

Previsibilidade em fusões e aquisições no Brasil: uma análise comparativa com algoritmos de *Machine Learning*

Predictability in mergers and acquisitions in Brazil: a comparative analysis using Machine Learning algorithms

Edimilson Costa Lucas Doutor em Finanças. Universidade Presbiteriana Mackenzie e
UNIFESP – Brasil. <https://orcid.org/0000-0003-0533-6067>

Marcio Quadros Lopes dos Santos Doutor em Controladoria, Finanças e Tecnologias de Gestão.
Universidade Presbiteriana Mackenzie – Brasil.
<https://orcid.org/0000-0002-7451-7489> marcio.quadros@gmail.com

Danilo Braun Santos Doutor em Finanças. Universidade Federal de São Paulo
(EPPEN/UNIFESP). danilo.braun@unifesp.br
<https://orcid.org/0000-0001-8275-1059>

Thiago Henriques Fernandes Doutorando em Controladoria, Finanças e Tecnologias de Gestão.
Universidade Presbiteriana Mackenzie – Brasil. – Brasil.
<https://orcid.org/0009-0002-5850-9902> thiagohenriques@gmail.com

Vinicius Augusto Brunassi Silva Doutor em Finanças. Fundação Escola de Comércio Álvares
Penteado (FECAP) – Brasil. vinicius.brunassi@fecap.br
<https://orcid.org/0000-0002-1299-321X>

RESUMO

As operações de Fusões e Aquisições (F&A) são estratégias corporativas de alto impacto, porém marcadas por incertezas quanto à sua conclusão. Diante da carência de estudos empíricos com foco em predição no Brasil, este trabalho objetiva desenvolver e comparar modelos de *machine learning* para prever o sucesso de transações de F&A no mercado brasileiro. A pesquisa utiliza um banco de dados da Thomson Reuters SDC com 6.697 operações anunciadas entre 2000 e 2016. Foram aplicados e avaliados quatro algoritmos distintos: regressão logística com e sem penalização, redes neurais e *random forest*. A performance foi mensurada pela área sob a curva ROC (AUC). Todos os modelos demonstraram capacidade preditiva (AUC $\approx$ 0.70), com as redes neurais apresentando o maior poder discriminatório (AUC = 0.7416). O estudo contribui para a literatura ao demonstrar a viabilidade da aplicação de técnicas de inteligência artificial na análise de F&A em mercados emergentes, oferecendo um método quantitativo que pode aprimorar a tomada de decisão estratégica e a gestão de riscos.

Palavras-chave: fusões e aquisições; *Machine Learning*; análise preditiva.

ABSTRACT

Mergers and Acquisitions (M&A) are high-impact corporate strategies, yet they are marked by uncertainty regarding their completion. Given the scarcity of empirical studies focused on prediction in Brazil, this paper aims to develop and compare machine learning models to predict the success of M&A transactions in the Brazilian market. The research uses a Thomson Reuters SDC database of 6,697 deals announced between 2000 and 2016. Four distinct algorithms were applied and evaluated: logistic regression with and without penalty, neural networks, and random forest. Performance was measured by the area under the ROC curve (AUC). All models demonstrated predictive capability (AUC $\approx$ 0.70), with neural networks showing the highest discriminatory power (AUC = 0.7416). This study contributes to the literature by demonstrating the feasibility of applying artificial intelligence techniques to M&A analysis in emerging markets, offering a quantitative method that can enhance strategic decision-making and risk management.

Keywords: mergers and acquisitions; Machine Learning; predictive analysis.

Recebido em 27/06/2025. Aprovado em 29/07/2025. Avaliado pelo sistema *double blind peer review*. Publicado
conforme normas da APA.

<https://doi.org/10.22279/navus.v16.2158>

1 INTRODUÇÃO

Em um cenário de crescente globalização, a competitividade econômica impulsiona as empresas a buscar vantagens estratégicas para maximizar a riqueza de seus acionistas (Ikwuo, Nworie & Ukoha, 2025). Nesse contexto, as operações de Fusões e Aquisições (F&A) emergem como uma das principais ferramentas do capitalismo moderno, permitindo às organizações alcançar múltiplos objetivos, como crescimento acelerado, entrada em novos mercados, obtenção de economias de escala e controle de mercado (Kopp, Fligge & Eulerich, 2022; Gouveia, 2014). A capacidade das F&A de gerar valor foi evidenciada em estudos pioneiros, como o de Jensen e Ruback (1983), que concluíram que tais transações criam valor para os acionistas ao viabilizar o acesso a recursos específicos de forma única.

O mercado brasileiro de F&A ganhou notoriedade a partir da década de 1990, impulsionado por políticas de abertura de mercado e pela inserção do país no cenário global, o que atraiu capital estrangeiro e aqueceu o volume de transações (Saikia, Kumar & Mundi, 2022; Tanure & Cançado, 2004). Relatórios da época já apontavam um crescimento acumulado de 134% no número de operações durante essa década, com 1997 marcando um recorde de 372 negócios. Essa tendência de alta se manteve, atingindo 726 transações em 2010 (KPMG, 2011), demonstrando a consolidação e a importância estratégica das F&A na economia nacional.

Apesar da relevância do tema, a literatura acadêmica no Brasil, embora vasta, apresenta lacunas. Muitos estudos se concentram em analisar o impacto de variáveis isoladas, como a participação de assessores financeiros ou fatores macroeconômicos (Ermel & Martelanc, 2018). Trabalhos recentes continuam a explorar os determinantes do sucesso de F&A, mas a aplicação de técnicas avançadas de previsão para o mercado brasileiro ainda constitui um campo fértil e pouco explorado.

Este estudo propõe preencher essa lacuna por meio da aplicação de algoritmos de *machine learning*, que são capazes de capturar relações complexas e não lineares nos dados, superando as limitações de modelos estatísticos tradicionais (Lucas et al., 2025; Santos et al., 2019). A aplicação de tais técnicas encontra forte respaldo na Teoria da Assimetria de Informação (Zhang & Doukas, 2020). Além disso, a aplicação dessas técnicas também encontra respaldo na Teoria dos Sinais (Spence, 1973), que complementa a lógica da assimetria informacional ao considerar que os agentes econômicos podem emitir sinais ao mercado para reduzir incertezas (Liu, 2025; Huang, Xu & Wu, 2024; Tariq et al., 2024). Em contextos de F&A, características como o histórico de transações do adquirente, o tipo de pagamento e a estrutura de capital podem funcionar como sinais de confiabilidade ou risco percebido. Assim, os algoritmos de *machine learning* não apenas capturam padrões ocultos, mas também interpretam o valor informacional desses sinais no processo de decisão. No contexto de F&A, a empresa adquirente possui informações incompletas sobre a empresa-alvo, gerando incertezas que podem levar ao fracasso da negociação. O *machine learning* atua como uma ferramenta para mitigar essa assimetria, identificando padrões sutis em dados históricos que sinalizam uma maior ou menor probabilidade de conclusão do negócio. Estudos recentes corroboram que a complexidade informacional é um fator crítico na previsão de resultados de F&A, tornando os modelos computacionais particularmente adequados para essa tarefa (Hajek & Henriques, 2024; Arsini, Straccamore & Zaccaria, 2022).

Diante do exposto, o objetivo desta pesquisa é desenvolver e comparar a capacidade preditiva de quatro modelos de *machine learning*, regressão logística, regressão logística com penalização, redes neurais e *random forest*, para prever o desfecho (sucesso ou abandono) de operações de F&A no Brasil. Para tal, será utilizada uma amostra de 6.697 transações anunciadas entre 2000 e 2016, extraídas da base de dados da *Thomson Reuters SDC*.

Embora o período analisado compreenda transações anunciadas entre os anos de 2000 e 2016, é importante destacar que a utilização de dados históricos continua sendo uma prática amplamente aceita e valorizada na literatura acadêmica e em estudos empíricos de finanças corporativas (Gomes et al., 2013). A longevidade e abrangência da base permitem a identificação de padrões estruturais robustos e a construção de modelos com maior estabilidade estatística. Conforme argumentam DeYoung e Huang (2021), mesmo bases temporais mais antigas oferecem importantes contribuições quando tratam de fenômenos com baixa frequência e alta complexidade, como as operações de F&A. Além disso, os determinantes fundamentais que influenciam a conclusão dessas transações, como a estrutura de capital, forma de pagamento e experiência prévia da adquirente, são relativamente estáveis ao longo do tempo. Portanto, apesar da defasagem temporal, os achados deste estudo mantêm plena relevância para o entendimento dos mecanismos que aumentam a probabilidade de sucesso em processos de fusão e aquisição, inclusive em cenários contemporâneos e futuros (Officer, Cousin & De Bodt, 2022; Verma, 2024; Liu & Yang, 2024).

Este trabalho justifica-se por sua dupla contribuição: teoricamente, avança na literatura de finanças corporativas ao aplicar uma abordagem metodológica inovadora para um problema clássico em um mercado emergente; praticamente, oferece *insights* que podem aprimorar a tomada de decisão de gestores e investidores, permitindo uma análise de risco mais acurada no dispendioso processo de F&A.

O artigo está estruturado da seguinte forma: a seção subsequente apresenta o referencial teórico; a seção 3 detalha a metodologia; a seção 4 discute a análise e os resultados obtidos; e, por fim, a seção 5 apresenta as considerações finais.

2 REVISÃO DA LITERATURA

Esta seção estabelece os fundamentos conceituais e o contexto histórico das operações de Fusões e Aquisições (F&A), que são elementos essenciais para compreender a análise empírica desenvolvida neste estudo.

2.1 Conceitos e Tipologias de Fusões e Aquisições

No campo das finanças corporativas, os termos relacionados a F&A são por vezes utilizados de forma intercambiável, embora possuam distinções jurídicas e operacionais precisas. A legislação brasileira, por meio da Lei nº 6.404/76, oferece definições claras para os principais tipos de reorganização societária.

A fusão é definida como a “operação pela qual se unem duas ou mais sociedades para formar sociedade nova, que lhes sucederá em todos os direitos e obrigações” (Brasil, 1976, art. 228). Em essência, as empresas originais (A e B) são extintas para dar origem a uma nova entidade (C), que herda todo

o patrimônio, direitos e deveres das predecessoras. Autores como Brigham, Gapenski e Ehrhardt (2001) e Gouveia (2014) corroboram essa visão, destacando a criação de sinergia como objetivo central.

A incorporação, por sua vez, é a "operação pela qual uma ou mais sociedades são absorvidas por outra, que lhes sucede em todos os direitos e obrigações" (Brasil, 1976, art. 227). Diferentemente da fusão, na incorporação uma das empresas (a incorporadora) sobrevive e mantém sua personalidade jurídica, enquanto a outra (a incorporada) é extinta, com seu patrimônio totalmente transferido (Warde Junior, 2009). Trata-se, efetivamente, de uma aquisição em que uma empresa-alvo deixa de existir (Ray, 2022). A distinção é crucial, pois muitas operações anunciadas como "fusões entre iguais" são, na prática, aquisições, como no notório caso da Daimler-Benz e Chrysler, em que diferenças culturais e de poder evidenciaram a absorção da segunda pela primeira (Vasconcelos et al., 2004).

Por fim, a cisão ocorre quando "a companhia transfere parcelas do seu patrimônio para uma ou mais sociedades, constituídas para esse fim ou já existentes" (Brasil, 1976, art. 229). A cisão pode ser total, com a extinção da empresa original, ou parcial, caso em que a companhia cindida continua a existir com seu capital social ajustado.

Além das definições legais, as F&A são classificadas estrategicamente. Segundo Gaughan (2007), existem três tipos principais:

1. Fusão Horizontal: Ocorre entre empresas concorrentes do mesmo setor, visando aumentar a participação de mercado e o poder de barganha. O caso da Exxon e Mobil em 1998 é um exemplo clássico.
2. Fusão Vertical: Envolve empresas que operam em diferentes estágios da mesma cadeia produtiva (relação fornecedor-cliente), como a união da farmacêutica Merck com a distribuidora de medicamentos Medco em 1993.
3. Fusão de Conglomerado: Une empresas de setores totalmente distintos, sem relação operacional evidente, como a fusão da tabaqueira Philip Morris com a empresa de alimentos General Foods em 1985, geralmente motivada pela diversificação de riscos (Ferreira, 2002).

2.3 Modelo Conceitual e Formulação de Hipóteses

Para fundamentar teoricamente as variáveis empregadas no modelo preditivo e conferir maior poder explicativo à análise, foi construído um modelo conceitual ancorado em teorias clássicas da literatura de finanças e estratégia corporativa. As principais vertentes teóricas que subsidiam esta estrutura analítica são: a Teoria dos Custos de Transação (de Melo Santos et al., 2017), a Teoria da Agência (Jensen & Meckling, 2008) e a Teoria dos Recursos e Capacidades (Barney, 1991)

Segundo a Teoria dos Custos de Transação, empresas buscam estruturas que minimizem os custos de negociação, coordenação e execução de contratos. Nesse sentido, operações com maior complexidade institucional, presença de múltiplos agentes ou setores regulados tendem a ter menor chance de conclusão. A variável setor regulado foi incorporada com esse intuito, refletindo a expectativa de maior barreira transacional.

A Teoria da Agência, por sua vez, sugere que conflitos entre acionistas e gestores podem afetar negativamente a eficácia de decisões estratégicas, incluindo F&A. Operações conduzidas por grupos com estrutura de controle mais difusa, ou em que haja assimetria de interesses, tendem a apresentar maior

risco de não conclusão. A presença de controle estrangeiro e o pertencimento a grupo econômico nacional funcionam como *proxies* para avaliar a clareza na estrutura de governança.

A Teoria dos Recursos e Capacidades sustenta que empresas buscam F&A como mecanismo de acesso a ativos estratégicos, como conhecimento, marca, canais de distribuição ou tecnologia. A variável número de aquisições anteriores (experiência acumulada) e o setor da empresa adquirente refletem essa lógica, pois empresas com maior capacidade de execução ou que atuam em setores mais dinâmicos tendem a concluir operações com mais sucesso.

Diante desse arcabouço teórico, foi elaborado o seguinte modelo conceitual: variáveis de estrutura, experiência, controle e regulação são integradas como determinantes da probabilidade de conclusão de operações de F&A no Brasil.

Com base nessas premissas, formulam-se as seguintes hipóteses, testadas indiretamente por meio dos modelos preditivos desenvolvidos:

- H1: Operações envolvendo empresas pertencentes a grupos econômicos nacionais têm maior probabilidade de serem concluídas, devido à maior capacidade de coordenação organizacional e menor assimetria de informações (Teoria da Agência).
- H2: A presença de controle estrangeiro na empresa adquirente aumenta a chance de conclusão da operação, pela maior experiência internacional e acesso a capital (Teoria dos Recursos e Capacidades).
- H3: Operações realizadas em setores regulados têm menor probabilidade de conclusão, em virtude de entraves legais e institucionais que elevam os custos de transação (Teoria dos Custos de Transação).
- H4: Empresas com histórico de aquisições anteriores têm maior chance de concluir novas operações, dado o acúmulo de *know-how* e a especialização em processos de F&A (Teoria dos Recursos e Capacidades).

Essas hipóteses fornecem um pano de fundo interpretativo para os resultados obtidos nos modelos de regressão logística, LASSO, redes neurais e *Random Forest*, discutidos nas seções empíricas do artigo. Embora a metodologia tenha foco comparativo-preditivo, a ancoragem teórica permite não apenas antecipar padrões nos dados, mas também explicar as razões estruturais subjacentes aos comportamentos observados.

3 METODOLOGIA

Este estudo caracteriza-se como uma pesquisa de natureza quantitativa e exploratória, com delineamento experimental. A abordagem exploratória é adequada quando há pouco conhecimento sistematizado sobre o fenômeno, como é o caso da aplicação de *machine learning* para a predição de resultados de F&A no Brasil. O caráter experimental reside na manipulação e teste de diferentes algoritmos preditivos para observar e comparar sua capacidade de explicar o sucesso das transações.

A opção por caracterizar esta pesquisa como quantitativa está relacionada à própria natureza do fenômeno investigado. O estudo busca compreender padrões a partir de dados mensuráveis como as informações financeiras, características das empresas e resultados das transações de Fusões & Aquisições, que podem ser tratados por meio de técnicas estatísticas e de *machine learning*. Em outras palavras, parte-se do pressuposto de que o comportamento do fenômeno pode ser traduzido em variáveis numéricas e

analisado com base em evidências objetivas, o que é coerente com a tradição da pesquisa quantitativa (Ocieszak, 2020).

A classificação como exploratória decorre do estágio atual da literatura. Embora a aplicação de algoritmos de aprendizado de máquina já esteja consolidada em diferentes áreas, no contexto específico da predição do sucesso de F&A no Brasil ainda existe pouco conhecimento sistematizado. Nesse sentido, o caráter exploratório reflete o esforço de mapear esse campo, identificar padrões iniciais e levantar hipóteses que possam ser aprofundadas em estudos futuros, conforme defendem autores como Gil (2019), ao destacar que pesquisas exploratórias são particularmente úteis em campos emergentes.

Por fim, descreve-se o delineamento como experimental visto que o estudo envolve a manipulação intencional de condições metodológicas. Diferentes algoritmos e configurações foram testados de forma controlada para observar como variam as capacidades preditivas dos modelos. Essa prática se aproxima da lógica experimental, ainda que em ambiente computacional, na medida em que permite comparar desempenhos sob critérios uniformes de avaliação, como divisão de dados em treino e teste e uso de validação cruzada (Lawrynczuk, 2024).

Dessa forma, o enquadramento metodológico quantitativo, exploratório e experimental, não é apenas uma escolha descritiva, mas reflete a coerência entre o objetivo do estudo, o estágio de desenvolvimento do tema e a forma como os algoritmos foram aplicados e comparados.

3.1 População e Amostra

A população da pesquisa compreende todas as operações de Fusões e Aquisições (F&A) anunciadas no mercado brasileiro. A amostra, de caráter não probabilístico e por acessibilidade, foi extraída da base de dados financeira da *Thomson Reuters SDC*, uma das fontes mais utilizadas em pesquisas de finanças corporativas em nível mundial (Gouveia, 2014).

A amostra final é composta por 6.697 anúncios de transações ocorridas entre os anos de 2000 e 2016. Os dados utilizados são secundários. Os critérios de seleção para a composição da amostra final foram: i) a transação deveria conter a informação sobre sua conclusão ou não (variável "Completo"); e ii) as observações não deveriam conter dados ausentes ("vazios") nas variáveis selecionadas para o estudo, a fim de evitar distorções nos modelos.

Essa base de dados apresenta alta qualidade devido à sua profundidade longitudinal (mais de 15 anos), entretanto, por falta de dados mais recentes isso se traduz em uma limitação para a presente pesquisa sendo recomendada, como sugestão para pesquisas futuras, a inclusão de dados atualizados.

3.2 Variáveis do Estudo

A variável dependente (variável-alvo) da análise preditiva é a "Completo", uma *dummy* binária que indica se a transação de F&A foi efetivamente concluída (valor 1) ou não (valor 0). A seleção desta variável é fundamental para o estudo, pois representa a medida de sucesso da negociação (Ermel & Martelanc, 2018).

As variáveis independentes (preditoras) foram selecionadas com base na literatura de F&A buscando capturar diferentes dimensões do negócio, como

características do adquirente, do alvo e da própria transação. A tabela 1 detalha cada uma das variáveis utilizadas.

Tabela 1

Descrição das Variáveis do Modelo

Variável	Definição	Referência Base
Aberta	Dummy: 1 se a empresa adquirente possui capital aberto; 0 caso contrário.	Golubov et al. (2012)
Setoric	Dummy: 1 se adquirente e adquirida atuam no mesmo setor; 0 caso contrário.	Servaes & Zenner (1996)
CapitalEstrangeiro	Dummy: 1 se o controlador da adquirente é estrangeiro; 0 caso contrário.	Erel, Liao & Weisbach (2012)
LnExpGeral	Logaritmo natural do número acumulado de F&A realizadas pela adquirente.	Golubov et al. (2012)
Public	Dummy: 1 se a empresa-alvo possui capital aberto; 0 caso contrário.	Golubov et al. (2012)
AllStock	Dummy: 1 se o pagamento foi realizado exclusivamente com ações; 0 caso contrário.	Servaes & Zenner (1996)
AllCash	Dummy: 1 se o pagamento foi realizado exclusivamente com caixa; 0 caso contrário.	Servaes & Zenner (1996)
Acquirerbank	Dummy: 1 se a empresa adquirente é uma instituição financeira; 0 caso contrário.	Servaes & Zenner (1996)

3.3 Modelagem Preditiva com *Machine Learning*

Para prever o desfecho das operações de F&A, foram desenvolvidos, treinados e comparados quatro algoritmos de *machine learning*, selecionados por representarem abordagens distintas de classificação. *Machine Learning* é um campo da inteligência artificial que permite aos sistemas computacionais aprenderem padrões a partir de grandes volumes de dados de forma autônoma, aprimorando sua capacidade preditiva a cada nova exposição aos dados (Sarker, 2021). Os modelos foram implementados nos *softwares* estatísticos *R* e *Python*.

3.3.1 Regressão Logística

Primeiramente, foi aplicado um modelo de Regressão Logística, método estatístico clássico para classificação binária que estima a probabilidade de um evento ocorrer com base em um conjunto de preditores. Seus coeficientes são estimados pelo método da máxima verossimilhança.

3.3.2 Regressão Logística Penalizada (Lasso)

Em seguida, utilizou-se uma Regressão Logística com penalização de Lasso. Este modelo adiciona um termo de regularização (hiperparâmetro *lambda*) à função de custo, o que força os coeficientes de variáveis menos relevantes a zero. O resultado é um modelo menos complexo, com menor variância e menor risco de sobreajuste (*overfitting*) a novas observações (Santos et al., 2019).

3.3.3 Redes Neurais Artificiais (RNA)

O terceiro modelo consiste em uma Rede Neural Artificial (RNA), um método conexionista inspirado no funcionamento do cérebro humano. As RNAs são formadas por camadas de neurônios interconectados (entrada, ocultas e saída) e são capazes de aprender relações não lineares e altamente complexas entre as variáveis (Abiodun et al., 2018). Os principais hiperparâmetros ajustados foram o número de neurônios na camada oculta (*size*) e o parâmetro de regularização (*decay*).

3.3.4 *Random Forest*

Por fim, foi implementado um modelo de *Random Forest* (Floresta Aleatória). Este algoritmo opera através da construção de um conjunto de Árvores de Decisão, onde cada árvore é treinada com uma subamostra aleatória dos dados e dos preditores. A classificação final é obtida por meio de um sistema de votação entre todas as árvores, o que reduz a variância e aumenta a robustez do modelo. Os hiperparâmetros otimizados foram o número de árvores na floresta (*ntree*) e o número de variáveis consideradas em cada nó (*mtry*).

3.4 Pré-processamento de dados

Para assegurar a robustez e a confiabilidade dos modelos, foi realizado um pré-processamento dos dados envolvendo as seguintes etapas:

- i) A variável dependente indica se a transação de F&A foi concluída (1) ou não concluída (0). As variáveis independentes estão descritas na Tabela 1, sendo essas as variáveis finais que ficaram sem dados faltantes.
- ii) Os dados foram divididos em conjunto de treino (70%) e teste (30%), utilizando a técnica de estratificação, que mantém a proporção original das classes (concluído/não concluído) nos dois conjuntos, garantindo uma avaliação equilibrada nos modelos. Na base de dados 74,21% foram concluídas e 25,79% foram não concluídas.
- iii) Devido ao desbalanceamento existente entre as classes da variável dependente (concluído versus não concluído), foram empregados pesos inversamente proporcionais à frequência de classes (ponderação das classes - *class weight*), de forma que os modelos não privilegiassem a classe majoritária e garantissem resultados mais robustos.

3.5 Validação cruzada estratificada

Com vistas à garantia da generalização dos modelos, foi implementado o procedimento de validação cruzada (*cross-validation*). Aplicou-se a técnica *Stratified K-fold Cross-Validation* com 5 divisões (*folds*), garantindo a manutenção da proporção das classes em todas as partições. Esse procedimento é especialmente adequado para problemas de classificação binária com classes desbalanceadas.

A robustez dos modelos preditivos desenvolvidos nesta pesquisa foi assegurada por meio da aplicação de procedimentos consolidados na literatura de ciência de dados. Após a divisão estratificada da amostra em subconjuntos de treinamento (70%) e teste (30%), foi empregada validação cruzada

estratificada do tipo *k-fold* com $k = 5$, garantindo que cada subconjunto preservasse a proporção original das classes da variável-alvo ("concluído" e "não concluído"). Essa abordagem permite uma avaliação mais fidedigna do desempenho preditivo dos modelos, minimizando o viés de sobreajuste (*overfitting*) e maximizando a generalização sobre novos dados.

O pré-processamento dos dados incluiu a padronização das variáveis explicativas contínuas por meio do algoritmo *StandardScaler* da biblioteca *scikit-learn*, garantindo que todos os atributos numéricos possuíssem média zero e desvio padrão igual a um. Essa transformação é particularmente importante em modelos sensíveis à escala dos dados, como a regressão logística regularizada e redes neurais.

Ainda que a variável dependente estivesse moderadamente desbalanceada, com maior proporção de operações concluídas, optou-se por não aplicar técnicas de reamostragem artificial (como *SMOTE* ou subamostragem aleatória), pois o objetivo do estudo era manter a integridade estatística da base real e refletir o comportamento verdadeiro das F&A no Brasil entre 2000 e 2016. Para lidar com esse desbalanceamento, o desempenho dos modelos foi avaliado por métricas que penalizam previsões desequilibradas, como o F1-score, além das tradicionais: precisão, *recall* e AUC (Área sob a Curva ROC).

Na sequência, os modelos foram comparados com base no seu desempenho na base de teste, e os resultados foram complementados com as médias e desvios-padrão obtidos nas rodadas de validação cruzada. O modelo de regressão logística com penalização L1 (LASSO), por exemplo, foi calibrado com ajuste do hiperparâmetro $\alpha = 1.0$, enquanto o modelo de rede neural utilizou $\text{size} = 1000$ e $\text{decay} = 2$, após testes iniciais com diferentes combinações.

Por fim, foram geradas as matrizes de confusão normalizadas em percentual, de forma a permitir comparações proporcionais entre modelos. Dessa forma, esse conjunto de procedimentos assegura a reprodutibilidade da pesquisa e amplia a confiabilidade dos resultados obtidos, fornecendo suporte metodológico rigoroso às interpretações inferenciais apresentadas nas próximas seções.


4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nesta seção, são apresentados e discutidos os resultados obtidos com a aplicação dos modelos de *machine learning*. A análise inicia-se com as correlações entre as variáveis e, em seguida, aprofunda-se no desempenho preditivo dos algoritmos e na relevância dos fatores determinantes para a conclusão de operações de F&A no Brasil. A métrica central para avaliação da performance dos modelos foi a Área Sob a Curva ROC (AUC), por sua capacidade de medir o poder de discriminação de um classificador (Agresti, Kateri & Lovric 2011).

4.1 Análise de Correlação das Variáveis

Uma análise preliminar por meio de uma matriz de correlação de Pearson foi realizada para investigar as relações lineares entre as variáveis do estudo, conforme Figura 1.

Figura 1:
Correlações entre as variáveis de estudo.



O principal achado foi a forte correlação positiva observada entre as variáveis *Aberta* (empresa adquirente de capital aberto) e *Public* (empresa-alvo de capital aberto). Este resultado era esperado, visto que, no contexto de F&A, existe uma sobreposição conceitual significativa entre elas. A maioria das demais variáveis apresentou correlações próximas de zero, sugerindo que as relações que determinam o sucesso de uma transação são predominantemente não lineares, o que reforça a adequação do uso de algoritmos de *machine learning*, capazes de capturar padrões mais complexos.

4.2 Desempenho Comparativo dos Modelos Preditivos

Os quatro algoritmos de *machine learning* foram treinados e testados, e seus desempenhos preditivos estão consolidados na Tabela 2. O principal resultado é que todos os modelos demonstraram uma capacidade preditiva considerável e estatisticamente significativa, com valores de AUC consistentemente superiores a 0,69. Isso indica que, utilizando apenas nove variáveis de transações passadas, é possível prever o desfecho de uma negociação de F&A com um grau de acerto substancialmente melhor do que o acaso. Sobre a base de dados de teste foram estimadas todas as métricas de performance que serão apresentadas, sendo todas calculadas por validação cruzada estratificada 5-fold.

Tabela 2
Resultados Comparativos dos Modelos Preditivos

Algoritmos	Regressão Logística	Regressão Logística com Penalização	Redes Neurais	Random Forest
Hiperparâmetros Otimizados	$\lambda = 0,1$	$\alpha=0,5$ $\lambda = 0,0002$	$size=1000$ $decay = 2$	$mtry= 6$ $ntree = 500$
AUC ROC Média	0,6915	0,6921	0,7416	0,7094
AUC (IC95%)	(0,6639; 0,7191)	(0,6645; 0,7197)	(0,7165; 0,7667)	(0,6831; 0,7357)
Ranking de Importância das Variáveis				
1	lnexpgeral	Aberta	Aberta	lnexpgeral
2	Allcash	Acquirerbank	lnexpgeral	Allcash
3	Acquirerbank	Allcash	Acquirerbank	Acquirerbank
4	Aberta	lnexpgeral	Allcash	Aberta
5	Setorsic	Setorsic	AllStock	Setorsic

Ao analisar a Tabela 2, o modelo de Redes Neurais destacou-se com o melhor desempenho, atingindo uma AUC de 0,7416. Isso sugere que a sua capacidade de modelar interações não lineares complexas foi a mais eficaz para capturar os padrões subjacentes aos dados de F&A. O modelo *Random Forest* também apresentou um desempenho robusto (AUC = 0,7094), superando os modelos lineares da regressão logística.

4.2.1 Performance dos Modelos Preditivos

Além da métrica área sob a curva ROC (AUC), foram utilizadas outras métricas fundamentais para avaliação de modelos classificatórios, proporcionando uma visão mais abrangente e detalhada da performance dos modelos, conforme Tabela 3. As métricas foram calculadas sobre a base de teste, preservando o caráter fora da amostra, e são complementadas por validação cruzada 5-fold estratificada.

Tabela 3:

Performance dos modelos preditivos

Modelo	precisão	recall	f-score	AUC
Regressão Logística	0,708	0,736	0,722	0,691
Regressão Logística (LASSO)	0,837	0,670	0,743	0,692
Redes Neurais	0,874	0,658	0,745	0,742
Random Forest	0,715	0,726	0,720	0,709

O modelo de redes neurais e o Lasso exibem maiores valores de precisão, indicando que, quando preveem uma transação como concluída, essa previsão é correta com elevada frequência. Esse resultado é estratégico do ponto de vista empresarial, pois evita falsos positivos, ou seja, reduz a chance de investir tempo e recursos em negociações que tendem a não se concretizar.

Ainda pela tabela 3, observa-se que a regressão logística tradicional e o *Random Forest* apresentam maiores *Recall*, indicando uma maior capacidade de identificar corretamente as transações que efetivamente foram concluídas

(menor taxa de falsos negativos). O modelo de redes neurais apresentou um maior *F1-score* (0,745), métrica que mostra um equilíbrio entre a capacidade de prever corretamente os casos positivos (concluídos) e a confiabilidade dessas previsões.

As matrizes de confusão dos modelos são apresentadas na Tabela 4.

Tabela 4:

Matriz de Confusão dos modelos

Modelo	Classe Real	visto Não Concluído (%)	visto Concluído (%)
são Logística	ncluído	16,22%	9,55%
são Logística	ido	24,38%	49,85%
		40,60%	59,40%
	ncluído	16,07%	9,70%
	ido	24,48%	49,75%
		40,55%	59,45%
Neurais	ncluído	13,70%	12,04%
Neurais	ido	22,56%	51,69%
		36,26%	63,73%
Forest	ncluído	14,03%	11,74%
Forest	ido	5,47%	68,76%
		19,50%	80,50%

A partir das tabelas 2, 3 e 4, se o objetivo for minimizar falsos positivos LASSO ou Regressão Logística são mais recomendados. O modelo *Random Forest* apresentou melhor desempenho na classe positiva (68,76%) com menor falsos negativos (5,47%), ou seja, alta capacidade de identificar corretamente negociações que realmente se concluem, sendo crucial para evitar perdas por omissão, se destacando como melhor escolha prática. Por outro lado, se a meta for acurácia geral e exploração de padrões complexos, o modelo de Redes Neurais é mais indicado, principalmente se a interpretabilidade não for restrição.

À luz das hipóteses formuladas na Seção 2.3, os resultados obtidos nos modelos de regressão logística, LASSO, redes neurais e *Random Forest* oferecem evidências empíricas que dialogam diretamente com a fundamentação teórica proposta.

A hipótese H1, que sugere que operações envolvendo empresas pertencentes a grupos econômicos nacionais tendem a apresentar maior chance de conclusão, foi sustentada empiricamente, uma vez que a variável “grupo econômico” demonstrou importância estatística significativa na regressão logística tradicional, bem como ganhou peso considerável na análise de importância de variáveis da *Random Forest*. Esse resultado reforça a ideia de que estruturas organizacionais mais consolidadas e coordenadas reduzem a assimetria de informações, conforme previsto pela Teoria da Agência.

Quanto à hipótese H2, que propõe que o controle estrangeiro aumentaria a probabilidade de conclusão, os modelos apresentaram resultados mistos. A regressão LASSO, ao realizar seleção automática de variáveis, manteve essa variável no modelo, mas com impacto marginal. Já os modelos baseados em aprendizado de máquina, sobretudo *Random Forest*, atribuíram-lhe menor importância relativa. Essa evidência sugere que a presença de controle estrangeiro pode estar condicionada a outras variáveis contextuais não capturadas diretamente no modelo, como o tipo de operação ou o ambiente institucional.

A hipótese H3, de que operações em setores regulados teriam menor probabilidade de conclusão, mostrou-se fortemente alinhada aos resultados empíricos. Em todos os modelos preditivos, a variável "setor regulado" apresentou impacto significativo e consistente com a expectativa teórica da Teoria dos Custos de Transação. Esse achado reforça a ideia de que entraves institucionais e exigências legais mais rígidas tendem a dificultar o avanço das negociações.

Por fim, a hipótese H4, que associa maior número de aquisições anteriores à maior probabilidade de conclusão, também encontra suporte nos resultados. A variável "experiência anterior" apresentou sinal positivo e robusto nos modelos estatísticos e ganhou destaque especial entre as variáveis mais relevantes na *Random Forest* e nas redes neurais. Esse achado reforça a Teoria dos Recursos e Capacidades, segundo a qual empresas com maior *know-how* e capacidade operacional possuem vantagem competitiva na execução de processos complexos como as F&A.

Em síntese, os resultados empíricos corroboram, em grande medida, o modelo conceitual desenvolvido, fortalecendo o argumento de que variáveis estruturais, institucionais e organizacionais são determinantes relevantes para a previsibilidade da conclusão de operações de F&A no Brasil.

4.3 Discussão sobre a Importância das Variáveis

A análise da importância das variáveis, também apresentada na Tabela 2, revela importantes contribuições. Embora o ranking exato varie entre os algoritmos, um conjunto de preditores consistentemente figura entre os mais relevantes: *lnexpgeral* (experiência da adquirente), *Aberta* (natureza do capital da adquirente), *Acquirerbank* (adquirente ser um banco) e *Allcash* (pagamento em dinheiro).

A proeminência da variável *lnexpgeral* sugere que a experiência acumulada da empresa adquirente em negociações anteriores é um forte indicador da probabilidade de conclusão do negócio, possivelmente por uma maior capacidade de gestão do processo e de *due diligence*.

Vale a pena ressaltar que, a importância da variável *lnexpgeral* pode ser compreendida à luz da *Resource-Based View (RBV)*, segundo a qual a vantagem competitiva das organizações está diretamente relacionada à posse de recursos valiosos, raros e difíceis de imitar (Barney, 1991). Nesse contexto, o histórico de participação em processos de fusão e aquisição configura um ativo intangível organizacional, indicando conhecimento tácito, competências jurídicas e operacionais e capacidade de conduzir *due diligence* com maior acurácia. Essa experiência acumulada reduz o risco de falhas negociais, mesmo na presença de assimetrias de informação, o que é coerente com os achados de Golubov et al. (2012), que demonstraram que empresas com histórico ativo de

F&A tendem a concluir mais transações com sucesso, especialmente em mercados emergentes onde os riscos institucionais são elevados.

A relevância de *Allcash* corrobora a hipótese de que transações pagas em dinheiro, por serem menos complexas e mais rápidas, têm maior chance de sucesso (Ermel & Martelanc, 2018). Similarmente, a importância de *Setorsic* (negócios no mesmo setor) pode ser atribuída à menor assimetria informacional, como também argumentado por Ermel e Martelanc (2018). Isso reforça o papel da *Teoria da Assimetria de Informação* como estrutura explicativa central das decisões de F&A.

Como apontado por Servaes e Zenner (1996), pagamentos exclusivamente em dinheiro são percebidos como sinais positivos de confiança por parte do adquirente, pois indicam menor incerteza quanto à avaliação da empresa-alvo e maior liquidez disponível. Esse sinal é ainda mais relevante em mercados caracterizados por menor transparência contábil e jurídica, como o brasileiro. Adicionalmente, transações intra-setoriais (capturadas pela variável *Setorsic*) tendem a apresentar menores custos de integração e maior familiaridade entre as partes envolvidas, reduzindo barreiras culturais, tecnológicas e operacionais. Essa leitura dialoga com os achados de Gouveia (2014) e Ermel e Martelanc (2018), que destacam a menor incidência de falhas em F&A entre empresas do mesmo setor, em razão da melhor capacidade de avaliação mútua e do menor grau de assimetria informacional envolvido.

A variação no ranking de importância entre os modelos é esperada. A Regressão Logística, um modelo linear, atribui pesos fixos, enquanto as Redes Neurais e o *Random Forest* identificam a importância das variáveis com base em interações complexas e não lineares, explicando por que a variável *Aberta* assume a primeira posição nesses modelos mais sofisticados.

4.4 Implicações e Escolha do Modelo Final

Os resultados demonstram que o *machine learning* é uma ferramenta viável e poderosa para a análise preditiva em F&A. A escolha de um modelo final para aplicação prática, contudo, envolve um *trade-off* entre performance e interpretabilidade.

Embora o modelo de Redes Neurais tenha apresentado a maior acurácia (AUC), ele opera como uma "caixa-preta" (*black-box*), tornando difícil a interpretação direta do impacto de cada variável. Por outro lado, modelos como a Regressão Logística e o *Random Forest* (que permite a análise da importância das variáveis) oferecem maior transparência.

Para um gestor que busca não apenas prever, mas também entender os fatores de risco, o modelo de *Random Forest* pode representar a escolha mais equilibrada, combinando alto desempenho preditivo com a capacidade de ranquear os determinantes do sucesso. A performance muito similar entre todos os modelos também sugere que, para este conjunto de dados, mesmo os algoritmos mais simples já conseguem extrair informações relevantes.

A questão da interpretabilidade dos modelos não é apenas uma preocupação técnica, mas estratégica. Em processos de F&A, as decisões envolvem múltiplos stakeholders, como conselhos de administração, investidores institucionais, consultorias financeiras e órgãos reguladores, que demandam justificativas claras sobre os critérios utilizados na avaliação e aprovação de uma transação. Modelos como o *Random Forest* e a Regressão Logística possibilitam

essa transparência ao fornecerem medidas quantitativas da importância de cada variável e a direção de seu impacto.

Outro ponto relevante diz respeito à operacionalização e manutenção dos modelos. Algoritmos como o *Random Forest* apresentam uma curva de aprendizagem mais acessível para equipes analíticas internas e menor sensibilidade a parâmetros mal ajustados, o que os torna mais viáveis para organizações que ainda estão amadurecendo sua cultura de dados. Além disso, sua resiliência a *overfitting* e capacidade de lidar com variáveis correlacionadas tornam-no especialmente útil em bases heterogêneas e imperfeitas como as de F&A.

A literatura destaca que a escolha de modelos em contextos organizacionais deve considerar não apenas a performance estatística, mas também fatores como escalabilidade, facilidade de atualização, integração com sistemas legados e custo computacional (Guidotti et al., 2018). Portanto, o *Random Forest*, por unir desempenho sólido, interpretabilidade e aplicabilidade prática, pode ser uma solução ideal para empresas que desejam incorporar inteligência artificial em suas decisões de forma responsável, transparente e sustentável.

4.5 Barreiras institucionais e o papel do ambiente regulatório no Brasil

Apesar dos avanços metodológicos apresentados neste estudo, é necessário reconhecer que fatores institucionais específicos do ambiente brasileiro podem influenciar significativamente a conclusão de operações de F&A (Cai et al., 2024), independentemente dos determinantes econômicos ou estratégicos identificados pelos modelos preditivos.

O Brasil caracteriza-se por uma elevada complexidade regulatória, com sistemas jurídico-tributários que impõem altos custos de conformidade e incertezas quanto ao tempo de aprovação de grandes transações, especialmente quando envolvem órgãos como o CADE (Conselho Administrativo de Defesa Econômica) e a CVM (Comissão de Valores Mobiliários). Vale enfatizar que a burocracia excessiva, a lentidão nos processos de autorização e a instabilidade das regras fiscais e societárias constituem obstáculos relevantes à eficácia das F&A. Esses elementos criam assimetrias institucionais que não estão integralmente refletidas nas variáveis tradicionalmente utilizadas em modelos quantitativos, mas que podem comprometer a taxa de sucesso de negociações. As fragilidades na governança regulatória e a baixa previsibilidade das decisões judiciais ou administrativas tendem a gerar prêmios de risco informais, impactando tanto o apreçamento quanto a probabilidade de conclusão de um acordo.

Dessa forma, embora os algoritmos de *machine learning* demonstrem elevado desempenho preditivo com base em características observáveis das transações, há um espaço importante para o aprimoramento dos modelos mediante a incorporação de variáveis que capturem o contexto institucional e regulatório, especialmente em mercados emergentes como o Brasil, nos quais a institucionalidade ainda se mostra volátil e heterogênea. Considerar essas nuances é fundamental para garantir maior acurácia e utilidade prática dos sistemas preditivos no suporte à tomada de decisão estratégica.

5 CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo central avaliar a eficácia de algoritmos de *machine learning* na predição do desfecho de operações de Fusões e Aquisições (F&A) no mercado brasileiro. A análise demonstrou que, mesmo com um conjunto limitado de variáveis públicas, os modelos preditivos, em especial as Redes Neurais e o *Random Forest*, alcançaram um poder de discriminação significativo ($AUC > 0,70$), validando a abordagem como uma ferramenta robusta e viável para a análise de F&A.

A principal contribuição desta pesquisa é dupla. Do ponto de vista teórico-metodológico, o trabalho avança na literatura nacional ao aplicar e comparar sistematicamente técnicas de inteligência artificial a um problema tradicionalmente dominado por análises econométricas mais convencionais, preenchendo uma lacuna de estudos preditivos no contexto de um mercado emergente. Na perspectiva prática, os resultados oferecem um caminho para que gestores, investidores e assessores financeiros possam desenvolver ferramentas de suporte à decisão, permitindo uma avaliação de risco mais quantitativa e objetiva e, potencialmente, evitando o envolvimento em negócios com baixa probabilidade de conclusão.

Não obstante, o estudo possui limitações que abrem caminhos para investigações futuras. A primeira reside na disponibilidade de dados; a análise foi restrita a um conjunto de nove variáveis devido à grande quantidade de dados ausentes em outras, uma dificuldade inerente ao estudo de F&A. A performance similar entre os modelos, embora robusta, pode ser um reflexo dessa limitação. A segunda limitação é o foco exclusivo na conclusão da transação como medida de sucesso, desconsiderando a performance da empresa no período pós-fusão.

Diante disso, a agenda de pesquisa futura é vasta. Estudos subsequentes poderiam enriquecer os modelos com um leque mais amplo de variáveis, como indicadores macroeconômicos, métricas de governança corporativa ou dados textuais extraídos de notícias e relatórios (análise de sentimento), além de dados posteriores ao ano de 2016. Seria igualmente importante aplicar arquiteturas mais avançadas, como modelos de *deep learning*, ou testar o framework aqui proposto em outros mercados emergentes para fins comparativos. Por fim, uma extensão natural seria utilizar o *machine learning* não apenas para prever a conclusão do negócio, mas também para estimar a probabilidade de criação de valor no longo prazo.

Em suma, este trabalho não apenas valida uma nova fronteira analítica para o estudo de F&A no Brasil, mas também pavimenta o caminho para pesquisas futuras que integrem de forma ainda mais profunda a ciência de dados e as finanças corporativas, buscando respostas mais precisas para os complexos desafios do mundo dos negócios.

REFERÊNCIAS

- Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4. <https://doi.org/10.1016/j.heliyon.2018.e00938>.
- Agresti, A., Kateri, M., & Lovric, M. (2011). International encyclopedia of statistical science. *Categorical Data Analysis*.

- Arsini, L., Straccamore, M., & Zaccaria, A. (2022). Prediction and visualization of Mergers and Acquisitions using Economic Complexity. *PLOS ONE*, 18. <https://doi.org/10.1371/journal.pone.0283217>.
- Barney, J. (1991). Special theory forum the resource-based model of the firm: origins, implications, and prospects. *Journal of management*, 17(1), 97-98. <https://doi.org/10.1177/014920639101700107>
- Brasil. (1976). *Lei nº 6.404, de 15 de dezembro de 1976. Dispõe sobre as sociedades por ações*. Diário Oficial da União.
- Brigham, E. F., Gapenski, L. C., & Ehrhardt, M. C. (2001). *Administração financeira: Teoria e prática* (Tradução da 10ª ed. norte-americana). São Paulo: Atlas.
- Cai, Y., Kamaşak, R., & Gorener, R. (2024). Closing the deal faster: the role of institutions and government involvement in cross-border M&A completions in Brazil. *Critical Perspectives on International Business*. <https://doi.org/10.1108/cpoib-08-2024-0088>.
- de Melo Santos, N., Ferraz, I. N., Falqueto, J. M. Z., & Verga, E. (2017). A teoria dos custos de transação nas pesquisas de estratégia no Brasil. *Revista Ibero Americana de Estratégia*, 16(2), 4-18. <https://doi.org/10.5585/riae.v16i2.2437>
- DeYoung, R., & Huang, M. (2021). The external effects of bank executive pay: Liquidity creation and systemic risk. *Journal of Financial Intermediation*, 47, 100920.
- Erel, I., Liao, R. C., & Weisbach, M. S. (2012). Determinants of cross-border mergers and acquisitions. *The Journal of finance*, 67(3), 1045-1082. <https://doi.org/10.1111/j.1540-6261.2012.01741.x>
- Ermel, M. D. A., & Martelanc, R. (2018). Antecedentes e consequências da participação de advisor em fusões e aquisições. *Revista de Administração Contemporânea*, 22(6), 859-884. <https://doi.org/10.1590/1982-7849rac2018170282>
- Ferreira, D. (2002). *Fusões, aquisições e reestruturações de empresas* (1ª ed.). Lisboa: Edições Sílabo.
- Gaughan, P. A. (2007). *Mergers, acquisitions, and corporate restructuring* (4th ed.). Hoboken, NJ: John Wiley & Sons.
- GIL, A. C. (2021). *Métodos e Técnicas de Pesquisa Social*, 7ª edição.[SI]: Grupo GEN, 2019.
- Golubov, A., Petmezas, D., & Travlos, N. G. (2012). When it pays to pay your investment banker: New evidence on the role of financial advisors in M&As. *The Journal of Finance*, 67(1), 271-311. <https://doi.org/10.1111/j.1540-6261.2011.01712.x>
- Gomes, E., Angwin, D. N., Weber, Y., & Yedidia Tarba, S. (2013). Critical success factors through the mergers and acquisitions process: revealing pre-and post-M&A connections for improved performance. *Thunderbird international business review*, 55(1), 13-35. <https://doi.org/10.1002/tie.21521>

- Gouveia, L. O. D. (2014). Fusões e aquisições: desenvolvimento de um modelo de prospecção para bancos comerciais.
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., & Pedreschi, D. (2018). A survey of methods for explaining black box models. *ACM computing surveys (CSUR)*, 51(5), 1-42.
- Hajek, P., & Henriques, R. (2024). Predicting M&A targets using news sentiment and topic detection. *Technological Forecasting and Social Change*. <https://doi.org/10.1016/j.techfore.2024.123270>.
- Huang, H., Xu, H., & Wu, D. (2024). Signaling or not? The pricing strategy under fairness concerns and cost information asymmetry. *Eur. J. Oper. Res.*, 321, 789-799. <https://doi.org/10.1016/j.ejor.2024.10.006>.
- Ikwuo, A., Nworie, G., & Ukoha, A. (2025). Cloud accounting: strategic advantage for maximising Shareholder wealth in Nigeria's pharmaceutical sector. *Journal of Governance and Accountability Studies*. <https://doi.org/10.35912/jgas.v5i1.2529>.
- Jensen, M. C., & Meckling, W. H. (2008). Teoria da firma: comportamento dos administradores, custos de agência e estrutura de propriedade. *Revista de Administração de Empresas*, 48, 87-125.
- Jensen, M. C., & Ruback, R. S. (1983). The market for corporate control: The scientific evidence. *Journal of Financial economics*, 11(1-4), 5-50. [https://doi.org/10.1016/0304-405X\(83\)90004-1](https://doi.org/10.1016/0304-405X(83)90004-1)
- Kopp, R., Fligge, B., & Eulerich, M. (2022). Mergers and acquisitions research - A bibliometric analysis. *European Management Journal*. <https://doi.org/10.1016/j.emj.2022.09.006>.
- KPMG Corporate Finance (2011). Pesquisa de Fusões e Aquisições 2010 - 4º trimestre. Brasil.
- Ławryńczuk, M. (2024). Koopman operator-based multi-model for predictive control. *Nonlinear Dynamics*. <https://doi.org/10.1007/s11071-024-09615-7>.
- Liu, J. (2025). Asymmetric Information: Insights Across Economic and Market Contexts. *Advances in Economics, Management and Political Sciences*. <https://doi.org/10.54254/2754-1169/2025.21130>.
- Liu, S., & Yang, C. (2024). Business strategy and M&A transactions. *The Quarterly Journal of Finance*. <https://doi.org/10.1142/s2010139224500058>.
- Lucas, E. C., Di Agustini, C. A., Santos, H. G., da Silva Oliveira, J. C., Ribeiro, V. H. A., & Neto, L. C. (2025). Previsão de Sinistros com Machine Learning: Evidências no Setor de Seguros Automotivos no Brasil. *Revista de Gestão e Secretariado*, 16(6), e4970-e4970. <https://doi.org/10.7769/gesec.v16i6.4970>
- Ocieszak, M. (2020). Determinants of Companies' Financial Performance Following M&A Transactions in Poland. *Central European Management Journal*, 28, 51 - 66. <https://doi.org/10.7206/cemj.2658-0845.34>.

- Officer, M., Cousin, J., & De Bodt, E. (2022). Financial constraints, ownership dilution, and the method of payment in M&A transactions. *Journal of Corporate Finance*. <https://doi.org/10.1016/j.jcorpfin.2022.102250>.
- Ray, K. G. (2022). *Mergers and acquisitions: Strategy, valuation and integration*. PHI Learning Pvt. Ltd.
- Saikia, A., Kumar, D., & Mundi, H. (2022). Domestic, inbound and outbound M&A activity interdependence in Brazil. *Managerial Finance*. <https://doi.org/10.1108/mf-03-2022-0146>.
- Santos, H. G. D., Nascimento, C. F. D., Izbicki, R., Duarte, Y. A. D. O., & Porto Chiavegatto Filho, A. D. (2019). Machine learning para análises preditivas em saúde: exemplo de aplicação para prever óbito em idosos de São Paulo, Brasil. *Cadernos De saúde pública*, 35, e00050818.
- Sarker, I. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *Sn Computer Science*, 2. <https://doi.org/10.1007/s42979-021-00592-x>.
- Servaes, H., & Zenner, M. (1996). The role of investment banks in acquisitions. *The Review of Financial Studies*, 9(3), 787-815.
- Spence, M. (1973). l the MIT press. *The Quarterly Journal of Economics*, 87(3), 355-374.
- Tanure, B., & Cançado, V. L. (2004). Relacionando o motivo da aquisição com diferentes processos de integração cultural. *Revista Economia & Gestão*, 4(8).
- Tariq, M., Naqvi, S., Shahid, Z., Hallo, L., & Paul, J. (2024). Signaling theory and its relevance in international marketing: a systematic review and future research agenda. *International Marketing Review*. <https://doi.org/10.1108/imr-04-2022-0092>.
- Verma, J. (2024). The Study of Merger and Acquisitions: Value Creation and Risk Management. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*. <https://doi.org/10.55041/ijsrem31193>.
- Warde Junior, W. J. (2009). *Fusão, cisão, incorporação e temas correlatos*. Quartier Latin.
- Vasconcelos, F. C., Caldas, M. P., & Wood Júnior, T. (2004). Fusões e aquisições no Brasil: uma análise crítica do teatro de operações. *Comportamento organizacional e gestão*, 10, 43-58.
- Zhang, R., & Doukas, J. (2020). Corporate Managerial Ability, Earnings Smoothing, and Acquisitions. *SPGMI: Compustat Fundamentals (Topic)*. <https://doi.org/10.2139/ssrn.3854243>.