

PREVISÃO DE VALOR CORPORATIVO EM PERÍODOS DE CRISE: USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA EM EMPRESAS DO G20**FORECASTING CORPORATE VALUE DURING CRISIS PERIODS: USE OF MACHINE LEARNING ALGORITHMS IN G20 COMPANIES****Ewerton Alex Avelar**

Universidade Federal de Minas Gerais (UFMG)

ewertonalexavelar@gmail.com**Octávio Valente Campos**

Universidade Federal de Minas Gerais (UFMG)

octaviovc@yahoo.com.br**Jacqueline Braga Paiva Orefici**

Centro Universitário Leonardo da Vinci (UNIASSELVI)

j.orefici@gmail.com**Victor Antunes Leocádio**

Universidade Federal de Minas Gerais (UFMG)

victorantunesleocadio@gmail.com**Resumo**

A pesquisa apresentada neste artigo avaliou a previsibilidade de criação e de destruição de valor corporativo em períodos de crise (pandemia de Covid-19 e invasão russa à Ucrânia) com base em indicadores econômico-financeiros. Nesse sentido, foram empregados algoritmos de aprendizado de máquina (AM) e regressão logística (RL) para realizar essa previsão em empresas de países do G20. A pesquisa quantitativa e descritiva foi realizada com base em dados de 12.282 empresas entre os anos de 2019 e 2022. Foram desenvolvidos modelos empregando os seguintes algoritmos de AM para fins de classificação: árvores de decisão (*decision tree* – DT), *k-nearest neighbors* (KNN) e *naive Bayes* (NB). O desempenho de cada modelo desenvolvido para cada país anualmente foi avaliado com base em sua acurácia, sendo empregadas as seguintes técnicas de análise: estatística descritiva, teste de Shapiro Wilk e teste t de Student. Os resultados indicaram uma heterogeneidade na criação e na destruição de valor corporativo nas empresas dos diferentes países. Verificou-se que a destruição de valor observada na invasão da russa à Ucrânia foi bem maior que na pandemia de Covid-19 com base nas empresas analisadas. De forma geral, observou-se um desempenho médio bastante similar entre os modelos desenvolvidos com base em AM e a RL, apesar de uma frágil superioridade daqueles baseados no KNN sobre todos os demais. Por fim, observou-se uma ampla dispersão dos valores de desempenho dos modelos entre os países, indicando a necessidade de se compreender as características institucionais específicas para escolha dos melhores modelos de previsão.

Palavras-chave: criação e de destruição de valor corporativo; aprendizado de máquina (AM); indicadores econômico-financeiros.

Abstract

AVELAR, E. A.; CAMPOS, O. V.; OREFICI, J. B. P.; LEOCÁDIO, V. A... Previsão de valor corporativo em períodos de crise: uso de algoritmos de aprendizado de máquina em empresas do G20. *CONTABILEMETRIA - Brazilian Journal of Quantitative Methods Applied to Accounting*, Monte Carmelo, v. 12, n. 2, p. 38-54, jul.-dez./2025.

- a) Submissão em: 18/12/2023.
b) Envio para avaliação em: 15/01/2024.
c) Término da avaliação em : 18/01/2024.
d) Correções solicitadas em: 18/01/2024.
e) Recebimento da versão ajustada em: 13/02/2024.
f) Aprovação final em: 19/02/2024.

The research presented in this paper assessed the predictability of corporate value creation and destruction during crisis periods (Covid-19 pandemic and Russian invasion of Ukraine) based on economic and financial indicators. In this regard, machine learning (ML) algorithms and logistic regression (LR) were employed to make these predictions in G20 country companies. The quantitative and descriptive research was conducted using data from 12,282 companies between 2019 and 2022. Models were developed using the following ML algorithms for classification purposes: decision trees (DT), k-nearest neighbors (KNN), and naive Bayes (NB). The performance of each model developed for each country annually was evaluated based on its accuracy, employing the following analysis techniques: descriptive statistics, Shapiro-Wilk test, and Student's t-test. The results indicated heterogeneity in the creation and destruction of corporate value in companies from different countries. Based on the analyzed companies, it was found that the destruction of value observed in the Russian invasion of Ukraine was much greater than in the Covid-19 pandemic. Overall, a fairly similar average performance was observed among the models developed based on ML and LR, despite a slight superiority of those based on KNN over all others. Finally, a wide dispersion of model performance values among countries was observed, indicating the need to understand specific institutional characteristics for choosing the best prediction models.

Keywords: corporate value creation and destruction; machine learning (ML); economic and financial indicators.

1 Introdução

A criação de valor é o usualmente apontada como o principal objetivo em finanças corporativas. Essa afirmação é ratificada por Hall (2016), que destaca que a maximização do valor aos proprietários é uma das maiores ortodoxias do nosso tempo. Assim, diversos trabalhos têm focado o processo de criação de valor, na busca por variáveis mais ligadas a esses processos, sejam elas de mercado ou de contábeis, tais como Tamosiuniene *et al.* (2015) e Pastor *et al.* (2017).

Na busca para encontrar modelos que expliquem a criação de valor nas empresas, recentemente, uma série de estudos têm empregados algoritmos de aprendizado de máquina (AM), em substituição a técnicas estatísticas tradicionais de acordo com os autores Rundo *et al.*, (2019) e Ding e Qin (2020). O AM pode ser compreendido como uma subárea da inteligência artificial (IA) e que tem recebido bastante atenção recentemente devido a sua capacidade de previsão de variáveis econômico-financeiras, incluindo valor das empresas, tal como ressaltado em Clarke *et al.* (2020), Théate *et al.* (2021) e Rashedi *et al.* (2021). Destaca-se que, dentre os algoritmos empregados em finanças para fins de classificação, podem ser citados conforme Singh e Khushi (2021) e Avelar *et al.* (2022a): árvores de decisão (*decision tree* – DT), *k-nearest neighbors* (KNN) e naive Bayes (NB).

Entretanto, apesar da grande relevância do valor para as decisões corporativas e das diferentes formas de estima-lo, duas importantes crises afetaram o preço das ações das empresas em mercados de capitais ao redor do mundo nos últimos anos: a pandemia de Covid-19 e a invasão russa à Ucrânia. Ambas as crises afetaram o valor de empresas em todo o mundo, destruindo valor de forma sistemática (pelo menos em um primeiro momento), tal como destacam estudos como os de Baker *et al.* (2020), Abbassi *et al.* (2023), Bougias *et al.* (2022) e Cardillo *et al.* (2023). Salienta-se que estes dois últimos estudos evidenciaram a importância de informações contábeis prévias para previsão do desempenho das empresas em ambas as

crises. Essas informações contábeis podem ser sintetizadas em indicadores econômico-financeiros, que geram importante suporte decisório aos agentes econômicos, principalmente, em períodos de crise, como ressaltam Andekina e Rakhmetova (2013), Heyden e Heyden (2020) e Tron (2021).

Nesse contexto, a pesquisa apresentada neste artigo visou avaliar a previsibilidade de criação e de destruição de valor corporativo em períodos de crise (pandemia de Covid-19 e invasão russa à Ucrânia) com base em indicadores econômico-financeiros. Nesse sentido, foram empregados algoritmos de AM e regressão logística (RL) para realizar essa previsão em empresas de países do G20. Especificamente, visou-se: (a) identificar os níveis de criação e de destruição de valor nas empresas analisadas durante as crises; (b) desenvolver modelos de classificação baseados em algoritmos de AM para previsão do fenômeno; e (c) avaliar o desempenho dos modelos em relação a técnicas estatísticas tradicionais, assim como entre os próprios algoritmos. Destaca-se o enfoque em países do G20, por serem as maiores economias do mundo, englobando mais de 80% do produto interno bruto (PIB) mundial, possibilitando uma ampla análise da criação e da destruição de valor das empresas nos principais mercados de capitais. Ademais, resalta-se que esse grupo de países foi fundado após a crise financeira asiática em 1999, para servir como um fórum para os Ministros das Finanças e Governadores dos Bancos Centrais possam discutir questões econômico e financeiras globais (*Group of Twenty, 2024*).

Além da abrangência econômica e política dos mercados abordados na pesquisa, esta também se justifica no sentido de auxiliar na melhor compreensão de períodos de crise, momentos em que as oscilações dos preços dos ativos podem colapsar uma carteira de investimentos ou, por outro lado, podem proporcionar uma rentabilidade bem acima de outros *benchmarks*. Logo, estudos sobre os momentos de mercado em períodos de crises são fundamentais para a literatura e para os investidores, principalmente quando essas crises são geradas por momentos de destaque na história mundial, como a pandemia de Covid-19 e da invasão russa à Ucrânia. Por fim, destaca-se o emprego de algoritmos de AM, cujo emprego têm se ampliado rapidamente devido à importância da IA hoje na sociedade e que ainda têm grande potencialidades a serem exploradas em pesquisas em Contabilidade e Finanças.

O presente artigo está segregado em cinco seções, contando com esta Introdução. Na seção 2, apresenta-se a revisão da literatura e desenvolvem-se as hipóteses do estudo. Em seguida, na seção 3, os procedimentos metodológicos do estudo são descritos. Posteriormente, os resultados são apresentados e discutidos na seção 4. Por fim, na seção 5, as considerações finais são destacadas, seguidas das referências.

2 Revisão da Literatura

A busca pela criação de valor para os proprietários pode ser compreendida como o principal objetivo das finanças corporativas. Nesse sentido, Hall (2016) destaca que uma das maiores ortodoxias dos negócios do nosso tempo é a de que o objetivo de uma empresa é maximizar o valor para os acionistas. Salienta-se que, recentemente, duas importantes crises globais afetaram o valor das empresas ao redor do mundo de diferentes formas: a pandemia de Covid-19 e a invasão russa à Ucrânia.

Pode-se dizer que a crise causada pela pandemia de Covid-19 é completamente diferente das crises anteriores em termos de causa, alcance e gravidade conforme destacado por Horn *et al.* (2020). As economias experimentaram um choque de oferta e demanda. Por um lado, houve bloqueios de circulação e impedimentos ao trabalho, causando redução da produção e impacto imediato nas cadeias de suprimentos. Pelo outro lado, famílias e empresas reduziram suas demandas por bens e serviços. Segundo Baker *et al.* (2020), tais medidas influenciaram negativamente as operações das empresas e esse fato foi visível por meio das bolsas de valores.

No início, de 24 de fevereiro a 23 de março de 2020, vários índices apresentaram reduções significativas, dos quais podem ser citados: Dow Jones Industrials (-33,5%), Nasdaq (-25,6%) e Standard & Poor's 500 Index (-30,6%).

Apesar dos efeitos negativos primeiramente observados devido à eclosão da pandemia de Covid-19 em março de 2020, os efeitos diferiram entre setores ao longo do ano. Avelar *et al.* (2022b) analisaram empiricamente os efeitos da pandemia de Covid-19 sobre o desempenho econômico-financeiro das companhias abertas brasileiras e observaram que, apesar de uma queda generalizada dos preços das ações no mercado no primeiro trimestre de 2020, empresas de alguns setores se valorizaram ao longo do referido ano, enquanto outras não conseguiram se recuperar. Além dos preços das ações, diversos indicadores econômico-financeiros de empresas de diferentes setores apresentaram relações semelhantes.

Nesse sentido Achim *et al.* (2022), analisando o mercado romeno, observaram que, independentemente do tamanho, em média, setores de serviços como hotelaria, restauração, farmacêutica e imobiliário registraram quedas significativas em seu desempenho durante o período analisado. Por outro lado, observou-se que as pequenas empresas envolvidas na agricultura, comércio, construção, tecnologia da informação, transporte e armazenamento registraram melhorias significativas em seus lucros líquidos no período da pandemia quando comparados com o período anterior.

Diante de estudos como os supracitados, alguns trabalhos ampliaram o entendimento sobre as variáveis associados à melhoria ou redução do valor de empresas devido à pandemia de Covid-19. Nesse sentido, analisando empresas europeias, Cardillo *et al.* (2023) investigaram como àquelas mais sustentáveis se saíram durante a pandemia. Eles observaram que níveis mais altos de caixa e ativos líquidos no período pré-pandemia ajudaram as empresas a desempenhar e absorver as externalidades da Covid-19 melhor do que outras empresas.

Por sua vez, Kaczmarek *et al.* (2021) observaram os dados de 1.200 empresas de viagens e lazer em 52 países, já que, devido às paralisações, os setores de viagens e lazer sofreram impacto direto em suas operações. Segundo os autores, durante o primeiro trimestre de 2020, o setor de viagens e lazer caiu mais de 40%, experimentando a quarta maior queda entre as 38 categorias de setores analisadas. Mesmo nesse cenário, ainda havia algum comportamento heterogêneo dos retornos das ações no setor. Enquanto algumas ações caíram mais de 80%, outras subiram no mesmo período. Assim, utilizando regressões e ferramentas de AM – por meio de indicadores econômico-financeiro das empresas, de variáveis macroeconômicas e respostas de políticas governamentais – os resultados apontaram que as empresas com baixo endividamento e altos investimentos foram mais imunes ao crash induzido pela pandemia.

Além da pandemia de Covid-19, no início de 2022 houve o início da invasão russa à Ucrânia. Segundo Abbassi *et al.* (2023), tal conflito afetou as relações comerciais globais devido ao reajuste das relações globais desencadeado pelos alinhamentos comerciais russos. Os países do G7, embora já tenham imposto várias sanções econômicas e financeiras – incluindo o congelamento de bens de indivíduos civis – as expectativas de cenários pós-guerra e uma nova ordem mundial afetam os mercados acionários globais. Salienta-se que, apesar de as nações do G7 terem sido as primeiras a impor sanções contra a Rússia, a maioria delas também está entre os principais parceiros de exportação e importação da Rússia. Espera-se que as sanções ocidentais e os contra-ataques da Rússia mudem drasticamente os cenários comerciais. Consequentemente, há a expectativa de que os investidores reajam à mudança de informações. Enquanto alguns mercados de ações sofreram impactos negativos, alguns são insignificantes para o conflito e outros foram influenciados positivamente, como apontado por Yousaf *et al.* (2022).

Considerando esse evento, Bougias *et al.* (2022) usaram um modelo estrutural para medir o impacto imediato da invasão russa à Ucrânia em empresas europeias. Com base em

dados de preços de ações de alta frequência, para uma amostra de 964 empresas, observou-se que a guerra levou a preços mais baixos de títulos corporativos e maior volatilidade de ativos. Os retornos das ações são menores para empresas altamente endividadas, enquanto o efeito da alavancagem nos retornos dos ativos é estatisticamente insignificante. Além disso, as empresas com ativos mais voláteis experimentam retornos de dívida mais baixos e probabilidade de inadimplência mais altas, enquanto os fatores de tamanho e liquidez não tiveram poder explicativo sobre os retornos de títulos realizados.

Já Abbassi *et al.* (2023), empregando uma amostra de 531 empresas dos países do G7, examinaram o impacto da invasão russa à Ucrânia nos mercados de ações e observaram uma heterogeneidade nos efeitos que a guerra tem em diferentes mercados. Enquanto as empresas no Canadá e na Itália exibiram impactos cumulativos positivos, as da Alemanha, Itália e Reino Unido tiveram retornos cumulativos negativos. Além disso, as empresas francesas e americanas foram impactadas de forma insignificante pelo conflito. Ao contrário do esperado, retorno sobre ativos, alavancagem e retornos passados foram negativamente associados a retornos anormais. Seguindo uma linha semelhante, Yousaf, Patel e Yarovaya (2022) observaram que os mercados de ações da Hungria, Rússia, Polônia e Eslováquia reagiram negativamente nos dias pré e pós-evento; enquanto os mercados da Austrália, França, Alemanha, Índia, Itália, Japão, Romênia, África do Sul, Espanha e Turquia reagiram negativamente apenas nos dias pós-evento.

Dessa forma, observa-se que tanto a pandemia de Covid-19 quanto a invasão russa à Ucrânia tiveram efeitos heterogêneos nas empresas em várias partes do mundo e que parte dos estudos enfoca que a situação econômico-financeira prévia medida por indicadores dessas empresas estão associadas direta ou indiretamente ao efeito sobre seu valor. Isto posto, observa-se a importância de se estudar estas variáveis a fim de se buscar melhores formas de se alocar os recursos durante os períodos de crises. Considerando a profunda heterogeneidade dos efeitos das crises sobre o valor das empresas, o que tende a reduzir a previsibilidade de eventos, formulou-se a Hipótese 1 (H1):

H1: *os períodos de crise (pandemia de Covid-19 e a invasão russa à Ucrânia) afetaram de forma negativa a criação de valor das empresas de diferentes países.*

De acordo com Ross *et al.* (2015), é importante destacar que o valor de uma empresa é atrelado, dentre outros fatores, às variáveis macroeconômicas e às decisões dos gestores das empresas, sendo refletidas nas demonstrações contábeis dessas organizações. Desse modo, pode ser traçado uma estreita associação entre as informações econômico-financeiras das empresas e seu valor. Robinson, Henry e Broihahn (2020) afirmam que o papel das demonstrações contábeis é prover informações sobre o desempenho das empresas e sua posição econômico-financeira; e que sejam úteis a uma grande variedade de usuários na tomada de decisões econômicas. Esses autores ainda ressaltam que indicadores econômico-financeiros podem ser mensurados a partir de tais demonstrações, fornecendo uma síntese das informações contidas nas mesmas, auxiliando na tomada de decisões dos agentes econômicos.

Os indicadores econômico-financeiros provenientes das demonstrações contábeis podem ser segregados em quatro grupos principais com base na literatura: (i) liquidez – conforme Ross *et al.* (2015) e Wulandari e Patrisia (2021), fornecem informações sobre a capacidade da organização em honrar suas obrigações, contrapondo os seus direitos realizáveis e as suas exigibilidades; (ii) ciclos (atividades) – segundo Ross *et al.* (2015) e Choudhry *et al.* (2020), avaliam a eficiência com a qual os ativos da organização estão sendo administrados; (iii) endividamento (ou estrutura de capital) – de acordo com Fama e French (2005) e Padoveze e Benedicto (2014), explicitam a porcentagem dos ativos financiada com capital de terceiros e próprios, apontando a dependência de recursos de terceiros; e (iv) rentabilidade/lucratividade –

conforme Nguyen e Nguyen (2020) e Wulandari e Patrisia (2021), indicam o retorno alcançado pela organização por meio de suas atividades.

Destaca-se que a utilização de distintos grupos de indicadores econômico-financeiros possibilita uma vasta análise envolvendo diferentes dimensões de desempenho, bem como, uma análise simultânea de fatores endógenos e exógenos, o que é ratificado por autores como Andekina e Rakhmetova (2013) e Youssef (2021). Ressalta-se ainda que, em períodos de crise, a análise de indicadores econômico-financeiro tende a se tornar ainda mais relevante, tal como enfatizado por Heyden e Heyden (2020) e Tron (2021).

É importante salientar que há críticas sobre a atual capacidade dos indicadores econômico-financeiros mensurados a partir das demonstrações contábeis efetivamente refletirem o valor das empresas, sendo considerada a possibilidade de outras *proxies* para tais, tais como as citadas por Tamosiuniene *et al.* (2015) e Pastor *et al.* (2017). Todavia, amplos estudos como o desenvolvido por Hall (2016) ainda destacam as variáveis baseadas em informações contábeis como superiores àquelas relacionadas ao mercado para previsão do valor de empresas.

Recentemente, com a emergência da IA, algoritmos de AM têm sido empregados para prever o valor de empresas a partir de indicadores econômico-financeiros, tal como evidenciam Ding e Qin (2020) e Avelar *et al.* (2022a). Aqueles primeiros autores destacam que, nas últimas décadas, antes do emprego intensivo de algoritmos de AM, técnicas estatísticas eram amplamente empregadas para previsão de valor de ativos. Rundo *et al.* (2019), porém, ressaltam que técnicas estatísticas previamente empregadas para tal tarefa, tais como o *autoregressive integrated moving average* (ARIMA) e o *exponential smoothing model*, enfrentam problemas em cumpri-la adequadamente, devido ao baixo desempenho quando lidam com um grande volume de dados intrinsecamente complexos, assim como o entendimento das relações escondidas (dependências) entre os dados.

Dentre os estudos desenvolvidos nos últimos anos que obtiveram resultados promissores sobre a previsão de algoritmos de AM para previsão de valor corporativo, podem ser citados Clarke *et al.* (2020), Théate *et al.* (2021), Rashedi *et al.* (2021), e Singh e Khushi (2021). Estes últimos autores, especificamente, empregaram alguns algoritmos de AM específicos para a classificação (foco do estudo ora apresentado), quais sejam: árvore de decisão, KNN e Naive Bayes (NB). No que se refere ao algoritmo de árvore de decisão, o seu aprendizado cria um modelo que prevê o valor de uma variável de destino com base em diversas variáveis de entrada por particionamento recursivo, tal como evidenciam Moon *et al.* (2018). A cada passo é escolhida uma variável que melhor divide o conjunto de amostras. Diferentes medidas de impureza ou critérios de divisão podem ser usadas em árvores binárias, tais como: impureza Gini, entropia de informação ou erro de classificação (FACELI *et al.*, 2021).

Já o algoritmo KNN, tal como resalta Mitchell (1997), escolhe o rótulo de classe do novo ponto de dados por maioria de votos entre seus “k” vizinhos mais próximos. Esses vizinhos mais próximos são determinados pela métrica de distância escolhida. O KNN é simples e direto de implementar, mas é sensível à estrutura local dos dados e à complexidade computacional para classificar novas amostras, que cresce linearmente com o número de amostras no conjunto de treinamento. Moon *et al.* (2018) afirmam que O parâmetro k pode ser escolhido dependendo dos dados e, em geral, valores maiores desse parâmetro reduzem o efeito do ruído na classificação, mas tornam as fronteiras entre as classes menos distintas.

Por sua vez, conforme Faceli *et al.* (2021), o NB computa todas as probabilidades (a priori e condicionais) dos dados de treinamento. Segundo os referidos autores, o termo “naive” (ingênuo) está relacionado à hipótese de que os valores dos atributos de um exemplo independem de sua classe. Segundo Mitchell (1997), uma diferença interessante do NB em relação a outros algoritmos de AM é que não há uma explícita procura pelo espaço de hipóteses

possível. As hipóteses são formadas simplesmente pela frequência da combinação dos diversos dados usados na fase de treinamento.

É importante destacar que alguns poucos evidenciaram que o desempenho de alguns algoritmos de AM foi similar ao de técnicas estatísticas tradicionais, como os de Jaggi *et al.* (2021), Parray *et al.* (2020) e Pyo *et al.* (2017), ou até mesmo inferior, como destacam Jang e Lee (2019). Porém, de forma geral, o emprego de algoritmos de AM tal como os citados têm apresentado bons desempenhos em previsão do valor das empresas (medido pelo preço de suas ações), em diferentes contextos e empregando indicadores econômico-financeiros como um de seus inputs, tal como destacado por Rundo *et al.* (2019), Kaczmarek *et al.* (2021) e Singh e Khushi (2021). Assim, foi desenvolvida a Hipótese 2 (H2):

H2: *O desempenho dos algoritmos de AM para previsão de criação ou destruição de valor corporativo é superior ao de técnicas estatísticas tradicionais.*

3 Metodologia

Segundo a classificação de Cooper e Schindler (2003), a pesquisa apresentada neste artigo teve caráter descritivo e quantitativo. O foco foram as empresas de capital aberto dos países do G20, quais sejam: África do Sul, Alemanha, Arábia Saudita, Argentina, Austrália, Brasil, Canadá, China, Coreia do Sul, Estados Unidos da América (EUA), França, Índia, Indonésia, Itália, Japão, México, Reino Unido, Rússia e Turquia. Esse grupo de países foi selecionado por sua representatividade política e econômica: os membros do G20 representam aproximadamente 85% do PIB global, mais de 75% do comércio mundial e cerca de dois terços da população do globo (G20, 2024).

Os dados secundários foram coletados da plataforma Refinitiv® Eikon entre os anos de 2019 e 2022. Como o objetivo principal do estudo foi a previsão do valor das empresas em períodos de crise – pandemia de Covid-19 em 2020 e a invasão russa à Ucrânia em 2022 –, selecionaram-se dados referentes aos anos do início de tais crises, assim como dos períodos imediatamente anteriores a elas, quais sejam: 2019 e 2021. Para a seleção da amostra de empresas de cada país, foram considerados apenas as que apresentaram patrimônio líquido positivo nos anos de 2019 e 2021, de forma a não considerar aquelas com flagrantes problemas financeiros antes das crises. Os dados sobre valor de mercado de todos os países foram apurados em dólar americano (US\$).

Foram analisados todos os indicadores econômico-financeiro disponíveis na plataforma Refinitiv® Eikon, verificando sua capacidade de discriminar entre empresas que criaram ou destruíram de valor nos períodos de crise. Para tanto, foi empregado o teste de Mann-Whitney para selecionar os indicadores que melhor discriminariam individualmente entre empresas que criaram ou destruíram valor durante as crises. Como todos os indicadores se apresentaram significantes a menos de 5,0%, optou-se por aqueles de diferentes grupos que apresentaram menor número de dados ausentes na base, quais sejam: ciclo operacional (CO), giro do ativo (GA), margem EBITDA (MEBTIDA), dívida sobre patrimônio líquido (DPL) e liquidez corrente (LC). A operacionalização das variáveis empregadas é apresentada no Quadro 1.

Quadro 1: Operacionalização das variáveis

Variável	Sigla	Operacionalização
Criação de valor	CV	Se 1, a empresa criou valor na crise, ou seja, seu valor de mercado foi superior no ano da crise em relação ao ano imediatamente anterior. Se 0, a empresa destruiu valor na crise, ou seja, seu valor de mercado foi inferior no ano da crise em relação ao ano imediatamente anterior.

Ciclo operacional	CO	(PME + PMR) ÷ Ativo total
Giro do ativo	GA	Receitas ÷ Ativo total
Margem EBITDA	MEBTIDA	EBITDA ÷ Receita
Dívida sobre patrimônio líquido	DPL	Passivo exigível ÷ Patrimônio líquido
Liquidez corrente	LC	Ativo circulante ÷ Passivo circulante
PME equivale a prazo médio de estocagem; PMR equivale a prazo médio de recebimento de clientes; e EBITDA equivale a <i>Earnings before interest, taxes, depreciation and amortization</i> (Lucros antes de juros, tributos, depreciação e amortização)		

Fonte: elaborado pelos autores.

Inicialmente, foi estimado um modelo de RL. Hair Jr. *et al.* (2009, p. 225) a conceituam como “uma forma especializada de regressão que é formulada para prever e explicar uma variável categórica binária (dois grupos), e não uma medida de dependência métrica. Trata-se de uma técnica estatística tradicional usada para fins de classificação e empregado em estudos comparativos de criação de valor corporativo tais como os de Ananthakumar e Sarkar (2017) e Parray *et al.* (2020).

O modelo estimado foi o apresentada na Equação 1. Neste caso, foram estimados modelos para cada ano de crise para cada país. Assim, verificou-se a criação (ou destruição de valor) nos anos de 2020 (pandemia de Covid-19) e de 2022 (invasão russa à Ucrânia), considerando as variáveis independentes de seus indicadores econômico-financeiros dos anos prévios (2019 e 2021).

$$CV_t = \beta_0 + \beta_1 CO_{t-1} + \beta_2 GA_{t-1} + \beta_3 MEBTIDA_{t-1} + \beta_4 DPL_{t-1} + \beta_5 LC_{t-1} + \varepsilon \quad (1)$$

Nesse sentido, todos os algoritmos de AM (NB, DT e KNN) foram empregados para fins de classificação, com o propósito de prever a criação ou destruição de valor empregando as mesmas variáveis apresentadas no Quadro 1. Para o treinamento do modelo, foram usados 80% dos dados da amostra. Para estimar o desempenho do modelo, optou-se pelo cálculo da acurácia (Equação 2) calculada a partir dos dados de teste (20% remanescente da amostra).

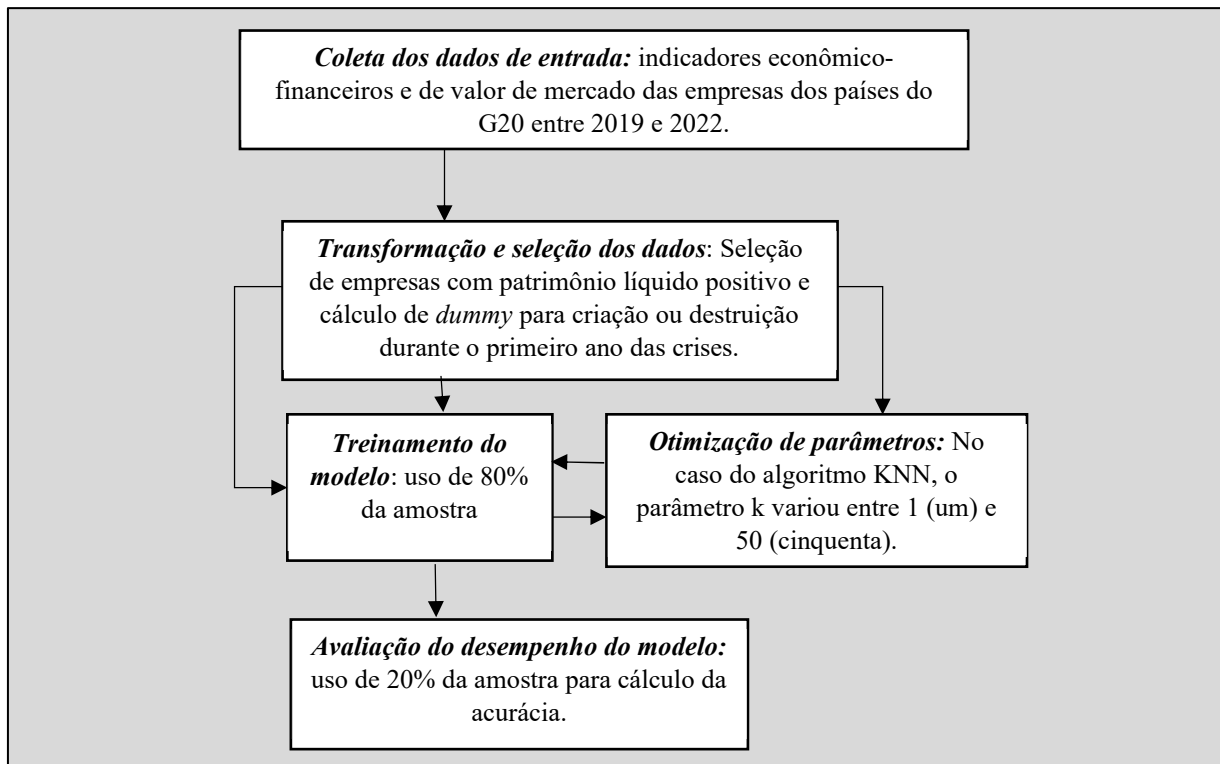
$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad (2)$$

Onde:

- ‘VP’ equivale a “verdadeiros positivos”;
- ‘VN’ equivale a “verdadeiros negativos”;
- ‘FP’ equivale a “falsos positivos”; e
- ‘FN’ equivale a “falsos negativos”.

Alguns parâmetros específicos foram ajustados para o algoritmo KNN. Possibilitou-se uma variação entre 1 (um) e 50 (cinquenta) para o parâmetro “k”, de modo que o algoritmo selecionasse o melhor “k-vizinhos mais próximos” para cada empresa para cada ano (Mitchell, 1997). Ademais, como os algoritmos DT e NB têm dificuldades em desenvolver modelos considerando dados contínuos, tal como evidenciado por Faceli *et al.* (2021), os mesmos foram categorizados conforme seus quartis. Na Figura 1 ressalta-se a forma de treinamento e teste dos modelos – com base em AM do fluxograma básico de Ferreira *et al.* (2021).

Figura 1: Fluxograma do processo de uso de algoritmos de IA para previsão da criação e destruição de valor corporativo



Fonte: elaborada pelos autores com base em Ferreira *et al.* (2021)

A análise dos resultados do estudo foi realizada por: estatística descritiva, teste de Shapiro Wilk e teste t de Student. A primeira técnica foi empregada para descrever os resultados obtidos. Por sua vez, o teste de Shapiro Wilk foi empregado para avaliar a normalidade dos dados usados nas análises. Uma vez confirmado esse pressuposto, o teste t de Student foi usado para avaliar a existência de diferenças estatisticamente significantes entre a criação ou destruição de valor corporativo entre os diferentes períodos, assim como entre desempenhos dos algoritmos de AM e entre esses desempenhos e o da RL. O nível de significância adotada nos testes foi de 5%. Todos os dados foram tratados e analisados a partir do R, utilizando os seguintes pacotes: *Functions for Classification* (class); *A Grammar of Data Manipulation* (dplyr); *Evaluation Metrics for Machine Learning* (Metrics); *Misc Functions of the Department of Statistics, Probability Theory Group* (e1071); *Read Excel Files* (readxl), e *Recursive partitioning for classification, regression and survival trees* (rpart) e *Testing Linear Regression Models* (lmtest). Por fim, o Quadro 2 apresenta a relação entre objetivos específicos, hipóteses e técnicas para a análise dos dados.

Quadro 2: Operacionalização das variáveis

Objetivo específico	Hipótese	Técnica(s) de análise
Identificar os níveis de criação e de destruição de valor nas empresas analisadas durante as crises.	H1	Estatística descritiva; e teste t de Student
Desenvolver modelos de classificação baseados em algoritmos de AM para previsão do fenômeno.	Não se aplica	Não se aplica

Avaliar o desempenho dos modelos em relação a técnicas estatísticas tradicionais, assim como entre os próprios algoritmos.	H2	Estatística descritiva; e teste t de Student
--	----	--

Fonte: elaborado pelos autores.

4 Apresentação e Análise dos Resultados

Esta seção apresenta e discute os resultados obtidos na pesquisa empírica. Salienta-se que, após a aplicação dos critérios citados na seção anterior para seleção da amostra, quatro países apresentaram um baixo número de observações, quais sejam: África do Sul, Argentina, Rússia e Índia. Dessa forma, como o baixo número de observações influenciaria de forma negativa o desenvolvimento de modelos de regressão, conforme Hair Jr. *et al.* (2009), optou-se por retirar estes países da amostra. Considerando, ainda, que a União Europeia, apesar de fazer parte do G20 não é um país *stricto sensu*, as análises foram realizadas com dados de 12.282 empresas dos 15 países remanescentes.

4.1 Efeitos das Crises sobre o Valor Corporativo

Esta subseção identifica os efeitos das crises na criação e na destruição de valor corporativo. Nesse sentido, a Tabela 1 apresenta o percentual de empresas que criaram valor por país anualmente. Em média, verificou-se que a proporção de empresas que gerou valor em 2019 (61,2%) foi inferior ao de 2020 (64,5%), mesmo com a crise gerada pela pandemia de Covid-19. Nesse contexto, destaca-se a Alemanha, que criou valor em 53,2% das empresas em 2019 e aumentou para 70,9% em 2020. Todavia, destaca-se a destruição de valor nas empresas americanas, que foram de 60,6% em 2019 para apenas 31,1% em 2020.

Essa grande heterogeneidade no número de empresas que criaram ou destruíram valor no primeiro ano da pandemia de Covid-19 corrobora o exposto por Kaczmarek *et al.* (2021) e Avelar *et al.* (2022b). Aqueles primeiros autores, assim como Cardillo *et al.* (2023), destacam que aspectos internos e externos às empresas no período pré-pandemia podem explicar parte do seu desempenho durante essa crise. Apesar da grande heterogeneidade das proporções em empresas, o teste t de Student indicou um coeficiente não significante de -0,7, ou seja, não é possível afirmar que a destruição de valor nas empresas da pandemia de Covid-19 afetou de forma relevante a proporção de empresas que criaram valor.

Tabela 1: Frequência de empresas que criaram valor por país anualmente

País	Obs.	Frequência relativa (%)			
		2019	2020	2021	2022
Alemanha	282	53,19	70,92	79,08	48,58
Arábia Saudita	225	44,44	42,22	66,22	55,56
Austrália	185	32,97	75,14	80,00	31,89
Brasil	279	94,62	92,47	46,24	58,42
Canadá	661	76,25	62,33	62,03	7,72
China	2.494	53,53	56,38	49,28	58,46
Coreia do Sul	2.249	67,76	63,76	85,73	56,83
EUA	3.195	60,59	31,14	68,11	28,76
França	260	54,23	76,92	73,85	39,62

Indonésia	561	72,19	59,36	70,59	60,96
Itália	257	56,03	70,82	72,37	39,69
Japão	771	63,42	76,65	71,85	29,57
México	122	76,23	69,67	87,70	59,84
Reino Unido	332	56,63	70,48	74,40	31,63
Turquia	409	56,23	48,41	44,01	28,12
Média		61,22	64,45	68,76	42,38

Fonte: elaborada pelos autores.

Observou-se que a proporção de empresas que gerou valor em 2022 (42,4%) foi inferior ao de 2021 (68,8%), com a crise gerada pela invasão russa à Ucrânia. Com exceção do Brasil e da China, em todos os outros países, a proporção de empresas que conseguiram criar valor em 2022 foi inferior a 2021. Houve casos bastante extremos como o do Canadá, cuja proporção de empresas que criaram valor foi de 62,0% em 2021 para apenas 7,7% em 2022. Mesmo as empresas dos EUA tiveram uma queda nessa proporção superior ao da pandemia de Covid-19, ou da Turquia, onde a maior parte das empresas perdeu valor de forma consistente.

Novamente, essa heterogeneidade de resultados corrobora estudos anteriores que enfocaram tal crise, tais como Bougias *et al.* (2022), Yousaf *et al.* (2022) e Abbassi *et al.* (2023). Esses dois últimos estudos enfocam, além de aspectos internos às empresas, os distintos efeitos da crise sobre diferentes países. Essa diferença nas proporções em empresas foi atestada estatisticamente pelo teste t de Student, indicando um coeficiente significativo (a menos de 1,0%) de 5,2, ou seja, é possível afirmar que a destruição de valor nas empresas da invasão russa à Ucrânia afetou de forma relevante a proporção de empresas que criaram valor.

Com base nos resultados obtidos, foi possível ratificar parcialmente H1, uma vez que, embora seja possível afirmar que houve uma maior destruição de valor das empresas durante a invasão russa à Ucrânia, o mesmo não é verdade em relação à pandemia de Covid-19.

4.2 Previsão de Criação de Valor Corporativo

Esta subseção apresenta e discute os resultados da avaliação de desempenho dos modelos baseados em AM em relação à RL, assim como entre os próprios algoritmos. A Tabela 2 apresenta a acurácia obtida em cada modelo considerando ambas as crises (pandemia de Covid-19 e invasão russa à Ucrânia). Por sua vez, as figuras 2 e 3 apresentam os gráficos box-plot dos desempenhos obtidos pelos modelos em ambos os contextos de crise.

Verifica-se que, no caso da pandemia de Covid-19, os melhores desempenhos médios foram obtidos pelo algoritmo KNN (70,7%) seguido do modelo de RL (67,9%). O pior desempenho médio foi obtido pelo algoritmo DT (64,7%). Todavia, é importante destacar a grande amplitude de desempenho entre os modelos considerando os diferentes países. No caso do DT, por exemplo, alcançou 90,0% no caso do Brasil e 86,2% para o Japão, igualando o desempenho do KNN. Por outro lado, o melhor desempenho obtido foi o da RL no caso do Brasil: 91,8% de acurácia.

Tabela 2: Acurácia estimada por modelo considerando as crises da pandemia de Covid-19 e a invasão russa à Ucrânia


Crise	Covid-19				Invasão russa à Ucrânia				
	País	NB	KNN	DT	RL	NB	KNN	DT	RL
Alemanha		0,5686	0,7059	0,5882	0,6200	0,4906	0,6038	0,4717	0,3770

Aráb. Saud.	0,5455	0,5758	0,5758	0,6060	0,3889	0,5833	0,4722	0,5830
Austrália	0,8182	0,8182	0,7576	0,7580	0,5758	0,7273	0,5152	0,6880
Brasil	0,9000	0,9000	0,9000	0,9180	0,6275	0,7059	0,6471	0,6080
Canadá	0,5506	0,6854	0,5393	0,6020	0,8646	0,9063	0,9063	0,9160
China	0,6105	0,5536	0,5996	0,5710	0,5938	0,5979	0,5833	0,5780
Cor. Sul	0,6396	0,6492	0,6468	0,6420	0,5812	0,5973	0,5721	0,5650
EUA	0,6989	0,6906	0,6823	0,6820	0,6886	0,6861	0,6837	0,6980
França	0,6957	0,8478	0,6522	0,7610	0,5319	0,6809	0,6383	0,6170
Indonésia	0,5474	0,5789	0,5053	0,5890	0,5882	0,6471	0,5490	0,6040
Itália	0,5682	0,6364	0,6591	0,6820	0,6596	0,6383	0,6383	0,6380
Japão	0,8483	0,8621	0,8621	0,7660	0,6776	0,6842	0,6776	0,6970
México	0,8636	0,7727	0,6364	0,6670	0,4545	0,6818	0,5455	0,3180
Reino Unido	0,6825	0,7143	0,6825	0,7460	0,7121	0,6970	0,6667	0,7120
Turquia	0,4795	0,6164	0,4110	0,5750	0,7403	0,7662	0,6753	0,7240
Média	0,6678	0,7072	0,6465	0,6790	0,6117	0,6802	0,6161	0,6215

Fonte: elaborada pelos autores.

Salienta-se que o teste t de Student não indicou nenhum desempenho estatisticamente significativo entre os modelos, apesar da superioridade média do KNN. Esse resultado vai de encontro ao apresentado por Rundo *et al.* (2019) e Ding e Qin (2020), mas em linha com estudos menos frequentes como o de Jaggi *et al.* (2021), Parray *et al.* (2020) e Pyo *et al.* (2017).

Gráfico 1: Box-plot do desempenho dos diferentes algoritmos para previsão da criação ou destruição de valor das empresas durante a pandemia de Covid-19



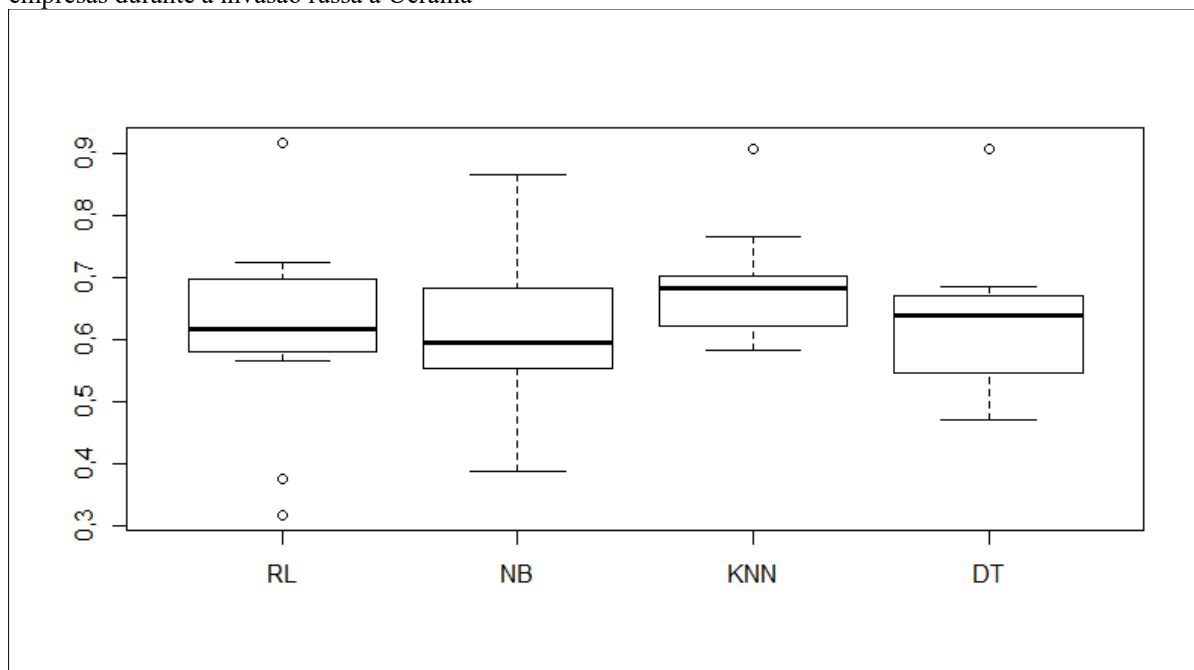
Fonte: elaborado pelos autores.

No caso do desempenho médio dos modelos referentes à invasão russa à Ucrânia, o melhor novamente foi obtido pelo algoritmo KNN (68,0%) seguido do modelo de RL (62,2%). Dessa vez, o pior desempenho médio foi obtido pelo algoritmo NB (61,2%). Mais uma vez, porém, é importante ressaltar a grande amplitude de desempenho entre os modelos considerando os diferentes países: no caso do NB, por exemplo, este alcançou acurácias de

66,0% e de 71,2% para Itália e Reino Unido, especificamente, os melhores desempenho para ambos os países entre todos os algoritmos.

O teste t de Student não indicou nenhum desempenho estatisticamente significativo entre os modelos a menos de 5,0%, apesar da superioridade média do KNN. Entretanto, é importante destacar que o teste supracitado indicou um coeficiente de -1,8 (significante a menos de 10%) entre o desempenho do KNN em relação ao NB e ao DT. Novamente, pode-se dizer que os achados vão contra ao esperado com base em Rundo *et al.* (2019) e Ding e Qin (2020), mas ao encontro dos Jaggi *et al.* (2021) e Parray *et al.* (2020). Estes últimos autores, especificamente, verificaram desempenhos similares entre modelos baseados em algoritmos de AM e aqueles estimados com base em RL.

Gráfico 2: Box-plot do desempenho dos diferentes algoritmos para previsão da criação ou destruição de valor das empresas durante a invasão russa à Ucrânia



Fonte: elaborado pelos autores.

De acordo com os achados, não foi possível corroborar a H2, pois, embora os modelos baseados no algoritmo KNN tenham tido um desempenho um pouco superior àqueles desenvolvidos com base em RL em uma das crises, os demais modelos estimados com base em algoritmos de AM não apresentaram resultados superiores àquela técnica estatística.

5 Considerações Finais

A pesquisa apresentada neste artigo visou avaliar a previsibilidade de criação e de destruição de valor corporativo em períodos de crise (pandemia de Covid-19 e invasão à Ucrânia) com base em indicadores econômico-financeiros. Nesse sentido, foram empregados algoritmos de AM e RL para realizar essa previsão em empresas de países do G20. No total, foram analisados dados de 12.282 empresas provenientes de 15 países.

Os resultados demonstraram diferentes níveis de criação de valor nas empresas analisadas durante as crises, apresentando resultados bastante heterogêneos entre os países. No que se relaciona à pandemia de Covid-19, que eclodiu em 2020, verificou-se, de forma inesperada, que um número maior de empresas gerou valor no referido ano em relação a 2019. Já no que se refere à invasão russa à Ucrânia, iniciada em 2022, observou-se uma redução

generalizada do número de empresas que conseguiram criar valor em quase todos os países. Essa queda foi confirmada como estatisticamente significativa.

No caso dos modelos baseados em algoritmos de AM e da RL empregados para previsão da criação ou destruição de valor das empresas durante as crises com base em indicadores econômico-financeiros, também foram verificados resultados bastante diferentes entre as empresas de cada país. Em ambas as crises, observou-se que o desempenho médio dos modelos desenvolvidos com base algoritmo KNN foi superior aos demais, porém, essa superioridade foi suportada estatisticamente (e de forma menos rigorosa) apenas no caso da crise relacionada à invasão russa da Ucrânia. Assim, em geral, não foi possível ratificar a superioridade dos modelos baseados em algoritmos de AM sobre aqueles estimados com base em técnicas tradicionais como a RL.

A pesquisa desenvolvida contribuiu de forma relevante para o estudo da criação de valor em períodos de crise sob diferentes aspectos: (a) demonstrou-se a heterogeneidade na criação e na destruição de valor corporativo considerando países bastante diversos nas mesmas crises; (b) verificou-se um desempenho médio bastante similar entre os modelos desenvolvidos com base em AM e a RL; e (c) destacou-se uma ampla dispersão dos desempenho dos modelos entre os países, indicando a necessidade de se compreender as características institucionais específicas para escolha dos melhores modelos de previsão.

Estudos futuros poderiam incluir outros grupos de países além do G20, em especial, os emergentes não contemplados pelo bloco. Ademais, poder-se-ia empregar variáveis específicas do ambiente institucional de cada país para desenvolvimento dos modelos, com o objetivo de aprimorar os já desenvolvidos com base em indicadores econômico-financeiros. Além disso, como as crises ainda geram efeitos econômicos ao redor do mundo, suas influências na criação de valor corporativo poderiam ser exploradas de forma longitudinal nos próximos anos. Por fim, para avaliar o impacto da política monetária de cada país sobre os resultados, poder-se-ia deflacionar os valores apresentados de acordo com a expansão dos agregados monetários M1 e M2 de cada nação ou, até mesmo, deflacioná-los pela taxa de aumento dos balanços patrimoniais dos respectivos bancos centrais.

Agradecimentos: os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo apoio no desenvolvimento desta pesquisa.

Referências

ABBASSI, W.; KUMARI, V.; PANDEY, D. K. What makes firms vulnerable to the Russia–Ukraine crisis? **Journal of Risk Finance**, [s.l.], v. 24, n. 1, p. 24-39, 2023.

ACHIM, M. V. *et al.* The impact of covid-19 on financial management: evidence from Romania. **Economic Research-Ekonomska Istraživanja**, [s.l.], v. 35, n. 1, p. 1807-1832, 2022.

ANANTHAKUMAR, U.; SARKAR, R. Application of logistic regression in assessing stock performances. *In*: INTERNATIONAL CONFERENCE ON DEPENDABLE, AUTONOMIC AND SECURE COMPUTING, INTERNATIONAL CONFERENCE ON PERVASIVE INTELLIGENCE AND COMPUTING, INTERNATIONAL CONFERENCE ON BIG DATA INTELLIGENCE AND COMPUTING AND CYBER SCIENCE AND TECHNOLOGY CONGRESS, 15., 2017, Orlando. **Anais[...]** Orlando: IEEE. p. 1242-1247.

ANDEKINA, R.; RAKHMETOVA, R. Financial analysis and diagnostics of the company. **Procedia Economics and Finance**, [s.l.], v. 5, p. 50-57, 2013.

AVELAR, E. A. *et al.* The Covid-19 pandemic effects on the financial performance of Brazilian listed companies. **Revista de Administração da UFSM**, Santa Maria, v. 15, p. 389-410, 2022a.

AVELAR, E. A. *et al.* Inteligência artificial e previsão de preços de ativos financeiros: uma revisão sistemática. **Sistemas & Gestão**, Rio de Janeiro, v. 17, n. 3, p. 271-285, 2022b.

BAKER, S. R. *et al.* Covid-induced economic uncertainty. **National Bureau of Economic Research**, Cambridge, n. 26983, p. 1-17, 2020.

BOUGIAS, A.; EPISCOPOS, A.; LELEDAKIS, G. N. Valuation of European firms during the Russia–Ukraine war. **Economics Letters**, [s.l.], v. 218, p. 110750, 2022.

CARDILLO, G.; BENDINELLI, E.; TORLUCCIO, G. COVID-19, ESG investing, and the resilience of more sustainable stocks: evidence from European firms. **Business Strategy and the Environment**, [s.l.], v. 32, n. 1, p. 602-623, 2023.

CHOUDHRY, T.; HASSAN, S. S.; SHABI, S. US economic uncertainty, EU business cycles, and the global financial crisis. **International Journal of Finance & Economics**, [s.l.], v. 25, n. 1, p. 28-42, 2020.

CLARKE, J. *et al.* Fake news, investor attention, and market reaction. **Information Systems Research**, [s.l.], v. 32, n. 1, p. 35-52, 2020.

COOPER, D. R.; SCHINDLER, P. S. **Métodos de pesquisa em administração**. 7.ed. Porto Alegre: Bookman, 2003.

DING, G.; QIN, L. Study on the prediction of stock price based on the associated network model of LSTM. **International Journal of Machine Learning and Cybernetics**, [s.l.], v. 11, p. 1307-1317, 2020.

FACELI, K. *et al.* **Inteligência Artificial: uma abordagem de aprendizado de máquina**. 2 ed. São Paulo: GEN, 2021.

FAMA, E. F.; FRENCH, K. R. Financing decisions: who issues stock? **Journal of Financial Economics**, [s.l.], v. 76, n. 3, p. 549-582, 2005.

FERREIRA, F. G. D. C.; GANDOMI, A. H.; CARDOSO, R. T. N. Artificial intelligence applied to stock market trading: a review. **IEEE Access**, [s.l.], v. 9, p. 30898-30917, 2021.

GROUP OF TWENTY. **About the G20: group is the main forum for international economic cooperation**. Disponível em: <https://www.g20.org/en/about-the-g20>. Acesso em 10 fev. 2024.

HAIR JÚNIOR, J. F. *et al.* **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

- HALL, J. H. Industry-specific determinants of shareholder value creation. **Studies in Economics and Finance**, [s.l.], v. 33, n. 2, p. 190-208, 2016.
- HEYDEN, K. J.; HEYDEN, T. Market reactions to the arrival and containment of COVID-19: an event study. **Finance Research Letters**, [s.l.], v. 38, p. 101745, 2021.
- HORN, S.; REINHART, C. M.; TREBESCH, C. China's overseas lending and the looming developing country debt crisis. **Kieler Beiträge Zur**, [s.l.], v. 35, 2020.
- JAGGI, Mukul *et al.* Text mining of stocktwits data for predicting stock prices. **Applied System Innovation**, [s.l.], v. 4, n. 1, p. 13, 2021.
- JANG, H.; LEE, J. Machine learning versus econometric jump models in predictability and domain adaptability of index options. **Physica A: Statistical Mechanics and its Applications**, [s.l.], v. 513, p. 74-86, 2019.
- KACZMAREK, T. *et al.* How to survive a pandemic: the corporate resiliency of travel and leisure companies to the COVID-19 outbreak. **Tourism Management**, [s.l.], v. 84, p. 104281, 2021.
- MITCHELL, T. M. **Machine learning**. Chennai, Ii; New York: McGraw-Hill Education; McGraw-Hill, 1997.
- MOON, K. S.; SOOKYUNG, J.; HONGJOONG, K. Speed up of the majority voting ensemble method for the prediction of stock price directions. **Economic Computation & Economic Cybernetics Studies & Research**, [s.l.], v. 52, n. 1, 2018.
- NGUYEN, T. N. L.; NGUYEN, V C. The determinants of profitability in listed enterprises: a study from Vietnamese stock exchange. **Journal of Asian Finance, Economics and Business**, [s.l.], v. 7, n. 1, p. 47-58, 2020.
- PADOVEZE, C. L.; BENEDICTO, G. C. **Análise das demonstrações financeiras**. 3 ed. São Paulo: Cengage Learning, 2014.
- PARRAY, I. R. *et al.* Time series data analysis of stock price movement using machine learning techniques. **Soft Computing**, [s.l.], v. 24, p. 16509-16517, 2020.
- PASTOR, D. *et al.* Intangibles and methods for their valuation in financial terms: literature review. **Intangible capital**, [s.l.], v. 13, n. 2, p. 387-410, 2017.
- PYO, S. *et al.* Predictability of machine learning techniques to forecast the trends of market index prices: hypothesis testing for the Korean stock markets. **PloS One**, [s.l.], v. 12, n. 11, p. e0188107, 2017.
- RASHEDI, K. A. *et al.* Application of radial basis function neural network coupling particle swarm optimization algorithm to classification of Saudi Arabia stock returns. **Journal of Mathematics**, [s.l.], v. 2021, p. 1-8, 2021.

ROBINSON, T. R.; HENRY, E.; BROIHAHN, M. A. **International financial statement analysis**. Hoboken, New Jersey: John Wiley & Sons, 2020.

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE, J.; LAMB, R. **Administração financeira**. 10 ed. São Paulo: AMGH, 2015.

RUNDO, F. *et al.* Machine learning for quantitative finance applications: a survey. **Applied Sciences**, [s.l.], v. 9, n. 24, p. 5574, 2019.

SINGH, J.; KHUSHI, M. Feature learning for stock price prediction shows a significant role of analyst rating. **Applied System Innovation**, [s.l.], v. 4, n. 1, p. 17, 2021.

THÉATE, T.; ERNST, D. An application of deep reinforcement learning to algorithmic trading. **Expert Systems with Applications**, [s.l.], v. 173, p. 114632, 2021.

TRON, A. Common characteristics of firms in financial distress and prediction of bankruptcy or recovery: an empirical research carried out in Italy. *In: Corporate financial distress*. Emerald Publishing, 2021. P. 67-99.

TAMOSIUNIENE, R.; SURVILAITĖ, S.; SHATREVICH, V. Intellectual capital approach to modern management through the perspective of a company's value added. **Business: Theory and Practice**, [s.l.], v. 16, n. 1, p. 31-44, 2015.

WULANDARI, A; PATRISIA, D. Comparative analysis of financial performance before and during the Covid-19 pandemic using profitability, liquidity, solvency and economic value added (EVA) ratios in go public companies listed on the Indonesia. **Financial Management Studies**, [s.l.], v. 1, n. 4, p. 47-59, 2021.

YOUSAF, I.; PATEL, R.; YAROVAYA, L. The reaction of G20+ stock markets to the Russia-Ukraine conflict "black-swan" event: evidence from event study approach. **Journal of Behavioral and Experimental Finance**, [s.l.], v. 35, p. 100723, 2022.

YOUSSEF, J. A. Investigating consumer finance in Lebanon: an empirical study of ATM and virtual currency. *In: HO, R. C.; NG, A. H. H.; NOURALLAH, M. (ed.). Impact of globalization and advanced technologies on online business models*. Hershey, PA: IGI Global, 2021. p. 32-54.