5º CONGRESSO UFU DE CONTABILIDADE
19 e 20 de outubro de 2023
Uberlândia-MG

PREVISÃO DO MARKET VALUE ADDED (MVA®): EMPREGO DE INTELIGÊNCIA ARTIFICIAL EM EMPRESAS DOS BRICS

Ewerton Alex Avelar (UFMG) - ewertonaavelar@gmail.com

André André Tarastcuk (UFMG) - vidalandre@outlook.com

Regiane Oliveira de Moraes Soares (UFMG) - regianebh1@gmail.com

Antônio Artur de Souza (ufmg) - artur@face.ufmg.br

Resumo:

O estudo apresentado visou avaliar o desempenho de algoritmos de inteligência artificial (IA) 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. Foram selecionadas empresas de capital aberto desses países que apresentaram MVA® positivo ao longo de todo o período. Seus dados foram empregados para treinar algoritmos de IA – especificamente, random forest (RF) e redes neurais artificiais (RNA) –, assim como modelos de regressão linear múltipla, para fins de previsão a partir de direcionadores de valor clássicos da literatura. Os resultados indicaram que tais direcionadores foram significantes e consistentes em explicar o MVA® positivo das empresas estudadas, mesmo em períodos de crise. No que se refere ao emprego de algoritmos de IA para previsão do valor agregado, verifica-se a aplicabilidade do RF e da RNA para essa atividade. Estatisticamente, os modelos baseados no algoritmo de RF tiveram um desempenho similar àqueles de regressão, enquanto os modelos de RNA apresentaram desempenho superior a ambos. 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 modelos de IA, assim, como os de estatística tradicionais para análise do fenômeno.

Palavras-chave: *Market Value Added (MVA®); Algoritmos de inteligência artificial (IA); BRICS.*

Área temática: *Mercado Financeiro, de Crédito e de Capitais*

PREVISÃO DO *MARKET VALUE ADDED* (MVA®): EMPREGO DE INTELIGÊNCIA ARTIFICIAL EM EMPRESAS DOS BRICS

Resumo
O estudo apresentado visou avaliar o desempenho de algoritmos de inteligência artificial (IA) 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. Foram selecionadas empresas de capital aberto desses países que apresentaram MVA® positivo ao longo de todo o período. Seus dados foram empregados para treinar algoritmos de IA – especificamente, *random forest* (RF) e redes neurais artificiais (RNA) –, assim como modelos de regressão linear múltipla, para fins de previsão a partir de direcionadores de valor clássicos da literatura. Os resultados indicaram que tais direcionadores foram significantes e consistentes em explicar o MVA® positivo das empresas estudadas, mesmo em períodos de crise. No que se refere ao emprego de algoritmos de IA para previsão do valor agregado, verifica-se a aplicabilidade do RF e da RNA para essa atividade. Estatisticamente, os modelos baseados no algoritmo de RF tiveram um desempenho similar àqueles de regressão, enquanto os modelos de RNA apresentaram desempenho superior a ambos. 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 modelos de IA, assim, como os de estatística tradicionais para análise do fenômeno.

Palavras-chave: *Market Value Added* (MVA®); Algoritmos de inteligência artificial (IA); BRICS.

Área temática do evento: Mercados Financeiro, de Crédito e de Capitais.

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

1 INTRODUÇÃO

A criação de valor das empresas é um dos principais temas abordado em finanças. 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. Nesse sentido, os mesmos autores afirmam que o atual ambiente competitivo tende a levá-las a aprimorar seu desempenho a partir da criação de valor. Devido à importância da geração de valor para as empresas e para os agentes de mercado, estudos vêm empregando técnicas estatísticas mais sofisticadas e outras relacionadas à inteligência artificial (IA) para buscar melhores previsões de tais valores tomando como base os preços das ações na bolsa de valores, como explanam Shynkevich *et al.* (2017) e Cao *et al.* (2019).

Hall (2018) afirma que existem diversas métricas para avaliar o valor de uma empresa, dentre as quais pode-se destacar o valor agregado pelo mercado (*market value added* – MVA®). Esta 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 esses mesmos autores, bem como segundo Sareewiwatthana

e Wanidwaranan (2019), o MVA® reflete 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 por variáveis endógenas e 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 da Rússia à Ucrânia (CARDILLO; BENDINELLI; TORLUCCIO, 2023; ABBASSI *et al.*, 2023). Estudos como os de Kaczmarek *et al.* (2021), Yousaf, Patel e Yarovaya (2022) e Abbassi *et al.* (2023) 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 períodos de crise.

Destaca-se que ambas as crises envolveram dois países emergentes em seu início 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 na geopolítica mundial (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 do exposto, o estudo apresentado neste artigo visou avaliar o desempenho de algoritmos de IA para previsão do MVA® em empresas de países do BRICS, tomando como base dados relativos ao período entre 2019 e 2022. Como objetivos específicos, foram desenvolvidos: (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 IA e de modelos tradicionais; e (iii) discutir os resultados sob a perspectiva da literatura de finanças.

O estudo desenvolvido se justifica sob diversas perspectivas. Primeiramente, tem-se o papel central da criação de valor para os proprietários e os *stakeholders* das empresas, que é usualmente considerado um objetivo explícito e primário da gestão (DAMODARAN, 2004; FAITEH; AASRI, 2023). Ademais, o estudo se baseou em uma medida amplamente empregada para mensuração do valor agregado pelas empresas tanto por profissionais no mercado quanto na Academia, o MVA® (HALL, 2018), possibilitando a comparação com outros estudos e casos. Além disso, a pesquisa considerou um período que engloba duas grandes crises contemporâneas, a pandemia de Covid-19 e a invasão russa à Ucrânia, que afetaram o mercado financeiro em todo o mundo e cujos estudos ainda são bastante recentes (KACZMAREK *et al.*, 2021; ABBASSI *et al.*, 2023). Ressalta-se, ainda, o foco do estudo em um grupo específico de países emergentes, os BRICS, do qual dois membros estavam no epicentro (pelo menos inicialmente) de ambas as crises citadas, assim como esse grupo tem cada vez mais influência na política e na economia global (OUR WORLD IN DATA, 2023; INFOBRICS, 2023). Por fim, evidencia-se o emprego de algoritmos de IA para estudo do tema, tecnologia cada vez mais relevante e empregada nas práticas e nas pesquisas em Contabilidade e Finanças (RUNDO *et al.*, 2019; CAO *et al.*, 2019; MOLL; YIGITBASIOGLU, 2019).

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Criação de Valor Corporativo

Santos *et al* (2021, p. 116) afirmam que a "criação de valor é o objeto principal da gestão financeira de uma empresa". Uma linha de pensamento para a mensuração de tal valor de

companhias abertas é aquela baseada no preço de suas ações a partir da sua negociação no mercado de capitais. Damodaran (2004) apresenta alguns benefícios da utilização dos preços das ações como medida de valor: (a) o preço das ações é uma medida observável; (b) em um mercado com investidores racionais, esse preço reflete os efeitos a longo prazo das decisões da empresa; e (c) o preço das ações é uma medida real da riqueza dos proprietários. Diversos trabalhos destacam a estreita 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), sendo que estes últimos autores justificam o emprego dessa variável como *proxy* de valor por que o valor de mercado de uma dada empresa reflete "a expectativa dos investidores sobre a sua geração futura de caixa", desde que o mercado seja eficiente e que o preço da ação seja coerente com o conjunto de informações que afetam o fluxo futuro de caixa da empresa.

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

No entanto, entender como esse valor é agregado pelo mercado não é algo trivial. Desse modo, compreender os direcionadores de valor é relevante para os agentes econômicos de uma forma geral. Conforme Aguiar *et al.* (2011, p. 93), o conhecimento sobre os direcionadores de valor é importante, pois:

> A identificação dos direcionadores de valor mais representativos para uma empresa permite aos gestores tanto um aprimoramento constante das atividades que agregam valor quanto uma oportunidade de melhorar os processos necessários para desempenhar determinadas atividades que consomem valor.

Diversas variáveis são empregadas nos estudos para explicar o valor corporativo, sendo muitas baseadas em informações contábeis (HALL, 2018). Dentre tais direcionadores de valor usualmente empregados na literatura, destacam-se o endividamento (END), a lucratividade e rentabilidade (LUC), o risco (RIS) e o tamanho (TAM) (ZÉGHAL; MAALOUL, 2010; AGUIAR *et al.*, 2011; MISHRA; MOHANTY, 2014; ROSS *et al.*, 2015; ALTAF, 2016; HALL, 2018; SANTOS *et al.*, 2021).

A discussão sobre a relação entre o END das empresas e seu valor vem sendo desenvolvida desde a década de 1950, com trabalhos como o de Durand (1952) e, especialmente, o de Modigliani e Miller (1958). Apesar de não haver um consenso único na Academia sobre essa relação ao longo das últimas décadas, alguns pressupostos são amplamente aceitos na literatura de finanças: os benefícios fiscais da dívida tendem a auxiliar na criação de valor ao reduzir o custo de financiamento dos ativos; e altos níveis de endividamento aumentam o risco da empresa e seus custos de falência (ROSS *et al.*, 2015).

Por sua vez, a LUC 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 (ROA) calculado a partir das demonstrações contábeis (ZÉGHAL; MAALOUL, 2010; AGUIAR *et al.*, 2011). Segundo Mishra e Mohanty (2014), o ROA é um importante indicador empregado para a mensuração do desempenho econômico-financeiro. Ademais, teoricamente, o ROA é positivamente correlacionado com os preços de mercado.

Assim, *ceteris paribus*, um maior ROA representaria uma maior probabilidade de criação de valor para os acionistas.

No que refere ao RIS, desde o trabalho clássico de Markowitz (1952), a variabilidade de resultados é amplamente empregada como *proxy* desse fenômeno em finanças. Destaca-se que desde a década de 1960 até hoje, uma medida de risco empregada, tanto no meio empresarial como acadêmico, é o beta (β), que, sinteticamente, enfatiza a variabilidade dos retornos de um ativo específico em relação ao de mercado (ROSS *et al.*, 2015). Por fim, conforme Mishra e Mohanty (2014), o TAM de uma empresa é muito empregado como variável de controle em modelos de desempenho, sendo diretamente relacionado ao valor 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.

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 das ferramentas de IA para fins de predição do mesmo, evidenciando desempenhos acima da média, como evidenciado 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 (RNA) e *random forest* (RF).

As RNAs são inspiradas no funcionamento do cérebro humano, em que diversos valores são atribuídos a uma função e cada um dos receptores recebe um desses valores diferentes, processando-os e gerando informações, que são ponderadas e dadas como saída. Essa rede de neurônios pode se encontrar distribuída entre uma ou mais camadas diferentes, que podem estar completamente, parcialmente ou apenas localmente conectadas à camada anterior de neurônios (FACELI *et al*, 2021). As RNAs 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. Esta regulação envolve o conceito de aprendizado pré-estabelecido para a construção do modelo (BRAGA; CARVALHO; LUDEMIR, 2016).

O algoritmo de RF, 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). Dessa maneira, esse algoritmo utiliza uma base de dados já existente, criando diversas árvores diferentes, que buscam achar uma média entre os resultados encontrados. Uma das características de aprendizagem do RF consiste em sua habilidade de descartar certos fatores de previsão. Assim, o modelo exclui essas possibilidades racionalizando a capacidade utilizada (JAMES *et al.*, 2013).

Apesar da importância de algoritmos de IA para a previsão do valor corporativo, apenas recentemente eles têm sido aplicados em estudos desse fenômeno, conforme evidenciam Avelar *et al.* (2022). Ainda 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.

2.2 BRICS

A primeira referência aos BRICS foi feita por Jim O'Neill, chefe de pesquisa em economia global pelo Goldman Sachs, em novembro de 2001, ainda sem levar a África do Sul em conta, em divulgação na revista "Goldman Sachs", denominado "Building better Global Economics BRICs" (O'NEILL, 2006). Na época, ainda não haviam diálogos formais entre os países que demonstrassem uma tendência de aproximação, mas os achados do trabalho demonstravam uma perspectiva de crescimento animadora para essas nações.

Não demorou para que eles de fato se unissem e essa aproximação começou a ocorrer de maneira informal em 2006, segundo o Ministério das Relações Exteriores (2022), agindo em paralelo às reuniões oficiais, como as da Organização das Nações Unidas (ONU), por exemplo. Em 2007 o Brasil organizou um encontro entre esses países e desde então os diálogos estão se aprofundando por meio de reuniões anuais, se organizando e causando ampliação da influência política e econômica da união desses países. No ano de 2011, a união se ampliou ainda mais com a chegada da África do Sul e, ainda que a aliança entre eles não fosse exatamente um bloco organizado política ou militarmente, muitos tratados de comércio, turismo e tecnologia foram assinados.

Subsequentemente, a China se beneficiou do cenário internacional após a grande recessão de 2008, favorecendo muito a despolarização do Ocidente e Oriente, fazendo com que o crescimento de um causasse desbalanço no outro, principalmente pela dependência das exportações, como relatam Balakrishnan, Toscani e Vargas (2018). O Brasil, por sua vez, teve um favorecimento ao bom ciclo de *commodities*, o que aumentou muito o produto interno bruto (PIB) e diminuiu, em partes, a desigualdade.

Ao longo do século XXI, o grupo dos BRICS está, aos poucos, ganhando mais protagonismo na economia mundial como um todo. Atualmente, a soma dos PIBs desse bloco é maior do que os do G7, totalizando USD 24,73 trilhões (INFOBRICS, 2023). O G7 é formado pelos sete países mais industrializados do mundo, quais sejam: Canadá, EUA, Alemanha, França, Itália, Japão e Reino Unido. Isso representa uma mudança na polarização da importância das economias do mundo, abrindo crescente espaço para as nações em desenvolvimento. A Figura 1 destaca o forte crescimento do PIB dos BRICS a partir do século XXI em relação aos do G7.

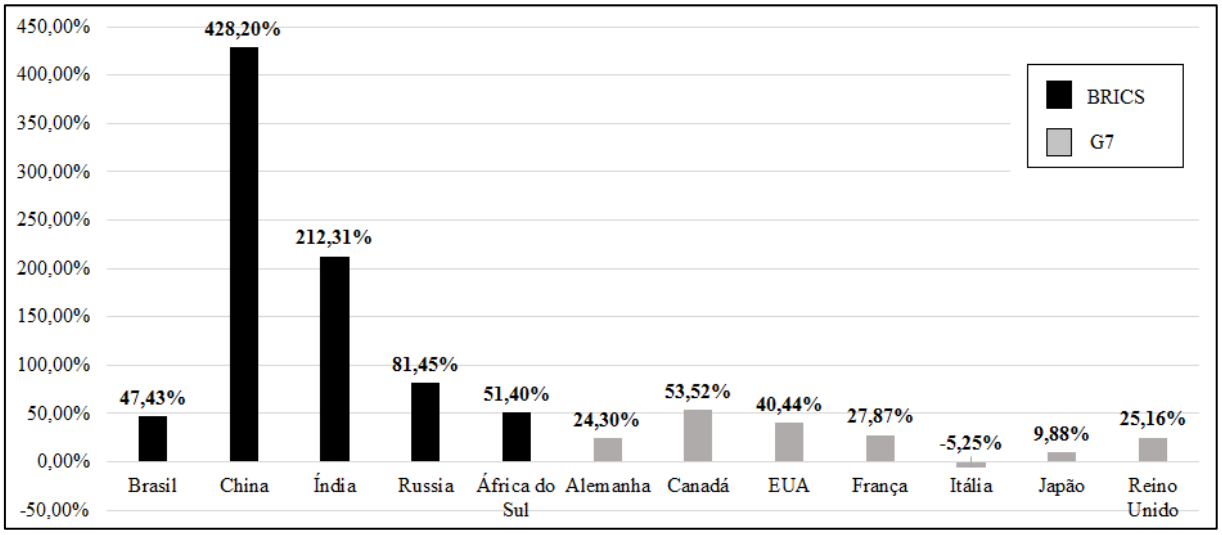

Figura 1: Evolução (%) do PIB dos países do G7 e dos BRICS entre 2000 e 2020 em USD ajustado pela inflação. Fonte: Adaptado da Ourworld in Data (2023).

Com base na Figura 1, observam-se crescimentos muito fortes de China e Índia (428,20% e 212,31%, respectivamente), seguidos de Rússia (81,45%), África do Sul (51,40%) e Brasil (47,43%). Dentre os países do G7, apenas o Canadá conseguiu um crescimento no período comparável aos BRICS: 53,52%. Em seguida, os EUA obtiveram um crescimento de 40,44%, sendo que os demais países do G7 não obtiveram crescimento superior a 30,0%, com destaque para a Itália que, neste período, decresceu 5,25%.

Além de sua importância econômica, os BRICS se organizaram com instituições próprias e multilaterais. Um exemplo disso é o Novo Banco de Desenvolvimento, que foi

fundado pelos Estados integrantes no BRICS, com foco no desenvolvimento de projetos de infraestrutura, energia e tecnologia. Esta instituição forneceu aproximadamente USD 33 bilhões de dólares em financiamento, divididos em quase 100 projetos diferentes (NEW DEVELOPMENT BANK, 2023).

Outro ponto de destaque é que os BRICS vêm tendo uma ação conjunta no cenário político internacional, mais recentemente com a invasão da Rússia à Ucrânia. Segundo dados fornecidos pelo Observatório de Política Externa e da Inserção Internacional do Brasil (OPEB), os BRICS 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 o membro dos BRICS envolvido na mesma de maneira severa (OPEB, 2022). Ainda que o Brasil tenha se mostrado favorável à condenação acerca das ações da Rússia, absteve-se quanto à suspensão do Conselho de Direitos Humanos da ONU e também se mostrou contrário às sanções impostas.

A posição Sul Africana, segundo a leitura feita pela OPEB (2022), remota ao histórico da relação entre a Rússia e a África do Sul, principalmente durante o *Apartheid*, em que o país do Leste Europeu forneceu auxílio militar e econômico para a nação africana. A Índia, por sua vez, possui relacionamento defensivo com a Rússia, visto que é um dos maiores compradores de suas armas e, além disso, depende de sua cooperação para assuntos como proteção de fronteira, por exemplo. Vale ainda destacar que todos os países dos BRICS são contra os embargos e influências impostas pelas economias do G7 e tendem a se alinhar contra possíveis sanções. Dessa maneira, dado o cenário da invasão promovida pela Rússia, os países mostram-se alinhados contra o isolamento político e econômico da mesma, ainda que não apoiem completamente a tomada do espaço ucraniano (OPEB, 2022).

3 METODOLOGIA

A pesquisa apresentada neste artigo teve caráter descritivo, correlacional e quantitativo, conforme a classificação de Sampieri *et al.* (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 desse valor.

Foram levantados dados que possibilitaram calcular as variáveis clássicas usadas como direcionadores de valor já citadas na seção anterior: END, LUC, RISC e TAM. A operacionalização dessas variáveis empregadas é apresentada no Quadro 1. Salienta-se que as equações escolhidas para operacionalização das variáveis foram selecionadas com base na literatura e de forma a minimizar o número de dados ausentes que influenciassem a estimação dos modelos.

Quadro 1: Operacionalização das variáveis

Variável	Operacionalização	Sinal esperado
MVA®	$\ln(Valor\ de\ Mercado - Patrimônio\ Líquido)$	Não se aplica
END	$(Passivo\ Exigível - Patrimônio\ Líquido) \div Ativo\ Total$	–
LUC	$EBIT \div Ativo\ Total$	+
RIS	$Cov(Retorno_{Ativo}, Retorno_{mercado}) \div Var(Retorno_{mercado})$	–
TAM	$\ln(Ativo\ Total)$	+

Fonte: Elaborado pelos autores

Inicialmente, foram estimadas regressões múltiplas 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 ε representa o erro. Para análise das regressões estimadas, foram aplicados os seguintes testes recomendados por Gujarati e Porter (2011): (i) Breusch-Pagan-Godfrey – para verificar a existência de heteroscedasticidade; (ii) Durbin-Watson – para verificar a existência de autocorrelação; e (iii) Shapiro Wilk – para verificar a existência de normalidade dos resíduos. Em 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 empregados 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 IA foram executados para fins de regressão, com o propósito de prever o MVA® das empresas, empregando as mesmas variáveis apresentadas no Quadro 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* (MAPE) (Equação 2) e do *Root Mean Squared Error* (RMSE) (Equação 3), ambas medidas necessárias para avaliar o erro de modelos de IA para fins de regressão, calculados a partir dos dados de teste (20% remanescente da amostra). Ressalta-se que, por se tratarem de métricas de erro, quanto menor o valor, melhor o desempenho do modelo.

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}(\,|\,|valor_real\,| - |valor_predito\,|\,| \div |valor_real\,|\,) \quad (2)$$

$$RMSE = \frac{1}{n}\sqrt{\sum_{i=1}^{n}(\,|\,|valor_real\,| - |valor_predito\,|\,)^2} \quad (3)$$

Alguns parâmetros específicos foram ajustados para os algoritmos. No caso do RF, 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 RNA, 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.* (2021), 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, a análise dos resultados do estudo foi realizada 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 IA 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* (randomForest); *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

Esta seção destina-se a apresentar e discutir os resultados obtidos na pesquisa. Na subseção 4.1, são apresentados os resultados do modelo de regressão, que visaram identificar as variáveis que contribuíram para a manutenção de um MVA® positivo nas empresas estudadas ao longo do período analisado. Em seguida, na subseção 4.2, avalia-se a capacidade de predição do MVA® pelos algoritmos de IA para as empresas de cada país. Por fim, na subseção 4.3, discutem-se os resultados sob a perspectiva da literatura de finanças. É importante destacar que, devido às poucas observações selecionadas com base nos parâmetros apresentados na seção anterior, as empresas russas foram excluídas das análises.

4.1 Modelos de Regressão

A Tabela 1 exibe os dados a África do Sul, nos quais se pode observar uma alta proporção na variância explicada pelos modelos, com uma pequena queda no ano de 2021, contudo ainda com 67%. O teste de Breush-Pagan indicou que os modelos não tiveram problemas de heteroscedasticidade nos anos de 2019 a 2021, entretanto em 2022 o teste não foi favorável. O teste de Durbin-Watson apresentou autocorrelação em 2020 e, por sua vez, o teste Shapiro Wilk indicou que os resíduos do modelo seguem uma distribuição normal em todos os anos. Já o teste F demonstrou que os modelos foram significantes em todos os anos.

Tabela 1: Modelos de regressão múltipla estimados para a África do Sul entre os anos de 2019 e 2022.

Ano	2019	2020	2021	2022
Intercepto	-0,32	4,29	8,72**	3,62
LUC	4,09	8,17*	2,14	7,31**
TAM	0,95***	0,71***	0,65***	0,81***
END	-1,16	-0,52	-3,41	-1,64
RIS	1,11	-0,28	-0,17	-0,52
R^2 ajustado	0,90	0,74	0,67	0,88
Teste F	25,17***	8,76***	6,67***	22,09***
Breusch_Pagan	1,68	7,44	5,77	8,45*
Durbin_Watson	1,87	1,20*	1,42	1,67
Shapiro_Wilk	0,90	0,94	0,96	0,97

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

No caso da África do Sul, poucos coeficientes tiveram um valor significante na agregação de valor. O que pode ser destacado é o TAM, com um percentual de influência significativa menor do que 1,0% em todos os anos. O LUC se mostrou significante a 10,0% no ano de 2020 e, em 2022, permaneceu com significância abaixo de 5,0%.

Por sua vez, a Tabela 2 apresenta os modelos de regressão múltipla estimados para o Brasil entre os anos de 2019 e 2022. Todos os modelos foram significantes, conforme o teste F. Em média, os modelos explicaram 54% da variância do fenômeno do MVA® positivo no período, sendo que o modelo com maior capacidade de explicação foi o estimado em 2021 (R^2 ajustado de 61%). Salienta-se que em nenhum dos anos foram observados problemas com heteroscedasticidade, contudo em alguns períodos foram observados problemas com a normalidade dos resíduos (2019 e 2022) e com a autocorrelação dos mesmos (2021).

Tabela 2: Modelos de regressão múltipla estimados para o Brasil entre os anos de 2019 e 2022.

Ano	2019	2020	2021	2022
Intercepto	2,78	3,10	3,25*	3,21
LUC	1,90	1,22	0,72	3,06*
TAM	0,85***	0,81***	0,84***	0,85***
END	-0,31	0,69	-0,79	-2,04 *
RIS	0,05	-0,08	-0,33	-0,61
R^2 ajustado	0,52	0,54	0,61	0,48
Teste F	22,57***	23,84***	31,66***	19,18***
Breusch_Pagan	3,55	0,66	0,54	2,99
Durbin_Watson	1,89	1,97	1,48***	1,92
Shapiro_Wilk	0,94***	0,98	0,97	0,92***

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

No que se refere aos coeficientes dos modelos apresentados na Tabela 2, apenas a variável TAM foi significante em todos os anos. O coeficiente positivo da variável indica sua relação positiva com o MVA®. Excepcionalmente, no ano de 2022, duas outras variáveis demonstraram significância a menos de 10%, quais sejam: LUC e END. Esta última apresentou um coeficiente com sinal negativo (indicando que contribuiu para destruição de valor no período), enquanto aquela apresentou um coeficiente com sinal positivo.

Já a Tabela 3 apresenta os dados da China, em que se pode observar uma tendência de aumento da capacidade de explicação dos modelos no decorrer dos anos, conforme representado pelo R^2 ajustado, com uma média de 60%. Os testes de Breusch-Pagan e Shapiro-Wilk se mostraram problemáticos no que se refere à normalidade na distribuição de resíduos e à heteroscedasticidade. Por outro lado, o teste de Durbin-Watson mostrou que não ocorreram problemas de autocorrelação nos resíduos. Por fim, o teste F indicou que todos os modelos foram significantes.

Tabela 3: Modelos de regressão múltipla estimados para a China entre os anos de 2019 e 2022.

Ano	2019	2020	2021	2022
Intercepto	3,44***	2,36***	2,74***	1,48*
LUC	1,77*	1,69	3,63**	4,19***
TAM	0,75***	0,79***	0,76***	0,74***
END	0,90	1,22*	1,52**	2,63***
RIS	0,44***	0,59***	0,54***	0,73***
R^2 ajustado	0,59	0,58	0,60	0,64
Teste F	251,36	248,24	269,50	307,74
Breusch_Pagan	17,57***	45,00***	32,29***	30,93***
Durbin_Watson	2,06	2,10	2,00	1,91
Shapiro_Wilk	0,97***	0,99***	0,99***	0,95***

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

Diversos coeficientes mostram-se relevantes para explicar o MVA® de empresas chinesas em todos os anos. A LUC teve um acréscimo expressivo na sua capacidade de explicação do fenômeno em 2019 até 2022, indo de 1,77 a 4,19. Outro coeficiente com o mesmo comportamento foi o END, com um aprimoramento crescente de 1,22 (2020) a 2,63 (2022). Em contrapartida, o TAM teve um efeito relativamente constante na explicação do fenômeno, com uma média de 0,76 no decorrer dos anos. Já o RIS resultou em um leve aumento de 0,44 em 2019 para 0,73 em 2022.

As observações na Tabela 4 para a Índia demonstram que o R^2 ajustado apresentou um valor médio de 81% ao explicar a variação de geração de valor entre 2019 e 2020, sobressaindo-se no último ano com 91%. O teste F evidenciou a significância de todos os modelos. Por sua

vez, os testes de Breusch-Pagan, Durbin-Watson e Shapiro-Wilk não apresentaram adversidades em relação aos pressupostos dos modelos estimados.

Tabela 4: Modelos de regressão múltipla estimados para a Índia entre os anos de 2019 e 2022.

Ano	2019	2020	2021	2022
Intercepto	5,68	2,42	2,98	1,70
LUC	9,61	7,83	7,84	2,44
TAM	0,76***	0,85***	0,77**	1,03***
END	-2,36	0,36	1,74	-1,15
RIS	1,10	0,41	0,45	-0,30
R^2 ajustado	0,80	0,79	0,74	0,91
Teste F	7,82	7,49	5,94	18,60
Breusch_Pagan	5,63	6,54	5,36	6,83
Durbin_Watson	2,01	2,24	1,93	2,64
Shapiro_Wilk	0,95	0,95	0,93	0,98

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

Analisando-se os coeficientes apresentados, apenas a variável TAM foi significante nos modelos, com sinal positivo em todos os anos estudados. Destaca-se um aumento ao longo do tempo de sua relação com o MVA®, de 0,76 no ano de 2019 para 1,03 no ano de 2022, evidenciando a geração de valor no período.

À luz dos resultados, é possível observar que cada país tem suas próprias peculiaridades e devem ser particularmente revisitados. A variável TAM mostrou-se relevante em muitos dos modelos, além de apresentar um coeficiente positivo em várias instâncias. Além disso, o R^2 ajustado demonstra usualmente uma ampla capacidade de explicação da variância dos modelos como um todo.

4.2 Modelos de IA

A Tabela 5 apresenta os resultados do desempenho dos algoritmos RF e RNA para os dados da África do Sul. No que se refere ao algoritmo RF, verificou-se que o número de árvores necessário para se obter um melhor desempenho tendeu a aumentar ao longo do tempo, chegando em 37 em 2022. O MAPE médio obtido foi de 0,0258, sendo o melhor resultado observado em 2020 (0,0218). O RMSE seguiu a mesma tendência observada no MAPE.

Tabela 5: Desempenho dos modelos de IA estimados para a África do Sul entre os anos de 2019 e 2022.

Algoritmo	RF				RNA			
Desempenho	MAPE		RMSE		MAPE		RMSE	
Ano	Arv.	Valor	Arv.	Valor	Arquitetura	Valor	Arquitetura	Valor
2019	20	0,0258	20	0,6466	2CO-4N	0,0244	2CO-4N	0,6335
2020	31	0,0218	37	0,5228	1CO-2N	0,0283	1CO-2N	0,7167
2021	34	0,0313	34	0,8920	1CO-2N	0,0174	1CO-2N	0,4050
2022	37	0,0244	37	0,5306	1CO-3N	0,0336	2CO-1N	0,7557

Notas: Arv. equivale ao número de árvores; CO equivale a camadas ocultas. e N equivale a neurônio(s)

Sobre o algoritmo RNA, enquanto nos anos de 2019 e 2022 foram necessárias duas camadas ocultas para obter o melhor desempenho, nos demais anos foi necessária apenas uma camada oculta. O melhor desempenho foi observado em 2021, tanto no que se refere ao MAPE (0,0174) quanto ao RMSE (0,4050).

Já a Tabela 6 apresenta os resultados do desempenho dos algoritmos RF e RNA para as empresas brasileiras. No que tange ao algoritmo RF, verificou-se que o número de árvores necessário para se obter um melhor desempenho tendeu a se reduzir ao longo do tempo, chegando em 23 em 2022, ao contrário do que ocorreu para a África do Sul. O MAPE médio

obtido foi de 0,0595, sendo o melhor resultado observado em 2020 (0,0504). O RMSE seguiu a mesma tendência observada no MAPE.

Tabela 6: Desempenho dos modelos de IA estimados para o Brasil entre os anos de 2019 e 2022.

Algoritmo	**RF**				**RNA**			
Desempenho	**MAPE**		**RMSE**		**MAPE**		**RMSE**	
Ano	**Arv.**	**Valor**	**Arv.**	**Valor**	**Arquitetura**	**Valor**	**Arquitetura**	**Valor**
2019	44	0,0504	44	1,3105	2CO-1 N	0,0622	1CO-1 N	1,7648
2020	39	0,0565	39	1,4574	1CO-2 N	0,0657	1CO-2 N	1,6560
2021	21	0,0542	33	1,4246	1CO-2 N	0,0569	1CO-2 N	1,4124
2022	23	0,0770	23	1,9203	2CO-2 N	0,0762	1CO-4 N	1,8912

Notas: Arv. equivale ao número de árvores; CO equivale a camadas ocultas; e N equivale a neurônio(s)

No que se refere ao algoritmo RNA, tal como no caso da África do Sul, enquanto nos anos de 2019 e 2022 foram necessárias duas camadas ocultas para obter o melhor desempenho, nos demais anos foi necessária apenas uma camada oculta. Já o melhor desempenho foi observado em 2019, ao contrário do caso da África do Sul, tanto no que se refere ao MAPE (0,0504) quanto ao RMSE (1,3105).

A Tabela 7 apresenta os resultados do desempenho dos algoritmos RF e RNA para as empresas da China. No que se refere ao algoritmo RF, verificou-se que o número de árvores necessário para se obter um melhor desempenho tendeu a se reduzir ao longo do tempo, chegando em 7 em 2022, tal como no caso brasileiro. O MAPE médio obtido foi de 0,0426, sendo o melhor resultado observado em 2020 (0,0388). O RMSE seguiu a mesma tendência observada no MAPE. Sobre o algoritmo RNA, ao contrário do caso brasileiro e sul-africano, o ano de 2020 demandou apenas uma camada. Ademais, o melhor desempenho do algoritmo foi no ano de 2019, tanto no que se refere ao MAPE (0,0351) quanto ao RMSE (0,9532).

Tabela 7: Desempenho dos modelos de IA estimados para a China entre os anos de 2019 e 2022.

Algoritmo	**RF**				**RNA**			
Desempenho	**MAPE**		**RMSE**		**MAPE**		**RMSE**	
Ano	**Arv.**	**Valor**	**Arv.**	**Valor**	**Arquitetura**	**Valor**	**Arquitetura**	**Valor**
2019	45	0,0388	45	1,0284	1CO-2 N	0,0351	1CO-2 N	0,9532
2020	47	0,0416	47	1,0984	1CO-3 N	0,0398	1CO-2 N	1,0433
2021	48	0,0453	29	1,1838	2CO-2 N	0,0438	2CO-2 N	1,1128
2022	28	0,0447	7	1,1617	1CO-3 N	0,0423	1CO-3 N	1,0794

Notas: Arv. equivale ao número de árvores; CO equivale a camadas ocultas. e N equivale a neurônio(s)

Por fim, a Tabela 8 destaca os resultados do desempenho dos algoritmos RF e RNA para as empresas indianas. No que se refere ao algoritmo RF, ao contrário do observado nos países anteriormente abordados, não foi possível verificar uma tendência de aumento ou de redução no número de árvores necessário para se obter um melhor desempenho e tendeu-se a reduzir ao longo do tempo. O MAPE médio obtido foi de 0,1305, sendo o melhor resultado observado em 2021 (0,1254). O melhor resultado para o RMSE, porém, foi observado no ano de 2022 (3,1903).

Tabela 8: Desempenho dos modelos de IA estimados para a Índia entre os anos de 2019 e 2022.

Algoritmo	**RF**				**RNA**			
Desempenho	**MAPE**		**RMSE**		**MAPE**		**RMSE**	
Ano	**Arv.**	**Valor**	**Arv.**	**Valor**	**Arquitetura**	**Valor**	**Arquitetura**	**Valor**
2019	32	0,1291	32	3,2641	1CO-4 N	0,0130	1CO-3 N	0,3848
2020	8	0,1428	9	3,6581	2CO-1 N	0,0241	2CO-1 N	0,7392
2021	41	0,1254	41	3,2772	2CO-3 N	0,0171	2CO-3 N	0,5430
2022	22	0,1247	22	3,1903	1CO-2 N	0,0211	1CO-2 N	0,7562

Notas: Arv. equivale ao número de árvores; CO equivale a camadas ocultas. e N equivale a neurônio(s)

4.3 Análise Geral

Primeiramente, destaca-se que todos os modelos de regressão estimados foram significantes e apresentaram um R^2 sempre superior a 51%, indicando a relevância das variáveis selecionadas como determinantes do MVA® das empresas estudadas, mesmo em períodos de crise. 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).

Dentre tais variáveis, o TAM se mostrou a mais consistente para explicar o MVA® das empresas ao longo de todo o período, realçando o exposto por Mishra e Mohanty (2014). A mesma foi muito significante em todos os modelos e em todos os anos, apresentando sempre coeficientes positivos. Em alguns casos, seu poder explicativo tendeu a aumentar ao longo do tempo. 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.

Já a variável LUC se mostrou significante em modelos de três países, principalmente, no ano de 2022. Salienta-se que o único país em que essa variável não foi significante em nenhum modelo foi a Índia. O coeficiente positivo demonstra sua contribuição ao MVA® das empresas no final do período estudado, ratificando o exposto por Zéghal e Maaloul (2010), Besanko *et al* (2012) e Mishra e Mohanty (2014). Uma possível explicação para essa significância no final do período é que após anos sofrendo com as crises da pandemia da Covid-19 e da invasão da Ucrânia, apesar de ainda ser determinante, o maior porte das organizações não seria mais a condição única para manter a agregação de valor no mercado, sendo necessário considerar aspectos relacionados à lucratividade.

Por sua vez, a variável END foi relevante em alguns modelos para alguns anos, em especial após 2019, mas com sinais divergentes. Essa divergência de resultados está em linha com o exposto por Ross *et al.* (2015). No caso brasileiro, essa variável foi significante e com sinal negativo no ano de 2022, indicando que ocorreu uma 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, a variável RIS só foi significante nos modelos estimados para a China. Porém, foi positivo e com tendência de crescimento em sua contribuição para o MVA®, indo contra o esperado, com base na literatura.

As figuras 2 e 3 apresentam, respectivamente, as métricas de desempenho MAPE e RMSE para cada país por ano. No caso da África do Sul (figuras 2a e 3a), observou-se que os modelos de IA apresentaram desempenhos superiores aos da regressão. Salienta-se que o desempenho da regressão apresentou uma tendência de melhora nas previsões ao longo do tempo.

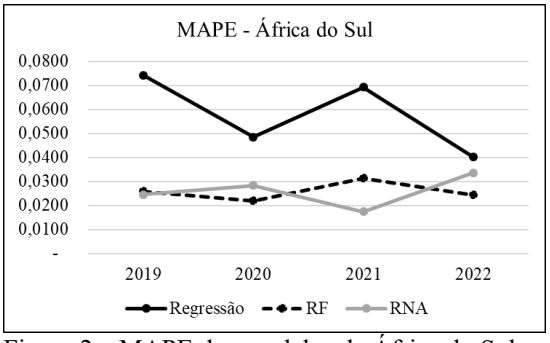

Figura 2a: MAPE dos modelos da África do Sul

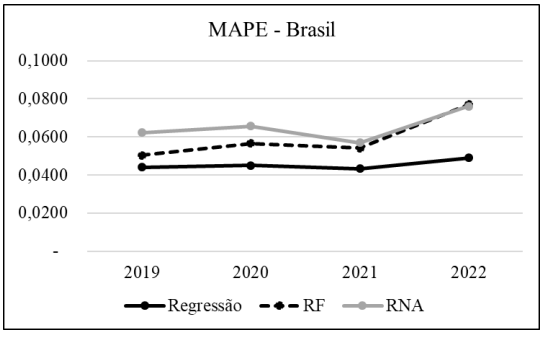

Figura 2b: MAPE dos modelos do Brasil

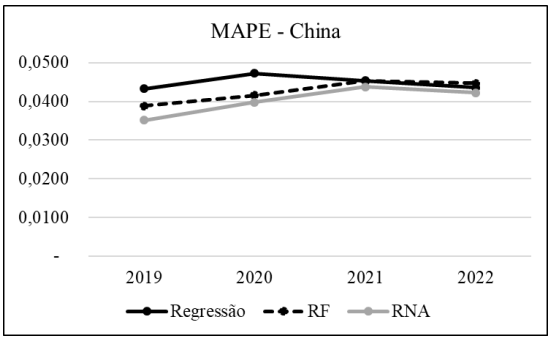

Figura 2c: MAPE dos modelos da China

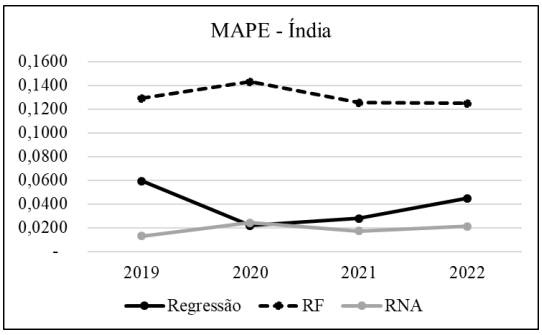

Figura 2d: MAPE dos modelos da Índia

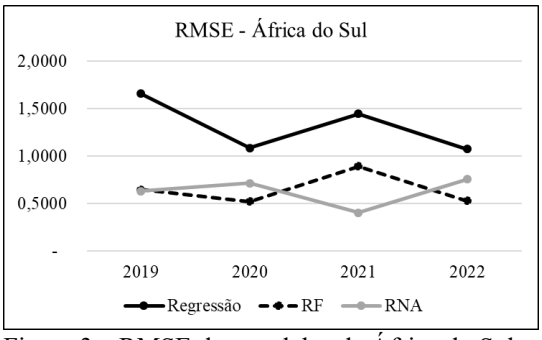

Figura 3a: RMSE dos modelos da África do Sul

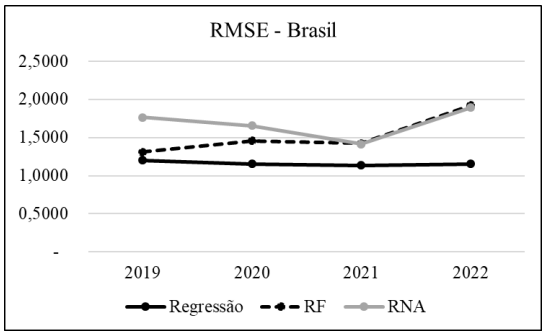

Figura 3b: RMSE dos modelos do Brasil

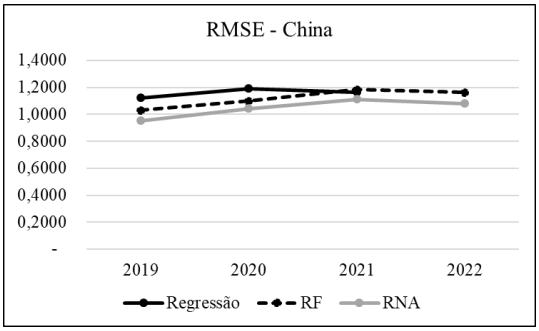

Figura 3c: RMSE dos modelos da China

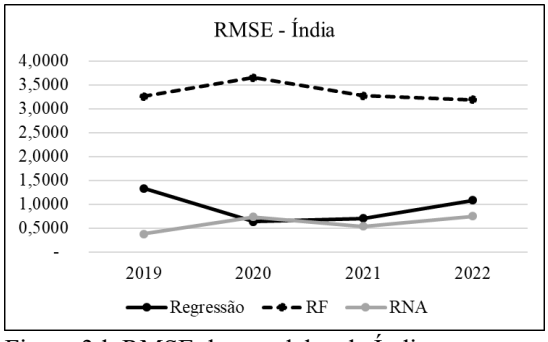

Figura 3d: RMSE dos modelos da Índia

Já no caso do Brasil (figuras 2b e 3b), os modelos de regressão apresentaram o melhor desempenho preditivo. Por sua vez, os modelos estimados para a China (figuras 2c e 3c) indicaram uma superioridade no desempenho desses algoritmos nos primeiros anos, sendo que se observou uma convergência no nível de previsão da regressão ao longo do tempo. Por fim, os algoritmos RNA e a regressão superaram o desempenho preditivo do RF no caso indiano (figuras 2d e 3d). O nível de discrepância observado foi o mais alto entre todos os modelos.

Apesar de descritivamente apresentarem desempenhos discrepantes, foi necessário empregar o teste de Mann-Whitney para avaliar se as diferenças realmente eram significativas. Os resultados do teste, tanto para a métrica RMSE quanto para a MAPE indicaram desempenho estatisticamente iguais entre o modelo de regressão e os estimados pelo RF (coeficientes de 103 e 111, respectivamente). Porém, o mesmo teste indicou que o desempenho das RNA foi estatisticamente superior ao dos modelos de regressão (coeficiente de 180, significante a menos de 1,0%) e do RF (coeficiente de 174, significante a menos de 5,0%). Tais resultados corroboram parcialmente aqueles apresentados por estudos como os de Qian e Rasheed (2007), Shynkevich *et al.* (2017) e Cao *et al.* (2019).

5 CONCLUSÕES

A pesquisa apresentada neste artigo visou avaliar o desempenho de algoritmos de IA para a previsão do MVA® em empresas de países que fazem parte dos BRICS, entre os anos de 2019 e 2022. Para tanto, foram selecionadas companhias abertas desses países que apresentaram MVA® positivo ao longo de todo o período e foram treinados algoritmos de IA (especificamente, RF e RNA), assim como modelos de regressão linear múltipla, a partir de direcionadores clássicos de valor disponíveis na literatura.

Os resultados indicaram que as variáveis 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.

No que se refere ao emprego de algoritmos de IA para a previsão do MVA® das empresas, verifica-se a aplicabilidade do RF e da RNA para previsão de valor dessas organizações. O desempenho dos algoritmos variou de país para país, porém, de forma geral, foi, no mínimo, similar à capacidade de previsão dos modelos de regressão tradicionais (que apresentaram altos valores de R^2). Estatisticamente, os algoritmos de RF tiveram um desempenho similar ao dos modelos de regressão, enquanto os modelos de RNA apresentaram desempenho superior a esses modelos. Tal resultado evidencia a capacidade desse tipo de algoritmo em lidar com problemas complexos como a adição de valor às empresas, podendo apresentar resultados superiores aos de outras técnicas.

Os resultados do estudo contribuem de forma relevante para o tema 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 IA 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 de IA, assim, como os de estatística tradicionais para análise do fenômeno de criação de valor empresarial.

A pesquisa, todavia, também apresenta algumas limitações, quais sejam: (a) os critérios adotados para seleção da amostra implicaram na 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 IA empregados; e (d) apesar de amplamente empregado, o MVA® é apenas uma das medidas de criação de valor corporativo, sendo limitada por definição. Assim, sugere-se que pesquisas futuras considerem outras *proxies* de valor corporativo, como o Q de Tobin ou o indicador *market-to-book*, assim como sejam empregados algoritmos de IA que possibilitem a análise longitudinal dos dados, tal como as RNA *long short-term memory* (LSTM). Por fim, a ampliação da amostra para outros países emergentes, assim como desenvolvidos, possibilitaria uma comparação interessante 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. 2023. 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, n. 2, p. 90-112, 2011.Disponível em: https://doi.org/10.1590/S1678-69712011000200005.

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. Disponpivel 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**, [S. l.], v. 17, n. 3, 2022. Disponível em: https://doi.org/10.20985/1980-5160.2022.v17n3.1807.

BALAKRISHNAN; TOSCANI; VARGAS. Regional Economic Outlook: Western Hemisphere Seizing the Momentum. **International Monetary Fund (IMF)**, 5, 2018.

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

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

BRASIL, Índia, China e África do Sul. **Ministério das relações exteriores.** 03 nov. 2022. Disponível em: https://www.gov.br/mre/pt-br/assuntos/mecanismos-internacionais/mecanismos-inter-regionais/brics. Acesso em 08 maio 2023.

CAO, H.; *et al.* Stock Price Pattern Prediction Based on Complex Network and Machine Learning. **Complexity.** p. 1–12, 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,** 32(1), p. 602-623, 2022. Disponível em: https://doi.org/10.1002/bse.3163.

DAMODARAN, A. **Finanças corporativas: teoria e prática**. 2. ed. Porto Alegre: Bookman, 2004.

DURAND, D. Costs of debt and equity funds for business: trends and problems of measurement. In: Conference on research in business finance. **National Bureau of Economic Research,** p. 215-262, 1952. Disponível em: https://ideas.repec.org/h/nbr/nberch/4790.html.

FACELI, K. *et al.* **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**, 2. ed. Rio de Janeiro: LTC, 2021.

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

GROSS Domestic Product (GDP). **Our world in data.** 2001. Disponível em: https://ourworldindata.org/grapher/gross-domestic-product?tab=chart&yScale=log&time=2001&country=RUS~IND~BRA~CHN~ZAF~DEU~CAN~USA~FRA~ITA~JPN~GBR. Acesso em 10 maio 2023.

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

HAIR, J. F., *et al.* **Análise Multivariada de Dados**. 6. ed. Porto Alegre: Bookman, 2009.

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.

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. Acesso em 08 maio 2023.

JAMES, G. *et al.* **An introduction to statistical learning**. New York: springer, 2013.

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, 104281, 2021. Disponível em: https://doi.org/10.1016/j.tourman.2020.104281.

MARKOWITZ, H. Portfolio selection. **The Journal of Finance**, v. 7, n. 1, 9. 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: DOI:10.1108/CG-12-2012-0089.

MODIGLIANI, F.; MILLER, M. H. The cost of capital, corporation finance and the theory of investment. **The American Review**, v. 48, n. 3, p. 261-297, 1958.

MOLL, J.; YIGITBASIOGLU, O. The role of internet-related technologies in shaping the work of accountants: new directions for accounting research. **The British Accounting Review**, v. 51, n. 6, p. 100833, 2019.

NEW DEVELOPMENT BANK. Página Inicial do New Delopment Bank. Disponível em: https://www.ndb.int/. Acesso em: 10 jun 2023.

OBSERVATÓRIO DE POLÍTICA EXTERNA E DA INSERÇÃO INTERNACIONAL DO BRASIL – OPEB. BRICS **Recuperam protagonismo com a guerra na Ucrânia**. Disponível em: https://opeb.org/2022/05/02/brics-recuperam-protagonismo-com-a-guerra-na-ucrania/. Acesso 10 maio 2023.

O'NEILL, J. Building Better Economic BRIC's. Goldman Sachs Global Paper. **Goldman Sachs Global Paper**. n. 66. 2001. Disponível em: https://www.goldmansachs.com/intelligence/archive/building-better.html.

OLIVEIRA S. G.; *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, p. 114–133, 2021. Disponível em: https://doi.org/10.22478/ufpb.2318-1001.2021v9n1.50429.

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, n. 1, p. 25–33, 2007. Disponível em: https://doi.org/10.1007/s10489-006-0001-7.

ROSS, S. A.; *et al.* **Administração Financeira**. 10. ed. Porto Alegre: AMGH Editora, 2015.

RUNDO, F.; *et al.* Machine learning for quantitative finance applications: A survey. **Applied Sciences**, v. 9, n. 24, p. 5574, 2019.

SADORSKY, Perry. A random forests approach to predicting clean energy stock prices. **Journal of risk and financial management**, v. 14, n. 2, p. 48, 2021.

SAMPIERI, R. H.; COLLADO, C. F.; LUCIO, P. B. **Metodologia de Pesquisa**. 3. ed. 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, Phasin. 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: doi: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, Larisa. 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, 100723, 2022. Disponível em: https://doi.org/10.1016/j.jbef.2022.100723.

ZEGHAL, D.; MAALOUL, 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. Disponivel em: DOI: 10.1108/14691931011013325.