



University of  
Texas Libraries



e-revist@s



Centro Universitário Santo Agostinho

# revistafsa

www4.unifsanet.com.br/revista

Rev. FSA, Teresina, v. 22, n. 5, art. 1, p. 3-21, mai. 2025

ISSN Impresso: 1806-6356 ISSN Eletrônico: 2317-2983

<http://dx.doi.org/10.12819/2025.22.5.1>

DOAJ DIRECTORY OF  
OPEN ACCESS  
JOURNALS

WZB  
Wissenschaftszentrum Berlin  
für Sozialforschung



## Previsão do Valor Corporativo com uso de Algoritmos de Inteligência Artificial

### Forecasting Corporate Value: Application of IA-Based Algorithms

#### Ewerton Alex Avelar

Doutor em Administração pela Universidade Federal de Minas Gerais  
Professor da Universidade Federal de Minas Gerais  
E-mail: ewertonalexavelar@gmail.com

#### André Vidal Tarastchuk

Graduando em Ciências Contábeis pela Universidade Federal de Minas Gerais  
Estudante da Universidade Federal de Minas Gerais  
E-mail: vidalandre@outlook.com

#### Regiane Oliveira de Moraes Soares

Graduada em Ciências Contábeis pela FAMINAS  
Mestranda em Controladoria e Contabilidade pela Universidade Federal de Minas Gerais  
E-mail: regianebh1@gmail.com

#### Antônio Artur de Souza

Ph.D. em Management Science pela Lancaster University (UK)  
Professor da Universidade Federal de Minas Gerais  
E-mail: antonioarturdesouza@gmail.com

#### Endereço: Ewerton Alex Avelar

Avenida Presidente Antônio Carlos, 6627, sala 2040 –  
Pampulha – Belo Horizonte – MG, Brasil. CEP: 31270-  
901. Brasil.

#### Endereço: André Vidal Tarastchuk

Avenida Presidente Antônio Carlos, 6627, sala 2040 –  
Pampulha – Belo Horizonte – MG, Brasil. CEP: 31270-  
901. Brasil.

#### Endereço: Regiane Oliveira de Moraes Soares

Avenida Presidente Antônio Carlos, 6627, sala 2040 –  
Pampulha – Belo Horizonte – MG, Brasil. CEP: 31270-  
901. Brasil.

#### Endereço: Antônio Artur de Souza

Avenida Presidente Antônio Carlos, 6627, sala 2040 –  
Pampulha – Belo Horizonte – MG, Brasil. CEP: 31270-  
901. Brasil.

**Editor-Chefe: Dr. Tonny Kerley de Alencar Rodrigues**

**Artigo recebido em 12/02/2025. Última versão recebida em 10/03/2025. Aprovado em 11/03/2025.**

**Avaliado pelo sistema Triple Review: a) Desk Review pelo Editor-Chefe; e b) Double Blind Review (avaliação cega por dois avaliadores da área).**

**Revisão: Gramatical, Normativa e de Formatação**



## RESUMO

O estudo apresentado visou avaliar o desempenho de algoritmos de inteligência artificial para previsão do *Market Value Added* (MVA®) em empresas de países que fazem parte dos BRICS (sigla em inglês para *Brazil, Russia, India, China and South Africa*) entre 2019 e 2022. Dados das empresas de capital aberto desses países foram empregados para treinar algoritmos de inteligência artificial – especificamente, *random forest* e redes neurais artificiais, assim como modelos de regressão linear, para fins de previsão a partir de direcionadores de valor clássicos da literatura baseadas em variáveis contábeis. Os resultados indicaram que tais direcionadores foram significantes e consistentes em explicar o MVA® positivo das empresas estudadas, mesmo em períodos de crise. Verificou-se a aplicabilidade do *random forest* e das redes neurais artificiais para essa previsão. Estatisticamente, os modelos baseados no algoritmo de *random forest* tiveram um desempenho similar àqueles de regressão, enquanto os modelos de redes neurais artificiais apresentaram desempenho superior. Os resultados do estudo contribuem de forma relevante ao tema criação de valor corporativo sob diferentes perspectivas, tais como: (a) foco em empresas de países emergentes cada vez mais relevantes no contexto global; (b) avaliação de modelos para previsão de valor em períodos distintos com diferentes crises econômicas globais; e (c) destaque da relevância do emprego de algoritmos de inteligência artificial, assim, como os de estatística tradicionais para análise do fenômeno.

**Palavras-chave:** *Market Value Added* (MVA®). Algoritmos de Inteligência Artificial. BRICS.

## ABSTRACT

This paper presents a study that aimed at assessing the performance of artificial intelligence (IA) based algorithms for predicting Market Value Added (MVA®) in companies from the BRICS countries (an acronym for Brazil, Russia, India, China, and South Africa) between 2019 and 2022. Data from public companies in these countries were used to train IA-based algorithms (random forest and artificial neural networks), as well as linear regression models, for prediction purposes grounded on classic value drivers from the literature based on accounting variables. The results indicated that these drivers were significant and consistent in explaining the positive MVA® for the studied companies, even during periods of crisis. The applicability of random forest and artificial neural networks for this activity was confirmed. Models based on the random forest algorithm performed similarly to regression models. On the other hand, artificial neural network models outperformed them. The study's findings make a relevant contribution to the topic of corporate value creation from various perspectives, such as: (a) a focus on companies from increasingly relevant emerging economies in the global context; (b) evaluation of models for value prediction in different periods with global economic crises; and (c) highlighting the importance of employing both artificial intelligence algorithms and traditional statistical methods for analyzing the phenomenon.

**Keywords:** *Market Value Added* (MVA®); IA-Based Algorithms; BRICS.

## 1 INTRODUÇÃO

A criação de valor das empresas é um dos principais temas abordados em finanças corporativas. Faiteh e Aasri (2023) explicam que o objetivo dessas organizações é maximizar a riqueza dos proprietários e de seus *stakeholders*, para garantir um crescimento sustentável. Devido à importância da geração de valor para as empresas e demais agentes de mercado, estudos vêm empregando técnicas estatísticas e outras relacionadas à inteligência artificial para buscar melhores previsões de tais valores, tomando como base os preços das ações em mercados de capitais, como explanam Shynkevich *et al.* (2017) e Cao *et al.* (2019).

Hall (2018) afirma que existem diversas métricas para se avaliar o valor de uma empresa, dentre as quais pode-se destacar o valor agregado pelo mercado (*market value added* – MVA®). Essa medida demonstra, segundo Petravičius e Tamošiūnienė (2008), que o excesso de valor criado pelas empresas decorre da diferença entre o valor de mercado das ações e o valor contábil. Nesse sentido, segundo Sareewiwatthana e Wanidwaranan (2019), o MVA® refletiria o desempenho de uma empresa ao longo de toda a sua existência.

Ressalta-se que, ao empregar o valor de mercado das empresas em sua mensuração, o MVA® é afetado tanto por variáveis endógenas como por variáveis exógenas às empresas. No que se refere a esse último tipo de variável, nos últimos anos, duas crises afetaram de forma significativa o valor de mercado das empresas em âmbito global: a pandemia de Covid-19 e a invasão russa à Ucrânia (CARDILLO *et al.*, 2023; ABBASSI *et al.*, 2023). Estudos como os de Kaczmarek *et al.* (2021) e Yousaf *et al.* (2022) evidenciaram que ambas as crises destruíram sistematicamente o valor das corporações ao redor do mundo. Porém, os mesmos trabalhos demonstraram que empresas de alguns setores e países conseguiram criar valor mesmo durante tais crises.

Destaca-se que ambas as crises, em seu início, envolveram dois países emergentes e que se destacaram no século XXI por seu forte crescimento econômico: China e Rússia. Ambos fazem parte do bloco denominado BRICS (sigla em inglês para Brazil, Russia, India, China and South Africa), um grupo de países emergentes que apresentou altas taxas de crescimento econômico nas primeiras décadas deste século e que tem tido um papel cada vez mais relevante econômica e politicamente no mundo (OUR WORLD IN DATA, 2023; INFOBRICS, 2023). Salienta-se que, mesmo diante das crises supracitadas, algumas empresas desses países conseguiram agregar valor de mercado de forma consistente nos últimos anos.

Diante disso, o estudo apresentado neste artigo visou avaliar o desempenho de algoritmos de inteligência artificial para a previsão do MVA® em empresas de países do

BRICS, tomando como base dados relativos ao período entre 2019 e 2022. Os objetivos específicos do estudo foram: (i) identificar as variáveis que contribuíram para a manutenção de um MVA® positivo das empresas ao longo do período analisado; (ii) avaliar a capacidade de predição do MVA® de algoritmos de inteligência artificial e de modelos tradicionais; e (iii) discutir os resultados sob a perspectiva da literatura de Contabilidade e Finanças. Para tanto, foram coletados dados secundários de empresas de capital aberto dos países que compõem os BRICS entre os anos de 2019 e 2022. Para a seleção da amostra, foram consideradas aquelas que apresentaram MVA® positivo em todos os anos de maneira consistente, de forma a compreender melhor as variáveis determinantes (direcionadores) desse valor. Foram estimados modelos baseados em regressões lineares e em algoritmos de inteligência artificial e analisados seus desempenhos para fins de previsão. Empregaram-se técnicas de estatística descritiva e testes estatísticos paramétricos e não paramétricos para análise dos resultados.

Os resultados indicaram que as variáveis contábeis determinantes de valor foram significantes e consistentes para explicar o MVA® positivo das empresas estudadas, mesmo em períodos de crise. Verificou-se a aplicabilidade de algoritmos de inteligência artificial para a previsão de valor das empresas, sendo que em alguns casos o desempenho desses algoritmos foi superior ao de técnicas estatísticas tradicionais. O estudo ora apresentado inova ao: (i) analisar empresas de países emergentes, que têm um papel político e econômico cada vez mais relevante no contexto global; (ii) avaliar o desempenho de modelos para previsão de valor em períodos distintos, incluindo duas crises econômicas globais; (iii) empregar diferentes algoritmos de inteligência artificial para fins de previsão do fenômeno de criação de valor empresarial, tecnologia cada vez mais usada pelos gestores, acadêmicos e pela sociedade de forma geral; e (iv) demonstrar a heterogeneidade de desempenho dos diferentes modelos, considerando os distintos contextos institucionais dos países e os momentos econômicos globais.

## 2 FUNDAMENTAÇÃO TEÓRICA

Segundo Santos *et al.* (2021), a “criação de valor é o objeto principal da gestão financeira de uma empresa”. Uma forma de mensuração de tal valor de companhias abertas é baseada no preço de suas ações a partir da sua negociação no mercado de capitais. Diversos trabalhos destacam a relação entre o preço das ações e o real valor de uma empresa, tais como os de Aguiar *et al.* (2011), Altaf (2016), Hall (2018) e Santos *et al.* (2021). Estes últimos

autores justificam o emprego dessa variável como uma *proxy* de valor, porque a precificação de mercado de uma dada empresa reflete a expectativa dos agentes sobre a sua futura geração de caixa, desde que o mercado seja eficiente e que o preço da ação seja coerente com o conjunto de informações que afetam o seu fluxo futuro de caixa.

Nessa linha, uma medida utilizada para mensuração de valor agregado de uma empresa baseada em seus preços de mercado amplamente empregada é o MVA® (HALL, 2018). Sareewiwatthana e Wanidwaranan (2019) afirmam que ela é fácil de ser calculada e representa a diferença entre o capital investido pelos proprietários e o valor de mercado da empresa (baseada nos preços públicos das suas ações). Os autores salientam que o MVA® pode ser considerado uma boa *proxy* da eficiência operacional e financeira de uma empresa e também da competência dos seus gestores decidirem sobre investimentos.

Entretanto, entender como esse valor é agregado pelo mercado não é trivial. Assim, compreender os direcionadores de valor é relevante para os agentes econômicos (AGUIAR *et al.*, 2011). Diversas variáveis são empregadas nos estudos para explicar o valor corporativo, dentre elas se destacam aquelas baseadas em informações contábeis (HALL, 2018). Dentre tais direcionadores de valor usualmente empregados na literatura, destacam-se: endividamento, lucratividade, rentabilidade, risco e tamanho da empresa (ZEGHAL; MAALLOUL, 2010; AGUIAR *et al.*, 2011; MISHRA; MOHANTY, 2014; ROSS *et al.*, 2015; ALTAF, 2016; HALL, 2018; SANTOS *et al.*, 2021).

A discussão moderna em finanças corporativas sobre a relação entre o endividamento das empresas e seu valor foi desenvolvida, especialmente, a partir de Modigliani e Miller (1958). Apesar de não haver um consenso na Academia sobre essa relação ao longo das últimas décadas, alguns pressupostos são amplamente aceitos na literatura: benefícios fiscais da dívida tendem a auxiliar na criação de valor, reduzindo o custo de financiamento dos ativos; altos níveis de endividamento aumentam os custos de falência da empresa, diminuindo o seu valor (ROSS *et al.*, 2015).

Já a rentabilidade visa evidenciar o aumento dos benefícios econômicos e está estreitamente relacionada à criação de valor corporativo, conforme Besanko *et al.* (2012). Embora esses autores ressaltem diferenças relevantes entre a lucratividade econômica e a contábil, dentre as suas formas de mensuração, uma *proxy* amplamente empregada na literatura é o retorno sobre os ativos, calculado a partir das demonstrações contábeis (ZEGHAL; MAALLOUL, 2010; AGUIAR *et al.*, 2011). No que refere ao risco, desde o trabalho clássico de Markowitz (1952), a variabilidade de resultados é amplamente empregada como *proxy* desse fenômeno em finanças. Desde a década de 1960 até hoje, uma

medida de risco empregada, tanto no meio empresarial como acadêmico, é o beta ( $\beta$ ), que, sinteticamente, enfatiza a variabilidade dos retornos de um ativo específico em relação ao retorno médio do mercado (ROSS *et al.*, 2015).

Por fim, conforme Mishra e Mohanty (2014), o tamanho de uma empresa é muito empregado como variável de controle em modelos de desempenho, sendo relacionado ao valor total de mercado de uma empresa. É importante destacar que companhias maiores podem gerar mais valor devido ao seu volume de ativos, reputação e capacidade de negociar em melhores condições. Diante do exposto, foi desenvolvida a Hipótese 1 (H1) do estudo:

***H1: As variáveis determinantes de valor são significantes para explicar o MVA® das empresas independentemente do país de origem.***

Recentemente, o valor de mercado das empresas ao redor do mundo foi afetado por duas crises: Pandemia de Covid-19 e Invasão russa à Ucrânia. Em relação à pandemia, cuja rápida expansão mundial ocorreu no primeiro semestre de 2020, muitas empresas interromperam suas atividades, tendo diminuído a produção e o atendimento das demandas do mercado, com governos ajustando políticas para ajudar a população e as empresas (MULYANINGSIH *et al.*, 2021). Estudos como os de Kaczmarek *et al.* (2021) e Ichsan *et al.* (2021) evidenciaram efeitos diversos negativos da pandemia de Covid-19 sobre o desempenho e o valor de empresas ao redor do mundo, com alguns setores mais impactados que outros. Ademais, os referidos estudos também evidenciaram que algumas companhias conseguiram um desempenho superior às demais durante a pandemia, a partir de características prévias refletidas em variáveis contábeis.

No que tange à invasão russa à Ucrânia, em fevereiro de 2022, ela gerou uma crise que afetou de forma significativa as empresas ao redor do mundo. Bougias *et al.* (2022) destacam que empresas que tiveram maior exposição à Rússia experimentaram retornos de ativos e ações mais baixos no início da guerra e níveis altos de risco de crédito. Assim, houve um impacto estatisticamente significativo nos retornos de ações e dívidas, assim como na probabilidade de inadimplência. Já Abbassi *et al.* (2023) verificaram que o país e o setor de atuação das empresas, assim como outras variáveis contábeis, também foram relevantes para explicar o comportamento do valor corporativo durante a invasão. Nesse sentido, foi proposta a Hipótese 2 (H2):

**H2:** *As variáveis determinantes de valor são significantes para explicar o MVA® das empresas, mesmo em períodos de crise (pandemia de Covid-19 e a invasão da Rússia à Ucrânia).*

Salienta-se que, diante da importância do valor das empresas para os agentes econômicos, ao longo dos últimos anos, uma grande quantidade de estudos tem empregado o potencial dos algoritmos de inteligência artificial para fins de predição do mesmo, evidenciando desempenhos acima da média, como indicado em Cao *et al.* (2019), Qian e Rasheed (2007) e Shynkevich *et al.* (2017). Dois algoritmos podem ser destacados para a previsão do valor de empresas, conforme Avelar *et al.* (2022): redes neurais artificiais e *random forest*.

As redes neurais artificiais são inspiradas no funcionamento do cérebro humano, em que diversos valores são atribuídos a uma função e cada um dos receptores os processa, gerando informações, que são ponderadas e dadas como saída. Essa rede de neurônios pode se encontrar distribuída entre uma ou mais camadas diferentes (FACELI *et al.*, 2023). As redes neurais artificiais têm como importante característica a capacidade de aprender por meio de exemplos representados sob a forma de parâmetros, que são ajustados de acordo com um processo que envolve a interatividade entre o ambiente externo e a regulação do aprendizado (BRAGA *et al.*, 2016).

O algoritmo de *random forest*, por sua vez, representa uma união de diversas árvores de decisões, que tratam de dados não paramétricos por meio de um treinamento supervisionado, utilizando-se de variáveis explanatórias a fim de traçar uma variável-alvo que explique a construção do modelo (SADORSKY; PERY, 2021). Esse algoritmo utiliza uma base de dados já existente, criando diversas árvores diferentes, que buscam achar uma média entre os resultados encontrados. Uma das principais características de aprendizagem do *random forest* consiste em sua habilidade de descartar certos fatores de previsão, excluindo essas possibilidades e racionalizando a capacidade utilizada (JAMES *et al.*, 2013). Assim, desenvolveu-se a Hipótese 3 (H3):

**H3:** *O desempenho dos algoritmos de inteligência artificial para previsão do MVA® é superior ao de técnicas estatísticas tradicionais.*

Apesar da importância de algoritmos de inteligência artificial para a previsão do valor corporativo, apenas recentemente eles têm sido aplicados em estudos desse fenômeno,

conforme evidenciam Avelar *et al.* (2022). Segundo os autores, em países emergentes, tais aplicações são ainda mais recentes. Dentre tais países, um grupo tem se destacado no século XXI: os BRICS.

A primeira referência aos BRICS, feita por Jim O'Neill, chefe de pesquisa em economia global pelo Goldman Sachs, foi em novembro de 2001 e ainda não levava a África do Sul em seu nome, no artigo nomeado “Building better Global Economics BRICs” (O'NEILL, 2006). Ao longo do século XXI, o grupo dos BRICS está, aos poucos, ganhando protagonismo na economia mundial. Atualmente, a soma do produto interno bruto desse bloco é maior do que a do G7, totalizando US\$ 24,73 trilhões (INFOBRICS, 2023). Além de sua importância econômica, os BRICS têm se organizado com instituições próprias, tal como o seu Novo Banco de Desenvolvimento.

Outro ponto de destaque é que os BRICS apresentaram uma ação conjunta no cenário político internacional, exemplo disso foi visto no caso da invasão da Rússia à Ucrânia. Segundo dados fornecidos pelo Observatório de Política Externa e da Inserção Internacional do Brasil (2022), eles vêm participando de uma série de votações em órgãos internacionais, como a ONU, sobre a invasão russa, mostrando uma ação relativamente alinhada de não condenar de maneira severa o membro do grupo envolvido na guerra.

### 3 METODOLOGIA

A pesquisa apresentada neste artigo teve caráter descritivo, correlacional e quantitativo, conforme a classificação de Sampieri, Collado, e Lucio, (2006). O foco foram as empresas de capital aberto dos países que compõem os BRICS. Os dados secundários foram retirados da plataforma Refinitiv® Eikon entre os anos de 2019 e 2022. Foram coletados dados desse período, para englobar: o último ano pré-crise (2019), o ano da eclosão da pandemia Covid-19 (2020), o ano entre crises (2021) e o ano da invasão da Ucrânia pela Rússia (2022). Para a seleção da amostra de empresas de cada país, foram considerados apenas aquelas que apresentaram MVA® positivo em todos os anos, de maneira consistente, de forma a compreender melhor os direcionadores de valor.

Foram levantados dados que possibilitaram calcular as variáveis clássicas usadas como direcionadores de valor já citadas na seção anterior: endividamento, rentabilidade, risco e tamanho. A operacionalização dessas variáveis empregadas é apresentada na Tabela 1. Salienta-se que as equações escolhidas para operacionalização das variáveis foram

selecionadas com base na literatura de forma a minimizar o número de dados ausentes que influenciassem a estimação dos modelos.

**Tabela 1 – Operacionalização das variáveis**

Variável	Operacionalização	Sinal esperado
MVA®	$\ln(\text{Valor de Mercado} - \text{Patrimônio Líquido})$	Não se aplica
Endividamento	$(\text{Passivo Exigível} - \text{Patrimônio Líquido}) \div \text{Ativo Total}$	–
Rentabilidade	$\text{EBIT} \div \text{Ativo Total}$	+
Risco	$\text{Cov}(\text{Retorno}_{\text{Ativo}}, \text{Retorno}_{\text{mercado}}) \div \text{Var}(\text{Retorno}_{\text{mercado}})$	–
tamanho	$\ln(\text{Ativo Total})$	+

Fonte: Elaborado pelos autores

Inicialmente, foram estimadas regressões lineares, de acordo com Hair Jr. *et al.* (2009), para cada país, anualmente, conforme a Equação 1, na qual o termo  $t$  indica o ano e o  $\varepsilon$  representa o erro. Para análise das regressões estimadas, foram aplicados os seguintes testes recomendados por Gujarati e Porter (2011): Breusch-Pagan-Godfrey, Durbin-Watson e Shapiro Wilk. Nos casos de heteroscedasticidade, os coeficientes foram estimados com base nos erros-padrão robustos de White, conforme sugerido por Gujarati e Porter (2011). Salienta-se que, no caso de problemas de normalidade, o número de observações empregado possibilita a suposição de normalidade assintótica, segundo os mesmos autores.

$$MVA_t = \beta_0 + \beta_1 \times TAM_t + \beta_2 \times END_t + \beta_3 \times LUC_t + \beta_4 \times RIS_t + \varepsilon \quad (1)$$

Todos os algoritmos de inteligência artificial foram executados para fins de regressão, com o propósito de prever o MVA® das empresas, empregando as mesmas variáveis apresentadas na Tabela 1. Para o treinamento dos modelos, foram usados 80% dos dados da amostra, anualmente. Para estimar o desempenho desses modelos, optou-se pelo cálculo do *mean absolute percentage error* (Equação 2) e do *root mean squared error* (Equação 3), ambas medidas necessárias para avaliar o erro de modelos de inteligência artificial para fins de regressão (Faceli *et al.*, 2023), calculados a partir dos dados de teste (20% remanescente da amostra).

$$\text{Mean absolute percentage error} = \frac{1}{n} \sum_{i=1}^n (| \text{valor\_real} | - | \text{valor\_predito} |) \quad (2)$$

$$\text{Root mean squared error} = \frac{1}{n} \sqrt{\sum_{i=1}^n (| \text{valor\_real} | - | \text{valor\_predito} |)^2} \quad (3)$$

Alguns parâmetros específicos foram ajustados para os algoritmos. No caso do *random forest*, foi dada a possibilidade de o próprio algoritmo selecionar o número de árvores (entre 1 e 50) que aprimorasse o desempenho. Por sua vez, no caso das redes neurais artificiais, foi usada uma abordagem empírica para definir a melhor arquitetura da rede (número de camadas ocultas e de neurônios por camada), que otimizasse o desempenho. Considerou-se o uso de até duas camadas ocultas, de forma a possibilitar o aprendizado profundo, tal como evidenciado por Faceli *et al.* (2023), com até quatro neurônios por camada. Em ambos os casos, foi calculado um modelo para cada país anualmente.

Além da análise de regressão múltipla para o modelo estimado com base na Equação 1, os resultados do estudo foram analisados com base nas técnicas de estatística descritiva e teste de Mann-Whitney. A primeira foi empregada para descrever os resultados obtidos pelos modelos estimados. Por sua vez, o teste de Mann-Whitney foi usado para verificar a existência de diferenças estatisticamente significantes entre os desempenhos dos algoritmos de inteligência artificial e entre esses desempenhos e o da regressão múltipla. O nível de significância adotada nesses testes foi de 5%. Todos os dados foram tratados e analisados a partir do MS-Excel e do R, utilizando os seguintes pacotes: *A Grammar of Data Manipulation* (dplyr); *Breiman and Cutler's Random Forests for Classification and Regression* (Random Forest); *Evaluation Metrics for Machine Learning* (Metrics); *Misc Functions of the Department of Statistics, Probability Theory Group* (e1071); *Read Excel Files* (readxl); e *Training of Neural Networks* (neuralnet).

## 4 RESULTADOS

### 4.1 Modelos de Regressão

Nesta subseção, apresentam-se os resultados dos modelos de regressão múltipla estimados de forma a identificar as variáveis determinantes para a criação de valor corporativo das empresas ao longo do período analisado, assim como para verificar se essas variáveis determinantes se mantêm relevantes para explicar esse valor mesmo em períodos de crise. É importante destacar que, devido às poucas observações selecionadas com base nos parâmetros apresentados na seção anterior, as empresas russas foram excluídas das análises.

A Tabela 2 apresenta os resultados obtidos em todos os modelos por país, anualmente. Ademais, o alto valor do coeficiente de determinação ( $R^2$  ajustado), cuja média foi de 68,7%, indica que os modelos estimados conseguiram explicar a maior parte da variabilidade do valor das empresas medido pelo MVA®. Ademais, todos os modelos foram significantes conforme o teste F. A consistência dessas variáveis para explicar o fenômeno estão em linha com os estudos de Aguiar *et al.* (2011), Altaf (2016), Hall (2018) e Santos *et al.* (2021). Esses resultados ratificam a capacidade explicativa das variáveis selecionadas sobre o fenômeno, corroborando-se H1.

Ao se analisar os resultados das tabelas, destaca-se que a variável tamanho foi significativa em todos os modelos, para todos os anos. Além disso, o coeficiente positivo em todos os modelos estimados reforça a consistência dessa variável em explicar o valor das empresas, realçando o exposto por Mishra e Mohanty (2014). Dessa forma, tem-se que empresas com maior porte tenderam a manter um MVA® positivo de forma mais consistente do que aquelas de menor porte.

Por sua vez, a variável rentabilidade se apresentou significativa em alguns anos para as empresas de três países. Nesses anos, seu coeficiente positivo indicou sua importância na criação de valor. Salienta-se que o único país em que essa variável não foi significativa em nenhum modelo foi a Índia. O coeficiente positivo demonstra sua contribuição ao MVA® das empresas, ratificando o exposto por Zeghal e Maaloul (2010), Besanko *et al.* (2012) e Mishra e Mohanty (2014).

Já no que se refere à variável endividamento, seu coeficiente foi significativo para as empresas de dois países, Brasil e China, durante os períodos de crise, mas com sinais distintos. Essa divergência de sinais está em linha com o exposto por Ross *et al.* (2015). No caso brasileiro, essa variável foi significativa e com sinal negativo no ano de 2022, indicando que o endividamento contribuiu para a destruição de valor no referido período. Já no caso chinês, o nível de endividamento contribuiu para aumentar o valor agregado pelo mercado de forma consistente entre 2020 e 2022, ou seja, após a eclosão das crises.

Por fim, no que se refere à variável risco, verificam-se coeficientes significantes e positivos em todos os anos para as empresas da China, o que demonstra a contribuição consistente dessa variável para a criação de valor corporativo. Em geral, observa-se a relevância das variáveis para explicar o MVA® das empresas dos BRICS. Todas as variáveis contábeis selecionadas foram significantes em pelo menos um modelo, ratificando sua importância para previsão de valor corporativo mesmo em períodos de crise. Dessa forma, corrobora-se H2.

**Tabela 2 – Modelos estimados para os países analisados**

<b>País</b>	<b>África do Sul</b>				<b>Brasil</b>			
<b>Ano</b>	<b>2019</b>	<b>2020</b>	<b>2021</b>	<b>2022</b>	<b>2019</b>	<b>2020</b>	<b>2021</b>	<b>2022</b>
Intercepto	-0,32	4,29	8,72**	3,62	2,78	3,1	3,25*	3,21
Rentabilidade	4,09	8,17*	2,14	7,31**	1,9	1,22	0,72	3,06*
Tamanho	0,95***	0,71***	0,65***	0,81***	0,85***	0,81***	0,84***	0,85***
Endividamento	-1,16	-0,52	-3,41	-1,64	-0,31	0,69	-0,79	-2,04 *
Risco	1,11	-0,28	-0,17	-0,52	0,05	-0,08	-0,33	-0,61
R2 ajustado	0,9	0,74	0,67	0,88	0,52	0,54	0,61	0,48
Teste F	25,17***	8,76***	6,67***	22,09***	22,57***	23,84***	31,66***	19,18***
Breusch Pagan	1,68	7,44	5,77	8,45*	3,55	0,66	0,54	2,99
Durbin Watson	1,87	1,20*	1,42	1,67	1,89	1,97	1,48***	1,92
ShapiroWilk	0,90	0,94	0,96	0,97	0,94***	0,98	0,97	0,92***

<b>País</b>	<b>China</b>				<b>Índia</b>			
<b>Ano</b>	<b>2019</b>	<b>2020</b>	<b>2021</b>	<b>2022</b>	<b>2019</b>	<b>2020</b>	<b>2021</b>	<b>2022</b>
Intercepto	3,44***	2,36***	2,74***	1,48*	5,68	2,42	2,98	1,7
Rentabilidade	1,77*	1,69	3,63**	4,19***	9,61	7,83	7,84	2,44
Tamanho	0,75***	0,79***	0,76***	0,74***	0,76***	0,85***	0,77**	1,03***
Endividamento	0,9	1,22*	1,52**	2,63***	-2,36	0,36	1,74	-1,15
Risco	0,44***	0,59***	0,54***	0,73***	1,1	0,41	0,45	-0,3
R2 ajustado	0,59	0,58	0,6	0,64	0,8	0,79	0,74	0,91
Teste F	251,36	248,24	269,5	307,74	7,82	7,49	5,94	18,6
Breusch Pagan	17,57***	45,00***	32,29***	30,93***	5,63	6,54	5,36	6,83
Durbin Watson	2,06	2,1	2	1,91	2,01	2,24	1,93	2,64
Shapiro Wilk	0,97***	0,99***	0,99***	0,95***	0,95	0,95	0,93	0,98

Fonte: Elaborado pelos autores

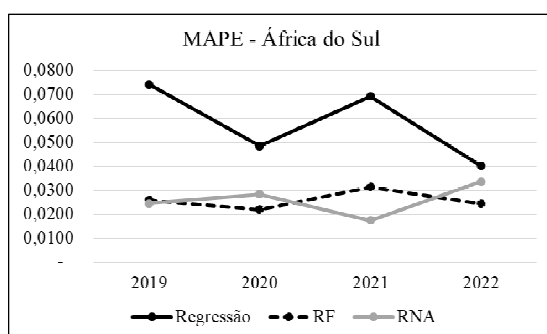
Notas: \* Significante a menos de 10,0%; \*\* Significante a menos de 5,0%; e \*\*\* Significante a menos de 1,0%.

## 4.2 Desempenho de previsão dos modelos

Com base nos parâmetros apresentados na Metodologia deste trabalho, foram realizadas previsões do MVA® das empresas de cada país usando os diferentes modelos obtidos a partir da regressão linear e dos algoritmos de inteligência artificial *random forest* e redes neurais artificiais. As figuras 2 e 3 apresentam, respectivamente, as métricas de desempenho *mean absolute percentage error* e *root mean squared error* para cada país, por ano. É importante evidenciar que, como são medidas de erro, os valores mais baixos indicam um melhor desempenho dos modelos.

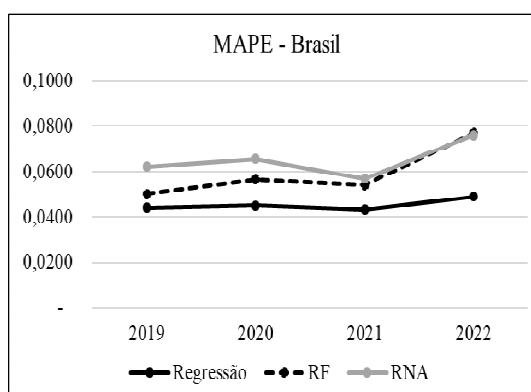
No caso da África do Sul (figuras 1a e 2a), observou-se que os modelos de inteligência artificial apresentaram desempenhos superiores aos da regressão. Salienta-se que o desempenho da regressão apresentou uma tendência de melhora nas previsões ao longo do tempo. Já no caso do Brasil (figuras 1b e 2b), os modelos de regressão apresentaram o melhor desempenho preditivo.

Figura 1a: *Mean absolute percentage error* dos modelos da África do Sul



Fonte: Elaborado pelos autores

Figura 1b : Means absolute porcentage error dos modelos do Brasil

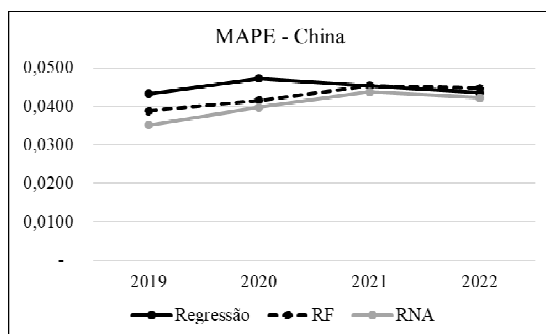


Fonte: Elaborado pelos autores

Figura 1c: *Mean absolute percentage error* dos

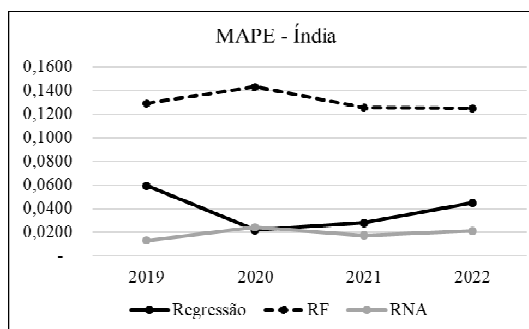
Figura 1d: *Mean absolute percentage error* dos

## modelos da China

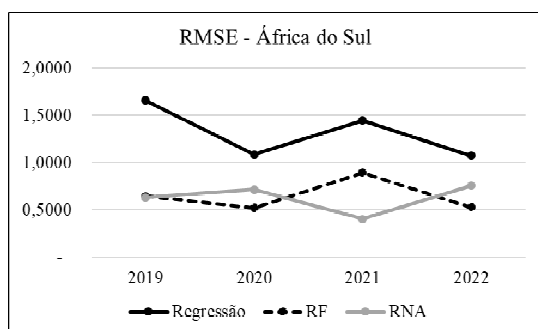


Fonte: Elaborado pelos autores

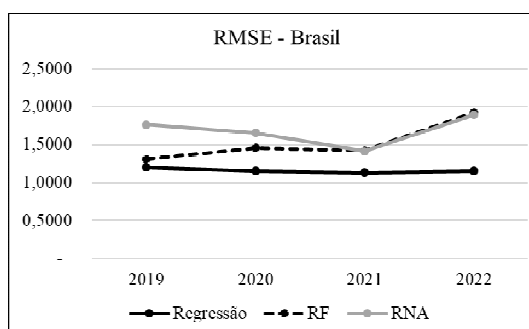
## modelos da Índia



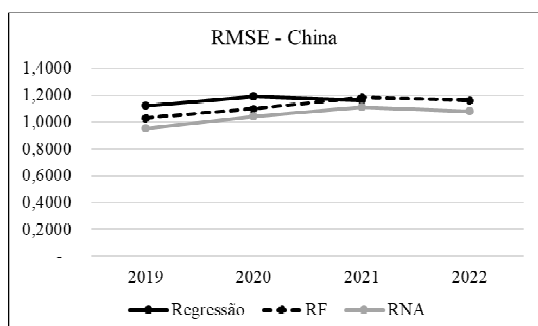
Fonte: Elaborado pelos autores

Figura 2a: *Root mean squared error* dos modelos da África do Sul

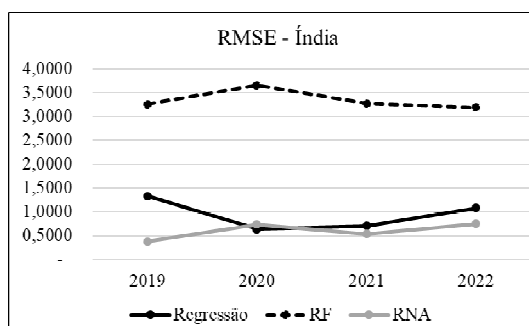
Fonte: Elaborado pelos autores

Figura 2b: *Root mean squared error* dos modelos do Brasil

Fonte: Elaborado pelos autores

Figura 2c: *Root mean squared error* dos modelos da China

Fonte: Elaborado pelos autores

Figura 2d: *Root mean squared error* dos modelos da Índia

Fonte: Elaborado pelos autores

Os modelos estimados para a China (figuras 2c e 3c), por sua vez, indicaram uma superioridade no desempenho dos modelos baseados em algoritmos de inteligência artificial nos primeiros anos. Além disso, observou-se uma convergência no nível de previsão da regressão ao longo do tempo. Por fim, os algoritmos baseados em redes neurais artificiais e a regressão superaram o desempenho preditivo do algoritmo de *random forest* no caso indiano (figuras 2d e 3d).

Apesar de descritivamente apresentarem desempenhos discrepantes, foi necessário empregar o teste de Mann-Whitney para avaliar se as diferenças são realmente significantes estatisticamente. Os resultados do teste para ambas as métricas indicaram desempenho estatisticamente iguais entre o modelo de regressão e os modelos baseados no algoritmo de *random forest*. Porém, o mesmo teste indicou que o desempenho das redes neurais artificiais foi estatisticamente superior ao dos modelos de regressão. Tais resultados corroboram parcialmente aqueles apresentados, achados, reportados por estudos como os de Qian e Rasheed (2007), Shynkevich *et al.* (2017) e Cao *et al.* (2019). Desse modo, H3 é ratificada de forma parcial.

Por fim, é importante destacar que a pesquisa desenvolvida apresentou algumas limitações, quais sejam: (a) os critérios adotados para a seleção da amostra implicaram a exclusão das empresas russas; (b) as crises da pandemia de Covid-19 e da invasão russa à Ucrânia ainda geram efeitos econômicos, não sendo totalmente considerados; (c) empregaram-se dados transversais para análise, devido às limitações inerentes aos algoritmos de inteligência artificial utilizados; e (d) apesar de amplamente empregado, o MVA® é apenas uma das medidas de criação de valor corporativo, sendo limitada por definição.

## 5 CONCLUSÕES

Constatou-se que as variáveis contábeis empregadas como direcionadores de valor foram significantes e consistentes em explicar o MVA® positivo das empresas dos BRICS, mesmo em períodos de crise: a da pandemia de Covid-19 e a da invasão russa à Ucrânia. Tal achado ratifica a robustez dessas variáveis em explicar a criação de valor nas empresas de diferentes países, em contextos diversos.

Verificou-se a aplicabilidade dos algoritmos de inteligência artificial *random forest* e redes neurais artificiais para a previsão de valor de empresas dos países integrantes do BRICS. O desempenho dos algoritmos variou entre os países, porém, de forma geral, foi no mínimo similar à capacidade de previsão dos modelos de regressão tradicionais, os quais

apresentaram altos valores de  $R^2$ . Estatisticamente, os algoritmos de *random forest* apresentaram um desempenho similar ao dos modelos de regressão estatística, enquanto os modelos de redes neurais artificiais apresentaram desempenho superior a esses modelos estatísticos. Tal resultado evidencia a capacidade desse tipo de algoritmo em lidar com problemas complexos, como a criação de valor corporativo, podendo apresentar resultados superiores aos de outras técnicas.

Os resultados do estudo contribuem de forma relevante para o tema da criação de valor corporativo sob diferentes perspectivas. Primeiramente, analisaram-se empresas de países emergentes, que têm um papel político e econômico cada vez mais relevante no contexto global. Ademais, avaliou-se o desempenho de modelos para previsão de valor em períodos distintos, com diferentes crises econômicas globais. Além disso, empregaram-se diferentes algoritmos de inteligência artificial para fins de previsão, tecnologia cada vez mais usada pelos gestores, acadêmicos e pela sociedade de forma geral. Demonstrou-se a heterogeneidade de desempenho dos diferentes modelos, considerando os distintos contextos institucionais dos países e os momentos econômicos globais. Por fim, destacou-se a relevância do emprego de modelos baseados em algoritmos de inteligência artificial, assim como aqueles baseados em técnicas estatísticas tradicionais, para a análise do fenômeno da criação de valor corporativo.

Os resultados obtidos trazem implicações práticas a diversos agentes do mercado. Primeiramente, fornece a investidores e analistas subsídios para a análise de variáveis direcionadoras de valor, mesmo em períodos de crises (Pandemia de Covid-19 e invasão russa à Ucrânia). Ademais, enfocam-se empresas de países emergentes, mercados com grande potencial de retorno e usualmente menos abordados pela literatura. Além disso, demonstra a capacidade de algoritmos de inteligência artificial no mercado financeiro. Sob a perspectiva dos gestores, os resultados podem auxiliá-los a focar suas ações de forma a aprimorar as principais variáveis determinantes da criação de valor corporativo, mesmo em tempo de crises, considerando a heterogeneidade dos países estudados.

Por fim, sugere-se que pesquisas futuras considerem outras *proxies* de valor corporativo, como o Q de Tobin e o indicador *market-to-book*. Sugere-se ainda que sejam empregados algoritmos de inteligência artificial que possibilitem a análise longitudinal dos dados, tal como as redes neurais artificiais *long short-term memory*. Por fim, a ampliação da amostra para outros países emergentes, assim como desenvolvidos, possibilitaria uma comparação ainda mais robusta dos resultados obtidos.

## REFERÊNCIAS

ABBASSI, W.; KUMARI, V.; PANDEY, D. K. What makes firms vulnerable to the Russia–Ukraine crisis? **The Journal of Risk Finance**, v. 24, n. 1, p. 24-39, 2022. Disponível em: <https://doi.org/10.1108/JRF-05-2022-0108>.

AGUIAR, A. B. D *et al.* Análise dos direcionadores de valor em empresas brasileiras. **RAM. Revista de Administração Mackenzie**, v. 12, p. 90-112, 2011. Disponível em: <https://doi.org/10.1590/S1678-69712011000200005>. Acesso em: 6 jan. 2025.

ALTAF, N. Economic value added or earnings: What explains market value in Indian firms? **Future Business Journal**, v. 2, n. 2, p. 152-166, 2016. Disponível em: <https://doi.org/10.1016/j.fbj.2016.11.001>.

AVELAR, E. A *et al.* Inteligência artificial e previsão de preços de ativos financeiros: uma revisão sistemática. **Sistemas & Gestão**, v. 17, n. 3, 2022. Disponível em: <https://doi.org/10.20985/1980-5160.2022.v17n3.1807>.

BESANKO, D *et al.* **A economia da estratégia**. 5. ed. Porto Alegre: Bookman Editora, 2012.

BOUGIAS, A.; EPISCOPOS, A.; LELEDAKIS, G. N. Valuation of European firms during the Russia–Ukraine war. **Economics Letters**, v. 218, 2022. Disponível em: <https://doi.org/10.1016/j.econlet.2022.110750>.

BRAGA, A. P.; FERREIRA, A. C. P. L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC Editora, 2007.

CAO, H.; LIN, T.; LI, Y.; ZHANG, H. Stock price pattern prediction based on complex network and machine learning. **Complexity**, 2019. Disponível em: <https://doi.org/10.1155/2019/4132485>.

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**, v. 32, n. 1, p. 602-623, 2023. Disponível em: <https://doi.org/10.1002/bse.3163>.

FACELI, K *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. 2. ed. Rio de Janeiro: LTC, 2023.

FAITEH, A.; AASRI, M. R. Economic value added: The best indicator for measuring value creation or just an illusion. **Investment Management and Financial Innovations**, v. 20, n. 1, p. 138-150, 2023. Disponível em: [http://dx.doi.org/10.21511/imfi.20\(1\).2023.13](http://dx.doi.org/10.21511/imfi.20(1).2023.13).

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5. ed. Porto Alegre: Amgh Editora, 2011.

HAIR, J. F *et al.* **Análise multivariada de dados**. Porto Alegre: Bookman Editora, 2009. Disponível em: <https://doi.org/10.1108/JRF-05-2022-0108>.

HALL, J. H. Value creation measures: an industry-based study. **International Journal of Productivity and Performance Management**, v. 67, n. 2, p. 426-444, 2018. Disponível em: <https://doi.org/10.1108/IJPPM-08-2016-0178>.

ICHASAN, R. N *et al.* Determinant of Sharia Bank's Financial Performance during the Covid-19 Pandemic. **Budapest International Research and Critics Institute-Journal**, v. 4, n. 1, p. 298-309, 2021. Disponível em: <https://doi.org/10.33258/birci.v4i1.1594>.

INFOBRICS. Led by China, India, the 5 BRICS Nations now Contribute More to World GDP than G7. **Brics Information Portal**, 2023. Disponível em: <http://infobrics.org/post/38158>.

JAMES, G *et al.* **An introduction to statistical learning**. New York: Springer, 2013. Disponível em: <https://doi.org/10.1007/978-1-0716-1418-1>.

KACZMAREK, T *et al.* How to survive a pandemic: The corporate resiliency of travel and leisure companies to the COVID-19 outbreak. **Tourism Management**, v. 84, p. 104281, 2021. Disponível em: <https://doi.org/10.1016/j.tourman.2020.104281>.

MULYANINGSIH, T.; CAHYANDIN, M.; SARMIDI, T. Firms' Financial Distress during the COVID-19 Pandemic and Fiscal Incentives. **Economic Research Institute for ASEAN and East Asia**, v. 7, p. 7, 2021.

MARKOWITZ, H. Portfolio selection. **The Journal of Finance**, v. 7, n. 1, p. 77-91, 1952.  
MISHRA, S.; MOHANTY, P. Corporate governance as a value driver for firm performance: evidence from India. **Corporate Governance**, v. 14, n. 2, p. 265-280, 2014. Disponível em: <https://doi.org/10.1108/CG-12-2012-0089>.

MODIGLIANI, F.; MILLER, M. H. The cost of capital, corporation finance and the theory of investment. **The American Economic Review**, v. 48, n. 3, p. 261-297, 1958. Disponível em: <https://www.jstor.org/stable/1809766>.

OBSERVATÓRIO DE POLÍTICA EXTERNA E DA INSERÇÃO INTERNACIONAL DO BRASIL. Brics Recuperam protagonismo com a guerra na Ucrânia. Disponível em: <https://opeb.org/2022/05/02/brics-recuperam-protagonismo-com-a-guerra-na-ucrania>.

O'NEILL, J. Building better global economic BRICs. New York: Goldman Sachs, 2001.  
PETRAVIČIUS, T.; TAMOŠIŪNIENE, R. Corporate performance and the measures of value added. **Transport**, v. 23, n. 3, p. 194-201, 2008. Disponível em: <https://doi.org/10.3846/1648-4142.2008.23.194-201>.

QIAN, B.; RASHEED, K. Stock market prediction with multiple classifiers. **Applied Intelligence**, v. 26, p. 25-33, 2007. Disponível em: <https://doi.org/10.1007/s10489-006-0001-7>.

ROSS, S. A *et al.* **Administração financeira**. Porto Alegre: AMGH Editora, 2015.

SADORSKY, P. A random forests approach to predicting clean energy stock prices. **Journal of Risk and Financial Management**, v. 14, n. 2, p. 48, 2021. Disponível em: <https://doi.org/10.3390/jrfm14020048>.

SAMPIERI, R. H.; COLLADO, C. F.; LUCIO, P. B. **Metodologia de pesquisa**. São Paulo: McGraw Hill, 2006.

SANTOS, D. F. L. *et al.* Influência do risco financeiro na criação de valor na indústria alimentícia de empresas listadas na B3. **Revista Evidenciação Contábil & Finanças**, v. 9, n. 1, 2021.

SAREEWIWATTHANA, P.; WANIDWARANAN, P. Alternative analyses of market value added: a case study of Thailand. **Investment Management and Financial Innovations**, v. 16, n. 1, p. 65-78, 2019. Disponível em: [https://doi.org/10.21511/imfi.16\(1\).2019.05](https://doi.org/10.21511/imfi.16(1).2019.05).

SHYNKEVICH, Y *et al.* Forecasting price movements using technical indicators: Investigating the impact of varying input window length. **Neurocomputing**, v. 264, p. 71-88, 2017. Disponível em: <https://doi.org/10.1016/j.neucom.2016.11.095>.

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**, v. 35, p. 100723, 2022. Disponível em: <https://doi.org/10.1016/j.jbef.2022.100723>.

ZEGHAL, D.; MAALLOUL, A. Analysing value added as an indicator of intellectual capital and its consequences on company performance. **Journal of Intellectual Capital**, v. 11, n. 1, p. 39-60, 2010. Disponível em: <https://doi.org/10.1108/14691931011013325>.

AGRADECIMENTOS: Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo apoio na realização da pesquisa.

**Como Referenciar este Artigo, conforme ABNT:**

AVELAR, E. A; TARASTCHUK, A. V; SOARES, R. O. M; SOUZA, A. A. Previsão do Valor Corporativo com uso de Algoritmos de Inteligência Artificial. **Rev. FSA**, Teresina, v. 22, n. 5, art. 1, p. 3-21, mai. 2025.

Contribuição dos Autores	E. A. Avelar	A. V. Tarastchuk	R. O. M. Soares	A. A. Souza
1) concepção e planejamento.	X	X		
2) análise e interpretação dos dados.	X	X		
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X	X	X
4) participação na aprovação da versão final do manuscrito.	X		X	X