



REVISTA CIENTÍFICA ACERTTE
ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO: O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA

CREDIT CARD FRAUD AND TRANSACTION COSTS: THE ROLE OF MACHINE LEARNING IN ECONOMIC EFFICIENCY

FRAUDE EN TARJETAS DE CRÉDITO Y COSTOS DE TRANSACCIÓN: EL PAPEL DEL MACHINE LEARNING EN LA EFICIENCIA ECONÓMICA

Vinicius Dias Oliveira¹

e511275

<https://doi.org/10.63026/acertte.v5i11.275>

PUBLICADO: 11/2025

RESUMO

A fraude em cartões de crédito constitui um dos principais desafios econômicos do sistema financeiro contemporâneo, afetando a eficiência, a confiança e a governança das instituições. Este estudo analisa o impacto econômico das fraudes sob a ótica da Teoria dos Custos de Transação, examinando como o *machine learning* pode atuar como instrumento de eficiência e inovação institucional. Com base em dados públicos de transações financeiras e em revisão teórica, o trabalho interpreta a aplicação de algoritmos de aprendizado de máquina como uma forma de racionalização dos custos de monitoramento e verificação, reduzindo perdas e elevando a produtividade. Os resultados indicam que modelos como Regressão Logística, *Support Vector Machine* e Árvores de Decisão apresentam elevado potencial na detecção de padrões anômalos, diminuindo custos de auditoria e aumentando a confiança no sistema. Conclui-se que o *machine learning* representa uma inovação schumpeteriana capaz de reduzir custos de transação e ampliar a eficiência econômica, configurando-se como um elemento estratégico para a modernização e a segurança das instituições financeiras no Brasil.

Palavras-chave: Fraude financeira. Custos de transação. *Machine learning*. Eficiência econômica. Governança.

ABSTRACT

Credit card fraud represents one of the main economic challenges of the contemporary financial system, affecting efficiency, trust, and institutional governance. This study analyzes the economic impact of fraud from the perspective of Transaction Cost Theory, examining how machine learning can serve as a tool for enhancing efficiency and promoting institutional innovation. Based on public financial transaction data and theoretical review, the paper interprets the use of machine learning algorithms as a mechanism for rationalizing monitoring and verification costs, thus reducing losses and improving productivity. The results show that models such as Logistic Regression, Support Vector Machines, and Decision Trees have strong potential to detect anomalous patterns, decrease audit costs, and enhance confidence in the financial system. It is concluded that machine learning represents a Schumpeterian innovation capable of reducing transaction costs and increasing economic efficiency, establishing itself as a strategic element for the modernization and security of financial institutions in Brazil.

Keywords: Financial fraud. Transaction costs. Machine learning. Economic efficiency. Governance.

RESUMEN

El fraude con tarjetas de crédito constituye uno de los principales desafíos económicos del sistema financiero contemporáneo, afectando la eficiencia, la confianza y la gobernanza institucional. Este estudio analiza el impacto económico de los fraudes desde la perspectiva de la Teoría de los Costos de Transacción, examinando cómo el *machine learning* puede actuar como instrumento de eficiencia e innovación institucional. A partir de datos públicos sobre transacciones financieras y de una revisión

¹ Graduando em Ciências Econômicas pela Escola Paulista de Política, Economia e Negócios, da Universidade Federal de São Paulo.



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

teórica, el trabajo interpreta la aplicación de algoritmos de aprendizaje automático como un mecanismo de racionalización de los costos de monitoreo y verificación, reduciendo pérdidas y aumentando la productividad. Los resultados muestran que modelos como Regresión Logística, Support Vector Machine y Árboles de Decisión presentan un alto potencial para detectar patrones anómalos, disminuyendo los costos de auditoría y fortaleciendo la confianza en el sistema. Se concluye que el machine learning representa una innovación schumpeteriana capaz de reducir los costos de transacción y ampliar la eficiencia económica, consolidándose como un elemento estratégico para la modernización y la seguridad de las instituciones financieras en Brasil.

Palabras clave: Fraude financiero. Costos de transacción. Machine learning. Eficiencia económica. Gobernanza.

1 INTRODUÇÃO

A fraude em cartões de crédito é um dos principais desafios econômicos, institucionais e tecnológicos do sistema financeiro contemporâneo. Com a expansão das transações digitais e a intensificação do comércio eletrônico, o número de operações realizadas por meios eletrônicos cresceu exponencialmente nas últimas décadas. Essa evolução trouxe ganhos notáveis em termos de comodidade, acessibilidade e eficiência operacional. Entretanto, o mesmo ambiente de inovação que facilitou o consumo e a circulação de crédito também criou novas vulnerabilidades. O aumento do volume e da complexidade das operações financeiras eletrônicas ampliou os riscos de fraude, exigindo das instituições uma resposta tecnológica e econômica à altura.

No Brasil, o cenário é particularmente desafiador. A Confederação Nacional de Dirigentes Lojistas (CNDL, 2024) registrou um aumento de mais de 20% nas tentativas de fraude em transações eletrônicas em apenas um ano. A Serasa Experian (2024) aponta que 42% dos consumidores brasileiros já foram vítimas de algum tipo de fraude financeira, enquanto 73% acreditam que os fraudadores estão sempre um passo à frente das instituições. A Federação Brasileira de Bancos (FEBRABAN, 2023) estima que o setor financeiro nacional sofre prejuízos superiores a R\$ 2,5 bilhões anuais apenas com fraudes envolvendo cartões de crédito e débito. Esses números evidenciam que a fraude não é um problema isolado de segurança, mas um fenômeno com repercussões econômicas profundas, que afeta a confiança, o consumo e o próprio funcionamento do sistema financeiro.

As consequências das fraudes se manifestam em múltiplos níveis. No plano microeconômico, os consumidores sofrem com prejuízos diretos e perda de confiança, enquanto as instituições financeiras enfrentam custos elevados de ressarcimento, monitoramento e auditoria. No plano macroeconômico, o aumento das fraudes contribui para a retração do consumo e para a redução do uso de meios digitais, o que diminui a eficiência do sistema financeiro e prejudica a circulação de crédito e capital.

Do ponto de vista teórico, o fenômeno pode ser analisado sob a ótica da Teoria dos Custos de Transação (COASE, 1937; WILLIAMSON, 1985). Em mercados com forte assimetria de informação, o comportamento oportunista e a incerteza elevam o custo de garantir que as transações sejam realizadas de forma segura e confiável. As fraudes representam, portanto, um aumento dos custos de monitoramento, fiscalização e verificação contratual, reduzindo a eficiência de mercado.



REVISTA CIENTÍFICA ACERTTE ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

Nesse contexto, a aplicação de tecnologias baseadas em *machine learning* (aprendizado de máquina) surge como uma alternativa capaz de racionalizar processos e mitigar custos. O *machine learning* permite identificar padrões anômalos, detectar comportamentos suspeitos e automatizar etapas do monitoramento, reduzindo o tempo de resposta e aumentando a eficiência do controle. A tecnologia aprende continuamente com os dados e adapta-se a novas formas de fraude, o que representa uma vantagem significativa em um ambiente de constante inovação criminosa.

Assim, este estudo tem como objetivo analisar o papel do *machine learning* como instrumento de eficiência econômica e mitigação de custos de transação no sistema financeiro brasileiro. Busca-se compreender de que maneira essa tecnologia atua como inovação institucional, reduzindo ineficiências e fortalecendo a governança econômica.

A hipótese central é que o uso do *machine learning* no combate à fraude representa uma forma de inovação institucional schumpeteriana, capaz de reconfigurar a estrutura de custos e a dinâmica de funcionamento do mercado financeiro. O estudo estrutura-se em cinco seções: a primeira apresenta a introdução e a contextualização do tema; a segunda discute os fundamentos teóricos dos custos de transação e da inovação tecnológica; a terceira aborda a metodologia aplicada; a quarta expõe e analisa os resultados; e, por fim, a quinta seção apresenta as considerações finais.

2 FUNDAMENTAÇÃO TEÓRICA

A Teoria dos Custos de Transação (TCT), formulada por Ronald Coase (1937) e aprofundada por Oliver Williamson (1985, 1996), constitui uma das principais ferramentas analíticas para compreender o funcionamento das instituições econômicas. Coase (1937) observou que o mercado não é um mecanismo perfeito de coordenação: toda transação envolve custos de busca, negociação, fiscalização e cumprimento contratual. Assim, as empresas e instituições surgem para reduzir esses custos por meio de estruturas organizacionais mais eficientes.

Williamson (1985) ampliou essa teoria ao incorporar conceitos como racionalidade limitada e comportamento oportunista. Os agentes econômicos não possuem informações completas sobre o ambiente e, por isso, tomam decisões com base em expectativas parciais. Essa limitação gera espaço para o oportunismo, isto é, a busca do interesse próprio com astúcia e engano, o que aumenta a necessidade de monitoramento e controle.

No sistema financeiro, os custos de transação assumem uma dimensão crítica. Transações financeiras são, em essência, promessas futuras de pagamento baseadas em confiança. Quando a confiança é abalada por fraudes e incertezas, as instituições são forçadas a investir mais em auditorias, sistemas de segurança e verificação de identidade. Esses custos adicionais reduzem a eficiência e a competitividade, funcionando como uma “fricção” no mercado.

A economia evolucionária contribui com um olhar complementar. Nelson e Winter (1982) e Possas (2006) destacam que as instituições econômicas evoluem ao longo do tempo, adaptando suas rotinas e estruturas em resposta às mudanças tecnológicas e ambientais. A inovação, nesse contexto, é um mecanismo de adaptação. Schumpeter (1942) argumenta que o desenvolvimento econômico é



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

impulsionado por processos de “destruição criativa”, nos quais novas tecnologias substituem práticas antigas e menos eficientes.

Sob essa ótica, o *machine learning* pode ser entendido como uma inovação tecnológica e institucional que transforma os mecanismos de governança financeira. Ele substitui métodos tradicionais de detecção de fraude, baseados em regras fixas e revisões humanas, por sistemas inteligentes e adaptativos. Essa transição representa uma forma moderna de destruição criativa: a eficiência aumenta, e os custos de transação diminuem.

Williamson (1996) introduz ainda a noção de governança como o conjunto de mecanismos que regulam as relações econômicas. Inovações tecnológicas, como o *machine learning*, não apenas reduzem custos diretos, mas também reconfiguram estruturas de governança ao tornar as relações mais transparentes, previsíveis e seguras.

2.1 Fraude Financeira e Impactos Econômicos no Brasil

A fraude financeira no Brasil é um fenômeno de natureza estrutural, de caráter recorrente e com efeitos significativos sobre a economia e a estabilidade institucional. O avanço da digitalização bancária, a popularização do comércio eletrônico e a expansão de sistemas de pagamento instantâneo, como o PIX, criaram novas oportunidades para o crescimento econômico, mas também ampliaram as vulnerabilidades do sistema financeiro.

Dados da FEBRABAN (2023) e da CNDL (2024) indicam que as tentativas de fraude em cartões de crédito e débito aumentaram de forma consistente nos últimos anos, acompanhando a intensificação das transações digitais. Em 2023, a cada dez brasileiros conectados à internet, três relataram ter sido alvo de algum tipo de tentativa de fraude online. Segundo a Serasa Experian (2024), o número de tentativas de golpe em compras virtuais cresceu 28% em relação ao ano anterior, impulsionado pelo aumento das transações realizadas em aplicativos de entrega, *marketplaces* e plataformas de pagamento digital.

O Banco Central do Brasil (BCB, 2023) destaca que, entre 2019 e 2023, o número de denúncias de fraude envolvendo o PIX aumentou mais de 400%. Parte dessa vulnerabilidade decorre das características que fizeram o PIX um sucesso, a rapidez e a irreversibilidade das transferências, que, paradoxalmente, também tornam mais difícil interceptar e reverter transações fraudulentas. Além disso, a combinação entre anonimato parcial e alta velocidade cria um ambiente propício para o comportamento oportunista descrito por Williamson (1985).

Esses custos adicionais de segurança e monitoramento representam, sob a ótica coasiana, uma ineficiência de alocação de recursos. Em vez de canalizar investimentos para inovação, crédito ou expansão de serviços, as instituições são obrigadas a destinar parcelas crescentes de seus orçamentos a sistemas antifraude, seguros, auditorias e indenizações. Em 2022, segundo a FEBRABAN, o setor bancário destinou cerca de 2,5% de seu faturamento a medidas de cibersegurança, um montante expressivo, considerando o volume total de receitas do sistema financeiro nacional.



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

A insegurança financeira também tem impactos comportamentais relevantes. Pesquisas da CNDL (2024) revelam que quase metade dos consumidores brasileiros evitam realizar transações de alto valor em plataformas digitais por medo de fraude. Esse comportamento reduz a eficiência das transações, provoca uma espécie de “reversão tecnológica” e fortalece a preferência por meios tradicionais, como o dinheiro físico. Tal fenômeno representa um retrocesso na digitalização e enfraquece os ganhos de escala e de eficiência que caracterizam os mercados eletrônicos.

O impacto macroeconômico das fraudes é expressivo. Elas reduzem a confiança dos agentes econômicos, aumentam a aversão ao risco e elevam os custos do crédito, configurando o que pode ser descrito como um “ciclo de desconfiança”: quanto maior a incerteza, maiores os custos de transação e menor a eficiência do mercado. Essa dinâmica afeta diretamente o produto potencial da economia, pois reduz o volume de intermediação financeira e encarece o custo do capital.

Em resposta, o Estado brasileiro tem buscado mitigar o problema por meio de regulamentações e iniciativas de segurança digital. A Resolução nº 4.753/2019 do Conselho Monetário Nacional estabeleceu diretrizes para gestão de riscos cibernéticos; o Banco Central criou o Laboratório de Inovações Financeiras e Tecnológicas (LIFT), com foco em soluções antifraude; e a Lei Geral de Proteção de Dados (Lei nº 13.709/2018) impôs padrões mais rigorosos para o tratamento de informações pessoais.

Contudo, apesar desses avanços normativos, a assimetria informacional ainda é elevada. Instituições financeiras, *fintechs* e consumidores operam sob níveis distintos de conhecimento técnico e capacidade de resposta, o que dificulta a prevenção eficaz. Nesse cenário, a aplicação de tecnologias baseadas em *machine learning* surge como resposta natural e necessária. Ao automatizar a detecção de padrões e anomalias, o ML reduz a dependência de verificações manuais, acelera a tomada de decisão e torna o processo de monitoramento mais barato, confiável e escalável.

Portanto, combater fraudes não é apenas uma questão de segurança digital, mas uma estratégia de eficiência econômica. Reduzir perdas e custos de controle libera recursos para investimentos produtivos e fortalece a governança do sistema financeiro, criando um ambiente mais competitivo e sustentável.

2.2 Machine Learning como Ferramenta de Eficiência Econômica

O *machine learning* constitui uma das vertentes mais dinâmicas da inteligência artificial, com potencial transformador sobre os processos econômicos e administrativos. Trata-se de um conjunto de métodos e algoritmos que permitem que sistemas computacionais aprendam, reconheçam padrões e façam previsões com base em grandes volumes de dados, sem a necessidade de programação explícita (GÉRON, 2019). No contexto brasileiro, estudos recentes vêm demonstrando a eficácia desses métodos na detecção de fraudes em cartões de crédito, comparando diferentes abordagens estatísticas e preditivas (OLIVEIRA, 2025). Essa capacidade de aprendizado contínuo torna o ML particularmente valioso em ambientes complexos e voláteis, como o mercado financeiro, em que novos tipos de fraude surgem diariamente.



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

Sob a ótica econômica, o *machine learning* impacta diretamente a eficiência do sistema ao atuar em três dimensões principais:

1. Redução de custos operacionais: os modelos de ML automatizam tarefas repetitivas, como verificação de transações e análise de risco, substituindo atividades manuais demoradas por processos automáticos em larga escala. Isso reduz custos de monitoramento e tempo de resposta.
2. Aumento da eficiência informacional: o ML diminui a assimetria de informação entre agentes, bancos, clientes e intermediários, ao fornecer análises rápidas e precisas sobre o comportamento transacional.
3. Fortalecimento da governança: ao tornar as relações mais previsíveis e transparentes, a tecnologia amplia a confiança nos mecanismos de pagamento e reduz os incentivos ao comportamento oportunista.

Essas dimensões alinham-se aos princípios da Teoria dos Custos de Transação (WILLIAMSON, 1996), segundo a qual as instituições buscam constantemente mecanismos que minimizem custos de coordenação e garantam a execução dos contratos com menor fricção possível.

Os algoritmos mais utilizados para detecção de fraudes incluem Regressão Logística, Support Vector Machines (SVM), Árvores de Decisão, Random Forest, K-Nearest Neighbors (KNN) e Redes Neurais Artificiais. Cada abordagem tem características específicas: enquanto os modelos lineares (como a Regressão Logística) oferecem maior interpretabilidade e simplicidade de implementação, os modelos baseados em árvores e redes neurais alcançam níveis superiores de precisão, ainda que a custo de maior complexidade computacional.

Do ponto de vista institucional, o *machine learning* altera profundamente as estruturas de governança das organizações financeiras. Antes, a prevenção à fraude dependia de regras estáticas e de equipes especializadas em identificar comportamentos suspeitos. Hoje, com a automação preditiva, é possível monitorar milhões de transações em tempo real, aplicando análises probabilísticas que antecipam o risco de fraude com base em padrões de histórico. Isso não apenas reduz custos, mas também aumenta a capacidade adaptativa das instituições, um atributo essencial na economia digital.

Em termos econômicos, a adoção do ML gera externalidades positivas. A redução da fraude aumenta a confiança dos consumidores e empresas no uso de meios digitais, o que impulsiona o consumo, o crédito e a arrecadação fiscal associada às transações eletrônicas. Em uma perspectiva schumpeteriana, o *machine learning* representa uma inovação destrutiva e criadora ao mesmo tempo: destrói modelos ineficientes de controle manual e cria novas formas de organização baseadas em dados, automação e eficiência informacional.

Além disso, o ML contribui para o desenvolvimento de políticas de *compliance* mais inteligentes e dinâmicas, alinhadas às exigências da regulação prudencial e da LGPD. Ao mesmo tempo, a tecnologia amplia a capacidade das instituições de detectar não apenas fraudes financeiras, mas



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

também outros riscos, como lavagem de dinheiro e evasão fiscal, ampliando seu alcance social e econômico.

Portanto, o *machine learning* deve ser compreendido como mais do que uma ferramenta técnica. Ele é, sobretudo, um instrumento de eficiência institucional, capaz de transformar a forma como os mercados funcionam, tornando as relações econômicas mais seguras, transparentes e produtivas. Ao reduzir custos de transação e aumentar a previsibilidade, o ML reforça o papel das instituições financeiras como agentes centrais da estabilidade e do desenvolvimento econômico.

3 METODOLOGIA

O estudo adota uma abordagem exploratória e comparativa, baseada em dados secundários provenientes da plataforma pública Kaggle, especificamente do conjunto “*Credit Card Fraud Detection*”. Esse dataset reúne 284.807 registros de transações financeiras, com uma proporção de apenas 0,17% de operações fraudulentas, sendo amplamente utilizado em pesquisas voltadas à identificação de eventos raros e à avaliação de desempenho de modelos de *machine learning*.

A análise foi conduzida de forma interpretativa, com base em resultados e métricas já disponíveis na literatura especializada (OLIVEIRA, 2025; GÉRON, 2019), que aplicaram modelos como Regressão Logística, Naive Bayes, Support Vector Machine (SVM) e Árvores de Decisão. A partir dessas evidências empíricas, o presente trabalho buscou compreender como o desempenho técnico desses algoritmos pode ser interpretado sob a ótica econômica, relacionando suas métricas, a saber, precisão, *recall*, *F1-Score* (média harmônica entre precisão e *recall*, utilizada para equilibrar falsos positivos e negativos) e área sob a curva ROC, à eficiência informacional e à redução dos custos de transação.

O método, portanto, combina revisão teórica e análise documental de dados públicos. Os resultados de desempenho dos modelos foram utilizados como base comparativa para discutir implicações econômicas e institucionais, demonstrando o potencial do *machine learning* como instrumento de eficiência e governança no sistema financeiro.

4 RESULTADOS

As evidências reunidas a partir de bases públicas e estudos especializados indicam que as técnicas de *machine learning* apresentam elevado potencial de eficiência na detecção e prevenção de fraudes financeiras. Pesquisas comparativas (Géron, 2019; Oliveira, 2025; IBM, 2022) baseadas no conjunto de dados *Credit Card Fraud Detection*, amplamente utilizado na literatura internacional, demonstram que os modelos de Regressão Logística, Naive Bayes, Support Vector Machine (SVM) e Árvores de Decisão alcançam desempenhos consistentes na identificação de padrões fraudulentos, reduzindo significativamente o número de falsos positivos e falsos negativos.

De acordo com Oliveira (2025), os modelos de Regressão Logística e SVM apresentaram os melhores resultados médios, com *F1-Score* de 0,82 e 0,79, respectivamente. Esses resultados refletem a capacidade dos algoritmos de equilibrar precisão e sensibilidade, identificando transações



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

fraudulentas sem comprometer o volume de operações legítimas. As Árvores de Decisão e o Naive Bayes também demonstraram resultados satisfatórios (0,75 e 0,72), ainda que com desempenho ligeiramente inferior em contextos de alta desproporção entre classes.

Esses achados são consistentes com os resultados observados em outros estudos internacionais (GÉRON, 2019; IBM, 2022; Banco Mundial, 2023), que apontam ganhos expressivos de acurácia e redução de custos operacionais em instituições financeiras que adotaram modelos de aprendizado de máquina para controle de fraude. Estudos conduzidos por instituições como o Banco Mundial (2023) e a IBM (2022) evidenciam que a utilização de sistemas preditivos reduziu em até 35% as perdas operacionais e em 30% os custos de conformidade regulatória (*compliance*), reforçando o papel do *machine learning* como ferramenta de mitigação de riscos.

De modo geral, os resultados consolidados sugerem que os modelos de aprendizado de máquina não apenas aprimoram a detecção de fraudes, mas também otimizam processos internos de auditoria e controle, contribuindo para a eficiência sistêmica e a estabilidade das transações financeiras digitais.

5 DISCUSSÃO

Os resultados apresentados pela literatura e pelos dados secundários analisados reforçam a aplicabilidade da Teoria dos Custos de Transação no contexto financeiro digital. A fraude pode ser entendida como uma manifestação de comportamento oportunista decorrente da assimetria informacional, conceito central em Williamson (1985). Ao reduzir essa assimetria por meio de análises automatizadas e aprendizado contínuo, o *machine learning* atua como mecanismo institucional de eficiência.

Em termos econômicos, a redução dos falsos positivos e negativos representa uma diminuição direta dos custos de monitoramento e auditoria, elementos típicos dos custos de transação. A eficiência obtida por meio de algoritmos inteligentes possibilita realocar recursos antes destinados à verificação manual para atividades de maior valor agregado, como crédito, inovação e atendimento ao cliente. Trata-se de um exemplo prático do que Williamson (1985) denomina eficiência alocativa.

A literatura também destaca os efeitos indiretos dessa eficiência sobre o comportamento dos consumidores e do mercado. Com menor incidência de fraudes e maior segurança percebida, há aumento da confiança nos meios digitais, estimulando o uso de cartões, aplicativos e transferências eletrônicas. Esse ciclo de retroalimentação positiva, um efeito de rede baseado na confiança, fortalece o sistema financeiro e amplia o volume de transações digitais, gerando ganhos macroeconômicos relevantes.

Do ponto de vista institucional, o *machine learning* pode ser interpretado como uma inovação schumpeteriana, ao substituir métodos tradicionais de controle, baseados em regras fixas e revisões humanas, por mecanismos adaptativos, automatizados e baseados em dados. Essa transformação configura um processo de “destruição criativa institucional”, no qual a inovação tecnológica reestrutura as práticas de governança e cria novas formas de organização mais eficientes.



REVISTA CIENTÍFICA ACERTTE

ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

Por fim, é importante reconhecer os desafios associados à adoção dessa tecnologia. A necessidade de grandes volumes de dados para treinamento de modelos eleva os custos de infraestrutura e impõe rigor adicional em termos de proteção de informações, especialmente sob as exigências da Lei Geral de Proteção de Dados (LGPD). Além disso, o uso de modelos opacos (*black box models*) demanda novas abordagens de transparência e regulação.

De modo geral, a discussão evidencia que o *machine learning* não deve ser visto apenas como ferramenta técnica, mas como um instrumento institucional de eficiência econômica, capaz de reduzir custos de transação, fortalecer a governança e impulsionar a modernização do sistema financeiro.

CONSIDERAÇÕES

Com base nas evidências reunidas e discutidas, conclui-se que a fraude em cartões de crédito constitui um problema econômico e institucional de natureza estrutural, cujos efeitos ultrapassam o campo tecnológico. Seus impactos atingem consumidores, instituições financeiras e a estabilidade do próprio sistema econômico, elevando custos de monitoramento, reduzindo a confiança e comprometendo a eficiência das transações digitais.

A análise dos estudos e bases de dados secundárias confirma que a aplicação de tecnologias de *machine learning* representa um instrumento eficaz para reduzir custos de transação, aumentar a eficiência e fortalecer a governança. Sob a ótica schumpeteriana, essa inovação expressa um processo de destruição criativa, no qual métodos tradicionais e onerosos são substituídos por sistemas automatizados e inteligentes, capazes de promover ganhos de produtividade e segurança institucional.

Do ponto de vista das políticas econômicas e institucionais, os resultados indicam a importância de investimentos contínuos em infraestrutura digital, capacitação técnica e regulação integrada. O sucesso do *machine learning* como ferramenta de eficiência depende não apenas do avanço tecnológico, mas também da consolidação de um ecossistema de governança que favoreça sua implementação ética, transparente e sustentável.

Por fim, recomenda-se que pesquisas futuras ampliem a análise sobre a relação entre tecnologias de aprendizado de máquina e custos de transação em outros contextos, como *open banking*, PIX e criptomoedas, contribuindo para o desenvolvimento de uma agenda de economia institucional aplicada à era digital.

REFERÊNCIAS

- BANCO CENTRAL DO BRASIL. **Relatório de Economia Bancária e Crédito 2023**. Brasília, 2023.
- CNDL – CONFEDERAÇÃO NACIONAL DE DIRIGENTES LOJISTAS. **Relatório Nacional de Fraudes Financeiras**. Brasília, 2024.
- COASE, R. The Nature of the Firm. **Economica**, v. 4, n. 16, p. 386–405, 1937.
- FEBRABAN – FEDERAÇÃO BRASILEIRA DE BANCOS. **Relatório FEBRABAN de Tecnologia Bancária 2023**. São Paulo, 2023.



REVISTA CIENTÍFICA ACERTTE
ISSN 2763-8928

FRAUDE EM CARTÕES DE CRÉDITO E CUSTOS DE TRANSAÇÃO:
O PAPEL DO MACHINE LEARNING NA EFICIÊNCIA ECONÔMICA
Vinicius Dias Oliveira

GÉRON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras e TensorFlow**. 2. ed. Rio de Janeiro: Alta Books, 2019.

NELSON, R.; WINTER, S. **An Evolutionary Theory of Economic Change**. Cambridge: Harvard University Press, 1982.

OLIVEIRA, Vinicius Dias. Métodos de Machine Learning na Detecção de Fraude em Cartão de Crédito: um Estudo Comparado. **Revista Científica Acertte**, v. 5, n. 9, p. e59265, 2025. DOI: 10.63026/acertte.v5i9.265.

POSSAS, M. **Concorrência e Dinâmica Capitalista: Uma Abordagem Schumpeteriana**. São Paulo: Hucitec, 2006.

SCHUMPETER, J. **Capitalismo, Socialismo e Democracia**. Rio de Janeiro: Fundo de Cultura, 1942.

SERASA EXPERIAN. **Panorama da Fraude no Brasil 2024**. São Paulo, 2024.

WILLIAMSON, O. **The Economic Institutions of Capitalism**. New York: Free Press, 1985.

WILLIAMSON, O. **Mechanisms of Governance**. New York: Oxford University Press, 1996.