃO 61

REFERÊNCIAS 64

APÊNDICE I 72

APÊNDICE II 74

APÊNDICE III 75

APÊNDICE IV 76

1 INTRODUÇÃO

A definição de inteligência artificial (IA) é ampla e abrange capacidades como aprender, raciocinar e compreender (Lichtenthaler, 2019). Para Huang e Rust (2021), trata-se de sistemas programados para simular e complementar habilidades humanas, por exemplo, ao desempenhar tarefas mecânicas ou cognitivas. Mishra, Ewing e Cooper (2022) enfatizam que a IA envolve a reprodução de comportamentos inteligentes por máquinas, cobrindo subáreas como aprendizado de máquina, redes neurais e aprendizado profundo. Em conjunto, esses estudos indicam que a IA está posicionada para impactar dimensões centrais do marketing e da gestão, sobretudo quando sustentada por cultura orientada a dados e capacidades organizacionais complementares (Fosso Wamba *et al*., 2024).

Além de imitar funções cognitivas e solucionar problemas (Huang e Rust, 2021), a IA distingue-se por aprender de forma autônoma a partir de dados, atualizando previsões e decisões sem reprogramação exaustiva (Huang e Rust, 2018; 2021). Essa característica amplia seu potencial organizacional: a tecnologia não apenas processa informações para apoio humano, mas também gera novos padrões e *insights* continuamente.

Nesse cenário, estudos em marketing e gestão associam o foco de IA a ganhos de eficiência, inovação e lucratividade (Mishra; Ewing; Cooper, 2022; Chen; Esperança; Wang, 2022; Fosso Wamba et al., 2024). Esses ganhos se refletem, sobretudo, por meio da melhoria da eficiência operacional e da qualidade das decisões gerenciais, o que tende a impactar positivamente métricas clássicas de desempenho contábil, como o Retorno sobre Ativos (ROA) e o Retorno sobre o Patrimônio Líquido (ROE). Do ponto de vista do mercado, a incorporação de IA pode atuar como um sinal da capacidade inovadora e do potencial de crescimento das firmas, sendo captada por indicadores como o Q de Tobin, que reflete a avaliação dos investidores. De modo complementar, o crescimento real das receitas de intermediação (VENDAS) expressa a dimensão de expansão do negócio, ao evidenciar a capacidade de escalabilidade, personalização e geração de valor econômico associada ao uso de IA conectando tecnologia, marketing e desempenho empresarial.

Estudos recentes têm avançado na mensuração do foco estratégico em inteligência artificial a partir de informações divulgadas pelas próprias organizações,

especialmente por meio da análise textual de relatórios anuais e documentos corporativos. Trabalhos como Mishra, Ewing e Cooper (2022) demonstram que a ênfase discursiva em IA pode atuar como um sinal ao mercado, influenciando expectativas de investidores e analistas, ainda que não reflita necessariamente o nível efetivo de implementação tecnológica.

No entanto, a evidência empírica existente concentra-se majoritariamente em contextos institucionais distintos do brasileiro, com predominância de estudos conduzidos em economias desenvolvidas, e não explora de forma sistemática as especificidades do setor bancário em economias emergentes, caracterizadas por elevada concentração, forte regulação e spreads historicamente elevados (Brynjolfsson; McAfee, 2014; Mishra, 2022). Além disso, parte da literatura privilegia análises contemporâneas ou agregadas, oferecendo evidências limitadas sobre a dinâmica temporal dos efeitos da IA e sobre a possível dissociação entre desempenho contábil e valorização de mercado no curto e médio prazo (Lee; Shin, 2018; Begenau; Farboodi; Veldkamp, 2018).

Nesse sentido, o presente estudo se diferencia ao investigar o impacto do foco em inteligência artificial sobre múltiplas dimensões de desempenho bancário rentabilidade, crescimento das receitas e valor de mercado no contexto brasileiro, incorporando modelos com defasagem temporal e controles estruturais e macroeconômicos. Ao fazê-lo, o trabalho contribui para a literatura ao examinar como sinais associados à IA são interpretados em um ambiente institucional específico, no qual os benefícios tecnológicos podem se manifestar de forma indireta, gradual e assimétrica entre métricas contábeis e de mercado.

A IA também é discutida como vetor de inovação e transformação organizacional (Chen; Lu; Wang, 2022; Lichtenthaler, 2019), com evidências de ganhos de eficiência e redução de custos (Bag *et al.*, 2021; Chen; Lu; Wang, 2022). Ainda assim, persiste a questão de custo-benefício, nem sempre é claro se os investimentos em IA superam seus custos, pois resultados dependem do nível de eficiência atual, da maturidade tecnológica e da integração estratégica (Mishra; Ewing; Cooper, 2022). Esses autores mostram que empresas listadas nos EUA vivem um processo de transformação iminente em IA, associando foco em IA a melhorias em lucratividade líquida, eficiência operacional e retorno do investimento em marketing.

A discussão custo-benefício relaciona-se também à comunicação das estratégias de IA ao mercado. À luz da teoria da sinalização, empresas podem divulgar

incrementalmente iniciativas tecnológicas para reduzir assimetria informacional e sinalizar competência e comprometimento com a inovação (Beyer *et al*., 2010), influenciando assim a percepção dos investidores e, por consequência, o Q de Tobin (Janiszewski *et al*., 2017). Como o efeito da IA pode amadurecer no tempo, a sinalização e a transparência tornam-se relevantes para alinhar expectativas e mitigar incertezas (Mishra; Ewing; Cooper, 2022). Em paralelo, estudos recentes no setor bancário documentam avanços em eficiência operacional, avaliação de risco, gestão de clientes e desempenho global associados ao focode IA (Doumpos *et al*., 2023).

No contexto financeiro, a IA tem possibilitado personalização de serviços, monitoramento de transações para prevenção de fraudes e melhorias em gestão de ativos e crédito, respondendo com rapidez e precisão às demandas dos clientes (Doumpos *et al*., 2023). A análise de dados em tempo real potencializa a conversão de grandes volumes informacionais em *insights* estratégicos, favorecendo adaptação às condições de mercado e fortalecendo a competitividade (Fosso Wamba *et al*., 2024; Federação Brasileira de Bancos – FEBRABAN, 2022). A automação de processos reduz custos e eleva a conformidade regulatória, inclusive na geração de relatórios (Ceccon, 2022), enquanto as interações mediadas por IA melhoram a experiência do cliente e liberam pessoas para atividades de maior valor (Blas *et al*., 2023).

Apesar dos avanços, a literatura mostra que a capacidade de IA não implica, por si só, impacto direto e universal no desempenho; seus efeitos são frequentemente mediados por criatividade, governança da IA e decisões orientadas por dados (Chen; Esperança; Wang, 2022). Aqui, o elo com o desempenho bancário torna-se analiticamente relevante, ao mesmo tempo em que a IA tende a elevar ROA (eficiência na utilização dos ativos), espera-se que repercuta em ROE (rentabilidade do capital próprio), Q de Tobin (valorização de mercado) e VENDAS (crescimento real das receitas), com defasagens temporais e condicionantes estruturais.

Dessa forma, esta dissertação parte da premissa, detalhada na revisão de literatura, de que os efeitos da IA sobre ROA, ROE, Q de Tobin e VENDAS emergem de mecanismos combinados de eficiência, inovação e sinalização ao mercado, modulados por variáveis estruturais e macroeconômicas.

1.1 Delimitação do tema e problema de pesquisa

Embora a literatura internacional venha avançando na análise da inteligência artificial no setor financeiro, os estudos existentes concentram-se majoritariamente em métricas de eficiência operacional, inovação tecnológica ou desempenho agregado, com menor atenção aos efeitos diretos da IA sobre indicadores contábeis tradicionais e métricas de valor de mercado, especialmente em economias emergentes como o Brasil (Brynjolfsson; McAfee, 2014; Mishra, 2022; Lee; Shin, 2018).

Delimita-se, assim, a análise a bancos brasileiros no período de 2013 a 2023, avaliando o impacto do foco em IA sobre o desempenho empresarial com base em indicadores de rentabilidade e valor de mercado.

Assim, formula-se o problema de pesquisa:

Como a implementação de inteligência artificial afeta o desempenho financeiro das instituições bancárias brasileiras?

A questão orienta uma abordagem quantitativa voltada a mensurar os efeitos da IA sobre múltiplas dimensões de desempenho, contribuindo para preencher lacunas teóricas e oferecer subsídios gerenciais à tomada de decisão no sistema bancário.

1.2 Objetivos

Buscando responder à questão acima, os objetivos desta pesquisa são:

1.2.1 Objetivo Geral

Analisar o impacto do foco em IA sobre o desempenho empresarial de bancos brasileiros listados na B3 do período de 2013-2023.

1.2.2 Objetivos Específicos

Caracterizar o foco em inteligência artificial dos bancos brasileiros listados, a partir das informações divulgadas em relatórios corporativos.

- Avaliar a relação entre o foco em IA e o desempenho financeiro, considerando ROA e ROE como medidas de rentabilidade;
- Avaliar o efeito do foco em IA sobre o valor de mercado, mensurado pelo Q de Tobin, que expressa a percepção do mercado quanto aos investimentos em inovação tecnológica;
- Analisar o efeito do foco em IA sobre o crescimento das receitas de intermediação financeira (VENDAS);

1.3 Justificativa

As capacidades de IA tendem a elevar desempenho e inovação do modelo de negócio, ao transformar dados em *insights* acionáveis e ganhos de eficiência (Fosso Wamba *et al*., 2024). Focar o segmento bancário é relevante pela centralidade do setor na economia e pelos desafios competitivos que enfrenta (Kaur *et al.,* 2020). Em mercados voláteis com mudanças rápidas em preferências, produtos, serviços e estratégias, bancos precisam adotar IA para manter competitividade e relevância (Tajeddini *et al*., 2006; YuSheng; Ibrahim, 2020; Lichtenthaler, 2020).

A literatura indica que inovação e investimentos tecnológicos melhoram produtividade e crescimento (Beck *et al*., 2012; YuSheng; Ibrahim, 2020), mas também alerta para inércias organizacionais e dúvidas sobre custos e expertise (Mishra; Ewing; Cooper, 2022). Nesse contexto, o presente estudo se justifica ao posicionar-se na interseção entre marketing, desempenho e finanças corporativas, investigando empiricamente como o foco em IA se relaciona com indicadores contábeis e de mercado no setor bancário brasileiro.

A escolha do período de análise (2013–2023) contempla a intensificação da transformação digital no setor financeiro e a maior disponibilidade de dados comparáveis, permitindo uma avaliação longitudinal consistente. Além disso, ao

analisar ROA, ROE, Q de Tobin e VENDAS, o estudo contribui para reduzir a lacuna de evidências empíricas em economias emergentes, oferecendo subsídios relevantes para gestores, reguladores e formuladores de políticas de inovação, bem como dialogando com a teoria da sinalização sobre transparência informacional e expectativas de mercado (Janiszewski *et al*., 2017).

1.4 Estrutura da Dissertação

A pesquisa está organizada da seguinte forma: no Capítulo 1, apresenta-se a introdução, a delimitação do tema e os objetivos; no Capítulo 2, desenvolve-se a revisão de literatura que embasa o estudo, com as hipóteses apresentadas ao longo do texto; no Capítulo 3, descrevem-se os procedimentos metodológicos; no Capítulo 4, são apresentados e discutidos os resultados; e, por fim, no Capítulo 5, expõem-se conclusões, implicações e limitações, além de sugestões para pesquisas futuras.

2 REVISÃO DE LITERATURA

Este capítulo apresenta o embasamento teórico que sustenta o estudo, abordando a evolução da inteligência artificial nas organizações e sua relação com o desempenho empresarial, com foco no setor bancário brasileiro. A revisão é organizada de forma progressiva: parte do conceito geral de IA e de seu papel estratégico na gestão, avança para os indicadores de desempenho financeiro e de mercado e, por fim, discute as particularidades do contexto bancário e das métricas de crescimento de receitas.

2.1 Inteligência Artificial nas Organizações

A inteligência artificial consolidou-se como um dos principais vetores de transformação organizacional nas últimas décadas. Inicialmente associada a tarefas técnicas e de automação, passou a ocupar posição estratégica nas empresas, influenciando processos de tomada de decisão, inovação e criação de valor (Russell e Norvig, 2016) Wedel e Kannan (2016) e Fosso Wamba *et al.* (2024) sustentam que a IA deve ser compreendida não apenas como ferramenta operacional, mas como capacidade organizacional dinâmica, capaz de integrar dados, aprendizado e decisões para gerar vantagem competitiva. Essa capacidade depende da combinação entre infraestrutura tecnológica, competências humanas e orientação estratégica, de modo que seu foco afeta diretamente a forma como as empresas respondem a mudanças de mercado e fortalecem seu posicionamento competitivo.

Dessa perspectiva, estudar a IA em contextos empresariais significa compreender como a tecnologia molda a eficiência, a rentabilidade e o valor de mercado, dimensões clássicas do desempenho organizacional.

2.1.1 Exclusão de Empresas Financeiras em Pesquisas Acadêmicas

A literatura indica que a exclusão de instituições financeiras é uma prática recorrente em estudos que analisam o impacto do capital intelectual e outros ativos intangíveis no desempenho organizacional. Carvalho et al. (2016), ao investigarem empresas brasileiras de capital aberto não financeiras entre 2011 e 2015, adotam essa delimitação sem explicitar suas razões, alinhando-se a estudos anteriores como

o de Janosevic, Dzenopoljac e Bontis (2013), que analisaram apenas o “setor real” da economia sérvia. Embora nesses trabalhos a exclusão de bancos e seguradoras seja um elemento central da estratégia metodológica, as justificativas para tal escolha nem sempre são claramente desenvolvidas, sugerindo que o critério esteja associado, de forma implícita, a especificidades regulatórias, contábeis e estruturais dessas organizações.

De modo mais amplo, revisões da literatura em Contabilidade e Finanças mostram que a exclusão do setor financeiro ocorre com frequência, ainda que muitas vezes sem fundamentação detalhada. Paulo e Mota (2019) apontam que a maioria dos estudos apenas comunica essa decisão metodológica, enquanto aqueles que a justificam destacam as particularidades da estrutura econômico-financeira dessas empresas, caracterizadas por elevado grau de alavancagem e padrões patrimoniais distintos. Evidências empíricas recentes corroboram esse entendimento ao identificar diferenças estatisticamente significativas entre empresas financeiras e não financeiras, especialmente em indicadores de endividamento (Campos; Boina, 2023). Nesse contexto, esta pesquisa adota estratégia oposta à literatura dominante ao focar exclusivamente instituições do setor bancário, reconhecendo suas especificidades regulatórias e estruturais e buscando assegurar maior comparabilidade interna e consistência analítica.

2.2 Inteligência Artificial e Eficiência Operacional (ROA)

A relação entre o foco de IA e o desempenho empresarial tem sido amplamente investigada, embora ainda não haja consenso quanto à magnitude e à direção de seus efeitos. Diversos estudos indicam que a implementação de IA está associada a ganhos de eficiência operacional, redução de custos e maior capacidade de inovação em processos organizacionais. Esses fatores contribuem para a otimização do uso dos recursos produtivos, refletindo-se em melhorias no desempenho operacional e financeiro das empresas, particularmente em métricas de rentabilidade como o Retorno sobre Ativos (ROA) (Mishra; Ewing; Cooper, 2022; Huang; Rust, 2018).

Outros autores, como Chen *et al*. (2022), destacam que tais efeitos não são automáticos, dependendo do grau de maturidade tecnológica, da cultura de inovação e da integração da IA à estratégia corporativa. Essas evidências indicam que o impacto da IA tende a manifestar-se inicialmente na eficiência operacional, ao otimizar a utilização dos ativos e elevar a produtividade. O Retorno sobre Ativos é, portanto, a métrica mais diretamente associada a essa dimensão, pois mensura a capacidade da empresa de gerar lucro a partir dos recursos disponíveis (Assaf Neto, 2003). Nesse contexto, ao reduzir ineficiências e aprimorar o aproveitamento dos ativos, o foco estratégico em IA pode fortalecer a eficiência operacional, o que tende a se refletir em melhores níveis de rentabilidade operacional captados pelo ROA. Assim, espera-se que instituições bancárias com maior foco em IA apresentem desempenho operacional superior, refletido em níveis mais elevados de retorno sobre ativos.

H1: O foco em inteligência artificial impacta positivamente o retorno sobre ativos (ROA).

2.3 Inteligência Artificial e Rentabilidade Financeira (ROE)

O desempenho empresarial não se resume à eficiência interna, mas envolve também a rentabilidade sobre o capital próprio. A literatura sobre desempenho financeiro bancário destaca que os resultados das instituições decorrem da combinação entre fatores tecnológicos e variáveis estruturais, como tamanho, eficiência operacional, spreads e liquidez. Estudos clássicos apontam que bancos de maior porte tendem a usufruir de economias de escala e maior capacidade de absorver inovações tecnológicas (Bolt *et al*., 2012; Lee e Hsieh, 2013).

Além do porte, a qualidade da gestão e o controle de custos influenciam diretamente a rentabilidade. Spreads elevados, embora possam elevar receitas no curto prazo, indicam ineficiência competitiva e podem reduzir o desempenho de longo prazo (Kohlscheen; Murcia Pabón; Contreras, 2018). Já o excesso de liquidez, por representar recursos ociosos, tende a afetar negativamente o retorno sobre o patrimônio líquido.

Nessa perspectiva, o Retorno sobre o Patrimônio Líquido (ROE) expressa a capacidade da instituição de gerar lucro a partir dos recursos investidos pelos

acionistas (Gitman, 2010). Ao aprimorar processos decisórios, automatizar análises e reduzir ineficiências operacionais, o foco estratégico de IA pode contribuir para uma alocação mais eficiente do capital próprio, refletindo-se em maior rentabilidade dos bancos e, consequentemente, em um aumento do retorno aos acionistas. Nesse contexto, ao apoiar decisões mais eficientes e reduzir perdas associadas a ineficiências operacionais, o foco estratégico em IA tende a favorecer a rentabilidade do capital próprio. Assim, espera-se que instituições bancárias com maior foco em IA apresentem melhor desempenho financeiro, refletido em níveis mais elevados de retorno sobre o patrimônio líquido.

H2: O foco estratégico em inteligência artificial está positivamente associado ao retorno sobre o patrimônio líquido (ROE)

2.4 Inteligência Artificial e Valorização de Mercado (Q de Tobin)

Além da eficiência e da rentabilidade, o foco de IA influencia a percepção do mercado sobre o valor das empresas. Sob a ótica da teoria da sinalização, investimentos em IA e transformação digital são interpretados pelos investidores como sinais de competência tecnológica e visão de longo prazo (Janiszewski *et al*., 2017). Essa sinalização positiva pode elevar a confiança do mercado e, consequentemente, o valor das ações.

No entanto, Mogaji *et al*. (2022) destacam que os impactos sobre o valor de mercado podem ocorrer de forma defasada. A introdução de IA é, inicialmente, percebida como um risco, devido aos custos de implementação e às preocupações com privacidade e confiabilidade algorítmica. À medida que os benefícios operacionais se consolidam, a percepção do mercado tende a se tornar positiva. O Q de Tobin, razão entre o valor de mercado e o custo de reposição dos ativos, captura precisamente essa expectativa de inovação e crescimento (Tobin, 1969; Bouhia *et al*., 2022; Northey *et al*., 2022).

Portanto, é plausível supor que bancos com foco estratégico em IA e inovação sejam percebidos como mais valiosos pelo mercado. À medida que os ganhos operacionais associados ao foco de IA se tornam mais visíveis e a incerteza inicial é reduzida, a sinalização de capacidade inovadora tende a ser incorporada às avaliações dos investidores. Assim, espera-se que instituições bancárias com maior

foco em IA apresentem maior valorização de mercado, refletida em níveis mais elevados de Q de Tobin.

H3: O foco em inteligência artificial impacta positivamente o valor de mercado das instituições bancárias, mensurado pelo Q de Tobin.

2.5 Inteligência Artificial e Crescimento de Receitas (Vendas)

O crescimento real das receitas constitui uma dimensão fundamental do desempenho empresarial, especialmente em setores intensivos em dados como o bancário. De acordo com Deshmukh e Boyd (2024), a IA representa um recurso estratégico para previsão de receitas e comportamento de mercado, pois antecipa tendências, otimiza alocação de recursos e apoia decisões de precificação e segmentação.

A IA preditiva integra modelos de aprendizado de máquina e análise de comportamento de clientes, permitindo identificar perfis de maior potencial de conversão, fidelização e rentabilidade (Gerling; Lessmann, 2024). Ao prever o ciclo de vida do cliente, a tecnologia fortalece o marketing relacional bancário, reduz evasão e amplia o valor de vida do cliente (Customer Lifetime Value), estimulando operações de *cross-selling* e *up-selling* de produtos financeiros (Basten; Juelsrud, 2023).

Esses mecanismos ampliam diretamente as receitas de intermediação financeira, núcleo das atividades bancárias, e contribuem para o planejamento estratégico de crescimento. Pesquisas como a de Song (2022) demonstram que modelos neurais e árvores de decisão superam técnicas estatísticas tradicionais na previsão de vendas, por capturarem relações não lineares entre variáveis econômicas e comportamentais. Ao ampliar a acurácia das previsões e reduzir erros decisórios em precificação, segmentação e oferta de produtos, essas capacidades analíticas tendem a apoiar estratégias mais eficazes de expansão de receitas. Assim, espera-se que o foco em IA impacte positivamente o crescimento das receitas das instituições.

H4: O foco em inteligência artificial impacta positivamente o crescimento real das receitas das instituições bancárias.

3. MÉTODO DE PESQUISA

Este capítulo apresenta a trajetória metodológica utilizada na pesquisa, descrevendo os procedimentos e técnicas que foram aplicados para atender aos objetivos propostos e responder à questão do estudo. O capítulo se divide em três seções: a primeira apresenta a caracterização da pesquisa; a segunda base de dados; variáveis utilizadas, análise de dados, amostra e critérios de exclusão e na última, serão apresentadas as técnicas de coleta e análise de dados utilizadas.

3.1 Caracterização da Pesquisa

A presente pesquisa adota uma abordagem quantitativa, com desenho longitudinal em painel, orientada à análise e à explicação de relações empíricas entre o foco em inteligência artificial e os indicadores de desempenho bancário. Trata-se de um estudo *ex post facto*, baseado em fatos já ocorridos no passado, sobre os quais o pesquisador não exerce controle nem interfere nos resultados observados (Maffili; Bressan; Souza, 2007).

A opção por métodos quantitativos decorre da necessidade de mensuração objetiva de fenômenos complexos, permitindo a estimação de parâmetros estatísticos capazes de indicar a direção, a magnitude e a significância das associações entre as variáveis analisadas (Wooldridge, 2010; Greene, 2018; Kennedy, 1998).

O uso de dados em painel, com observações de múltiplas instituições financeiras ao longo de diversos períodos, confere maior robustez à análise empírica, uma vez que possibilita o controle simultâneo da heterogeneidade não observada entre as unidades analisadas e das variações temporais específicas de cada período (Baltagi, 2008; Wooldridge, 2010). Esse arranjo metodológico é amplamente consolidado na literatura aplicada em econometria, finanças e economia bancária, sendo reconhecido como uma estratégia eficaz para aprimorar a consistência e a eficiência das estimativas em estudos observacionais (Greene, 2018; Hausman, 1978).

A especificação empírica contempla um conjunto de variáveis de controle de natureza institucional, como capitalização, spreads, liquidez e despesas financeiras intermediárias, bem como controles macroeconômicos, incluindo Produto Interno Bruto, taxa Selic e inflação. Essa abordagem reconhece que o desempenho bancário

resulta da interação entre fatores internos à instituição e condições macroeconômicas do ambiente em que opera, sendo consistente com evidências empíricas que demonstram a sensibilidade de métricas como ROA, ROE e Q de Tobin a esses determinantes (Bolt *et al*., 2012; Lee e Hsieh, 2013; Kohlscheen, Murcia Pabón e Contreras, 2018).

Nesse escopo, considerando que os efeitos do foco da inteligência artificial tendem a se manifestar de forma gradual, esta pesquisa utiliza modelos com defasagem de um ano nas variáveis explicativas. Essa abordagem permite capturar efeitos temporais e dinâmicos, reduzir potenciais problemas de simultaneidade e respeitar a precedência temporal entre as variáveis analisadas, contribuindo para maior consistência das estimativas em estudos observacionais (Arellano; Bond, 1991; Wooldridge, 2010).

Conforme observado por He e Rao (2024), estudos em marketing que utilizam dados observacionais com defasagens temporais avançam na interpretação das relações entre práticas organizacionais e desempenho, sem recorrer a experimentos. De maneira semelhante, Liu *et al*. (2025) introduzem variáveis independentes defasadas para examinar a evolução do desempenho ao longo do tempo, permitindo identificar efeitos que emergem de forma gradual.

3.2 Base de Dados

No que tange à amostra, esta foi composta por instituições bancárias de capital aberto, com informações extraídas das bases da B3 e do sistema IF.Data, do Banco Central do Brasil, abrangendo o período de 2013 a 2023.

A coleta de dados envolveu a utilização de relatórios anuais de caráter público, notadamente: (i) os Formulários de Referência, que apresentam informações detalhadas sobre estrutura de governança, estratégia corporativa e perfil de risco das instituições; e (ii) as Demonstrações Financeiras Padronizadas (DFPs), que evidenciam a posição patrimonial, o desempenho econômico-financeiro e as variáveis explicativas das instituições analisadas.

Adicionalmente, foram extraídas do sistema IF.Data variáveis financeiras consolidadas reportadas ao Banco Central do Brasil, incluindo ativos totais, operações de crédito, capitalização, spreads e liquidez. Essa combinação de fontes permitiu a

construção de uma base de dados abrangente e comparável, restrita a bancos de capital aberto, com informações consistentes ao longo dos dez anos analisados.

Os relatórios obtidos junto à B3 reúnem informações financeiras e operacionais das instituições e configuraram-se como uma fonte válida de dados secundários para a mensuração das variáveis utilizadas neste estudo. Esses dados mensuram a influência do foco em IA nas operações e resultados financeiros das empresas. A Quadro 1 demonstra os bancos que foram trabalhados no presente estudo.

Quadro 1: Resumo dos bancos

Instituição	RIC
ABC-BRASIL	ABCB3
BANCO DA AMAZÔNIA S.A.	BAZA3
BANCO DO ESTADO DE SERGIPE S.A.	BGIP3
BANCO DO NORDESTE DO BRASIL S.A.	BNBR3
BANESTES	BEES3
BANRISUL	BRSR3
BANCO DO BRASIL	BBAS3
BRADESCO	BBDC3
BRB	BRBI3
BTG PACTUAL	BPAC3
ITAÚ	ITUB3
MERCANTIL DO BRASIL	BMEB3
PAN	BPAN3
PINE	PINE3
SANTANDER	SANB3

Fonte: dados da pesquisa, (2025).

3.3. Amostra e Critérios de Exclusão

A amostra do estudo é composta por instituições bancárias listadas na B3 no período de 2013 a 2023, selecionadas com base em critérios de disponibilidade, consistência e comparabilidade dos dados financeiros e de mercado. A opção por bancos de capital aberto decorre da necessidade de acesso a informações padronizadas e auditadas, bem como da formação regular de preços de mercado, requisito essencial para o cálculo de indicadores contábeis e de valor, como ROA, ROE e Q de Tobin.

Foram excluídas da amostra instituições que não apresentaram séries históricas completas para as variáveis analisadas, bem como aquelas que não possuíam liquidez mínima em mercado secundário ao longo do período

considerado. Adicionalmente, bancos com modelo de negócio predominantemente digital foram excluídos da análise, uma vez que suas características operacionais, estrutura de custos e dinâmica de crescimento diferem substancialmente das instituições bancárias tradicionais, podendo comprometer a comparabilidade dos resultados.

Esses critérios visam assegurar a homogeneidade da amostra e a robustez das estimativas econométricas, permitindo que os efeitos observados sejam atribuídos às variáveis de interesse e não a diferenças estruturais extremas entre as instituições analisadas.

3.3.2 Exclusão de Bancos da Análise

Além dos critérios gerais de seleção, algumas instituições foram excluídas da amostra em função de particularidades que inviabilizam sua inclusão nos modelos econométricos. Entre essas situações destacam-se casos de descontinuidade operacional, ausência de negociação regular de ações no mercado, mudanças relevantes de estrutura societária que impedem a construção de séries temporais consistentes, ou insuficiência de informações públicas necessárias para o cálculo das variáveis do estudo.

Essas exclusões seguem critérios objetivos e replicáveis, amplamente utilizados na literatura empírica sobre desempenho bancário, e não refletem juízos específicos sobre instituições individuais. O objetivo é preservar a consistência estatística da amostra e evitar distorções nos resultados decorrentes de observações atípicas ou de dados incompletos.

A relação final das instituições incluídas na análise encontra-se apresentada no Quadro 1, garantindo transparência quanto à composição da amostra utilizada.

3.4 Variáveis Utilizadas

Nesta seção são apresentadas as fórmulas utilizadas para operacionalizar as variáveis do estudo, explicitando as escolhas adotadas para sua mensuração. O presente trabalho emprega métricas de desempenho financeiro amplamente reconhecidas na literatura, tais como Retorno sobre Ativos (ROA), Retorno sobre o Patrimônio Líquido (ROE) e Q de Tobin.

3.4.1 Variáveis Dependentes

O presente estudo adota quatro métricas amplamente utilizadas na literatura para mensurar o desempenho empresarial, considerando tanto indicadores contábeis quanto de mercado, conforme recomendações de estudos recentes (Katsikeas *et al*., 2016; Tavares; Penedo, 2018). As métricas selecionadas são:

(i) Retorno sobre Ativos,
(ii) Retorno sobre o Patrimônio Líquido, e
(iii) Q de Tobin.
(iv) Vendas (crescimento real das receitas)

Em primeiro lugar, o Retorno sobre Ativos mensura a eficiência operacional da instituição, indicando a capacidade de gerar lucro a partir do conjunto de ativos disponíveis (Assaf Neto, 2003; Gitman, 2010). Trata-se de um indicador tradicional na literatura de contabilidade e finanças bancárias, amplamente empregado em estudos empíricos sobre desempenho e rentabilidade de instituições financeiras (Athanasoglou, Brissimis e Delis, 2008; Bolt et al., 2012; Lee e Hsieh, 2013). No presente estudo, o ROA é operacionalizado como a razão entre o lucro líquido e o ativo total.

A segunda métrica, o Retorno sobre o Patrimônio Líquido, mede a rentabilidade do capital próprio investido pelos acionistas, refletindo a capacidade da instituição de gerar valor para seus proprietários (Gitman, 2010). O ROE é amplamente utilizado em análises financeiras e estudos sobre desempenho bancário, por captar o retorno do ponto de vista do investidor (Tavares; Penedo, 2018; Nguyen, 2023). Nesta pesquisa, o ROE é calculado pela razão entre o lucro líquido e o patrimônio líquido.

O Q de Tobin representa a relação entre o valor de mercado da empresa e o custo de reposição de seus ativos, sendo interpretado como um indicador das expectativas do mercado quanto ao desempenho futuro da firma (Tobin, 1969). Essa métrica tem sido amplamente utilizada como proxy de desempenho econômico-

financeiro e de atratividade para investidores em estudos de finanças e marketing financeiro (Srinivasan; Hanssens, 2009; Tavares; Penedo, 2018). Além disso, estudos clássicos, como Dornbusch (1976), destacam a relevância das expectativas de mercado e da precificação dos ativos para compreender as dinâmicas de valorização no curto e no longo prazo. Seguindo a metodologia consolidada na literatura, o Q de Tobin é operacionalizado como a razão entre o valor de mercado do patrimônio acrescido do valor contábil da dívida e o ativo total (Abel, 1982; Auerbach, 1982; Chung e Pruitt, 1994).

Embora amplamente utilizado como proxy de valor de mercado, o Q de Tobin não está isento de críticas. A literatura aponta que o indicador pode capturar expectativas de mercado influenciadas por fatores macroeconômicos, volatilidade financeira e comportamento especulativo, não refletindo exclusivamente fundamentos econômicos ou ganhos de eficiência produtiva (Perfect e Wiles, 1994; Erickson e Whited, 2000). Além disso, em setores fortemente regulados, como o bancário, o Q de Tobin pode ser sensível a mudanças regulatórias e à percepção de risco sistêmico, independentemente do desempenho operacional das instituições.

Ainda assim, o Q de Tobin é adotado neste estudo por sua capacidade de capturar a reação do mercado às decisões estratégicas das instituições, especialmente em contextos de assimetria informacional. Sob a ótica da Teoria da Sinalização, o indicador permite avaliar como investimentos em tecnologias emergentes, como a inteligência artificial, são incorporados às expectativas dos investidores, mesmo antes da materialização de ganhos contábeis. Dessa forma, o Q de Tobin é apropriado para examinar efeitos de curto e médio prazo associados à percepção de valor das instituições bancárias.

Por fim, o crescimento real das receitas é incorporado como uma dimensão adicional do desempenho empresarial, especialmente relevante em setores intensivos em dados, como o bancário. Estudos recentes indicam que a inteligência artificial contribui para a previsão de demanda, segmentação de clientes e estratégias de precificação, impactando diretamente o crescimento das receitas (Deshmukh e Boyd, 2024; Gerling e Lessmann, 2024). Evidências empíricas mostram ainda que o uso de IA em práticas de *cross-selling* e *up-selling* está associado ao aumento das receitas de intermediação financeira (Basten e Juelsrud, 2023). Nesta pesquisa, o crescimento real das receitas é mensurado pela variação percentual anual das receitas, ajustada pela inflação.

De forma geral, a literatura reconhece que o desempenho bancário é um fenômeno multidimensional, sensível tanto a fatores internos quanto às condições macroeconômicas, o que justifica a utilização conjunta de métricas contábeis e de mercado (Katsikeas *et al*., 2016; Catapan; Colauto, 2014; Nguyen, 2023). Assim, o foco simultânea de ROA, ROE, Q de Tobin e crescimento das receitas permite capturar diferentes dimensões do desempenho das instituições bancárias analisadas.

3.4.2 Variável Independente

Para construir a variável de foco em Inteligência Artificial, a pesquisa segue a metodologia de Mishra, Ewing e Cooper (2022). Um conjunto de 122 palavras e expressões-chave relacionadas à IA (disponível no quadro do Apêndice I) foi utilizado para quantificar a frequência de menções à tecnologia nos relatórios anuais das empresas listadas na B3. A variável resultante foi normalizada, calculada como a razão entre o número total de ocorrências dessas palavras e o número total de palavras do relatório. Essa medida relativa permite a comparabilidade entre as instituições e o longo do tempo, e é essencial para avaliar a relação entre o foco da IA e o desempenho organizacional, especialmente em termos de eficiência operacional e rentabilidade

Os relatórios das empresas listadas na B3, que reúnem informações financeiras e operacionais, constituem uma fonte relevante de dados secundários para identificar o foco em Inteligência Artificial. Dessa forma, a variável independente deste estudo é o foco de IA, mensurada pela frequência relativa de menções ao tema nas Demonstrações Financeiras Padronizadas (DFP) das instituições listadas na B3, obtidas diretamente no site da B3.

3.4.3 Variáveis de Controle

As variáveis de controle utilizadas neste estudo foram selecionadas com base na literatura sobre desempenho bancário e eficiência financeira. Elas representam fatores internos e externos que, segundo estudos anteriores, exercem influência sobre o desempenho das instituições, independentemente do foco em inteligência artificial. A inclusão dessas variáveis visa isolar seus efeitos e garantir maior precisão na estimativa do impacto da IA sobre as métricas de desempenho analisadas.

O tamanho do banco, mensurado pelo logaritmo do ativo total, é uma variável amplamente reconhecida como determinante do desempenho financeiro. Estudos como o de Athanasoglou, Brissimis e Delis (2008) indicam que bancos de maior porte tendem a usufruir de economias de escala, maior diversificação de produtos e maior capacidade de absorver inovações tecnológicas. No entanto, o efeito do tamanho não é linear: instituições muito grandes podem enfrentar ineficiências associadas à burocracia e à complexidade operacional.

O spread bancário é outro indicador relevante, refletindo a diferença entre as taxas cobradas nas operações de crédito e as pagas nas captações. Spreads elevados podem indicar margens de intermediação amplas e maior rentabilidade no curto prazo, mas também podem sinalizar estruturas de custos ineficientes ou práticas conservadoras de precificação. Kohlscheen, Murcia Pabón e Contreras (2018) ressaltam que o spread constitui um elemento sensível às condições macroeconômicas e à estrutura competitiva do mercado bancário.

A liquidez, definida como a proporção entre ativos líquidos e ativos totais, representa a capacidade da instituição em honrar compromissos de curto prazo. Níveis adequados de liquidez são desejáveis para a estabilidade financeira, mas o excesso de recursos ociosos pode reduzir a rentabilidade. Conforme Athanasoglou, Brissimis e Delis (2008) e Lee e Hsieh (2013), o impacto da liquidez sobre o desempenho bancário é ambíguo: enquanto níveis moderados contribuem para a segurança financeira, políticas excessivamente conservadoras tendem a limitar o retorno sobre o patrimônio líquido.

Além das variáveis estruturais, foram incluídos controles macroeconômicos, conforme a literatura de desempenho bancário. Afanasieff, Lhacar e Nakane (2002) destacam que o ambiente econômico exerce influência significativa sobre o spread e a rentabilidade das instituições financeiras. Nesse sentido, o Produto Interno Bruto (PIB) e a taxa Selic foram incorporados como variáveis de controle, representando, respectivamente, o nível de atividade econômica e as condições monetárias do período analisado.

Nesse sentido, as variáveis de controle foram incorporadas aos modelos econométricos com o propósito de ajustar os resultados e proporcionar uma estimativa mais precisa do efeito do foco em inteligência artificial sobre o desempenho das instituições bancárias. Essas variáveis desempenham papel essencial para assegurar a robustez das análises empíricas e a consistência dos resultados obtidos.

De modo geral, o desempenho das instituições financeiras é influenciado não apenas por fatores tecnológicos, mas também por características estruturais e macroeconômicas amplamente documentadas na literatura. Evidências empíricas indicam que variáveis internas, como porte institucional (Tamanho), *spreads*, despesas operacionais e liquidez exercem influência significativa sobre o desempenho financeiro bancário (Bolt *et al.,* 2012; Athanasoglou; Brissimis; Delis, 2008). Bancos de maior porte tendem a apresentar maior capacidade de absorção e retorno de investimentos tecnológicos, enquanto spreads elevados e níveis excessivos de liquidez podem refletir ineficiências associadas à estrutura competitiva e ao uso subótimo dos ativos (Maffili, 2007; Lee; Hsieh, 2013). Diante disso, essas variáveis são incorporadas aos modelos econométricos como controles estruturais, com o objetivo de isolar o efeito específico do foco em inteligência artificial sobre o desempenho financeiro e operacional das instituições bancárias.

As correlações entre as variáveis utilizadas nos modelos econométricos encontram-se apresentadas na Figura 1 abaixo, que exibe a matriz de correlação elaborada a partir dos dados da pesquisa.

Figura 1: matriz de correlação

	Ano	Quantidade	Total_palavras	ROA	ROE	IA	QTOBIN	SIZE	DEPOSITO	DESP	SPREAD	LIQUIDEZ	DPAN	VARPIB	SELICMETA	IPCA
Ano																
Quantidade	0.12															
Total_palavras	0.13	0.73***														
ROA	0.24***	0.05	0.07													
ROE	0.26***	0.14*	0.14	0.90***												
IA	0.01	0.78***	0.20**	0.02	0.07											
QTOBIN	0.11	0.36***	0.41***	0.44***	0.35***	0.21**										
SIZE	0.14	0.73***	0.78***	0.20**	0.27***	0.40***	0.46***									
DEPOSITO	0.15*	-0.08	-0.23***	-0.32***	-0.21**	0.09	-0.23***	-0.44***								
DESP	0.36***	0.04	0.11	0.27***	0.28***	-0.12	0.21**	0.12	-0.05							
SPREAD	-0.22**	0.07	0.14	-0.32***	-0.33***	0.01	-0.18**	0.24***	-0.47***	-0.48***						
LIQUIDEZ	0.06	-0.29***	-0.20**	0.14	0.18**	-0.30***	-0.15*	-0.10	-0.38***	0.46***	0.01					
DPAND	0.34***	0.18**	0.15*	0.04	0.03	0.08	0.05	0.05	0.10	0.45***	-0.29***	0.06				
VARPIB	0.48***	0.12	0.13	0.14*	0.16*	0.02	-0.10	0.07	0.09	0.07	0.03	-0.04	0.36***			
SELICMETA	-0.16*	-0.11	-0.10	-0.03	0.00	-0.05	-0.32***	-0.01	-0.05	-0.63***	0.39***	-0.12	-0.47***	0.26***		
IPCA	-0.17**	0.04	0.01	-0.01	-0.01	0.02	-0.23***	-0.02	-0.02	-0.35***	0.24***	-0.09	0.29***	0.43***	0.53***	
VENDAS	0.30***	0.04	0.07	0.22**	0.22***	-0.04	0.02	0.03	-0.04	-0.15*	0.14	-0.02	0.08	0.67***	0.39***	0.48***

Fonte: Elaborado pela autora (2025)

Quadro 2: Resumo das variáveis utilizadas

Variável	Definição	Medida/Indicador	Fonte de Dados	Tipo de Variável
IA	Foco de tecnologias de Inteligência Artificial nos bancos	Score ou índice de implementação de IA	Relatórios Anuais / Sites Oficiais	Contínua
ROA	Retorno sobre ativos: mede a lucratividade da instituição em relação aos ativos totais	Lucro Líquido / Ativo Total	Relatórios Financeiros / B3	Contínua
ROE	Retorno sobre patrimônio líquido: mede a rentabilidade para os acionistas	Lucro Líquido / Patrimônio Líquido	Relatórios Financeiros / B3	Contínua
Q de Tobin	Avaliação de mercado em relação ao valor contábil dos ativos	(Valor de Mercado do Patrimônio + Dívida) / Ativos Totais	Economática / B3	Contínua
Tamanho do banco	Magnitude das operações bancárias	Logaritmo do Ativo Total	Relatórios Financeiros / B3	Contínua
Liquidez	Capacidade de honrar obrigações de curto prazo	Ativo Circulante / Passivo Circulante	IFDATA / B3	Contínua
Spread Bancário	Diferença entre taxas de captação e empréstimos	Taxa Média de Juros Ativa – Passiva	IFDATA / Bacen	Contínua
Capitalização	Solidez financeira do banco	Patrimônio Líquido / Ativos Totais	IFDATA / B3	Contínua
PIB	Crescimento econômico do país	Variação percentual anual do PIB	IBGE / Banco Mundial	Contínua
IPCA	Inflação ao consumidor	Variação percentual anual do IPCA	IBGE	Contínua
SELIC	Taxa básica de juros	Taxa anualizada	Banco Central do Brasil	Contínua
Crescimento real das receitas	Proxy de variação de vendas	Variação percentual anual ajustada pela inflação	Relatórios anuais / Bacen / CVM	Contínua

Fonte: Elaborado pela autora (2025).

3.5 Análise de Dados

Quanto à técnica de análise de dados, adotou-se inicialmente a análise descritiva, cujo objetivo é sintetizar e descrever as principais características da amostra e das variáveis investigadas, bem como identificar padrões gerais e possíveis relações preliminares entre os indicadores analisados (Lakatos; Marconi, 2017). Essa etapa é fundamental para compreender o comportamento das variáveis

ao longo do tempo e orientar a especificação dos modelos econométricos subsequentes.

A presente pesquisa insere-se no escopo dos estudos longitudinais, caracterizados pela observação de um conjunto de unidades ao longo de múltiplos períodos, permitindo analisar mudanças, tendências e dinâmicas temporais (Lakatos; Marconi, 2017). Esse tipo de abordagem é particularmente adequado para investigações no setor bancário, uma vez que o desempenho das instituições resulta de processos cumulativos e decisões estratégicas cujos efeitos tendem a se manifestar de forma gradual ao longo do tempo.

Em seguida, os modelos econométricos foram estimados no software R, conforme detalhado no Apêndice II, utilizando rotinas específicas para análise de dados em painel. Inicialmente, foram realizadas as etapas de importação, padronização e integração dos dados contábeis ativos, passivos e demonstrações de resultados, provenientes das bases utilizadas. Na sequência, procedeu-se à construção das variáveis derivadas, incluindo ROA, ROE, Q de Tobin, tamanho do banco, indicadores de liquidez, spread bancário, depósitos e demais variáveis de controle.

A variável independente de interesse, correspondente ao foco em Inteligência Artificial, foi obtida a partir da proporção de menções a termos relacionados à IA nos relatórios anuais das instituições, processados em ambiente Python. O código utilizado para essa etapa encontra-se apresentado no Apêndice III. Essa operacionalização permite capturar, de forma sistemática e comparável, a intensidade relativa da atenção dedicada à IA ao longo do tempo.

O conjunto de dados foi estruturado em formato longitudinal, abrangendo observações anuais no período de 2013 a 2023. A base resultante apresenta variação no número de observações entre as instituições, característica comum em estudos aplicados ao setor bancário, em razão de eventos como entrada, saída ou indisponibilidade de informações em determinados períodos. As variáveis explicativas foram defasadas em um período, com o objetivo de mitigar potenciais problemas de simultaneidade e permitir a análise do efeito temporal do foco de IA sobre o desempenho subsequente das instituições.

Adicionalmente, foi realizado o tratamento de observações extremas por meio de *winsorização* a 1% nas variáveis de resultado sujeitas a maior volatilidade. Também se estabeleceu um critério mínimo de três observações válidas por

instituição ao longo do período analisado, a fim de assegurar maior estabilidade nas estimativas econométricas.

Optou-se pela utilização de modelos de efeitos fixos por instituição, abordagem amplamente recomendada quando há elevada probabilidade de correlação entre características inobserváveis das unidades analisadas e as variáveis explicativas. Essa especificação permite controlar a heterogeneidade não observada específica de cada banco, assegurando maior consistência e robustez das estimativas em painéis aplicados ao setor financeiro (Baltagi, 2005; Wooldridge, 2010; Greene, 2018).

Em especificações alternativas, foram incorporados controles macroeconômicos agregados, como PIB, taxa Selic e inflação (IPCA), com o objetivo de capturar variações temporais comuns ao ambiente econômico e monetário, em substituição aos efeitos fixos de tempo. Essa estratégia é consistente com a prática recomendada na literatura de econometria aplicada, especialmente em contextos nos quais choques macroeconômicos afetam simultaneamente todas as unidades analisadas (Baltagi, 2005; Wooldridge, 2010).

As inferências estatísticas foram realizadas com erros-padrão robustos clusterizados por instituição, de modo a corrigir possíveis problemas de heterocedasticidade e autocorrelação serial dentro dos bancos ao longo do tempo. Esse procedimento contribui para a confiabilidade dos testes estatísticos e para a validade dos resultados empíricos apresentados.

3.5.1 Modelo Empírico

Os modelos empíricos apresentados a seguir foram construídos para testar as

Os modelos empíricos apresentados a seguir foram construídos com o objetivo de testar as hipóteses desta dissertação, examinando o impacto do foco em Inteligência Artificial sobre o desempenho financeiro das instituições bancárias brasileiras no período de 2013 a 2023. Para tanto, adotou-se o método de Mínimos Quadrados Ordinários (MQO) aplicado a dados em painel, com a inclusão de efeitos fixos por instituição, de modo a controlar a heterogeneidade não observada e invariante no tempo entre os bancos.

O desempenho bancário é mensurado por quatro indicadores distintos: Retorno sobre Ativos, Retorno sobre o Patrimônio Líquido, Q de Tobin e crescimento real das receitas, permitindo capturar, de forma complementar, dimensões de eficiência operacional, rentabilidade do capital próprio, valorização de mercado e expansão econômica das instituições analisadas. Adicionalmente, são incorporadas variáveis de controle institucionais e macroeconômicas, reconhecendo que o desempenho bancário resulta da interação entre fatores internos à firma e condições econômicas externas.

Considerando que os impactos do foco de Inteligência Artificial tendem a se manifestar de forma gradual, e visando mitigar potenciais problemas de simultaneidade e endogeneidade, as variáveis explicativas de interesse são incorporadas aos modelos com uma defasagem temporal de um período. Essa estratégia permite assegurar que o foco em IA preceda temporalmente os resultados observados, reforçando a consistência das inferências em um contexto observacional longitudinal, conforme prática consolidada na literatura de dados em painel.

O modelo empírico geral pode ser representado da seguinte forma:

$$DES_{i,t} = \alpha + \beta_1 IA_{i,t-1} + \beta_2 X_{i,t-1} + \gamma_i + \varepsilon_{i,t}$$

em que:

$DES_{i,t}$ representa o desempenho financeiro da instituição i no período t, mensurado alternativamente por ROA, ROE, Q de Tobin ou crescimento real das receitas;

$IA_{i,t-1}$ corresponde ao foco em Inteligência Artificial da instituição i, mensurado pela frequência relativa de termos relacionados à IA nos relatórios anuais, defasada em um período;

$X_{i,t-1}$ representa o vetor de variáveis de controle institucionais, defasadas em um período, incluindo:

$SIZE_{i,t-1}$: logaritmo do ativo total (proxy para o tamanho do banco);

$DEPOSITO_{i,t-1}$: depósitos totais sobre ativos totais;

$DESP_{i,t-1}$: despesas financeiras intermediárias sobre ativos totais;

$SPREAD_{i,t-1}$: diferença entre receitas e despesas financeiras em relação à receita financeira;

$LIQUIDEZ_{i,t-1}$: disponibilidades e aplicações líquidas sobre ativos totais;

γ_i captura os efeitos fixos específicos de cada instituição, controlando características não observáveis e invariantes no tempo;

$\varepsilon_{i,t}$ é o termo de erro idiossincrático.

Com base nesse modelo geral, são estimadas quatro especificações empíricas, uma para cada métrica de desempenho:

Equação (1): Impacto do foco em IA sobre o Retorno sobre Ativos;

Equação (2): Impacto do foco em IA sobre o Retorno sobre o Patrimônio Líquido;

Equação (3): Impacto do foco em IA sobre o Q de Tobin;

Equação (4): Impacto do foco em IA sobre o crescimento real das receitas.

As estimativas são realizadas com erros-padrão robustos clusterizados por instituição, a fim de controlar a autocorrelação serial e a heterocedasticidade. Adicionalmente, as variáveis dependentes sujeitas a elevada dispersão são submetidas ao procedimento de *winsorização* a 1%, e são excluídas instituições com número insuficiente de observações válidas no período analisado. Esse conjunto de procedimentos assegura maior robustez estatística e consistência às estimativas obtidas.

Com base nesse modelo geral, foram estimadas três especificações, uma para cada indicador de desempenho:

Equação 1: Impacto da IA sobre o ROA:

$$ROA_{i,t}=\beta_0+\beta_1 IA_{i,t-1}+\sum_{k=2}^{K}\beta_k CONTROLES_{i,t-1}+\gamma_i+\varepsilon_{i,t}$$

Equação 2: Impacto da IA sobre o ROE:

$$ROE_{i,t}=\beta_0+\beta_1 IA_{i,t-1}+\sum_{k=2}^{K}\beta_k CONTROLES_{i,t-1}+\gamma_i+\varepsilon_{i,t}$$

Equação 3: Impacto da IA sobre o Q de Tobin:

$$QTOBIN_{i,t} = \beta_0 + \beta_1 IA_{i,t-1} + \sum_{k=2} K \beta_k CONTROLES_{i,t-1} + \gamma_i + \varepsilon_{i,t}$$

Equação 4: Impacto da IA sobre VENDAS

$$VENDAS_{i,t} = \beta_0 + \beta_1 IA_{i,t-1} + \sum_{k=2} K \beta_k CONTROLES_{i,t-1} + \gamma_i + \varepsilon_{i,t}$$

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 Análise Descritiva

Inicialmente, apresenta-se a estatística descritiva das variáveis utilizadas nos modelos, incluindo média, desvio-padrão, valores mínimos e máximos, de modo a caracterizar a amostra e assegurar a consistência dos dados analisados.

A Tabela 1 apresenta as estatísticas descritivas das variáveis utilizadas na amostra, com base em 137 observações referentes ao período de 2013 a 2023. Observa-se que o ROA apresenta média de 0,006, indicando baixa rentabilidade dos ativos, com variação entre -0,007 e 0,019. Já o ROE possui média de 0,067, refletindo rentabilidade moderada sobre o patrimônio líquido, embora com amplitude expressiva entre -0,097 e 0,158.

A variável de interesse IA apresenta média de 0,175, com valores variando entre 0,052 e 0,576, o que indica diferenças substanciais na intensidade do foco de tecnologias de inteligência artificial entre as instituições analisadas. Essa amplitude evidencia um processo de transformação digital heterogêneo no setor bancário, em que algumas instituições se encontram em estágios iniciais de incorporação da IA restritos, por exemplo, à automação de tarefas e análise operacional, enquanto outras já apresentam estratégias mais consolidadas de aplicação, voltadas à eficiência analítica, atendimento ao cliente e gestão de riscos. Essa variação é relevante do ponto de vista analítico, pois sugere que os efeitos da IA sobre o desempenho bancário podem depender do grau de maturidade tecnológica de cada instituição. Em termos descritivos, o porte médio das instituições, mensurado pelo logaritmo do ativo total (tamanho), foi de 18,259 no período analisado. As variáveis relacionadas à estrutura de captação e liquidez apresentaram médias de 0,423 e 0,440, respectivamente, indicando níveis consistentes de depósitos e disponibilidade de recursos ao longo da amostra. Esses resultados são apresentados nas estatísticas descritivas (Figura 1) e refletem um perfil relativamente homogêneo das instituições analisadas no que se refere à estrutura financeira básica.

As variáveis macroeconômicas IPCA e taxa Selic apresentaram variações compatíveis com o contexto econômico do período analisado, sem movimentos extremos persistentes, o que contribui para a estabilidade das estimativas econométricas ao longo do painel. As variáveis macroeconômicas apresentaram

comportamento relativamente estável ao longo do período analisado. O IPCA, com média de 0,059, e a taxa Selic, com média de 0,094, indicam um cenário de estabilidade monetária e de juros, sem oscilações extremas que pudessem distorcer os resultados.

De modo semelhante, o PIB registrou média de 0,076, com leve dispersão, refletindo um ritmo moderado e consistente de crescimento econômico. Esse contexto contribui para reduzir o impacto de choques macroeconômicos sobre o desempenho das instituições, permitindo uma avaliação mais precisa dos efeitos do foco de inteligência artificial. Por outro lado, a variável VENDAS apresentou média de 0,089 e elevado desvio-padrão (0,294), o que revela significativa heterogeneidade no crescimento real das receitas entre os bancos da amostra. Essa variação sugere que as diferenças de desempenho comercial estão mais associadas a fatores internos como porte, estrutura operacional e nível de digitalização do que a condições macroeconômicas conjunturais. A matriz de correlação (Figura 1) evidencia associações consistentes entre as variáveis de desempenho, em especial entre ROA e ROE (r = 0,90), o que era esperado por ambas refletirem dimensões contábeis da rentabilidade. Observa-se também uma correlação positiva, embora fraca, entre IA e Q de Tobin (r = 0,21), sugerindo que bancos com maior foco em inteligência artificial tendem a ser ligeiramente mais valorizados pelo mercado. As variáveis estruturais, como tamanho (SIZE) e liquidez, apresentam correlações de baixa a moderada magnitude com os indicadores de desempenho, indicando influência, mas sem risco de multicolinearidade. Nenhum coeficiente ultrapassou 0,80, valor de referência convencional para identificação de correlação excessiva entre variáveis independentes. Esses resultados reforçam a adequação dos dados para as análises econométricas subsequentes.

Tabela 1: Estatística descritiva da amostra

Variável	N	Média	Mediana	Mínimo	Máximo	Desvio-padrão
ROA	137	0,006	0,007	-0,007	0,019	0,004
ROE	137	0,067	0,072	-0,097	0,158	0,046
IA	137	0,175	0,150	0,052	0,576	0,100
QTOBIN	137	95,658	79,849	11,407	348,866	67,083
SIZE	137	18,259	17,651	15,131	21,615	1,956
DEPOSITO	137	0,423	0,387	0,091	0,844	0,196
DESP	137	-0,043	-0,041	-0,106	-0,011	0,020
SPREAD	137	1,708	1,690	1,261	2,282	0,200
LIQUIDEZ	137	0,440	0,407	0,073	0,803	0,166
DPAND	137	0,204	0	0	1	0,405

Variável	N	Média	Mediana	Mínimo	Máximo	Desvio-padrão
PIB	137	0,076	0,064	0,030	0,184	0,045
SELIC	137	0,094	0,092	0,020	0,142	0,041
IPCA	137	0,059	0,046	0,030	0,107	0,024
VENDAS	137	0,089	0,037	-0,488	0,936	0,294

Fonte: Dados da pesquisa (2025).

4.2 REGRESSÕES

Esta seção apresenta os resultados das regressões com dados em painel estimadas para avaliar a relação entre o foco em inteligência artificial e o desempenho das instituições bancárias brasileiras. As estimativas permitem analisar como a intensidade do foco de IA se associa às diferentes dimensões de desempenho consideradas no estudo, contemplando indicadores de rentabilidade, valor de mercado e crescimento das receitas. Os resultados são apresentados de forma incremental, iniciando-se pelas métricas contábeis e avançando para os indicadores de mercado e expansão operaciona.

4.2.1 ROA

As Tabelas 2 e 3 apresentam os resultados das regressões por efeitos fixos para a variável dependente ROA, considerando, respectivamente, controles institucionais e a inclusão adicional de variáveis macroeconômicas. Essa estratégia permite avaliar a robustez dos resultados à incorporação de diferentes conjuntos de controles.

No modelo com controles institucionais, o coeficiente associado à variável IA não apresentou significância estatística, indicando ausência de associação entre o foco em inteligência artificial e a rentabilidade dos ativos. Em contraste, variáveis estruturais como depósitos, spread e liquidez exibem efeitos negativos e estatisticamente significativos, reforçando o papel predominante da estrutura financeira no desempenho operacional.

A inclusão de variáveis macroeconômicas não altera substancialmente esse resultado. O coeficiente da variável IA permanece não significativo, enquanto os efeitos de depósitos, spread e liquidez se mantêm estatisticamente relevantes. As variáveis macroeconômicas não apresentaram significância, sugerindo que, no

período analisado, o desempenho dos ativos bancários foi determinado predominantemente por fatores internos.

Tabela 2: Resultados do Modelo 1.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	0,001789	0,003412	0,524	0,608
SIZE	-0,002980	0,002828	-1,054	0,310
DEPOSITO	-0,016625	0,006414	-2,592	0,021 *
DESP	0,012526	0,034679	0,361	0,723
SPREAD	-0,010625	0,002762	-3,846	0,002 **
LIQUIDEZ	-0,017996	0,008471	-2,124	0,052 *

Nota: R² ajustado: 0,5939
R² do modelo projetado: 0,0857
Erro padrão residual: 0,002867
F-estatístico (modelo completo): 7,858 (p < 0,001)
F-estatístico (modelo projetado): 28,63 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Nota: Os asteriscos indicam os níveis de significância estatística associados aos coeficientes estimados: * p < 0,10; ** p < 0,05; *** p < 0,01.
Fonte: Dados da pesquisa (2025).

Tabela 3: Resultados do Modelo 1.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	0,003264	0,004432	0,736	0,474
SIZE	0,002115	0,001539	1,375	0,191
DEPOSITO	-0,012208	0,005589	-2,184	0,046 *
DESP	0,001246	0,043054	0,029	0,977
SPREAD	-0,009277	0,002999	-3,094	0,008 **
LIQUIDEZ	-0,016998	0,008437	-2,015	0,064 *
PIB	0,010643	0,006968	1,527	0,149
SELIC	0,002099	0,012389	0,169	0,868
IPCA	-0,002486	0,015677	-0,159	0,876

Nota: R² ajustado: 0,5426
R² do modelo projetado: 0,1209
Erro padrão residual: 0,003043
F-estatístico (modelo completo): 8,014 (p < 0,001)
F-estatístico (modelo projetado): 12,96 (p < 0,001)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.2 ROE

As Tabelas 4, 5 e 6 apresentam os resultados das regressões por efeitos fixos para a variável dependente ROE, considerando, respectivamente, um modelo com controles institucionais básicos, uma especificação ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora controles macroeconômicos. Essa estratégia permite avaliar a robustez dos resultados associados ao foco em inteligência artificial frente à inclusão progressiva de diferentes conjuntos de variáveis explicativas.

Nos três modelos estimados, o coeficiente associado à variável de interesse IA apresenta sinal positivo, porém não estatisticamente significativo, indicando ausência de associação entre o foco em inteligência artificial e o retorno sobre o patrimônio líquido das instituições bancárias no período analisado. Esse resultado é consistente entre as diferentes especificações, sugerindo que a inclusão de variáveis estruturais e macroeconômicas não altera substancialmente a relação estimada entre IA e ROE.

Entre os controles institucionais, o spread bancário apresenta coeficiente negativo e estatisticamente significativo em todas as especificações, evidenciando que spreads mais elevados estão associados à redução da rentabilidade patrimonial, possivelmente em razão do aumento do custo de intermediação financeira. A variável liquidez também apresenta coeficiente negativo em todos os modelos, com significância marginal nas especificações ampliadas, indicando que níveis elevados de liquidez podem estar associados a menor eficiência na utilização do capital próprio.

No modelo com variáveis adicionais de estrutura bancária, observa-se que o tamanho da instituição exerce efeito positivo e estatisticamente significativo sobre o ROE, sugerindo que bancos de maior porte tendem a apresentar maior rentabilidade patrimonial, possivelmente em função de economias de escala e maior diversificação de receitas. As variáveis depósitos e liquidez mantêm efeito negativo e significância marginal, reforçando a relevância da estrutura de captação e da gestão de recursos líquidos na determinação do desempenho patrimonial. As despesas operacionais não apresentaram efeito estatisticamente significativo em nenhuma das especificações.

A inclusão de variáveis macroeconômicas no Modelo 2.3 não altera o padrão dos resultados. PIB, Selic e IPCA não apresentam coeficientes estatisticamente significativos, indicando que, no período analisado, as condições macroeconômicas não exerceram influência direta sobre o retorno sobre o patrimônio líquido das instituições. O poder explicativo dos modelos permanece consistente, e os testes F

globais confirmam a significância conjunta dos parâmetros em todas as especificações.

Em síntese, os resultados indicam que o foco em inteligência artificial não se associa a variações estatisticamente significativas no retorno sobre o patrimônio líquido, enquanto fatores estruturais e financeiros especialmente porte institucional, spreads, depósitos e liquidez permanecem como os principais determinantes da rentabilidade patrimonial dos bancos no período analisado.

Tabela 4: Resultados do Modelo 2.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	0,03905	0,04509	0,866	0,401
SIZE	0,01355	0,04274	0,317	0,756
SPREAD	−0,12178	0,05155	−2,362	0,033 *
LIQUIDEZ	−0,10143	0,06509	−1,558	0,142

Nota: R^2 ajustado: 0,4727
R^2 do modelo projetado: −0,0228
Erro padrão residual: 0,03315
F-estatístico (modelo completo): 5,515 (p < 0,001)
F-estatístico (modelo projetado): 2,733 (p = 0,072)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 5: Resultados do Modelo 2.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	0,05736	0,05541	1,035	0,318
SIZE	0,03593	0,01535	2,340	0,035 *
DEPOSITO	−0,10416	0,05595	−1,862	0,084 *
DESP	−0,24794	0,42429	−0,584	0,568
SPREAD	−0,10346	0,04608	−2,245	0,041 *
LIQUIDEZ	−0,11784	0,05738	−2,054	0,059 *

Nota: R^2 ajustado: 0,465
R^2 do modelo projetado: 0,0929
Erro padrão residual: 0,03339
F-estatístico (modelo completo): 6,91 (p < 0,001)
F-estatístico (modelo projetado): 3,344 (p = 0,029)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 6: Resultados do Modelo 2.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	0,05148	0,05713	0,901	0,383
SIZE	0,02974	0,01519	1,958	0,071 *
DEPOSITO	−0,10995	0,05579	−1,971	0,069 *
DESP	−0,14932	0,47860	−0,312	0,760
SPREAD	−0,10876	0,04443	−2,448	0,028 *
LIQUIDEZ	−0,10796	0,05893	−1,832	0,088 *
PIB	0,07371	0,06116	1,205	0,248
SELIC	0,06478	0,15940	0,406	0,691
IPCA	−0,02258	0,15939	−0,142	0,889

Nota: R^2 ajustado: 0,4574
R^2 do modelo projetado: 0,0800
Erro padrão residual: 0,03363
F-estatístico (modelo completo): 5,984 (p < 0,001)
F-estatístico (modelo projetado): 3,996 (p = 0,010)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.3 Q Tobin

A As Tabelas 7, 8 e 9 apresentam os resultados das regressões por efeitos fixos para a variável dependente Q de Tobin, indicador de valorização de mercado das instituições bancárias em relação ao seu valor contábil. As especificações consideram, respectivamente, um modelo com controles institucionais básicos, uma versão ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora controles macroeconômicos. Essa estratégia permite avaliar a robustez da relação entre o foco em inteligência artificial e o valor de mercado diante da inclusão progressiva de diferentes conjuntos de controles.

Nos três modelos estimados, o coeficiente associado à variável de interesse IA apresenta sinal negativo, porém não estatisticamente significativo, indicando ausência de evidências de associação entre o foco em inteligência artificial e a valorização de mercado das instituições bancárias no período analisado. Esse resultado se mantém estável independentemente da especificação adotada, sugerindo que a inclusão de variáveis estruturais e macroeconômicas não altera substancialmente a relação estimada.

Entre os controles institucionais, o spread bancário e a liquidez apresentam coeficientes negativos e estatisticamente significativos em todas as especificações. Esses resultados indicam que spreads mais elevados e níveis excessivos de liquidez estão associados a menor valorização de mercado, possivelmente refletindo custos

de intermediação mais altos, menor eficiência na alocação de recursos e uma percepção menos favorável por parte dos investidores quanto ao potencial de geração de valor das instituições.

As variáveis tamanho, depósitos e despesas operacionais não apresentaram significância estatística nas diferentes especificações, indicando que o porte institucional e a estrutura de captação e custos não explicam diretamente o Q de Tobin quando controlados os efeitos fixos e demais variáveis financeiros. O poder explicativo dos modelos permanece elevado, com valores de R^2 ajustado superiores a 0,72 em todas as especificações, e os testes F globais confirmam a significância conjunta dos parâmetros estimados.

No modelo que incorpora variáveis macroeconômicas, observa-se que a taxa Selic apresenta coeficiente negativo e estatisticamente significativo, sugerindo que condições monetárias mais restritivas estão associadas à redução do valor de mercado das instituições bancárias. Em contraste, PIB e IPCA não exibem efeitos estatisticamente significativos, indicando que variações no nível de atividade econômica e na inflação não explicam diretamente a valorização de mercado no período analisado.

Em síntese, os resultados indicam que o foco em inteligência artificial não se associa a variações estatisticamente significativas no Q de Tobin, enquanto fatores estruturais internos especialmente spreads e liquidez e, em menor medida, condições monetárias, permanecem como os principais determinantes da valorização de mercado das instituições bancárias no período analisado.

Tabela 7: Resultados do Modelo 3.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−131,633	90,194	−1,459	0,167
SIZE	8,434	30,813	0,274	0,788
SPREAD	−186,904	43,272	−4,319	0,001 ***
LIQUIDEZ	−214,280	49,957	−4,289	0,001 ***

Nota: R^2 ajustado: 0,7655
R^2 do modelo projetado: 0,2536
Erro padrão residual: 32,49
F-estatístico (modelo completo): 17,44 ($p < 0,001$)
F-estatístico (modelo projetado): 8,849 ($p < 0,001$)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 8: Resultados do Modelo 3.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−130,682	92,399	−1,414	0,179
SIZE	3,399	29,123	0,117	0,909
DEPOSITO	−12,848	79,522	−0,162	0,874
DESP	−335,980	425,917	−0,789	0,443
SPREAD	−199,094	50,220	−3,964	0,001 **
LIQUIDEZ	−210,438	53,627	−3,924	0,002 **

Nota: R^2 ajustado: 0,7626
R^2 do modelo projetado: 0,2443
Erro padrão residual: 32,69
F-estatístico (modelo completo): 16,06 (p < 0,001)
F-estatístico (modelo projetado): 6,522 (p < 0,01)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 9: Resultados do Modelo 3.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−144,987	93,155	−1,556	0,142
SIZE	2,536	13,242	0,191	0,851
DEPOSITO	−20,411	90,772	−0,225	0,825
DESP	−738,666	513,334	−1,439	0,172
SPREAD	−192,481	62,830	−3,064	0,008 **
LIQUIDEZ	−230,352	58,146	−3,962	0,001 **
PIB	4,259	65,479	0,065	0,949
SELIC	−385,753	157,186	−2,454	0,028 *
IPCA	−125,691	174,721	−0,719	0,484

Nota:
R^2 ajustado: 0,7214
R^2 do modelo projetado: 0,3660
Erro padrão residual: 35,41
F-estatístico (modelo completo): 16,31 (p < 0,001)
F-estatístico (modelo projetado): 19,10 (p < 0,001)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.4 Vendas

A As Tabelas 10, 11 e 12 apresentam os resultados das regressões por efeitos fixos para a variável dependente VENDAS, que representa o crescimento real das receitas das instituições bancárias. As três especificações consideram, respectivamente, um modelo com controles institucionais básicos, uma versão ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora

variáveis macroeconômicas. Essa abordagem permite avaliar a robustez da relação entre o foco em inteligência artificial e o desempenho comercial diante da inclusão progressiva de diferentes conjuntos de controles.

Em todas as especificações estimadas, o coeficiente associado à variável de interesse IA apresenta sinal negativo e não é estatisticamente significativo, indicando ausência de evidências de associação direta entre o foco em inteligência artificial e o crescimento real das receitas bancárias no período analisado. Esse resultado se mantém estável independentemente da inclusão de variáveis estruturais e macroeconômicas, sugerindo que do foco de IA não se reflete, de forma imediata, na expansão das receitas das instituições.

Entre os controles institucionais, o tamanho da instituição apresenta coeficiente positivo e estatisticamente significativo no modelo base, indicando que bancos de maior porte tendem a apresentar maior crescimento real de receitas, possivelmente em função de economias de escala, maior base de clientes e diversificação de produtos. No entanto, esse efeito perde significância nas especificações ampliadas, sugerindo que sua influência é parcialmente absorvida por outras características estruturais e macroeconômicas.

O spread bancário apresenta coeficiente negativo e estatisticamente significativo em todas as especificações, evidenciando que margens de intermediação mais elevadas estão associadas à redução do crescimento das receitas. Esse resultado sugere que spreads amplos podem restringir a competitividade das operações de crédito e limitar a expansão comercial das instituições. As variáveis liquidez, depósitos e despesas operacionais não apresentam efeitos estatisticamente significativos de forma consistente, indicando que essas dimensões não explicam isoladamente as variações no crescimento das receitas.

No modelo que incorpora variáveis macroeconômicas, o Produto Interno Bruto (PIB) e o IPCA apresentam coeficientes positivos e estatisticamente significativos, indicando que a expansão da atividade econômica e a elevação do nível de preços estão associadas ao aumento das receitas bancárias. Em contraste, a taxa Selic não apresenta significância estatística, sugerindo que, no período analisado, a política monetária não exerceu influência direta sobre o crescimento real das receitas.

Os valores de R^2 ajustado situam-se entre 0,55 e 0,61, indicando bom poder explicativo dos modelos, e os testes F globais confirmam a significância conjunta dos parâmetros estimados, assegurando a adequação estatística das regressões.

Em síntese, os resultados indicam que o foco em inteligência artificial não se associa a variações estatisticamente significativas no crescimento real das receitas bancárias, enquanto fatores estruturais internos especialmente o spread bancário e condições macroeconômicas, como o nível de atividade econômica e a inflação, permanecem como os principais determinantes do desempenho comercial das instituições no período analisado.

Tabela 10: Resultados do Modelo V.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−0,05017	0,14825	−0,338	0,740
SIZE	0,31343	0,13324	2,352	0,034 *
SPREAD	−0,26646	0,13904	−1,916	0,076 *
LIQUIDEZ	−0,23460	0,37378	−0,628	0,540

Nota:R² ajustado: 0,6073
R² do modelo projetado: −0,1399
Erro padrão residual: 0,184
F-estatístico (modelo completo): 8,791 (p < 0,001)
F-estatístico (modelo projetado): 4,38 (p < 0,05)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 11: Resultados do Modelo V.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−0,07468	0,17126	−0,436	0,669
SIZE	0,28160	0,20785	1,355	0,197
DEPOSITO	0,27308	0,46763	0,584	0,569
DESP	−4,22645	4,41840	−0,957	0,355
SPREAD	−0,41625	0,11003	−3,783	0,002 **
LIQUIDEZ	−0,13171	0,45476	−0,290	0,776

Nota: R² ajustado: 0,6126
R² do modelo projetado: −0,1246
Erro padrão residual: 0,1828
F-estatístico (modelo completo): 8,416 (p < 0,001)
F-estatístico (modelo projetado): 3,558 (p < 0,05)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 12: Resultados do Modelo V.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA	−0,07864	0,26163	−0,301	0,768
SIZE	0,15124	0,07133	2,120	0,052 *
DEPOSITO	0,23399	0,42281	0,553	0,589
DESP	−5,98916	3,73220	−1,605	0,131
SPREAD	−0,35091	0,08498	−4,129	0,001 **
LIQUIDEZ	−0,43727	0,38566	−1,134	0,276
PIB	3,35900	0,72016	4,664	0,000 ***
SELIC	−0,01546	1,39663	−0,011	0,991
IPCA	2,21317	0,63359	3,493	0,004 **

Nota: R^2 ajustado: 0,5487
R^2 do modelo projetado: 0,5135
Erro padrão residual: 0,1973
F-estatístico (modelo completo): 8,188 (p < 0,001)
F-estatístico (modelo projetado): 21,27 (p < 0,001)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.5 Modelos com Defasagem

As Tabelas 13, 14 e 15 apresentam os resultados das regressões por efeitos fixos para a variável dependente ROA, considerando as variáveis explicativas defasadas em um período. As três especificações avaliam, respectivamente, um modelo com controles institucionais básicos, uma versão ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora variáveis macroeconômicas. Essa abordagem permite examinar se o foco em inteligência artificial apresenta efeitos temporais sobre a rentabilidade operacional das instituições bancárias.

Em todas as especificações estimadas, o coeficiente associado à variável de interesse IA defasada apresenta sinal negativo e não é estatisticamente significativo, indicando ausência de evidências de que o foco de inteligência artificial no período anterior esteja associada a variações no retorno sobre os ativos no período corrente. Esse resultado permanece estável mesmo após a inclusão de controles institucionais adicionais e variáveis macroeconômicas, sugerindo que o efeito da IA sobre a rentabilidade operacional não se manifesta de forma defasada no horizonte temporal analisado.

No modelo com controles institucionais básicos, as variáveis tamanho, spread e liquidez defasadas também não apresentam significância estatística, indicando que seus efeitos sobre o ROA não persistem no período subsequente. Na especificação

ampliada, depósitos e spread defasados exibem efeitos negativos com significância marginal, sugerindo que maiores custos de captação e margens de intermediação elevadas no período anterior estão associados a menor rentabilidade operacional, ainda que de forma moderada. As demais variáveis estruturais não apresentam efeitos estatisticamente relevantes.

Quando incorporadas as variáveis macroeconômicas defasadas, nenhuma delas apresenta significância estatística, indicando que o contexto econômico do período anterior não explica de maneira substantiva o desempenho operacional corrente das instituições. De forma consistente, as variáveis institucionais defasadas também não mantêm efeitos estatisticamente significativos nessa especificação.

Os valores de R^2 ajustado situam-se entre 0,48 e 0,52, indicando poder explicativo satisfatório dos modelos, e os testes F globais confirmam a significância conjunta dos parâmetros estimados, assegurando a adequação estatística das regressões.

Em síntese, os resultados indicam que o foco em inteligência artificial não se associa a variações estatisticamente significativas no retorno sobre os ativos, mesmo quando considerado com defasagem temporal. De forma semelhante, os fatores estruturais e macroeconômicos analisados não demonstram efeitos persistentes sobre a rentabilidade operacional no período subsequente, reforçando a ausência de impactos temporais diretos sobre o ROA no intervalo analisado.

Tabela 13: Resultados do Modelo 1.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,005265	0,006238	−0,844	0,414
SIZE_lag	−0,002644	0,003832	−0,690	0,502
SPREAD_lag	−0,007423	0,004608	−1,611	0,131
LIQUIDEZ_lag	−0,007409	0,007116	−1,041	0,317

Nota: R^2 ajustado: 0,5098
R^2 do modelo projetado: −0,1228
Erro padrão residual: 0,003183
F-estatístico (modelo completo): 6,28 ($p < 0,001$)
F-estatístico (modelo projetado): 3,473 ($p < 0,05$)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 14: Resultados do Modelo 1.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,003883	0,005639	−0,689	0,503
SIZE_lag	−0,003973	0,003513	−1,131	0,279
DEPOSITO_lag	−0,012297	0,006752	−1,821	0,092 *
DESP_lag	−0,000685	0,037030	−0,018	0,986
SPREAD_lag	−0,006997	0,003941	−1,775	0,099 *
LIQUIDEZ_lag	−0,009546	0,007427	−1,285	0,221

Nota: R² ajustado: 0,5211
R² do modelo projetado: −0,0970
Erro padrão residual: 0,003146
F-estatístico (modelo completo): 6,129 (p < 0,001)
F-estatístico (modelo projetado): 10,92 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 15: Resultados do Modelo 1.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,001778	0,005558	−0,320	0,754
SIZE_lag	0,002349	0,001812	1,296	0,217
DEPOSITO_lag	−0,005073	0,006658	−0,762	0,460
DESP_lag	0,030278	0,044601	0,679	0,509
SPREAD_lag	−0,006472	0,004630	−1,398	0,186
LIQUIDEZ_lag	−0,005183	0,007592	−0,683	0,507
PIB_lag	0,006475	0,010165	0,637	0,535
SELIC_lag	0,012210	0,016531	0,739	0,473
IPCA_lag	−0,004623	0,011651	−0,397	0,698

Nota: R² ajustado: 0,4789
R² do modelo projetado: −0,0137
Erro padrão residual: 0,003282
F-estatístico (modelo completo): 6,514 (p < 0,001)
F-estatístico (modelo projetado): 2,137 (p = 0,104)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.6 ROE Defasado

As Tabelas 16, 17 e 18 apresentam os resultados das regressões por efeitos fixos para a variável dependente ROE, considerando as variáveis explicativas defasadas em um período. As três especificações analisam, respectivamente, um

modelo com controles institucionais básicos, uma versão ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora variáveis macroeconômicas. Essa abordagem permite avaliar se o foco em inteligência artificial apresenta efeitos temporais sobre a rentabilidade do patrimônio líquido das instituições bancárias.

Em todas as especificações estimadas, o coeficiente associado à variável de interesse IA defasada não apresenta significância estatística, independentemente do conjunto de controles incluído. Esse resultado indica ausência de evidências de que o foco de inteligência artificial no período anterior esteja associada a variações no retorno sobre o patrimônio líquido no período subsequente.

No modelo com controles institucionais básicos, as variáveis defasadas de tamanho e liquidez também não apresentam significância estatística. O spread bancário exibe coeficiente negativo com significância marginal, sugerindo que margens de intermediação mais elevadas no período anterior estão associadas à redução do ROE, ainda que esse efeito não seja estatisticamente robusto.

Na especificação com controles ampliados de estrutura bancária, o coeficiente da variável IA defasada permanece estatisticamente não significativo. Entre as variáveis de controle, o spread mantém efeito negativo com significância marginal, enquanto tamanho, depósitos, despesas e liquidez não explicam variações relevantes na rentabilidade patrimonial quando considerados com defasagem temporal.

De forma semelhante, no modelo que incorpora variáveis macroeconômicas defasadas, a variável de interesse IA defasada continua não significativa. Nenhum dos indicadores macroeconômicos defasados PIB, taxa Selic e IPCA apresenta associação estatisticamente significativa com o ROE. As variáveis estruturais defasadas também não demonstram efeitos relevantes sobre a rentabilidade patrimonial nessa especificação.

Os valores de R^2 ajustado situam-se entre 0,39 e 0,42, indicando poder explicativo moderado dos modelos, enquanto os testes F globais confirmam a significância conjunta dos parâmetros estimados, assegurando a adequação estatística das regressões.

Em síntese, os resultados indicam que o foco em inteligência artificial não se associa a variações estatisticamente significativas no retorno sobre o patrimônio líquido, mesmo quando considerado com defasagem temporal. De modo consistente,

os fatores estruturais e macroeconômicos analisados também não apresentam efeitos persistentes sobre o ROE no período subsequente, reforçando a ausência de impactos temporais diretos sobre a rentabilidade patrimonial no intervalo analisado.

Tabela 16: Resultados do Modelo 2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,000256	0,054476	−0,005	0,996
SIZE_lag	−0,010924	0,051847	−0,211	0,836
SPREAD_lag	−0,093523	0,055003	−1,700	0,113
LIQUIDEZ_lag	−0,036190	0,074465	−0,486	0,635

Nota: R^2 ajustado: 0,4196
R^2 do modelo projetado: −0,1392
Erro padrão residual: 0,03517
F-estatístico (modelo completo): 4,67 (p < 0,001)
F-estatístico (modelo projetado): 2,445 (p = 0,099)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 17: Resultados do Modelo 2.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	0,005931	0,055434	0,107	0,916
SIZE_lag	−0,018057	0,051919	−0,348	0,734
DEPOSITO_lag	−0,054167	0,051722	−1,047	0,314
DESP_lag	−0,116880	0,363971	−0,321	0,753
SPREAD_lag	−0,095573	0,045535	−2,099	0,056 *
LIQUIDEZ_lag	−0,043203	0,077424	−0,558	0,586

Nota: R^2 ajustado: 0,4129
R^2 do modelo projetado: −0,1523
Erro padrão residual: 0,03537
F-estatístico (modelo completo): 4,316 (p < 0,001)
F-estatístico (modelo projetado): 15,82 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 18: Resultados do Modelo 2.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	0,018301	0,053577	0,342	0,738
SIZE_lag	0,027960	0,018950	1,475	0,164
DEPOSITO_lag	−0,002328	0,059018	−0,039	0,969
DESP_lag	0,069076	0,418696	0,165	0,871
SPREAD_lag	−0,086607	0,051220	−1,691	0,115
LIQUIDEZ_lag	−0,006207	0,054691	−0,113	0,911
PIB_lag	0,012398	0,112809	0,110	0,914

Variável	Coeficiente	Erro-padrão	t	p-valor
SELIC_lag	0,185959	0,201256	0,924	0,372
IPCA_lag	−0,020911	0,123526	−0,169	0,868

Nota: R² ajustado: 0,3963
R² do modelo projetado: −0,0330
Erro padrão residual: 0,03587
F-estatístico (modelo completo): 4,939 (p < 0,001)
F-estatístico (modelo projetado): 1,319 (p = 0,315)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.7 Tobin Defasado

As Tabelas 19, 20 e 21 apresentam os resultados das regressões por efeitos fixos para a variável dependente Q de Tobin defasada, considerando, respectivamente, um modelo com controles institucionais básicos, uma especificação ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora variáveis macroeconômicas. Essa abordagem permite avaliar a existência de efeitos temporais associados ao foco em inteligência artificial sobre a valorização de mercado das instituições bancárias.

Em todas as especificações estimadas, o coeficiente associado à variável de interesse IA defasada apresenta sinal negativo e é estatisticamente significativo. Esse resultado indica que o foco em inteligência artificial no período anterior está associado a uma redução no valor de mercado das instituições bancárias no período subsequente, mesmo após a inclusão de diferentes conjuntos de controles institucionais e macroeconômicos.

No modelo com controles institucionais básicos, a variável IA defasada apresenta coeficiente negativo e estatisticamente significativo, enquanto o spread bancário e a liquidez também exibem efeitos negativos e significativos. Esses resultados sugerem que, além do foco em inteligência artificial, fatores estruturais relacionados à intermediação financeira e à gestão de liquidez exercem influência relevante sobre a valorização de mercado no período seguinte.

A inclusão de variáveis adicionais de estrutura bancária não altera substancialmente esse padrão. No modelo ampliado, a variável IA defasada permanece negativa e estatisticamente significativa, assim como o spread e a liquidez. As variáveis relacionadas ao porte institucional, depósitos e despesas não

apresentam significância estatística, indicando que essas dimensões não explicam variações relevantes no Q de Tobin quando consideradas com defasagem temporal.

De forma consistente, no modelo que incorpora variáveis macroeconômicas defasadas, o coeficiente da variável IA defasada mantém sinal negativo e significância estatística. Além disso, o spread bancário, a liquidez e a taxa Selic defasada apresentam efeitos negativos e estatisticamente significativos, indicando que condições financeiras internas e o ambiente monetário exercem papel relevante na determinação do valor de mercado das instituições no período subsequente.

Os valores elevados de R^2 ajustado, situados entre 0,72 e 0,78, indicam alto poder explicativo dos modelos, enquanto os testes F globais confirmam a significância conjunta dos parâmetros estimados, assegurando a robustez das especificações econométricas adotadas.

Em síntese, os resultados indicam que o foco em inteligência artificial está associado a uma redução estatisticamente significativa da valorização de mercado no período subsequente, enquanto variáveis estruturais internas especialmente spread e liquidez e condições monetárias, como a taxa de juros, permanecem como determinantes centrais do Q de Tobin das instituições bancárias no período analisado.

Tabela 19: Resultados do Modelo 3.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−189,150	59,129	−3,199	0,007 **
SIZE_lag	−3,672	32,435	−0,113	0,912
SPREAD_lag	−169,824	50,465	−3,365	0,005 **
LIQUIDEZ_lag	−141,232	49,023	−2,881	0,013 *

Nota: R^2 ajustado: 0,7774
R^2 do modelo projetado: 0,2241
Erro padrão residual: 30,47
F-estatístico (modelo completo): 18,73 (p < 0,001)
F-estatístico (modelo projetado): 11,65 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 20: Resultados do Modelo 3.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−195,102	58,720	−3,323	0,006 **
SIZE_lag	−5,843	27,507	−0,212	0,835
DEPOSITO_lag	58,841	72,041	0,817	0,429
DESP_lag	−755,092	491,639	−1,536	0,149
SPREAD_lag	−198,023	58,390	−3,391	0,005 **
LIQUIDEZ_lag	−115,016	53,657	−2,144	0,052 *

Nota: R² ajustado: 0,7814
R² do modelo projetado: 0,238
Erro padrão residual: 30,19
F-estatístico (modelo completo): 17,85 (p < 0,001)
F-estatístico (modelo projetado): 11,75 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 21: Resultados do Modelo 3.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−212,70	67,33	−3,159	0,008 **
SIZE_lag	−12,96	12,62	−1,027	0,323
DEPOSITO_lag	46,62	78,75	0,592	0,564
DESP_lag	−1082,49	655,25	−1,652	0,122
SPREAD_lag	−184,62	69,81	−2,645	0,020 *
LIQUIDEZ_lag	−147,73	56,20	−2,629	0,021 *
PIB_lag	65,10	61,10	1,065	0,306
SELIC_lag	−444,77	171,24	−2,597	0,022 *
IPCA_lag	−151,75	147,39	−1,030	0,322

Nota: R² ajustado: 0,7284
R² do modelo projetado: 0,3560
Erro padrão residual: 33,65
F-estatístico (modelo completo): 17,09 (p < 0,001)
F-estatístico (modelo projetado): 15,12 (p < 0,001)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.2.8 Vendas com Defasagem

As Tabelas 22, 23 e 24 apresentam os resultados das regressões por efeitos fixos para a variável dependente VENDAS defasada, considerando, respectivamente, um modelo com controles institucionais básicos, uma especificação ampliada com variáveis adicionais de estrutura bancária e um modelo que incorpora variáveis macroeconômicas. Essa abordagem permite avaliar a existência de efeitos temporais associados ao foco em inteligência artificial sobre o crescimento real das receitas das instituições bancárias.

No modelo com controles institucionais básicos, a variável de interesse IA defasada apresenta coeficiente negativo, porém não estatisticamente significativo, indicando ausência de associação entre o foco em inteligência artificial no período anterior e o crescimento das receitas no período subsequente. O tamanho da instituição apresenta coeficiente negativo com significância marginal, enquanto as

variáveis spread e liquidez não exibem significância estatística. O modelo apresenta bom poder explicativo e significância conjunta dos parâmetros.

Na especificação ampliada com variáveis adicionais de estrutura bancária, o coeficiente associado à variável IA defasada torna-se negativo e estatisticamente significativo. Esse resultado indica que o foco em inteligência artificial no período anterior está associado a uma redução no crescimento real das receitas no período subsequente. Nesse modelo, as variáveis despesas, spread e depósitos apresentam efeitos positivos e estatisticamente significativos, enquanto tamanho e liquidez permanecem não significativos. O R^2 ajustado elevado e o teste F global confirmam a robustez da especificação.

Por sua vez, no modelo que incorpora variáveis macroeconômicas defasadas, a variável IA defasada apresenta coeficiente negativo, mas não estatisticamente significativo, indicando que a associação observada na especificação ampliada não se mantém quando controladas as condições macroeconômicas. Nesse modelo, destacam-se as variáveis despesas e IPCA defasado, com efeitos positivos e estatisticamente significativos, enquanto liquidez apresenta efeito negativo e significativo. As demais variáveis macroeconômicas não exibem significância estatística. O modelo apresenta poder explicativo moderado e significância conjunta dos parâmetros.

De forma geral, os resultados indicam que o foco em inteligência artificial não apresenta associação robusta e consistente com o crescimento real das receitas no período subsequente. A significância observada em uma das especificações não se mantém de maneira estável quando diferentes conjuntos de controles são incorporados. Em contrapartida, variáveis estruturais internas especialmente despesas operacionais, spread bancário e depósitos e fatores macroeconômicos específicos, como a inflação, emergem como determinantes mais relevantes do crescimento das receitas das instituições bancárias no período analisado.

Tabela 22: Resultados do Modelo 4.1

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,2362	0,2254	−1,048	0,314
SIZE_lag	−0,1204	0,0644	−1,869	0,084 *
SPREAD_lag	0,3170	0,2273	1,395	0,187
LIQUIDEZ_lag	−0,2817	0,4275	−0,659	0,522

Nota:
R^2 ajustado: 0,6042

R² do modelo projetado: −0,1930
Erro padrão residual: 0,1847
F-estatístico (modelo completo): 8,75 (p < 0,001)
F-estatístico (modelo projetado): 5,022 (p < 0,05)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 23: Resultados do Modelo 4.2

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,30935	0,14181	−2,181	0,048 **
SIZE_lag	0,06988	0,08237	0,848	0,412
DEPOSITO_lag	0,56158	0,27529	2,040	0,062 *
DESP_lag	11,55372	2,20022	5,251	0,000 ***
SPREAD_lag	0,69503	0,20967	3,315	0,006 **
LIQUIDEZ_lag	−0,42702	0,29481	−1,448	0,171

Nota: R² ajustado: 0,6947
R² do modelo projetado: 0,0799
Erro padrão residual: 0,1622
F-estatístico (modelo completo): 11,73 (p < 0,001)
F-estatístico (modelo projetado): 16,67 (p < 0,001)
Efeitos fixos: Instituição e Ano
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

Tabela 24: Resultados do Modelo 4.3

Variável	Coeficiente	Erro-padrão	t	p-valor
IA_lag	−0,03072	0,34387	−0,089	0,930
SIZE_lag	0,06567	0,09185	0,715	0,487
DEPOSITO_lag	0,70781	0,40340	1,755	0,103
DESP_lag	14,23192	2,13513	6,666	0,000 ***
SPREAD_lag	0,56464	0,26725	2,113	0,055 *
LIQUIDEZ_lag	−0,62998	0,26665	−2,363	0,034 *
PIB_lag	0,31527	0,42328	0,745	0,470
SELIC_lag	0,14315	0,61519	0,233	0,820
IPCA_lag	4,32028	0,90648	4,766	0,000 ***

Nota: R² ajustado: 0,3677
R² do modelo projetado: 0,3141
Erro padrão residual: 0,2334
F-estatístico (modelo completo): 4,489 (p < 0,001)
F-estatístico (modelo projetado): 37,95 (p < 0,001)
Efeitos fixos: Instituição
*p < 0,1; **p < 0,05; **p < 0,01
Fonte: Dados da pesquisa (2025).

4.3 Discussão de Resultados

4.3.1 Rentabilidade Sobre Ativos (ROA)

Os resultados indicam que o foco de IA, medida pela frequência de menções nos relatórios anuais, não apresentou efeito estatisticamente significativo sobre o ROA em nenhuma das especificações testadas, ainda que o coeficiente tenha mantido sinal positivo. Tal achado não confirma a hipótese H1, que previa impacto positivo e significativo do foco em IA sobre o retorno dos ativos.

Esses resultados dialogam com a literatura que destaca a natureza indireta e gradual dos efeitos da IA sobre o desempenho operacional. Chen, Esperança e Wang (2022) demonstram que a capacidade de IA influencia o desempenho empresarial por meio de fatores mediadores, como criatividade, gestão baseada em dados e integração de processos , mas raramente de forma direta. Essa evidência é coerente com a *resource-based view*, segundo a qual o valor estratégico da tecnologia depende da combinação de recursos tangíveis, intangíveis e humanos.

Mishra, Ewing e Cooper (2022) acrescentam que o foco em IA tende a gerar eficiência e lucratividade apenas quando acompanhado de estruturas organizacionais eficientes e cultura orientada à inovação, o que explica, em parte, a ausência de significância estatística observada no contexto brasileiro. O sistema bancário nacional é caracterizado por heterogeneidade tecnológica e diferenças no grau de digitalização entre instituições (Federação Brasileira de Bancos – FEBRABAN, 2022), o que limita a uniformidade dos resultados.

As variáveis de controle reforçam o peso dos determinantes tradicionais da rentabilidade bancária. Spreads e liquidez apresentaram efeitos negativos e significativos sobre o ROA, em linha com Bolt *et al.* (2012) e Lee e Hsieh (2013), que associam margens amplas e excesso de liquidez à menor eficiência financeira. Tais evidências sugerem que, no período analisado, a estrutura de intermediação e a gestão de recursos permaneceram mais determinantes para o desempenho do que os investimentos em IA.

Esses achados reforçam o argumento de Lichtenthaler (2019) de que a IA potencializa ganhos de produtividade apenas quando integrada a processos gerenciais sólidos e capacidades complementares. Assim, o resultado para o ROA indica que o impacto da IA sobre a eficiência operacional é latente e condicionado por fatores internos, mais do que imediato ou automático.

4.3.2 Rentabilidade Sobre o Patrimônio Líquido

De forma convergente aos resultados obtidos para o ROA, as estimativas relativas ao ROE indicam que o foco de inteligência artificial não exerceu impacto estatisticamente significativo sobre o retorno do patrimônio líquido, ainda que o coeficiente associado à variável de interesse apresente sinal positivo na maioria das regressões estimadas. Dessa forma, a hipótese H2, que previa um efeito positivo do foco em IA sobre a rentabilidade do capital próprio, não foi confirmada.

Esse resultado é consistente com a evidência empírica apresentada por Gyau *et al*. (2024), que apontam que a relação entre foco de inteligência artificial e desempenho financeiro bancário não se manifesta de maneira uniforme ou imediata, variando conforme o grau de integração tecnológica e organizacional das instituições. Assim, a ausência de significância estatística nos modelos estimados sugere que, no contexto analisado, a IA ainda não se traduz diretamente em ganhos mensuráveis de rentabilidade patrimonial.

O tamanho institucional apresentou efeito positivo e estatisticamente significativo em algumas especificações, reforçando que bancos de maior porte tendem a obter retornos mais elevados sobre o patrimônio líquido. Esse resultado está em linha com Athanasoglou, Brissimis e Delis (2008), que destacam o papel do porte institucional na diluição de custos, na diversificação de operações e na maior capacidade de absorção de investimentos estratégicos.

Adicionalmente, as variáveis spread e liquidez mantiveram efeitos negativos e estatisticamente significativos, corroborando Dietrich e Wanzenried (2011) e indicando que margens de intermediação elevadas e níveis excessivos de liquidez estão associados à menor eficiência na alocação de recursos, afetando negativamente a rentabilidade do capital próprio. Esses achados reforçam que fatores financeiros e estruturais tradicionais permanecem centrais na explicação do desempenho patrimonial dos bancos brasileiros.

Por fim, os resultados dialogam com Chen, Esperança e Wang (2022), ao evidenciar que o valor econômico associado à inteligência artificial depende de sua integração efetiva com processos organizacionais, estrutura de dados e capacidades humanas. No contexto nacional, essa integração ainda se apresenta de forma heterogênea, o que contribui para que a IA se manifeste predominantemente como um elemento de modernização organizacional, sem impacto direto e estatisticamente significativo sobre a rentabilidade patrimonial no período analisado.

4.3.3 Valor de Mercado (Q de Tobin)

A interpretação dos resultados associados ao Q de Tobin deve considerar as limitações inerentes a essa métrica, especialmente em um setor regulado e concentrado como o bancário. Diferentemente de indicadores contábeis, o Q de Tobin reflete expectativas de mercado, que podem reagir de forma sensível a investimentos tecnológicos, custos de adaptação organizacional e alterações no ambiente macroeconômico, independentemente da geração imediata de valor econômico. Nesse sentido, os efeitos negativos observados de forma defasada podem refletir reavaliações temporárias de risco e custo por parte dos investidores, e não necessariamente deterioração estrutural do desempenho das instituições.

A análise do Q de Tobin mostra que o coeficiente da IA foi negativo e marginalmente significativo apenas nas especificações defasadas, sugerindo que o foco de IA tende a reduzir o valor de mercado no curto prazo. Esse resultado contraria a hipótese H3, que previa relação positiva entre o foco em IA e a valorização de mercado.

Esse comportamento é compatível com Mogaji *et al*. (2022), que argumentam que investimentos intensivos em IA podem ser percebidos como arriscados, especialmente em economias emergentes, onde a confiança na automação algorítmica ainda é limitada. Bouhia *et al*. (2022) e Northey *et al*. (2022) reforçam essa visão, destacando que a reação negativa inicial dos investidores reflete incerteza quanto ao retorno econômico da inovação e assimetrias de informação sobre o estágio real de maturidade tecnológica.

Sob a ótica da teoria da sinalização (Janiszewski *et al*., 2017), as menções à IA nos relatórios corporativos funcionam como sinal de comprometimento estratégico, mas o mercado tende a interpretá-las como projeções de longo prazo, e não como evidência imediata de desempenho. Assim, o efeito negativo defasado pode representar o período de ajuste entre investimento e consolidação dos benefícios, típico das tecnologias de propósito geral (Brynjolfsson; Rock; Syverson, 2021).

As variáveis spread e liquidez mantiveram efeitos negativos robustos, confirmando o papel estrutural desses determinantes na avaliação de mercado, conforme Maffili (2007) e Lee e Hsieh (2013). Adicionalmente, o efeito negativo da

taxa Selic reforça a sensibilidade do valor de mercado à política monetária (Kohlscheen; Murcia Pabón; Contreras, 2018).

Dessa forma, o Q de Tobin evidencia que a IA ainda é percebida como investimento de custo elevado e retorno incerto, e que os sinais tecnológicos emitidos pelas empresas não se converteram, até o momento, em valorização de mercado mensurável.

Esses resultados dialogam diretamente com Mishra, Ewing e Cooper (2022), ao reforçar que a mensuração da IA via *disclosure* captura prioritariamente a dimensão simbólica e estratégica da tecnologia. No contexto brasileiro, essa sinalização parece ser interpretada de forma cautelosa pelo mercado, gerando efeitos negativos de curto prazo sobre o valor de mercado, sem se traduzir em ganhos operacionais imediatos.

4.3.4 Efeitos Defasados e Maturidade Tecnológica

Os modelos com defasagem temporal indicam que o impacto do foco de inteligência artificial não se manifesta de forma imediata sobre os indicadores contábeis de desempenho. Tanto para o ROA quanto para o ROE, os coeficientes associados à IA defasada permaneceram estatisticamente não significativos em todas as especificações, sugerindo ausência de efeitos diretos de curto prazo sobre a rentabilidade operacional e patrimonial das instituições bancárias.

Em contraste, no caso do Q de Tobin, os resultados apontam coeficientes negativos e estatisticamente significativos para a IA defasada, indicando que, no período subsequente à intensificação do foco em inteligência artificial, observa-se uma redução na valorização de mercado das instituições. Esse comportamento sugere uma reação inicial adversa do mercado, compatível com a interpretação de que investimentos em tecnologias de propósito geral implicam custos elevados, incerteza quanto aos retornos e ajustes organizacionais no curto prazo.

Essa evidência empírica é consistente com a literatura sobre a chamada curva de produtividade em “J”, conforme discutido por Brynjolfsson, Rock e Syverson (2021). No entanto, os resultados deste estudo não permitem afirmar a reversão desse efeito no médio ou longo prazo, uma vez que a variável de inteligência artificial não apresentou trajetória crescente ou efeitos positivos significativos nas especificações estimadas ao longo do tempo analisado.

Dessa forma, os achados sugerem que, no contexto dos bancos brasileiros, o foco em inteligência artificial não se comporta como uma variável constante ou progressivamente cumulativa ao longo do período, mas sim como um processo heterogêneo, marcado por custos iniciais e respostas assimétricas entre indicadores contábeis e de mercado. A ausência de efeitos positivos defasados sobre ROA e ROE indica que eventuais ganhos de eficiência ainda não se traduziram em melhorias mensuráveis de rentabilidade dentro do horizonte temporal considerado.

Esses resultados alinham-se às conclusões de Lichtenthaler (2019) e Fosso Wamba et al. (2024), que destacam que os benefícios econômicos do foco de tecnologias digitais dependem do grau de integração organizacional, da maturidade analítica e da capacidade de absorção das instituições. No caso analisado, os efeitos observados sugerem que o sistema bancário brasileiro ainda se encontra em uma fase de transição tecnológica, na qual os custos e ajustes associados ao foco da IA precedem a consolidação de retornos econômicos sustentáveis.

4.3.5 Crescimento de Receitas (VENDAS)

Os resultados referentes ao crescimento real das receitas indicam que a inteligência artificial não apresentou efeito estatisticamente significativo, nem contemporâneo nem defasado, sobre o desempenho comercial dos bancos, não confirmando a hipótese H4. Isso sugere que, no período analisado, o foco de IA ainda não se traduz em expansão direta das receitas operacionais, refletindo um processo de maturação tecnológica em curso no setor bancário brasileiro.

Por outro lado, variáveis estruturais como spread, despesas operacionais e liquidez mostraram associação estatisticamente significativa com as receitas, indicando que o desempenho comercial continua fortemente vinculado à eficiência interna e à gestão das operações de intermediação financeira. Em outras palavras, o crescimento das receitas depende, sobretudo, da capacidade dos bancos de administrar margens, custos e disponibilidade de recursos, mais do que do uso direto de ferramentas de IA, em consonância com a literatura sobre determinantes estruturais da rentabilidade bancária.

Esses resultados estão alinhados a Deshmukh e Boyd (2024) e Gerling e Lessmann (2024), que argumentam que a IA preditiva aprimora a projeção de receitas e o marketing analítico, mas seus efeitos econômicos requerem tempo para se

materializar. Da mesma forma, Basten e Juelsrud (2023) destacam que os impactos da IA sobre vendas dependem da integração entre dados de clientes, segmentação e automação comercial, dimensões que ainda se encontram em fase de amadurecimento nos bancos brasileiros.

Essas evidências convergem também com Chen, Esperança e Wang (2022), segundo os quais a IA atua como mediadora do desempenho, ao aprimorar decisões e a alocação de recursos, mas não como determinante direto do crescimento no curto prazo. Dessa forma, o impacto econômico da inteligência artificial mostra-se indireto e gradual, condicionado pela maturidade organizacional e pela integração tecnológica das instituições. Essa constatação reforça a necessidade de considerar horizontes temporais mais amplos e abordagens dinâmicas de análise para capturar os efeitos estruturais e cumulativos da IA sobre o desempenho bancário.

4.3.6 Fatores Estruturais e Macroeconômicos

Os resultados obtidos indicam que variáveis estruturais e macroeconômicas continuam exercendo influência relevante sobre o desempenho bancário no Brasil. Entre as variáveis internas, spread e liquidez apresentaram efeitos negativos e estatisticamente significativos sobre as métricas de desempenho contábil e de mercado, corroborando a literatura clássica (Bolt *et al*., 2012; Lee e Hsieh, 2013). Esse resultado reforça que margens de intermediação elevadas e excesso de recursos ociosos estão associados à menor eficiência financeira e a posturas operacionais conservadoras. Em contrapartida, o tamanho institucional apresentou impacto positivo sobre a rentabilidade, indicando que as economias de escala e a capacidade de investimento permanecem fatores determinantes para retornos superiores no setor bancário.

As variáveis macroeconômicas, representadas pelo PIB e pela taxa Selic, mostraram-se significativas em alguns modelos, evidenciando que o ambiente econômico afeta diretamente a rentabilidade contábil (ROA e ROE) e a valorização de mercado (Q de Tobin) das instituições bancárias (Bolt *et al*., 2012; Kohlscheen *et al.*, 2018). Em termos econômicos, ciclos de crescimento e condições monetárias mais restritivas influenciam tanto a capacidade de geração de resultados operacionais quanto as expectativas dos investidores em relação ao valor futuro das instituições.

Assim, as condições macroeconômicas atuam como fatores condicionantes do desempenho financeiro e do valor de mercado, alterando simultaneamente a eficiência operacional interna e a precificação das instituições pelo mercado. Dessa forma, a inclusão dessas variáveis como controles reforça a robustez dos modelos estimados, ao permitir isolar com maior precisão o efeito específico da inteligência artificial sobre os indicadores de desempenho analisados.

De forma geral, os resultados empíricos revelam um padrão contrastante entre os indicadores analisados. Enquanto o foco de inteligência artificial não se associou de maneira estatisticamente significativa às métricas contábeis de desempenho (ROA, ROE) e ao crescimento real das receitas, observou-se um efeito negativo e estatisticamente significativo sobre o Q de Tobin quando considerada a defasagem temporal. Essa aparente contradição sugere que os impactos da inteligência artificial não se manifestam de forma homogênea entre desempenho operacional e percepção de valor pelo mercado.

Uma interpretação plausível é que os investimentos em inteligência artificial geram custos iniciais e exigem ajustes organizacionais que afetam negativamente as expectativas dos investidores no curto prazo, sem, contudo, comprometer imediatamente os resultados contábeis das instituições. Assim, a ausência de efeitos sobre ROA, ROE e VENDAS não invalida o efeito observado sobre o Q de Tobin, mas indica que o mercado reage de maneira mais sensível aos custos e incertezas associados ao foco tecnológico do que aos ganhos operacionais de curto prazo.

5 CONCLUSÃO

A presente dissertação analisou o impacto da inteligência artificial sobre o desempenho financeiro e de mercado das instituições bancárias brasileiras listadas na B3, no período de 2013 a 2023. Partindo do reconhecimento de que a IA constitui um dos principais vetores da transformação digital no setor financeiro, o estudo investigou se o foco estratégico em IA se traduz em melhorias mensuráveis de desempenho em um contexto institucional característico de economias emergentes.

Com base em uma abordagem quantitativa, descritiva e longitudinal, foram estimados modelos de dados em painel com efeitos fixos, contemplando quatro dimensões de desempenho: rentabilidade sobre ativos, rentabilidade sobre o patrimônio líquido, valor de mercado (Q de Tobin) e VENDAS. As análises incorporaram controles estruturais, como tamanho institucional, spread bancário, liquidez e despesas operacionais e variáveis macroeconômicas, incluindo o Produto Interno Bruto e a taxa Selic, com o objetivo de isolar o efeito específico da inteligência artificial sobre o desempenho bancário.

Os resultados empíricos indicaram que o foco de inteligência artificial não exerceu impacto estatisticamente significativo sobre os indicadores contábeis de rentabilidade (ROA e ROE) nem sobre o crescimento real das receitas no período analisado. Embora os coeficientes associados à variável de IA tenham mantido, em geral, sinal positivo, sua magnitude mostrou-se reduzida, sugerindo que eventuais variações no foco estratégico em IA implicariam efeitos econômicos diretos limitados sobre essas métricas. Dessa forma, as hipóteses H1, H2 e H4 não foram confirmadas, indicando que os benefícios associados à IA ainda não se refletem de maneira imediata nos indicadores financeiros tradicionais.

Em contraste, observou-se que a inteligência artificial apresentou efeito negativo e estatisticamente significativo sobre o Q de Tobin quando considerada de forma defasada. Esse resultado sugere que o mercado reage de forma cautelosa aos investimentos em IA no curto prazo, interpretando-os como projetos associados a custos iniciais elevados, incertezas quanto ao retorno e necessidade de ajustes organizacionais. Tal evidência é consistente com a Teoria da Sinalização, segundo a qual inovações tecnológicas podem inicialmente ampliar a assimetria informacional e

elevar a percepção de risco, sendo valorizadas pelo mercado apenas após a demonstração concreta de seus benefícios.

De forma consistente ao longo dos modelos estimados, as variáveis estruturais e macroeconômicas mostraram-se determinantes relevantes do desempenho bancário. O spread bancário e a liquidez exerceram efeitos negativos e estatisticamente significativos sobre o desempenho contábil e a valorização de mercado, indicando que margens de intermediação elevadas e excesso de recursos ociosos estão associados a menor eficiência financeira e a posturas operacionais mais conservadoras. Em contrapartida, o tamanho institucional apresentou impacto positivo sobre a rentabilidade, evidenciando o papel das economias de escala e da capacidade de investimento no setor bancário. As variáveis macroeconômicas, especialmente o PIB e a taxa Selic, mostraram-se relevantes em parte das especificações, confirmando que o ambiente econômico atua como moderador do desempenho financeiro e da percepção de valor das instituições.

Em conjunto, os resultados revelam um comportamento assimétrico entre desempenho contábil e valorização de mercado. A inteligência artificial não afeta diretamente os resultados operacionais no curto prazo, mas influencia negativamente a percepção de valor das instituições quando considerados os efeitos temporais. Esse padrão reforça a interpretação de que a IA atua, no período analisado, predominantemente como um vetor estratégico e indireto de transformação organizacional, associado a mudanças em processos internos, gestão da informação e estrutura operacional, sem se traduzir em ganhos quantitativos imediatos nas métricas financeiras tradicionais.

Esses achados devem ser interpretados à luz do contexto institucional brasileiro, caracterizado por elevada concentração bancária, spreads historicamente elevados e forte regulação prudencial. Nesse ambiente, a inteligência artificial tende a assumir papel predominantemente organizacional e operacional, voltado à automação de processos internos, à gestão de riscos e ao atendimento a exigências regulatórias, o que contribui para explicar a ausência de efeitos diretos sobre a rentabilidade e o crescimento das receitas no período analisado.

Ao confrontar os resultados com a literatura, observa-se convergência com estudos que tratam a inteligência artificial como uma tecnologia de propósito geral, cujos impactos econômicos dependem da maturidade organizacional, da integração

aos processos decisórios e da consolidação de capacidades analíticas complementares. Assim, os benefícios associados ao foco de IA tendem a emergir de forma gradual e não linear, antecedendo o reflexo quantitativo nas métricas financeiras tradicionais.

Entre as limitações do estudo, destaca-se a mensuração da variável foco em IA por meio da frequência de menções em relatórios anuais, que capta a ênfase discursiva e estratégica das instituições, mas não necessariamente o nível efetivo de implementação tecnológica. Adicionalmente, a heterogeneidade do sistema bancário brasileiro e o período analisado, ainda representativo de uma fase inicial de foco tecnológico podem limitar a observação de efeitos econômicos mais pronunciados.

Como agenda para pesquisas futuras, sugere-se o aprimoramento da mensuração da inteligência artificial por meio da combinação de análise textual com métricas financeiras e operacionais, a ampliação da perspectiva longitudinal com modelos dinâmicos capazes de captar efeitos acumulados e não lineares, bem como a integração de técnicas de machine learning para explorar relações complexas entre foco tecnológico, estrutura institucional e desempenho financeiro. Estudos qualitativos complementares também podem contribuir para aprofundar a compreensão dos mecanismos organizacionais que condicionam o impacto da IA no setor bancário.

Dessa forma, conclui-se que a inteligência artificial representa um ativo estratégico em processo de incorporação no sistema bancário brasileiro. Embora seus benefícios diretos sobre as métricas financeiras analisadas não se mostrem estatisticamente significativos no período considerado, os resultados indicam que a IA exerce efeitos estruturais relevantes sobre a organização, a eficiência operacional e a capacidade de aprendizado das instituições, configurando-se como um elemento central da transformação organizacional e da modernização do setor bancário.

REFERÊNCIAS

ABEL, Andrew B. Dynamic effects of permanent and temporary tax policies in a q model of investment. *Journal of Monetary Economics*, v. 9, n. 3, p. 353–373, 1982.

AFANASIEFF, Tarsila Segalla et al. The determinants of bank interest spread in Brazil. *Money Affairs*, v. 15, n. 2, p. 183–207, 2002.

ATHANASOGLOU, Panayiotis P.; BRISSIMIS, Sophocles N.; DELIS, Matthaios D. Bank-specific, industry-specific and macroeconomic determinants of bank profitability. *Journal of international financial Markets*, Institutions and Money, v. 18, n. 2, p. 121-136, 2008.

AUERBACH, Alan J. Taxation, corporate financial policy and the cost of capital. National Bureau of Economic Research, 1982.

B3. *Valor de mercado*. Disponível em: https://www.b3.com.br/pt_br/noticias/valor-de-mercado.htm?utm_source. Acesso em: 10 mar. 2025.

Bag, S., Gupta, S., Kumar, A., & Sivarajah. An integrated artificial intelligence framework for knowledge creation and B2B marketing rational decision making for improving firm performance. *Industrial marketing management*, v. 92, p. 178-189, 2021.

BAG, Surajit et al. Role of institutional pressures and resources in the adoption of big data analytics powered artificial intelligence, sustainable manufacturing practices and circular economy capabilities. *Technological Forecasting and Social Change*, v. 163, p. 120420, 2021.

BALTAGI, Badi Hani; BALTAGI, Badi H. Econometric analysis of panel data. Chichester: *John Wiley & Sons*, 2008.

BASTEN, Christoph; JUELSRUD, Ragnar. Cross-Selling in Bank-Household Relationships: Mechanisms and Implications for Pricing. *The Review of Financial Studies*, Oxford, v. 00, n. 0, p. 1-34, 2023. DOI: 10.1093/rfs/hhad062.

BECK, Thorsten et al. Financial innovation: The bright and the dark sides. *Journal of Banking & Finance*, v. 72, p. 28-51, 2016.

BEYER, Anne et al. The financial reporting environment: Review of the recent literature. *Journal of Accounting and Economics*, v. 50, n. 2-3, p. 296-343, 2010.

BITTENCOURT, Wanderson Rocha et al. Rentabilidade em bancos múltiplos e cooperativas de crédito brasileiros. *Revista de Administração Contemporânea*, v. 21, p. 22-40, 2017.

BLACK, Bernard S.; DE CARVALHO, Antonio Gledson; SAMPAIO, Joelson O. The evolution of corporate governance in Brazil. Emerging Markets Review, v. 20, p. 176–195, 2014.

BLAS, Jesus et al. Integración de la Inteligencia Artificial en el Marketing: Métodos y Estrategias para Aumentar el Valor Empresarial. *Journal of Economics Finance and International Business*, v. 7, n. 1, 2023.

BOLT, Wilko et al. Bank profitability during recessions. Journal of Banking & Finance, v. 36, n. 9, p. 2552-2564, 2012.

BOTOSAN, Christine A.; PLUMLEE, Marlene A. A re-examination of disclosure level and the expected cost of equity capital. *Journal of Accounting Research*, v. 40, n. 1, p. 21-40, 2002.

BRASIL. CÂMARA DOS DEPUTADOS. Comissão de Defesa do Consumidor. Notas Taquigráficas da 4ª Sessão Legislativa Ordinária da 56ª Legislatura – Audiência Pública Extraordinária (Semipresencial), de 31 de maio de 2022. Brasília, DF, 2022.

BRASIL. Presidência da República. Mensagem ao Congresso Nacional 2022. Brasília, DF, 2022.

BRYMAN, Alan. Social research methods. *Oxford university press*, 2016.

BRYNJOLFSSON, Erik; HITT, Lorin M. Beyond computation: information technology, organizational transformation and business performance. *Journal of Economic Perspectives*, Pittsburgh, v. 14, n. 4, p. 23–48, 2000.

BRYNJOLFSSON, Erik; McAFEE, Andrew; SORELL, Fiona. The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies. *New York*: *W. W. Norton & Company*, 2016.

BRYNJOLFSSON, Erik; MCELHERAN, Kristina. The rapid adoption of data-driven decision-making. *American Economic Review: Papers and Proceedings*, v. 106, n. 5, p. 133–139, 2016.

BRYNJOLFSSON, Erik; ROCK, Daniel; SYVERSON, Chad. The productivity J-curve: how intangibles complement general purpose technologies. *American Economic Journal: Macroeconomics, Providence*, v. 13, n. 1, p. 333–372, jan. 2021. DOI: 10.1257/mac.20180386.

BUSINESSWIRE.COM. Disponível em: https://www.businesswire.com/. Acesso em: 04 jul. 2025.

CAMPOS, Octávio Valente; BOINA, Terence; Por que (não) excluir empresas do setor financeiro em amostras nas pesquisas em Contabilidade e Finanças? Análise empírica no mercado de capitais brasileiro. In: *CONGRESSO USP DE CONTROLADORIA E CONTABILIDADE*, 23., 2023, São Paulo. *Anais.* São Paulo: USP/Fipecafi, 2023.

CARVALHAL DA SILVA, A. L.; LEAL, R. P. C. Corporate governance index, firm valuation and performance in Brazil. Revista Brasileira de Finanças, v. 3, n. 1, p. 1-18, 2005. DOI: 10.12660/rbfin.v3n1.2005.1143.

CARVALHO, Fabiana Miranda Reis de; DARADDA, Lidiane Fernanda Rocha; DAL VESCO, Delci Grapegia; FIIRST, Clóvis. *A influência dos componentes de capital intelectual no desempenho econômico/financeiro e valor de mercado (Q-Tobin) nas empresas brasileiras listadas na BMF&Bovespa*, 2016.

CATAPAN, A.; COLAUTO, R. D. Governança corporativa: uma análise de sua relação com o desempenho econômico-financeiro de empresas cotadas no Brasil nos anos de 2010–2012. *Contaduría y Administración*, v. 59, n. 3, p. 137-164, 2014.

CECCON, Denny. Relatório da FEBRABAN mostra que IA é prioridade para os bancos brasileiros. 22 jun. 2022. Disponível em: https://iaexpert.academy/2022/06/22/relatorio-febraban-mostra-ia-prioridade-para-bancos-brasileiros/. Acesso em: 16 jul. 2025.

CHARLES, Muo; OCHIENG, Sei Benson. Strategic outsourcing and firm performance: a review of literature. *International Journal of Social Science and Humanities Research (IJSSHR)*, ISSN, p. 2959-7056, 2023.

CHEN, Donghua; ESPERANÇA, José Paulo; WANG, Shaofeng. The impact of artificial intelligence on firm performance: an application of the resource-based view to e-commerce firms. *Frontiers in Psychology*, v. 13, p. 1-15, 2022. DOI: https://doi.org/10.3389/fpsyg.2022.884830.

CHUNG, K. H.; PRUITT, S. W. A simple approximation of Tobin's q. *Financial Management,* v. 23, n. 3, p. 70-74, 1994. DOI: https://doi.org/10.2307/3665623.
CSU. About CSU. Disponível em: https://www2.csu.com.br/en/about-csu/?utm_source. Acesso em: 04 jul. 2025.

CSU. Services to shareholders – FAQ. Disponível em: https://ri.csu.com.br/en/services-to-shareholders/faq/?utm_source. Acesso em: 04 jul. 2025.

CVM. Ofício de deferimento de cancelamento do registro de companhia aberta do Banco Alfa de Investimento. Brasília, 2024. Disponível em: https://www.gov.br/cvm/pt-br. Acesso em: 29 abr. 2025.

DAMI, A. B. T. Governança corporativa: estrutura de propriedade, desempenho e valor–uma análise de empresas brasileiras. 2006. *Dissertação de mestrado. Universidade Federal de Uberlândia*, Uberlândia, MG, Brasil.

DE PAULA, Luiz Fernando Rodrigues. Dinâmica da firma bancária: uma abordagem não-convencional. *Revista Brasileira de Economia*, v. 53, n. 3, p. 323-356, 1999.

DEMIRGÜÇ-KUNT, Asli; HUIZINGA, Harry. Bank activity and funding strategies: the impact on risk and returns. *Journal of Money, Credit and Banking*, v. 42, n. 7, p. 1250–1275, 2010.

DESHMUKH, Aarav; BOYD, Lilah. Predictive analytics in banking: leveraging AI for strategic forecasting and market positioning. SSRN *Electronic Journal*, 2024. Disponível em: https://ssrn.com/abstract=5393028
. Acesso em: 16 jul. 2025

DIAS, Magali Aparecida Medeiros; ALBERTO, José Guilherme Chaves; LEITE, Adriano Cordeiro. As cotações das ações dos maiores bancos refletem a lucratividade do setor bancário no período pré-crise do subprime?. *Brazilian Applied Science Review*, v. 2, n. 3, p. 999–1014, 2018

DORNBUSCH, R. Expectations and Exchange Rate Dynamics. *Journal of Political Economy*, v. 84, n. 6, p. 1161-1176, 1976.

DOUMPOS, Michalis et al. Operational research and artificial intelligence methods in banking. *European Journal of Operational Research*, v. 306, n. 1, p. 1-16, 2023.

DUBÉ, Laurette et al. Convergent innovation in food through big data and artificial intelligence for societal-scale inclusive growth. *Technology Innovation Management Review*, v. 8, n. 2, 2018.

EFTHYMIOU, Fotis et al. The power of AI-generated voices: How digital vocal tract length shapes product congruency and ad performance. *Journal of Interactive Marketing*, v. 59, n. 2, p. 117-134, 2024.

FEBRABAN. Inteligência Artificial aproxima bancos dos clientes e torna atendimento mais personalizado e consultivo. São Paulo: *FEBRABAN*, 2022. Disponível em: https://portal.febraban.org.br/noticia/4310/pt-br/?utm_source. Acesso em: 15 jul. 2025.

FEBRABAN. Segurança cibernética, Inteligência Artificial e Open Finance são prioridades para os bancos em 2022. São Paulo: *FEBRABAN*, 2022. Disponível em: https://portal.febraban.org.br/noticia/3474/pt-br?utm_source. Acesso em: 15 jul. 2025.

FERREIRA, R. N.; SANTOS, A. C.; LOPES, A. L. M.; NAZARETH, L. G. C.; FONSECA, R. A. Governança corporativa, eficiência, produtividade e desempenho. RAM. Revista de Administração Mackenzie, v. 14, p. 134-164, 2013.

FORTUNA, Eduardo. Mercado financeiro. 17. ed. Rio de Janeiro: Qualitymark Editora Ltda, 2008.

FOSSO WAMBA, Samuel et al. Artificial intelligence capability and firm performance: a sustainable development perspective by the mediating role of data-driven culture. *Information Systems Frontiers*, p. 1-15, 2024.

FRANCIS, Jennifer; SCHIPPER, Katherine. Have financial statements lost their relevance? *Journal of Accounting Research*, v. 37, n. 2, p. 319-352, 1999.

FREIXAS, Xavier; ROCHET, Jean-Charles. Microeconomics of banking. MIT press, 2008.

FRIESS, Maximilian et al. The contingent effects of innovative digital sales technologies on B2B firms' financial performance. *International Journal of Research in Marketing*, 2024.

GERLING, Christopher; LESSMANN, Stefan. Leveraging AI and NLP for Bank Marketing: A Systematic Review and Gap Analysis. arXiv preprint arXiv:2411.14463, 2024.

GOMES, Dennis dos Santos. Inteligência Artificial: conceitos e aplicações. *Revista Olhar Científico*, v. 1, n. 2, p. 234-246, 2010.

GREENE, William H. Reconsidering heterogeneity in panel data estimators of the stochastic frontier model. *Journal of Econometrics*, v. 126, n. 2, p. 269–303, 2005. DOI: 10.1016/j.jeconom.2004.05.003

GREENE, William. Reconsidering heterogeneity in panel data estimators of the stochastic frontier model. *Journal of Econometrics*, v. 126, n. 2, p. 269–303, 2005. DOI: 10.1016/j.jeconom.2004.05.003.

GREENWOOD, Robin; IALENTI, Robert; SCHARFSTEIN, David. The Evolution of Financial Services in the United States. *Annual Review of Financial Economics*, v. 17, 2025.

GYAU, E. B. et al. Transforming banking: Examining the role of AI technology innovation in boosting banks financial performance. International Review of Financial Analysis, [S. l.], v. 96, art. 103700, 2024. Disponível em: https://doi.org/10.1016/j.irfa.2024.103700

GYAU, Emmanuel Baffour et al. Transforming banking: Examining the role of AI technology innovation in boosting banks financial performance. *International Review of Financial Analysis*, v. 96, p. 103700, 2024.

HAUSMAN, J. A. Specification tests in econometrics. *Econometrica*, v. 46, n. 6, p. 1251–1271, 1978.

HE, Z.; RAO, V. R. Methods for Causal Inference in Marketing. *Foundations and Trends® in Marketing*, v. 18, n. 3–4, p. 176–309, 2024.

HERNANDEZ, J. M. C.; BASSO, K.; BRANDÃO, M. M. Pesquisa Experimental em Marketing. Brazilian *Journal of Marketing* - BJM, v. 13, n. 2, p. 98-117, 2014.

HUANG, M. H.; RUST, R. T. Artificial intelligence in service. *Journal of Service*, 2018.
HUANG, Ming-Hui; RUST, Roland T. A framework for collaborative artificial intelligence in marketing. *Journal of Retailing*, v. 98, n. 2, p. 209-223, 2022.

HUANG, Ming-Hui; RUST, Roland T. Artificial Intelligence in Service. *Journal of Service Research*, v. 21, n. 2, p. 155–172, 2018. DOI: 10.1177/1094670517752459

HUANG, Ming-Hui; RUST, Roland T. Engaged to a robot? The role of AI in service. *Journal of Service Research*, v. 24, n. 1, p. 30-41, 2021.

JANISZEWSKI, Vanessa Janiszewski et al. Relação da Teoria da Sinalização com o Desempenho das Empresas a partir dos seus Indicadores de Performance de Divulgação Voluntária. *Revista de Contabilidade & Controladoria*, v. 9, n. 2, p. 93, 2017.

JANOŠEVIĆ, Stevo; DŽENOPOLJAC, Vladimir; BONTIS, Nick. Intellectual capital and financial performance in Serbia. *Knowledge and Process Management*, v. 20, n. 1, p. 1-11, 2013. DOI: https://doi.org/10.1002/kpm.1404

KATSIKEAS, Constantine S. et al. Assessing performance outcomes in marketing. *Journal of Marketing*, v. 80, n. 2, p. 1-20, 2016.

KAUR, Dr. Navleen et al. Banking 4.0: 'the influence of artificial intelligence on the banking industry & how ai is changing the face of modern day banks'. *International Journal of Management*, v. 11, n. 6, 2020.

KENNEDY, Peter. A Guide to Econometrics. 4th ed. *Cambridge, Massachusetts*: The MIT Press, 1998.

KENNEDY, Peter. A Guide to Econometrics. 5. ed. *Cambridge*, MA: MIT Press, 1998.

KLAPPER, Leora F.; LOVE, Inessa. Corporate governance, investor protection, and performance in emerging markets. Journal of corporate Finance, v. 10, n. 5, p. 703-728, 2004.

KOHLSCHEEN, Emanuel; MURCIA PABÓN, Andrés; CONTRERAS, Julieta. Determinants of bank profitability in emerging markets. 2018.

KUMAR, Vipin et al. Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, v. 61, n. 4, p. 135-155, 2019.

LAKATOS, E. M. *Fundamentos de metodologia científica*. 2017.
LEE, Chien-Chiang; HSIEH, Meng-Fen. The impact of bank capital on profitability and risk in Asian banking. Journal of international money and finance, v. 32, p. 251-281, 2013.

LICHTENTHALER, Ulrich. An intelligence-based view of firm performance: profiting from artificial intelligence. *Journal of Innovation Management*, v. 7, n. 1, p. 7-20, 2019.

LIU, L.; WANG, X.; TANG, L.; SUN, Z.; WANG, X. Exploring the Conditional ESG Payoff of AI Adoption: The Roles of Learning Capability, Digital TMT, and Operational Slack. *Systems*, v. 13, n. 6, 399, 2025.

LONGONI, C.; BONEZZI, A.; MOREWEDGE, C. K. Resistance to medical artificial intelligence. *Journal of Consumer Research*, v. 46, n. 4, p. 629-650, 2019.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados*, v. 35, p. 85-94, 2021.

MACEDO, Marcelo Alvaro da Silva; SILVA, Fabrícia de Farias da; SANTOS, Rodrigo Melo. Análise do mercado de seguros no Brasil: uma visão do desempenho organizacional das seguradoras no ano de 2003. *Revista Contabilidade & Finanças*, v. 17, p. 88-100, 2006.

MAFFILI, Dener William; BRESSAN, Aureliano Angel; SOUZA, Antônio Artur de. Estudo da rentabilidade dos bancos brasileiros de varejo no período de 1999 a 2005. *Contabilidade Vista & Revista*, Belo Horizonte, v. 18, n. 2, p. 117-138, abr./jun. 2007.

MARQUES, Frank Borges; FREITAS, Vérica; PAULA, Veronica Angelica Freitas de. Cadê o banco que estava aqui? O impacto dos bancos digitais no mercado brasileiro. *JISTEM-Journal of Information Systems and Technology Management*, v. 19, p. e202219002, 2022.

MISHRA, Sagarika; EWING, Michael T.; COOPER, Holly B. Artificial intelligence focus and firm performance. *Journal of the Academy of Marketing Science*, v. 50, n. 6, p. 1176-1197, 2022.

MODRO, Wilton Moisés; DOS SANTOS, José Odálio. A relação entre o retorno das ações ordinárias, métricas de desempenho e fatores econômicos: um estudo dos três principais bancos brasileiros entre 2001 e 2010. *Revista Administração em Diálogo-RAD*, v. 17, n. 3, p. 33-58, 2015.

MOGAJI, E. et al. Guest editorial: Artificial intelligence in financial services marketing. International Journal of Bank Marketing, [S. l.], v. 40, n. 6, p. 1097-1101, 2022. Disponível em: https://doi.org/10.1108/IJBM-09-2022-617.

MOURA, Juliana de Souza et al. A evolução digital do mercado bancário brasileiro: análise comparativa entre bancos tradicionais e bancos digitais. 2023.

NGUYEN, H. Credit risk and financial performance of commercial banks: evidence from Vietnam. SSRN Electronic Journal, 2023. DOI: 10.2139/ssrn.4424408

NOONE, Breffni M.; LIN, Michael S.; SHARMA, Amit. Firm performance during a crisis: Effects of adhocracy culture, incremental product innovation, and firm size. *Journal of Hospitality & Tourism Research*, v. 48, n. 1, p. 153-183, 2024.

PAULO, Edilson; MOTA, Renato Henrique Gurgel. Ciclos econômicos e estratégias de gerenciamento de resultados contábeis: um estudo nas companhias abertas brasileiras. *Revista Contabilidade & Finanças*, v. 30, p. 216-233, 2019.

PORTAL FEBRABAN. Segurança cibernética, Inteligência Artificial e Open Finance são prioridades para os bancos em 2022. 2022. Disponível em: https://portal.febraban.org.br/noticia/3781/pt-br. Acesso em: 16 jul. 2025.

PRATONO, Aluisius Hery. From social network to firm performance: The mediating effect of trust, selling capability and pricing capability. *Management Research Review*, v. 41, n. 6, p. 680-700, 2018.

RAHMAN, Muhammad Sabbir; HOSSAIN, Md Afnan; ABDEL FATTAH, Fadi Abdel Muniem. Does marketing analytics capability boost firms' competitive marketing performance in data-rich business environment?. *Journal of Enterprise Information Management*, v. 35, n. 2, p. 455-480, 2022.

RAMOS, Pedro Costa. Theoretical Model to Analyze the Influence of Outsourcing on Industrial Business Value Creation. *Universal Journal of Management*, v. 8, n. 1, p. 1-11, 2020.

SHEHZAD, Choudhry Tanveer; DE HAAN, Jakob; SCHOLTENS, Bert. The relationship between size, growth and profitability of commercial banks. *Applied economics*, v. 45, n. 13, p. 1751-1765, 2013.

SODRÉ, Vladimir Guimarães Farias. Eficiência e rentabilidade em instituições financeiras bancárias no Brasil. 2020.

SONG, Mei. AI-powered predictive models for accurate sales forecasting. Massachusetts Institute of Technology, 2022. Disponível em: https://www.researchgate.net/publication/386785093. Acesso em: 27 out. 2025.

SRINIVASAN, S.; HANSSENS, D. M. Marketing and firm value: Metrics, methods, findings, and future directions. *Journal of Marketing Research*, v. 46, n. 3, p. 293-312, 2009.

TAJEDDINI, K.; TRUEMAN, M.; LARSEN, G. Examining the effect of market orientation on innovativeness. *Journal of Marketing Management*, v. 22, n. 5–6, p. 529–551, 2006. DOI: 10.1362/026725706777978640.

WOOLDRIDGE, Jeffrey M. Econometric analysis of cross section and panel data. MIT press, 2010.

WOOLDRIDGE, Jeffrey M. Econometric Analysis of Cross Section and Panel Data. 2. ed. *Cambridge*, MA: MIT Press, 2010.

YOON, B.; LEE, S.; CHO, M. Corporate social responsibility and financial performance: new evidence from the Korean market. *SAGE Open*, v. 14, n. 1, p. 1-15, 2024. DOI: 10.1177/21582440241255196.

APÊNDICE I

Apêndice I: Palavras de busca

Palavras			
Reconhecimento de padrões	Classificação de intenção	Identificação do idioma	Robô
Reconhecimento de fala	Preenchimento de slot	Extração de entidade nomeada	Inteligência artificial
OCR	Reconhecimento de entidade	Reconhecimento de entidade nomeada	Deep learning
Reconhecimento de caligrafia	Tradução semântica	Extração de relacionamento	Rede neural
Reconhecimento facial	Maquina de tradução	Extração de terminologia	Rede neural artificial
Processamento de linguagem natural	Chatbot	Automação robótica de processos	Rede neural convolucional
Compreensão da linguagem natural	Agente autônomo	Robótico	Rede neural recorrente
Rede adversária generativa	Rede feedforward	Aprendizado de máquina	Aprendizado de máquina supervisionado
Aprendizado de máquina não supervisionado	Aprendizagem por reforço	Registro de modelo	Manifestação do modelo
Análise preditiva	Estrutura cognitiva	Serviços cognitivos	Modelo de aprendizado de máquina
Estrutura de aprendizado de máquina	Treinamento de modelo	Segmentação de clientes	Mecanismos de personalização
Inferência	Incorporação	Algoritmo	Automação
Ciência de dados	Aquisição de dados	Processamento de dados	Modelagem
Operações de IA	AIOps	Operações de aprendizado de máquina	Pipelines de dados
Python	TensorFlow	Google cloud platform	Tensor
Tensor Processing Unit	TPU	Cuda	Fluxo de diálogo
Word2Vec	Doc2Vec	GloVe	Codificação de frase universal
Incorporações de modelos de linguagem	Modelo de linguagem de rede neural	Análise semântica latente	Modelos de espaço vetorial
Rede de média profunda	Predição	Trabalhos de matemática	Blocos de dados
H20.ai	Robô de dados	Aprendizado de máquina Amazon	Aprendizado de máquina do Google Cloud
IBM Watson	Aprendizado de máquina do Microsoft Azure	Kit de ferramentas cognitivas do Azure	Apache SystemML
Apache Spark MLlib	Apache Mahout	Caffe	OpenNN
Torch	Deeplearning4j	Veles	Theano
Aprendizagem Scikit	Web semântica	Visão computacional	Reconhecimento de objeto
Reconhecimento inteligente de palavras	Análise inteligente de imagens	Processamento de imagem	Manutenção de modelo

Monitoramento de modelo	validação do modelo	Transferir aprendizagem	Aprendizagem instantânea
Agrupamento	MLOps	Ontologias de aprendizado de máquina	Ética da IA
Viés de aprendizado de máquina	Viés de máquina	Dados de treinamento	Mecanismo de cluster
Modelagem de tópico	RapidMiner	KNIME	Alteryx
SAS	PyTorch	Keras	Pandas

Fonte: Adaptado de Mishra, Ewing e Cooper (2022).

APÊNDICE II

Link-R

APÊNDICE III

Link-Python

APÊNDICE IV

	Ano	Quantidade	Total_palavras	ROA	ROE	IA	QTOBIN	SIZE	DEPOSITO	DESP	SPREAD	LIQUIDEZ	DPAN	VARPIB	SELICMETA	IPCA
Ano																
Quantidade	0.12															
Total_palavras	0.13	0.73***														
ROA	0.24***	0.05	0.07													
ROE	0.26***	0.14*	0.14	0.90***												
IA	0.01	0.78***	0.20**	0.02	0.07											
QTOBIN	0.11	0.36***	0.41***	0.44***	0.35***	0.21**										
SIZE	0.14	0.73***	0.78***	0.20**	0.27***	0.40***	0.46***									
DEPOSITO	0.15*	-0.08	-0.23***	-0.32***	-0.21**	0.09	-0.23***	-0.44***								
DESP	0.36***	0.04	0.11	0.27***	0.28***	-0.12	0.21**	0.12	-0.05							
SPREAD	-0.22**	0.07	0.14	-0.32***	-0.33***	0.01	-0.18**	0.24***	-0.47***	-0.48***						
LIQUIDEZ	0.06	-0.29***	-0.20**	0.14	0.18**	-0.30***	-0.15*	-0.10	-0.38***	0.46***	0.01					
DPAND	0.34***	0.18**	0.15*	0.04	0.03	0.08	0.05	0.05	0.10	0.45***	-0.29***	0.06				
VARPIB	0.48***	0.12	0.13	0.14*	0.16*	0.02	-0.10	0.07	0.09	0.07	0.03	-0.04	0.36***			
SELICMETA	-0.16*	-0.11	-0.10	-0.03	0.00	-0.05	-0.32***	-0.01	-0.05	-0.63***	0.39***	-0.12	-0.47***	0.26***		
IPCA	-0.17**	0.04	0.01	-0.01	-0.01	0.02	-0.23***	-0.02	-0.02	-0.35***	0.24***	-0.09	0.29***	0.43***	0.53***	
VENDAS	0.30***	0.04	0.07	0.22**	0.22***	-0.04	0.02	0.03	-0.04	-0.15*	0.14	-0.02	0.08	0.67***	0.39***	0.48***