

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE ESTRESSE FISCAL EM MUNICÍPIOS DE MINAS GERAIS

DANIEL VITOR TARTARI GARRUTI
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

FLAVIO LUIZ DE MORAES BARBOZA
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

JOSEDILTON
UNIVERSIDADE FEDERAL DA PARAÍBA (UFPB)

Agradecimento à órgão de fomento:
CAPES

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE ESTRESSE FISCAL EM MUNICÍPIOS DE MINAS GERAIS

1 Introdução

O tema da Condição Financeira Governamental surgiu nos Estados Unidos no século passado, em meio a crises enfrentadas pelos governos locais (CLARK, 1994). No entanto, esse assunto é ainda recente no Brasil e começou a ser debatido na literatura local após a publicação da obra de Lima e Diniz (2016). É fundamental que um ente subnacional tenha 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).

Enquanto a condição fiscal está relacionada com o 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). Logo, uma gestão apropriada dos recursos favorece a geração de emprego e renda, e, como consequência, diminui o risco de inadimplência do próprio governo (BISOGNO et al., 2019; NAVARRO-GALERA et al., 2017).

De acordo com Dantas Junior, Diniz e Lima (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). Se não for possível cobrir todas as despesas, pode-se concluir que a localidade está passando por um momento de 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 dos Estados Unidos. Enquanto Chen (2021) utilizou técnicas de Inteligência Artificial (IA) para prever o estresse fiscal, alcançando uma taxa de acerto de aproximadamente 85%.

É evidente a preocupação global com o assunto e, no Brasil, tem aumentado ultimamente, com a Secretaria do Tesouro Nacional publicando uma visão integrada da dívida consolidada a partir de 2017. Em 2021, a dívida de todos os estados do país chegou a cerca de 1 trilhão de reais, e o estado de Minas Gerais representou mais de 15% desse total, com um montante de R\$ 154 bilhões (TNT, 2022).

Diante da relevância do estresse fiscal para a gestão pública e a necessidade de aprimorar as técnicas de previsão desse fenômeno, este trabalho tem como objetivo aplicar o RF na previsão de estresse fiscal em municípios de Minas Gerais. Para isso, foi utilizado 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, Godsey e Shulman (1981) e Groves e Valente (2003).

Os resultados indicaram que o modelo apresentou melhor desempenho na previsão de estresse fiscal, com uma média de acertos de 68,4%. Esse valor foi superior à classificação inicial da amostra de 2011 proposta por Trussel e Patrick (2018). Por outro lado, a previsão de ausência de estresse fiscal obteve uma taxa de acerto de 49,2%. É importante ressaltar que esses resultados foram impactados pela crise da Covid-19, apresentando mudanças significativas.

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 ou não do evento investigado, os resultados apresentaram melhora substancial, atingindo uma taxa de previsão correta de 85% para os municípios. É válido destacar que esse resultado é semelhante ao encontrado por Chen (2021).

Destaca-se ainda 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 pelos autores. Não obstante, uma implicação deste

trabalho é a antecipação da verificação 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 coletados. Sugere-se, portanto, para pesquisas futuras, ampliar a abrangência para todas as cidades brasileiras, considerar outras metodologias de IA, estender o período de análise e avaliar outras variáveis relevantes.

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; GODSEY; SHULMAN, 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; DI MEDIO; MCNENA., 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 trabalho seminal de Groves, Godsey e Shulman (1981) apresenta uma das maneiras mais abrangentes de análise da Condição Financeira Governamental, que é afetada por três fatores principais: 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, Weissert e Kleine (2005), acrescido de duas variáveis referentes à independência financeira propostas por Zafra-Gómez, López-Hernández e Hernández-Bastida (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, tendo como primeiro trabalho o de Lima e Diniz (2016). Observa-se que o tema começa a ser discutido em períodos de instabilidade econômica do país, como nos anos de 2015 e 2016, considerados de baixo crescimento (DANTAS JUNIOR; DINIZ; LIMA, 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, como períodos de crise, estão fora de seu controle.

Por fim, este assunto ganhou notoriedade em época de instabilidades econômicas nos municípios dos Estados Unidos (CLARK, 1994). Após a crise financeira internacional de 2008,

a preocupação acerca da temática aumentou (ANTULOV-FANTULIN; LAGRAVINESE; RESCE, 2021; CHUNG; WILLIAMS, 2021).

Quanto à pandemia da Covid-19, há poucos resultados na literatura, embora McDonald e Larson (2020) tenham investigado como a queda na arrecadação de impostos poderia afetar a saúde fiscal de entes subnacionais da Carolina do Norte, verificando cenários preocupantes para as finanças. Maher, Hoang e Hindery (2020) afirmam que organizações sem fins lucrativos precisam de reservas financeiras para períodos como este e que os efeitos fiscais seriam percebidos apenas após dois anos da recente crise, mas que as possíveis lições aprendidas pelos Governos Locais na recessão de 2008 poderiam colocá-los em uma posição melhor.

O objetivo deste trabalho é analisar a realidade 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, pois as demandas dos serviços públicos podem variar de acordo com a população atendida. Logo, investigou-se a condição fiscal.

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 a agravar a situação, reforçando a importância de manter programas sociais para serviços essenciais e uma retomada econômica em prazo mais curto.

A Condição Fiscal é um aspecto financeiro que caracteriza a dificuldade enfrentada por governos locais (LIMA; DINIZ, 2016). Nesse sentido, é parte da Condição Financeira Governamental, uma vez que a falta de recursos pode afetar a qualidade e até mesmo resultar em cortes de serviços essenciais. 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 alto 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 quais fatores influenciam a gestão fiscal dos municípios do Paraná e encontraram uma relação positiva entre as variáveis 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.

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; COSTANZO; MANES-ROSSI, 2017). Dantas Junior, Diniz e Lima (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 terá como ponto de partida o modelo de Trussel e Patrick (2018) e considerará os três fatores de variáveis mencionados por Groves, Godsey e Shulman (1981) e Groves e Valente (2003), além de levar em conta a realidade brasileira, como a Lei de Responsabilidade Fiscal (LRF) e os estudos de Hendrick (2004), Dantas Junior, Diniz e Lima (2019), Silva *et al.* (2020) e Bolognesi, Ribeiro e Codato (2023). A variável dependente a ser analisada será o *stress test* de Bowman e Calia (1997), e o modelo de previsão será baseado na técnica RF de IA.

Para este propósito, foram utilizados o IBGE para coletar informações sobre o código do município, área, mesorregião e estimativa populacional, e a base de dados da Secretaria do Tesouro Nacional, a SICONFI, para coletar os dados financeiros de 2014 a 2021. A Tabela 1 apresenta a quantidade de municípios analisados em cada ano, indicando quantos foram afetados ou não pelo estresse fiscal no período seguinte. É importante destacar que foram coletados dados de todos os 853 municípios, porém a amostra final é menor devido a dados ausentes.

TABELA 1 - 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 de acordo com o *stress test*.

Fonte: Dados da pesquisa.

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; DINIZ; LIMA, 2019). O processo de análise requer quatro etapas, seguido da avaliação dos sinais, como apresentado na Tabela 2.

Na primeira, é realizado o cálculo do superávit financeiro no ano t. Na segunda, é calculada a variação do superávit financeiro entre os anos t e t-1. Na terceira, é calculada a variação das despesas operacionais entre os mesmos anos. Por fim, na quarta e última, é obtido o resultado do *stress test*, que consiste na divisão entre a variação do superávit financeiro e das despesas correntes.

TABELA 2 - Análise dos resultados para a condição fiscal.

Resultado	Despesas operacionais	Condição
$Stress\ test \leq 1$	Crescente	1
$Stress\ test > 1$	Decrescente	1
$Stress\ test \leq 1$	Decrescente	0
$Stress\ test > 1$	Crescente	0

Nota: Se o resultado do superávit financeiro for de déficit para os dois anos necessários do cálculo, considera-se em estresse fiscal.

Fonte: Adaptado de Bowman e Calia (1997).

As variáveis independentes do modelo foram, em sua maioria, baseadas no trabalho de Trussel e Patrick (2018), mas algumas foram adaptadas para o contexto brasileiro. Ademais, considerou-se os fatores ambientais, governamentais e financeiros que influenciam a condição financeira, definidos por Groves, Godsey e Shulman (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 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. As variáveis de despesas em saúde e educação 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, Diniz e Lima (2019).

De acordo com Groves e Valente (2003), em locais com altos níveis de emprego, a população tende a recorrer menos aos serviços públicos, já que preferem arcar com os gastos. Por outro lado, Dantas Junior, Diniz e Lima (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).

A variável de despesa com pessoal 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.

No Brasil, a lei complementar nº 101 de 2000 estabelece regras para que os entes da União possam ter 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 e, quando ultrapassado 90% do limite (54%), os tribunais de contas alertam os poderes (CIVIL *et al.*, 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).

QUADRO 1 - Variáveis independente do modelo.

Categorias	Indicador	Conta	Referência	
V1	Receita per capita	$\frac{Receita\ total}{População}$	(TRUSSEL; PATRICK, 2018)	
V2	Receitas intergovernamentais	$\frac{Receitas\ de\ outros\ governos}{Receitas\ totais}$	(TRUSSEL; PATRICK, 2018)	
V3	Indicadores baseados em operações	Despesas per capita	$\frac{Despesa\ total}{População}$	(TRUSSEL; PATRICK, 2018)
V4		Posição operacional	$\frac{Receita\ total}{Despesa\ total}$	(TRUSSEL; PATRICK, 2018)
V5	Despesas em saúde	$\frac{Despesas\ em\ saúde}{Receita\ total}$	(DANTAS JUNIOR; DINIZ; LIMA, 2019)	
V6	Despesas em educação	$\frac{Despesas\ em\ educação}{Receita\ total}$	(DANTAS JUNIOR; DINIZ; LIMA, 2019)	
V7	Serviço da dívida	$\frac{Juros\ e\ encargos\ da\ dívida}{Receita\ Total}$	(TRUSSEL; PATRICK, 2018)	
V8	Indicadores baseados na dívida	Dívida para receita	$\frac{Dívida\ total}{Receita\ total}$	(TRUSSEL; PATRICK, 2018)
V9		Passivo per capita	$\frac{Passivo\ total}{População}$	(TRUSSEL; PATRICK, 2018)
V10	Indicadores baseados na estrutura de capital	Dívida para ativo	$\frac{Dívida\ total}{Ativo\ total}$	(TRUSSEL; PATRICK, 2018)
V11		Patrimônio líquido para receita	$\frac{Patrimônio\ Líquido}{Receita\ Total}$	(TRUSSEL; PATRICK, 2018)
V12		Patrimônio líquido para ativo	$\frac{Patrimônio\ Líquido}{Ativo\ Total}$	(TRUSSEL; PATRICK, 2018)
V13	Indicadores baseados na liquidez	Caixa para receita	$\frac{Caixa\ +\ investimentos}{Receita\ total}$	(TRUSSEL; PATRICK, 2018)
V14		Caixa para dívida	$\frac{Caixa\ +\ investimentos}{Dívida\ total}$	(TRUSSEL; PATRICK, 2018)
V15		Liquidez corrente	$\frac{Ativo\ circulante}{Passivo\ circulante}$	(TRUSSEL; PATRICK, 2018)
V16	Indicador baseado em funcionários	Gasto com pessoal	$\frac{Gasto\ com\ pessoal}{Receita\ corrente\ líquida}$	Adaptada da (CIVIL et al., 2000)
V17	Indicador baseado em impostos	Concentração da receita tributária	$\frac{Receita\ tributária}{Receita\ total}$	(TRUSSEL; PATRICK, 2018)
V18		População	Logaritmo natural da estimativa da população	(TRUSSEL; PATRICK, 2018)
V19	Outros indicadores e variáveis de controle	Participação de despesas de capital	$\frac{Despesa\ de\ capital}{Despesa\ total}$	(TRUSSEL; PATRICK, 2018)
V20		Densidade populacional	$\frac{População}{Área\ do\ município}$	(HENDRICK, 2004)
V21		Localização	Mesorregiões de Minas Gerais	Adaptada de Silva et al. (2020)
V22	Ideologia política	Partidos de esquerda ou direita	(BOLOGNESI; RIBEIRO; CODATO, 2023)	

Fonte: Elaborada pelos autores.

Foram acrescentadas três variáveis aos outros indicadores e variáveis de controle, sendo as últimas do modelo. A densidade populacional, 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.

Trussel e Patrick (2018) utilizaram o tipo de município como variável de controle, pois nos Estados Unidos esses entes subnacionais são divididos em diferentes categorias, mas essa divisão não existe no Brasil. Diante disso e com base em estudos relevantes (ANTULOV-FANTULIN; LAGRAVINESE; RESCE, 2021; PRESTON, 1985; PSYCHARIS; ZOI; ILIOPOULOU, 2016), utilizou-se as mesorregiões de Minas Gerais para a pesquisa, uma vez que essas regiões possuem indicadores importantes para estudos nessa área. Além disso, Silva *et al.* (2020) destacam que a localização geográfica é significativa para a gestão fiscal no Brasil.

Para fins de pesquisa sobre a condição fiscal, as ideologias políticas são interessantes. Em Portugal, municípios governados por partidos de direita apresentaram maior probabilidade de enfrentar dificuldades financeiras (LOBO; RAMOS; LOURENÇO, 2011). Para classificar a ideologia dos partidos em esquerda ou direita, utilizou-se o estudo de Bolognesi, Ribeiro e Codato (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:

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

Neste modelo, $P_{Y(i,t)}$ é a probabilidade de o município i sofrer estresse fiscal no ano, ou seja, a variável *dummy* igual a 1, se for estressado fiscalmente, e igual a 0, se não for; $V_{i,t-1}$, é o vetor das variáveis independentes da cidade i no ano $t-1$; e $\varepsilon_{i,t-1}$ refere-se ao termo de erro da cidade i no ano $t-1$.

3.2 Inteligência Artificial

As técnicas de Inteligência Artificial (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; CUTLER; STEVENS, 2012). Recentemente, sua importância tem sido destacada em estudos de previsão de estresse financeiro de empresas e valores de ações, como nos trabalhos de Malakauskas e Lakstutiene (2021) e Patel *et al.* (2015).

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, Lagravinese e Resce (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.

Neste estudo, utiliza-se a técnica de aprendizado de máquina 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. Além disso, o autor afirma que a técnica não apresenta problemas de *overfitting*, sendo, portanto, um previsor confiável, que pode ser facilmente implementado.

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

Nesta pesquisa, utilizou-se a linguagem de programação *Python* para desenvolver o modelo e analisar os resultados. Foram avaliados diferentes períodos, incluindo os três primeiros 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. Conseqüentemente, 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, Lagravinese e Resce (2021). Os dados de treinamento foram equilibrados em relação à variável dependente, seguindo a prática de Antulov-Fantulin, Lagravinese e Resce (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: precisão, 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; DANOVI; FALINI, 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; LAGRAVINESE; RESCE, 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 um 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.

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.

TABELA 3 - Resultados do modelo.

Validação	Condição	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Suporte
2016	Não Estresse (0)	0,46	0,45	0,45	155
	Estresse (1)	0,74	0,76	0,75	330
	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	344
	Acurácia			0,60	725
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: *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.

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 mais baixos, mas conseguiram superar os resultados citados em alguns pontos.

4.1 Área cinzenta

Tais áreas são caracterizadas pela imprecisão, com uma baixa probabilidade de ocorrer o que foi previsto (ALTMAN; DANOVI; FALINI, 2013), assim, a remoção dessas áreas 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. 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, que é igual à referência.

Além disso, 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%.

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 Iacuzzi (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.

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.

Tal resultado contradiz os estudos de Groves e Valente (2003) e vai de encontro às proposições de Antulov-Fantulin, Lagravinese e Resce (2021), que consideram alguns indicadores referentes à região como mais importantes do que dados financeiros para a previsão. Também se opõe 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. Portanto, é possível que os indicadores financeiros já contemplem os efeitos dessas variáveis ambientais.

As variáveis referentes às despesas com saúde e educação, que ficaram abaixo da média, merecem destaque por sua importância. Este resultado é significativo, à luz das lições aprendidas com Vieira (2016), uma vez que, 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, Diniz e Lima (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, Hoang e Hindery (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.

A pesquisa 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 Iacuzzi (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, Lagravinese e Resce (2021). Verificou-se ainda que os fatores ambientais e organizacionais não tiveram relevância na análise, o que não confirma a definição de Groves, Godsey e Shulman (1981) e Groves e Valente (2003).

Embora apresente algumas melhorias, este trabalho possui limitações, como o pequeno período pesquisado, pois a base do SICONFI possui dados apenas após 2014, além de se investigar apenas municípios de um estado brasileiro. Desta maneira, sugere-se como trabalho futuro uma ampliação do tempo de pesquisa, analisando o período pós-pandemia, bem como uma análise de todos os municípios brasileiros. Além disso, verifica-se a possibilidade de empregar outras metodologias de IA, assim como mais variáveis.

Apesar de ter algumas melhorias, este estudo tem limitações, como a restrição temporal, já que a base do SICONFI apresenta apenas dados após 2014, e a análise é restrita a municípios de um único estado brasileiro. Portanto, é sugerido como trabalho futuro a expansão do período de pesquisa para incluir o período pós-pandemia, bem como uma análise de todos os municípios brasileiros. Além disso, há a possibilidade de explorar outras metodologias de IA e incluir mais variáveis na análise.

Referências

ALTMAN, Edward I.; DANOVI, Alessandro; FALINI, Alberto. Z-Score Models' application to Italian companies subject to extraordinary administration. **Journal of Applied Finance (Formerly Financial Practice and Education)**, v. 23, n. 1, 2013.

ANTULOV-FANTULIN, Nino; LAGRAVINESE, Raffaele; RESCE, Giuliano. Predicting bankruptcy of local government: A machine learning approach. **Journal of Economic Behavior & Organization**, v. 183, p. 681-699, 2021.

BISOGNO, Marco et al. Budgetary solvency of Italian local governments: an assessment. **International Journal of Public Sector Management**, v. 32, n. 2, p. 122-141, 2019.

BOLOGNESI, Bruno; RIBEIRO, Ednaldo; CODATO, Adriano. Uma nova classificação ideológica dos partidos políticos brasileiros. **Dados**, v. 66, 2022.

BOWMAN, W., & CALIA, R. Evaluating Local Government Financial Health: Financial Indicators. **The civic federation**, 1997.

BREIMAN, L. Random Forests. **Machine Learning**, 45, 5–32, 2001.

BROWN, Ken W. et al. The 10-point test of financial condition: Toward an easy-to-use assessment tool for smaller cities. **Government Finance Review**, v. 9, p. 21-21, 1993.

CHEN, Dan. Risk assessment of government debt based on machine learning algorithm. **Complexity**, v. 2021, p. 1-12, 2021.

CHUNG, Il Hwan; WILLIAMS, Daniel. Local governments' responses to the fiscal stress label: the case of New York. **Local Government Studies**, v. 47, n. 5, p. 808-835, 2021.

- CLARK, Terry Nichols. Fiscal management of American cities: Funds flow indicators. **Journal of Accounting Research**, p. 54-94, 1977.
- CLARK, Terry N. Municipal fiscal strain: Indicators and causes. **Government Finance Review**, v. 10, p. 1-27, 1994.
- COHEN, Sandra; COSTANZO, Antonella; MANES-ROSSI, Francesca. Auditors and early signals of financial distress in local governments. **Managerial Auditing Journal**, 2017.
- CUTLER, Adele; CUTLER, D. Richard; STEVENS, John R. Random forests. **Ensemble machine learning: Methods and applications**, p. 157-175, 2012.
- DANTAS JUNIOR, Amarando Francisco; DINIZ, Josedilton Alves; LIMA, Severino Cesário de. A INFLUÊNCIA DO FEDERALISMO FISCAL SOBRE O ESTRESSE FISCAL DOS MUNICÍPIOS BRASILEIROS. **Advances in Scientific & Applied Accounting**, v. 12, n. 3, 2019.
- GARCÍA-SÁNCHEZ, Isabel-María et al. A new predictor of local financial distress. **International Journal of Public Administration**, v. 35, n. 11, p. 739-748, 2012.
- GERRISH, Ed; SPREEN, Thomas Luke. Does benchmarking encourage improvement or convergence? Evaluating North Carolina's fiscal benchmarking tool. **Journal of public administration research and theory**, v. 27, n. 4, p. 596-614, 2017.
- GROVES, Sanford M.; GODSEY, W. Maureen; SHULMAN, Martha A. Financial indicators for local government. **Public Budgeting & Finance**, v. 1, n. 2, p. 5-19, 1981.
- Groves, S. M., & Valente, M. G. Evaluating financial condition: A handbook for local government. **The international City/Country Management Association – ICMA**, 2003.
- HENDRICK, Rebecca. Assessing and measuring the fiscal health of local governments: Focus on Chicago suburban municipalities. **Urban Affairs Review**, v. 40, n. 1, p. 78-114, 2004.
- HONADLE, Beth Walter. The states' role in US local government fiscal crises: A theoretical model and results of a national survey. **International Journal of Public Administration**, v. 26, n. 13, p. 1431-1472, 2003.
- IACUZZI, Silvia. An appraisal of financial indicators for local government: a structured literature review. **Journal of Public Budgeting, Accounting & Financial Management**, v. 34, n. 6, p. 69-94, 2022.
- JUCÁ, Michele Nascimento; FISHLOW, Albert. Political uncertainty of impeachment upon corporate investment decisions. **Borsa Istanbul Review**, v. 21, n. 2, p. 149-160, 2021.
- KLOHA, Philip; WEISSERT, Carol S.; KLEINE, Robert. Developing and testing a composite model to predict local fiscal distress. **Public Administration Review**, v. 65, n. 3, p. 313-323, 2005.
- CIVIL, Casa et al. LEI COMPLEMENTAR Nº 101, DE 4 DE MAIO DE 2000. **Estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências**, 2000.
- LIMA, SC de; DINIZ, Josedilton Alves. Contabilidade pública: análise financeira governamental. **São Paulo: Atlas**, v. 576, 2016.
- LIN, Tom CW. Artificial intelligence, finance, and the law. **Fordham L. Rev.**, v. 88, p. 531, 2019.

- LOBO, Flora Cunha; RAMOS, Pedro; LOURENCO, Oscar. Causes of financial distress of Portuguese municipalities: empirical evidence. **International Journal of Monetary Economics and Finance**, v. 4, n. 4, p. 390-409, 2011.
- MAHER, Craig S.; HOANG, Trang; HINDERLY, Anne. Fiscal responses to COVID-19: Evidence from local governments and nonprofits. **Public Administration Review**, v. 80, n. 4, p. 644-650, 2020.
- MALAKAUSKAS, Aidas; LAKŠTUTIENĖ, Aušrinė. Financial distress prediction for small and medium enterprises using machine learning techniques. **Engineering Economics**, v. 32, n. 1, p. 4-14, 2021.
- MCDONALD, Bruce; LARSON, Sarah. Implications of the coronavirus on sales tax revenue and local government fiscal health. **Journal of Public and Nonprofit Affairs**, v. 6, n. 3, p. 377-400, 2020.
- MEYER, Daniel F.; NEETHLING, Jan R. An assessment of the financial health of the South African metropolitan municipal regions. In: **Forum Scientiae Oeconomia**. p. 59-77, 2021.
- MIRANDA, Walter Luiz Leite Carvalho et al. Avaliação da gestão fiscal nos estados brasileiros: análise no quinquênio 2011 a 2015. **Revista Mineira de Contabilidade**, v. 19, n. 1, p. 55-67, 2018.
- NAVARRO-GALERA, Andrés et al. What can increase the default risk in local governments?. **International Review of Administrative Sciences**, v. 83, n. 2, p. 397-419, 2017.
- OLIVEIRA, Tomas Matheus Giacomet et al. Gestão Fiscal Municipal: uma análise sob a ótica do federalismo fiscal e dos ciclos políticos nos governos locais. **Administração Pública e Gestão Social**, 2021.
- PATEL, Jigar et al. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. **Expert systems with applications**, v. 42, n. 1, p. 259-268, 2015.
- PRESTON, Brian T. Rich town, poor town: the distribution of rate-borne spending levels in the Edwardian city system. **Transactions of the Institute of British Geographers**, p. 77-94, 1985.
- PSYCHARIS, Yannis; ZOI, Maria; ILIOPOULOU, Stavroula. Decentralization and local government fiscal autonomy: evidence from the Greek municipalities. **Environment and Planning C: Government and Policy**, v. 34, n. 2, p. 262-280, 2016.
- SILVA, Maurício Corrêa et al. Fatores explicativos da gestão fiscal em municípios brasileiros. **Revista Contemporânea de Contabilidade**, v. 17, n. 42, p. 26-37, 2020.
- STANLEY, D. T.; LEVINE, C. H. Managing fiscal stress: the crises in the public sector. 1980.
- TNT, T. N. T. (2022). Visão Integrada das Dívidas da União, dos Estados, do Distrito Federal e dos Municípios.
- TRUSSEL, John M.; PATRICK, Patricia A. Assessing and ranking the financial risk of municipal governments: The case of Pennsylvania. **Journal of Applied Accounting Research**, 2018.
- TURLEY, Gerard et al. A reassessment of local government's financial position and performance: The case of Ireland. **Administration**, v. 68, n. 2, p. 1-35, 2020.

VIEIRA, Fabiola Sulpino. Crise econômica, austeridade fiscal e saúde: que lições podem ser aprendidas? 2016.

ZAFRA-GÓMEZ, José Luis; LÓPEZ-HERNÁNDEZ, Antonio Manuel; HERNÁNDEZ-BASTIDA, Agustín. Developing an alert system for local governments in financial crisis. **Public Money & Management**, v. 29, n. 3, p. 175-181, 2009.

Apêndice 1: Resultados da área cinzenta

Validação	Condição	Corte de 45% a 55%				Corte de 40% a 60%				Corte de 35% a 65%				Corte de 30% a 70%				Corte de 25% a 75%			
		Precisiono	Recall	F1-Score	Quantidade	Precisiono	Recall	F1-Score	Quantidade	Precisiono	Recall	F1-Score	Quantidade	Precisiono	Recall	F1-Score	Quantidade	Precisiono	Recall	F1-Score	Quantidade
2016	Não estresse (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
	Estresse (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
	Acurácia			0,67	411			0,70	330			0,73	270			0,79	200			0,81	160
2017	Não estresse (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
	Estresse (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
	Acurácia			0,67	491			0,71	385			0,75	324			0,80	262			0,85	212
2018	Não estresse (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
	Estresse (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
	Acurácia			0,64	640			0,66	578			0,71	509			0,76	434			0,81	352
2019	Não estresse (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
	Estresse (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
	Acurácia			0,63	561			0,68	392			0,71	306			0,79	213			0,83	166
2020	Não estresse (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
	Estresse (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
	Acurácia			0,79	620			0,81	526			0,81	437			0,82	317			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.