

**INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE PREVISÃO DO
ENDIVIDAMENTO CORPORATIVO EM EMPRESAS DO G20 FACE ÀS RECENTES
CRISES MUNDIAIS**

EWERTON ALEX AVELAR

UNIVERSIDADE FEDERAL DE MINAS GERAIS (UFMG)

HUDSON FERNANDES AMARAL

CENTRO UNIVERSITÁRIO UNIHORIZONTES - MG

RICARDO VINÍCIUS DIAS JORDÃO

SWISS MANAGEMENT CENTER

TERENCE MACHADO BOINA

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO (UFRJ)

INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE PREVISÃO DO ENDIVIDAMENTO CORPORATIVO EM EMPRESAS DO G20 FACE ÀS RECENTES CRISES MUNDIAIS

1 INTRODUÇÃO

Diversos estudos foram desenvolvidos ao longo do tempo a respeito de decisões de financiamento envolvendo a estrutura de capital com ênfase no emprego de variáveis determinantes do nível de endividamento das empresas (*e.g.*, Titman & Wessels, 1988; Rajan & Zingales, 1995; Frank & Goyal, 2009; Aybar *et al.*, 2023). Não obstante a relevância das decisões de financiamento e seu impacto no endividamento das empresas, é possível constatar um número reduzido de estudos que abordaram essa temática em momentos de crises, especialmente as recentes: pandemia de Covid-19 e invasão da Ucrânia pela Rússia (*e.g.*, Nguyen *et al.*, 2023; Prakash *et al.*, 2023). São dois momentos singulares da história com consequências políticas, econômicas e sociais que podem ter influenciado sobremaneira as decisões financeiras de diferentes formas em empresas ao redor do mundo.

Usualmente, são usados modelos estatísticos para previsão de endividamento corporativo considerando variáveis determinantes consolidadas na literatura. Embora nos últimos anos algoritmos de inteligência artificial (IA) tenham sido utilizados em pesquisas relacionadas às finanças corporativas (Rundo *et al.*, 2019), especialmente para previsão de preços de ativos (Ferreira *et al.*, 2021), não se constatam um grande número de pesquisas relacionadas a previsão de níveis de endividamento das empresas ou a comparação desses algoritmos com modelos baseados em técnicas estatísticas tradicionais, segundo Jang e Lee (2019) e Jaggi *et al.* (2021), gerando uma considerável lacuna de investigação que merece ser investigada em profundidade.

Reconhecendo e explorando a lacuna supracitada, o estudo, cujos resultados são apresentados neste artigo, propôs a seguinte questão de pesquisa: qual o desempenho de algoritmos de IA na previsão do nível de endividamento corporativo considerando períodos de crise? Nesse sentido, o estudo apresentado visou avaliar o desempenho de algoritmos de IA na previsão do nível de endividamento de empresas em períodos de crise. Para isso, foram analisados dados de 11.944 empresas de países que fazem parte do Grupo dos Vinte (G20) entre os anos de 2019 e 2022. Como objetivos específicos, buscou-se: (i) identificar a consistência das variáveis determinantes do endividamento das empresas ao longo do período analisado; (ii) comparar a capacidade de predição do nível endividamento entre algoritmos de IA e técnicas estatísticas tradicionais; (iii) avaliar o desempenho dos modelos em prever o nível endividamento entre países desenvolvidos e emergentes; e (iv) discutir os resultados sob a perspectiva da literatura de finanças.

Este estudo é relevante teórica e empiricamente, pois apresenta os impactos das principais variáveis determinantes de endividamento das empresas dos países que compõe o G20 no período imediatamente anterior à crise sanitária da Covid-19 ser deflagrada para diversos países em todo mundo (2019) e nos períodos seguintes (2020-2022), incluindo o ano de invasão da Ucrânia pela Rússia (2022). Pode-se destacar, ainda, a relevância de pesquisas acadêmicas que considerem o G20, pela sua importância social, política e econômica mundial, sendo composto por 19 países e o bloco econômico da União Europeia, que representam cerca de 85% do produto interno bruto global, mais de 75% do comércio internacional e cerca de dois terços da população mundial (G20, 2023). Ademais, o estudo contribui para a literatura e profissionais de mercado, apresentando uma avaliação comparada entre algoritmos de IA e técnicas estatísticas tradicionais para fins de predição do nível de endividamento de empresas, considerando o emprego recente e a potencialidade do uso de tais algoritmos em finanças corporativas (*e.g.*, Clarke *et al.*, 2020; Singh & Khushi; 2021; Avelar

et al., 2022). Por fim, avalia-se o desempenho dos modelos estimados segregado para empresas de países desenvolvidos e de países emergentes, considerando as diferenças esperadas na qualidade da informação contábil (Al-Enzy *et al.*, 2023; Viana Jr. *et al.*, 2023) e na eficiência de mercado (Sánchez-Granero *et al.*, 2020).

2 FUNDAMENTAÇÃO TEÓRICA

Decisões relacionadas ao nível de endividamento (estrutura de capital) das empresas conforme Nguyen *et al.* (2023), dizem respeito ao financiamento das operações corporativas por meio de uma combinação entre fontes de capital próprio e de terceiros. Desde que Modigliani e Miller (1958; 1963) questionaram a (ir)relevância dos efeitos do nível de endividamento corporativo no valor das empresas, foram gerados campos de pesquisa e consolidadas teorias para explicar esse fenômeno, dentre as quais se destacam: a *trade-off theory* (TOT) e a *pecking order theory* (POT).

A TOT, segundo Lemmon e Zender (2010), prevê que as empresas tendem a escolher uma proporção de capital próprio e de terceiros que equilibre os custos e os benefícios da dívida. De acordo com esses autores, os benefícios da dívida e o controle dos fluxos de caixa livres incentivam as empresas ao endividamento, enquanto o aumento da probabilidade de falência e outros custos de agência tendem a desincentivar o endividamento. Desse modo, de acordo com a TOT, quando o custo marginal e os benefícios da dívida se igualam à proporção de financiamento, o nível de endividamento pode ser considerado ótimo (Lemmon & Zender, 2010).

Já no caso da POT, não há a pressuposição de que as empresas busquem um nível ótimo de endividamento, conforme discutido em Myers (1984). Frank e Goyal (2009) destacam que a POT é baseada na assimetria informacional entre gestores e investidores, sendo que os administradores prefeririam empregar recursos gerados internamente, em função do menor risco de seleção adversa, em detrimento da emissão de títulos de propriedade que, sob a perspectiva dos investidores, tende a apresentar maior risco. De um modo geral, no que tange à perspectiva da POT, é esperado que as empresas financiem suas operações por meio de retenção de lucros. Entretanto, caso esses recursos próprios não sejam suficientes, o financiamento das operações ocorreria por meio de assunção de dívidas e, em último caso, mediante emissão de novas ações.

Além do desenvolvimento e testes de teorias, diversos estudos, ao longo das últimas décadas enfocaram as variáveis que determinariam o nível de endividamento corporativo (*e.g.*, Titman & Wessels, 1988; Rajan & Zingales, 1995; Frank & Goyal, 2009; Aybar *et al.*, 2023), tais como: escudo fiscal não provenientes de dívida, tamanho da empresa, liquidez, tangibilidade dos ativos, crescimento, lucratividade e risco (Ross *et al.*, 2015; Aybar *et al.*, 2023; Prakash *et al.*, 2023). É importante destacar que, dependendo da teoria utilizada para o estudo do fenômeno, a relação esperada entre tais variáveis clássicas e o nível de endividamento difere. No caso da TOT, por exemplo, é esperado que empresas com alto crescimento sejam menos endividadas, devido a seu maior risco; enquanto aquelas com alta lucratividade sejam mais endividadas, já que teriam maiores condições de arcar com os encargos financeiros. Sob a perspectiva da POT, essa interpretação se inverte: empresas mais lucrativas gerariam mais recursos internos (primeira opção para financiamento), o que tenderia a reduzir sua necessidade de financiamento externo; enquanto empresas com altos níveis de crescimento demandariam mais recursos de terceiros para financiar tal crescimento, o que levaria a maiores níveis de endividamento.

Conforme Alnori (2023), apesar da relevância da discussão sobre nível de endividamentos nas últimas décadas, poucos estudos, tais como Homapour *et al.* (2022), Aybar *et al.* (2023), Nguyen *et al.* (2023) e Prakash *et al.* (2023) têm se dedicado a este fenômeno em períodos de crise,

um importante fator de influência do contexto econômico adverso nesse fenômeno. Prakash *et al.* (2023) observaram que, mesmo em períodos de crise, todas as variáveis clássicas supracitadas determinantes do nível de endividamento corporativo foram consistentes para explicar o fenômeno do endividamento e encontraram evidências da supremacia da POT em relação à TOT, assim como no estudo de Aybar *et al.* (2023).

Por sua vez, Homapour *et al.* (2022) desenvolveram modelos que constataram a relevância de variáveis macroeconômicas em explicar o nível de endividamento das empresas em períodos de crise. Aybar *et al.* (2023) ainda destacam diferenças, em períodos de crise, nas decisões de endividamento das empresas de países emergentes e de países desenvolvidos. Já Alnori (2023) e Nguyen *et al.* (2023) constataram que as empresas tendem a reduzir seu nível de endividamento em períodos de crise, para tentar minimizar o risco de falência ante ao aumento das adversidades externas.

Em termos de crises recentes que afetaram de forma muito significativa as empresas em todo o mundo, destacam-se: crise sanitária da pandemia de Covid-19 (vírus SARS-CoV2) e crise militar-civil-política-econômica da invasão russa à Ucrânia. No que se refere a esta última crise, ainda, não foram encontradas evidências na literatura entre sua relação e o fenômeno do nível de endividamento corporativo. Já no que se refere à pandemia de Covid-19, Nguyen *et al.* (2023) e Prakash *et al.* (2023) constataram a influência do período no qual ocorreu a crise sanitária nas decisões de financiamento dos gestores. Prakash *et al.* (2023), inclusive, evidenciaram quedas significantes no nível de endividamento das empresas e que todas as variáveis clássicas determinantes foram consistentes para explicar fenômeno do endividamento das empresas durante a crise sanitária. Diante do exposto, foi proposta a Hipótese 1 (H1):

H1: Mesmo em períodos de crise, as variáveis clássicas determinantes de endividamento são consistentes para explicar o fenômeno.

Desde os estudos clássicos de Titman e Wessels (1988) e Rajan e Zingales (1995), há um enfoque no uso de modelos estatísticos para análise das variáveis determinantes do nível de endividamento corporativo. Nos últimos anos, porém, houve um aumento expressivo da aplicação de algoritmos de IA, especialmente, aqueles relacionados ao aprendizado de máquina, em diversas áreas das finanças corporativas, tal como destacam Rundo *et al.* (2019). Muitos estudos focam na potencialidade de algoritmos de IA com a finalidade de predição no mercado financeiro, obtendo desempenhos acima da média, como exposto em Shynkevich *et al.* (2017) e Cao *et al.* (2019). Nesse diapasão, Avelar *et al.* (2022) salientam dois dos principais algoritmos usados para realizar previsões em finanças: Redes Neurais Artificiais (RNA) e *Random Forest* (RF).

As RNA representam uma forma avançada de algoritmo de aprendizado de máquina, que apresentam relações com o funcionamento do cérebro humano, sendo uma extensa rede de neurônios interconectados (Coppin, 2010). De acordo com Nielsen (2019), as RNA são capazes de aprender a partir de dados por meio de um processo de treinamento, onde os pesos das conexões são ajustados para que a rede seja capaz de realizar tarefas específicas. Ainda de acordo com o mesmo autor, ao se combinar muitos neurônios simples em uma estrutura organizada em camadas, é possível criar um sistema que processará as informações complexas e realizar tarefas cognitivas. Namin e Namin (2018) destacam que as RNA possuem, no mínimo, três camadas, sendo: uma de entrada, uma oculta e uma de saída.

Já a RF pode ser definida como a combinação de diferentes árvores de decisões, que tratam dados não paramétricos por meio de um treinamento supervisionado, conforme exposto por

Sadorsky (2021). Dessa forma, segundo o mesmo autor, esse algoritmo manuseia uma base de dados existente e cria distintas árvores, que buscam a média dos resultados gerados. Conforme James *et al.* (2023), a RF ignora alguns fatores de previsão considerados irrelevantes, permitindo que o modelo faça a exclusão das possibilidades, o que racionaliza a capacidade utilizada.

Diversos estudos realizados nos últimos anos obtiveram resultados promissores sobre o emprego de algoritmos de IA para previsão em finanças corporativas, tais como Clarke *et al.* (2020) e Singh e Khushi (2021). É importante destacar que alguns poucos estudos evidenciaram que o desempenho de alguns algoritmos de IA foi similar ao de técnicas estatísticas tradicionais para fins de previsão (*e.g.*, Jaggi, 2021), ou até mesmo inferior (*e.g.*, Jang & Lee, 2019). Porém, de forma geral, o uso de algoritmos IA tem apresentado bons desempenhos em previsão de fenômenos em finanças corporativas. Assim, foi proposta a Hipótese 2 (H2):

H2: *Algoritmos de IA apresentam um desempenho preditivo superior às técnicas estatísticas tradicionais para explicar o fenômeno do endividamento.*

Destaca-se que, independentemente do modelo empregado para previsão em finanças (estatísticos ou baseados em IA), a qualidade dos dados como *inputs* e a eficiência na precificação das informações pelos agentes econômicos devem ser consideradas. Baseando-se na Hipótese do Mercado Eficiente (HME) destacada por Fama (1970), há expectativa de que as informações referentes às decisões financeiras tomadas nas empresas sejam precificadas pelo mercado. Segundo Nazlioglu *et al.* (2023), a HME sugere que os preços das ações nos mercados financeiros refletem totalmente as informações disponíveis e relevantes, classificando a eficiência de mercado em três formas: (a) fraca – informações contidas nos preços passados dos ativos já estão refletidas no preço atual e não ajudariam na previsão de movimentos futuros de preços; (b) semiforte – os preços dos ativos refletiriam integralmente todas as informações publicamente disponíveis; e (c) forte – os preços dos ativos refletiriam integralmente todas as informações, inclusive as privilegiadas, o que impediria qualquer investidor de alcançar consistentemente retornos maiores do que a média do mercado (Ross *et al.*, 2015).

Como as informações provenientes das demonstrações contábeis divulgadas periodicamente pelas organizações são relevantes informações públicas precificadas pelo mercado, conforme Al Ani (2021), analistas, credores, gestores e outros participantes do mercado almejam averiguar a qualidade dessas informações em mercados desenvolvidos e emergentes para o desenvolvimento de modelos preditivos. Nesse contexto, Dechow e Schrand (2004), Chaney *et al.* (2011) e Boina e Macedo (2018) destacam que a qualidade da informação contábil divulgada pelas empresas pode ser mensurada de diversas formas, tais como: persistência dos lucros, *value relevance*, gerenciamento de resultados e capacidade preditiva.

Ademais, Borges (2010) destaca que a eficiência de um mercado varia ao longo do tempo e de acordo com contexto econômico, político e social de determinado país, sendo que Sánchez-Granero *et al.* (2020) e Nazlioglu *et al.* (2023) ressaltam diferenças entre países desenvolvidos e emergentes. Para aqueles primeiros autores, a eficiência de mercado tende a ser maior em países desenvolvidos em relação aos emergentes, o que implica maiores oportunidades de lucros (considerando maiores níveis de risco) para investidores em países emergentes.

Assim como no caso da eficiência de mercado, a classificação de países em emergentes e desenvolvidos é considerado um preditor importante para a qualidade da informação contábil divulgada pelas empresas. De forma geral, em países desenvolvidos, são esperadas informações com maior qualidade, devido a um melhor ambiente institucional, com segurança jurídica e

proteção aos acionistas minoritários, por exemplo, de acordo com Viana Jr. *et al.* (2023). Al-Enzy *et al.* (2023) ressaltam que, em alguns países emergentes, nem mesmo a convergência às normas internacionais de Contabilidade (*International Financial Reporting Standards – IFRS*) melhorou a qualidade da informação contábil.

Diante do exposto e considerando que a maior parte dos estudos historicamente usa variáveis baseadas em informações contábeis para explicar o endividamento (*e.g.*, Titman & Wessels, 1988; Rajan & Zingales, 1995; Frank & Goyal, 2009; Aybar *et al.*, 2023; Prakash *et al.*, 2023), foi proposta a Hipótese 2 (H2):

H3: *Técnicas estatísticas tradicionais e algoritmos de IA usados para explicar o fenômeno do endividamento apresentam desempenhos preditivos superiores para os países desenvolvidos em relação aos países emergentes.*

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 o G20, quais sejam: África do Sul, Alemanha, Arábia Saudita, Argentina, Austrália, Brasil, Canadá, China, Estados Unidos da América (EUA), França, Índia, Indonésia, Itália, Japão, México, Reino Unido, República da Coreia, Rússia, Turquia (G20, 2023). Salienta-se que a União Europeia também faz parte do G20, mas, por não ser um país *stricto sensu*, não foi considerada para composição da amostra.

Salienta-se que os países do G20 podem ser divididos em dois grupos: desenvolvidos e emergentes. Estes últimos, conforme Mody (2004), são países que empreendem programas de reforma e desenvolvimento econômico e emergem como atores significativos na economia global. Ademais, países emergentes são marcados por constantes instabilidades e escassa credibilidade de suas instituições em níveis político, educacional, demográfico, econômico e de interação com capitais internacionais. Na mesma linha de raciocínio, Benachenhou (2013) salienta que países emergentes buscam diversificação de sua economia, intensificação do uso de tecnologias e aumento da produtividade de seus setores econômicos, desenvolvendo e exportando principalmente os produtos de maior demanda no mercado mundial e aumentando o fluxo de investimentos estrangeiros. Em termos de G20, considerando as históricas classificações do Fundo Monetário Internacional (FMI, 2023), são considerados países emergentes: África do Sul, Arábia Saudita, Argentina, Brasil, China, Índia, Indonésia, República da Coreia, México, Rússia e Turquia. Consequentemente, os usualmente considerados países desenvolvidos do G20 são: Alemanha, Austrália, Canadá, EUA, França, Itália, Japão e Reino Unido.

Os dados secundários empregados na pesquisa foram retirados da plataforma Refinitiv® Eikon e se referiam aos anos de 2019 a 2022. Esse período foi selecionado por conter: o último ano pré-crise (2019), o ano da eclosão da crise sanitária de Covid-19 (2020), o ano entre crises (2021) e o ano da invasão da Ucrânia pela Rússia (2022). Em termos de amostra, foram selecionadas as empresas de cada país que apresentaram patrimônio líquido positivo ao longo do período, com o intuito de não incluir companhias que já apresentavam problemas econômico-financeiros prévios às crises. Foram coletados dados que possibilitaram calcular algumas das principais variáveis clássicas usadas como determinantes de endividamento citadas na fundamentação teórica: crescimento (CRES), lucratividade (LUC), necessidade de capital de giro (NCG) (usado como *proxy* de liquidez), risco (RISC) e tamanho (TAM). A operacionalização dessas variáveis é apresentada na Tabela 1. Salienta-se que as equações escolhidas para operacionalização das

variáveis foram selecionadas segundo a literatura e de forma a minimizar o número de dados ausentes que influenciariam a estimação dos modelos. Nesse sentido, não foram calculadas as variáveis relacionadas ao escudo fiscal não proveniente de dívidas nem tangibilidade dos ativos, devido a poucas observações contendo informações mais analíticas sobre despesas com depreciação e amortização, assim como de valores segregados de estoque e ativo imobilizado. Ressalta-se também que houve a exclusão de observações com dados ausentes.

Tabela 1: Operacionalização das variáveis

Variável	Operacionalização	Sinal esperado
END	$(Passivo\ Exigível - Patrimônio\ Líquido) \div Ativo\ Total$	Não se aplica
CRES	$Valor_{mercado} \div Valor_{contábil}$	+ / -
LUC	$EBIT \div Ativo\ Total$	+ / -
NCG	$(Clientes + Estoques - Fornecedores) \div Ativo\ Total$	+
RIS	$Cov(Retorno_{Ativo}, Retorno_{mercado}) \div Var(Retorno_{mercado})$	-
TAM	$\ln(Ativo\ Total)$	+

Fonte: elaborado pelos autores

Inicialmente, foram estimadas regressões múltiplas lineares (RL) por mínimos quadrados ordinários, 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 RL estimadas, foram aplicados os seguintes testes estatísticos recomendados por Gujarati e Porter (2011): (i) Breusch-Pagan – para verificar a existência de heteroscedasticidade; (ii) Durbin-Watson – para verificar a existência de autocorrelação dos resíduos; 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, também conforme recomendação de Gujarati e Porter (2011). Salienta-se que, no caso de problemas de normalidade, o número de observações possibilita a suposição de significância assintótica conforme os mesmos autores.

$$END_t = \beta_0 + \beta_1 \times CRES_t + \beta_2 \times LUC_t + \beta_3 \times NCG_t + \beta_4 \times RIS_t + \beta_5 \times TAM_t + \varepsilon \quad (1)$$

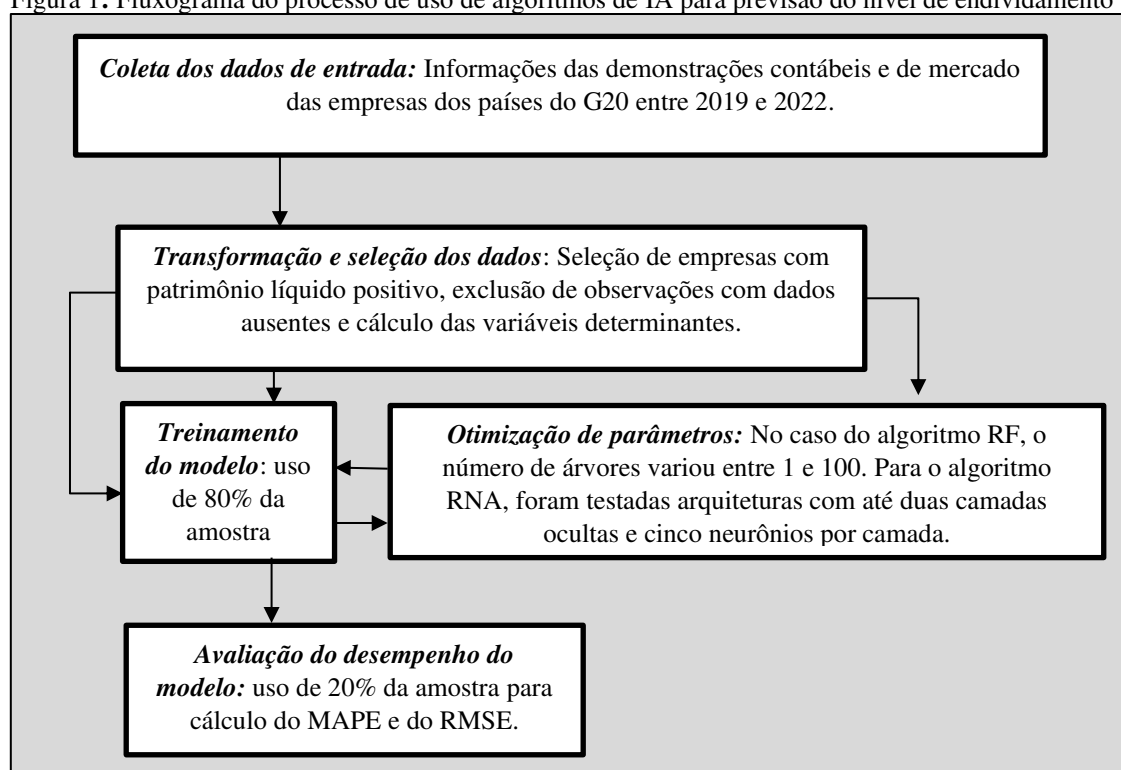
Todos os algoritmos de IA foram executados para fins de regressão, com o propósito de prever o nível de endividamento das empresas, empregando as mesmas variáveis apresentadas no Quadro 1. Para o treinamento dos modelos, foram usados 80% dos dados da amostra anualmente. Para estimar o desempenho desses modelos, optou-se pelas medidas do *Mean Absolute Percentage Error* (MAPE) (Equação 2) e do *Root Mean Squared Error* (RMSE) (Equação 3), que são usualmente usadas para avaliar o erro de modelos para fins de regressão, calculados a partir dos dados de teste (20% remanescente da amostra). Por se tratar de métricas de erro, quanto menor o valor, melhor o desempenho do modelo.

$$MAPE = \frac{1}{n} \sum_{i=1}^n [(|valor_{real}|_i - |valor_{predito}|_i) \div |valor_{real}|_i] \quad (2)$$

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (|valor_{real}|_i - |valor_{predito}|_i)^2} \quad (3)$$

Salienta-se que 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 100) 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 com até cinco neurônios por camada, como evidenciado por Faceli *et al.* (2021). Considerou-se, ainda, o número máximo de etapas para convergência de 10 milhões, sendo que, quando a convergência não era obtida com base nesse limite, o modelo foi estimado considerando apenas uma camada oculta de neurônios. Em ambos os algoritmos de IA, foi estimado um modelo para cada país anualmente. Na Figura 1, apresenta-se a forma de treinamento e teste dos modelos, conforme fluxograma básico de Ferreira *et al.* (2021).

Figura 1: Fluxograma do processo de uso de algoritmos de IA para previsão do nível de endividamento



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

Argentina, México e Rússia apresentaram um baixo número de observações (inferior a 10 por variável do modelo). Assim, ao se estimar os modelos de RL, observaram que alguns não foram considerados significantes de acordo com o Teste F. Dessa forma, optou-se por retirar estes países da amostra, uma vez que o baixo número de observações influenciaria de forma negativa o desenvolvimento de modelos de RL, conforme Hair Jr. *et al.* (2009). Desse modo, as análises foram realizadas, em corte transversal, com os 16 países remanescentes com dados de 11.944 empresas.

Foram aplicadas as seguintes técnicas para análise de dados: análise de regressão, estatística descritiva e teste de Mann-Whitney. A primeira técnica foi utilizada para se identificar a influência das variáveis clássicas determinantes do endividamento das empresas dos países do G20 em todos os períodos estudados (2019 a 2022). Por sua vez, a estatística descritiva foi empregada para descrever melhor os resultados gerais de desempenho da pesquisa. Por fim, o teste de Mann-

Whitney foi utilizado para comparar o desempenho dos diferentes modelos estimados. O nível de significância adotado em todos nos testes relacionados à análise de regressão foi de 5,0%. Já no caso do teste de Mann-Whitney, aplicou-se um nível de significância de 10,0% devido ao menor número de observações (máximo de 16 por grupo). Todos os dados foram tratados e analisados a partir de planilhas eletrônicas e do software 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). Por fim, no Tabela 2, é apresentada a relação entre objetivos específicos, hipóteses e técnicas estatísticas para a análise dos dados.

Tabela 2: Relação entre objetivos específicos, hipóteses e técnicas para a análise dos dados.

Objetivo específico	Hipótese	Técnica(s) de análise
Identificar a consistência das variáveis clássicas determinantes do endividamento das empresas ao longo do período analisado.	H1	Análise de regressão
Comparar a capacidade de predição do nível endividamento entre algoritmos de IA e técnicas estatísticas tradicionais.	H2	Estatística descritiva; análise de regressão e teste de Mann-Whitney.
Avaliar o desempenho dos modelos em prever o nível endividamento entre países desenvolvidos e emergentes.	H3	Estatística descritiva; e teste de Mann-Whitney
Discutir os resultados sob a perspectiva da literatura de Finanças.	-	Não se aplica

Fonte: elaborado pelos autores.

4 RESULTADOS

4.1 Variáveis determinantes do nível de endividamento

Primeiramente, é importante destacar que todos os modelos foram considerados significantes a menos de 5,0% pelo Teste F. Na Tabela 3, são evidenciados os resultados obtidos em todos os modelos por país anualmente. Ademais, a média do coeficiente de determinação ajustado (R^2 ajustado) foi de 20,7%. Ao se analisar os resultados da Tabela 3, destaca-se que a variável TAM, que foi significativa em praticamente todos os modelos nos anos de 2019, 2020 e 2022. O coeficiente positivo e significativo a menos de 1,0% nos modelos ao longo de todo o período reforça a consistência dessa variável em explicar o nível de endividamento das empresas independente do país nos referidos anos. Porém, especificamente no ano de 2021, essa variável deixou de ser significativa em muitos países e passou a apresentar um coeficiente negativo nos países em que foi significativa (especificamente, para China, Coreia do Sul, Índia, Indonésia, Itália e Japão), o que sinaliza certa retração de atividades das grandes empresas.

Por sua vez, a variável LUC também foi significativa nos modelos estimados pelos diversos anos para as empresas de vários países, sendo, em 2021, significativa em praticamente todos os países analisados (exceção de Austrália e Brasil). Neste ano, especificamente, seu coeficiente foi positivo em todos os modelos estimados, com associação positiva com o nível de endividamento das empresas, indicando maior financiamento de suas atividades com recursos próprios, com supremacia da POT em detrimento da TOT para explicação do fenômeno do endividamento. Porém, em todos os modelos dos demais anos (com exceção da Austrália em 2020), os coeficientes significantes dessa variável foram negativos. Este sinal do coeficiente da variável LUC foi consistente nos modelos estimados para os seguintes países: China, Coreia do Sul, EUA, Índia e Japão. Nesse sentido, há evidências da TOT em detrimento da POT para explicação do fenômeno,

com mais recursos de terceiros para financiar suas atividades, corroborando Aybar *et al.* (2023) e Prakash *et al.* (2023).

Já no que se refere à variável CRESC, seu coeficiente, quando significativo, foi sempre positivo para os modelos estimados. No caso da África do Sul e da Alemanha, especificamente, tal variável apresentou coeficiente positivo e significativo em todos os anos, indicando sua relação positiva para explicar o nível de endividamento das empresas. Novamente, observam-se evidências da POT em detrimento da TOT para explicação do fenômeno, com mais recursos de terceiros para financiar suas atividades, ratificando Aybar *et al.* (2023) e Prakash *et al.* (2023).

Um comportamento semelhante foi observado no que se refere à variável RISC, sendo o coeficiente estimado consistentemente positivo, contrário ao esperado, indicando que um maior risco estaria associado a um maior nível de endividamento, para modelos dos seguintes países: Coreia do Sul, Japão e Turquia. Todavia, ressaltam-se os coeficientes negativos encontrados nos modelos estimados para as empresas chinesas, indo ao encontro do esperado. Por fim, destaca-se a variável NCG, cujo coeficiente, apesar de baixo, influenciou de forma positiva e significativa o nível de endividamento de empresas de diversos modelos a partir de 2020, ao encontro do esperado. Isso ocorreu de forma consistente no que se refere os modelos estimados para as empresas japonesas e turcas, indicando a necessidade de financiamento do capital de giro para as operações das empresas após a crise da pandemia de Covid-19.

Em geral, observa-se a relevância das variáveis em explicar o nível de endividamento das empresas do G20, corroborando H1. Todas as variáveis selecionadas (com destaque para TAM e LUC) foram significantes em quase todos os modelos ao longo do tempo, ratificando sua importância para previsão do nível de endividamento corporativo mesmo em períodos de crise. Esses resultados corroboram estudos clássicos sobre variáveis determinantes do nível de endividamento corporativo como Titman e Wessels (1988) e Rajan e Zingales (1995), assim como estudos recentes, como Aybar *et al.* (2023) e Prakash *et al.* (2023).

4.2 Algoritmos de IA e técnicas estatísticas tradicionais para previsão do nível de endividamento

Na Tabela 4, salientam-se as estatísticas de desempenho dos modelos estimados com RL e com base em algoritmos de IA. É importante ressaltar que, por serem medidas de erro, os menores valores representam melhor desempenho. Observa-se que, consistentemente, os modelos estimados segundo esses algoritmos apresentaram resultados medianos superiores àqueles estimados com base em RL, pois os erros, calculados pelas medidas MAPE e RMSE, foram inferiores nas médias e nas medianas, nos quatro anos analisados, nos algoritmos de IA empregados na pesquisa em relação à técnica estatística tradicional RL. Complementarmente, nas figuras 2a e 2b, ressaltam-se, respectivamente, as medianas do MAPE e do RMSE dos modelos baseados em RL e em algoritmos de IA ao longo dos anos.

Tabela 3: Modelos de RL estimados para os anos de 2019 a 2022

País	Interc.	LUC	TAM	RIS	NCG	CRESC	R ²	Interc.	LUC	TAM	RIS	NCG	CRESC	R ²
	2019							2020						
África Sul	0,0602	-0,2791	0,0244	-0,2107*	0,0000	0,0434**	0,4523	-0,5867	-0,4541	0,0573*	-0,1274*	0,0000	0,0374**	0,6459
Alemanha	-0,1048	-0,0929	0,0329**	-0,0055	0,0000	0,0078**	0,1587	-0,1413	-0,1377	0,0338**	0,0201	0,0000	0,007**	0,2011
Ar. Saud.	-0,6185*	-0,5473	0,0453**	0,1707	0,0000	0,0026*	0,2070	-1,4448**	-0,1848	0,0762**	0,3121**	0,0000	0,0025	0,2775
Austrália	0,6174*	0,358**	-0,0142	0,0208	0,0000*	0,0285**	0,4068	0,2719	0,1616	0,0057	-0,0021	0,0000*	0,0078	0,2869
Brasil	-0,1870	-0,2061	0,036**	0,0191	0,0000	0,0001	0,0826	-0,2502	0,0731	0,0389**	0,0264	0,0000	0,0002	0,1204
Canadá	-0,1822	0,0673	0,0337**	-0,0095	0,0000	0,0051	0,1627	-0,1712	0,0470	0,0309**	0,0188	0,0000	0,0026	0,1166
China	-1,0991**	-0,6207**	0,0775**	-0,0032	0,0000	0,0009	0,3234	-1,0248**	-0,7476**	0,0743**	-0,0227**	0,0000	0,0037**	0,3045
Cor. Sul	-0,6737**	-0,6703**	0,0584**	0,0237*	0,0000	-0,0010	0,1726	-0,7761**	-0,6327**	0,0613**	0,0442**	0,0000	0,0023	0,2130
EUA	-0,363**	-0,122**	0,0435**	-0,0067	0,0000	0,0015	0,1856	-0,5815**	-0,1378**	0,0506**	0,0359**	0,0000	0,0019*	0,2355
França	-0,0930	-0,2351	0,0328**	0,0395	0,0000	-0,0093	0,1767	-0,0181	-0,4618**	0,029**	0,0371	0,0000	0,0000	0,1511
Índia	-0,1185	-0,4426**	0,0313**	0,0319*	0,0000	0,0000	0,1172	-0,0764	-0,404**	0,0273**	0,0383*	0,0000*	0,0001	0,1023
Indonésia	-0,3233*	-0,3863	0,0427**	-0,0017	0,0000	0,0011	0,0999	-0,4329**	-0,7721**	0,0487**	0,0004	0,0000	0,0031	0,1497
Itália	-0,1590	-0,2207	0,0368*	0,0438	0,0000	-0,0004	0,1262	-0,0490	-0,4026*	0,0287**	0,1265**	0,0000	0,0000	0,1686
Japão	0,0487	-0,6014**	0,0202**	0,038**	0,0000	0,0023	0,1079	0,0041	-0,7596**	0,0213**	0,0518**	0,0000*	0,0041	0,1502
Reino Un.	-0,2348	0,1161	0,0377**	-0,0136	0,0000	0,0037	0,2044	-0,3573	-0,0331	0,0416**	0,0228	0,0000	0,0079	0,2193
Turquia	-0,0209	-0,0210	0,0242**	0,1388**	0,0000	-0,0003	0,0795	-0,1084	0,2680	0,0268**	0,1351**	0,0000*	-0,0002	0,0866
País	2021							2022						
África Sul	-0,1758	0,0357	-0,1350	-0,1604**	0,0000	0,0504**	0,8019	0,3817	-0,3023	0,0088	-0,1322*	0,0000	0,0555**	0,6392
Alemanha	-0,1120	0,0323**	-0,1399	0,0036	0,0000	0,0065**	0,1407	-0,1120	0,0323**	-0,1399	0,0036	0,0000	0,0065**	0,1407
Ar. Saud.	-1,2999**	0,0767**	-0,2576	0,183**	0,0000	0,0034	0,2239	-1,415**	-0,3567	0,0799**	0,1825*	0,0000*	0,0332*	0,1736
Austrália	0,4433	-0,0041	0,3744**	0,0038	0,0000	0,0110	0,4186	0,1044	0,1620	0,0130	0,0258	0,0000	0,0220	0,0675
Brasil	-0,2502	0,0731	0,0389**	0,0264	0,0000	0,0002	0,1204	-0,2889	-0,3285	0,0386**	0,0773*	0,0000	0,0149	0,1869
Canadá	-0,1474	0,0279**	-0,0040	0,0139	0,0000	0,0173**	0,1283	-0,0587	-0,0421	0,0246**	0,0012	0,0000	0,0258**	0,1227
China	-0,9861**	0,0727**	-0,709**	-0,0342**	0,0000	0,0045**	0,3047	-0,9697**	-0,8821**	0,0723**	-0,0287**	0,0000	0,0047	0,3122
Cor. Sul	-0,7302**	0,0596**	-0,5599**	0,0333**	0,0000	0,0041	0,1933	-0,8719**	-0,5957**	0,0656**	0,0429**	0,0000**	0,0144	0,2099
EUA	-0,6603**	0,0538**	-0,0952	0,0382**	0,0000*	0,0014	0,2744	-0,5497**	-0,2085**	0,0502**	0,0292**	0,0000	0,0005	0,1936
França	0,0053	0,0254**	-0,2554	0,0644**	0,0000	0,0029	0,1434	0,0675	-0,3616**	0,0226**	0,0704*	0,0000	-0,0003	0,1525
Índia	-0,0338	0,0256**	-0,3968**	0,0299	0,0000**	0,0001	0,0930	-0,1261	-0,4226**	0,0304**	0,0207	0,0000	0,0004	0,1202
Indonésia	-0,4144*	0,0485**	-0,5885**	0,0000	0,0000	0,0005	0,1227	-0,3732*	-0,5299**	0,0465**	0,0018	0,0000	0,0007	0,1080
Itália	-0,1168	0,0339**	-0,9554**	0,0816**	0,0000	0,0129**	0,2202	-0,0271	-0,663**	0,0278**	0,1185**	0,0000	0,0142*	0,1897
Japão	0,0236	0,0205**	-0,6392**	0,0457**	0,0000*	0,0027	0,1351	0,0474	-0,6773**	0,0196**	0,0412**	0,0000*	0,0065**	0,1369
Reino Un.	-0,3215	0,0379**	0,1577	0,0301	0,0000	0,0073	0,2187	-0,2827	-0,0254	0,0367**	0,0323	0,0000	0,0079**	0,2450
Turquia	-0,0697	0,0249*	0,1026	0,1521**	0,0000*	-0,0003	0,1114	0,0250	0,0621	0,0186*	0,1582**	0,0000**	-0,0001	0,0879

Fonte: elaborada pelos autores.

* Significante a 5,0%; e ** Significante a 1%

Tabela 4: Estatísticas de desempenho dos modelos estimados

Medida/ Ano	MAPE / 2019	RMSE / 2019	MAPE / 2020	RMSE / 2020	MAPE / 2021	RMSE / 2021	MAPE / 2022	RMSE / 2022
Modelos baseados em RL								
Média	0,5578	0,2023	0,5304	0,2576	0,6987	0,3844	0,5408	0,1963
DP	0,3174	0,0637	0,2443	0,2415	0,7254	0,7525	0,2769	0,0445
CV	0,5690	0,3147	0,4605	0,9376	1,0381	1,9575	0,5121	0,2266
Mediana	0,4749	0,1947	0,5129	0,2041	0,4889	0,1893	0,4889	0,1952
Máximo	1,3132	0,4192	1,1254	1,1848	3,2023	3,2955	1,3051	0,3378
Mínimo	0,1451	0,1128	0,1490	0,1097	0,1140	0,1008	0,1330	0,1140
Modelos baseados em RF								
Média	0,5588	0,1669	0,5127	0,1682	0,5155	0,1673	0,4698	0,1672
DP	0,3949	0,0343	0,3810	0,0262	0,3417	0,0248	0,2123	0,0251
CV	0,7067	0,2057	0,7431	0,1555	0,6627	0,1482	0,4519	0,1501
Mediana	0,4519	0,1780	0,4569	0,1749	0,4440	0,1726	0,4427	0,1734
Máximo	1,7735	0,2128	1,8295	0,2063	1,6010	0,2017	0,8274	0,2089
Mínimo	0,1316	0,0960	0,1183	0,1072	0,1206	0,1061	0,1178	0,1115
Modelos baseados em RNA								
Média	0,6151	0,1685	0,5181	0,1706	0,5711	0,1705	0,4730	0,1686
DP	0,6713	0,0310	0,3669	0,0389	0,5044	0,0255	0,2342	0,0270
CV	1,0914	0,1840	0,7081	0,2282	0,8833	0,1493	0,4951	0,1604
Mediana	0,4694	0,1823	0,4757	0,1848	0,4765	0,1755	0,4403	0,1770
Máximo	3,1019	0,2020	1,7272	0,2036	2,3521	0,2051	0,9681	0,2047
Mínimo	0,1630	0,0854	0,0942	0,0478	0,1431	0,1147	0,1374	0,1090

Fonte: elaborada pelos autores.

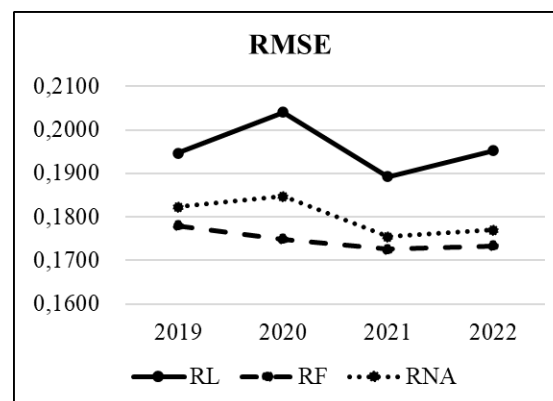



Figura 2a: Evolução do desempenho mediano calculado pelo MAPE para os modelos estimados

Figura 2b: Evolução do desempenho mediano calculado pelo RMSE para os modelos estimados

Considerando as referidas figuras, reforça-se a superioridade do desempenho mediano dos modelos baseados em algoritmos de IA em relação ao RL ao longo do tempo. No caso do RMSE, verifica-se uma grande diferença nesse desempenho no ano de 2020. Já no caso do MAPE, os modelos baseados nos algoritmos de RF foram superiores aos baseados em RNA até o ano de 2021.

Para verificar se os modelos de IA apresentaram um desempenho efetivamente superior ao modelo de RL, empregou-se o teste de Mann-Whitney. Nesse caso, apenas nos anos de 2020 e 2022, foi possível confirmar uma superioridade do desempenho estatisticamente significativa dos modelos baseados em RF em relação àqueles baseados em RL, corroborando os estudos de Clarke *et al.* (2020) e Singh e Khushi (2021). Destaca-se, ainda, que os modelos baseados em RNA, em nenhum ano, foram estatisticamente superiores aos demais, ratificando os resultados de Jaggi *et al.* (2021). Dessa forma, H2 não pode ser ratificada haja vista as evidências apresentadas.

4.3 Desempenho dos modelos considerando países desenvolvidos e emergentes

Na Tabela 5, demonstram-se as estatísticas de desempenho dos modelos estimados com RL e com base em algoritmos de IA ao longo dos anos, considerando a segregação em países emergentes (África do Sul, Arábia Saudita, Brasil, China, Coreia do Sul, Índia, Indonésia e Turquia) e desenvolvidos (Alemanha, Austrália, Canadá, EUA, França, Itália, Japão e Reino Unido), grupo que engloba também todos os membros do G7. Em complemento, as figuras 3a e 3b, são demonstradas, respectivamente, as medianas do MAPE e do RMSE dos modelos baseados em RL e em algoritmos de IA.

Pela análise do MAPE (Figura 3a), os valores medianos de desempenho dos modelos estimados para os países desenvolvidos sempre foram superiores àqueles estimados para os países emergentes independentemente do uso ou não de algoritmos de IA. No caso do RMSE (Figura 3b), também há superioridade do desempenho mediano para os países desenvolvidos em relação os países emergentes, mas os resultados provenientes do RNA e da RF para estes para 2020 e 2022 foram superiores em relação aos resultados oriundos da RL para aqueles.

No intuito de verificar se os modelos estimados para os países desenvolvidos apresentaram um desempenho efetivamente superior aos estimados para os países emergentes, empregou-se o teste de Mann-Whitney. Nesse caso, observou-se que, nos anos de 2019 e 2021, todos os modelos baseados em RF estimados para os países desenvolvidos foram superiores àqueles estimados para os países emergentes, considerando o MAPE. No caso dos modelos baseados em RNA, foram constatadas diferenças estatisticamente significantes em 2019 do modelo para países desenvolvidos em relação aos emergentes (também considerando o MAPE como métrica de desempenho). Por fim, no caso dos modelos baseados em RL, verificou-se uma superioridade dos modelos estimados para países desenvolvidos em relação ao emergentes de acordo com a métrica RMSE em 2021.

Esses resultados podem ser explicados devido à maior eficiência de mercado e da qualidade da informação contábil nos países desenvolvidos em relação aos emergentes, tal como evidenciado por Al-Enzy *et al.* (2023), Nazlioglu *et al.* (2023) e Viana Jr. *et al.* (2023). A qualidade das informações tem efeito direto na qualidade dos modelos estimados. Dessa forma, H3 é corroborada de forma parcial.




Figura 3a: Evolução do desempenho médio calculado pelo MAPE para os modelos estimados por bloco de países

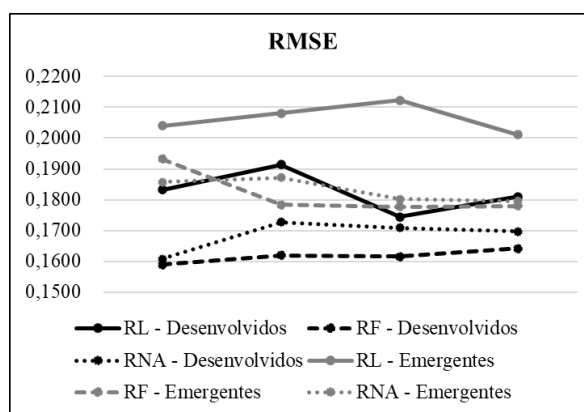


Figura 3b: Evolução do desempenho médio calculado pelo RMSE para os modelos estimados por bloco de países

Tabela 5: Estatísticas de desempenho dos modelos estimados considerando a segregação em países desenvolvidos e emergentes

Países		DESENVOLVIDOS								EMERGENTES							
		Medida/ Ano	MAPE /2019	RMSE /2019	MAPE /2020	RMSE /2020	MAPE /2021	RMSE /2021	MAPE /2022	RMSE /2022	MAPE /2019	RMSE /2019	MAPE /2020	RMSE /2020	MAPE /2021	RMSE /2021	MAPE /2022
Modelos baseados em RL	Média	0,4861	0,1775	0,4249	0,1898	0,5334	0,5546	0,4548	0,1951	0,6295	0,2271	0,6359	0,3253	0,8640	0,2142	0,6267	0,1976
	DP	0,3024	0,0371	0,1571	0,0420	0,4457	1,0363	0,2252	0,0610	0,3158	0,0742	0,2690	0,3251	0,8939	0,0243	0,2964	0,0152
	CV	0,6221	0,2089	0,3698	0,2214	0,8356	1,8687	0,4951	0,3127	0,5017	0,3266	0,4230	0,9992	1,0346	0,1135	0,4730	0,0772
	Mediana	0,4688	0,1833	0,4624	0,1914	0,4635	0,1745	0,4632	0,1811	0,5283	0,2041	0,5324	0,2081	0,5270	0,2123	0,5457	0,2011
	Máximo	1,2151	0,2381	0,6206	0,2571	1,6525	3,2955	0,9088	0,3378	1,3132	0,4192	1,1254	1,1848	3,2023	0,2606	1,3051	0,2152
	Mínimo	0,1451	0,1128	0,1490	0,1097	0,1140	0,1008	0,1330	0,1140	0,2549	0,1745	0,2622	0,1759	0,2770	0,1783	0,2393	0,1607
Modelos baseados em RF	Média	0,4090	0,1579	0,3503	0,1591	0,3634	0,1581	0,3887	0,1592	0,7086	0,1760	0,6751	0,1772	0,6677	0,1765	0,5510	0,1753
	DP	0,2618	0,0336	0,1503	0,0290	0,1504	0,0256	0,2056	0,0250	0,4455	0,0326	0,4637	0,0191	0,4056	0,0201	0,1863	0,0225
	CV	0,6401	0,2129	0,4289	0,1824	0,4138	0,1620	0,5290	0,1568	0,6287	0,1854	0,6868	0,1075	0,6075	0,1138	0,3381	0,1285
	Mediana	0,3795	0,1590	0,3732	0,1619	0,4092	0,1616	0,3890	0,1642	0,6601	0,1932	0,5403	0,1784	0,5277	0,1778	0,6023	0,1780
	Máximo	1,0345	0,2128	0,5860	0,2063	0,6106	0,1945	0,8274	0,1879	1,7735	0,1989	1,8295	0,2055	1,6010	0,2017	0,8026	0,2089
	Mínimo	0,1316	0,1025	0,1183	0,1072	0,1206	0,1061	0,1178	0,1115	0,1783	0,0960	0,2807	0,1375	0,2806	0,1352	0,2754	0,1304
Modelos baseados em RNA	Média	0,3669	0,1634	0,3790	0,1695	0,3725	0,1622	0,4157	0,1632	0,8634	0,1737	0,6571	0,1717	0,7697	0,1788	0,5304	0,1739
	DP	0,1400	0,0248	0,1597	0,0260	0,1526	0,0267	0,2479	0,0304	0,8710	0,0354	0,4528	0,0485	0,6378	0,0211	0,2042	0,0219
	CV	0,3816	0,1516	0,4214	0,1535	0,4096	0,1647	0,5964	0,1861	1,0088	0,2040	0,6890	0,2825	0,8287	0,1180	0,3849	0,1262
	Mediana	0,3758	0,1608	0,4065	0,1727	0,4265	0,1709	0,3873	0,1697	0,5931	0,1858	0,5641	0,1872	0,5285	0,1802	0,5219	0,1796
	Máximo	0,5974	0,1961	0,6619	0,2027	0,5695	0,1956	0,9681	0,2047	3,1019	0,2020	1,7272	0,2036	2,3521	0,2051	0,8624	0,1940
	Mínimo	0,1704	0,1299	0,1514	0,1241	0,1431	0,1147	0,1374	0,1090	0,1630	0,0854	0,0942	0,0478	0,2898	0,1376	0,2171	0,1248

Fonte: elaborada pelos autores.

5 CONCLUSÕES

A pesquisa cujos resultados foram apresentados neste trabalho visou avaliar o desempenho de algoritmos de IA para previsão do nível de endividamento de empresas em períodos de crise (a pandemia de Covid-19 e a invasão russa à Ucrânia). Para isso, foram analisados dados de 11.944 empresas de países que fazem parte do G20 entre 2019 e 2022 e estimados modelos com base em RL e em dois algoritmos de IA: RF e RNA.

Os resultados evidenciaram que as variáveis clássicas selecionadas como determinantes do nível de endividamento corporativo foram significantes de forma consistente durante todo o período de análise nos modelos segregados por país, ratificando sua importância para explicação desse fenômeno mesmo em períodos de crises. Por outro lado, ao contrário do esperado segundo a literatura, os modelos estimados com base em algoritmos de IA não apresentaram desempenhos significativos e consistentemente superiores aos modelos baseados em RL durante todo o período de análise, de acordo com o teste de Mann-Whitney. Contudo, verificou-se que os modelos baseados em tais algoritmos estimados para empresas de países desenvolvidos tenderam a apresentar desempenho superior àqueles estimados para empresas de países emergentes em 2019 e 2021, o que pode ser associado à maior qualidade da informação contábil e eficiência de mercado para aquele primeiro grupo de países.

Os resultados da pesquisa contribuem de forma relevante para o estudo do fenômeno de endividamento corporativo sob diferentes perspectivas. Primeiramente, analisaram-se empresas de países do G20, grupo cujo papel político e econômico é extremamente relevante no contexto global. Ademais, avaliou-se o desempenho de modelos para previsão de nível de endividamento em períodos distintos, considerando duas graves crises recentes. Além disso, utilizaram-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 e de estatísticas tradicionais para análise do fenômeno do endividamento empresarial.

A pesquisa, todavia, também apresenta algumas limitações a serem destacadas: (a) os critérios adotados para seleção da amostra implicaram exclusão das empresas de três países do G20; (b) as crises da pandemia de Covid-19 e da invasão russa à Ucrânia ainda geram efeitos econômicos, que podem não ter sido totalmente apreendidos; (c) foram usados dados transversais para análise, devido às limitações inerentes aos algoritmos de IA empregados em lidar com dados longitudinais; e (d) apesar de amplamente utilizadas, as métricas usadas para prever o nível de endividamento são apenas algumas das possíveis medidas disponíveis na literatura. Assim, sugere-se que pesquisas futuras considerem outras *proxies* de endividamento, 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 (especialmente, os emergentes que não fazem parte do G20), possibilitaria uma comparação dos resultados obtidos.

REFERÊNCIAS

- Al Ani, M. K. (2021). Earnings quality and foreign investors in gulf cooperation council countries. *Contemporary Management Research*, 17(3), 223-270.
- Al-Enzy, N. S. K., Monem, R., & Nahar, S. (2023). IFRS experience and earnings quality in the GCC region. *International Journal of Managerial Finance*, 19(3), 670-690.
- Alnori, F. (2023). Financial shock and the United States multinational and domestic corporations leverage. *Cogent Economics & Finance*, 11(1), 2210364.

- Avelar, E. A., Campos, O. V., Orefici, J. B. P., Borges, S. L., & Souza, A. A. (2022). Inteligência artificial e previsão de preços de ativos financeiros: uma revisão sistemática. *Sistemas & Gestão*, 17(3).
- Aybar, B., Deligonul, S., & An, B. (2023). Financial Crises and Capital Structure Decisions: Empirical Evidence from Emerging Markets. *Journal of Asia-Pacific Business*, 24(1), 19-38.
- Benachenhou, A. (2013). *Países emergentes*. Brasília: FUNAG. Recuperado de: https://funag.gov.br/biblioteca-nova/produto/1-142-paises_emergentes.
- Boina, T. M., & Macedo, M. A. da S. (2018). Capacidade preditiva de accruals antes e após as IFRS no mercado acionário brasileiro. *Revista Contabilidade & Finanças*, 29(78), 375-389.
- Borges, M. R. (2010). Efficient market hypothesis in European stock markets. *The European Journal of Finance*, 16(7), 711-726.
- Cao, H., Lin, T., Li, Y., & Zang, H. (2019). Stock Price Pattern Prediction Based on Complex Network and Machine Learning. *Complexity*. 1–12.. <https://doi.org/10.1155/2019/4132485>
- Chaney, P. K., Faccio, M., & Parsley, D. (2011). The quality of accounting information in politically connected firms. *Journal of Accounting and Economics*, 51(1-2), 58-76.
- Clarke, J., Chen, H., Du, D., & Hu, Y. J. (2020). Fake news, investor attention, and market reaction. *Information Systems Research*, 32(1), 35-52.
- Coppin, B. (2010). *Inteligência Artificial* (1. ed.). Rio de Janeiro: LTC.
- Dechow, P. M., & Schrand, C. M. (2004). *Earnings quality*. Charlottesville, VA: The Research Foundation of CFA Institute. Retirado de: <http://csinvesting.org/wp-content/uploads/2015/04/Defining-Earnings-Quality-CFA-Publication.pdf>
- Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A., & Carvalho, A. C. P. L. F. (2021). *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina* (2. ed.) Rio de Janeiro: LTC.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417.
- Ferreira, F. G. D. C., Gandomi, A. H., & Cardoso, R. T. N. (2021). Artificial intelligence applied to stock market trading: a review. *IEEE Access*, 9, 30898-30917.
- FMI. (2023). *World Economic Outlook*: Fundo Monetário Internacional. Recuperado de: <https://www.imf.org/en/Publications/WEO>.
- Frank, M. Z., & Goyal, V. K. (2009). Capital Structure Decisions: Which Factors are Reliably Important?. *Financial Management*, 38(1), 1-37.
- G20. Membros do G20. <https://www.g20.org/pt/about-g20/>. Acesso em 15 maio 2023.
- Gujarati, D. N., & Porter, D. C. (2011). *Econometria básica*. (5. ed.) Porto Alegre: AMGH.
- Hair Jr., J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2009). *Análise Multivariada de Dados*. (6. ed.) Porto Alegre: Bookman.
- Homapour, E., Su, L., Caraffini, F., & Chiclana, F. (2022). Regression analysis of macroeconomic conditions and capital structures of publicly listed British firms. *Mathematics*, 10(7), 1119.
- Jaggi, M., Mandal, P., Narang, S., Naseem, U., & Khushi, M. (2021). Text mining of stocktwits data for predicting stock prices. *Applied System Innovation*, 4(1), 13.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2023). *An introduction to statistical learning: with Applications in R*. (2. ed.) New York: springer.
- Jang, H., & Lee, J. (2019). Machine learning versus econometric jump models in predictability and domain adaptability of index options. *Physica A: Statistical Mechanics and its Applications*, 513, 74-86.
- Lemmon, M. L., & Zender, J. F. (2010). Debt Capacity and Tests of Capital Structure Theories. *Journal of Financial and Quantitative Analysis*, 45(5), 1161–1187.
- Modigliani, F., & Miller, M. H. (1958). The cost of capital, corporation finance and the theory of investment. *The American economic review*, 48(3), 261-297.

- Modigliani, F., & Miller, M. H. (1963). Corporate income taxes and the cost of capital: a correction. *The American economic review*, 53, 433-443.
- Mody, A. (2004). *What is An Emerging Market?*. Working Paper n. 2004/177. Recuperado de: <https://www.imf.org/en/Publications/WP/Issues/2016/12/31/What-is-An-Emerging-Market-17598>.
- Myers, S. C. The Capital Structure Puzzle. (1984). *The Journal of Finance*, 39(3), 575-592.
- Namin, S. S., & Namin, A. S. (2018). *Forecasting Economic and Financial Time Series: Arima vs. LSTM*. Cornell University. <https://doi.org/10.48550/arXiv.1803.06386>
- Nazlioglu, S., Pazarci, S., Kar, A., & Varol, O. (2023). Efficient market hypothesis in emerging stock markets: gradual shifts and common factors in panel data. *Applied Economics Letters*, 1-7.
- Nguyen, L. T. M., Le, D., Vu, K. T., & Tran, T. K. (2023). The role of capital structure management in maintaining the financial stability of hotel firms during the pandemic—A global investigation. *International Journal of Hospitality Management*, 109, 103366.
- Nielsen, M. (2019). *Neural Networks and Deep Learning*. Recuperado de: <http://neuralnetworksanddeeplearning.com>
- Prakash, N., Maheshwari, A., & Hawaldar, A. (2023). The impact of Covid-19 on the capital structure in emerging economies: evidence from India. *Asian Journal of Accounting Research*, 8(3), 236-249.
- Rajan, R. G., & Zingales, L. (1995). What Do We Know about Capital Structure? Some Evidence from International Data. *The Journal of Finance*, 50(5), 1421-1460.
- Ross, S. A., Westerfield, R. W., Jaffe, J., & Lamb, R. (2015). *Administração financeira*. (10. ed.) São Paulo: AMGH Editora.
- Rundo, F., Trenta, F., Di Stallo, A. L., & Battiato, S. (2019). Machine learning for quantitative finance applications: A survey. *Applied Sciences*, 9(24), 5574.
- Sadorsky, P. (2021). A random forests approach to predicting clean energy stock prices. *Journal of Risk and Financial Management*, 14(2), 48.
- Sampieri, R. H., Collado, C. H., & Lucio, P. B. (2006). *Metodologia de pesquisa*. (3. ed.) São Paulo: MacGraw-Hill.
- Sánchez-Granero, M. A., Balladares, K. A., Ramos-Requena, J. P., & Trinidad-Segovia, J. E. (2020). Testing the efficient market hypothesis in Latin American stock markets. *Physica A: Statistical Mechanics and its Applications*, 540, 123082.
- Shynkevich, Y., McGinnity, T. M., Coleman, S., Li, Y & Belatreche, A. (2017). Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*, 264, 71–88.
- Singh, J., & Khushi, M. (2021). Feature learning for stock price prediction shows a significant role of analyst rating. *Applied System Innovation*, 4(1), 17.
- Titman, S., & Wessels, R. (1988). The Determinants of Capital Structure Choice. *The Journal of Finance*, 43(1), 1-19.
- Viana Jr, D. B. C., Lourenço, I., Black, E. L., & Martins, O. S. (2023). Macroeconomic instability, institutions, and earnings management: An analysis in developed and emerging market countries. *Journal of International Accounting, Auditing and Taxation*, 51, 100544.