

FUCAPE PESQUISA E ENSINO S/A – FUCAPE BH

DANILO RICARDO LOPES BATISTA ROCHA

**PREVISIBILIDADE DE CAIXA: aplicação da Lógica Fuzzy na predição do fluxo
de caixa livre ao acionista**

BELO HORIZONTE

2024

DANILO RICARDO LOPES BATISTA ROCHA

PREVISIBILIDADE DE CAIXA: aplicação da Lógica Fuzzy na predição do fluxo de caixa livre ao acionista

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis e Administração, da Fucape Pesquisa e Ensino S/A - Fucape BH, como requisito parcial para obtenção do título de Mestre em Ciências Contábeis e Administração – Nível Profissionalizante.

Orientador: Prof. Dr. Danilo Soares Monte-Mor.

BELO HORIZONTE

2024

DANILO RICARDO LOPES BATISTA ROCHA

PREVISIBILIDADE DE CAIXA: aplicação da Lógica Fuzzy na predição do fluxo de caixa livre ao acionista

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis e Administração, da Fucape Pesquisa e Ensino S/A - Fucape BH, como requisito parcial para obtenção do título de Mestre em Ciências Contábeis e Administração – Nível Profissionalizante.

Aprovada em 21 de novembro de 2024.

COMISSÃO EXAMINADORA

Profº Dr.: DANILO SOARES MONTE-MOR

Fucape Pesquisa e Ensino S/A

Profº Dr.: OCTÁVIO LOCATELLI

Fucape Pesquisa e Ensino S/A

Profº Msc.: LEONARDO VERONEZ SIMÕES

Instituto Federal do Espírito Santo

RESUMO

A predição de fluxos de caixa é essencial para os diversos usuários da informação contábil e para as entidades, uma vez que a incerteza sobre esses fluxos pode impactar variáveis importantes, como a política de pagamento de dividendos e de investimentos em pesquisa e desenvolvimento. Além disso, é fundamental para estimar a capacidade de pagamento de empresas que cometem infrações contra a Administração Pública, buscando conciliar a multa ótima com a capacidade financeira da entidade e aumentar a eficácia na arrecadação de sanções pecuniárias aplicadas por órgãos públicos. Neste contexto, esta pesquisa teve como objetivo comparar a Lógica Fuzzy com outros modelos de predição (ARIMA, ARIMAX, Regressão Linear e *Machine Learning*) a fim de verificar se apresenta maior precisão na estimativa de fluxos futuros de caixa livre ao acionista. A análise foi realizada com dados de 71 empresas durante o período de 2004 a 2023, período que as entidades passaram a adotar obrigatoriamente o padrão IFRS e também com impactos da pandemia do Covid-19. Para alcançar o objetivo desta pesquisa, utilizou-se, como ferramenta tecnológica, a linguagem de programação Python e comparou-se o desempenho dos modelos por meio das métricas de performance MSE, MAE e RMSE. Os resultados demonstram que a série temporal univariada de Lógica Fuzzy obteve melhor performance que os demais modelos, sendo capaz de diminuir incertezas típicas de situações observadas no mundo real. Assim, esta pesquisa sugere que a aplicação da Lógica Fuzzy pode aperfeiçoar a política sancionatória de órgãos públicos, promovendo maior eficácia nas arrecadações sem comprometer a continuidade operacional das empresas. A projeção de fluxos futuros de caixa também é relevante para investidores, gestores, credores e analistas, ampliando as contribuições desta pesquisa para além do setor público, alcançando igualmente o setor privado e de finanças. Dessa forma, o estudo contribui para o aprimoramento das práticas de previsão de fluxos de caixa, especialmente no uso de inteligência artificial.

Palavras-chave: Predição de fluxos de caixa; Lógica Fuzzy; capacidade de pagamento.

ABSTRACT

The prediction of cash flows is essential for various users of accounting information and for entities, as uncertainty about these flows can impact important variables such as dividend policy and investments in research and development. Furthermore, it is crucial for estimating the payment capacity of companies that commit infractions against Public Administration, seeking to align the optimal fine with the financial capacity of the entity and increase the effectiveness in collecting pecuniary sanctions applied by public authorities. In this context, this research aimed to compare Fuzzy Logic with other prediction models (ARIMA, ARIMAX, Linear Regression, and Machine Learning) to verify if it shows greater accuracy in estimating future free cash flow to equity. The analysis was conducted with data from 71 companies during the period from 2004 to 2023, a period in which entities were required to adopt the IFRS standard, also considering the impacts of the COVID-19 pandemic. To achieve the objective of this research, the Python programming language was used as a technological tool, and the performance of the models was compared using the MSE, MAE and RMSE performance metrics. The results demonstrate that the univariate Fuzzy Logic time series performed better than the other models, reducing uncertainties typical of real-world situations. Thus, this research suggests that applying Fuzzy Logic can improve the sanctioning policy of public authorities, promoting greater effectiveness in collections without compromising the operational continuity of the companies. The projection of future cash flows is also of interest to investors, managers, creditors, and analysts, expanding the contributions of this research beyond the public sector, also reaching the private and financial sectors. Therefore, the study contributes to the improvement of cash flow forecasting practices, especially with the use of artificial intelligence.

Keywords: Cash flow prediction; Fuzzy Logic; payment capacity.

SUMÁRIO

1 INTRODUÇÃO	6
2 REFERENCIAL TEÓRICO.....	12
2.1 FLUXO DE CAIXA E A IMPORTÂNCIA DE SUA PREVISIBILIDADE	12
2.2 O IMPACTO DA INCERTEZA DOS FLUXOS DE CAIXA EM DIFERENTES VARIÁVEIS	18
2.3 MODELOS DE PREDIÇÃO.....	20
2.3.1 Lógica Fuzzy	22
2.3.2 <i>Auto Regressive Integrated Moving Average - ARIMA</i>	26
2.3.3 Regressão Linear	32
2.3.4 <i>Machine Learning</i>	33
2.3.5 Comparação entre os métodos de predição	38
3 METODOLOGIA	40
4 ANÁLISE DE DADOS.....	46
4.1 ANÁLISE DESCRITIVA.....	46
4.2 RESULTADOS DOS MODELOS PREDITIVOS.....	48
4.3 DISCUSSÃO TEÓRICO-PRÁTICA DOS RESULTADOS	53
5 CONCLUSÃO	65
REFERÊNCIAS.....	68

Capítulo 1

1 INTRODUÇÃO

A previsão de fluxos de caixa futuros é um tema amplamente pesquisado no campo da contabilidade e de finanças, sendo considerada crucial para tomada de decisões dos diversos usuários da informação contábil e também para a entidade (Hendriksen & Breda, 1999; Barth et al., 2001; Correia Neto et al., 2002; Nikkinem & Sahlström, 2004; Lustosa & Santos, 2007; Bhandari & Iyer, 2013; Linares-Mustarós et al., 2013; Javedan & Largani, 2014; Costa, 2015; Mulenga & Bhatia, 2017; Soboleva et al., 2018; Noury et al., 2020; Sarraf, 2020; Ali & Ali, 2021; Chen et al., 2021; Evdokimov et al., 2023).

Nesse contexto, o *Financial Accounting Standards Board* – FASB, por meio do *Statement of Financial Accounting Concepts Nº 1*, de 1978, afirmou que o lucro de uma entidade possui capacidade preditiva superior, em comparação a informações restritas aos efeitos financeiros de pagamento e recebimento de caixa, para prever fluxos de caixa futuros, posicionando-o como a principal variável para predição da geração futura de caixa.

Conforme Mulenga e Bhatia (2017), diversos pesquisadores de contabilidade e de finanças dedicaram-se a investigar essa afirmação do FASB, analisando a capacidade preditiva dos lucros, dos fluxos de caixa e de seus componentes na predição de fluxos futuros de caixa.

Posto isso, algumas pesquisas subsequentes apresentaram resultados que questionam essa afirmação. Estudo como o de Barth et al. (2001) sugere que os fluxos de caixa e *accruals* têm o potencial de melhor prever fluxos futuros de caixa em

relação aos lucros, levantando dúvidas sobre a supremacia dos lucros como a principal variável preditiva. De acordo com Mulenga e Bhatia (2017), os achados na literatura são inconsistentes no tocante a essa afirmação do FASB, uma vez que os resultados encontrados são mistos.

Por conseguinte, Dadteev et al. (2020) destacam que o progresso tecnológico está inserido em diversas atividades humanas. Como consequência, esses autores enfatizam que ele é capaz de processar grandes volumes de dados de maneira eficaz, o que resulta em inovações de muitas organizações, sejam elas comerciais ou estatais.

Portanto, diante da falta de consenso sobre qual variável melhor prevê os fluxos futuros de caixa e considerando os avanços tecnológicos e o crescente uso de inteligência artificial, o presente trabalho contribui com as pesquisas a respeito da predição de fluxos de caixa futuros, mais especificamente no tocante a métodos de previsão de fluxos de caixa, explorando técnicas modernas.

Nesse sentido, Giudice et al. (2017) descrevem que a Lógica Fuzzy já foi aplicada em diversos campos de estudo, tais como controle de tráfego ferroviário, diagnóstico médico, avaliações geológicas a respeito da estabilidade de taludes, entre outros.

Em finanças, Sanchez-Roger et al. (2019) demonstram que o número de artigos utilizando a Lógica Fuzzy vem aumentando significativamente desde a metade dos anos 2000. Lucas et al. (2022) também destacam que a Lógica Fuzzy vem ganhando notoriedade em virtude de sua boa performance em previsão de séries temporais.

Dessa forma, este trabalho visa responder o seguinte questionamento: a Lógica Fuzzy pode ser entendida como um método que traz avanços e reduz incertezas em relação à predição de futuros Fluxos de Caixa Livre ao Acionista – FCLA quando comparada aos métodos *Auto Regressive Integrated Moving Average* – ARIMA e sua extensão *Moving Average with Explanatory Variable* – ARIMAX, Regressão Linear e *Machine Learning*?

Assim, o objetivo desta pesquisa é verificar se o modelo de série temporal de Lógica Fuzzy apresenta melhores resultados de predição de FCLA do que outros modelos presentes na literatura.

Para tanto, foram utilizados dados de 71 empresas listadas na Bolsa de Valores do Brasil, a B3, durante o período de 2004 a 2023, período que as entidades passaram a adotar obrigatoriamente o padrão *International Financial Reporting Standards* – IFRS e também com impactos da pandemia da Covid-19. Ainda, comparou-se o desempenho dos modelos por meio das métricas de performance *Mean Squared Error* – MSE, *Mean Average Error* – MAE e *Root Mean Squared Error* – RMSE.

Dessa forma, por meio da linguagem de programação Python e do uso de técnicas estatísticas, este estudo procurou testar o grau de assertividade de predição de FCLA das empresas em análise para períodos que possam ser considerados de curto, médio ou longo prazo (4 trimestres a 24 trimestres). Os resultados encontrados demonstram que a série temporal univariada de Lógica Fuzzy obteve melhor performance na predição do que outras técnicas envolvidas nesta pesquisa.

Estudos semelhantes foram desenvolvidos por Weytjens et al. (2021) e Evdokimov et al. (2023). Aqueles compararam os métodos ARIMA, Prophet, *Multi-Layer Perceptrons* – MLP e *Long Short-Term Memory* – LSTM para previsão de fluxo de caixa provenientes de clientes, enquanto estes investigaram o desempenho de 9

algoritmos de *Machine Learning* em comparação a um modelo ARIMA na predição da taxa de crescimento de fluxo de caixa livre.

Por todo o exposto, a pesquisa traz contribuições para a literatura no tocante a métodos de predição de fluxos futuros de caixa, variável amplamente pesquisada desde quando o FASB (1978) emitiu documento considerando que o lucro de uma entidade tem o potencial de melhor prever fluxos de caixa futuros do que informações limitadas aos efeitos financeiros de pagamento e recebimento de caixa. Dessa forma, o estudo contribui para o aprimoramento das práticas de previsão de fluxos de caixa, especialmente no uso de inteligência artificial.

Como contribuição prática, esta pesquisa propõe a aplicação da metodologia Lógica Fuzzy para a predição, por parte dos órgãos públicos, de cenários mais realistas de FCLA a fim de que possam proporcionar melhores negociações e aplicações de multas mais efetivas com o intuito de combater atos contra a Administração Pública, aperfeiçoando a política sancionatória por parte de órgãos públicos e resultando em ganhos para a sociedade.

Essa sugestão se justifica devido a identificação de baixa arrecadação de valores de multas aplicadas, consoante monitoramento efetuado pelo Tribunal de Contas da União - TCU referente aos exercícios de 2015 e 2016 (Acórdão 729/2020 - Plenário¹), o qual inclui multas impostas por autarquias federais, entre elas, Banco Central do Brasil – Bacen, Comissão de Valores Mobiliários – CVM, Conselho Administrativo de Defesa Econômica – CADE, Superintendência de Seguros Privados – SUSEP etc. Conforme esse monitoramento, foram arrecadadas, em média, 2,37%

¹ Disponível em: https://pesquisa.apps.tcu.gov.br/documento/acordao-completo/*/NUMACORDAO%253A729%2520ANOACORDAO%253A2020/DTRELEVANCIA%2520desc%252C%2520NUMACORDAOINT%2520desc/0.

dos valores totais de multas aplicadas, representando um baixo grau de efetividade na arrecadação dessas multas.

De forma complementar, Pimenta (2022) realizou um levantamento a respeito das multas aplicadas pelo CADE durante o período de 2009 a 2020. Como resultado, Pimenta (2022) identificou uma arrecadação no referido período na faixa de 5,01% das multas estabelecidas por esse órgão, representando uma taxa de efetividade baixa na arrecadação dessas multas.

Ademais, a recente Arguição de Descumprimento de Preceito Fundamental – ADPF 1051/DF, em trâmite no Supremo Tribunal Federal – STF², pede a suspensão dos pagamentos das obrigações pecuniárias, que incluem indenizações e multas, aplicadas em todos os acordos de leniência firmados entre o Estado e empresas investigadas durante a Operação Lava Jato, anteriores à assinatura do Acordo de Cooperação Técnica – ACT, em 6/8/2020. Entre as razões apontadas na referida ADPF, destacam-se eventuais obrigações pecuniárias desproporcionais e que podem ameaçar a continuidade da atividade empresarial das empresas, além de comprometer a restituição dos valores referentes aos danos causados ao erário.

Essa ADPF fez com que o STF determinasse que os entes públicos, consensualmente com as empresas que firmaram acordos de leniência e estavam habilitadas nos autos da referida ADPF, buscassem tratativas de renegociar os acordos, levando em conta a capacidade de pagamento das empresas (*ability to pay*) a partir de análise técnica de suas situações contábeis.

² Disponível em: <https://portal.stf.jus.br/processos/detalhe.asp?incidente=6605876>.

Dessa forma, a predição de fluxos futuros de caixa é importante na análise de capacidade de pagamento (*ability to pay*) de sanções pecuniárias aplicadas por órgãos públicos a empresas infratoras (Farber et al., 2016).

Oportuno enfatizar também que projeções de fluxos futuros de caixa são importantes para investidores, gestores, analistas (Li et al., 2015) e, dessa forma, a pesquisa também é relevante e apresenta contribuições além do seu uso no setor público, alcançando igualmente o setor privado e de finanças.

Capítulo 2

2 REFERENCIAL TEÓRICO

2.1 FLUXO DE CAIXA E A IMPORTÂNCIA DE SUA PREVISIBILIDADE

O *Financial Accounting Standards Board* – FASB emitiu, em 1978, o *Statement of Financial Accounting Concepts Nº 1*, o qual diz respeito aos objetivos dos relatórios financeiros para as empresas. Entre os objetivos, o FASB (1978) descreve que os relatórios financeiros fornecem informações aos seus diversos usuários, tais como credores e investidores, a fim de ajudá-los na avaliação do montante, do tempo e das incertezas referentes aos fluxos futuros de caixa. Ainda, o FASB (1978) considera que o lucro de uma entidade tem o potencial de melhor prever fluxos de caixa futuros do que informações restritas aos efeitos financeiros de pagamento e recebimento de caixa.

Dechow (1994) destaca que o sucesso de uma entidade está estritamente relacionada com sua capacidade de gerar fluxos de caixa maiores que os desembolsos ocorridos.

Hendriksen e Breda (1999) informam que potenciais investidores fundamentam suas decisões com base nos fluxos futuros de caixa da companhia, os quais são a base para estimar o valor de mercado de título de dívidas, de ações, bem como de outros instrumentos financeiros constantes na contabilidade da entidade, tais como debêntures, hipotecas, notas promissórias etc. Esses autores enfatizam que grande parte das mensurações contábeis de uma empresa se sustentam em fluxos de caixa passados, presentes e/ou futuros, podendo fornecer informações relevantes aos usuários das demonstrações contábeis no tocante a predições. Dessa forma,

Hendriksen e Breda (1999) definem que o principal objetivo da contabilidade é fornecer dados que ajudem nessa predição do volume de caixa.

No mesmo sentido, Barth et al. (2001) lecionam que a habilidade de uma entidade em gerar fluxos de caixa influencia o valor de seus títulos.

Conforme Correia Neto et al. (2002), a projeção de fluxos de caixa é frequentemente estimada a fim de se realizar uma gestão financeira, ou seja, como forma de procurar se antecipar a uma situação financeira operacional, a seu ponto de equilíbrio financeiro, identificar eventuais necessidades de captação de recursos, bem como sua capacidade de investimento.

Nikkinen e Sahlström (2004) também relatam que o objetivo principal dos relatórios financeiros é fornecer informações para os diferentes usuários das informações contábeis a respeito dos fluxos de caixa futuros das empresas. Esses autores destacam que a padronização mundial das práticas contábeis contribui para que os relatórios financeiros atinjam esse objetivo independentemente do ambiente contábil.

Nikkinen e Sahlström (2004) ainda complementam que as previsões de fluxos futuros de caixa são importantes para diversas áreas, como, por exemplo, na avaliação de ações.

Lustosa e Santos (2007) também apontam que gestores, credores, investidores etc. tomam decisões no presente tendo como base uma determinada expectativa a respeito dos fluxos futuros de caixa da entidade. Para esses autores, a previsão, por exemplo, dos fluxos livres futuros de caixa é a medida que interessa para quem resolve investir em uma empresa. Para isso, Lustosa e Santos (2007) destacam que

as informações constantes nas demonstrações contábeis são elementos importantes nessa análise.

Bhandari e Iyer (2013) descrevem, de forma geral, a importância dos fluxos de caixa, exemplificando seu uso para pagamento de salários e dívidas, aquisições de bens, além de poder compensar os acionistas da empresa. Ainda, Bhandari e Iyer (2013) também destacam que a falta de dinheiro pode ocasionar um acúmulo de inadimplimento de contas a pagar e, em último caso, a falência da companhia.

Por sua vez, Linares-Mustarós et al. (2013) descrevem que a gestão do caixa e sua previsão consistem em uma importante ferramenta para o empreendedor no sentido de ele poder estimar se precisará adicionar mais dinheiro em seu negócio, além dos recursos gerados por meio das operacionais normais da empresa, a fim de evitar a falta de fundos.

Linares-Mustarós et al. (2013) exemplificam cenários de previsão de fluxos de caixa. Esses autores informam que, em um cenário pessimista, se a empresa apresentar fluxo de caixa positivo, pode-se deduzir que a companhia não terá problemas com pagamentos a serem realizados. Por outro lado, caso a entidade apresente fluxo de caixa negativo em um cenário otimista, Linares-Mustarós et al. (2013) discorrem que se pode deduzir que a empresa terá dificuldades em efetuar os pagamentos.

De forma complementar, Javedan e Largani (2014) consideram a previsão de fluxos de caixa uma atividade importante nas decisões econômicas das empresas, uma vez que é os fluxos de caixa são a base das atividades operacionais, bem como para pagamento de juros, de impostos, de investimentos etc.

Nesse contexto de predição de fluxo futuros de caixa, Costa (2015) relata que, consoante estudos elaborados em todo o mundo, variáveis contábeis podem prever os fluxos de caixa. Portanto, segundo Costa (2015), as demonstrações contábeis são uma importante fonte para tomada de decisões gerenciais, seja para analisar o passado, seja para prever resultados futuros por meio de dados anteriores.

Costa (2015) cita, por exemplo, que uma boa administração do caixa em empresas que atuam no mercado de seguros é indispensável para sua operação e continuidade, em virtude dos compromissos financeiros assumidos perante segurados e/ou beneficiários do seguro, os quais são muitas vezes imprevisíveis, sendo, portanto, relevante nesse setor.

No setor de seguros, Costa (2015) ainda complementa que as demonstrações contábeis de companhias desse segmento são encaminhadas mensalmente ao órgão regulador a fim de que ele acompanhe o desempenho e solvência dessas entidades, o que demonstra interesse por parte do governo. Nesse ponto, inclusive, Costa (2015) destaca a importância de estudos sobre a previsibilidade dos fluxos de caixa para subsidiar o regulador brasileiro na formulação de políticas públicas.

Mulenga e Bhatia (2017) descrevem que a previsão de fluxos futuros de caixa de uma empresa é uma questão fundamental na área de contabilidade e finanças. Dessa forma, Mulenga e Bhatia (2017) também destacam que a previsão dos fluxos de caixa é importante para os negócios da entidade, bem como para credores, investidores, pesquisadores e demais usuários dos relatórios financeiros.

Soboleva et al. (2018) descrevem, por sua vez, que o excesso de caixa na entidade pode significar uma utilização ineficiente dos recursos financeiros da empresa, enquanto que a falta de caixa pode comprometer os indicadores de desempenho, agravar a situação financeira e, em última instância, resultar em

falência. Portanto, Soboleva et al. (2018) afirmam que a solvência e a estabilidade da empresa dependem do funcionamento equilibrado dos fluxos de caixa.

Adicionalmente, Sarraf (2020) discorre que a previsão de fluxos futuros de caixa é essencial para as empresas, pois esses fluxos são a base das amortizações de empréstimos e/ou financiamentos, pagamentos de juros e também distribuição de dividendos.

Chen et al. (2021) consideram que a previsão dos fluxos futuros de caixa de forma mais precisa é essencial para a avaliação de empresas. Ademais, esses autores também consideram a precisão importante para os analistas que realizam previsões dos fluxos de caixa, uma vez que sua carreira e reputação são impactadas pelo seu desempenho e grau de assertividade.

Noury et al. (2020) também destacam a importância das informações presentes nos relatórios contábeis para fins de previsão de fluxo de caixa, o qual, segundo esses autores, é uma variável relevante no mundo dos investimentos, o que inclui acionistas, banqueiros, gestores e demais partes interessadas nas informações presentes nas demonstrações contábeis.

Nesse sentido, Noury et al. (2020) elencam, por exemplo, que a previsão de fluxos de caixa operacionais, variável objeto de estudo desses autores, é importante para os tomadores de decisão quando estão diante de decisões de investimento e/ou financiamento, tais como financiamento de projetos futuros, pagamento de dívidas relacionadas à manutenção das atividades empresais que podem aumentar a lucratividade, além de decisões referentes à política de pagamento de dividendos. Ademais, Noury et al. (2020) complementam que a previsão de fluxos de caixa é fundamental para detectar cenários de deterioração da situação financeira das empresas.

Ali e Ali (2021) também explicam que o objetivo principal dos relatórios financeiros é prever fluxos futuros de caixa. Esses autores informam que a previsão de potenciais fluxos futuros de caixa pode ajudar os executivos das empresas a melhor gerir os fluxos de caixa da entidade, considerando a manutenção de suas operações, estratégias de investimento e de financiamento a fim de buscar a sustentabilidade e crescimento da companhia. Ali e Ali (2021) também acrescentam que a previsão de fluxos futuros de caixa é interessante para investidores, uma vez que os fluxos futuros de caixa trazidos a valor presente determinam o valor do investimento, podendo, inclusive, prever os valores das ações.

Ainda sobre a avaliação de ações de uma empresa, Ali e Ali (2021) destacam a importância da previsão dos fluxos de caixa de uma companhia, pois o pagamento de dividendos no futuro está relacionado com a capacidade que a entidade possui de gerar fluxos de caixa potenciais.

Ali e Ali (2021) também enfatizam que a geração de fluxos de caixa futuros de uma empresa impacta diversos *stakeholders*. Para o setor de construção, por exemplo, esses autores destacam a importância da previsão dos fluxos de caixa com o objetivo de avaliar a distribuição de receitas e despesas de um projeto. Ali e Ali (2021) ressaltam que uma má gestão do caixa pode impactar negativamente as empresas desse setor da economia, diminuindo sua lucratividade, ou até mesmo levando à falência, bem como também impacta negativamente o cumprimento de prazos.

Evdokimov et al. (2023), por sua vez, estudaram especificamente o fluxo de caixa livre, o que os autores definem como uma medida do caixa livre aos acionistas após a aplicação de todos os recursos necessários em investimentos, bem como no pagamento de despesas. Dessa forma, Evdokimov et al. (2023) explicam que os

investidores têm interesse em prever o crescimento dos fluxos de caixa a fim de estimar o valor intrínseco de um negócio, ou seja, quanto um negócio ou ativo vale.

2.2 O IMPACTO DA INCERTEZA DOS FLUXOS DE CAIXA EM DIFERENTES VARIÁVEIS

Considerando que um dos objetivos da contabilidade é fornecer informações aos seus diversos usuários a fim de que possam, entre outras análises, realizar a predição dos fluxos futuros de caixa (FASB, 1978; Hendriksen & Breda, 1999; Nikkinen & Sahlström, 2004; Ali & Ali, 2021) e considerando também a importância dos fluxos de caixa para a entidade e seus *stakeholders* (Hendriksen & Breda, 1999; Barth et al., 2001; Correia Neto et al., 2002; Nikkinen & Sahlström, 2004; Lustosa & Santos, 2007; Bhandari & Iyer, 2013; Linares-Mustarós et al., 2013; Javedan & Largani, 2014; Costa, 2015; Mulenga & Bhatia, 2017; Soboleva et al., 2018; Noury et al., 2020; Sarraf, 2020; Ali & Ali, 2021; Chen et al., 2021; Evdokimov et al., 2023), alguns estudos procuraram verificar o impacto da incerteza dos fluxos de caixa em determinadas variáveis, tais como na política de pagamento de dividendos (Chay & Suh, 2009) e em investimentos em pesquisa e desenvolvimento (Beladi et al., 2021).

Nesse sentido, o estudo de Chay e Suh (2009) demonstrou que empresas com maiores incertezas em relação aos fluxos de caixa tendem a pagar dividendos mais baixos, além de diminuir também a probabilidade de pagarem dividendos aos seus acionistas, sendo, portanto, um determinante fundamental da política de distribuição de dividendos. O racional por trás desse resultado pode ser o fato de que entidades com alta incerteza nos fluxos de caixa têm medo da escassez de caixa, além dos custos relacionados a eventuais financiamentos externos (Chay & Suh, 2009).

Ainda sobre dividendos, Walkup (2016) investigou a relação entre a incerteza no nível de mercado e a decisão referente à distribuição de dividendos. Os resultados encontrados por Walkup (2016) demonstraram um impacto estatisticamente significativo nas decisões de pagamento de dividendos, observando que empresas que possuem baixos níveis de fluxos de caixa tendem a reduzir o pagamento de dividendos, ou até mesmo suspender os pagamentos, como uma atitude conservadora a fim de guardar recursos financeiros, enquanto que empresas com altos níveis de fluxos de caixa tendem a recomprar ações, demonstrando uma decisão oportunista.

Nota-se, portanto, um exemplo da importância do gerenciamento dos fluxos de caixa, bem como de sua previsibilidade, visto que, consoante Walkup (2016), uma companhia somente tenderá a reduzir o pagamento de dividendos por ação se os fluxos de caixa atuais e/ou futuros estiverem comprometidos por fatores internos ou externos à entidade.

Por sua vez, Beladi et al. (2021) pesquisaram, utilizando dados de empresas listadas na bolsa de valores de Xangai e Shenzhen, a relação entre as incertezas no tocante à fluxos de caixa e os investimentos realizados em pesquisa e desenvolvimento, o que pode resultar em inovações. Como resultados, esses autores observaram que entidade com maiores incertezas referentes aos fluxos de caixa futuros tendem a investir de forma mais cautelosa e conservadora em pesquisa e desenvolvimento, enquanto que empresas que possuem menos incerteza, ou seja, fluxos de caixa mais previsíveis, tendem a realizar investimentos de forma mais ousada em pesquisa e desenvolvimento.

Sobre a capacidade de inovação, Beladi et al. (2021) destacam que é determinante para a competitividade das empresas, bem como para a taxa de

crescimento econômico e influência internacional. Entretanto, esses autores informam que os custos com inovação apresentam características de longo prazo e de altos gastos. Dessa forma, Beladi et al. (2021) destacam que as empresas serão mais eficazes em suas atividades de inovação se puderem aproveitar oportunidades e reduzir riscos relativos às incertezas dos fluxos de caixa, visto que os resultados desses autores demonstram que as inovações corporativas são bastante sensíveis às incertezas dos fluxos futuros de caixa.

Outro ponto que Beladi et al. (2021) apresentam diz respeito ao financiamento externo. Beladi et al. (2021) discorrem que quanto maiores às incertezas sobre os fluxos de caixa e, conseqüentemente, maior a assimetria informacional entre os agentes, maiores tendem a ser os custos de financiamento, impactando os investimentos corporativos.

2.3 MODELOS DE PREDIÇÃO

A predição de fluxos futuros de caixa é importante para os diversos usuários da informação contábil, bem como para a entidade (Hendriksen & Breda, 1999; Barth et al., 2001; Correia Neto et al., 2002; Nikkinem & Sahlström, 2004; Lustosa & Santos, 2007; Bhandari & Iyer, 2013; Linares-Mustarós et al., 2013; Javedan & Largani, 2014; Costa, 2015; Mulenga & Bhatia, 2017; Soboleva et al., 2018; Noury et al., 2020; Sarraf, 2020; Ali & Ali, 2021; Chen et al., 2021; Evdokimov et al., 2023).

A respeito dos fluxos de caixa livre da companhia, Cunha et al. (2014) distinguem-os em Fluxo de Caixa Livre da Firma – FCLF e Fluxo de Caixa Livre ao Acionista – FCLA. Cunha et al. (2014) conceituam o FLCF como o fluxo de caixa livre disponível a todos os supridores de capital, ou seja, acionistas e credores, enquanto

o FCLA considera novas captações de dívidas, bem como o pagamento do seu principal e juros.

Por sua vez, Fernandez (2007) detalha que o FCLA é calculado após a contabilização de todas as receitas operacionais e financeiras, despesas com reinvestimento em bens de capital e investimento em capital de giro, captação e/ou amortização de empréstimos e financiamentos e, também, tributos.

Cunha et al. (2014) complementam que para se estimar os fluxos de caixa esperados, deve-se projetar as demonstrações do resultado e balanços patrimoniais. Entretanto, consoante Correia et al. (2002), a estimativa de projeções não é uma tarefa fácil e simples. Para Correia et al. (2002), as extrapolações futuras requerem que as premissas adotadas sejam bem fundamentadas e embasadas conceitualmente a fim de que o projetado e o realizado não apresentem diferenças significativas.

Por conseguinte, um modelo pode ser definido como uma equação matemática a qual procura representar a realidade e que contenha uma variável a ser prevista como função de observações passadas e de parâmetros estimados. (Weytjens et. al., 2021). Assim, considera-se um bom modelo de predição quando a diferença entre os valores estimados e os de fato realizados é minimizada (Weytjens et al., 2021).

Conforme Dadteev et al. (2020), não existe um único modelo de predição de fluxos futuros de caixa que possa ser utilizado em todas as circunstâncias. Esses autores enfatizam que é necessário entender cada modelo de previsão, os quais possuem características distintas e podem ser melhor aplicados a depender, por exemplo, do horizonte temporal.

A seguir, são apresentadas as descrições e possíveis aplicações da Lógica Fuzzy, ARIMA, juntamente com sua extensão ARIMAX, Regressão Linear e *Machine Learning* na predição de variáveis.

2.3.1 Lógica Fuzzy

Uma abordagem apresentada por Zadeh (1973) corresponde à Lógica Fuzzy, a qual, por meio de variáveis linguísticas, declarações condicionais e algoritmos fuzzy, é capaz de lidar, de forma aproximada e eficaz, com análises de sistemas complexos e processos de decisão.

Zadeh (1973) explica que as variáveis linguísticas presentes na Lógica Fuzzy têm como principal função fornecer um meio sistemático para uma caracterização aproximada de fenômenos complexos, tal qual é realizada pelo cérebro humano em diversas tarefas, inclusive cotidianas (andar, cozinhar, dirigir, procurar um objeto etc.). Para esse autor, os elementos-chave do pensamento humano não são números com alto grau de precisão, mas sim rótulos de conjunto difusos (fuzzy) a fim de executar uma tarefa com um grau mínimo de precisão.

Para Caetano (2021), considerar variáveis como elementos linguísticos é mais simples do que expressar a realidade em números. Segundo esse autor, no mercado financeiro os analistas constantemente procuram interpretar o significado dos números por meio de palavras. Dessa forma, Caetano (2021) descreve que, em um conjunto fuzzy, uma variável linguística é sempre acompanhada de adjetivos como “alto”, “baixo”, “pouco”, “muito pouco”, “muito pequeno” etc. dependendo de seu nível de pertinência.

No caso de séries temporais fuzzy, Lucas et al. (2022) explicam que a criação de valores de variáveis linguísticas depende de três hiperparâmetros, sendo eles: a quantidade de partições que o universo da série temporal foi dividido; a técnica utilizada para esse particionamento, a qual existem basicamente duas (intervalos fixos e intervalos desiguais); e a função de pertinência.

Cardoso (2010) também descreve que, diferentemente da teoria dos conjuntos clássicos, a qual determinado elemento pertence ou não a um conjunto, os conjuntos fuzzy são modelos matemáticos capazes de lidar com as imprecisões e incertezas, isto é, quando não é possível determinar se um dado pertence ou não a um conjunto, ou seja, sendo capaz de estimar valores pertencentes a um intervalo vago.

Conforme Giudice et al. (2017), ao contrário de uma afirmação determinística, a qual atribui-se que determinada variável é X, a Lógica Fuzzy permite um julgamento sem definição exata e unívoca, possibilitando a afirmação que uma variável é aproximadamente X. Essas variáveis podem ser, por exemplo, receitas, despesas financeiras, taxa de desconto etc., quando apresentam valores incertos.

Giudice et al. (2017) explicam que o conjunto fuzzy é constituído por elementos que apresentam grau de pertencimento de 0 a 1. Para tanto, inicialmente é atribuído 1 para o valor que se acredita ser o mais provável e 0 quando o valor não fizer parte do conjunto de valores assumidos pela variável. Dessa forma, qualquer outro valor atribuível a essa variável e que esteja entre os valores mínimos e máximos será colocado no conjunto fuzzy.

Nesse sentido, Bagnoli e Smith (1998) explicam que a Lógica Fuzzy não se baseia em uma lógica dual ou binária, mas sim que permite julgamentos imprecisos por meio de uma função de pertencimento, isto é, determinado elemento poderá assumir um grau de pertencimento entre 0 e 1, e não somente 0 ou 1. Assim, conforme

aponta Zadeh (1973), a transição de uma variável entre pertencimento e não pertencimento acontece de forma gradual, e não abrupta.

Ainda, Zadeh (1973) complementa que, tal como aplicada em técnicas quantitativas, é possível criar declarações condicionais entre as variáveis linguísticas da forma SE *A* ENTÃO *B*. Por fim, os algoritmos fuzzy são capazes de caracterizar relações complexas através de uma sequência ordenada de instruções.

Em resumo, Caetano (2021) considera que a Lógica Fuzzy vem se destacando dentre as diversas áreas do ramo da inteligência artificial, uma vez que possibilita uma associação simultânea entre dados numéricos e conhecimento linguístico, onde expressões qualitativas representam intervalos de interesse e os resultados de observações. Isso permite traduzir resultados matemáticos para um formato mais acessível, com expressões como “muito alto”, “bastante caro”, “mais baixo”, “menos quente”, entre outras (Caetano, 2021).

Posto isso, Yao et al. (2005) aplicaram a Lógica Fuzzy em seus estudos com o objetivo de testar a capacidade de diminuir as incertezas relacionadas à predição de modelo de *valuation* de empresas, mais precisamente no tocante ao fluxo de caixa descontado. Como resultado, os citados autores concluíram que essa ferramenta contribui para a análise do valor intrínseco de determinado ativo.

Caetano (2006) apresentou aplicações práticas do uso da Lógica Fuzzy, em especial no tocante a decisões de investimentos e fixação da taxa de juros no Brasil. O autor enfatiza o fato de essa metodologia criar uma associação simultânea entre dados numéricos e conhecimento linguístico, sendo uma característica deste último a difícil quantificação da informação linguística em variáveis numéricas, o que é possível por meio da *defuzzificação*.

Assim, ao comparar a série histórica da taxa Selic estabelecida pelo Banco Central do Brasil - Bacen, no período de fevereiro de 2000 a abril de 2003, com os valores de saída nas respostas fornecidas por meio da Lógica Fuzzy, Caetano (2006) identificou um padrão de elevação ou diminuição dessa taxa similar às decisões reais, antecipando-se, inclusive, em alguns períodos às decisões do Bacen.

Giudice et al. (2017) aplicaram a Lógica Fuzzy em análise de investimentos imobiliários, especificamente à compra de um edifício comercial. A conclusão dos autores é no sentido de que esse método pode reduzir incertezas e melhorar o processo de tomada de decisão por parte de investidores e operadores do setor imobiliário, o qual apresenta características de mercado com informações imperfeitas.

Por sua vez, Zrobek et al. (2020) também propõem a utilização do método da Lógica Fuzzy para fins de determinação de valor de mercado de terras agrícolas. Conforme esses autores, a Lógica Fuzzy é capaz de fornecer um resultado final mais objetivo do que outras metodologias, no caso estudado, além de apresentar maior transparência e menores custos.

Posto isso, estudos com aplicação da Lógica Fuzzy podem ser encontrados desde a década de 80 como, por exemplo, Buckley (1987), que se concentrou em aplicar a Lógica Fuzzy na área de matemática financeira e concluiu como satisfatória o uso dessa técnica em finanças, a qual é a área de concentração deste trabalho. Ainda, Cai et al. (2015) consideram que a predição baseada em séries temporais fuzzy pode ter uma acurácia satisfatória em situações encontradas no mundo real.

A respeito de análise e predição por meio baseada em séries temporais, Lucas et al. (2022) apresentam a biblioteca pyFITS de linguagem de programação Python. Segundo esses autores, essa biblioteca é capaz de aplicar modelos básicos de séries temporais fuzzy, sendo de acesso livre e aberto.

2.3.2 Auto Regressive Integrated Moving Average - ARIMA

Dadteev et al. (2020) informam que métodos de previsão de fluxos de caixa por meio de séries temporais já demonstraram êxito diversas vezes. Um modelo citado pelos autores corresponde ao ARIMA, que se trata de uma extensão do modelo denominado *Auto Regressive Moving Average Model* – ARMA.

Segundo Dadteev et al. (2020), ambos os modelos acima são adequados para descrever e prever valores de séries temporais. Entretanto, o modelo ARMA deve ser aplicado a séries temporais estacionárias, ou seja, aquelas que suas propriedades probabilísticas não alteram ao longo do tempo. Já o modelo ARIMA pode ser aplicado tanto para séries temporais estacionárias quanto não estacionárias.

Werner e Ribeiro (2003) explicam que o modelo ARIMA também é conhecido por modelo Box-Jenkins. Esse modelo matemático é composto por três componentes representados por AR(p), de *auto regressive*, I(d), de *integrated*, e MA(q), de *moving average*, isto é, modelos ARIMA (p,d,q) (Dadteev et. al., 2020).

De forma geral, Dadteev et al. (2020) detalham que o modelo Box-Jenkins (ARIMA) é retratado pela seguinte fórmula, destacando que os parâmetros p, d e q são números inteiros não negativos:

$$\Delta^d x_t = c + \sum_{i=1}^p \alpha_i \Delta^d x_{t-1} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t \quad (1)$$

onde c , α_i e b_j são os parâmetros do modelo, Δ^d é um operador de diferença de séries temporais de ordem d e ε_t é uma série temporal estacionária (Dadteev et al., 2020).

Posto isso, para escolher qual modelo Box-Jenkins adotar, Werner e Ribeiro (2003) destacam que se deve: 1) identificar se a série temporal é estacionária ou não estacionária; 2) analisar as funções de autocorrelações (ACF) e de autocorrelações parciais (PACF); 3) estimar os parâmetros do modelo, bem como da variância do resíduo σ_ε^2 e da constante do modelo proposto; e 4) avaliar se o modelo selecionado é adequado.

Nesse mesmo sentido, Bueno (2018) ensina que a primeira condição para se estimar um modelo é classificar a série temporal em estacionária ou não estacionária. Esse autor ainda destaca que compreender o conceito de estacionariedade corresponde à ideia principal para a estimação de uma série temporal.

De acordo com os fundamentos estatísticos, uma série é considerada estacionária se tanto a média quanto a variância forem constantes para todo o período da série analisada, bem como se a autocovariância não depender do fator tempo, mas sim da distância temporal entre as medidas observadas (Bueno, 2018).

Assim, para verificar se uma série temporal é estacionária ou não-estacionária, pode-se analisar graficamente os dados da série, a fim de observar padrões, como uma inclinação onde demonstre que os dados não permanecem ao redor de uma linha horizontal ao longo do tempo ou se flutuam ao redor de uma média fixa com variância constante durante o período, bem como aplicar testes estatísticos, por exemplo, o de raiz unitária Dickey-Fuller (Werner & Ribeiro, 2003; Bueno, 2018).

Caso a série temporal seja não-estacionária, Werner e Ribeiro (2003) esclarecem que ela deve ser transformada em uma série temporal estacionária, sendo a ordem de integração (I) o que permite torná-la estacionária. Portanto, a ordem d

corresponde as quantidades de vezes que a série precisa ser diferenciada para se tornar estacionária (Bueno, 2018).

Sendo a série temporal classificada como estacionária, passa-se à identificação das ordens p e q do modelo (Bueno, 2018). Para tanto, utilizam-se as funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) com o objetivo de identificar o modelo a ser estimado (Werner & Ribeiro, 2003).

Conforme Bueno (2018), a função de autocorrelação (FAC) permite identificar a ordem $MA(q)$, ou seja, de um processo de média móvel, enquanto a função de autocorrelação parcial (FACP) revela a ordem $AR(p)$.

Identificado as ordens p , d e q do modelo, o passo seguinte é estimar os parâmetros do modelo proposto (Werner & Ribeiro, 2003; Bueno, 2018). Essa etapa pode ser realizada por meio da função de verossimilhança (Bueno, 2018) ou também pelo método de *forecasting* de mínimos quadrados incondicionais (Werner & Ribeiro, 2003).

Tendo o modelo matemático sido estimado, é necessário realizar um diagnóstico de seus resíduos a fim de analisar se não rejeitam a hipótese nula de serem ruído branco (Bueno, 2018). Dessa forma, os resíduos serão considerados ruídos brancos se tiverem média igual a zero, variância constante e não forem correlacionados com qualquer medida da série temporal em análise, ou seja, autocorrelação igual a zero (Bueno, 2018). Ainda, pode-se fazer uso do teste Ljung-Box para confirmar se os resíduos são, de fato, ruídos brancos (Werner & Ribeiro, 2003; Bueno, 2018).

Nesse sentido, Bueno (2018) enfatiza que o objetivo do pesquisador é extrair o máximo de informações da série temporal observada. Para isso, a melhor modelagem

possível é quando se obtém resíduos que correspondem a ruídos brancos e, dessa forma, o modelo estimado, teoricamente, poderá apresentar as melhores previsões estatísticas.

Bueno (2018) também destaca que o modelo ideal é aquele que for mais parcimonioso, isto é, com o menor número de parâmetros, porém que também resulte nos menores resíduos possíveis. Para tanto, critérios de informação, tais como *Bayesian Information Criterion* – BIC ou *Schwarz Bayesian Criterion* – SBC e *Akaike Information Criterion* – AIC auxiliam na identificação da quantidade de parâmetros, sendo interpretados como quanto menores seus valores, melhores os modelos estimados (Bueno, 2018).

Por todo o exposto, de forma resumida, procura-se identificar e estimar um modelo com o menor número de parâmetros possíveis, onde os resíduos gerados sejam considerados ruídos brancos e que apresentem o menor valor do critério de informação (Bueno, 2018).

Realizada a previsão dos dados da série temporal estudada, considerando um determinado intervalo de confiança, Bueno (2018) apresenta medidas para avaliar o desempenho das previsões efetuadas como, por exemplo, a *Mean Square (Prediction) Error* – MS(P)E, a *Mean Absolute (Prediction) Error* – MA(P)E e a *Mean Absolute Percentual Error* – MAPE.

Por fim, Dadteev et al. (2020) ainda complementam que o modelo ARIMA é flexível, podendo o modelo Box-Jenkins ser modificado levando em considerações características como a sazonalidade, o *Seasonal ARIMA* (SARIMA), ou a fracionalidade, o *Fractionally ARIMA* (FARIMA).

Almeida (2023) também cita outra extensão do modelo ARIMA: o *Moving Average with Explanatory Variable* (ARIMAX), o qual inclui variáveis independentes ou exógenas à análise da série temporal. Segundo Almeida (2023), essas variáveis exógenas podem ser tanto séries temporais quanto determinados fatores que possam impactar na série temporal da variável alvo ou dependente.

Conforme descrito por Almeida (2023), o modelo ARIMAX pode ser representado pela equação a seguir:

$$X_t = c + \sum \alpha_i X_{t-1} + \sum \beta_i \varepsilon_{t-i} + \beta_1 Z_{1t} + \dots + \beta_k Z_{kt} + \varepsilon_t \quad (2)$$

onde $\beta_1 Z_{1t} + \dots + \beta_k Z_{kt}$ correspondem aos termos exógenos, denotados por $Z_{1t}, Z_{2t}, \dots, Z_{kt}$, onde k representa o número de variáveis exógenas incluídas no modelo. Já os coeficientes $\beta_1, \beta_2, \dots, \beta_k$ atribuem pesos à contribuição dessas variáveis exógenas na previsão da série temporal (Almeida, 2023).

Dessa forma, Dadteev et al. (2020) aplicaram o modelo ARIMA para previsão de volumes de fluxos de caixa de bancos comerciais, uma vez que se trata de um fator chave do planejamento financeiro dessas instituições no sentido de terem que manter uma quantidade de dinheiro em espécie em diferentes regiões do país.

Os resultados de Dadteev et al. (2020) foram que o modelo ARIMA demonstrou uma maior precisão, quando comparada a outros modelos, em regiões com economias mais tranquilas, como, por exemplo, mais distantes dos grandes centros e com leis mais simples. Por outro lado, a acurácia foi reduzindo à medida que se aproximava desses grandes centros comerciais.

Por sua vez, Lorek e Willinger (2008) pesquisaram a capacidade preditiva de séries temporais para fluxos trimestrais de caixa operacionais. Para tanto, compararam 4 modelos de predição: modelo de regressão de séries temporais multivariadas (MULT); modelo *Random Walk* com *Drift Process* (RWD); modelo *Seasonal Random Walk* com *Drift Process* (SRWD); e modelo BR ARIMA desenvolvido por Brown e Rozeff em 1979.

Como resultados, Lorek e Willinger (2008) identificaram que o modelo BR ARIMA superou o poder preditivo para fluxos futuros trimestrais de caixa operacionais, quando comparado aos demais modelos. A metodologia utilizada pelos autores para verificar o modelo de melhor predição foi o MAPE.

Mais recentemente, Weytjens et al. (2021) compararam os modelos ARIMA, Prophet, MLP e LSTM para predição de fluxos de caixa das contas a receber de clientes. Esses autores utilizaram como medida de desempenho a *Mean Squared Error* – MSE e a *Mean Average Error* – MAE, bem como desenvolveram outra medida, chamada de *Interest Opportunity Cost* – IOC. Os resultados encontrados foram que ARIMA apresentou pior desempenho de acurácia em comparação aos demais modelos, porém ele é mais fácil de ser aplicado do que, por exemplo, redes neurais.

Apesar disso, estudo anterior de Werner e Ribeiro (2003) enfatiza que se o modelo Box-Jenkins (ARIMA) for bem modelado será capaz de oferecer bons resultados de predição, uma vez que consistem em modelos matemáticos que procuram identificar, através da análise da correlação seriada ou autocorrelação entre os valores observados da série temporal, comportamentos que servirão de suporte e fundamento para as previsões futuras.

Isso porque o modelo Box-Jenkins tem como característica pressupor que cada valor da série pode ser determinado por meio de seus valores passados, os quais, na

maioria das vezes, apresentam uma estrutura de correlação temporal (Werner & Ribeiro, 2003).

Portanto, Weytjens et al. (2021) define ARIMA como um modelo robusto, amplamente utilizado para análise de séries temporais, com a facilidade de ser aplicado por meio de *softwares* e que também são capazes de lidar com tendências e sazonalidades.

2.3.3 Regressão Linear

A regressão linear representa um método estatístico em que as variáveis explicativas (ou preditoras), as quais são conhecidas pelo analista e/ou pesquisador, procuram prever o valor de uma variável dependente que ainda não se sabe seu valor quantitativo (Fang & Lahdelma, 2016).

Santos e Camargo (2015) explicam que esse método desenvolve uma equação, no formato de uma linha reta, com o objetivo de minimizar a soma das diferenças encontradas entre os valores previsto e os valores reais de uma determinada variável. O modelo de previsão por Regressão Linear, conforme Fang e Lahdelma (2016), pode ser assim representado:

$$Y_t = X_t b + e_t \quad (3)$$

onde Y_t refere-se a variável a ser estimada, X_t correspondem às variáveis explicativas, b diz respeito aos coeficientes das variáveis preditoras e e_t é o erro aleatório no tempo.

Ainda, Santos e Camargo (2015) discorrem que o método dos mínimos quadrados é o mais utilizado para determinar os valores dos coeficientes dessa equação.

Posto isso, Fang e Lahdelma (2016), considerando o contexto de planejamento de produção dos sistemas de aquecimento distrital na cidade de Espoo, Finlândia, aplicaram modelos de regressão linear a fim de prever a demanda de calor, visto que esse sistema entrega água aquecida aos clientes. Como resultados, Fang e Lahdelma (2016), por meio de dados históricos de condições climáticas e de consumo de calor, observaram que um modelo de regressão linear proposto apresentou melhor robustez e precisão que os demais modelos comparados.

Por sua vez, Ottaviani e De Marco (2022) aplicaram regressão linear múltipla com o objetivo de melhor prever a estimativa de custo final de um projeto. O modelo em questão foi comparado com um modelo *benchmark* e apresentou maior precisão e menor variância na referida comparação.

2.3.4 Machine Learning

Outro método que pode ser utilizado para predição de dados, inclusive na área de finanças, é o *Machine Learning* (Alzubi et al., 2018). Conforme Alzubi et al. (2018), *Machine Learning* pode ser definido como um tipo de inteligência artificial a qual os computadores, por meio de dados, pensam e aprendem tarefas por conta própria. Esses autores informam que *Machine Learning* tem sido aplicado em diversas áreas nas últimas décadas, tais como astronomia, biologia, climatologia, medicina etc. com objetivos que vão desde jogos de videogame a veículos autônomos.

No campo de finanças, Evdokimov et al. (2023) comunicam que *Machine Learning* tem ganhado popularidade para previsões financeiras, em especial, no tocante a lucros por ação e receitas.

Dessa forma, o processo de aprendizagem dos computadores possui três características principais: a definição da tarefa a ser aprendida, a medida de desempenho a ser melhorada e o método para adquirir experiência (Alzubi et al., 2018).

Alzubi et al. (2018) também explicam que, independentemente do algoritmo a ser utilizado, o modelo geral de *Machine Learning* é formado por 6 componentes: (i) coleta e preparação dos dados; (ii) seleção das características; (iii) escolha do algoritmo; (iv) seleção de modelos e parâmetros; (v) treinamento; e, por último, (vi) avaliação de desempenho.

A respeito dos algoritmos, esses são definidos como uma sequência de procedimentos a serem executados em determinada ordem, considerando os dados de entrada, a fim de resultar em dados de saída (Sicsú et al., 2023). No tocante a sua escolha, Alzubi et al. (2018) enfatizam que nem todos os algoritmos podem ser aplicados para todos os problemas, isto é, há algoritmos mais adequados para cada tipo de problema.

Além disso, Alzubi et al. (2018) explicam que os algoritmos são provenientes de diferentes paradigmas, os quais podem ser classificados em 10 categorias: (i) Aprendizado Supervisionado; (ii) Aprendizado Não Supervisionado; (iii) Aprendizado por Reforço; (iv) Aprendizado Evolutivo; (v) Aprendizado Semi-Supervisionado; (vi) Aprendizado de Conjunto; (vii) Rede Neural Artificial; (viii) Aprendizado baseado em Instâncias; (ix) Algoritmos de Redução de Dimensionalidade; e (x) Aprendizado

Híbrido. Conforme esses autores, o paradigma mais popular entre pesquisadores e profissionais é o Aprendizado Supervisionado.

Alzubi et al. (2018) explica que cada um desses paradigmas dá origem a diversos algoritmos e cita alguns, conforme Figura 1 abaixo:

Paradigma	Algoritmo
Aprendizado Supervisionado	Árvore de Decisão
	Naïve Bayes
	Máquinas de Vetores de Suporte (Support Vector Machines)
	Análise de Regressão
Aprendizado Não Supervisionado	Agrupamento K-Means (K-Means Clustering)
Aprendizado Baseado em Instâncias	Vizinhos mais Próximos (K-Nearest Neighbors)
Aprendizado de Conjunto	Floresta Aleatória (Random Forest)
Redução de Dimensionalidade	Algoritmo de Componentes Principais

Figura 1: Paradigmas e algoritmos de *Machine Learning*
 Fonte: Elaborada pelo autor

Sendo assim, Zhu et al. (2022) testaram a eficácia das previsões de fluxo de caixa livre por meio de um modelo proposto de redes neurais BP (*backpropagation*) baseado no algoritmo genético aprimorado, comparando-o com o modelo cinza, o modelo de Markov e o modelo de rede neural BP. Zhu et al. (2022) explicam que redes neurais BP correspondem a uma rede neural *feed-forward* de múltiplas camadas e que possui a capacidade de ser utilizada em previsões com dados em condições complexas, tais como não estacionariedade.

O modelo proposto por Zhu et al. (2022) considerou os fluxos de caixa livre dos últimos 5/10/15/20/25 dias, correspondendo, portanto, a 5 camadas de entrada. O número de neurônios ocultos que apresentou melhor resultado foi de 15, quando a

população da rede neural foi igual a 30, e sendo 1 neurônio de saída. Ademais, esse modelo apresentou melhor performance, quando comparado aos outros 3 modelos citados no parágrafo anterior.

Já Evdokimov et al. (2023) empregaram *Machine Learning* para prever a taxa de crescimento de fluxo de caixa livre de 100 empresas, bem como comparar seu desempenho com um modelo ARIMA. Para tanto, Evdokimov et al. (2023) utilizaram, como dados, a média e o desvio-padrão dessa variável e também índices financeiros, como índice de liquidez corrente, margem de lucro bruto, grau de alavancagem, retorno sobre ativos e retorno sobre patrimônio líquido.

Um desafio enfrentado por Evdokimov et al. (2023) foi o fato de, ao fazerem uso de dados financeiros trimestrais das companhias, a quantidade de dados ser pequena, correspondendo a um total de 120 dados disponíveis (30 anos x 4 trimestres). Assim, para superar esse problema, os autores utilizaram uma abordagem conhecida como janela expansível.

Ao comparar 9 algoritmos de *Machine Learning* (*Automatic Relevance Determination, Bayesian Ridge, Decision Tree, Random Forest, XGBoost, Lasso Linear Regression, K-Nearest Neighbor, Multilayer Perceptron e Support Vector Regressor*) com ARIMA, Evdokimov et al. (2023) concluíram que o algoritmo *K-Nearest Neighbor* – KNN (K-Vizinhos mais Próximos, em português) foi o que apresentou menor *Root Mean Squared Error* – RMSE (Raiz do Erro Quadrático Médio, em português) e, portanto, com melhor desempenho de predição, considerando uma quantidade pequena de dados.

Por sua vez, Kureljusic e Metz (2023) aplicaram algoritmos de *Machine Learning* para identificar padrões de comportamento de pagamentos de faturas realizados por clientes e, dessa forma, prever as futuras datas de pagamentos,

permitindo que as empresas tenham uma melhor gestão do caixa. Os dados utilizados corresponderam a mais de um milhão de faturas de uma empresa referentes ao período de 2017 a 2019. Como resultado, Kureljusic e Metz (2023) demonstraram que redes neurais são capazes de prever as datas de pagamento dos clientes com precisão.

A qualidade das previsões estudadas por Kureljusic e Metz (2023) foi mensurada por medidas de performance padrão, tais como R-quadrado (R^2), MAE e MSE, bem como por métricas específicas desenvolvidas pelos autores, por exemplo, porcentagem de acurácia das previsões diárias.

No contexto de análise de séries temporais, a ferramenta PyCaret facilita a aplicação de modelos complexos de *Machine Learning* de forma fácil e acessível para não especialistas, simplificando muitas funções referentes a um processo de predição (Westergaard et al., 2024).

Whig et al. (2023) explicam que o PyCaret é uma poderosa biblioteca da linguagem de programação Python simples de ser utilizada, com baixos códigos e códigos abertos de *Machine Learning*, sendo capaz de auxiliar os usuários desde a preparação dos dados até a implementação e exame do modelo.

Conforme Westergaard et al. (2024), o PyCaret aplica diversos algoritmos de *Machine Learning* automaticamente em um determinado conjunto de dados a fim de treinar e avaliar os modelos e, em seguida, apresenta aquele com melhor performance.

No estudo de Westergaard et al. (2024), o qual os autores compararam 3 ferramentas de *Machine Learning* automatizado (AutoML), o PyCaret apresentou os melhores resultados na previsão do preço do Bitcoin, considerando as métricas RMSE

e MAPE, e o melhor desempenho na previsão de mortes por Covid-19, por meio da métrica RMSE.

2.3.5 Comparação entre os métodos de predição

A Figura 2 a seguir apresenta, de forma resumida, os métodos de predição, bem como seus respectivos benefícios e limitações.

Método	Benefícios	Limitações
Lógica Fuzzy	Capaz de lidar com imprecisões, incertezas e relações complexas, podendo afirmar que uma variável é aproximadamente "X"	Requer que o analista e/ou pesquisador tenha conhecimento sobre a área de estudo
ARIMA	Amplamente utilizado, fácil de ser aplicado e adequado para modelar, descrever e prever valores de séries temporais	Pode apresentar resultados inapropriados quando a variável em análise apresentar comportamento não linear, além de necessitar de muitos dados.
ARIMAX	Além dos benefícios do modelo ARIMA, há a inclusão de variáveis independentes e/ou exógenas na análise da série temporal	Assim como o método ARIMA, pode também apresentar resultados inapropriados quando a variável em análise apresentar comportamento não linear, além de também necessitar de muitos dados.
Regressão Linear	Método tradicional e amplamente difundido, simples de ser aplicado e fácil de ser entendido e interpretado	Necessita de um número grande de observações e é menos flexível a variáveis linguísticas e opiniões de especialistas
<i>Machine Learning</i>	Inteligência artificial capaz de pensar e aprender as tarefas por conta própria, inclusive quando há poucos dados disponíveis.	A depender do algoritmo e modelo, pode ser complexo e demorado.

Figura 2: Modelos de predição de variáveis

Fonte: Elaborada pelo autor

Portanto, diante da perspectiva de que a aplicação da Lógica Fuzzy pode ser útil em cenários que apresentam incertezas e imprecisões (Cardoso, 2010; Giudice et

al., 2017), que é o caso de estimar os fluxos de caixa futuros de empresas, e o fato de esse método ter mais flexibilidade na adoção de variáveis linguísticas em comparação a métodos mais tradicionais (Lucas et al., 2022), a seguinte hipótese é testada nesta pesquisa:

H1: a Lógica Fuzzy oferece melhor precisão de fluxos futuros de caixa livres aos acionistas em comparação aos demais modelos (ARIMA, ARIMAX, Regressão Linear e *Machine Learning*).

Capítulo 3

3 METODOLOGIA

Como método científico, esta pesquisa enquadra-se como uma análise empírica, baseada em dados econômicos, financeiros e patrimoniais constantes nas demonstrações contábeis de companhias de capital aberto listadas na Bolsa de Valores do Brasil, a B3.

Ainda, conforme exposto acima, trata-se, também, de uma pesquisa com dados secundários e que foram coletados por meio da plataforma Refinitiv. Para tanto, considerou-se os trimestres do período de início de 2004 até o final de 2023, ou seja, dos últimos 20 anos, tendo a plataforma retornado com resultados para 717 entidades. Destaca-se que ao longo desse intervalo as empresas passaram a adotar obrigatoriamente o padrão *International Financial Reporting Standards* – IFRS, a partir de 2010, e também sofreram impactos da pandemia do Covid-19, a partir de 2020, caracterizando-se uma pesquisa com corte longitudinal.

Na plataforma Refinitiv, foram filtradas as seguintes variáveis para empresas com sede no Brasil: Earnings Before Interest, Taxes, Depreciation & Amortization (EBITDA); Net Income Before Minority Interest; Working Capital – Increase/(Decrease); Capital Expenditures - Total; Debt – Long-Term & Short-Term – Issuance/Retirement – Total – Cash Flow; e Free Cash Flow to Equity. A Figura 3 abaixo descreve cada uma dessas variáveis, conforme definição constante na plataforma Refinitiv.

Variável	Definição
Earnings Before Interest, Taxes, Depreciation & Amortization (EBITDA)	Representa o Lucro antes de Juros, Impostos, Depreciação e Amortização do período
Net Income Before Minority Interest	Representa o Lucro antes das Operações Descontinuadas e Itens Extraordinários e após os impostos reportados
Working Capital – Increase/(Decrease) – Cash Flow	Representa o valor total das movimentações nos ativos e passivos operacionais da entidade
Capital Expenditures – Total	Englobam gastos, por exemplo, com equipamentos, fábricas, ativos intangíveis etc. que possuem vida útil superior a um ano. Consistem tanto em despesas necessárias para manutenção quanto para crescimento da empresa.
Debt – Long-Term & Short-Term – Issuance/Retirement – Total – Cash Flow	Representam as mudanças líquidas no fluxo de caixa como consequência de alterações no nível de dívida de uma companhia
Free Cash Flow to Equity	Representa a quantidade de dinheiro disponível para os acionistas de uma determinada empresa após o pagamento de todas as despesas, bem como reinvestimentos e dívidas. Na Refinitiv, inclui: Fluxo de Caixa Líquido das Atividades Operacionais; Capex Líquido que impacta no fluxo de caixa; e Dívidas de curto e longo prazo que impactam no fluxo de caixa

Figura 3: Definição constante na plataforma Refinitiv referente as variáveis filtradas
Fonte: Elaborada pelo autor

A escolha dessas variáveis teve como referência de metodologia o estudo de Li et al. (2015), o qual os autores desagregaram o fluxo de caixa operacional em seus principais componentes com o objetivo de incorporar outras informações contábeis na previsão de fluxo de caixa operacional.

Posteriormente, observou-se que muitas entidades, como fundos de investimentos, não apresentaram sequer um valor para quaisquer das variáveis filtradas, e, portanto, optou-se por excluí-las, o que reduziu a amostra desta pesquisa

para 376 empresas. Optou-se, também, por excluir companhias do setor financeiro em virtude de apresentarem características específicas desse setor.

Por fim, com o intuito de obter uma quantidade mínima de períodos para as séries históricas das variáveis, excluiu-se, também, empresas que não possuíam, no mínimo, 60 períodos com observações para as variáveis selecionadas. Isso posto, a amostra foi composta por um total de 71 entidades.

Em seguida, realizou-se uma higienização para preenchimento de eventuais dados faltantes/ausentes. Neste caso, no período sem informação de valor para determinada variável, foi inserido o último valor válido correspondente a essa mesma variável.

Ainda, considerando que a variável alvo, Fluxo de Caixa Livre ao Acionista, pode ter uma variabilidade maior, por exemplo, do que a variável Lucro (Li et al., 2015), optou-se por aplicar uma suavização às series históricas de todas as variáveis por meio da média móvel do período corrente e o imediatamente anterior, ou seja, uma média móvel de dois em dois trimestres e cumulativamente, o que pode ajudar a identificar melhor tendências ao longo do tempo.

Outra técnica aplicada aos dados e que teve como referência os estudos de Lustosa e Santos (2007) e Li et al. (2015) foi a padronização de todas as variáveis pelo Ativo Total da entidade com o objetivo de mitigar potenciais efeitos decorrentes do tamanho das empresas. Dessa forma, para as variáveis explicativas e/ou exógenas apresentadas na Figura 3, considerou-se a razão entre a variável do ano anterior pelo Ativo Total do ano anterior. Já para a variável alvo, a razão foi entre o valor corrente do FCLA pelo Ativo Total do ano anterior.

Assim, os dados históricos a partir do 1º trimestre de 2004 serviram de referência e treinamento para aplicação dos modelos de predição ARIMA, bem como sua extensão ARIMAX, Regressão Linear, *Machine Learning* (série temporal e regressão) e Lógica Fuzzy (série temporal) a fim de estimar os fluxos de caixa livre ao acionista para períodos que possam ser considerados de curto, médio ou longo prazo (4 trimestres a 24 trimestres), considerados o conjunto de dados de validação.

É oportuno destacar que para modelos de série temporal univariada, considerou-se apenas os dados históricos do FCLA. Para os demais modelos que adotam variáveis exógenas e/ou explicativas, foram incluídos também os dados de EBITDA, Lucro Líquido, Capital de Giro, CAPEX e variação das Dívidas.

Para alcançar o objetivo desta pesquisa, utilizou-se, como ferramenta tecnológica, a linguagem de programação Python. Dessa forma, para os modelos ARIMA e ARIMAX, foi utilizada a função “auto_arima” da biblioteca “pymarima” no ambiente Colab. Essa função tem como benefício projetar automaticamente os melhores parâmetros para os referidos modelos.

Para a modelagem da regressão linear, aplicou-se a função “LinearRegression” da biblioteca “scikit-learn”, com o objetivo de treinar o modelo usando os dados de treinamento e, em seguida, realizar as previsões para os dados de validação.

Em relação aos modelos de *Machine Learning*, utilizou-se a biblioteca “PyCaret”, a qual é uma ferramenta de automação de *Machine Learning*. As funções aplicadas na modelagem foram a “TSForecastingExperient” e “RegressionExperient”.

Já para o modelo de Lógica Fuzzy, foi empregada a biblioteca “pyFTS” e a função “ConventionalFTS”, sendo que o universo de dados foi dividido em 10 partições

com função de pertinência Triangular, a qual, conforme Lucas et al. (2022), consiste em uma função de pertinência comum e aplicada em diversas pesquisas.

A Figura 4 a seguir resume as bibliotecas e funções aplicadas para cada modelo na linguagem de programação Python.

Modelo	Biblioteca	Função
ARIMA	Pdmarima	auto_arima
ARIMAX	Pdmarima	auto_arima
Regressão	scikit-learn	LinearRegression
<i>Machine Learning</i> (Série Temporal)	PyCaret	TSTimeSeriesForecaster
<i>Machine Learning</i> (Regressão)	PyCaret	RegressionExperient
Lógica Fuzzy	pyFuzzy	ConventionalFuzzy

Figura 4: Bibliotecas e funções aplicadas na linguagem de programação Python
Fonte: Elaborada pelo autor

Dessa forma, para atingir os objetivos desta pesquisa, as projeções estimadas por cada modelo foram avaliadas comparando-as com os resultados efetivamente ocorridos (valores reais). Portanto, assim como realizado por Evdokimov et al. (2023) para resolver o problema de regressão, o qual procurou minimizar a função de perda conhecida por meio do RMSE, este estudo também optou por examinar a performance dos modelos por meio dessa métrica, descrita a seguir:

$$RMSE = \sqrt{\frac{1}{T} * \sum_{t=1}^T (g_t - \hat{g}_t)^2} \quad (4)$$

onde g_t corresponde à variável alvo no tempo t e \hat{g}_t refere-se ao valor estimado pelo modelo no tempo t .

Ainda, consoante Khashei et al. (2009) e Weytjens et al. (2021), este estudo também verificou eventual ganho de desempenho da Lógica Fuzzy em relação aos demais modelos de predição por meio do *Mean Absolute Error* – MAE e do *Mean Squared Error* – MSE.

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (5)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (6)$$

onde e_i corresponde ao conjunto de erros ou resíduos observados na amostra de tamanho N (Karunasingha, 2022).

Portanto, a hipótese dessa pesquisa será confirmada se os resultados obtidos por meio das métricas RMSE, MAE e MSE para o modelo de Lógica Fuzzy forem inferiores aos resultados dessas medidas para os demais modelos, representando seu maior poder de precisão.

Capítulo 4

4 ANÁLISE DE DADOS

Considerando a metodologia definida na sessão anterior, a seguir são apresentados os resultados encontrados com os recursos de linguagem de programação Python e econométricos.

4.1 ANÁLISE DESCRITIVA

A Tabela 1 abaixo apresenta a estatística descritiva para o conjunto de empresas presentes nesta pesquisa, o que inclui a média aritmética como medida de tendência central, bem como informações de dispersão para cada variável estudada (desvio padrão e coeficiente de variação).

TABELA 1: ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS

Variável	Obs.	Média	SD	CV	Mín.	25%	50%	75%	Máx.
FCFEAT	5323.0	0,010	0,039	4,000	-0,287	-0,006	0,007	0,025	0,488
LUCROAT	5323.0	0,011	0,050	4,360	-0,628	0,003	0,011	0,022	1,919
EBITDAAT	5323.0	0,030	0,046	1,535	-0,288	0,014	0,027	0,043	1,933
CAPGIROAT	5323.0	-0,007	0,028	-4,354	-0,512	-0,016	-0,004	0,005	0,524
DIVIDAAT	5323.0	0,004	0,031	7,725	-0,279	-0,009	0,001	0,014	0,359
CAPEXAT	5323.0	0,015	0,017	1,122	-0,193	0,005	0,011	0,019	0,284

Fonte: Elaborada pelo autor

Nota: FCFEAT – Fluxo de Caixa Livre ao Acionista padronizado pelo Ativo Total; LUCROAT – Lucro Líquido padronizado pelo Ativo Total; EBITDAAT – EBITDA padronizado pelo Ativo Total; CAPGIROAT – Capital de Giro padronizado pelo Ativo Total; DIVIDAAT – Variação das Dívidas padronizado pelo Ativo Total; CAPEXAT – *Capital Expenditure* padronizado pelo Ativo Total

O número de observações constantes na Tabela 1 diz respeito a todas as empresas em todo o período referente aos dados das variáveis. Nota-se que o Fluxo de Caixa Livre ao Acionista trimestral médio para o grupo de empresas estudado reflete que essa variável corresponde a cerca de 1% do Ativo Total.

A única variável que apresentou valor médio negativo foi o Capital de Giro, o que pode ser atribuído ao fato de o Ativo Total de uma entidade ser sempre positivo, enquanto a variável Capital de Giro se referir aos recursos de curto prazo da entidade aplicados na manutenção de sua atividade operacional (Assaf Neto & Silva, 2011).

Por meio do coeficiente de variação, é possível observar que todas as variáveis apresentaram alta variabilidade no conjunto de dados, representando uma amostra heterogênea e sendo a variável Dívida sobre Ativo Total a que apresentou maior variabilidade relativa em relação à média. Ainda, o Lucro sobre o Ativo Total apresentou maior dispersão dos dados em comparação ao Fluxo de Caixa sobre o Ativo Total, o que vai de encontro ao estudo de Li et al. (2015) no sentido que, conforme esses autores, o Fluxo de Caixa tende a apresentar maior variabilidade que o Lucro.

Por conseguinte, a Tabela 2 a seguir apresenta a matriz de correlação entre a variável de interesse (alvo) e as demais variáveis independentes (exógenas).

TABELA 2: MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS

	FCFEAT	LUCROAT	EBITDAAT	CAPGIROAT	DIVIDAAT	CAPEXAT
FCFEAT	1.00000					
LUCROAT	0,08752*	1.00000				
EBITDAAT	0,10614*	0,81854	1.00000			
CAPGIROAT	0,10094*	-0,10115	-0,14662	1.00000		
DIVIDAAT	0,32210*	-0,00230	-0,00766	-0,15249	1.00000	
CAPEXAT	-0,03471**	0,05139	0,13577	0,07514	0,17030	1.00000

Fonte: Elaborada pelo autor

Nota: FCFEAT – Fluxo de Caixa Livre ao Acionista padronizado pelo Ativo Total; LUCROAT – Lucro Líquido padronizado pelo Ativo Total; EBITDAAT – EBITDA padronizado pelo Ativo Total; CAPGIROAT – Capital de Giro padronizado pelo Ativo Total; DIVIDAAT – Variação das Dívidas padronizado pelo Ativo Total; CAPEXAT – *Capital Expenditure* padronizado pelo Ativo Total. Os asteriscos (*) e (**) são estatisticamente significativos a 1% e 5%, respectivamente.

Verifica-se que a variável FCFEAT possui correlação positiva a um nível de significância de 1% com todas as demais variáveis, exceto CAPEXAT. Em relação ao

CAPEXAT, a variável de interesse apresentou correlação negativa, com nível de significância de 5%, o que faz sentido na medida que investimentos realizados em CAPEX diminuem o fluxo de caixa da empresa.

Por outro lado, a variável FCFEAT apresentou maior correlação com a variável DÍVIDAAT, demonstrando que as dívidas e o fluxo de caixa livre ao acionista tendem a se deslocar no mesmo sentido ao longo do tempo.

4.2 RESULTADOS DOS MODELOS PREDITIVOS

Para cada modelo e para cada empresa deste estudo, foram aplicadas as métricas de performance MSE, RMSE e MAE a fim de comparar os modelos e, conseqüentemente, alcançar o objetivo desta pesquisa. De forma geral, essas medidas de avaliação indicam que, quanto menor o resultado, maior a acurácia do modelo preditivo.

Para fazer uma análise geral dos modelos, considerou-se, então, a média aritmética de cada métrica referente a todas as empresas em cada modelo. A Tabela 3 apresenta os valores obtidos para os modelos ARIMA, ARIMAX, Regressão Linear, *Machine Learning* – Série Temporal, *Machine Learning* – Regressão e Lógica Fuzzy – Série Temporal.

TABELA 3: PERFORMANCE DE DESEMPENHO DOS MODELOS PREDITIVOS

Painel A: Erro Quadrático Médio (MSE)						
MODELO	Horizonte Previsto na Validação					
	4 Trim	8 Trim	12 Trim	16 Trim	20 Trim	24 Trim
ARIMA	0,01719	0,02345	0,02495	0,02912	0,03224	0,03144
ARIMAX	0,01719	0,02345	0,02495	0,02912	0,03224	0,03144
Regressão Linear	0,00078	0,00097	0,00107	0,00165	0,00161	0,00158
ML – Série Temporal	0,00072	0,00091	0,00116	0,00120	0,00189	0,00175
ML – Regressão	0,00086	0,00145	0,00136	0,00118	0,00113	0,00109
Fuzzy – Série Temporal	0,00007	0,00007	0,00007	0,00011	0,00010	0,00017
Painel B: Raiz do Erro Quadrático Médio (RMSE)						
MODELO	Horizonte Previsto na Validação					
	4 Trim	8 Trim	12 Trim	16 Trim	20 Trim	24 Trim

	4 Trim	8 Trim	12 Trim	16 Trim	20 Trim	24 Trim
ARIMA	0,01719	0,02345	0,02495	0,02912	0,03224	0,03144
ARIMAX	0,01719	0,02345	0,02495	0,02912	0,03224	0,03144
Regressão Linear	0,02109	0,02527	0,02736	0,03102	0,03155	0,03261
ML – Série Temporal	0,02262	0,02701	0,03049	0,03138	0,03687	0,03550
ML – Regressão	0,02360	0,02751	0,02870	0,02977	0,02961	0,03015
Fuzzy – Série Temporal	0,00653	0,00678	0,00684	0,00759	0,00783	0,00908

Painel C: Erro Médio Absoluto (MAE)

MODELO	Horizonte Previsto na Validação					
	4 Trim	8 Trim	12 Trim	16 Trim	20 Trim	24 Trim
ARIMA	0,01480	0,01964	0,01999	0,02323	0,02634	0,02459
ARIMAX	0,01480	0,01964	0,01999	0,02323	0,02634	0,02459
Regressão Linear	0,01773	0,02073	0,02232	0,02449	0,02463	0,02527
ML – Série Temporal	0,02006	0,02276	0,02540	0,02574	0,03042	0,02878
ML – Regressão	0,02025	0,02194	0,02297	0,02355	0,02347	0,02329
Fuzzy – Série Temporal	0,00588	0,00586	0,00574	0,00603	0,00602	0,00647

Fonte: Elaborada pelo autor

Nota: ML – *Machine Learning* aplicado por meio da biblioteca PyCaret na linguagem de programação Python; Fuzzy – Lógica Fuzzy.

Pelo exposto, observa-se que o modelo de Lógica Fuzzy para série temporal univariada apresentou a melhor performance de predição de fluxo de caixa livre ao acionista para as empresas desta pesquisa em todas as métricas de performance, podendo ser considerado um bom modelo de predição dessa variável alvo visto que, conforme explica Weytjens et al. (2021), foi capaz de minimizar a diferença entre os valores estimados e os de fato realizados.

É interessante, inclusive, notar que o desempenho da Lógica Fuzzy para o maior período de previsão, 24 trimestres, é melhor que o desempenho dos demais modelos para o período mais curto, referente a 4 trimestres, revelando o poder de acurácia desse modelo em situações encontradas no mundo real, como dispõe Cai et al. (2015).

Dessa forma, os resultados também demonstram que as variáveis exógenas selecionadas foram utilizadas nos modelos multivariados, porém sua inclusão não gerou melhores resultados do que a série univariada do modelo de Lógica Fuzzy, evidenciando novamente o poder preditivo dessa ferramenta, o que vai ao encontro

do *paper* de Lucas et al. (2022), que informa que a Lógica Fuzzy série temporal tem ganhado notoriedade entre os pesquisadores em virtude de sua boa acurácia.

Abaixo, também são apresentadas a Figura 5, a Figura 6 e a Figura 7, as quais comparam as medianas dos modelos estudados através das métricas MSE, RMSE e MAE ao longo do tempo a fim de, por meio dessa outra medida de tendência central, melhor visualizar o desempenho desses modelos e corroborar no alcance do objetivo desta pesquisa. Essas figuras validam os resultados anteriormente apresentados e revelam a baixa variabilidade das métricas de performance para o modelo Lógica Fuzzy.

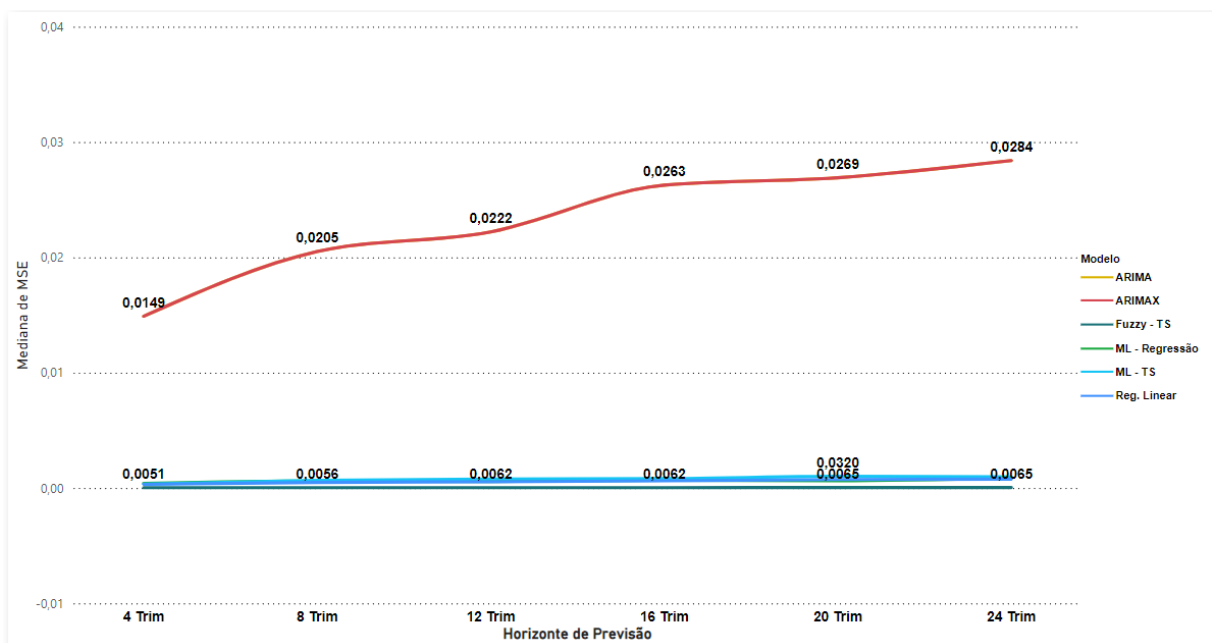


Figura 5: Gráfico de desempenho dos modelos por meio da métrica MSE

Fonte: Elaborada pelo autor

Nota: ML – *Machine Learning* aplicado por meio da biblioteca PyCaret na linguagem de programação Python; Fuzzy – Lógica Fuzzy; TS – *Time Series* (Série Temporal); Reg.Linear – Regressão Linear.

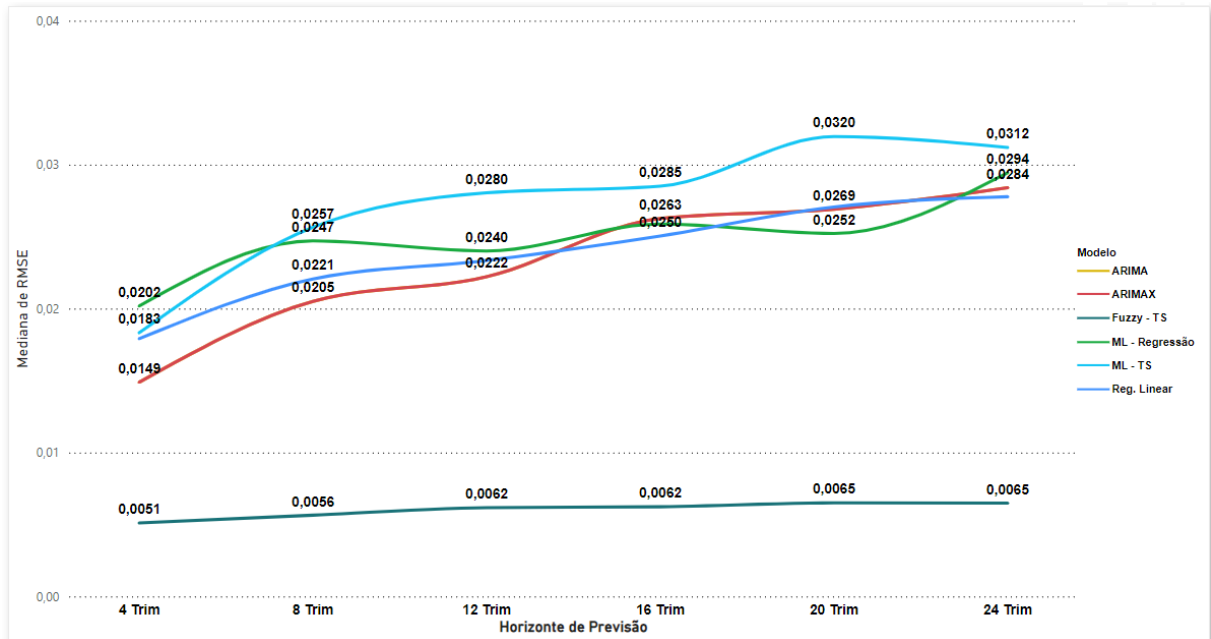


Figura 6: Gráfico de desempenho dos modelos por meio da métrica RMSE

Fonte: Elaborada pelo autor

Nota: ML – *Machine Learning* aplicado por meio da biblioteca PyCaret na linguagem de programação Python; Fuzzy – Lógica Fuzzy; TS – *Time Series* (Série Temporal); Reg.Linear – Regressão Linear.

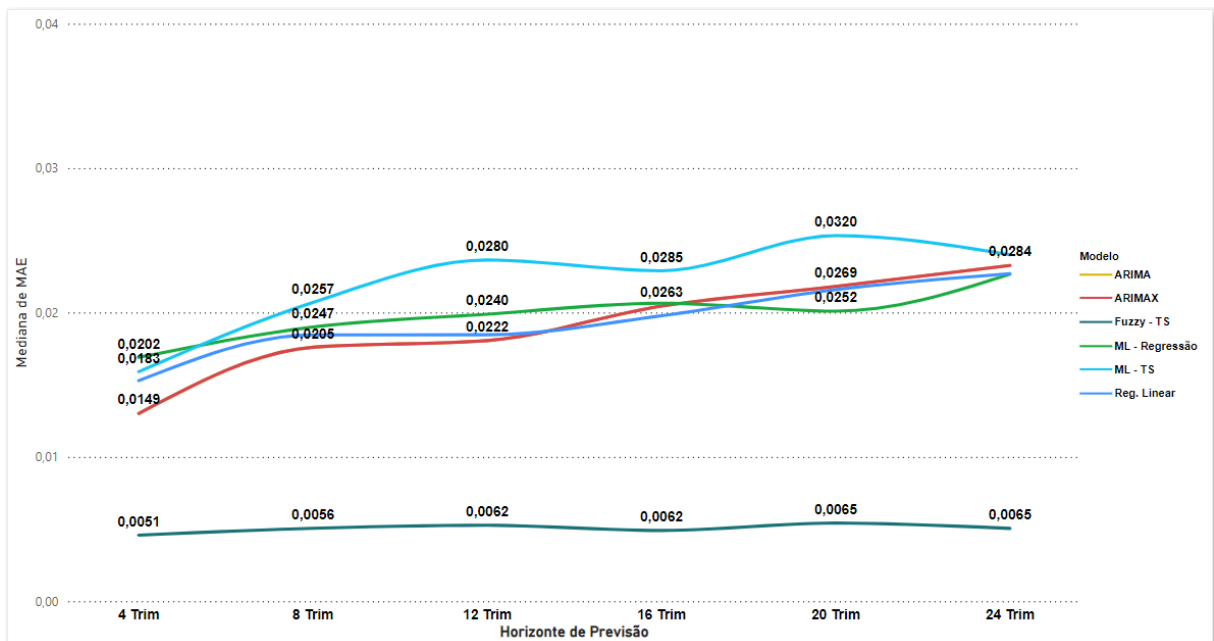


Figura 7: Gráfico de desempenho dos modelos por meio da métrica MAE

Fonte: Elaborada pelo autor

Nota: ML – *Machine Learning* aplicado por meio da biblioteca PyCaret na linguagem de programação Python; Fuzzy – Lógica Fuzzy; TS – *Time Series* (Série Temporal); Reg.Linear – Regressão Linear.

De forma ilustrativa, optou-se também por apresentar, por meio da Figura 8 a seguir, a trajetória dos valores previstos pela Lógica Fuzzy, em comparação aos efetivamente ocorridos, para o período de 24 trimestres da Petrobras S.A., empresa com maior valor de mercado na Bolsa de Valores do Brasil em 29/11/2023, conforme dados disponíveis pela B3³. Observa-se que os montantes estimados para o FCFEAT obtiveram comportamentos e valores muito similares aos de fato realizados por essa companhia.

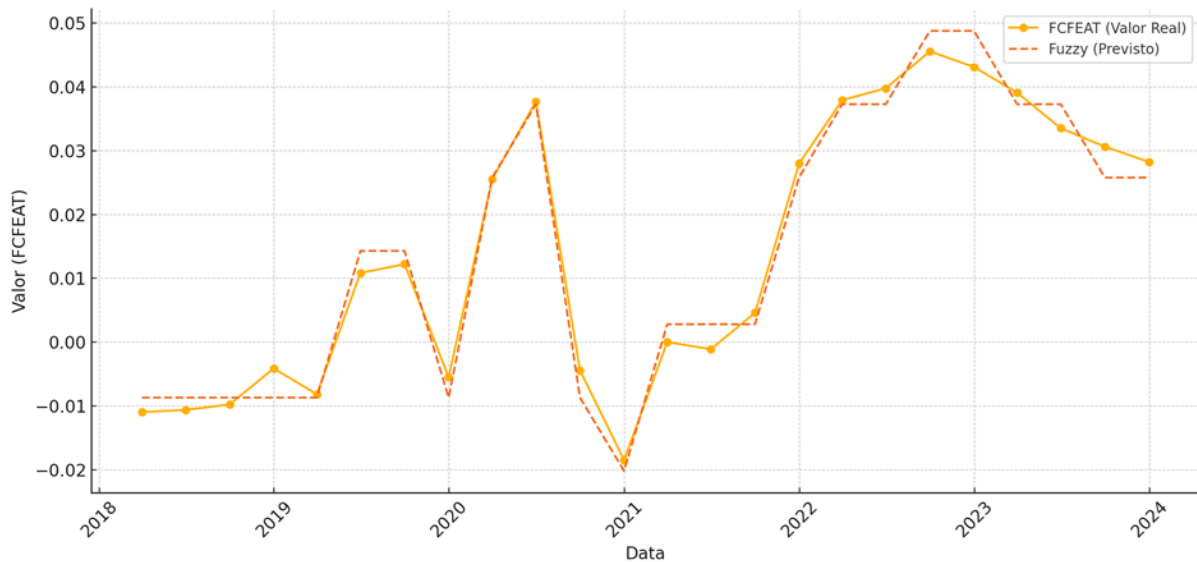


Figura 8: Comparação: FCFEAT (Valor Real) vs. FCFEAT (Valor Previsto - Lógica Fuzzy) da Petrobras S.A.

Fonte: Elaborada pelo autor

Nota: FCFEAT – Fluxo de Caixa Livre ao Acionista padronizado pelo Ativo Total; Fuzzy – Lógica Fuzzy.

Portanto, nota-se que, assim como nos estudos de Caetano (2006) e Giudice et al. (2017), a utilização do método de Lógica Fuzzy nesta pesquisa diminuiu as incertezas típicas de situações observadas no mundo real.

³ Disponível em: https://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/valor-de-mercado-das-empresas-listadas/bolsa-de-valores-mensal/

Quanto aos demais modelos, os estudos de Evdokimov et al. (2023) compararam 9 algoritmos de *Machine Learning* com ARIMA para previsão de série temporal financeira. Assim como nesta pesquisa, Evdokimov et al. (2023) destacam como limitação a quantidade de dados disponíveis, que tanto neste estudo quanto no estudo de Evdokimov et al. (2023) eram trimestrais. Os resultados de Evdokimov et al. (2023), que dizem respeito à previsão da taxa de crescimento de fluxo de caixa livre, demonstraram que a maioria dos algoritmos de *Machine Learning* performaram melhor que o modelo ARIMA. Entretanto, neste estudo, baseando-se na mesma medida de desempenho empregada por Evdokimov et al. (2023), a RMSE, observou-se que o modelo ARIMA, de forma geral, foi capaz de prever melhor a variável em questão do que os modelos aplicados pela biblioteca PyCaret de *Machine Learning*.

No tocante ao modelo de regressão linear, esse modelo, para todas as métricas analisadas, não apresentou o pior desempenho em nenhum período no horizonte de tempo previsto. Esse resultado corrobora, em parte, com os estudos de Fang e Lahdelma (2016) e Ottaviani e De Marco (2022), os quais demonstram a robustez e capacidade preditiva desse modelo, visto que não foi o melhor modelo de predição nesta pesquisa, porém também não foi o pior.

4.3 DISCUSSÃO TEÓRICO-PRÁTICA DOS RESULTADOS

Conforme resultados encontrados e apresentados na seção anterior, a Lógica Fuzzy é capaz de diminuir incertezas típicas do mundo real, as quais podem incluir a estimação da capacidade de pagamento de empresas em sanções pecuniárias aplicadas pelos órgãos públicos.

Para Farber et al. (2016), o Fluxo de Caixa Livre ao Acionista – FCLA é a melhor variável para estimar os recursos disponíveis para pagamento de sanções pecuniárias por parte de empresas infratoras. Dessa forma, no tocante a sanções pecuniárias e a capacidade de pagamento de empresas, também chamada de *ability to pay*, é salutar uma breve contextualização.

Becker (1968) foi pioneiro nos estudos que relacionam a racionalidade econômica e a formulação de punições, descrevendo que uma sanção ótima tem a característica de minimizar a perda social, o que inclui os danos propriamente ditos, os custos de apreensão, de condenação, bem como de execução das penas. Dessa forma, Becker (1968) menciona que uma multa ótima equivale a compensar totalmente as vítimas e restaurar o *status quo*.

Werden e Simon (1987) esclarecem que a multa ótima de Becker é no sentido de o infrator compensar a sociedade por todos os danos sofridos, tornando a multa dissuasiva. Nesse sentido, Werden e Simon (1987) explicam que os violadores apenas teriam interesse em cometer crimes caso os benefícios superassem os custos, no caso de serem apreendidos e condenados.

Nesse contexto, Werden e Simon (1987) também escrevem a respeito da análise de capacidade de pagamento das corporações para pagamento de multas. Segundo esses autores, a maioria das entidades não suportariam a multa ideal proposta por Becker. Além disso, Werden e Simon (1987) consideram que identificar o limite da capacidade de pagamento de uma empresa infratora é difícil, custoso e requer a utilização substancial de recursos.

No mesmo sentido, Gallo et al. (1994) também explicam que, para Becker, a multa ótima é aquela que iguala os custos esperados de apreensão e condenação pelo infrator aos custos à sociedade da prática antitruste. Dessa forma, os potenciais

infratores seriam desencorajados a cometerem condutas ilegais, a menos que os benefícios superassem os custos (Gallo et al., 1994).

A respeito desse tema, Gallo et al. (1994) investigaram as multas efetivamente impostas pelo *Department of Justice* (DOJ) dos Estados Unidos da América (EUA) a empresas em decorrência de práticas de fixação de preços no período de 1955 a 1993 e as multas que seriam ótimas e observaram que, quando houve condenação apenas de multa por parte do DOJ, esta foi significativamente abaixo do valor de multa ótima, representando menos de 1% desse valor nas condenações até 1985 e de pouco mais de 1% após esse ano.

Entretanto, Craycraft et al. (1997) discorrem que Gallo et al. (1994) não incluíram explicitamente a capacidade de pagamento na análise realizada, o que Craycraft et al. (1997) consideram que pode ser um fator que influencia a determinação de multas em casos antitruste. Dessa forma, esses autores testaram empiricamente a capacidade de pagamento de empresas no tocante às multas reais impostas, às multas máximas permitidas e às multas ótimas proposta pelo modelo de Gallo et al. (1994).

Por meio de medidas contábeis classificadas em medidas de estoque, que diz respeito a reservas de caixa disponíveis ou potenciais demonstrados no Balanço Patrimonial, e em medidas de fluxo, que medem os fundos gerados pelas operações divulgados na Demonstração de Resultados, Craycraft et al. (1997) observaram que a maioria das empresas da amostra teriam a capacidade de pagar as multas reais impostas e também as multas máximas permitidas, porém, mais da metade das empresas não suportariam o pagamento de uma multa ótima.

Wils (2006) também sugere que a aplicação de multas são importantes instrumentos para contribuir para a prevenção de violações, por exemplo, se tiver um

poder dissuasivo. Dessa forma, a ameaça de a empresa infratora ser processada e multada impacta no equilíbrio dos custos e benefícios esperados pela entidade, podendo atingir, assim, seu objetivo proposto (Wils, 2006).

Nesse raciocínio, Wils (2006) descreve que a dissuasão pode ser atingida por diferentes níveis de valores de multa e de probabilidade de que a multa seja imposta, ou seja, esse fim pode ser alcançado por meio de uma multa alta e probabilidade baixa de punição, bem como por meio de multas baixas e probabilidade alta de detecção e punição. Quanto às multas muito altas, Wils (2006) discorre que elas podem apresentar alguns problemas, entre eles, a de exceder o limite de capacidade de pagamento das companhias infradoras, podendo levá-las a falência.

Wils (2006) explica que a falência de uma entidade apresenta custos sociais que envolvem não somente os gestores e acionistas, mas também clientes, fornecedores, credores, governo, funcionários etc. e que, dessa forma, é interessante que as multas impostas sejam correspondentes à capacidade de pagamento das empresas.

Nos EUA, Farber et al. (2016) informam que a Divisão Antitruste do DOJ, em suas aplicações de multas e penalidades antitruste, reconhecem a legitimidade de se considerar a capacidade de pagamento das companhias em acordos.

Farber et al. (2016) consideram que os recursos disponíveis para o pagamento de uma multa equivalem à diferença entre o caixa final projetado e registrado no balanço patrimonial e o caixa necessário para manutenção e continuidade das operações da empresa. Dessa forma, Farber et al. (2016) explicam que para analisar a capacidade de pagamento de uma determinada empresa, é necessário examinar detalhadamente as demonstrações contábeis da entidade e seu desempenho

financeiro, bem como realizar previsões futuras a respeito da empresa e do seu setor de atuação.

Nesse sentido, Farber et al. (2016) informam que o *Guidelines* do DOJ não fornece uma metodologia específica para estimar a capacidade de pagamento de uma empresa. Porém, segundo Farber et al. (2016), os analistas costumam examinar o balanço patrimonial, por exemplo, por meio de indicadores, e também realizar a projeção do fluxo futuro de caixa livre. Esses autores propõem que o FCLA é a melhor medida para identificar os recursos disponíveis para pagamento da multa.

Portanto, conforme se verifica no sítio eletrônico do *United States Sentencing Commission* – USSC⁴, as sanções impostas às organizações têm como objetivo a aplicação de penas justas, dissuasivas e que criem incentivos para que as entidades desenvolvam e mantenham mecanismos de controle e prevenção no tocante a condutas criminosas.

Nesse diapasão, a USSC (2023) prevê, no item §8C3.3., do *Guidelines Manual Annotated*, a possibilidade de redução de multa em virtude da incapacidade de pagamento por meio da organização infratora com o objetivo de não comprometer significativamente a viabilidade da companhia de continuar operando suas atividades.

No âmbito da União Europeia, foi elaborado o documento Orientações para o cálculo das coimas aplicadas por força do n.º 2, alínea a), do artigo 23.º do Regulamento (CE) n.º 1/2003 (CE, 2006). Essas sanções pecuniárias referem-se a infrações cometidas por empresas que violam regras de concorrência dispostas no Tratado sobre o Funcionamento da União Europeia (CE, 2016).

⁴ <https://www.ussc.gov/guidelines/2023-guidelines-manual/annotated-2023-chapter-8#8a11> recuperado em 10 de setembro de 2024.

Dessa forma, essas orientações determinam que no cálculo da pena sejam considerados o valor das vendas dos bens e/ou serviços referentes à infração, bem como sua duração e gravidade de forma que a multa tenha um caráter dissuasivo geral, isto é, a nível da empresa que infringiu a lei como também de coibir que outras empresas tenham comportamentos prejudiciais à concorrência (CE, 2006). Entretanto, o Tratado sobre o Funcionamento da União Europeia estabelece que a sanção não pode exceder a 10% do faturamento total realizado no exercício anterior à decisão (CE, 2016).

O parágrafo 35 dessas orientações diz respeito da capacidade de pagamento da empresa condenada. Primeiramente, as orientações dispõem que a multa aplicada não será reduzida com base na simples observação de uma condição financeira desfavorável ou deficitária. Por outro lado, de forma excepcional, a Comissão pode reduzir a multa com base em provas objetivas de que sua aplicação comprometerá de forma irreversível a sustentabilidade econômico-financeira da empresa em questão e que causará perda significativa do valor de seus ativos (CE, 2006).

No Brasil, a Lei nº 12.529/2011 (Lei de Defesa da Concorrência) e a Lei nº 12.846/2013 (Lei Anticorrupção) tratam, respectivamente, de parâmetros para determinação dos valores de multas a serem aplicadas em casos de infração da ordem econômica e de atos lesivos à administração pública.

A respeito da Lei nº 12.529/2011, o art. 37, inciso I, estabelece que, no caso de empresa, a multa será de 0,1% a 20% do faturamento bruto obtido pela companhia, grupo ou conglomerado no último exercício anterior à instauração do processo administrativo, no ramo da atividade empresarial que ocorreu a infração, e nunca menor que o valor da vantagem auferida, quando esta for possível de ser estimada.

O inciso II dispõe que não sendo possível utilizar o critério do faturamento bruto, a multa será de R\$ 50.000,00 a R\$ 2.000.000.000,00.

O § 2º do citado artigo ainda complementa que no caso de não dispuser do valor do faturamento no ramo da atividade empresarial em que ocorreu a infração ou quando este for apresentado de forma incompleta, o percentual da multa poderá ser sobre o faturamento total da empresa ou grupo de empresas.

A fim de trazer maior transparência a respeito de suas ações e decisões, o CADE (2023) elaborou um guia denominado Guia de Dosimetria de Multas de Cartel com o objetivo de apresentar a metodologia utilizada por essa autarquia federal nas condenações do seu Tribunal Administrativo. Dessa forma, o referido guia inicia informando que a definição das multas deve respeitar os princípios da transparência e da proporcionalidade, bem como serem adequadas e suficientes para inibir condutas anticompetitivas pelos agentes econômicos.

Conforme o CADE (2023), o cálculo da multa deve resguardar o caráter dissuasório e de proporcionalidade. Desse modo, leva-se em conta a duração da conduta, efeitos negativos produzidos no mercado, dimensão geográfica afetada, além da identificação do faturamento bruto no sub-ramo ou mercado atingido.

Ainda, a Lei nº 12.529/2011, em seu art. 45, inciso VII, determina que seja levada em consideração, na aplicação da pena, a situação econômica do infrator. Assim, o CADE (2023) discorre que esse elemento pode ser um atenuante no cálculo da multa quando, comprovadamente, o infrator se encontrar em situação de dificuldade financeira, demonstrando uma capacidade financeira comprometida.

No tocante à Lei nº 12.846/2013, seu art. 6º, inciso I, define, de forma semelhante à Lei nº 12.529/2011, os percentuais de multa no caso de atos lesivos à

administração pública, isto é, no valor de 0,1% a 20% do faturamento bruto do exercício anterior ao da instauração do processo administrativo, excluindo-se os tributos. A referida Lei também dispõe que a multa nunca será inferior ao à vantagem auferida, quando esta puder ser estimada.

Contudo, diferentemente da Lei de Defesa da Concorrência, a Lei Anticorrupção estabelece que, na ausência do faturamento bruto da pessoa jurídica, os valores mínimos e máximos da multa serão, respectivamente de R\$ 6.000,00 e 60.000.000,00.

De forma semelhante ao CADE, a CGU (2023) elaborou o Relatório de análise da dosimetria de sanções em Processos Administrativo de Responsabilização com o objetivo de oferecer maior transparência aos critérios de dosimetria das sanções, a fim de assegurar que esses critérios sejam adequados e proporcionais.

Nesse sentido, a CGU (2023) entende que os parâmetros para a dosimetria da sanção de multa, dentro desses limites mínimo e máximo, devem ser adequadamente estipulados. Esses parâmetros incluem agravantes e atenuantes que resultarão em aumento ou diminuição da alíquota a ser aplicada sobre a base de cálculo, conforme prevê o Decreto nº 11.129/2022, que regulamenta a Lei Anticorrupção.

A CGU (2023) observou que, do total de 65 multas aplicadas por esse órgão desde o início da vigência da Lei nº 12.846/2013 até maio de 2023, a alíquota média calculada foi de 3,2% e a mediana de 2,8%, sendo que todas as alíquotas calculadas encontram-se dentro do intervalo de 0,1% e 10%. A CGU (2023) considera que os valores mínimo e máximo legais de multa não têm impedido a dosimetria efetiva de cálculo.

Ainda, o art. 7º, inciso VI, da Lei Anticorrupção determina que seja levado em consideração na aplicação das sanções a situação econômica do infrator. Posto isso, o Decreto nº 11.129/2022 dispõe um aumento da alíquota a ser aplicada sobre a base de cálculo no caso de empresa com índices de solvência geral e liquidez geral superiores a um e lucro líquido no exercício anterior ao da instauração do processo administrativo de responsabilização, contudo, sem tratar de eventual dificuldade financeira do infrator e, conseqüentemente, da sua capacidade de pagamento.

Contudo, Pimenta (2022) informa, por exemplo, que sanções aplicadas pelo CADE geralmente negligenciam a análise da capacidade de pagamento das empresas infradoras e, dessa forma, as multas resultantes podem ser injustas, inefetivas ou contraproducentes. Conforme Pimenta (2022), uma multa excessivamente elevada (*overenforcement*) pode ser contraproducente no sentido de aumentar o risco de insolvência do agente econômico ou de criar incentivos para protelação e/ou judicialização, tornando-se menos efetiva.

Portanto, Pimenta (2022) considera ser interessante a análise de capacidade de pagamento da empresa a fim de identificar um limite de multa que não necessariamente será a mesma prevista em lei e que, posto isso, tende a ser mais justa e proporcional e, conseqüentemente, com maior probabilidade de ser recolhida, alcançando assim seus objetivos propostos.

Além de toda a discussão teórica apresentada acima, é oportuno também evidenciar percentuais de arrecadação de multas aplicadas no Brasil, bem como desafios a serem enfrentados no âmbito dos órgãos e entidades públicas.

Em relação às multas impostas por agências reguladoras e outros órgãos e entidades federais com atribuições de fiscalização e controle, incluindo Bacen, CVM, CADE, SUSEP, entre outras, o TCU realizou monitoramento, referente aos exercícios

de 2015 e 2016, com o objetivo de apresentar um panorama a respeito da arrecadação de multas aplicadas por essas autarquias, destacando possíveis problemas de natureza sistêmica e oferecendo uma visão resumida para análises comparativas entre as entidades (Acórdão 729/2020 - Plenário).

Como resultados, a Corte de Contas verificou que as autarquias federais arrecadaram nesse período, em média, 2,37% dos valores totais de multas aplicadas, representando um baixo grau de efetividade na arrecadação dessas multas, sendo que as entidades que mais arrecadaram foram a Agência Nacional de Águas e Saneamento Básico – ANA e a Agência Nacional de Transportes Aquaviários – Antaq, as quais também foram as que aplicaram multas de valores mais baixos (Acórdão 729/2020 - Plenário).

Pimenta (2022) também realizou um levantamento a respeito das multas aplicadas, neste caso, pelo CADE durante o período de 2009 a 2020. Como resultado, Pimenta (2022) constatou que, no período analisado, apenas 5,01% das multas impostas por essa autarquia foram arrecadadas, indicando uma baixa taxa de efetividade na arrecadação dessas sanções pecuniárias. Ademais, Pimenta (2022) enfatiza o fato de o CADE desconsiderar a capacidade de pagamento das empresas, isto é, de usar o faturamento bruto como base para cálculo de multas, mas sem ajustes que levem em conta a situação econômica das empresas condenadas.

A respeito dos acordos de leniência celebrados no Brasil, a CGU disponibiliza, no Painel Acordos de Leniência⁵, dados sobre os acordos firmados, nome das empresas colaboradoras, entes lesados, valores recebidos, detalhes dos pagamentos

⁵ Disponível em:

<https://app.powerbi.com/view?r=eyJrljoiZTU2MmWI0MjYtY2EzOS00NzYyLTg3MmWQtYWE3MmFiMmY0ODM4liwidCI6IjY2NzhkOWZILTA5MjEtNDE3ZC04NDExLTVmMWMxOGRIZmJiYiJ9>.

etc. De acordo com esse Painel, de 2015 a 2024, a CGU recebeu 93 propostas de acordos, tendo sido celebrados 29 acordos que totalizam cerca de R\$ 18,7 bilhões de valores a serem pagos pelas empresas. O Painel também informa que as companhias pagaram, até setembro de 2024, cerca de R\$ 9,4 bilhões e que os montantes ainda não pagos podem estar relacionados a valores provenientes de parcelamento.

Referente a esses acordos, no ano de 2023 foi proposta a Arguição de Descumprimento de Preceito Fundamental – ADPF 1051/DF perante o Supremo Tribunal Federal – STF⁶, a qual pede a suspensão dos pagamentos das obrigações pecuniárias, que incluem indenizações e multas, aplicadas em todos os acordos de leniência firmados entre o Estado e empresas investigadas durante a Operação Lava Jato, anteriores à assinatura do Acordo de Cooperação Técnica – ACT, em 6/8/2020. Entre os motivos constantes na referida ADPF, citam-se eventuais obrigações pecuniárias desproporcionais e que podem colocar em risco a continuidade da atividade empresarial das empresas, bem como a restituição dos valores de danos ao erário.

Em seguida, o STF determinou que os entes públicos, consensualmente com as empresas que firmaram acordos de leniência e estavam habilitadas nos autos da referida ADPF, buscassem tratativas de renegociar os acordos, levando em conta a capacidade de pagamento das empresas (*ability to pay*) a partir de análise técnica de suas situações contábeis.

Diante desses cenários apresentados e considerando que Wils (2006) julga ser importante que as multas impostas sejam correspondentes à capacidade de pagamento das empresas, uma vez que, caso as multas excedam esse limite, podem

⁶ Disponível em: <https://portal.stf.jus.br/processos/detalhe.asp?incidente=6605876>.

apresentar alguns problemas para as entidades, entre eles, a de levá-las a falência, bem como o fato de uma multa excessivamente elevada (*overenforcement*) poder ser contraproducente em razão de elevar o risco de insolvência do agente econômico ou de criar incentivos para protelação e/ou judicialização, tornando-se menos efetiva, conforme Pimenta (2022), revela-se necessária a estimativa de capacidade de pagamento das empresas em sanções pecuniárias aplicadas por órgãos públicos.

Essa análise está em conformidade com a legislação brasileira, visto que, consoante demonstrado, a Lei nº 12.529/2011 e a Lei nº 12.846/2013 determinam que seja levada em consideração, na aplicação das sanções pecuniárias, a situação econômica do infrator. Ademais, o USSC (2023), por meio do *Guidelines Manual Annotated*, e a União Europeia, através do documento Orientações para o cálculo das coimas aplicadas por força do n.º 2, alínea a), do artigo 23.º do Regulamento (CE) n.º 1/2003 (CE, 2006), também destacam a possibilidade de redução de multa à empresa infratora caso seja constatada sua incapacidade de pagamento e, conseqüentemente, comprometa significativamente a viabilidade de a entidade permanecer operando suas atividades.

Por todo exposto, levando em conta que Farber et al. (2016) propõem que o Fluxo de Caixa Livre ao Acionista – FCLA é a melhor medida para identificar os recursos disponíveis para pagamento de uma sanção pecuniária, os resultados dessa pesquisa sugerem que, caso fosse adotada a Lógica Fuzzy na predição de FCLA e, conseqüentemente, na estimativa da capacidade de pagamento de empresas infradoras, os órgãos públicos teriam o potencial de melhorar o cenário atual de arrecadação das multas impostas, tornando-as mais efetivas e atingindo os objetivos propostos, resultando em ganhos para a sociedade e sem prejudicar a continuidade operacional das empresas infradoras.

Capítulo 5

5 CONCLUSÃO

Desde a declaração do *Financial Accounting Standards Board* – FASB (1978) a respeito da superioridade dos lucros baseados no regime de competência em relação ao regime de caixa na previsão de fluxos de caixa futuros, o tema tem sido amplamente pesquisado, resultando em um vasto corpo de literatura desenvolvido ao longo das últimas décadas. Entretanto, os resultados são inconclusivos sobre se o lucro ou se fluxo de caixa é o que melhor consegue prever fluxos futuros de caixa (Mulenga & Bhatia, 2017).

Por outro lado, o progresso tecnológico vem avançando nos últimos anos, estando inserido em diversas atividades humanas e sendo capaz de processar grandes volumes de dados de maneira eficaz, o que resulta em inovações de muitas organizações, sejam elas comerciais ou estatais (Dadteev et al., 2020).

Dessa forma, esta pesquisa teve como objetivo contribuir com as pesquisas a respeito da predição de fluxos de caixa futuros por meio da utilização de *soft computing*, inteligência artificial, algoritmos, modelos matemáticos e estatísticos a fim de validar se a Lógica Fuzzy é um método que apresenta melhor desempenho em comparação a métodos tradicionais de Regressão Linear e ARIMA, juntamente com sua extensão ARIMAX, bem como em relação a modelos de *Machine Learning* para a predição de fluxos futuros de caixa livre ao acionista. Conforme Farber et al. (2016), o Fluxo de Caixa Livre ao Acionista – FCLA é a melhor medida para identificar também os recursos disponíveis para pagamento de multas aplicadas a empresas que cometem infrações contra a Administração Pública.

Nesse sentido, os resultados encontrados contribuem com a literatura de predição de fluxos futuros de caixa no sentido de demonstrar que, para o grupo de empresas estudado, a Lógica Fuzzy, considerando a série temporal da variável em questão, apresentou os melhores desempenhos de predição no curto, médio e longo prazo (4 trimestres a 24 trimestres), avaliados por meio das métricas MSE, RMSE e MAE. Esses achados vão ao encontro do estudo de Lucas et al. (2022), o qual informa que a Lógica Fuzzy série temporal tem ganhado notoriedade entre os pesquisadores em virtude de sua boa acurácia.

As contribuições práticas vão no sentido de propor o aperfeiçoamento da política sancionatória pecuniária e também de fomentar o debate, por parte de órgãos públicos, do uso de métodos que incluem *soft computing*, inteligência artificial e variáveis linguísticas na análise da capacidade de pagamento de empresas infratoras com o intuito de melhor preverem seus fluxos de caixa e, conseqüentemente, possam celebrar, por exemplo, acordos de leniência que sejam cumpridos em sua totalidade, sendo mais efetivos e resultando em ganhos para a sociedade.

Outra aplicação prática pode ser o uso da Lógica Fuzzy por parte de gestores, credores, investidores, analistas financeiros etc., uma vez que a predição de fluxos futuros de caixa também é de interesse do setor privado e de finanças.

A pesquisa foi realizada com companhias de capital aberto listadas na Bolsa de Valores do Brasil, a B3, e, dessa forma, utilizou-se dados de um mercado emergente que apresenta um cenário, o que inclui investidores e credores, diferente de países com mercado de capitais mais maduro. Portanto, uma das limitações identificadas refere-se aos dados utilizados, os quais correspondem apenas a companhias abertas e listadas na B3. Dessa forma, os resultados devem ser interpretados com cautela em virtude do tamanho da amostra.

Tendo sido validado o modelo de série temporal de Lógica Fuzzy para predição de fluxos futuros de caixa livre ao acionista como o de melhor performance entre os modelos estudados para o grupo de empresa em análise, sugere-se, como oportunidade de pesquisas futuras, avaliar os mesmos modelos para empresas de diferentes setores econômicos com o objetivo de verificar quais modelos se sobressaem em cada setor. Assim, poder-se-á identificar características do contexto de cada setor, tais como instabilidade, imprevisibilidade etc. a fim de conciliar os aspectos teóricos do comportamento de cada setor com os resultados dos modelos de predição para curto, médio e longo prazo.

Outras oportunidades vislumbradas para futuras pesquisas são: (1) a inclusão de empresas de capital fechado; (2) a aplicação da metodologia com companhias em outro país; (3) inclusão de outras variáveis contábeis; (4) inclusão de variáveis macroeconômicas, como inflação e taxa de juros; e (5) aplicação da Lógica Fuzzy com múltiplas variáveis como entrada, representando um modelo Fuzzy Multivariado.

REFERÊNCIAS

- Almeida, J. P. M. D. (2023). *Métodos clássicos e baseados em aprendizado de máquina para previsão de preço de tomate in natura*. [Dissertação Mestrado, Universidade Estadual de Ponta Grossa]. Repositório Institucional da UEPG <http://tede2.uepg.br/jspui/handle/prefix/4094>
- Ali, M. M., & Ali, K. M. (2021). Using a cash flow model to predict future cash flow from historical cash flow: A Malaysian perspective. *Academy of Accounting and Financial Studies Journal*, 25(5), 1-11.
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine learning from theory to algorithms: an overview. *Journal of Physics: conference series*. <https://doi.org/10.1088/1742-6596/1142/1/012012>
- Assaf Neto, A., & Silva, C. A. T. (2011). *Administração do capital de giro, 4ª edição*. Grupo GEN. <https://integrada.minhabiblioteca.com.br/books/9788522484751>
- Bagnoli, C., & Smith, H. (1998). The theory of fuzz logic and its application to real estate valuation. *Journal of Real Estate Research*, 16(2), 196-200. <https://doi.org/10.1080/10835547.1998.12090941>
- Bhandari, S. B., & Iyer, R. (2013). Predicting business failure using cash flow statement based measures. *Managerial Finance*, 39(7), 667-676. <https://doi.org/10.1108/03074351311323455>
- Barth, M. E., Cram, D. P., & Nelson, K. K. (2001). Accruals and the prediction of future cash flows. *The accounting review*, 76(1), 27-58. <https://doi.org/10.2308/accr.2001.76.1.27>
- Becker, G. S. (1968). Crime and punishment: An economic approach. *Journal of Political Economy*, 76(2), 169-217. <https://doi.org/10.1086/259394>
- Beladi, H., Deng, J., & Hu, M. (2021). Cash flow uncertainty, financial constraints and R&D investment. *International Review of Financial Analysis*, 76, 101785. <https://doi.org/10.1016/j.irfa.2021.101785>

- Brasil. Presidência da República. Casa Civil. (2011). *Lei nº 12.529, de 30 de novembro de 2011*. Estrutura o Sistema Brasileiro de Defesa da Concorrência; dispõe sobre a prevenção e repressão às infrações contra a ordem econômica; altera a Lei n. 8.137, de 27 de dezembro de 1990, o Decreto-Lei n. 3.689, de 3 de outubro de 1941 - Código de Processo Penal, e a Lei n. 7.347, de 24 de julho de 1985; revoga dispositivos da Lei n. 8.884, de 11 de junho de 1994, e a Lei n. 9.781, de 19 de janeiro de 1999; e dá outras providências. https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/112529.htm
- Brasil. Presidência da República. Casa Civil. (2013). *Lei nº 12.846, de 1º de agosto de 2013*. Dispõe sobre a responsabilização administrativa e civil de pessoas jurídicas pela prática de atos contra a administração pública, nacional ou estrangeira, e dá outras providências. http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2013/lei/112846.htm
- Brasil. Presidência da República. Casa Civil. (2022). *Decreto nº 11.129, de 11 de julho de 2022*. Regulamenta a Lei nº 12.846, de 1º de agosto de 2013, que dispõe sobre a responsabilização administrativa e civil de pessoas jurídicas pela prática de atos contra a administração pública, nacional ou estrangeira. https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2022/Decreto/D111129.htm
- Buckley, J. J. (1987). The fuzzy mathematics of finance. *Fuzzy Sets and Systems*, 21, 257-273. [https://doi.org/10.1016/0165-0114\(87\)90128-X](https://doi.org/10.1016/0165-0114(87)90128-X)
- Bueno, R. D. L. D. S. (2018). *Econometria de Séries Temporais - 2ª edição revista e atualizada* (2nd ed.). Cengage Learning Brasil. <https://integrada.minhabiblioteca.com.br/books/9788522128259>
- B3. (n.d.). *Valor de mercado das empresas listadas: Bolsa de valores mensal*. Recuperado em 13 de dezembro de 2024, de https://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/valor-de-mercado-das-empresas-listadas/bolsa-de-valores-mensal/
- Conselho Administrativo de Defesa Econômica (2023). Guia Dosimetria de multas de cartel. <https://cdn.cade.gov.br/Portal/centrais-de-conteudo/publicacoes/guias-do-cade/Guia-dosimetria-de-multas-de-cartel.pdf>
- Caetano, M. A. L. (2006). Lógica fuzzy para tomada de decisão em negócios e finanças. *Revista de Economia e Administração*, 5(1), 12-39. <https://doi.org/10.11132/rea.2002.110>

- Caetano, M. A. L. (2021). *Python e mercado financeiro*. Editora Blucher. <https://integrada.minhabiblioteca.com.br/books/9786555062410>
- Cai, Q., Zhang, D., Zheng, W., & Leung, S. C. (2015). A new fuzzy time series forecasting model combined with ant colony optimization and auto-regression. *Knowledge-Based Systems*, 74, 61-68. <https://doi.org/10.1016/j.knosys.2014.11.003>
- Cardoso Junior, G. J. X. (2010). *Utilização do modelo fuzzy de avaliação de investimentos reais (VIRF) para avaliação de ativos e comparação com o modelo clássico de avaliação por fluxos de caixa descontados (FCD). Estudo de caso: avaliação do Vale* [Dissertação de mestrado]. Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil. http://objdig.ufrj.br/60/teses/coppe_m/GilbertoJoseXavierCardosoJunior.pdf
- Chay, J. B., & Suh, J. (2009). Payout policy and cash-flow uncertainty. *Journal of Financial Economics*, 93(1), 88-107. <https://doi.org/10.1016/j.jfineco.2008.12.001>
- Chen, X., Lu, M., Shan, Y., & Zhang, Y. (2021). Australian evidence on analysts' cash flow forecasts: issuance, accuracy and usefulness. *Accounting & Finance*, 61(1), 3-50. <https://doi.org/10.1111/acfi.12552>
- Comissão Europeia (2006). *Orientações para o cálculo das coimas aplicadas por força do n.º 2, alínea a), do artigo 23.º do Regulamento (CE) n.º 1/2003*. <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:C:2006:210:0002:0005:PT:PDF>
- Comissão Europeia (2016). *Tratado sobre o funcionamento da União Europeia*. https://eur-lex.europa.eu/resource.html?uri=cellar:9e8d52e1-2c70-11e6-b497-01aa75ed71a1.0019.01/DOC_3&format=PDF
- Controladoria-Geral da União (2024). *Painel Acordos de Leniência*. Acessado em setembro de 2024, em <https://app.powerbi.com/view?r=eyJrljoiZTU2MWI0MjYtY2EzOS00NzYyLTg3MmWQtYWE3MmFiMmY0ODM4liwidCI6ljY2NzhkOWZILTA5MjEtNDE3ZC04NDExLTVmMWMxOGRIZmJiYiJ9>.
- Controladoria-Geral da União (2023). Relatório de análise da dosimetria de sanções em Processos Administrativo de Responsabilização. <https://www.gov.br/cgu/pt-br/aceso-a-informacao/institucional/eventos/anos-anteriores/2023/10-anos-da-lac/arquivos/sipri-relatorio-dosimetria-1.pdf>

- Correia Neto, J. F, Moura, H. J. de, & Forte, S. H. A. C. (2002). Modelo prático de previsão de fluxo de caixa operacional para empresas comerciais considerando os efeitos do risco, através do método de Monte Carlo. *Revista Eletrônica de Administração*, 8(3). <https://seer.ufrgs.br/index.php/read/article/view/44231>
- Costa, J. A. (2015). *O valor preditivo do resultado líquido contábil, dos accruals e do fluxo de caixa operacional das empresas do mercado segurador brasileiro* [Tese de doutorado, Universidade de São Paulo]. Biblioteca Digital USP.
- Craycraft, C., Craycraft, J. L., & Gallo, J. C. (1997). Antitrust sanctions and a firm's ability to pay. *Review of Industrial Organization*, 12, 171-183. <https://doi.org/10.1023/A:1007718618005>
- Cunha, M. F da., Martins, E., & Assaf Neto, A. (2014). Avaliação de empresas no Brasil pelo fluxo de caixa descontado: evidências empíricas sob o ponto de vista dos direcionadores de valor nas ofertas públicas de aquisição de ações. *Revista de Administração*, 49(2), 251-266. <http://doi.org/10.5700/rausp1144>
- Dadteev, K., Shchukin, B., & Nemeshaev, S. (2020). Using artificial intelligence Technologies to predict cash flow. *Procedia Computer Science*, 169, 264-268. <https://doi.org/10.1016/j.procs.2020.02.163>
- Dechow, P. (1994). Accounting earnings and cash flows as measures of firm performance: The role of accounting accruals. *The Accounting Review*.
- Del Giudice, V., De Paola, P., & Cantisani, G. B. (2017). Valuation of real estate investments through Fuzzy Logic. *Buildings*, 7(1), 26. <https://doi.org/10.3390/buildings7010026>
- Evdokimov, I., Kampouridis, M., & Papastylanou, T. (2023). Application of Machine Learning Algorithms to Free Cash Flows Growth Rate Estimation. *Procedia Computer Science*, 222, 529-538. <https://doi.org/10.1016/j.procs.2023.08.191>
- Fang, T., & Lahdelma, R. (2016). Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system. *Applied energy*, 179, 544-552. <https://doi.org/10.1016/j.apenergy.2016.06.133>
- Farber, S. C., Litvak, J., Duxstad, L. E., & Ihnow, G. (2016). Criminal Antitrust Fines and Penalties: Reductions Based on Ability to Pay. *Antitrust*, 31, 94.
- Financial Accounting Standards Board (1978). *Statement of Financial Accounting Concepts* No. 1.

[https://fasb.org/page/ShowPdf?path=con1.pdf&title=CON%201%20\(AS%20ISSUED\)](https://fasb.org/page/ShowPdf?path=con1.pdf&title=CON%201%20(AS%20ISSUED))

Fernandez, P. (2007). Company valuation methods. The most common errors in valuations. *IESE Business School*, 449, 1-27. <https://media.iese.edu/research/pdfs/DI-0449-E.pdf>

Gallo, J. C., Dau-Schmidt, K. G., Craycraft, J. L., & Parker, C. J. (1994). Criminal penalties under the Sherman Act: a study of law and economics. *Research in Law and Economics*, 16, 25.

Hendriksen, E. S., & Breda, M. F. V. (1999). *Teoria da Contabilidade*. Grupo GEN. <https://integrada.minhabiblioteca.com.br/books/9786559770250>

Javedan, F. A., & Largani, M. S. (2014). The effect of cash-flow component (core and non-core) on predicting future cash flow. *Bulletin of Applied and Research Science*, 4(2).

Karunasingha, D. S. K. (2022). Root mean square error or mean absolute error? Use their ratio as well. *Information Sciences*, 585, 609-629. <https://doi.org/10.1016/j.ins.2021.11.036>

Khashei, M., Bijari, M., & Ardali, G. A. R. (2009). Improvement of auto-regressive integrated moving average models using fuzzy logic and artificial neural networks (ANNs). *Neurocomputing*, 72(4-6), 956-967. <https://doi.org/10.1016/j.neucom.2008.04.017>

Kureljusic, M., & Metz, J. (2023). The applicability of machine learning algorithms in accounts receivables management. *Journal of Applied Accounting Research*. <https://doi.org/10.1108/JAAR-05-2022-0116>

Li, Y., Moutinho, L., Opong, K. K., & Pang, Y. (2015). Cash flow forecast for South African firms. *Review of Development Finance*, 5(1), 24-33. <https://doi.org/10.1016/j.rdf.2014.11.001>

Linares-Mustarós, S., Carles Ferrer-Comalat, J., & Cassú-Serra, E. (2013). The assessment of cash flow forecasting. *Kybernetes*, 42(5), 720-735. <https://doi.org/10.1108/K-03-2013-0060>

Lorek, K. S., & Willinger, G. L. (2008). Time-series properties and predictive ability of quarterly cash flows. *Advances in accounting*, 24(1), 65-71. <https://doi.org/10.1016/j.adiac.2008.05.010>

- Lucas, P. O., Orang, O., Silva, P. C., Mendes, E. M. A. M., & Guimaraes, F. G. (2022). A Tutorial on Fuzzy Time Series Forecasting Models: Recent Advances and Challenges. *Learning and Nonlinear Models*, 19(2), 29-50.
- Lustosa, P. R. B., & dos Santos, A. (2007). Poder relativo do lucro contábil e do fluxo de caixa das operações para prever fluxos de caixa futuros: um estudo empírico no Brasil. *Revista de Educação e Pesquisa em Contabilidade*, 1(1), 39-58.
- Mulenga, M., & Bhatia, M. (2017). The review of literature on the role of earnings, cash flows and accruals in predicting of future cash flows. *Accounting and finance Research*, 6(2), 59-70. <https://doi.org/10.5430/afr.v6n2p59>
- Nikkinen, J., & Sahlström, P. (2004). Impact of an accounting environment on cash flow prediction. *Journal of international accounting, auditing and taxation*, 13(1), 39-52. <https://doi.org/10.1016/j.intaccaudtax.2004.02.002>
- Noury, B., Hammami, H., Ousama, A. A., & Zeitun, R. (2020). The prediction of future cash flows based on operating cash flows, earnings and accruals in the French context. *Journal of Behavioral and Experimental Finance*, 28, 100414. <https://doi.org/10.1016/j.jbef.2020.100414>
- Ottaviani, F. M., & De Marco, A. (2022). Multiple linear regression model for improved project cost forecasting. *Procedia Computer Science*, 196, 808-815. <https://doi.org/10.1016/j.procs.2021.12.079>
- Pimenta, R. D. C. (2022). Limites jurídicos e econômicos da multa antitruste: a capacidade de pagamento como elemento de justiça e efetividade das condenações do CADE.
- Refinitiv (2024). <https://workspace.refinitiv.com>
- Sanchez-Roger, M., Oliver-Alfonso, M. D., & Sanchís-Pedregosa, C. (2019). Fuzzy logic and its uses in finance: a systematic review exploring its potential to deal with banking crises. *Mathematics*, 7(11), 1091. <https://doi.org/10.3390/math7111091>
- Santos, F. J. J dos., & Camargo, H. D. A. (2015). A hybrid forecast model combining fuzzy time series, linear regression and a new smoothing technique. In 2015 Conference of the International Fuzzy Systems Association and the European Society for Fuzzy Logic and Technology (IFSA-EUSFLAT-15) (pp. 1362-1368). Atlantis Press. <https://doi.org/10.2991/ifsa-eusflat-15.2015.192>

- Sarraf, F. (2020). Cash flow forecasting by using simple and sophisticated models in Iranian companies. *Iranian Journal of Finance*, 3(1), 24-52. <https://doi.org/10.22034/ijf.2020.202650.1071>
- Sicsú, A. L., Samartini, A., & Barth, N. L. (2023). *Técnicas de machine learning*. Editora Blucher. <https://integrada.minhabiblioteca.com.br/books/9786555063974>
- Soboleva, Y. P., Matveev, V. V., Ilminskaya, S. A., Efimenko, I. S., Rezvyakova, I. V., & Mazur, L. V. (2018). Monitoring of businesses operations with cash flow analysis. *International Journal of Civil Engineering and Technology*, 9(11), 2034.
- Supremo Tribunal Federal. (2024). *ADPF 1051/DF* (Arguição de Descumprimento de Preceito Fundamental). Acessado em outubro de 2024, em <https://portal.stf.jus.br/processos/detalhe.asp?incidente=6605876>.
- Tribunal de Contas da União (2020). *Acórdão 729/2020 - Plenário*. https://pesquisa.apps.tcu.gov.br/documento/acordao-completo*/NUMACORDAO%253A729%2520ANOACORDAO%253A2020/DTRELEVANCIA%2520desc%252C%2520NUMACORDAOINT%2520desc/0
- United States Sentencing Commission (2023). *Guidelines Manual Annotated*. <https://www.ussc.gov/guidelines/2023-guidelines-manual-annotated>
- Walkup, B. (2016). The impact of uncertainty on payout policy. *Managerial Finance*, 42(11), 1054-1072. <https://doi.org/10.1108/MF-09-2015-0237>
- Werden, G. J., & Simon, M. J. (1987). Why price fixers should go to prison. *The Antitrust Bulletin*, 32(4), 917-937. <https://doi.org/10.1177/0003603X8703200403>
- Werner, L., & Ribeiro, J. L. D. (2003). Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. *Gestão & Produção*, 10, 47-67. <https://doi.org/10.1590/S0104-530X2003000100005>
- Westergaard, G., Erden, U., Mateo, O. A., Lampo, S. M., Akinci, T. C., & Topsakal, O. (2024). Time Series Forecasting Utilizing Automated Machine Learning (AutoML): A Comparative Analysis Study on Diverse Datasets. *Information*, 15(1), 39. <https://doi.org/10.3390/info15010039>
- Weytjens, H., Lohmann, E., & Kleinstauber, M. (2021). Cash flow prediction: MLP and LSTM compared to ARIMA and Prophet. *Electronic Commerce Research*, 21(2), 371-391. <https://doi.org/10.1007/s10660-019-09362-7>

- Wils, W. P. (2006). Optimal antitrust fines: Theory and practice. *World Competition*, 29(2). <https://doi.org/10.54648.woco2006014>
- Whig, P., Gupta, K., Jiwani, N., Jupalle, H., Kouser, S., & Alam, N. (2023). A novel method for diabetes classification and prediction with Pycaret. *Microsystem Technologies*, 29(10), 1479-1487. <https://doi.org/10.1007/s00542-023-05473-2>
- Yao, J. S., Chen, M. S., & Lin, H. W. (2005). Valuation by using a fuzzy discounted cash flow model. *Expert Systems with Applications*, 28, 209-222. <https://doi.org/10.1016/j.eswa.2004.10.003>
- Zadeh, L. A. (1973). Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transactions on systems, Man, and Cybernetics*, (1), 28-44. <https://doi.org/10.1109/TSMC.1973.5408575>
- Zhu, L., Yan, M., & Bai, L. (2022). Prediction of enterprise free cash flow based on a backpropagation neural network model of the improved genetic algorithm. *Information*, 13(4), 172. <https://doi.org/10.3390/info13040172>
- Zrobek, S., Kovalyshyn, O., Renigier-Bilozor, M., Kovalyshyn, S., & Kovalyshyn, O. (2020). Fuzzy logic method of valuation supporting sustainable development of the agricultural land market. *Sustainable Development*, 28(5), 1094-1105. <https://doi.org/10.1002/sd.2061>