

Utilização de Inteligência Artificial na previsão do estresse fiscal: evidências para municípios brasileiros

Daniel Vitor Tartari Garruti¹ , Flávio Luiz de Moraes Barboza² , Josedilton Alvez Diniz³ 

^{1,2} Universidade Federal de Uberlândia, Uberlândia, Minas Gerais, Brasil.

² Universidade Federal da Paraíba, João Pessoa, Paraíba, Brasil.



¹daniel.garruti@ufu.br

²flmbarboza@ufu.br

³josedilton@gmail.com

Editado por:
Cláudia Cruz

Resumo

Objetivo: Utilizar o modelo proposto por Trussel e Patrick (2018), juntamente com os fatores propostos por Groves et al. (1981) e Groves e Valente (2003), adaptadas à realidade brasileira, para prever o estresse fiscal em municípios de Minas Gerais entre 2016 e 2020.

Método: Foi utilizado o modelo Random Forest (RF), uma técnica de aprendizado de máquina da família das Árvores de Decisão, para prever estresse fiscal nos municípios de Minas Gerais. Essa escolha se deve ao seu sucesso recente em problemas de previsão.

Resultados: O modelo apresentou uma taxa de acerto média de 68,2%. Com a definição de pontos de corte, foi possível alcançar uma taxa de precisão antecipada de até 85%. O modelo foi mais eficaz na previsão da ocorrência de estresse fiscal do que na ausência desse problema. No entanto, os resultados variaram significativamente entre os diferentes períodos analisados. As variáveis mais importantes foram relacionadas à categoria de liquidez, enquanto as variáveis organizacionais e ambientais demonstraram ter baixa importância. Esses resultados corroboram e contradizem alguns autores, além de superar alguns artigos.

Contribuições: Este artigo apresenta duas inovações: a aplicação de técnicas de Inteligência Artificial (IA) em pesquisas sobre a Condição Financeira Governamental no Brasil e a previsão do estresse fiscal em municípios brasileiros.

Palavras-chave: Condição Financeira Governamental; Condição Fiscal; Entes Subnacionais; Inteligência Artificial; Random Forest.

Como Citar:

Garruti, D. V. T., Barboza, F. L. de M., & Diniz, J. A. (2024). Utilização de Inteligência Artificial na previsão do estresse fiscal: evidências para municípios brasileiros. *Advances in Scientific and Applied Accounting*, 17(3), 152–165/166. <https://doi.org/10.14392/asaa.2024170307>

Submetido em: 13 de Abril de 2023
Revisões Requeridas em: 10 de Outubro de 2023
Aceito em: 13 de Dezembro de 2023

Introdução

O tema da Condição Financeira Governamental surgiu nos Estados Unidos no século passado, em meio a crises enfrentadas pelos governos locais (Clark, 1994). Porém, esse assunto é ainda recente no Brasil e começou a ser debatido na literatura local após a publicação de Lima e Diniz (2016). É fundamental que um ente subnacional possua saúde financeira, o que implica estar em dia com os pagamentos e oferecer serviços públicos de qualidade que atendam às expectativas da sociedade (Lima & Diniz, 2016).

Parte da Condição Financeira Governamental, a condição fiscal está relacionada apenas ao resultado financeiro, verificando se as receitas são suficientes para cobrir as despesas (Bowman & Calia, 1997). Destaca-se que a falta de recursos pode levar a queda de qualidade das atividades básicas que devem ser oferecidas (McDonald & Larson, 2020), isso ocorre porque um município em situação de estresse fiscal enfrenta dificuldades, como restrição ao crédito, pagamento de juros elevados, deterioração da liquidez e risco de agravar sua situação financeira (Leiser et al., 2021). Logo, uma gestão apropriada dos recursos favorece a geração de emprego e renda, e, consequentemente, diminui seu próprio risco de inadimplência (Bisogno et al., 2019; Navarro-Galera et al., 2020).

Conforme Dantas Junior et al. (2019), uma das formas de avaliar se as receitas governamentais são suficientes para cobrir as despesas é o stress test proposto por Bowman e Calia (1997). Caso o resultado do teste seja negativo, conclui-se que a localidade está em estresse fiscal.

Trussel e Patrick (2018) propuseram um modelo com 21 variáveis, a maioria financeiras, que classificou corretamente a probabilidade de estresse fiscal em até 99% dos entes subnacionais americanos. Chen (2021) utilizou técnicas de IA para prever o estresse fiscal em governos chineses, alcançando uma taxa de acerto de aproximadamente 85%.

A preocupação global com o tema tem se destacado, refletindo um aumento de interesse no contexto brasileiro. Isso se evidencia por meio da iniciativa da Secretaria do Tesouro Nacional com o Tesouro Nacional Transparente (Brasil, 2022), que, a partir de 2017, publica uma análise da dívida consolidada.

No cenário dos municípios mineiros, observa-se uma diversidade nas estruturas socioeconômicas, o que resulta em disparidades na arrecadação (Costa et al., 2015; Vieira et al., 2021). Cabe ressaltar que o referido estado abriga a maior concentração de entidades subnacionais no Brasil (Vieira et al., 2021).

Diante da relevância do estresse fiscal para a gestão pública e a necessidade de aprimorar as técnicas

de previsão desse fenômeno, aplicou-se a técnica de RF na previsão do problema em municípios mineiros. Utilizou-se como ponto de partida o modelo proposto por Trussel e Patrick (2018), com adaptações ao contexto brasileiro e a inclusão de fatores propostos por Groves et al. (1981) e Groves e Valente (2003).

Os resultados indicaram que o modelo apresentou maior precisão na previsão de estresse fiscal (taxa média de acertos de 68,4%), quando comparada à previsão de situações de não estresse (49,2%). É importante ressaltar que esses resultados foram impactados pela crise da Covid-19, apresentando mudanças significativas. A acurácia de previsão do problema também foi superior à classificação inicial da amostra de 2011 proposta por Trussel e Patrick (2018). A média geral de acertos (acurácia) alcançada pelo modelo foi de 65,8%. No entanto, ao realizar a aplicação de pontos de corte baseados na probabilidade de ocorrência do evento, os resultados apresentaram melhora, chegando a acurácia de 85%. É válido destacar que esse resultado é semelhante ao encontrado por Chen (2021).

Ademais, as três variáveis mais relevantes estão relacionadas à liquidez, confirmando o resultado obtido por Iacuzzi (2022) e sustentando a visão de Lima e Diniz (2016) de que a variável posição operacional não pode ser considerada como dependente, como realizado no estudo de McDonald e Larson (2020). No entanto, a importância média das mesorregiões do estado foi a menor entre as variáveis, o que contradiz os achados de Antulov-Fantulin et al. (2021).

Destacam-se duas contribuições deste estudo para a literatura: a aplicação de IA nesta área e a previsão de estresse fiscal em municípios brasileiros; dois pontos que, até o momento, não foram encontrados na literatura nacional.

Uma implicação desta pesquisa é a antecipação do estresse fiscal, permitindo que os governantes gerenciem melhor as finanças e se planejem para evitar o problema. A população também pode acompanhar a condição do seu município, evitando possíveis quedas na qualidade e/ou quantidade dos serviços essenciais.

Apesar de tais contribuições, destacam-se como limitações deste estudo o tamanho da amostra, período analisado e a confiabilidade dos dados. Vale mencionar que o regime de competência não foi completamente adotado pelos municípios brasileiros (Costa & Leão, 2021). Isso desempenha um papel crucial no setor público, fornecendo informações sobre transações passadas, obrigações futuras e facilitando a tomada de decisões econômicas (Cruvinel & Lima, 2011). Contudo, é fundamental compreender que essa limitação não invalida as informações patrimoniais; ao contrário, enfatiza a importância de uma análise criteriosa.

Além da introdução, este artigo está estruturado em: Condição Financeira Governamental e condição fiscal, como corpo teórico; a metodologia, que detalha as técnicas empregadas na pesquisa; os resultados; e, por fim, as conclusões.

2 Condição Financeira Governamental

O debate sobre a Condição Financeira Governamental começou nos Estados Unidos, após a crise de Nova Iorque nos anos 70, que resultou em alta inflação e dificuldades para os governos locais (Clark, 1994; Groves et al., 1981). Desde então, houve interesse crescente da população e dos governantes pelo assunto, já que momentos turbulentos na economia podem afetar a gestão pública e a prestação de serviços essenciais (McDonald & Larson, 2020; Turley et al., 2020). Apesar disso, somente nos anos 90 os acadêmicos passaram a se dedicar mais ao tema (Lima & Diniz, 2016).

De acordo com Groves e Valente (2003), para uma localidade ser considerada financeiramente saudável, é necessário garantir a qualidade dos serviços essenciais tanto no curto como no longo prazo, bem como resistir a momentos de instabilidade econômica e pressões da população. O estudo seminal de Groves et al. (1981) apresenta uma das maneiras mais abrangentes de análise da Condição Financeira Governamental, que é afetada por três fatores: financeiros, organizacionais e ambientais.

O teste dos dez pontos da Condição Financeira é uma das maneiras de avaliação, desenvolvido por Brown (1993), contempla variáveis relacionadas a receitas, despesas, estrutura de endividamento e posição operacional. Posteriormente, García-Sánchez et al. (2012) verificaram que o modelo de Kloha et al. (2005), acrescido de duas variáveis referentes à independência financeira, propostas por Zafra-Gómez et al. (2009), apresentou o melhor desempenho na análise da condição financeira.

Apesar do tempo que se desenvolvem, as pesquisas sobre o assunto são ainda recentes no Brasil, obtendo o estudo de Lima e Diniz (2016) como pioneiro. O tema começou a ser discutido em períodos de instabilidade econômica do país, como nos anos de 2015 e 2016, considerados de baixo crescimento (Dantas Junior et al., 2019). Além disso, o país passava por um momento turbulento na política, com o impeachment presidencial e a perda de confiança na classe política (Jucá & Fishlow, 2021).

De acordo com Lima e Diniz (2016), a boa Condição Financeira Governamental se dá quando o governo cumpre suas obrigações de pagamento e mantém o funcionamento adequado dos serviços públicos, atendendo às expectativas da sociedade em termos de qualidade. Os autores apontam que este assunto é complexo e influenciado tanto por fatores internos quanto externos. Ou seja, alguns desses fatores estão sob controle dos

governantes, enquanto outros não, como períodos de crise.

Este assunto ganhou notoriedade em época de instabilidades econômicas nos municípios americanos (Clark, 1994). Após a crise financeira internacional de 2008, a preocupação acerca da temática aumentou (Antulov-Fantulin et al., 2021; Chung & Williams, 2021). De acordo com Afonso e Jalles (2020), instabilidades pressionam as autoridades fiscais a agir ativamente para controlar a dívida, atuando como um mecanismo disciplinador, como ocorreu após 2008. Como consequência, entes subnacionais adotaram políticas para redução de servidores (Shi, 2019).

Quanto à pandemia da Covid-19, pouco se sabe, embora McDonald e Larson (2020) investigaram como a queda na arrecadação de impostos afetou a saúde fiscal de entes subnacionais da Carolina do Norte, verificando cenários preocupantes. Maher et al. (2020) afirma que organizações sem fins lucrativos precisam de reservas financeiras para períodos críticos e que os efeitos fiscais seriam percebidos apenas alguns anos depois, mas que possíveis lições aprendidas na recessão de 2008 poderiam colocá-las em uma posição melhor.

O objetivo deste trabalho é analisar a situação financeira dos entes subnacionais brasileiros. A definição da Condição Financeira Governamental por meio de uma única variável dependente, a partir de dados financeiros, não seria factível, considerando que as demandas dos serviços públicos podem variar de acordo com a população atendida. Por esta razão, optou-se por investigar a condição fiscal dos municípios.

2.1 Condição Fiscal

Ao lidar com crises econômicas, é comum realizar ajustes fiscais, mas estes podem afetar a sociedade, como foi o caso dos cortes de gastos em saúde e educação no Brasil por 20 anos (Vieira, 2016). Entretanto, a autora conclui, a partir de revisões sistemáticas, que tais procedimentos tendem agravar a situação, reforçando a importância de manter programas sociais para serviços essenciais e uma retomada econômica em prazo mais curto. Ressalta-se a relevância de incorporar a participação da população e dos sindicatos na formulação de decisões durante períodos de estresse fiscal em âmbito municipal (Warner et al., 2021).

A Condição Fiscal é um aspecto financeiro que caracteriza a dificuldade enfrentada por governos locais (Lima & Diniz, 2016), ou seja, há uma relação intrínseca entre elas (Magkonis & Tsopanakis, 2016), evidenciando que a falta de recursos pode afetar a qualidade e até mesmo resultar em cortes de serviços essenciais.

Diferentes definições para a condição fiscal são observadas. Nos Estados Unidos, uma pesquisa aplicada

a funcionários de cargos importantes em 50 estados constatou que apenas 10 possuíam uma definição formal para crises em governos locais, enquanto os demais possuíam apenas algo funcional ou deixavam os entes subnacionais definirem o problema (Honadle, 2003).

De acordo com Stanley (1980), as dificuldades fiscais podem ser classificadas em crise fiscal, que se refere à falta de recursos para cobrir as despesas atuais do ente, e declínio de longo prazo, que é a queda na economia ao longo do tempo. Nesse sentido, as ações do governo municipal são limitadas, pois no caso de problemas de longo prazo, eles podem apenas contingenciar despesas e estabelecer a ordem nos procedimentos. Já no curto prazo, o governo pode contar com a ajuda de outros entes ou adotar medidas de cortes de gastos.

Miranda et al. (2018) constataram que o elevado gasto com juros e amortização da dívida afeta a gestão fiscal dos estados brasileiros, impactando sua liquidez e Condição Financeira Governamental. Em outra pesquisa, Oliveira et al. (2021) investigaram os fatores que influenciam a gestão fiscal dos municípios do Paraná e encontraram uma relação positiva entre as variáveis representativas da autonomia com a dívida consolidada líquida e o gasto com pessoal.

Quando um governo enfrenta pressão por gastos e não consegue arrecadar recursos suficientes, é considerado em situação de estresse fiscal (Clark, 1977). Isso impossibilita a prestação de serviços essenciais à população devido à necessidade de financiamento (Honadle, 2003). Para avaliar essa situação nos governos locais, diferentes abordagens são utilizadas.

McDonald e Larson (2020) definem a situação fiscal por meio da variável receita total sobre despesa total, dividindo os resultados em cinco categorias, desde muito estressados até muito saudáveis. Eles sugerem que os governantes busquem equilibrar receitas e despesas correntes, assim como o nível de endividamento, para alcançar uma gestão adequada (Bisogno et al., 2019). Por outro lado, o stress test de Bowman e Calia (1997) utiliza uma variável dummy para classificar os governos como estressados ou não, com base na suficiência das receitas correntes para recompor os ativos empenhados nas despesas operacionais.

Há estudos recentes relevantes em várias partes do mundo sobre o assunto. Na Itália, diferenças entre municípios endividados e não endividados foram observadas em relação às despesas com funcionários, receitas totais, passivo de curto prazo, receitas correntes e subsídios per capita (Cohen et al., 2017). Dantas Junior et al. (2019) investigaram o federalismo fiscal e sua relação com o endividamento de municípios brasileiros. Concluiu-se que, em épocas de instabilidade econômica, os

municípios mais dependentes financeiramente de outros governos estão mais propensos a enfrentar problemas de estresse fiscal.

Trussel e Patrick (2018) criaram um modelo de classificação de risco de estresse fiscal para governos subnacionais nos Estados Unidos, com base em 21 variáveis, que acertou até 99% da amostra, após corte de acordo com o custo do erro. Contudo, o modelo possui apenas duas variáveis relacionadas ao fator ambiental, enquanto as outras 19 são financeiras, e não há nenhuma variável relacionada ao fator organizacional.

3 Metodologia

O modelo deste estudo baseia-se em Trussel e Patrick (2018) e utiliza os três fatores mencionados por Groves et al. (1981) e Groves e Valente (2003), além de considerar a realidade brasileira, especialmente a Lei de Responsabilidade Fiscal (LRF) e os estudos de Hendrick (2004), Dantas Junior et al. (2019), Silva et al. (2020) e Bolognesi et al. (2023). A variável dependente a ser analisada será o stress test de Bowman e Calia (1997), e o modelo de previsão aplicou a técnica RF.

Foram utilizados dados do Instituto Brasileiro de Geografia e Estatística (IBGE) sobre o código do município, área, mesorregião e estimativa populacional, e da Secretaria do Tesouro Nacional para coletar os dados financeiros de 2014 a 2021.

3.1 Variáveis

De acordo com Trussel e Patrick (2018), para identificar o estresse fiscal, é preciso seguir três etapas: identificar a ocorrência, investigar as possíveis causas e avaliar a probabilidade. Nesse sentido, foi utilizado o stress test de Bowman e Calia (1997) como variável dependente para verificar a possibilidade de pagamento diante das receitas, o qual se adequa realidade brasileira (Dantas Junior et al., 2019). O processo de análise requer quatro etapas, seguido da avaliação dos sinais, como apresentado na Tabela 1.

Inicialmente, estima-se o superávit financeiro no ano. Depois, a sua variação entre dois anos consecutivos. Na sequência, calcula-se a variação das despesas operacionais entre os mesmos anos. Por fim, apura-se o stress test, que é a razão entre a variação do superávit e das despesas.

Tabela 1: Análise dos resultados para a condição fiscal

Resultado	Despesas operacionais	Condição
Stress test ≤ 1	Crescente	1
Stress test > 1	Decrescente	1
Stress test ≤ 1	Decrescente	0
Stress test > 1	Crescente	0

Notas: (i) Se o resultado do superávit financeiro for de déficit para os dois anos necessários do cálculo, considera-se em estresse fiscal; (ii) Se o resultado da condição for igual à 1, o município apresenta estresse, caso contrário, o município não apresenta estresse fiscal. Fonte: Adaptado de Bowman e Calia (1997).

A Tabela 2 apresenta a quantidade de municípios analisados em cada ano, indicando quantos foram afetados ou não pelo estresse fiscal. Cabe destacar que se coletaram dados de todos os 853 municípios, porém dados ausentes reduziram a amostra.

Tabela 2: Amostra da pesquisa em relação a variável dependente

Exercício	Amostra	Ano de previsão	Em estresse	Sem estresse
2014	483	2015	389	94
2015	495	2016	329	166
2016	485	2017	330	155
2017	600	2018	507	93
2018	704	2019	404	300
2019	725	2020	381	344
2020	720	2021	189	531

Nota: Exercício = ano das variáveis independentes; Amostra = quantidade de municípios com os dados disponíveis; Ano de previsão = ano da variável dependente; Em estresse = quantidade de municípios em estresse fiscal de acordo com o stress test; Sem estresse = quantidade de municípios sem estresse fiscal.

Fonte: Dados da pesquisa.

As variáveis independentes do modelo foram, em sua maioria, baseadas em Trussel e Patrick (2018), mas algumas foram adaptadas para o contexto brasileiro. Ademais, foram considerados os fatores ambientais e governamentais que influenciavam a condição financeira, definidos por Groves et al. (1981) e Groves e Valente (2003). Os indicadores V18, V20 e V21 correspondem aos fatores ambientais, o V22 é referente ao fator organizacional, enquanto os demais são todos financeiros e podem ser observados no Quadro 1.

Por questões de conveniência, serão descritas a seguir apenas as variáveis que foram adaptadas ou acrescentadas ao modelo.

Quadro 1 - Variáveis independente do modelo

Categorias	Indicador	Conta	Referência
V1	Receita per capita	Receita total População	
V2	Receitas intergovernamentais	Receitas de outros governos	
V3	Indicadores baseados em operações	Receitas totais Despesa total População	Trussel e Patrick (2018)
V4	Posição operacional	Receita total Despesa total	
V5	Despesas em saúde	Despesas em saúde (Receita total)	
V6	Despesas em educação	Despesas em educação Receita total	Dantas Junior et al. (2019)
V7	Serviço da dívida	Juros e encargos da dívida	
V8	Indicadores baseados na dívida	Receita total Dívida total	Trussel e Patrick (2018)
V9	Passivo per capita	Receita total Passivo total População	
V10	Dívida para ativo	Dívida total Ativo total	
V11	Indicadores baseados na estrutura de capital	Patrimônio líquido Receita total Patrimônio líquido	Trussel e Patrick (2018)
V12	Patrimônio líquido para ativo	Ativo total	
V13	Caixa para receita	Caixa+investimentos	
V14	Indicadores baseados na liquidez	Receita total Caixa+investimentos	Trussel e Patrick (2018)
V15	Caixa para dívida	Dívida total Ativo circulante	
V16	Indicador baseado em funcionários	Passivo circulante Gasto com pessoal	Adaptada da LRF (2000)
V17	Indicador baseado em impostos	Receita corrente líquida Receita tributária Receita total	Trussel e Patrick (2018)
V18	População	Logaritmo natural da estimativa da população	
V19	Participação de despesas de capital	Despesa de capital Despesa total	Trussel e Patrick (2018)
V20	Densidade populacional	População	Hendrick (2004)
V21	Localização	Área do município	Adaptada de Silva et al. (2020)
V22	Ideologia política	Mesorregiões de Minas Gerais Partidos de esquerda ou direita	Bolognesi et al. (2023)

Fonte: Elaborada pelos autores.

As variáveis de despesas em saúde (V5) e educação (V6) foram ajustadas para o contexto brasileiro, tendo em vista que Trussel e Patrick (2018) usaram variáveis que avaliam cobranças de usuários de serviços e gastos públicos com estradas municipais. Nessa linha de indicadores, optou-se por utilizar as variáveis de Dantas Junior et al. (2019).

De acordo com Groves e Valente (2003), em locais com altos níveis de emprego, a população tende a recorrer menos aos serviços públicos, pois preferem arcar com os gastos. Por outro lado, Dantas Junior et al. (2019) afirmam que quanto maior for o investimento em educação ou saúde em relação às receitas totais, maior será o risco de os entes subnacionais brasileiros sofrerem estresse fiscal.

No entanto, é indispensável que tais serviços sejam fornecidos à sociedade (Lima & Diniz, 2016). O contingenciamento de investimentos em áreas essenciais pode resultar em problemas sociais significativos, como desemprego, depressão e aumento do número de suicídios (Vieira, 2016). Adicionalmente, é importante observar que o desemprego é afetado de forma diferente entre as áreas, sendo os serviços humanos mais impactados pelas reduções (Brien et al., 2021).

A variável de despesa com pessoal (V16) foi adaptada para atender à LRF, uma vez que no modelo original foram utilizadas duas variáveis referentes aos custos de pensões e benefícios a empregados. Essa adaptação justifica-se pelo contexto brasileiro.

A LRF estabelece regras para os entes da Federação possuir uma gestão fiscal eficiente, com o objetivo de equilibrar receitas e despesas. Para o gasto com pessoal, o limite é de 60% da receita corrente líquida, aplicável tanto a municípios quanto a estados. Quando ultrapassado 90% do limite (54%), os tribunais de contas alertam os poderes (LRF, 2000).

De acordo com Miranda et al. (2018), os estados que apresentam maiores gastos com pessoal tendem a ter uma pior condição fiscal, resultado este também observado em municípios do Paraná por Oliveira et al. (2021).

Foram acrescentadas três variáveis aos outros indicadores e variáveis de controle. A densidade populacional (V20), que afeta a produção e distribuição dos serviços à sociedade (Lima & Diniz, 2016), foi incluída, porém, Hendrick (2004) argumenta que tal variável não mede todas as necessidades de investimentos.

Embora essa variável se assemelhe ao tamanho da população, seu efeito nas despesas dos municípios na Austrália divergiu (Tran et al., 2019). O tamanho da população influenciou positivamente a economia de escala dos governos locais, enquanto a densidade populacional não apresentou o mesmo efeito.

Trussel e Patrick (2018) empregaram o tipo de município como variável de controle, pois essas entidades subnacionais são classificadas nos Estados Unidos em quatro categorias distintas, nomeadamente: 'cidade', 'borough' (uma espécie de distrito), 'município de primeira classe' (superior a 10 mil habitantes) e 'município de segunda classe' (entre 1500 e 9999 habitantes). Este indicador aborda três aspectos fundamentais: densidade populacional, circunstâncias históricas e a gama de serviços disponibilizados à população (Trussel & Patrick, 2018).

No entanto, essa divisão não é aplicável ao Brasil. Assim, com base em estudos relevantes (Antulov-Fantulin et al., 2021; Preston, 1985; Psycharis et al., 2016), optou-se por utilizar as mesorregiões de Minas Gerais (V21) nesta pesquisa.

Kim e Warner (2018) constataram que regiões metropolitanas e rurais nos Estados Unidos são suscetíveis ao estresse fiscal e Aarsaether (1990) verificou que variáveis espaciais refletem na condição fiscal na Noruega, especialmente no nível de industrialização. Silva et al. (2020) destacam que a localização geográfica é significativa para a gestão fiscal no Brasil. Assim, justifica-se a inclusão dessa variável, pois as mesorregiões do estado podem sinalizar particularidades representativas.

A literatura mostra resultados variados para ideologias políticas, sob a ótica da condição fiscal. Em Portugal, municípios governados por partidos de direita tendem a enfrentar desafios financeiros (Lobo et al., 2011). Na Espanha, no entanto, não foi identificada uma relação significativa entre o nível de dívida e a ideologia política (Benito et al., 2010). Em contraste, um estudo recente conduzido por Navarro-Galera et al. (2020) revelou que a ideologia política dos prefeitos exerce influência no risco financeiro, com aqueles de orientação esquerdista demonstrando maior propensão a enfrentar dificuldades, pois são propensos a gastar mais com políticas sociais.

Para classificar a ideologia dos partidos (V22) em esquerda ou direita, utilizou-se o estudo de Bolognesi et al. (2023), que utilizou uma pesquisa respondida por cientistas políticos em 2018. A escala variava de 0 a 10, sendo que valores menores indicavam ideologias mais à esquerda, e valores maiores, ideologias mais à direita. Essa variável é contínua, podendo assumir valores entre 0 e 10.

Desta maneira, define-se a equação geral do modelo:

$$P_{Y(i,t)} = \frac{1}{1 + e^{(\beta_0 + \beta_1 V_{i,t-1} + \epsilon_{i,t-1})}}$$

onde $P_{Y(i,t)}$ é a probabilidade do município i sofrer estresse fiscal no ano, ou seja, se for estressado fiscalmente atribui-se 1, e, 0 caso contrário; $V_{i,t-1}$ representa as variáveis independentes da cidade i no ano $t-1$; e $\epsilon_{i,t-1}$ refere-se ao termo de erro.

3.2 Inteligência Artificial

As técnicas de IA têm sido amplamente utilizadas nas finanças modernas, proporcionando financiamentos mais baratos e rápidos. Entretanto, é importante atentar-se às limitações, como os vieses de dados (Lin, 2019). Entre essas técnicas, destaca-se o RF, que tem apresentado resultados positivos em diversas áreas do conhecimento (Cutler et al., 2012). Na previsão de estresse fiscal em governos locais, o RF apresenta resultados superiores do que as técnicas de regressão logística (Jarmulski, 2022).

Embora recentes, técnicas de IA começam a ser utilizadas na análise da condição financeira de governos locais. Chen (2021) utilizou Redes Neurais e Decision Trees para avaliar o risco de estresse fiscal em entes subnacionais da China, obtendo mais de 85% de precisão na previsão antecipada desse problema. Antulov-Fantulin et al. (2021) identificaram as melhores técnicas para prever falência municipal na Itália, destacando o Gradient Boosting Machines e o RF, enquanto o Lasso e as Neural Networks

apresentaram resultados inferiores. Por fim, Zarkova et al. (2023) previram as dívidas públicas de países da União Européia usando RF, destacando o potencial da técnica para a previsão realizada.

Neste estudo, utiliza-se RF. De acordo com Breiman (2001), essa técnica apresenta diversas qualidades, como alta precisão, relativa robustez para ruídos e outliers, e estimativas apropriadas para variáveis internas, como correlação, força, erro e importância da variável. Adicionalmente, o autor afirma que a técnica dificilmente apresenta problemas de overfitting, sendo, portanto, um previsor confiável, e facilmente implementado.

Por outro lado, o método RF pode manifestar superestimação dos erros da amostra em situações de baixa quantidade de dados e baixa correlação entre as variáveis preditoras (Janitzka & Hornung, 2018). Ainda, observou-se que árvores profundas podem resultar em modelos inconsistentes (Tang et al., 2018).

3.3 Análise dos Resultados (definição do modelo de IA de previsão)

Utilizou-se a linguagem de programação Python para desenvolver o modelo e analisar os resultados. Foram avaliados diferentes períodos, incluindo os três anos anteriores à crise mundial de 2020, que não foram afetados pela Pandemia de Covid-19 nos dados, enquanto o quarto ano foi afetado pela variável dependente e o último ano foi afetado também nas independentes. Para analisar essa situação, empregou-se o método de janela rolante.

Assim, foram utilizados dois anos de dados para treinamento do modelo, enquanto as variáveis do ano subsequente foram empregadas para a validação do modelo. Consequentemente, foram criadas cinco janelas temporais, em que a primeira foi treinada com dados de 2014 e 2015, validada com dados de 2016, e assim por diante, até chegar aos dados de 2018 e 2019, utilizados para treinamento e validação do modelo em 2020.

A justificativa para a divisão mencionada anteriormente se deve ao fato de se aproximar de uma proporção de 70% dos dados para treinamento e 30% para teste, conforme observado por Antulov-Fantulin et al. (2021). Os dados de treinamento foram equilibrados em relação à variável dependente, seguindo a prática de Antulov-Fantulin et al. (2021), uma vez que uma amostra desequilibrada pode levar o modelo a classificar com base na classe majoritária, sendo necessário o uso da biblioteca `imblearn.over_sampling` para corrigir esse problema.

Para avaliar o desempenho do modelo, utilizou-se o

Classification-Report da biblioteca `sklearn.metrics`. Ele retorna quatro métricas: *precision*, que representa a proporção de previsões corretas em relação ao total de previsões; *recall*, que indica a porcentagem de dados classificados corretamente em relação às situações reais; *F1-Score*, que é uma média harmônica da precisão e *recall*; e *acurácia*, que representa a precisão geral do modelo (Chen, 2021).

Os resultados das previsões são apresentados em forma de probabilidade de ocorrência ou não do estresse fiscal, no entanto, algumas probabilidades são baixas, como, por exemplo, 51% de chances de ocorrer o estresse fiscal ou de cobrir as despesas do período. Esta é uma área conhecida como zona cinzenta, na qual não se sabe com certeza o que irá ocorrer no futuro. Portanto, essa área pode ser excluída para uma avaliação mais precisa (Altman et al., 2013).

O objetivo deste procedimento é reduzir os erros do tipo I e tipo II, os quais complementam o *recall*. O erro do tipo I ocorre quando o município analisado é previsto para passar por uma situação de estresse fiscal, porém, na realidade, não enfrenta o problema. Já o erro do tipo II ocorre quando o ente subnacional enfrentou o problema de estresse fiscal, mas foi previsto que não o enfrentaria (Antulov-Fantulin et al., 2021). Portanto, o erro do tipo II é mais problemático que o erro do tipo I.

Para analisar a importância das variáveis, utilizou-se a função `feature_importances_` da biblioteca `matplotlib.pyplot`, a qual fornece valores em porcentagem para classificar as principais características.

4 Resultados

Observa-se pela Tabela 3 que o modelo apresentou resultados promissores para a previsão de estresse fiscal fora do período de pandemia, com o *F1-Score* sempre superior a 0,7, porém obteve resultados inferiores a 0,5 para a previsão de não estresse. Durante os anos de pandemia, os resultados foram invertidos, e é importante notar que a variável dependente de 2019 se refere ao ano de 2020, indicando que os dados já foram afetados pela crise sanitária.

Tabela 2: Amostra da pesquisa em relação a variável dependente

Validação	Condição	Precisão	Recall	F1-Score	Quantidade
2016	Não Estresse (0)	0,46	0,45	0,45	155
	Estresse (1)	0,74	0,76	0,75	130
	Acurácia			0,66	485
2017	Não Estresse (0)	0,23	0,54	0,32	93
	Estresse (1)	0,89	0,66	0,76	507
	Acurácia			0,65	600
2018	Não Estresse (0)	0,81	0,17	0,28	300
	Estresse (1)	0,61	0,97	0,75	404
	Acurácia			0,63	704
2019	Não Estresse (0)	0,65	0,51	0,58	381
	Estresse (1)	0,56	0,70	0,62	442
	Acurácia			0,60	723
2020	Não Estresse (0)	0,84	0,81	0,83	531
	Estresse (1)	0,52	0,57	0,54	189
	Acurácia			0,75	720

Nota: Precisão = acertos em relação ao total de previsões realizadas; Recall = dados classificados corretamente em relação às situações reais; F1-Score = média harmônica do *precision* e *recall*; Quantidade = Quantidade de municípios em determinada condição e no total; Acurácia = Média de acertos geral do modelo. Fonte: Dados da pesquisa.

A precisão geral do modelo foi de pelo menos 60%, como pode ser observado na Tabela 3. É interessante notar que apenas em 2020 o valor foi superior a 70%, com um acerto de 75%. Destaca-se que este foi o único ano em que tanto a variável dependente quanto as independentes foram impactadas pela pandemia.

Trussel e Patrick (2018) estabeleceram pontos de corte em sua amostra, considerando o custo do erro, e relataram apenas os resultados para o caso de estresse fiscal. Eles obtiveram um resultado de 0,77 entre os anos de 2007 e 2010 e 0,17 em 2011. Em comparação, este estudo não alcançou resultados melhores do que a primeira amostra, mas teve resultados superiores em todos os anos quando comparado com a segunda.

No entanto, deve-se observar que este estudo realiza previsões, enquanto Trussel e Patrick (2018) apenas analisaram os fatores que afetam o estresse fiscal. Portanto, os resultados deste trabalho tendem a ser menores, mas conseguiram superar os resultados citados em alguns pontos.

4.1 Área cinzenta

Os Tais áreas são caracterizadas pela imprecisão, com uma baixa probabilidade de ocorrer o que foi previsto (Altman et al., 2013), assim, a remoção delas é implementada com o objetivo de aprimorar os índices de precisão. Para tanto, foram realizados 5 pontos de corte: no primeiro, todos os valores na faixa de 45% e 55% foram removidos, no segundo, entre 60% e 40%, no terceiro, entre 65% e 35%, no quarto, entre 30% e 70%, e, por fim, entre 25% e 75%.

Os resultados obtidos podem ser visualizados no Apêndice 1. À medida que se aumenta a área dos pontos de corte, os valores de acerto dos modelos também aumentam, indicando que a retirada das baixas probabilidades alcançou os resultados esperados. Notavelmente, no último ponto de corte, todos os valores de acurácia foram superiores a 0,8, o que significa que eles alcançaram um alto nível de acerto geral, superior a 80%. Estes valores são similares ao trabalho de Chen (2021), que obteve uma taxa de acerto de 85%. Além disso, no ano de 2020, obteve-se uma taxa de acerto de 0,85, sendo igual à referência.

Além disso, no Apêndice 2 foram incluídas cinco figuras que apresentam a quantidade de erros do tipo I e II, juntamente com os acertos em relação à previsão de estresse e não estresse fiscal. Os gráficos apresentam o eixo X referente à quantidade de municípios e o eixo Y relacionado à probabilidade de estresse fiscal, sendo importante destacar que quando essa probabilidade é menor do que 50%, a previsão indica que o ente subnacional não enfrentará problemas. Os gráficos

são divididos em quatro partes, iniciando sempre em valores identificáveis no eixo X, facilitando a leitura.

Ao analisar as cinco figuras apresentadas, constata-se que houve uma maior incidência de erros do tipo I em comparação aos do tipo II, com exceção do ano de previsão de 2017. Além disso, à medida que as probabilidades aumentam, menores são as chances de os problemas fiscais ocorrerem. Logo, o objetivo de reduzir essas ocorrências e aprimorar a média geral de acertos do modelo foi alcançado.

Considerando a análise realizada, apenas sete dos municípios previstos para não enfrentarem estresse fiscal passaram pelo problema, quando analisados acima dos 85% (ou abaixo dos 15% nos gráficos), e apenas um quando analisado acima dos 90%. É importante destacar que no ano de 2019 não houve erros deste tipo acima de 80%. Por outro lado, quando o ente subnacional foi previsto para não enfrentar o problema, mas o enfrentou, houve um número maior de ocorrências, sendo 42 vezes acima do ponto de corte de 85%, 13 vezes acima de 90% e nenhum erro desse tipo ocorreu em três anos de análise com o ponto de corte de 95%.

A análise visual também confirma as mudanças no desempenho do modelo em relação aos períodos de antes e durante a pandemia. Entre 2016 e 2018, observa-se uma taxa de acertos significativamente maior na previsão de estresse fiscal, sendo no mínimo quatro vezes maior. Em 2019, a taxa de acertos para ambas as previsões quase se iguala, enquanto em 2020, o modelo acertou a previsão de não enfrentamento do problema aproximadamente quatro vezes mais.

4.2 Importância das variáveis


Ao analisar a Figura 1, verifica-se que, em média, ao longo dos anos, as variáveis mais relevantes foram aquelas baseadas em liquidez, ou seja, V13, V14 e V15. Este resultado está em linha com a descoberta de lacuzzi (2022), que constatou uma concentração de indicadores baseados em liquidez nas variáveis estudadas nessa área. Além disso, a variável 15 é a mais importante em todos os anos.

A média geral de importância das variáveis foi de 4,55%. Além das três já mencionadas, apenas a variável V4 ficou acima dessa média. Esse resultado corrobora a visão de Lima e Diniz (2016), uma vez que, embora a posição operacional seja importante, ela não pode ser considerada dependente, como feito por McDonald e Larson (2020). O problema real é quando há gastos maiores do que as receitas em vários períodos seguidos ou quando são criadas reservas sem justificativa. Portanto, essa variável pode ser utilizada

para verificar o declínio em longo prazo e corrobora o objetivo da LRF de equilibrar as receitas e despesas.

Dentre as variáveis do modelo, destacam-se como as menos importantes a V21 e V22, sendo a primeira relacionada ao fator ambiental e a segunda, organizacional. Esse resultado não corrobora os estudos de Groves e Valente (2003), que atribuem grande importância aos indicadores ambientais e organizacionais na previsão do equilíbrio fiscal.

Figura 1: Importância das variáveis



Fonte: Elaborada pelos autores.

Tal resultado também contradiz o estudo de Antulov-Fantulin et al. (2021), que consideram alguns indicadores referentes à região como mais importantes do que dados financeiros para a previsão, além de se opor à verificação de Silva et al. (2020), que considera a região um dado fundamental para se verificar a gestão fiscal no Brasil. Além disso, as outras duas variáveis ambientais (V18 e V20) também apresentaram importância abaixo da média.

No contexto da ideologia política (V22), observa-se uma relativa insignificância dessa variável. Portanto, esse resultado está em consonância com a pesquisa de Benito et al. (2010), que também não identificou associação significativa entre essa variável e a dívida. No entanto, contrasta com as descobertas de Lobo et al. (2011) e Navarro-Galera et al. (2021), que estabeleceram uma relação significativa. Portanto, é possível que os indicadores financeiros já contemplem os efeitos das variáveis ambientais e organizacionais.

As variáveis referentes às despesas com saúde e educação, as quais ficaram abaixo da média, merecem destaque por sua importância. Este resultado é significativo, à luz das lições aprendidas com Vieira (2016), pois, se tais recursos não afetam significativamente o estresse fiscal, não há justificativa para promover programas de austeridade fiscal que possam gerar problemas sociais.

Entretanto, é necessário ter cautela, uma vez que, de acordo com Dantas Junior et al. (2019), essas despesas afetaram o estresse fiscal de municípios brasileiros. Essa contradição pode estar relacionada à análise, já que a verificação do que influencia usa variáveis do mesmo ano, enquanto a previsão utiliza variáveis do período seguinte.

4.2.1 Importância das variáveis durante os diferentes períodos

Os resultados apresentaram mudanças significativas durante a crise sanitária internacional. Além disso, a variável "caixa por dívidas" apresentou alterações, uma vez que, nos anos de 2016 a 2018, seus valores permaneceram em torno de 7%, enquanto nos dois últimos anos, esses resultados foram superiores a 10%. Esse resultado reforça a análise de Maher et al. (2020) de que organizações sem fins lucrativos precisam de reservas financeiras para enfrentar períodos de turbulência econômica.

Durante o período da crise sanitária, a variável "desembolso de capital" apresentou mudanças em relação ao período anterior, porém com menor volatilidade e redução de sua importância. Nos três primeiros anos, os valores foram em torno de 4%, enquanto nos dois últimos anos foram de aproximadamente 3,5%.

As outras variáveis não apresentaram mudanças significativas nos resultados entre os dois períodos analisados. Portanto, em termos percentuais, a variável caixa por dívidas ganhou importância durante a crise, enquanto a despesa de capital diminuiu. No entanto, a primeira variável sofreu uma mudança mais significativa.

5 Conclusões

A análise da condição financeira governamental tem sido amplamente investigada e debatida pela academia no contexto internacional. Mais recentemente, esse assunto vem ganhando força na literatura brasileira. A condição fiscal está diretamente ligada à condição financeira governamental e pode resultar na queda de serviços à população quando um ente apresenta estresse fiscal. Portanto, cenários de crises e novas metodologias podem ser incentivos para que os pesquisadores busquem novos resultados e análises nesse tema.

Assim sendo, este estudo adaptou um modelo recente visando analisar os fatores que afetam a condição fiscal dos municípios e empregou a técnica de inteligência artificial, random forest para investigar os resultados, haja vista que tal técnica tem apresentado resultados

promissores recentemente.

Este estudo teve como objetivo prever, com um ano de antecedência, a condição fiscal dos municípios de Minas Gerais, a fim de verificar sua possibilidade de estresse fiscal. Isso permitiu a comparação dos resultados com outros trabalhos que buscaram realizar a mesma previsão ou verificar sua precisão para o mesmo período.

O resultado inicial superou uma das amostras primárias utilizadas por Trussel e Patrick (2018) como base para a adaptação deste modelo, embora o objetivo desses autores tenha sido investigar os fatores que influenciam a condição fiscal. Ao aplicar pontos de corte nas probabilidades do modelo, foi alcançado um resultado semelhante ao obtido por Chen (2021), que também previu essa situação.

O modelo apresentou resultados distintos para os diferentes períodos analisados, uma vez que houve uma mudança significativa na previsão do estresse fiscal e da ausência deste problema quando se considerou a influência dos dados (independentes e/ou dependentes) da pandemia.

Ao analisar a importância das variáveis, observa-se que as mais relevantes estão relacionadas à liquidez dos municípios, o que está de acordo com a descoberta de lacuzzi (2022) e coincide com a visão de Lima e Diniz (2016) sobre a posição operacional, que é importante, mas não deve ser considerada dependente. No entanto, a mesorregião apresentou uma menor importância, em contraposição aos resultados de Antulov-Fantulin et al. (2021).

Por último, é relevante ressaltar a limitada influência da ideologia política no estresse fiscal, de modo que esse desfecho se coaduna com os achados de Benito et al. (2010), divergindo das conclusões de Lobo et al. (2011) e Navarro-Galera et al. (2021). Nota-se, assim, que os fatores ambientais e organizacionais não demonstraram relevância nessa análise, contrapondo Groves et al. (1981) e Groves e Valente (2003).

Apesar das melhorias implementadas neste estudo, é importante reconhecer suas limitações. O período de análise foi restrito pela disponibilidade de dados do SICONFI, que abrange apenas a partir de 2014, e a análise se concentrou em municípios de um único estado brasileiro.

Como direção para futuras pesquisas, sugere-se ampliar o período de análise, abrangendo o pós-pandemia, e expandir a análise para incluir todos os municípios do Brasil. Além disso, é possível considerar a exploração de outras metodologias de IA e a inclusão de variáveis adicionais para aprimorar a compreensão do estresse fiscal em contextos municipais.

Referências

- Aarsaether, N. (1990). Organizational and Spatial Determinants of Fiscal Stress: An Analysis of Norwegian Municipalities. *Public Budgeting & Finance*, 10(1), 55-66. <https://doi.org/10.1111/1540-5850.00850>
- Altman, E. I., Danovi, A., & Falini, A. (2013). Z-Score Models' Application to Italian Companies Subject to Extraordinary Administration. *Journal of Applied Finance (Formerly Financial Practice and Education)*, 23(1), 1-10. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2686750
- Afonso, A., & Jalles, J. T. (2020). Sovereign indebtedness and financial and fiscal conditions. *Applied Economics Letters*, 27(19), 1611-1616. <https://doi.org/10.1080/13504851.2019.1707758>
- Antulov-Fantulin, N., Lagravinese, R., & Resce, G. (2021). Predicting bankruptcy of local government: A machine learning approach. *Journal of Economic Behavior and Organization*, 183, 681-699. <https://doi.org/10.1016/j.jebo.2021.01.014>
- Benito, B., Bastida, F., & Muñoz, M. J. (2010). Factores Explicativos de la Presión Fiscal Municipal: Explanatory Factors of the Municipal Fiscal Burden. *Revista de Contabilidad-Spanish Accounting Review*, 13(2), 239-283. [https://doi.org/10.1016/S1138-4891\(10\)70018-2](https://doi.org/10.1016/S1138-4891(10)70018-2)
- Bisogno, M., Cuadrado-Ballesteros, B., Santis, S., & Citro, F. (2019). Budgetary solvency of Italian local governments: an assessment. *International Journal of Public Sector Management*, 32(2), 122-141. <https://doi.org/10.1108/IJPSM-11-2017-0328>
- Bolognesi, B., Ribeiro, E., & Codato, A. (2023). Uma Nova Classificação Ideológica dos Partidos Políticos Brasileiros. *Dados*, 66(2). <https://doi.org/10.1590/dados.2023.66.2.303>
- Bowman, W., & Calia, R. (1997). Evaluating Local Government Financial Health: Financial Indicators for Cook, DuPage, Kane, Lake, McHenry e Will Counties. Chicago: The Civic Federation.
- Brasil (2022). Visão Integrada das Dívidas da União, dos Estados, do Distrito Federal e dos Municípios. <https://www.tesourotransparente.gov.br/historias/visao-integrada-das-dividas-da-uniao-dos-estados-do-distrito-federal-e-dos-municipios>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Brien, S. T., Eger III, R. J., & Matkin, D. S. (2021). The

- timing of managerial responses to fiscal stress. *Public Administration Review*, 81(3), 414-427. <https://doi.org/10.1111/puar.13359>
- Brown, K. W. (1993). The 10-point test of financial condition: Toward an easy-to-use assessment tool for smaller cities. *Government Finance Review*, 9, 1-21. <https://localgovernment.extension.wisc.edu/files/2016/04/kenneth-brown-Ten-point-test.pdf>
- Chen, D. (2021). Risk Assessment of Government Debt Based on Machine Learning Algorithm. *Complexity*, 2021. <https://doi.org/10.1155/2021/3686692>
- Chung, I. H., & Williams, D. (2021). Local governments' responses to the fiscal stress label: the case of New York. *Local Government Studies*, 47(5), 808-835. <https://doi.org/10.1080/03003930.2020.1797693>
- Clark, T. N. (1977). Fiscal Management of American Cities: Funds Flow Indicators. *Journal of Accounting Research*, 15, 54-94. <https://doi.org/10.2307/2490632>
- Clark, T. N. (1994). Municipal fiscal strain: Indicators and causes. *Government Finance Review*, 10, 1-27.
- Cohen, S., Costanzo, A., & Manes-Rossi, F. (2017). Auditors and early signals of financial distress in local governments. *Managerial Auditing Journal*, 32(3), 234-250. <https://doi.org/10.1108/MAJ-05-2016-1371>
- Costa, C. C. D. M., Ferreira, M. A. M., Braga, M. J., & Abrantes, L. A. (2015). Fatores associados à eficiência na alocação de recursos públicos à luz do modelo de regressão quantílica. *Revista de Administração Pública*, 49(5), 1319-1347. <https://doi.org/10.1590/0034-7612130868>
- Costa, F. M. D., & Leão, F. H. F. C. (2021). Gerenciamento de resultados e ciclo eleitoral em municípios brasileiros. *Revista de Administração Pública*, 55, 697-715. <https://doi.org/10.1590/0034-761220200112>
- Cruvinel, D. P., & Lima, D. V. (2011). Adoção do regime de competência no setor público brasileiro sob a perspectiva das normas brasileiras e internacionais de contabilidade. *Revista de Educação e Pesquisa em contabilidade*, 5(3), 69-85. <https://www.redalyc.org/pdf/4416/441642859005.pdf>
- Cruvinel, D. P., & Lima, D. V. (2011). Adoção do regime de competência no setor público brasileiro sob a perspectiva das normas brasileiras e internacionais de contabilidade. *Revista de Educação e Pesquisa em contabilidade*, 5(3), 69-85. <https://www.redalyc.org/pdf/4416/441642859005.pdf>
- Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random Forests. *Ensemble Machine Learning*, 157-175. https://doi.org/10.1007/978-1-4419-9326-7_5
- Dantas Junior, A. F., Diniz, J. A., & Lima, S. C. (2019). A Influência Do Federalismo Fiscal Sobre O Estresse Fiscal Dos Municípios Brasileiros. *Advances in Scientific and Applied Accounting*, 12(3), 062-078. <https://doi.org/10.14392/asaa.2019120304>
- García-Sánchez, I. M., Cuadrado-Ballesteros, B., Frías-Aceituno, J. V., & Mordan, N. (2012). A New Predictor of Local Financial Distress. *International Journal of Public Administration*, 35(11), 739-748. <https://doi.org/10.1080/01900692.2012.679173>
- Groves, S. M., Godsey, W. M., & Shulman, M. A. (1981). Financial Indicators for Local Government. *Public Budgeting & Finance*, 1(2), 5-19. <https://doi.org/10.1111/1540-5850.00511>
- Groves, S. M., & Valente, M. G. (2003). Evaluating financial condition: A handbook for local government. 4. ed. revised by Karl Nollenberger. Washington: The International City/Country Management Association – ICMA.
- Hendrick, R. (2004). Assessing and measuring the fiscal health of local governments: Focus on Chicago suburban municipalities. *Urban Affairs Review*, 40(1), 78-114. <https://doi.org/10.1177/1078087404268076>
- Honadle, B. W. (2003). The states' role in U.S. local government fiscal crises: A theoretical model and results of a national survey. *International Journal of Public Administration*, 26(13), 1431-1472. <https://doi.org/10.1081/PAD-120024405>
- Iacuzzi, S. (2022). An appraisal of financial indicators for local government: a structured literature review. *Journal of Public Budgeting, Accounting and Financial Management*, 34(6), 69-94. <https://doi.org/10.1108/JPBAFM-04-2021-0064>
- Janitzka, S., & Hornung, R. (2018). On the overestimation of random forest's out-of-bag error. *PloS one*, 13(8), 1-31. <https://doi.org/10.1371/journal.pone.0201904>
- Jarmulski, B. (2022). Random forest versus logit models: Which offers better early warning of fiscal stress?. *Journal of Forecasting*, 41(3), 455-490. <https://doi.org/10.1002/for.2806>
- Jucá, M. N., & Fishlow, A. (2021). Political uncertainty of impeachment upon corporate investment decisions. *Borsa Istanbul Review*, 21(2), 149-160. <https://doi.org/10.1002/for.2806>

org/10.1016/j.bir.2020.09.007

Kim, Y., & Warner, M. E. (2018). Geographies of local government stress after the great recession. *Social Policy & Administration*, 52(1), 365-386. <https://doi.org/10.1111/spol.12307>

Kloha, P., Weissert, C. S., & Kleine, R. (2005). Developing and Testing a Composite Model to Predict Local Fiscal Distress. *Public Administration Review*, 65(3), 313-323. <https://doi.org/10.1111/j.1540-6210.2005.00456.x>

Lei de Responsabilidade Fiscal (LRF) (2000). "LEI COMPLEMENTAR Nº 101, DE 4 DE MAIO DE 2000". Presidência da República. https://www.planalto.gov.br/ccivil_03/leis/lcp/lcp101.htm

Leiser, S., Wang, S., & Kargman, C. (2021). Perceptions of Local Government Fiscal Health and Fiscal Stress: Evidence from Quantile Regressions with Michigan Municipalities and Counties. *State and Local Government Review*, 53(4), 317-336. <https://doi.org/10.1177/0160323X211038356>

Lima, S. C. de, & Diniz, J. A. (2016). *Contabilidade Pública - Análise Financeira Governamental* (1ª ed.). Atlas.

Lin, T. C. W. (2019). Artificial Intelligence, Finance, and the Law. *Fordham Law Review*, 88(2), 531-551. <https://ir.lawnet.fordham.edu/flr/vol88/iss2/6>

Lobo, F. C., Ramos, P., & Lourenço, Ó. (2011). Causes of financial distress of Portuguese municipalities: empirical evidence. *International Journal Monetary Economics and Finance*, 4(4), 390-409. <https://doi.org/10.1504/IJMEF.2011.043402>

Magkonis, G., & Tsopanakis, A. (2016). The financial and fiscal stress interconnectedness: The case of G5 economies. *International review of financial analysis*, 46, 62-69. <https://doi.org/10.1016/j.irfa.2016.03.019>

Maher, C. S., Hoang, T., & Hindery, A. (2020). Fiscal Responses to COVID-19: Evidence from Local Governments and Nonprofits. *Public Administration Review*, 80(4), 644-650. <https://doi.org/10.1111/puar.13238>

McDonald, B. D., & Larson, S. E. (2020). Implications of the coronavirus on sales tax revenue and local government fiscal health. *Journal of Public and Nonprofit Affairs*, 6(3), 377-400. <https://doi.org/10.20899/JPNA.6.3.377-400>

Miranda, W. L. L. C. de, Araújo, R. J. R. de, Leite, I. F., & Nobre, C. J. F. (2018). Avaliação da gestão fiscal nos estados brasileiros: Análise no quinquênio 2011 a 2015. *Revista Mineira de Contabilidade*, 19(1), 55-67. <https://doi.org/10.21714/2446-9114rmc2018v19n1t05>

Navarro-Galera, A., Lara-Rubio, J., Buendía-Carrillo, D., & Rayo-Cantón, S. (2020). Analyzing political and systemic determinants of financial risk in local governments. *Transylvanian Review of Administrative Sciences*, 16(59), 104-123. <http://dx.doi.org/10.24193/tras.59E.6>

Oliveira, T. M. G., Dall'Asta, D., Zonatto, V. C. S., & Martins, V. A. (2021). Gestão Fiscal Municipal: uma análise sob a ótica do federalismo fiscal e dos ciclos políticos nos governos locais. *Administração Pública E Gestão Social*, 13(4). <https://doi.org/10.21118/apgs.v13i4.11770>

Preston, B. T. (1985). Rich Town, Poor Town: The Distribution of Rate-Borne Spending Levels in the Edwardian City. *Transactions of the Institute of British Geographers*, 10(1), 77-94. <https://doi.org/10.2307/622251>

Psycharis, Y., Zoi, M., & Iliopoulou, S. (2016). Decentralization and local government fiscal autonomy: evidence from the Greek municipalities. *Environment and Planning C: Government and Policy*, 34(2), 262-280. <https://doi.org/10.1177/0263774X15614153>

Shi, Y. (2019). A response to fiscal stress: public sector employment reduction across states during a budget crisis. *International Journal of Public Administration*, 42(13), 1095-1105. <https://doi.org/10.1080/01900692.2019.1575852>

Silva, M. C., Souza, F. J. V., Martins, J. D. M., & Câmara, R. P. B. (2020). Fatores explicativos da gestão fiscal em municípios brasileiros. *Revista Contemporânea de Contabilidade*, 17(42), 26-37. <https://doi.org/10.5007/2175-8069.2020v17n42p26>

Stanley, D. T. (1980). *Managing fiscal stress: the crises in the public sector*. Chatham House Publishers.

Tang, C., Garreau, D., & von Luxburg, U. (2018). When do random forests fail?. *Advances in neural information processing systems*, 31. <https://proceedings.neurips.cc/paper/2018/hash/204da255aea2cd4a75ace6018fad6b4d-Abstract.html>

Tran, C., Kortt, M., & Dollery, B. (2019). Population size or population density? An empirical examination of scale economies in South Australian local government, 2015/16. *Local Government Studies*, 45(5), 632-653. <https://doi.org/10.1080/03003930.2018.1501364>

Trussell, J. M., & Patrick, P. A. (2018). Assessing and ranking the financial risk of municipal governments. *Journal of Applied Accounting Research*, 19(1), 81-101. <https://doi.org/10.1108/JAAR-05-2016-0051>

Turley, G., Di Medio, R., & McNena, S. (2020). A

- or population density? An empirical examination of scale economies in South Australian local government, 2015/16. *Local Government Studies*, 45(5), 632-653. <https://doi.org/10.1080/03003930.2018.1501364>
- Trussel, J. M., & Patrick, P. A. (2018). Assessing and ranking the financial risk of municipal governments. *Journal of Applied Accounting Research*, 19(1), 81–101. <https://doi.org/10.1108/JAAR-05-2016-0051>
- Turley, G., Di Medio, R., & McNena, S. (2020). A reassessment of local government's financial position and performance: The case of Ireland. *Administration*, 68(2), 1–35. <https://doi.org/10.2478/admin-2020-0009>
- Vieira, M. A., De Ávila, L. A. C., & Lopes, J. D. V. S. (2021). Desenvolvimento socioeconômico e eficiência tributária: uma análise dos Municípios de Minas Gerais. *Revista Universo Contábil*, 16(3), 160-179. <http://dx.doi.org/10.4270/ruc.2020320>
- Vieira, F. S. (2016). Crise econômica, austeridade fiscal e saúde: que lições podem ser aprendidas? Brasil: Instituto de Pesquisa Econômica Aplicada. http://repositorio.ipea.gov.br/bitstream/11058/7266/1/NT_n26_Disoc.pdf
- Warner, M. E., Aldag, A. M., & Kim, Y. (2021). Pragmatic municipalism: US local government responses to fiscal stress. *Public Administration Review*, 81(3), 389-398. <https://doi.org/10.1111/puar.13196>
- Zafra-Gómez, J. L., López-Hernández, A. M., & Hernández-Bastida, A. (2009). Developing an alert system for local governments in financial crisis. *Public Money and Management*, 29(3), 175–181. <https://doi.org/10.1080/09540960902891731>
- Zarkova, S., Kostov, D., Angelov, P., Pavlov, T., & Zahariev, A. (2023). Machine Learning Algorithm for Mid-Term Projection of the EU Member States' Indebtedness. *Risks*, 11(4), 71. <https://doi.org/10.3390/risks11040071>

Agradecimentos:

CAPES pelo financiamento do mestrado.

Apêndice 1: Resultados da área cinzenta

Tabela 4: Resultados do modelo após a retirada de determinadas

V a l i d a t i o n	C o n d i t i o n	Cut of 45% to 55%				Cut of 40% to 60%				Cut of 35% to 65%				Cut of 30% to 70%				Cut of 25% to 75%			
		P r e c i s i o n	R e c a l l	F 1 - S c o r e	Q u a n t i t y	P r e c i s i o n	R e c a l l	F 1 - S c o r e	Q u a n t i t y	P r e c i s i o n	R e c a l l	F 1 - S c o r e	Q u a n t i t y	P r e c i s i o n	R e c a l l	F 1 - S c o r e	Q u a n t i t y	P r e c i s i o n	R e c a l l	F 1 - S c o r e	Q u a n t i t y
2016	No Stress (0)	0.46	0.42	0.44	124	0.47	0.40	0.43	95	0.49	0.42	0.46	73	0.46	0.45	0.46	40	0.42	0.38	0.40	26
	Stress (1)	0.76	0.78	0.77	287	0.77	0.82	0.80	235	0.80	0.84	0.82	197	0.86	0.87	0.87	160	0.88	0.90	0.89	134
	Accuracy	0.67	0.67	0.67	411	0.70	0.70	0.70	330	0.73	0.73	0.73	270	0.79	0.79	0.79	200	0.81	0.81	0.81	160
2017	No Stress (0)	0.21	0.54	0.30	65	0.22	0.58	0.32	45	0.20	0.67	0.31	27	0.22	0.68	0.33	19	0.25	0.69	0.37	13
	Stress (1)	0.91	0.69	0.78	426	0.93	0.73	0.82	340	0.96	0.76	0.85	297	0.97	0.81	0.88	243	0.98	0.86	0.92	199
	Accuracy	0.67	0.67	0.67	491	0.71	0.71	0.71	385	0.75	0.75	0.75	324	0.80	0.80	0.80	262	0.85	0.85	0.85	212
2018	No Stress (0)	0.76	0.10	0.18	250	0.76	0.08	0.14	208	0.82	0.09	0.16	158	0.62	0.05	0.09	104	0.40	0.03	0.06	66
	Stress (1)	0.63	0.98	0.77	390	0.66	0.99	0.79	370	0.71	0.99	0.83	351	0.76	0.99	0.86	320	0.82	0.99	0.89	286
	Accuracy	0.64	0.64	0.64	640	0.66	0.66	0.66	578	0.71	0.71	0.71	509	0.76	0.76	0.76	434	0.81	0.81	0.81	352
2019	No Stress (0)	0.68	0.51	0.58	281	0.68	0.50	0.58	169	0.66	0.46	0.54	113	0.69	0.39	0.49	57	0.73	0.24	0.36	33
	Stress (1)	0.61	0.76	0.67	280	0.68	0.83	0.75	223	0.73	0.86	0.79	193	0.81	0.94	0.87	156	0.84	0.98	0.90	133
	Accuracy	0.63	0.63	0.63	561	0.68	0.68	0.68	392	0.71	0.71	0.71	306	0.79	0.79	0.79	213	0.83	0.83	0.83	166
2020	No Stress (0)	0.86	0.85	0.85	458	0.86	0.89	0.87	385	0.86	0.88	0.87	308	0.87	0.88	0.87	220	0.88	0.85	0.87	151
	Stress (1)	0.59	0.61	0.60	162	0.66	0.62	0.64	141	0.70	0.64	0.67	129	0.71	0.69	0.70	97	0.74	0.78	0.76	80
	Accuracy	0.79	0.79	0.79	620	0.81	0.81	0.81	526	0.81	0.81	0.81	437	0.82	0.82	0.82	317	0.83	0.83	0.83	231


Nota: Precision = acertos em relação ao total de previsões realizadas; Recall = dados classificados corretamente em relação às situações reais; F1-Score = média harmônica do precision e recall; Quantidade = Quantidade de municípios em determinada condição e no total; Acurácia = Média de acertos geral do modelo.

Fonte: Dados da pesquisa.

Apêndice 2: Figuras da mancha cinzenta

Figura 2: Resultado da previsão de 2016


Erro do Tipo I Acertou o Estresse Fiscal Acertou o Não Estresse Fiscal Erro do Tipo II



Fonte: Elaborada pelos autores.

Figura 4: Resultado da previsão de 2018


Erro do Tipo I Acertou o Estresse Fiscal Acertou o Não Estresse Fiscal Erro do Tipo II



Fonte: Elaborada pelos autores.

Figura 6: Resultado da previsão de 2020


Erro do Tipo I Acertou o Estresse Fiscal Acertou o Não Estresse Fiscal Erro do Tipo II



Fonte: Elaborada pelos autores.

Figura 3: Resultado da previsão de 2017


Erro do Tipo I Acertou o Estresse Fiscal Acertou o Não Estresse Fiscal Erro do Tipo II



Fonte: Elaborada pelos autores.

Figura 5: Resultado da previsão de 2019

Erro do Tipo I Acertou o Estresse Fiscal Acertou o Não Estresse Fiscal Erro do Tipo II



Fonte: Elaborada pelos autores.