

**FUNDAÇÃO GETULIO VARGAS
ESCOLA BRASILEIRA DE ADMINISTRAÇÃO PÚBLICA E DE EMPRESAS
MESTRADO PROFISSIONAL EM ADMINISTRAÇÃO PÚBLICA**

**IMPACTO DA INTELIGÊNCIA ARTIFICIAL NA
ATIVIDADE DE AUDITORIA:
EQUACIONANDO GARGALOS NOS REPASSES DA UNIÃO
PARA ENTES SUBNACIONAIS**

DISSERTAÇÃO APRESENTADA À ESCOLA BRASILEIRA DE
ADMINISTRAÇÃO PÚBLICA E DE EMPRESAS PARA OBTENÇÃO DO
GRAU DE MESTRE

SÉRGIO TADEU NEIVA CARVALHO

Rio de Janeiro - 2020

SÉRGIO TADEU NEIVA CARVALHO

**IMPACTO DA INTELIGÊNCIA ARTIFICIAL NA ATIVIDADE DE
AUDITORIA: EQUACIONANDO GARGALOS NOS REPASSES DA UNIÃO
PARA ENTES SUBNACIONAIS**

Dissertação apresentada à Escola Brasileira de Administração Pública e de Empresas para obtenção do grau de Mestre.

Orientador: Professor Dr. Bernardo Guelber Fajardo

RIO DE JANEIRO – 2020

Dados Internacionais de Catalogação na Publicação (CIP)
Ficha catalográfica elaborada pelo Sistema de Bibliotecas/FGV

Carvalho, Sérgio Tadeu Neiva

Impacto da inteligência artificial na atividade de auditoria: equacionando gargalos nos repasses da união para entes subnacionais / Sérgio Tadeu Neiva Carvalho. – 2020.

114 f.

Dissertação (mestrado) – Escola Brasileira de Administração Pública e de Empresas, Centro de Formação Acadêmica e Pesquisa.

Orientador: Bernardo Guelber Fajardo.

Inclui bibliografia.

1. Administração pública. 2. Auditoria - Processamento de dados. 3. Prestação de contas. 4. Inteligência artificial. I. Fajardo, Bernardo de Abreu Guelber. II. Escola Brasileira de Administração Pública e de Empresas. Centro de Formação Acadêmica e Pesquisa. III. Título.

CDD – 658.054

SÉRGIO TADEU NEIVA CARVALHO


“IMPACTO DA INTELIGÊNCIA ARTIFICIAL NA ATIVIDADE DE AUDITORIA: EQUACIONANDO GARGALOS NOS REPASSES DA UNIÃO PARA ENTES SUBNACIONAIS”.


Trabalho de conclusão apresentado(a) ao Curso de Mestrado Profissional em Administração Pública do(a) Escola Brasileira de Administração Pública e de Empresas da Fundação Getulio Vargas para obtenção do grau de Mestre(a) em Administração Pública.


Data da defesa: 04/09/2020

ASSINATURA DOS MEMBROS DA BANCA EXAMINADORA

Presidente da Comissão Examinadora: Prof^o Bernardo de Abreu Guelber Fajardo



Bernardo de Abreu Guelber Fajardo
Orientador


PI Marco Antonio Carvalho Teixeira
Membro Interno


PI Thiago Veiga Marzagão
Membro Externo

Em cumprimento Lei nº 13.979 de 06/02/20 - DOU nº 27 de 07/02/20, a Portaria MEC nº 473 de 12/05/20 - DOU nº 90 de 13/05/20 e ao Decreto nº 068 de 11/05/20 - Poder Executivo do Estado do Rio de Janeiro, DOE nº 082-A em 11/05/20 que dispõe sobre a suspensão temporária das atividades acadêmicas presenciais e a utilização de recursos tecnológicos (em conformidade à legislação vigente), face ao COVID-19, as apresentações das defesas de Tese e Dissertação, de forma excepcional, serão realizadas de forma remota e síncrona, incluindo-se nessa modalidade membros da banca e discente.


Flavio Carvalho de Vasconcelos
Diretor


Antonio de Araujo Freitas Junior
Pró-Reitor de Ensino, Pesquisa e Pós-Graduação FGV
Antonio Freitas, PhD
Pró-Reitor de Ensino, Pesquisa e Pós-Graduação
Fundação Getúlio Vargas

Instrução Normativa nº 01/19, de 09/07/19 - Pró-Reitoria FGV

Em caso de participação de Membro(s) da Banca Examinadora de forma não-presencial*, o Presidente da Comissão Examinadora assinará o documento como representante legal, delegado por esta I.N.

*Skype, Videoconferência, Apps de vídeo etc

*“A simplicidade é o último grau de
sophisticacão.”*

(Leonardo da Vinci, 1452-1519)

AGRADECIMENTOS

Primeiramente, aos meus pais, Deia e Romeu. Seu esforço, preocupação e empenho em prover a mim uma educação de qualidade são seu melhor legado, muito maior do que qualquer presente que eu poderia ter. Muito obrigado, Mãe e Pai.

À Aryana, minha amada esposa, a quem dedico este trabalho, porque sem ela nada seria possível. Seu apoio, compreensão e ternura durante meus momentos difíceis nesta jornada foram fundamentais.

À CGU, instituição pela qual tenho muito carinho, patrocinadora dessa empreitada. As implicações desta dissertação passarão a ser imediatamente colocadas em prática na política pública de Transferências Voluntárias da União, proporcionando um serviço público melhor para a sociedade brasileira.

Ao meu Orientador, Prof. Dr. Bernardo Fajardo, quem me conduziu ao longo desta trajetória para o alcance dos resultados apresentados na pesquisa.

Aos meus colegas de turma de Mestrado, que me acolheram tão bem e fizeram minha experiência mais feliz. Começamos o caminho como colegas e encerramos como verdadeiros amigos.

Aos meus Professores e Monitores da EBAPE, com quem aprendi a olhar a vida de maneira diferente. Sou especialmente grato a: Fernando Tenório, Octávio Amorim Neto, Gregory Michener, Edson Kondo, Roberto Pimenta, Armando Cunha, Paulo Motta, Diego de Faveri, Yuna Fontoura, Joaquim Rubens Filho, e ao meu amigo Diego Altieri.

Aos meus chefes imediatos e colegas de trabalho da CGU, especialmente Lea, Gustavo e Dias, que sempre foram sensíveis à importância deste momento e entenderam as minhas ausências.

Ao Gustavo Van Erven, amigo e colega de CGU, pelo incentivo e inspiração do tema da dissertação. Sua paciência e ensinamentos foram imprescindíveis para que eu trilhasse o caminho certo.

Ao meu tio e padrinho Délio, por ter sido um grande entusiasta e incentivador nos meus estudos acadêmicos.

Por fim, cada pessoa que Deus tem colocado no meu caminho e que, de alguma forma, contribuiu para a conclusão deste trabalho. Certamente, essa é uma vitória coletiva e não quero e nunca me esquecerei disso.

RESUMO

Objetivos: Esta pesquisa visa compreender as circunstâncias em que o uso do sistema “*Malha Fina de Convênios*”, que usa Inteligência Artificial (IA) para analisar as prestações de contas de convênios e prevê o resultado da análise, é suficientemente percuciente para dispensar a necessidade de análise convencional de prestação de contas de convênios por parte de servidores públicos. A utilização de técnicas de auditoria por meio de soluções tecnológicas como *machine learning* (ML) e IA vem se ampliando no setor privado com impactos positivos em termos de prevenção às fraudes e incremento da eficiência e eficácia do trabalho realizado pelos auditores. Entretanto, os estudos acerca de seu uso na Administração Pública ainda são incipientes. Logo, este trabalho almeja, também, compreender os impactos da IA na atividade de auditoria. **Metodologia:** a estratégia metodológica valeu-se da implementação empírica de um ambiente computacional em linguagem *python* para testar 2 arquiteturas de treinamento para a aprendizagem do algoritmo, parametrizando a sequência de treinamento conforme o seu tamanho e a identidade do órgão concedente. Dessa forma, o desempenho dos algoritmos foi avaliado pelas métricas inexatidão (ϵ) e *Area Under the Curve* (AUC). **Resultados:** os resultados apontam que a identidade do órgão concedente influencia o desempenho do algoritmo de ML e à medida que o tamanho da sequência de treinamento cresce, o desempenho aumenta, não obstante ocorra um ponto de saturação em que o aumento do tamanho não interfere no desempenho. **Limitações:** ocorre um intenso desbalanceamento das sequências de treinamento, na medida em que a quantidade de contas rejeitas é muito inferior às contas aprovadas. Além disso, as arquiteturas de teste exigem grande capacidade computacional para serem executadas. **Contribuições:** a compreensão do desempenho do “*Malha Fina de Convênios*” diante de circunstâncias diferentes validará essa abordagem inovadora, fazendo com que os atores do processo de Transferências Voluntárias da União empreguem seus esforços apenas nos convênios com indícios de rejeição, racionalizando a força de trabalho. **Originalidade:** pelo conhecimento adquirido durante esta pesquisa, constatou-se que este é o primeiro trabalho que aborda o uso de IA nas Transferências Voluntárias da União.

Palavras-Chave: *Controle, Auditoria, Inteligência Artificial, Administração Pública, Transferências Discricionárias*

ABSTRACT

Purpose: This research aims to understand the circumstances in which the use of the “*Malha Fina de Convênios*” system, which uses *Artificial Intelligence* (AI) to analyze the provision of accounts and predicts the result of the analysis, is sufficiently clear to dispense the need for conventional analysis by public servants. The use of auditing techniques through technological solutions such as *machine learning* (ML) and AI has been expanding in the private sector with positive impacts in terms of preventing fraud and increasing the efficiency and effectiveness of the work performed by the auditors. However, studies on its use in Public Administration are still incipient. Therefore, this work also aims to understand the impacts of AI in the audit activity. **Methodology:** the methodological strategy used an empirical implementation of a computational environment in Python to test 2 training architectures for the ML algorithm, parameterizing the training sequence according to its size and the identity of the granting public agency. Thus, the performance of the algorithms was evaluated by the metrics inaccuracy (ϵ) and Area Under the Curve (AUC). **Findings:** the results indicate that the identity of the granting public agency influences the performance of the ML algorithm and as the size of the training sequence grows, the performance increases, despite the occurrence of a saturation point in which the increase in size does not interfere with performance. **Research limitations:** there is an intense imbalance of the training sequences, as the number of rejected accounts is much lower than the approved accounts. In addition, test architectures require large computational capacity to be executed. **Practical implications:** an understanding of the performance of the “*Malha Fina de Convênios*” under different circumstances will validate this innovative approach, making the actors of the Brazilian’s Discretionary Transfers process employ their efforts only in accounts with signs of rejection, rationalizing the workforce and save their efforts, which allows capacity for other issues. **Originality:** from the knowledge acquired during this research, it was found that this is the first work that addresses the use of AI in Brazilian’s Discretionary Transfers.

Keywords: *Control, Auditing, Artificial Intelligence, Public Administration, Discretionary Transfers*

LISTA DE TABELAS

Tabela 1 - Quantitativo e Valores Totais de instrumentos operacionalizados na Plataforma +Brasil por natureza jurídica do destinatário. Elaborado pelo autor. Fonte: Plataforma +Brasil.	19
Tabela 2 - Passivo de convênios aguardando análise do concedente nas prestações de contas em 31/12/2017. Elaborado pelo Autor. Fonte Plataforma +Brasil.....	44
Tabela 3 - Passivo de convênios aguardando análise do concedente nas prestações de contas em 31/08/2018. Elaborado pelo Autor. Fonte Plataforma +Brasil.....	45
Tabela 4 - Distribuição da nota atribuída pelo algoritmo aos 13.992 convênios aguardando análise da prestação de contas em 31/12/2017.	49
Tabela 5 - Distribuição do score atribuído pelo algoritmo do sistema "Malha Fina de Convênios" aos convênios analisados entre 01/01/2018 e 18/04/2018.	50
Tabela 6 - Distribuição do intervalo acumulado de notas atribuídas pelo "Malha Fina de Convênios" dos convênios analisados entre 01/01/2018 e 18/04/2018.....	51
Tabela 7 - Relacionamento entre Constructos e Hipóteses de Pesquisa. Fonte: Elaborado pelo autor.	54
Tabela 8 – Distribuição da situação das prestações de contas dos convênios dos 10 órgãos mais representativos da população. Fonte: Plataforma +Brasil. Data base: novembro de 2019.	60
Tabela 9 - Amostra utilizada para realizar os testes do construto “Identidade do repassador de recurso”. Fonte: elaborado a partir do ANEXO II	65
Tabela 10 - Amostra utilizada para realizar os testes do construto “Tamanho de treinamento de dados”. Data base janeiro de 2020. Fonte: Plataforma +Brasil.	68
Tabela 11 – Métrica Inexatidão (ϵ) do Algoritmo de IA treinado a partir do universo (Probabilidade de Falso Positivo).....	72
Tabela 12 – Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios de cada órgão concedente. (Probabilidade de Falso Positivo).....	79
Tabela 13 – Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios separados por ano de celebração. (Probabilidade de Falso Positivo).	84

LISTA DE FIGURAS

Figura 1 – Distribuição do quantitativo e materialidade de instrumentos operacionalizados na Plataforma +Brasil. Fonte: Plataforma +Brasil. Elaborado pelo autor.	18
Figura 2 - Boxplot dos Valores Globais dos convênios segregado por Ente. Elaborado pelo Autor. Fonte: Plataforma +Brasil.	20
Figura 3 – Classificação da STN para os tipos de transferências fiscais da União. Elaborado pelo Autor.	22
Figura 4 - Evolução do arcabouço normativo das transferências voluntárias. Elaborado pelo Autor.	25
Figura 5 – Concentração de Instrumentos Celebrados por Unidade da Federação. Elaborado pelo Autor. Fonte: Plataforma +Brasil.	26
Figura 6 – Matriz de Confusão. Adaptado de Fawcett (2006) e Alpayadin (2020). Elaborado pelo Autor.	36
Figura 7 – Curva ROC. Adaptado de Alpaydin (2020) e Fawcett (2006). Elaborado pelo Autor.	38
Figura 8 - Estoque de prestação de contas pendentes de análise. Elaborado pelo Autor. Adaptado de Brasil (2018a) . Fonte: Plataforma +Brasil.	40
Figura 9 – Precisão do "Malha Fina de Convênios". Posição: convênios analisados entre 01/01/2018 e 18/04/2018. Elaborado pelo Autor.	52
Figura 10 – Árvore de problemas da fase de prestação de contas do ciclo de vida de um convênio.	55
Figura 11 - Árvore de objetivos para solucionar o gargalo da fase de prestação de contas no ciclo de vida de um convênio. Fonte: Elaborado pelo próprio Autor	56
Figura 12 - Distribuição percentual do resultado da análise das prestações de contas dos convênios dos 10 órgãos mais representativos da população. Fonte: Plataforma +Brasil. Data base: novembro de 2019.	61
Figura 13 - Metodologia para verificar o impacto da identidade do repassador de recursos na precisão(métricas AUC e inexatidão) do algoritmo de inteligência artificial. Elaborado pelo autor.	66
Figura 14 – Metodologia para teste para verificar o impacto da volumetria sequência de treinamento na precisão (métricas AUC e inexatidão) do algoritmo de inteligência artificial. Elaborado pelo autor.	69
Figura 15 - Curva ROC e métrica AUC do algoritmo de IA treinado com o universo.	71
Figura 16 – Métrica Inexatidão (ϵ) do Algoritmo de IA treinado a partir do universo (Probabilidade de Falso Positivo).	73
Figura 17 – Convergência (ϕ) entre algoritmos treinados conforme o órgão concedente e a partir da população completa.	75
Figura 18 – Métrica AUC. Curva ROC dos algoritmos treinados conforme a identidade do órgão concedente.	78

Figura 19 – Curvas da Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios de cada órgão concedente.	80
Figura 20 – Métrica AUC. Curva ROC dos algoritmos treinados a partir do incremento da volumetria.	83
Figura 21 - Curva de ocorrência de convênios com prestação de contas rejeitadas dentro dos intervalos acumulados de risco.	85

SUMÁRIO

SUMÁRIO.....	11
1. INTRODUÇÃO.....	12
2. REFERENCIAL TEÓRICO.....	17
2.1. Relações Federativas e Transferências Voluntárias.....	17
2.2. Controle	28
2.3. O papel do uso da tecnologia aplicada ao Controle.....	30
2.4. A Sofisticação dos métodos de Auditoria: Técnicas de mensuração de desempenho de <i>Machine Learning</i>	34
3. CONTEXTUALIZAÇÃO DO PROBLEMA.....	39
3.1. Transferências Voluntárias e a Plataforma +Brasil (antigo SICONV).....	39
3.2. O Sistema “ <i>Malha Fina de Convênios</i> ”	42
3.3. Descrição do problema	50
3.4. Importância do Problema.....	54
4. METODOLOGIA.....	58
4.1. Relevância para o algoritmo de IA em distinguir a identidade dos repassadores de recursos.....	63
4.2. Relevância do tamanho da série de treinamento para o algoritmo de IA	66
5. ANÁLISE DOS RESULTADOS	70
5.1.1. Métricas <i>AUC</i> e <i>inexatidão</i> (ϵ) conforme a identidade do órgão concedente 70	
5.1.1.1. Cenário 1: algoritmo de IA treinado com o universo e aplicado em cada órgão concedente separadamente	70
5.1.1.2. Cenário 2: algoritmo de IA treinado com convênios conforme a identidade do órgão concedente	76
5.1.2. Métricas <i>AUC</i> e <i>inexatidão</i> (ϵ) conforme a volumetria da sequência de treinamento.....	81
6. CONSIDERAÇÕES FINAIS	86
REFERÊNCIAS	90
ANEXO I - CÓDIGO PHYTON UTILIZADO NAS SIMULAÇÕES.....	102
ANEXO II - CONVÊNIOS ENCERRADOS	107

1.INTRODUÇÃO

Este trabalho tem como objetivo analisar como a integração de tecnologia com a auditoria interna pode ser útil no controle das Transferências Voluntárias da União, intermediadas pela Plataforma +Brasil¹. Nessa perspectiva, analisa-se o caso do sistema “*Malha Fina de Convênios*”, abordagem tecnológica inovadora envolvendo a Controladoria-Geral da União – CGU - e o Ministério da Economia - ME. Nesse bojo emerge a relevância de dois pontos centrais: o papel do Controle e a aplicação da Tecnologia para o seu desempenho.

Primeiramente, o Controle apresenta sua importância na medida em que possibilita avaliar e monitorar as políticas públicas. Por sua vez, distinguir adequadamente a avaliação e o monitoramento é primordial para entender a importância do controle no ciclo de vida da política pública (BARZELAY, 1997; MONTEIRO, 2015; POWER, 1997).

De um lado, a avaliação se refere à utilização dessas informações para a intervenção oportuna que confirma ou corrige as ações monitoradas (JENKINS-SMITH, 1982; TREVISAN; BELLEN, 2008). As avaliações são usadas para responder perguntas específicas relacionadas ao desenho, à implementação e aos resultados. Encontra-se relacionada ao acompanhamento, de modo a determinar a relevância, a eficiência, a efetividade, o impacto e a sustentabilidade de determinada ação. Diferentemente do monitoramento, as avaliações são realizadas em pontos de controle pré-determinados.

Por outro lado, o monitoramento pode ser conceituado como o processo sistemático e contínuo que, produzindo informações sintéticas e em tempo eficaz, permite a rápida avaliação situacional (MATLAND,1995). Geralmente, o monitoramento acompanha insumos, atividades e produtos. O processo de monitoramento visa mensurar a produção de bens e serviços ofertados à sociedade (RAMOS; SCHABBACH, 2012).

Logo, o controle realizado por meio da avaliação e do monitoramento constitui-se em um efetivo instrumento de fiscalização das ações do governo (OLIVEIRA, 2012). Sua importância deriva do mecanismo democrático que concebe: a possibilidade de os cidadãos, legítimos destinatários do agir público, avaliarem e monitorarem o ciclo de vida de uma política pública.

¹ O Sistema de Convênios do Governo Federal – SICONV – foi rebatizado para Plataforma +Brasil (Decreto n. 10.035, 2019).

Adicionalmente, o uso da Tecnologia também revela sua importância, não obstante, na mesma medida da função Controle. A Tecnologia se torna importante porque considera a natureza variável dos registros e a incorporação de fontes não tradicionais de dados nos domínios da auditoria (VASARHELYI; KOGAN; TUTTLE, 2015). As novas oportunidades de análise de auditoria proporcionada pelo uso da Tecnologia vão ao encontro da necessidade de alterações nos padrões de controle. Contudo, existem desafios e obstáculos no caminho de sua utilização, além dos seus benefícios potenciais.

O percurso de superação desses obstáculos na Administração Pública possui nuances intrínsecos. Wirtz, Weyerer e Geyer (2019) propõem 4 categorias diferentes de desafios a serem superados, especificamente para o setor público: (i) implementação da tecnologia, (ii) legislação e regulação da aplicabilidade da Tecnologia, (iii) ética e (iv) paradigma comportamental. Por sua vez, o paradigma comportamental enseja um debate mais complexo em relação às outras categorias, haja vista que aborda temas tortuosos de uma burocracia (BARZELAY, 2019; BRESSER-PEREIRA, 2008; MINTZBERG, 1979; OLIVIERI, 2008), como a substituição e a transformação da força de trabalho, a aceitação e a confiança da adoção de tecnologias em detrimento dos métodos convencionais de trabalho, e, por último, a interação homem-máquina. Issa, Sun e Vasarhelyi (2016) propõem uma reflexão sobre os efeitos que a automação gera na substituição de auditores como força de trabalho.

Entretanto, a adoção da Tecnologia na atividade de auditoria deve ser encorajada. Uma vez que o auditor aprende a lidar apropriadamente com as técnicas de mineração de dados, inteligência artificial, Lei de Benford, entre outras, há uma esclarecedora ruptura dos métodos vigentes, levando-o a questionar como as auditorias eram feitas sem o emprego dessas modernidades tecnológicas (HUANG; VASARHELYI, 2019; ZHANG, 2019b). Notadamente, a Administração Pública precisa buscar incessantemente a melhoria no desempenho do Controle para que as políticas públicas sejam avaliadas e monitoradas, com menor custo e com mais rapidez. O uso de inovações tecnológicas na função Controle permite o avanço nessa seara (MACIEJEWSKI, 2017).

Enquanto, por um lado, a Tecnologia aplicada ao Controle é relevante para a execução das Políticas Públicas, por outro lado, a implementação delas no Brasil é um enorme desafio. Somos um país com dimensões continentais, diversidades culturais profundas, configurados em um número suntuoso de entidades subnacionais independentes, contemplando 27 unidades da federação e 5570 municípios (Instituto Brasileiro de Geografia Estatística [IBGE], 2020). Por sua vez, as Transferências

Voluntárias da União operacionalizadas na Plataforma +Brasil é uma opção útil para a implantação de políticas públicas no país.

As Transferências Voluntárias são recursos financeiros repassados pela União, sem determinação constitucional ou legal, a outros entes federados ou a entidades privadas sem fins lucrativos para a realização de obras ou serviços de interesse comum (TCU, 2016, p. 9). O Estado federal brasileiro utiliza o federalismo por cooperação para a consecução dos princípios e objetivos fundamentais definidos na Constituição Federal de 1988 (CF88, artigos 1º e 3º)², em especial o desenvolvimento nacional e a redução das desigualdades sociais e regionais.

Todavia, o arranjo institucional estipulado pela CF88 atribui competências concorrentes entre os entes, nem sempre harmoniosas, na medida em que a estrutura federativa é muito desigual entre as esferas municipais, estaduais e federal (FAJARDO, 2016). Com efeito, a realização de políticas públicas pelo Governo Federal por meio de parcerias e convênios com os entes subnacionais é imperiosa, mas nem sempre os repasses de recursos são redistributivos, conforme demonstram as pesquisas empreendidas por Amorim Neto e Simonassi (2013), Brollo e Nannicini (2012), Ferreira e Bugarin (2008), Meireles (2019), e Soares e Melo (2016).

Ocorre que os recursos provenientes de Transferências Voluntárias devem ser fiscalizados e o fato de serem executados em entes subnacionais não os exime de serem auditados pelo Governo Federal. Conseqüentemente, a CGU, na condição de órgão central de controle interno do Poder Executivo Federal (LOUREIRO et al, 2015), exerce seu protagonismo, na medida em que possui atribuição para avaliar e monitorar as políticas públicas conduzidas com o emprego desses recursos federais.

Por sua vez, a CGU constatou em suas avaliações da política pública das Transferências Voluntárias da União um flagrante desequilíbrio entre a quantidade de convênios celebrados e a capacidade dos órgãos concedentes analisarem as prestações de contas das entidades convenientes (BRASIL, 2018a). A expressão dessa realidade é o acúmulo contínuo de prestação de contas pendente de análise. A consequência prática desse fenômeno é a existência de um estoque incremental de passivo de convênios, cuja

2

“Art. 1º A República Federativa do Brasil, formada pela união indissolúvel dos Estados e Municípios e do Distrito Federal, constitui-se em Estado Democrático de Direito e tem como fundamentos: I - a soberania; II - a cidadania; III - a dignidade da pessoa humana; IV - os valores sociais do trabalho e da livre iniciativa; V - o pluralismo político. Parágrafo único. Todo o poder emana do povo, que o exerce por meio de representantes eleitos ou diretamente, nos termos desta Constituição. [...] Art. 3º Constituem objetivos fundamentais da República Federativa do Brasil: I - construir uma sociedade livre, justa e solidária; II - garantir o desenvolvimento nacional; III - erradicar a pobreza e a marginalização e reduzir as desigualdades sociais e regionais; IV - promover o bem de todos, sem preconceitos de origem, raça, sexo, cor, idade e quaisquer outras formas de discriminação”

prestação de contas não possui perspectiva algum de ser analisada tempestivamente, afastando o preceito constitucional do dever de prestar contas. Outrossim, as exigências impostas pelos órgãos de controle, notadamente a CGU, aos órgãos concedentes e convenentes quanto aos requisitos de comprovações de despesas contribuem para a morosidade do processo de prestação de contas. Logo, a CGU também é parte do problema, embora indiretamente.

Diante desse cenário paradoxal, em que a atuação do órgão de controle implica na deficiência da política pública que ele mesmo controla, a CGU fomentou a propositura de uma solução por meio do uso da tecnologia nas ações de controle. Essa solução, denominada “*Malha Fina de Convênios*”, facilita a análise de prestação de contas de convênios, observando o expressivo volume de instrumentos celebrados e a limitada capacidade de análise do corpo de servidores dos órgãos concedentes. O sistema “*Malha Fina de Convênios*” é um modelo preditivo criado pela CGU que permite indicar, com determinado grau de certeza, o resultado da análise das prestações de contas dos convênios no momento em que suas contas são apresentadas pelos convenentes (entes subnacionais recebedores de recursos) aos concedentes (órgãos da União repassadores de recursos). Ou seja, o Malha Fina permite inferir, por meio de Inteligência Artificial, se as contas dos convênios serão aprovadas ou rejeitadas. Trata-se de uma iniciativa inovadora porque soluciona o problema do gargalo operacional das prestações de contas de uma forma inédita e disruptiva.

Nesse contexto, as potencialidades do uso do Malha Fina de Convênios, seus impactos já demonstrados e suas limitações ainda não são claros e definitivos. Dessa forma, o objetivo do trabalho é analisar alguns desses aspectos, especificamente no que tange a precisão e a acurácia do Sistema Malha Fina de Convênios em diferentes condições da sequência de treinamento geradoras dos algoritmos de classificação. Analisar-se-á a influência do tamanho e a identidade dos órgãos repassadores de recursos, em diferentes cenários de sequência de treinamento, na acurácia e na precisão dos algoritmos (ALPAYDIN, 2014; BREIMAN, 2001; DOMINGOS, 2012). A implementação desses diferentes cenários será conduzida por meio da utilização do algoritmo de aprendizado de máquina supervisionado *Random Forest*, executado em linguagem Python.

Para entender o impacto do “*Malha Fina de Convênios*” no mundo real das Transferências Voluntárias da União, este estudo se centra no tema das relações entre auditoria e tecnologia (ISSA; SUN; VASARHELYI, 2016), questão clássica para a função Controle na ciência Administração contemporânea, uma vez que a forte expansão

da delegação de políticas públicas aos entes subnacionais a partir da Constituição Federal de 1988 ampliou a relevância da conexão entre incremento de recursos transferidos pela União e a necessidade de fiscalizá-los eficientemente (ABRUCIO; FRANZESE, 2007; ARRETCHE, 2010; AFONSO; ARAÚJO; FAJARDO, 2016). Tal questão será tratada tanto do ponto de vista teórico como empírico, neste caso, analisando-se a aplicabilidade do “*Malha Fina de Convênios*” no Governo Federal.

O presente estudo analisará essa temática em 5 etapas, além desta Introdução. A seção 2, subsequente a esta seção introdutória, consiste em uma revisão da literatura, iniciando-se com uma breve visão geral das Transferências Voluntárias da União, dos conceitos do Controle e sua importância na Administração Pública, além de destacar o papel da tecnologia no redesenho da atividade de auditoria, abordando conceitos de *machine learning*.

Em seguida, a seção 3 aborda o problema da prestação de contas dos repasses da União operacionalizados na Plataforma +Brasil. Ainda nessa seção é exposto o sistema “*Malha Fina de Convênios*” como proposta de solução para o passivo de contas a serem analisadas, bem como a caracterização de suas limitações e potencialidades. Por sua vez, o problema de pesquisa é delineado e as hipóteses a serem testadas são elencadas.

Posteriormente, na seção 4 são apresentados os procedimentos metodológicos adotados, descrevendo a estratégia de testes de simulação do aprendizado de máquina e o detalhamento da base de dados da Plataforma +Brasil, incluindo o seu corte temporal.

Ato contínuo, na seção 5 são apresentados os resultados obtidos nas simulações e os dados empíricos. As análises estão apresentadas conforme duas arquiteturas configuradas para simular o desempenho dos algoritmos de aprendizado de máquina: identidade do repassador de recursos e volumetria da sequência de treinamento.

Por fim, na seção 6, apresentam-se as considerações finais, explicitando-se as principais conclusões, bem como as limitações do presente estudo e algumas propostas de trabalho para futuras pesquisas.

2.REFERENCIAL TEÓRICO

Esta seção aborda o referencial teórico utilizado para o embasamento do estudo, ou seja, busca-se aqui revisar a literatura já desenvolvida, ressaltando as potenciais contribuições deste trabalho. Feitas as considerações sobre as relações federativas e sua influência nas Transferências Voluntárias, passa-se à discussão do Controle no arcabouço racional-legal da Administração Pública e, em seguida, à contextualização do papel da Tecnologia aplicada ao Controle no paradigma da “*Digital Era Governament*”. Dessa forma, o objetivo desta seção é remeter a aplicabilidade de uma nova tecnologia para o uso do Controle com o propósito de solucionar um problema real de uma política pública, qual seja as Transferências Voluntárias.

2.1. Relações Federativas e Transferências Voluntárias

As Transferências Voluntárias da União são uma política pública em que a União repassa recursos públicos federais discricionariamente a Estados, Municípios, Distrito Federal ou entidades privadas sem fins lucrativos. O propósito para o repasse de recursos federais aos entes federados ou às organizações sociais serve para que esses executem políticas em áreas de educação, saúde, saneamento, construção e recuperação de estradas, abastecimento de água, habitação e energia urbana e rural. Afinal de contas, o cidadão mora no município (AMORIM NETO; SIMONASSI, 2013) e a execução mais assertiva da política pública só poderia ocorrer nesse ente subnacional (SOARES; MELO, 2016).

As transferências voluntárias desempenham um importante papel na relações federativas brasileiras, principalmente entre União e municípios. Segundo Fajardo (2016), a Constituição Federal de 1988 (CF88) foi um marco no arranjo institucional da federação brasileira uma vez que conferiu aos municípios a categoria de ente federativo, revestindo-os de uma importância singular, tendo em vista sua representatividade maior em termos de quantidade em relação aos Estados. Por sua vez, Arretche (2010) e outros acadêmicos, como Afonso, Araújo e Fajardo (2016) e Loureiro e Abrucio (2004), destacam a peculiaridade do advento do ente municipal no modelo do federalismo brasileiro, cada um em sua perspectiva decorrente de suas pesquisas. Em resumo, grande parte dessas perspectivas são negativas porque as evidências empíricas desses estudos mostram que arrecadação pequena desses entes subnacionais e sua grande parcela na composição do gasto público ameaçam a sustentabilidade do ente municipal. Igualmente, essas perspectivas negativas são corroboradas com a assertiva de Amorim Neto e

Simonassi (2013) em que a captação de apoio político prepondera sobre critérios de equidade nas transferências da União para os entes subnacionais. Não obstante, o município exerce um papel central nas transferências voluntárias da União. De certa forma, o protagonismo dos municípios na política pública das transferências voluntárias da união pode ser observado na Figura 1, na medida em que é o destinatário com maior volume e materialidade de convênios, ultrapassando até mesmo as entidades privadas sem fins lucrativos.

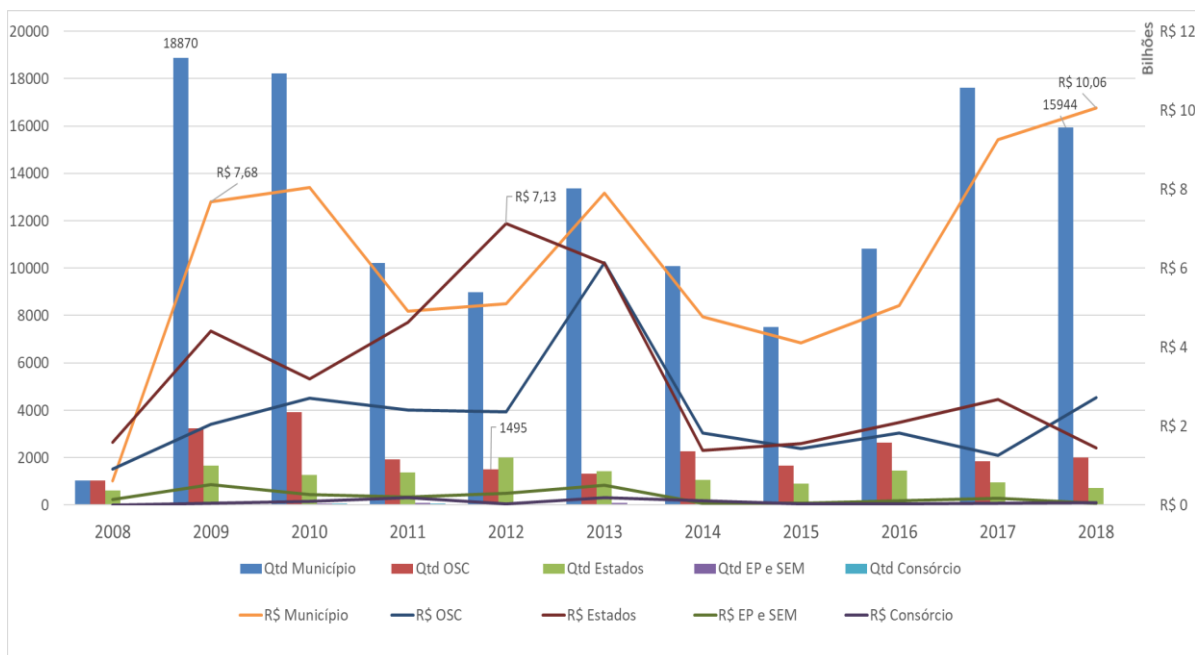


Figura 1 – Distribuição do quantitativo e materialidade de instrumentos operacionalizados na Plataforma +Brasil. Fonte: Plataforma +Brasil. Elaborado pelo autor³.

Afora a flagrante supremacia dos municípios em relação aos estados em termos de quantidade de instrumentos, a Figura 1 ilustra um panorama menos expressivo em relação a materialidade de repasse feito aos Municípios em relação aos Estados, ainda que esses sejam superiores ao primeiro destinatário quando comparado ao segundo. A Figura 1 representa as quantidades de instrumentos pelas barras e os valores de recursos transferidos pelas linhas. Com efeito, as barras azuis, que simbolizam a quantidade de instrumentos em que os Municípios configuram como beneficiados, são muito maiores em magnitude do que qualquer outra categoria de barra, ou seja, os Estados e as entidades sem fins lucrativos. Entretanto, a linha laranja, que simboliza o valor total de recursos transferidos aos Municípios, não está tão distante das linhas que simbolizam os valores

³ EP- Empresa Pública, SEM – Sociedade de Economia Mista, OSC – Organização da Sociedade Civil.

repassados aos Estados e às entidades sem fins lucrativos, destacando-se que em 2012 o volume de aporte feito aos Estados superou àquele feito aos municípios. Todavia, a Tabela 1 permite inferir que o patamar de recursos transferidos aos Municípios é quase o dobro daqueles transferidos aos Estados.

Natureza Jurídica	Quantidade	Valor
Município	136.429	R\$ 69.319.120.959,84
Organização da Sociedade Civil	24.118	R\$ 26.614.140.309,16
Estados	13.624	R\$ 36.598.277.602,35
Empresas Públicas e Sociedade de Economia Mista	852	R\$ 2.331.638.055,77
Consórcio Público	433	R\$ 815.383.238,07
Total	175456	R\$ 135.678.560.165,19

Tabela 1 - Quantitativo e Valores Totais de instrumentos operacionalizados na Plataforma +Brasil por natureza jurídica do destinatário. Elaborado pelo autor. Fonte: Plataforma +Brasil.

Em certa medida, a Figura 1 e a Tabela 1 robustecem o protagonismo que o Município exerce na política pública das transferências voluntárias da União e consequentemente no arranjo federativo (ARRETCHE, 2010). Ademais, o cenário apresentado permite constatar que os instrumentos celebrados com os municípios são quantitativamente volumosos e possuem valores baixos, conforme observado na Figura 2. Isso contribui para a pulverização de recursos, o que pode gerar efeitos adversos, haja vista que nem sempre há coordenação para execução de programas por parte do governo federal e os governos subnacionais adotam posturas exageradamente autônomas (ABRUCIO, 2005; FAJARDO, 2016). Naturalmente, políticas públicas são sombreadas, a grande maioria dos municípios brasileiros não contam com um estrutura burocrática adequada para o gerenciamento de grande quantidade de convênios, ocorre sobrecarga na capacidade operacional para gerenciá-los nos órgãos da União e, principalmente, no município, e por último e mais impactante, o fracionamento dos recursos transferidos materializando-se em convênios de baixo valor (Figura 2) faz com que a efetividade de programas de governo seja baixa, contrapondo com a hipótese de os recursos serem aplicados de maneira centralizada, em grande escala. Igualmente, os custos envolvidos para gerenciar o ciclo de vida de convênios de alto valor não é diferente do custo daqueles de baixo valor. Esses desafios, por vezes, afetam a boa aplicação dos recursos públicos oriundos de transferências voluntárias.

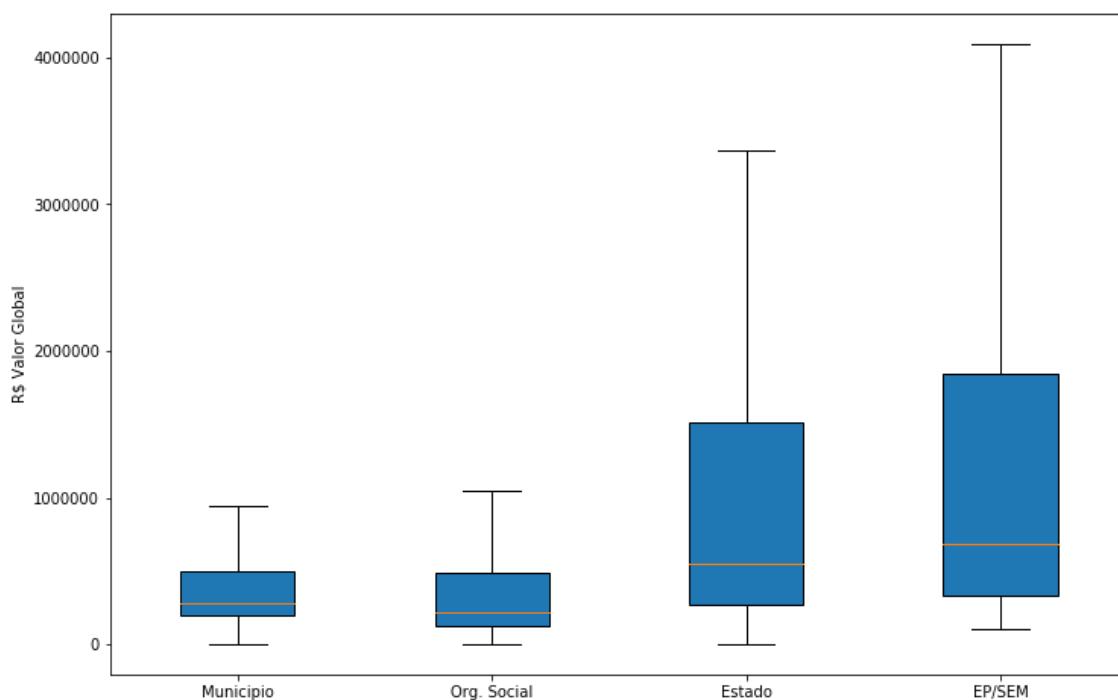


Figura 2 - Boxplot dos Valores Globais dos convênios segregado por Ente. Elaborado pelo Autor. Fonte: Plataforma +Brasil.

A constituinte de 1988 adotou uma fórmula federativa que previu a cooperação intergovernamental vertical, sendo que as transferências voluntárias são uma ferramenta para a consecução desse objetivo. A criação dos municípios após a promulgação da CF88 vai ao encontro desse preceito e irradia efeitos sob o prisma político, o que remete a existência de uma articulação concebida ao longo do tempo, pretérita ao evento de promulgação da Carta Constitucional. Fajardo (2016), por sua vez, argumenta, ancorado nas pesquisas promovidas por Abrucio (2005) e Arretche (2010), que a CF88 foi um processo que se iniciara bem antes da sua promulgação, promovendo consequências sob os primas administrativos e fiscais, além do ponto de vista político, cujo maior impacto foi a criação do ente municipal. Sob a prima administrativo, a CF88 foi leniente na atribuição de competências governamentais de cada ente, pois houve uma superposição de atribuições sobre alguns temas, enquanto outros ficaram à mercê de serem devidamente atribuídos para um ente competente (ABRUCIO; FRANZESE, 2007.) Por último, sob o prisma fiscal, ocorreu a descentralização na divisão dos recursos públicos, conferindo aos governos subnacionais autonomia na cobrança dos tributos e na elaboração dos orçamentos, e a desconcentração de receita devido ao formato como são realizadas as transferências da União para os entes subnacionais. Nesse aspecto merece

destaque as diferentes categorias de transferências de recursos realizadas pela União e qual categoria as transferências voluntárias se inserem.

Entretanto, a pluralidade de temas com competências concorrentes entre os entes federados e a ampla diversidade de legislação correlata, abrangendo desde saúde, perpassando por educação, segurança, cultura, até a assistência social, torna muito difícil a existência de uma classificação precisa dos tipos de transferências da União, implicando em divergências na doutrina e academia (BRASIL, 2008; DALLAVERDE, 2014)). Conquanto a existência dessas intempéries, órgãos decisores das políticas de relacionamento federativo e gerenciamento da despesa pública, situados em posição central no Governo Federal, empreenderam esforços para elucidar o panorama das transferências fiscais da União. Constituiu-se um grupo formado pelo extinto Ministério do Planejamento (SOF e SLTI), Ministério da Fazenda (STN) e CGU, liderado pela STN, cujo resultado do trabalho foi a categorização das transferências fiscais da União, conforme disposto na Nota Técnica nº 14/2015/COINT/SURIN/STN/MF-DF.

As transferências da União admitem, segundo a nota supracitada, as classificações (i) *obrigatórias* e (ii) *discricionárias*, conforme ilustrado na Figura 3. As transferências obrigatórias compreendem aquelas que possuem previsão expressa na Constituição Federal ou Lei e são transferidas diretamente, uma que vez que não há necessidade de celebração de instrumento jurídico formal entre a parte concedente e a beneficiada. Ato contínuo, as transferências emanadas diretamente do ordenamento da Constituição subclassificam-se como *constitucionais*, enquanto aquelas em que a obrigatoriedade tem sede em Lei subclassificam-se como *legais*. São exemplos de transferências *obrigatórias constitucionais* aquelas realizadas para o Fundo de Participação dos Municípios – FPM - ou Fundo de Participação dos Estados – FPE. Por outro lado, as transferências *obrigatórias legais* podem ser encontradas em políticas públicas de educação básica como nos PNAE, PNAT, PDDE, tanto como nas políticas de saúde no Sistema Único de Saúde – SUS - e no Fundo Nacional de Saúde-FNS.

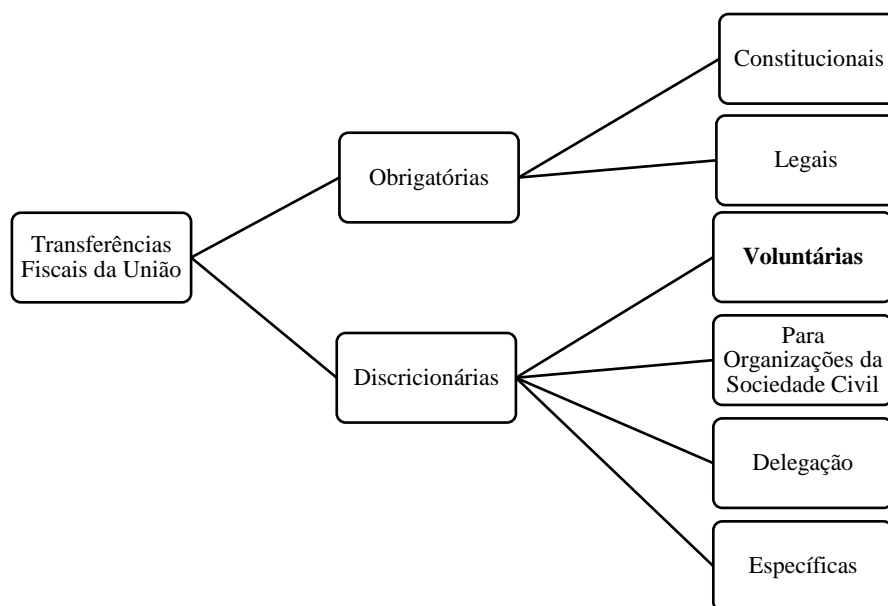


Figura 3 – Classificação da STN para os tipos de transferências fiscais da União. Elaborado pelo Autor.

Por seu turno, as transferências *discricionárias* compreendem os recursos repassados sob a égide de um instrumento jurídico celebrado entre duas partes e subclassificam-se em 4 categorias. A primeira subclassificação, e mais importante para o propósito deste estudo, são as transferências *discricionárias voluntárias*, consistindo naquelas em que a entrega de recursos aos entes subnacionais almeja a cooperação, auxílio ou assistência financeira. As transferências *discricionárias voluntárias* não são destinadas ao SUS, como também não estão enquadradas nas hipóteses das transferências *obrigatórias*. Comumente denominadas como transferências voluntárias no cotidiano da burocracia federal, as transferências *discricionárias voluntárias* são operacionalizadas na Plataforma +Brasil e consistem basicamente em dois tipos de instrumentos jurídicos: o convênio e o contrato de repasse. A diferença entre esses instrumentos reside no fato de que o primeiro é celebrado diretamente entre as partes, de um lado um órgão do ente federal e de outro um órgão do ente subnacional, e o segundo é celebrado por intermédio de uma agente financeiro federal no papel de mandatária da União. Atualmente, esse papel é exercido pela CAIXA. Geralmente, os objetos de convênios têm escopo para aquisição de bens e contratação de serviços enquanto os objetos de contratos de repasse consistem em obras de construção civil.

Ademais, as transferências *discricionárias para Organizações da Sociedade Civil* são realizadas para essas entidades sem fins lucrativos a título de subvenção, auxílio e contribuição, com o propósito de realizar ações de interesse público. Essas subvenções são disciplinadas no Marco Regulatório das Organizações Sociais e da Sociedade Civil -

MROSC - (Lei n. 13.019, 2014 e Decreto n. 8.726, 2016) e constituem-se em 3 tipos de instrumentos jurídicos, quais sejam, termo de fomento, termo de colaboração e acordo de cooperação. Oportunamente, esses instrumentos são operacionalizados na Plataforma +Brasil, assim como os convênios e contratos de repasse, instrumentos da subcategoria transferências *discricionárias voluntárias*. Posteriormente, as transferências *discricionárias por delegação* valem-se dos consórcios públicos para a execução descentralizada de políticas públicas de responsabilidade exclusiva do ente que concede os recursos. Por último, as transferências *discricionárias específicas* são caracterizadas por repasses em que o ente beneficiado é dispensado por lei em cumprir requisitos fiscais. Adicionalmente, esse tipo de transferência exige a celebração de um instrumento jurídico entre as partes envolvidas. Entre os exemplos da subcategoria transferências *discricionárias específicas* elencam-se os serviços públicos de Proteção Social Básica e o custeio do Serviço de Atendimento Móvel de Urgência – SAMU.

A importância ostentada pelas transferências voluntárias (transferências *discricionárias voluntárias*) no arranjo institucional federal do estado brasileiro não está refletida em sua legislação ordinária. Com efeito, o volume de transferências voluntárias é expressivamente inferior ao volume da categoria transferências *obrigatórias*. Em 2018 as transferências voluntárias totalizaram mais de R\$ 14 bilhões⁴, enquanto as transferências obrigatórias atingiram patamar superior a R\$ 350 bilhões⁵. Porém, isso não é motivo para rotular aquelas como insignificantes nem tampouco inexpressivas em relação a estas. Pelo contrário, os recursos se mostram altamente expressivos para os entes que dependem de recursos federais para a realização de novos investimentos (FAJARDO, 2016), tendo em vista que as receitas de grande parte dos Municípios, sejam elas de sua própria arrecadação ou transferidas por força de determinação constitucional, acabam sendo quase que integralmente empregadas nas despesas correntes para manutenção da máquina administrativa (ABRUCIO, 2005). Ocorre que as transferências *obrigatórias*

4 Dados obtidos na Plataforma +Brasil. Trata-se da soma dos valores globais de todos os instrumentos cadastrados no sistema. Os valores globais são a parcela repassada pela União e contrapartida aportada pelos convenientes. O valor total de convênios celebrados em 2018 atingiu R\$ 14.335.621.107,03.

5 Dados obtidos no Sistema Integrado de Administração Financeira – SIAFI. As transferências obrigatórias incluem Fundo de Participação dos Estados e do Distrito Federal - FPE; Fundo de Participação dos Municípios - FPM; IPI - Exportação; CIDE-Combustíveis; Fundo de Manutenção e Desenvolvimento da Educação Básica e de Valorização dos Profissionais da Educação - Fundeb; Royalties; Imposto sobre a Propriedade Territorial Rural – ITR; IOF-Ouro; e Lei Kandir (LC 87/96). O valor total transferido para estados e municípios em 2018 atingiu R\$ 351.447.109.424,57.

possuem respaldo normativo robusto, enquanto as transferências *discricionárias voluntárias* destacam-se pela ausência de legislação ordinária detalhada.

O arcabouço normativo das transferências voluntárias da União emana da expressa previsão legal no artigo 116 da Lei Federal n. 8.666/93. Existem estudos indicando que as transferências voluntárias estão amparadas no dispositivo constitucional (art. 241), entre eles Campos (2018) e Castro (2019), embora essa linha de pensamento é silente na Doutrina do Direito Administrativo brasileiro, notadamente em Pietro(2015):

“(…)

Art. 241. A União, os Estados, o Distrito Federal e os Municípios disciplinarão por meio de lei os consórcios públicos e os **convênios de cooperação entre os entes federados**, autorizando a gestão associada de serviços públicos, bem como a transferência total ou parcial de encargos, serviços, pessoal e bens essenciais à continuidade dos serviços transferidos.

(…)” **grifo meu.**

De certa forma, o desamparo de diplomas legais regulando a política pública de transferências voluntárias é um reflexo da contemporaneidade recente da alçada do município para ente federado, inovação proporcionada pela CF88. As transferências voluntárias, por se tratar de uma política discricionária com aplicabilidade em amplo espectro de temas, não incentiva os atores do processo em discipliná-lo mediante legislação aprovada no Congresso Nacional, relegando-os para normas infralegais (Pietro, 2015). Nesse quesito, a lacuna legal foi suplantada com uma miríade de portarias e decretos editadas ao longo do tempo, conforme se observa na Figura 4. Pode-se dizer que as transferências voluntárias ganham contornos radicalmente diferentes após a criação do SICONV em 2007 (MEIRELES, 2019), na medida em que todo o processo de gerenciamento dos convênios com o governo federal passou a ser feito nesse sistema. Anteriormente, os convênios celebrados com a União eram registrados no SIAFI, mas esse sistema carecia de funcionalidades para permitir o controle assertivo das transferências, prejudicando a transparência de informações e a divulgação de dados, e, por outro lado, favorecendo o cenário de prestações de contas pendentes e a malversação dos recursos públicos. Ora, o SIAFI foi desenvolvido para servir como um sistema de execução financeira do Governo Federal (ABRUCIO E LOUREIRO, 2018) e não um sistema de gerenciamento de convênios.

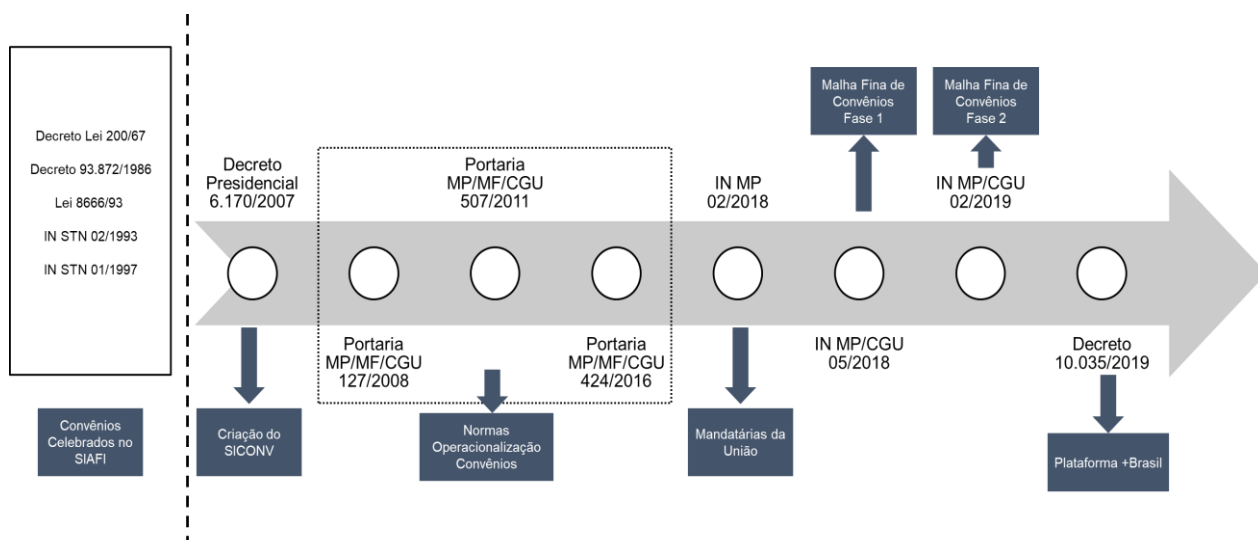


Figura 4 - Evolução do arcabouço normativo das transferências voluntárias. Elaborado pelo Autor.

A Instrução Normativa nº 01/97 da STN se destacou como um importante marco regulamentador das transferências voluntárias, tendo perdurado até a edição do Decreto n. 6.170 de 2007, o qual revolucionou o processo com a criação do SICONV. Em 2008, a Portaria Interministerial 127 foi editada com o propósito de veicular as normas operacionais para a execução do Decreto n. 6.170 (2007) e foi sucedida pelas Portarias Interministeriais 507 e 424 de 2011 e 2016, respectivamente. Em seguida, a cronologia apresentada na Figura 4 evidencia outro grande marco normativo, a Instrução Normativa n. 2 de 2018, que tratou de estabelecer diretrizes e regras para a execução de contratos de repasse (tipo de instrumento das transferências *discricionárias voluntárias*) por intermédio das Mandatárias da União. Ainda em 2018, houve a implementação da primeira fase do sistema “*Malha Fina de Convênios*”, com a edição da Instrução Normativa CGU/MP n. 5 de 2018, viabilizando uma alternativa automatizada para a análise de prestação de contas. Nessa medida, em 2019 iniciou-se a segunda fase do “*Malha Fina de Convênios*”, por meio da publicação da Instrução Normativa CGU/MP n. 2 de 2019. Enquanto a primeira fase restringiu o escopo da análise automatizada apenas ao estoque de passivo de prestações de contas pendentes de análise, a segunda fase permitiu o uso da análise automatizada em prestações de contas anacronicamente, conquanto o estoque fosse saneado.

As considerações abordadas em epígrafe ilustram que as transferências voluntárias da união não figuram com uma política pública isolada, muito menos um fim em si mesma, haja vista que sua finalidade primordial é possibilitar, a título de cooperação, o financiamento dos serviços públicos nos entes subnacionais. Nesse ponto, pode surgir um questionamento se a cooperação financeira recebida por um ente mais pobre, em

detrimento de sua pequena contribuição comparada a um ente mais rico, contraria o equilíbrio do pacto federativo. Em resposta, consagra-se a modulação que os desígnios das relações federativas aplicam nas transferências voluntárias, pois o equilíbrio federativo solidifica-se com o mecanismo de repasse de recursos (AFONSO; ARAÚJO; FAJARDO, 2016; AMORIM NETO; SIMONASSI, 2013; FAJARDO, 2016). Objetiva-se a inclusão dos entes mais carentes e necessitados no processo de desenvolvimento, e não a exclusão dos entes mais favorecidos, responsáveis muitas vezes por impulsionar a economia da Federação.

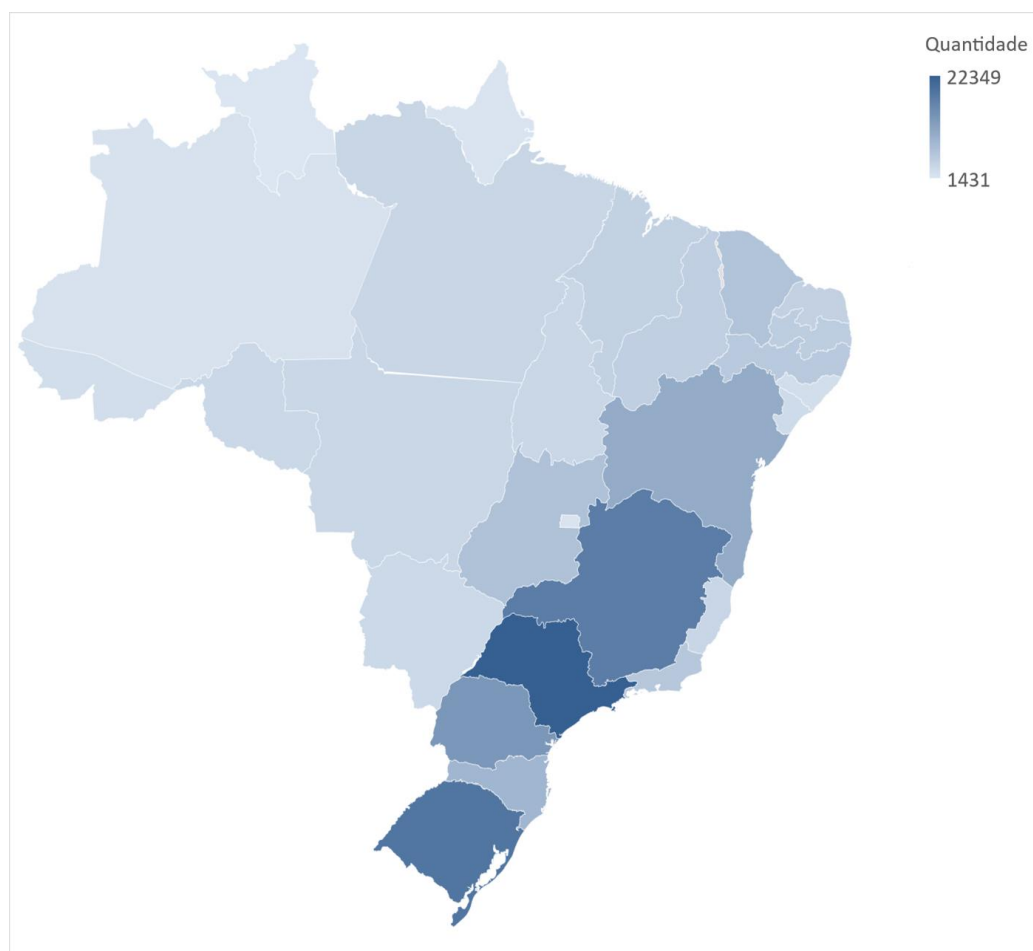


Figura 5 – Concentração de Instrumentos Celebrados por Unidade da Federação. Elaborado pelo Autor.
Fonte: Plataforma +Brasil.

Por derradeiro, é imprescindível que os critérios de equidade se sobreponham aos objetivos políticos nos repasses decorrentes de transferências voluntárias, pois assim esse recurso contribuiria para a diminuição das desigualdades inter-regionais na federação brasileira. Entretanto, as evidências empíricas das pesquisas de Amorim Neto e Simonassi (2013), Brollo e Nannicini (2012), Limongi e Figueiredo (2005), Meireles (2019) e Soares e Melo (2016) indicam o contrário, retratando que os entes subnacionais com

alinhamento político com o mandatário da União ou com maior representatividade no Congresso Nacional recebem mais recursos, indiferentemente de outros critérios. A Figura 5, acima, endossa esse cenário, haja vista que as regiões mais pobres do país são desprestigiadas em relação às mais ricas em termos de quantidade de instrumentos celebrados.

2.2. Controle

O Controle é uma das funções básicas da Administração desde que essa ciência se constituiu como ciência. Taylor (1911) estabeleceu o controle como um dos princípios da administração científica, tendo como função “controlar o trabalho, para se certificar de que esse está sendo executado de acordo com as normas estabelecidas e segundo o plano previsto”. Fayol (1949) evidenciou o Controle como uma das funções do Administrador, além do planejamento, da organização, do comando e da coordenação.

Dessa forma, o controle no âmbito organizacional deve ser tratado como uma etapa integrada ao planejamento (OTLEY, 1999), devendo ser usado pelos gestores como um mecanismo de geração de insumos para promoção de ajustes necessários e análise de desvios indesejados (COSO, 2013). Oportunamente, todos os colaboradores, desde o nível hierárquico mais baixo até o dirigente máximo, devem se apropriar de sua responsabilidade de gerenciar riscos e implementar ações corretivas para resolver deficiências nos processos do negócio (WREN; BEDEIAN; BREEZE, 1975).

Cumprir, porém, que Fayol atribuiu um significado abrangente para a palavra “administração” e para a utilização das funções o administrador, devendo ser utilizada em todos os tipos de organização, a despeito do tamanho, propósito, ou campo de atuação (WREN; BEDEIAN, 2009).

No âmbito da Administração Pública, o Controle ganha proporções mais amplas, já que envolve também uma perspectiva republicana em seu escopo, na qual a sociedade tem o direito de exigir a prestação de contas a todo agente público por sua administração (MICHENER; BERSCH, 2013; SCHEDLER, 1999). Essa premissa remonta à Declaração dos Direitos do Homem e do Cidadão de 1789. Esse direito de colocar o controle na condição de princípio da gestão, obriga o ente público e seus governantes a prestarem contas de seus atos na aplicação de recursos (FILGUEIRAS, 2018; SUNSTEIN, 2018). Essa linha de pensamento, oriunda da Revolução Francesa (ABRUCIO; LOUREIRO, 2018), norteia o arcabouço jurídico brasileiro, haja vista o art. 70 da CF88 estipula que qualquer pessoa que utilize, arrecade, guarde, gerencie ou administre dinheiros, bens ou valores públicos deverá prestar contas.

Assim, seu escopo transborda o dever de autotutela (OLIVIERI, 2011), configurando-se em uma atuação mais abrangente, incluindo o controle de legalidade,

oportunidade e conveniência sobre seus próprios atos e agentes (BRESSER-PEREIRA, 1998). Essa forma de atuação é instrumentalizada pela atividade de auditoria.

Dessa forma a atividade de auditoria é formulada para abranger não apenas a verificação da legalidade dos atos da Administração, mas também para abarcar a avaliação da eficiência e efetividade das políticas públicas, de modo a se tornar um instrumento útil para o gestor na promoção da qualidade na gestão pública (LOUREIRO et. al, 2015). Ou seja, o propósito do controle não se resume somente em apontamentos e punição de irregularidades, na medida em que se nota a importância da ampliação das suas forma da atuação visando o combate à fraude (FAJARDO, 2012).

Conseqüentemente, uma boa atividade de auditoria é aquela em que o auditado seja o foco principal de novos estudos, ao contrário do foco em auditores e agências de auditoria. Os autores Power (2003a e 2003b), Lélis e Pinheiro (2012) e Ahrens, Ferry, e Khalifa (2018) apontam em seus estudos que o auditado é um ser complexo que carrega consigo a dicotomia entre o desconforto associado com nervosismo diante de um processo de auditoria e fiscalização e o reconhecimento da necessidade de colaboração no exercício da atividade de auditoria.

Contudo, é mister diferenciar controle interno e externo (ISMAEL; ROBERTS, 2018). Isso se deve porque Mintzberg(1979) assevera que o grau e o tipo de controle exercido sobre as organizações repercute em seu projeto organizacional, na medida em que afeta o nível de risco das decisões gerenciais, implicando em condicionantes às opções feitas pelos tomadores de decisão. Adicionalmente, Adam (1994) aponta que os controles internos e externos são intrínsecos à Teoria da Agência, a qual postula que existe uma relação contratual entre os proprietários de recursos econômicos (principal) e os gerentes (agentes) que são encarregados de usar e controlar esses recursos.

Em seu aspecto legal, a distinção entre controle interno e externo somente foi feita no Brasil com o sanção da Lei n. 4.320 (1964), que previu a atribuição do controle interno do Poder Executivo, sem prejuízo da atribuição do Tribunal de Contas da União (art. 76) quanto à prática de verificação da legalidade dos atos de execução orçamentária como prévia, concomitante e subsequente (art. 77).

Assim, o controle externo é um processo de verificação realizado pelo poder legislativo em relação aos poderes executivo e judiciário, para controle dos atos de gestão desses poderes. Essa forma de controle é um instituto relacionado aos freios e contrapesos, decorrentes do princípio de separação e autonomia entre os poderes. O titular

do controle externo no Brasil é o Congresso Nacional, que o exerce com o auxílio do Tribunal de Contas da União – TCU.

Outrossim, o controle interno é a forma de organizar os controles integrados às operações cotidianas da gestão pública (IMONIANA; NOHARA, 2006). Nesse sentido, o sistema de controle interno é concebido em decorrência da ação de vigilância voltada às práticas do poder ou administração a que pertence. O controle interno se insere na estrutura do próprio órgão fiscalizado, materializando-se em uma especialização do controle administrativo (DIAS, 2018; JR e LEITÃO, 2006). No Brasil a instância máxima do sistema de controle interno na esfera federal é a Controladoria-Geral da União - CGU. Neste trabalho, há delimitação de escopo no controle interno.

Nesse aspecto, o Instituto dos Auditores Internos (IIA, 2012) afirma que o controle existe para agregar valor à organização e as suas partes interessadas, além de contribuir para a eficácia e eficiência dos processos de governança, gerenciamento de riscos e controles. As Normas Internacionais para a Prática Profissional de Auditoria Interna do IIA definem controle como:

“Any action taken by management, the board, and other parties to manage risk and increase the likelihood that established objectives and goals will be achieved. Management plans, organizes, and directs the performance of sufficient actions to provide reasonable assurance that objectives and goals will be achieved”.

De acordo com Olivieri (2008), o propósito do controle interno governamental consiste no conjunto de atividades de auditoria e fiscalização que busca, além da garantia de conformidade legal dos atos da administração pública, prover os gestores com instrumentos de monitoramento quanto à eficiência, economicidade e eficácia de suas ações, objetivando mitigar perdas, aprimorar a gestão pública e garantir a prestação pública de contas.

2.3.O papel do uso da tecnologia aplicada ao Controle

Diante do exposto, com amparo na revisão bibliográfica referenciada, parte-se da premissa que as novas tecnologias de informação são um importante instrumento para o exercício da atividade de auditoria interna governamental.

Dunleavy et al (2006) argumentam que o *New Public Management* tende a morrer e dar espaço a uma nova era de governança digital, denominada “*Digital-Era Governance*”. Esse novo paradigma se vale dos avanços tecnológicos e tem como objetivo torná-los centrais nas ofertas dos serviços públicos. Ou seja, a tecnologia deixa

de ser um instrumento que possibilita ganhos de eficiência para se tornar uma solução que ajuda a moldar o próprio serviço público.

Em primeira análise, o *New Public Management* deixou de ser novo (BARZELAY, 2019, p. 239) configurando-se, reconhecidamente, em um modelo de meia-idade, o qual, aplicado na realidade burocrática contemporânea, pode gerar adversidades nos resultados esperados. Torna-se urgente reverter esse déficit, enfatizando que a Tecnologia da Informação e os Sistemas de Informação são mecanismos chaves para a continuidade da racionalização weberiana dos processos da administração pública na década de 2020. O futuro chegou. Naturalmente, destaca-se a grande importância que a tecnologia assume na nova maneira de operar os sistemas de gerenciamento e dos métodos de interagir com os cidadãos e os consumidores de serviço público (BARZELAY; GALLEGO, 2006)

As raízes do desprestígio do *New Public Management* são fundadas na negligência desse modelo em reconhecer que o empecilho para a simplificação da Administração Pública perpassa pela superação da conjuntura de “criar dificuldades para vender facilidades” (BRESSER-PEREIRA, 1996). O problema se manifesta quando servidores públicos exercendo o papel de auditores instauram burocracias-boutique em que criam complexos níveis de exigências formais. Perverter a racionalidade para desenvolver fortes gerências legalistas nas agências governamentais são vistas como problemáticas, porque geram atitudes de gerenciamento obcecadas por objetivos organizacionais intermediários, ao invés de prestação de serviços ou eficácia (HOOD; JAMES; SCOTT, 2000; SECCHI, 2009).

Não obstante, o modelo “*Digital-Era Governance*” influencia a atividade de auditoria e controle. Isso se deve porque a auditoria e o controle (DUNLEAVY et al., 2006) são parte da ciência social Administração (FAYOL, 1911; MINTZBERG, 1979; TAYLOR, 1948). Por seu turno, essa influência implica em efeitos abrangentes uma vez que não está restrita a aplicações iminentemente tecnológicas (NEWELL; SIMON, 1976). Diferentemente do que se sugere, a influência do “*Digital-Era Governance*” na atividade de auditoria não se restringe aos instrumentos de tecnologia, pois essa influência provoca a associação de uma ampla arquitetura de conceitos envolvendo cognição, comportamento, mudança organizacional, política e cultural ligada a tecnologia da informação. O advento “*Digital-Era Governance*” é atualmente a influência mais difundida e peculiar sobre como os arranjos de governança estão se modificando para o exercício do controle governamental.

Percebe-se que o paradigma vigente faz com que os auditores se furtem em adotar técnicas obsoletas (VASARHELYI; HARPER, 1991) como exames físicos de papel, exame de autenticidade de documentos por meio de comparação visual ou correlacionar informações por meio de observação presencial. Da mesma forma em que datilógrafos foram extintos da Administração Pública porque não se usa mais as máquinas de escrever, os auditores devem estar atentos para não terem o mesmo fim. As técnicas de auditoria ultrapassadas devem ser deixadas de lado, ao passo que a oferta de serviços públicos é preponderantemente digital, exigindo que o servidor público investido na atividade de auditoria opere sistemas de informação eletrônicos. Nesse aspecto, surge a necessidade de enfrentamento das novas relações do ecossistema de disrupção tecnológica (MARGETTS; DUNLEAVY, 2002) criado pelo “*Digital-Era Governance*”.

Segundo Parker, Jacobs e Schmitz (2019) quanto mais inovadora a tecnologia, maior a perspectiva de que os auditores proponham novos paradigmas para a operação do negócio e para as tomadas de decisão do gestor. Por sua vez, quanto maior a complexidade da tecnologia, maior a possibilidade de inovação, mas a dificuldade de sua implementação é majorada, justamente pela complexidade de seu manuseio pelos auditores. Essa implementação de novas tecnologias exige mudança de abordagem e comportamento. Toda ação provoca uma reação. Consequentemente, instaura-se uma resistência na adoção de novas tecnologias por parte dos auditores (KIM; MANNINO; NIESCHWIETZ, 2009).

Naturalmente, o aparato burocrático brasileiro exerce e continuará exercendo resistência para mudar a lógica de aceitação de inovações (HEBER, 2014) em que a regra é a interpretação obtusa do princípio da legalidade (CAMPANA, 2017). Afinal de contas, acata-se ao pé da letra “*Dura Lex, Sed Lex,*” a lei é dura, mas é a lei. No contexto público só é permitido fazer aquilo que está nos limites da legislação, enquanto qualquer ato que extrapole as regras normativas pode ser considerado ilegal (BRESSER-PEREIRA, 2008). Isso implica em duas vertentes nefastas: inibe o bom auditor a propor alternativas não tradicionais e inovadoras, e faz com que o mal auditor esteja amparado com justificativas plausíveis para sua inércia.

Todavia, segundo os autores Kim, Mannino e Nieschwietz (2009) há progressos na aceitação de tecnologias na atividade de auditoria interna, fazendo com que uma abordagem inovadora ancore a gestão.

Adicionalmente, a cultura do medo, disseminada na gestão pública (ALVES; CALMON, 2008), foi um fator preponderante, e continua sendo, para a plenitude do

desenvolvimento da prática inovadora, o sistema "malha fina de convênios". No âmbito da Administração Pública, observa-se atualmente a formação de uma contenda em que os pólos litigantes são de um lado os gestores públicos e de outro os órgãos de controle. Por seu turno, a configuração desse cenário é muito maléfica, na medida em que suas consequências são nefastas para a engrenagem da máquina pública (POWER, 2003b, 2003a).

Precipuamente, o controle tem como objetivo primordial assegurar a boa governança (BRASIL, 2017a; COSO, 2013). Contudo, gestores públicos frequentemente apontam que os órgãos de controle transpõem as atribuições a que se destinam, causando interferências inapropriadas na gestão. Por sua vez, essas interferências pautam a gestão, haja vista que causam alguns efeitos nos gestores: receio na execução de orçamento, omissão para implementar inovação, aversão para assumir riscos, e por fim inquietação em assumir cargos para executar as políticas públicas.

Diante do exposto, configura-se o paradoxo do controle: sua atuação aprimora a governança pública à medida que causa efeitos adversos na gestão. Dessa forma, qual seria a relação das ações de controle com a gestão orientada ao medo?

O triunfo sobre esse obstáculo que se postou em frente à implementação do “*malha fina de convênios*”, qual seja, o medo dos gestores em definir um apetite ao risco para estarem aptos a usar o malha de convênios e então aprovarem contas automaticamente, exigiu o uso da persistência como um fator chave (POWER, 2009). De fato, a proposta de um novo arquétipo procedimental para análise instantânea de prestação de contas gera desconforto nos gestores quando esses o comparam com o processo tradicional de prestação de contas.

O processo tradicional de prestação de contas envolve manipulação de processos, que muitas vezes são constituídos de papel físico, elaboração de pareceres, diligências com o conveniente, verificação de recibos e notas fiscais, tramitação na cadeia hierárquica, e está sujeito a todas as intempéries de um processo administrativo comum de uma burocracia racional (TENORIO, 1981; RAMOS, 1983). A alternativa de uma análise que gera um resultado instantâneo, eximindo as etapas necessárias de um processo tradicional, é vista como uma revolução pelo tomador de decisão. Porém, gera receio.

Dessa forma, a persistência e resiliência adotada pela equipe do "Malha Fina de Convênios" foram essenciais para não permitir o desvanecimento da iniciativa. Logo, os principais fatores que contribuíram para implantação do “*Malha Fina De Convênios*”

foram persistência, resiliência e trabalho em equipe com o Departamento de Transferências Voluntárias da União do Ministério da Economia.

2.4.A Sofisticação dos métodos de Auditoria: Técnicas de mensuração de desempenho de *Machine Learning*

A concepção e a natureza das técnicas de auditoria estão se modificando em decorrência do surgimento do “*Digital-Era Governance*”, sustentadas por frameworks como Big Data, Internet das Coisas (IoT) e Inteligência Artificial. Nesse novo paradigma, o aprendizado de máquina (*Machine Learning*) emerge com uma técnica revestida de protagonismo na atividade de auditoria (BROWN-LIBURD; VASARHELYI, 2015), na medida em que é muito versátil para correlacionar causa e efeito, sofisticando a metodologia de predição de resultados. Stanic, Radojevic e Stanic (2019) afirmam que uma linha de pesquisas precedentes se baseavam no clássico uso de modelos estatísticos, principalmente regressão logística e probit, para desenhar uma metodologia de predição. Por sua vez, esses mesmos autores alegam que pesquisas mais recentes demonstram que o uso de técnicas de Machine Learning, em detrimento de modelos estatísticos, possui desempenho melhor na predição.

Há diversos algoritmos diferentes de aprendizado de máquina, sendo que a principal distinção entre eles está nas categorias de aprendizado supervisionado e não-supervisionado. Entre os algoritmos supervisionados, destaca-se o *Random Forest*, uma vez que apresenta o melhor desempenho em comparação com outros algoritmos supervisionados, entre eles Naive Bayesian, Bayesian Belief Network, Artificial *Neural Network*, *Support Vector Machine*, *Decision Tree* e *Random Tree*. Oportunamente, essa constatação empírica encontra amparo em Breiman (2001), Cecchini et al. (2010), Tiwari e Hooda (2018) e Grover, Bauhoff e Friedman (2019), na medida em que esse afirma que o *Random Forest* constrói um mecanismo de árvores de decisão múltiplas e seleciona o melhor cenário de combinação de variáveis para fornecer uma predição e por isso possui um desempenho melhor entre as outras categorias de algoritmo de aprendizado de máquina. O *Random Forest* utiliza a combinação de uma miríade de árvores de decisão para computar um *score*, que significa o grau de previsão de classificação. Esse *score* é calculado com base na média das previsões de cada árvore individual. Consequentemente, o *Random Forest* fornece uma nota de risco mais assertiva para medir a probabilidade de aprovação ou reprovação das contas, por exemplo.

Por seu turno, a precisão de algoritmos de classificação estão atrelados ao seu

desempenho (FAWCETT, 2006). Na literatura, existem várias abordagens sobre a aferição de desempenho de algoritmos de aprendizado de máquina, sendo que Stanisic, Radojevic e Stanic (2019), Zhang (2019a) e Bao et al. (2020) sublinham que não há uma consagrada. Nesse panorama, uma abordagem comum para avaliar o desempenho é proceder com testes de validação cruzada (KOHAVI, 1995). Todavia, os dados utilizados para treinamento, quais sejam convênios reprovados e aprovados ao longo dos anos, são de natureza intertemporal, o que torna a aferição de desempenho por meio da validação cruzada inadequada (BAO et al., 2020). Oportunamente, a predição do resultado da análise das prestações de contas pode ser categorizada em duas classes mutuamente exclusivas: aprovada e rejeitada. Conseqüentemente, torna-se viável a mensuração de desempenho por meio de métricas que aferem eventuais erros de categorização nas classes (i) prestação de contas aprovada ou (ii) prestações de contas rejeitada (BAO et al., 2020; STANISIC; RADOJEVIC; STANIC, 2019; ZHANG, 2019a).

Nessa configuração específica em que os algoritmos de aprendizado de máquina classificam as instâncias, neste caso convênios, em duas categorias exclusivas (aprovado ou rejeitado), Alpaydın (2020) e Fawcett (2006) propõem uma abordagem analítica para problemas de classificação quando existem apenas duas categorias. Nesse cenário há quatro resultados possíveis. De um lado, se a predição do algoritmo for correta para um convênio aprovado, temos um verdadeiro positivo; caso a predição for incorreta para convênio aprovado, há um falso negativo. Por outro lado, se a predição do algoritmo indicar corretamente um convênio reprovado, temos um verdadeiro negativo; caso a predição apontar incorretamente um convênio reprovado, há um falso positivo. Assim, o conjunto dos resultados das predições do algoritmo classificador possibilita a elaboração de uma tabela de contingência com duas linhas e duas colunas, comumente denominada matriz de confusão, que representa as disposições do conjunto de resultados. A matriz de confusão permite identificar quais tipos de classificação incorreta ocorrem, ou seja, quais as categorias (convênios aprovados ou reprovados) são frequentemente confundidas.

	<i>Resultado Aprovado</i>	<i>Resultado Rejeitado</i>
<i>Hipótese de Aprovação</i>	Verdadeiro Positivo (VP)	Falso Positivo (FP)
<i>Hipótese de Rejeição</i>	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Figura 6 – Matriz de Confusão. Adaptado de Fawcett (2006) e Alpayadin (2020). Elaborado pelo Autor.

A Figura 6 mostra uma matriz de confusão. Os números na diagonal principal (VP e VN) representam as previsões corretas do algoritmo, e os números da diagonal secundária (FP e FN) representam os erros, a confusão entre as duas categorias. Por sua vez, a matriz de confusão forma a base de 3 métricas para aferição de desempenho de algoritmos de classificação gerados por *machine learning*: **acurácia, especificidade e sensibilidade**. Essas métricas são amplamente utilizadas na literatura, conforme se observa Alpaydin (2020), Fawcett (2006), Hooda, Bawa, e Rana (2020), Grover, Bauhoff e Friedman (2019), Tiwari e Hooda (2018) e Zhang(2019a), não obstante Hooda, Bawa, e Rana (2020) e Tiwari e Hooda (2018) adotarem uma forma de computa dessas métricas diferente dos demais. A metodologia de cálculo da acurácia, especificidade e sensibilidade adotada majoritariamente na literatura é:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FN + FP}$$

$$\text{Sensibilidade(Recall)} = \frac{VP}{VP + FN}$$

$$\text{Especificidade} = \frac{VN}{VN + FP}$$

Contudo, as métricas para mensuração de desempenho usualmente utilizadas (acurácia, especificidade e sensibilidade) não são apropriadas quando há um balanceamento desequilibrado da sequência de treinamento, em que a ocorrência de um categoria é muito maior que a outra (GROVER; BAUHOFF; FRIEDMAN, 2019; BAO et al., 2020; ALPAYDIN, 2020).

Segundo Bao et al. (2020), poder-se-ia utilizar uma métrica, denominada precisão balanceada, como uma alternativa para aferir adequadamente o desempenho de um modelo preditivo. Essa métrica balanceada é definida como a média entre a média simples entre a sensibilidade e a especificidade de predição das instâncias (prestações de contas de convênios). Por seu turno, a métrica de precisão balanceada é:

$$\text{Precisão Balanceada} = \frac{\text{Sensibilidade} + \text{Especificidade}}{2}$$

Por outro lado, Larcker e Zakolyukina (2012) ponderam que há uma limitação no uso da métrica de precisão balanceada como parâmetro de avaliação de desempenho. A referida métrica é concebida com base na assertividade de predição das classes, no caso em tela, aprovação ou rejeição. Objetivamente, isso significa que a predição depende da rotulação dos dados na sequência de treinamento, ou seja, o resultado conclusivo da análise que os órgãos concedentes realizaram nas prestações de contas apresentadas. Ocorre que os algoritmos de aprendizagem são bastante sensíveis ao desequilíbrio da sequência de treinamento. Uma vez que os órgãos concedentes reprovam um número muito reduzido de convênios proporcionalmente ao total, isso influenciará na distribuição da predição, conseqüentemente na sensibilidade e especificidade, superestimando-as (FAWCETT, 2006).

Destarte, uma maneira de superar essa limitação é a utilização da curva ROC (*Receiver Operating Characteristics*) e aferição da métrica AUC (*Area Under the Curve*) (BAO et al., 2020; FAWCETT, 2006; STANISIC; RADOJEVIC; STANIC, 2019). A curva ROC é uma representação bidimensional do desempenho de um classificador, nesta pesquisa representado pelo algoritmo do “*Malha Fina de Convênios*”. Por seu turno, a curva ROC combina a taxa de ocorrência de verdadeiros positivos, a sensibilidade, e a taxa de ocorrência de falsos positivos, o valor da subtração de 1 e a especificidade, em um gráfico com dois eixos. Por conseguinte, é possível inferir o desempenho de um modelo preditivo por meio de um único escalar ao calcular a métrica AUC. Como a AUC é uma parte da área do quadrado da unidade, seu valor sempre estará entre 0 e 1,0. Na medida em que uma seleção aleatória produz a linha diagonal entre (0, 0) e (1, 1), que tem uma área de 0,5, nenhum algoritmo de predição plausível deveria ter uma AUC menor que 0,5. O valor até 0,5 significa um modelo sem qualquer poder discriminativo e o valor 1 significa um modelo perfeito. A métrica AUC equivale à probabilidade de que um

convênio reprovável escolhido aleatoriamente seja classificado com um score mais alto (verdadeiro negativo) do que um convênio aprovável (verdadeiro positivo), também escolhido aleatoriamente (BAO et al., 2020; BREIMAN, 2001; FAWCETT, 2006; STANISIC; RADOJEVIC; STANIC, 2019;).

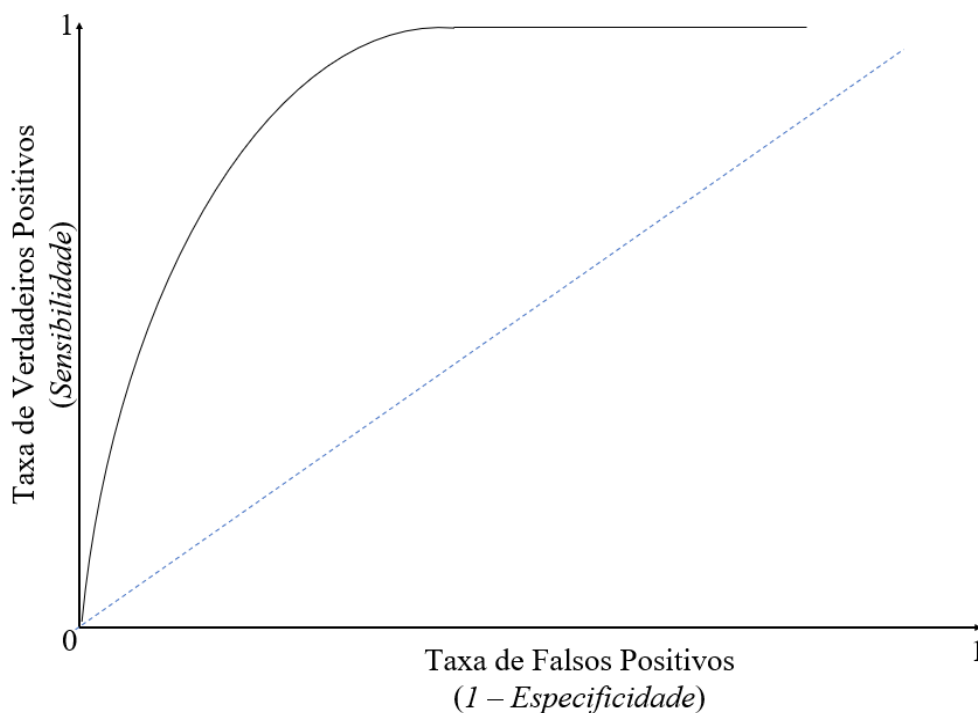


Figura 7 – Curva ROC. Adaptado de Alpaydin (2020) e Fawcett (2006). Elaborado pelo Autor.

As curvas ROC são uma ferramenta muito útil para visualizar o desempenho de algoritmos de classificação (CECCHINI et al., 2010). Elas são capazes de fornecer percuciência da medida do desempenho, complementarmente às medidas escalares como acurácia, sensibilidade, sensibilidade ou taxas de erro. No entanto, Fawcett (2006) sublinha que a curva ROC deve ser usada com parcimônia, pois, como com qualquer métrica de avaliação, possui limitações. Dessa forma, é sugerido que sua adoção seja cotejada com as outras métricas escalares.

3. CONTEXTUALIZAÇÃO DO PROBLEMA

O objetivo desta seção é tratar do gargalo operacional que se configurou no fluxo processual das Transferências Voluntárias da União. A criticidade do problema da falta de capacidade na etapa de análise de prestação de contas é elucidada, com o destaque de que esse problema se agrava com a contínua ampliação do quantitativo de prestações de contas pendentes de análise conclusiva. Esta seção está dividida em mais 4 partes, para além desta introdução. Na primeira descreveremos os incentivos que levaram à concepção do “*Malha Fina de Convênios*”. Na segunda parte, tratamos do que consiste essa solução. Em seguida, na terceira parte, são colocados os problemas e as incertezas na sua utilização. Por fim, na quarta seção, evidenciamos a importância desses problemas, a ponto de motivarem este trabalho.

3.1. Transferências Voluntárias e a Plataforma +Brasil (antigo SICONV)

O processo de Transferências Voluntárias da União movimentou mais de R\$ 135 bilhões entre 2008 e 2019 por meio de mais 170 mil instrumentos entre os entes da Federação, segundo dados da Plataforma +Brasil. Precisamente, em novembro de 2019 contava com 175.456 instrumentos cadastrados (BRASIL, 2019b).

Contudo, a concessão de transferências voluntárias pelos órgãos e entidades governamentais constitui um grande desafio aos administradores públicos, tanto no tocante à lisura desejada, quanto à operacionalização ágil e eficaz dos milhares de instrumentos destinados à implementação de políticas públicas nos Estados e Municípios brasileiros. Esse desafio ocorre devido a quantidade de agentes e a multiplicidade de objetos presentes na pactuação da concessão.

Entre as políticas públicas que receberam recursos por meio de repasse federal nos últimos 10 anos elenca-se: planejamento, gestão e desenvolvimento urbano (R\$ 11,3 bi); apoio ao turismo (R\$ 9,3 bi); atenção especializada em saúde (R\$ 7,5 bi); agricultura familiar (R\$ 5,5 bi); recursos hídricos (R\$ 4,3 bi); segurança pública (R\$ 4,3 bi); políticas indígenas (R\$ 4,2 bi); esportes de grandes eventos (R\$ R\$ 3,7 bi); esporte e lazer (R\$ 2,8 bi); e agricultura e pecuária (R\$ 2,7 bi).

Em que pese as deficiências notadamente reconhecidas na Plataforma +Brasil (antigo SICONV), esse sistema vem sendo aprimorado ao longo da última década e hoje permite atender requisitos primordiais da boa governança pública, a qual exige a transparência como pilar fundamental. Por sua vez, o processo de transferências

voluntárias se mostra ainda excessivamente moroso, pouco eficiente e eficaz (BRASIL, 2018a). Segundo os dados de um relatório de auditoria da CGU, o tempo médio do ciclo de vida de um processo de repasse de verbas federais no SICONV atinge mais de 5 anos. Adicionalmente, a CGU detectou um grande desequilíbrio entre a capacidade operacional dos órgãos concedentes e o volume de trabalho despendido para analisar as prestações de contas dos repasses efetuados. A quantidade de repasses efetuados exigiria um esforço de análise muito superior à capacidade de análise disponível dos órgãos repassadores.

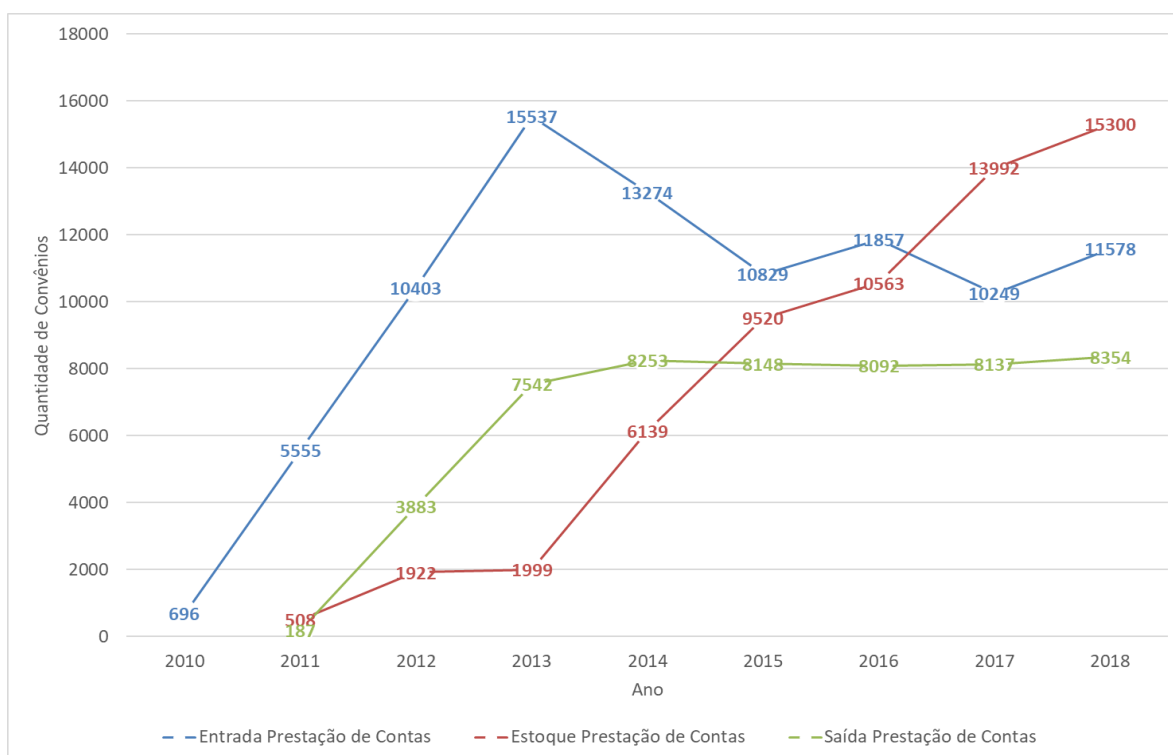


Figura 8 - Estoque de prestação de contas pendentes de análise. Elaborado pelo Autor. Adaptado de Brasil (2018a)⁶. Fonte: Plataforma +Brasil.

Diante desse gargalo operacional, emerge o problema de estoque de prestação de contas pendentes de análise pelos órgãos repassadores. A criticidade do problema é caracterizada pelo crescimento contínuo desse estoque. Na perspectiva da atividade de auditoria governamental, há duas linhas de atuação (BRASIL 2017; IIA 2012; OLIVIERI 2011) para a situação ilustrada na Figura 8.

⁶ A Figura 8 foi elaborada a partir do histórico da base(fotografia) no último dia de cada ano. Apenas assim seria possível verificar a real situação ano-a-ano da situação dos convênios, na medida em que a base de dados da Plataforma +Brasil possui inconsistências. Ao longo de 10 anos, muitas intervenções e atualizações no sistema Plataforma +Brasil se sucederam. Dessa forma, não seria fidedigno ilustrar a evolução do passivo de prestação de contas pendente de análise por meio de uma simples conta aritmética, subtraindo a quantidade de prestação de contas submetidas para análise em um determinado ano pela quantidade que foram analisadas no ano subsequente.

A primeira linha é a avaliação independente e objetiva do processo de operação das transferências voluntárias visando o aprimoramento do gerenciamento de risco, dos controles internos e da governança (BRASIL, 2017a). O resultado imediato de atuação nessa abordagem seriam algumas recomendações cujo teor demandaria que os órgãos repassadores de recursos envidem esforços para realizarem a análise de prestação de contas, ou caso não tenham capacidade de análise, abstenham-se de promover novos repasses. Trata-se de recomendações relevantes e úteis, porém óbvias, não passa de mais do mesmo (POWER, 2003b).

Por outro lado, a segunda linha de atuação consiste na consultoria, em que a auditoria presta serviços de assessoria e aconselhamento em assuntos estratégicos (BRASIL, 2017a) do processo de transferências voluntárias da união. O resultado da consultoria, geralmente, é um produto ou uma solução construída conjuntamente com o gestor. No caso em epígrafe, a consultoria produziu uma solução para o estoque de prestação de contas de repasses pendentes de análise.

Após a concretização da realização da auditoria interna seguindo os preceitos da forma de atuação em consultoria, foi entregue um sistema que permite resolver o flagrante desequilíbrio entre a capacidade operacional dos órgãos concedentes e o volume de trabalho requerido para analisar a prestação de contas. Esse desequilíbrio gerou um passivo de mais de 15 mil instrumentos, os quais correspondem a aproximadamente R\$ 17 bilhões pendentes de análise. Esse sistema foi denominado malha fina de convênios e consiste no uso de inteligência artificial.

Com base nas características de cada convênio ou contrato de repasse, a ferramenta reconhece padrões e permite prever, com elevado grau de precisão, o resultado da análise de contas, caso fosse realizada uma avaliação manual por servidores dos órgãos federais concedentes (ISSA; SUN; VASARHELYI, 2016; HUANG; VASARHELYI, 2019). Na prática, a aplicação da “Malha Fina de Convênios” verifica os instrumentos operacionalizados na Plataforma +Brasil, utiliza o aprendizado de máquina com o algoritmo supervisionado *Random Forest* e fornece um *score* para medir a probabilidade de aprovação ou reprovação das contas. A metodologia combina também a emissão de alertas gerados nas trilhas de auditoria aplicadas pela CGU, na busca por padrões pré-definidos de indícios de impropriedades ou irregularidades.

3.2. O Sistema “*Malha Fina de Convênios*”

O sistema “*Malha Fina de Convênios*” é um modelo preditivo criado pela CGU que permite indicar, com determinado grau de certeza, o resultado da análise das prestações de contas dos convênios quando são apresentadas pelos convenentes (entes subnacionais recebedores de recursos) aos concedentes (órgãos da União repassadores de recursos). Ou seja, o Malha Fina permite inferir se as contas dos convênios serão aprovadas ou rejeitadas.

Resumidamente, esse sistema foi o resultado do desenvolvimento de uma solução que usa um algoritmo de aprendizado de máquina com base nas características dos convênios cujas contas já foram analisadas. Entre setembro de 2008 e dezembro de 2017 mais de 61.000 convênios (BRASIL, 2019b) tiveram suas contas analisadas pelos concedentes, proporcionando uma quantidade de dados satisfatória para que o aprendizado do algoritmo fornecesse resultados com precisão. Ato contínuo, 104 variáveis de cada convênio foram utilizadas no algoritmo de aprendizagem supervisionado *Random Forest*, por seu desempenho ser melhor em comparação com outros (BREIMAN,2001; DOMINGOS, 2012).

Igualmente, o “*Malha Fina de Convênios*” possibilitará maior agilidade na deflagração do gatilho das providências administrativas a serem tomadas visando à elisão do dano ao Erário. Entre 2018 e 2019, foram instaurados 2.869 processos de Tomadas de Contas Especial (TCE) relativos a convênios e contratos de repasse com indícios de irregularidades, que buscam recuperar prejuízos estimados em mais de R\$ 6 bilhões⁷.

Esse sistema foi oficialmente disponibilizado à Administração Pública Federal em 07/11/2018 com a publicação no Diário Oficial da União da Instrução Normativa Interministerial nº 5, de 6 de novembro de 2018 (BRASIL, 2018b), editada conjuntamente entre a CGU, o extinto Ministério da Fazenda e o extinto Ministério do Planejamento, Desenvolvimento e Gestão. Aludida Instrução Normativa estipulou a data de 31/08/2018 como delimitador de prazo para definir o passivo de estoque. Dessa forma, todas as prestações de contas enviadas aos órgãos concedentes até 31/08/2018 são considerados estoque e sua análise pode ser amparada pelo sistema malha fina de convênios. Cabe ressaltar que a passivo aumentou aproximadamente 14% em quantidade e 9% em valor

⁷ Dados extraídos do sistema e-TCE, mantido pela Controladoria-Geral da União e Tribunal de Contas da União.

com o decurso de prazo de 8 meses entre 31/12/2017 (Tabela 2) e 31/08/2018 (Tabela 3), respaldando a tendência ilustrada na Figura 8.

Em seguida, a Instrução Normativa ME/CGU nº 1, de 14 de fevereiro de 2019 (BRASIL, 2019a), ampliou a abrangência de aplicabilidade do “*Malha Fina de Convênios*” para prestações de contas submetidas para análise a partir de 01/09/2018, conquanto o estoque de passivo referente à data base de 31/08/2018 esteja saneado.

Destarte, as duas Instruções Normativas supracitadas delinearão o escopo de abrangência do “*Malha Fina de Convênios*” e estabeleceram o marco de estreia. A operação do sistema na Plataforma +Brasil deu início a partir da publicação da IN MP/MF/CGU nº 05, de 06/11/2018. Essa Instrução Normativa contribuiu de forma significativa para a redução do prazo médio da fase de prestação de contas, que em 2018 superava em 2,5 anos. Com a inovação, houve um benefício imediato decorrente da diminuição de custos de processos administrativos, como a quantidade de servidores relacionados à análise do passivo existente (ISSA; SUN; VASARHELYI, 2016; WIRTZ; WEYERER; GEYER, 2019).

Órgão Superior Concedente	Total de Convênios		Valor Total dos Convênios	
Ministério do Turismo	2245	16,04%	R\$ 1.125.672.602,56	7,35%
Ministério da Saúde	1534	10,96%	R\$ 1.688.015.614,45	11,02%
Ministério do Esporte	1335	9,54%	R\$ 1.221.149.270,10	7,97%
Ministério da Justiça	1154	8,25%	R\$ 1.248.929.609,17	8,15%
Ministério da Integração Nacional	1055	7,54%	R\$ 964.877.853,50	6,30%
Ministério da Educação	1013	7,24%	R\$ 1.360.257.686,33	8,88%
Ministério da Agricultura, Pecuária e Abastecimento	813	5,81%	R\$ 598.888.074,09	3,91%
Ministério da Cultura	799	5,71%	R\$ 556.884.127,81	3,63%
Ministério do Desenvolvimento Social	643	4,60%	R\$ 2.793.503.462,56	18,23%
Presidência da República	629	4,50%	R\$ 315.130.127,01	2,06%
Ministério das Cidades	590	4,22%	R\$ 295.855.034,26	1,93%
Ministério dos Direitos Humanos	509	3,64%	R\$ 351.912.866,19	2,30%
Secretaria de Agricultura Familiar e do Desenvolvimento Agrário	433	3,09%	R\$ 624.652.594,87	4,08%
Ministério do Desenvolvimento Agrário	322	2,30%	R\$ 473.696.914,28	3,09%
Ministério do Trabalho e Emprego	271	1,94%	R\$ 545.836.212,74	3,56%
Ministério da Defesa	235	1,68%	R\$ 237.247.698,91	1,55%
Ministério da Ciência, Tecnologia, Inovações e Comunicações	199	1,42%	R\$ 608.145.941,46	3,97%
Ministério do Desenvolvimento, Indústria e Comércio Exterior	92	0,66%	R\$ 148.763.218,21	0,97%
Ministério do trabalho e Previdência Social	60	0,43%	R\$ 113.247.482,61	0,74%
Ministério do Meio Ambiente	46	0,33%	R\$ 34.297.066,37	0,22%
Ministério de Minas e Energia	12	0,09%	R\$ 11.256.083,04	0,07%
Ministério do Planejamento, Desenvolvimento e Gestão	1	0,01%	R\$ 777.825,00	0,01%
Justiça Eleitoral	1	0,01%	R\$ 514.460,65	0,00%
Ministério dos Transportes	1	0,01%	R\$ 1.430.704,88	0,01%
Total Geral	13992	100%	R\$ 15.320.942.531,05	100%

Tabela 2 - Passivo de convênios aguardando análise do concedente nas prestações de contas em 31/12/2017. Elaborado pelo Autor. Fonte Plataforma +Brasil

Órgão Superior Concedente	Total de Convênios		Valor Total dos Convênios	
Ministério da Saúde	2243	14,66%	R\$ 2.064.572.925,18	12,36%
Ministério do Turismo	2115	13,82%	R\$ 1.070.053.176,45	6,41%
Ministério do Esporte	1416	9,25%	R\$ 1.301.841.452,22	7,80%
Ministério da Justiça	1205	7,88%	R\$ 1.302.123.217,50	7,80%
Ministério da Integração nacional	1109	7,25%	R\$ 1.023.379.009,39	6,13%
Ministério da Educação	1059	6,92%	R\$ 1.444.256.052,34	8,65%
Ministério da Agricultura, Pecuária e Abastecimento	894	5,84%	R\$ 516.133.850,15	3,09%
Presidência da República	830	5,42%	R\$ 495.708.688,49	2,97%
Ministério da Cultura	823	5,38%	R\$ 587.646.518,43	3,52%
Ministério das Cidades	760	4,97%	R\$ 371.683.423,51	2,23%
Ministério do Desenvolvimento Social	653	4,27%	R\$ 2.879.625.133,53	17,24%
Ministério dos Direitos Humanos	545	3,56%	R\$ 370.170.155,79	2,22%
Secretaria de Agricultura Familiar e do Desenvolvimento Agrário	469	3,07%	R\$ 648.547.655,40	3,88%
Ministério do Desenvolvimento Agrário	305	1,99%	R\$ 473.913.885,79	2,84%
Ministério do Trabalho e Emprego	258	1,69%	R\$ 518.660.571,00	3,11%
Ministério da Defesa	230	1,50%	R\$ 637.759.438,63	3,82%
Ministério da Ciência, Tecnologia, Inovações e Comunicações	192	1,25%	R\$ 649.926.740,64	3,89%
Ministério do trabalho e Previdência Social	70	0,46%	R\$ 138.538.169,93	0,83%
Ministério do Meio Ambiente	53	0,35%	R\$ 39.800.858,50	0,24%
Ministério do Desenvolvimento, Indústria e Comércio Exterior	52	0,34%	R\$ 146.587.135,28	0,88%
Ministério de Minas e Energia	16	0,10%	R\$ 15.770.059,31	0,09%
Ministério dos Transportes	1	0,01%	R\$ 1.430.704,88	0,01%
Justiça Eleitoral	1	0,01%	R\$ 677.247,82	0,00%
Ministério do Planejamento, Desenvolvimento e Gestão	1	0,01%	R\$ 777.825,00	0,00%
Total Geral	15300	100,00%	R\$ 16.699.583.895,16	100,00%

Tabela 3 - Passivo de convênios aguardando análise do concedente nas prestações de contas em 31/08/2018. Elaborado pelo Autor. Fonte Plataforma +Brasil..

A necessidade de apresentação de uma solução para a adversidade imposta pelo crescente aumento de convênios sem prestação de contas conclusiva foi encorajada pelo pleito recorrente dos gestores envolvidos na operação dos convênios. Mesmo antes da instituição do antigo SICONV em 2007, o problema do passivo de prestação de contas em convênio tem sido um percalço inconveniente aos órgãos concedentes e aos órgãos de controle que rotineiramente precisam flexibilizar as exigências impostas de prazos para conclusão de prestação de contas. Dessa forma surge a encomenda para a realização de pesquisas e critérios que pudessem amparar a análise de prestações de contas de modo mais célere (BRASIL, 2017a, 2017b) tendo em vista o constante incremento da quantidade de instrumentos em estoque.

O principal objetivo da “*Malha Fina de Convênios*” é solucionar o problema crítico de falta de capacidade operacional que envolve o processo de transferências voluntárias da União. A situação vem se agravando, ao considerar a contínua ampliação do quantitativo de prestações de contas pendentes de análise. Até o final do mês de agosto de 2018, a quantidade de convênios inseridos em um estoque de passivo aguardando prestação de contas já somava 15,3 mil instrumentos, no valor total de R\$ 16,7 bilhões.

O público alvo desta iniciativa são todos os órgãos concedentes de recursos de transferências discricionárias operacionalizadas na Plataforma +Brasil por meio de convênios e contratos de repasse. Especificamente, os setores que mais se beneficiaram ou poderão se beneficiar do sistema malha fina de convênios são aqueles responsáveis pela execução financeira e análise de prestação de contas dentro dos órgãos. Geralmente, a estrutura administrativa que vigora no aparato burocrático do governo federal denomina esses setores como Diretoria de Gestão Interna, Diretoria de Finanças e Contabilidade, Subsecretaria de Planejamento, Orçamento e Administração, Diretoria de Administração, entre outros. Assim, o público alvo determinante do “*Malha Fina de Convênios*” são 140 órgãos da Administração Pública Federal Direta, Autárquica e Fundacional que celebram convênios sobre a égide das normas da Plataforma +Brasil (ANEXO II).

A implementação do sistema malha fina convênios envolveu um esforço empreendido ao longo de 3 anos, em 4 grandes etapas.

A primeira etapa consistiu na encomenda de pesquisas e critérios que pudessem amparar a análise de prestações de contas de modo mais célere, tendo em vista o constante incremento da quantidade de instrumentos em estoque, conforme consignado no Relatório nº 201700374 (BRASIL, 2018a) e das propostas do Grupo de Trabalho constituído pela

Portaria nº 378, de 07 de fevereiro de 2017, da Secretaria Federal de Controle Interno (BRASIL, 2017b).

A segunda etapa valeu-se no desenvolvimento de um modelo preditivo criado pela Diretoria de Pesquisas e Informações Estratégicas – DIE – da CGU a partir do qual, por meio de aprendizado de máquina e com base nas características de cada instrumento de transferência, é possível prever, com determinado grau de certeza, o resultado da análise das prestação de contas caso elas fossem apresentadas aos concedentes, ou seja, a aprovação ou rejeição das contas. A aplicação do modelo resulta na constituição de uma nota de risco dos instrumentos analisados por faixas predefinidas a partir da probabilidade de reprovação ou aprovação

A terceira etapa iniciou-se com a validação do modelo desenvolvido pela DIE/CGU. Essa validação foi realizada pela Secretaria Federal de Controle Interno – SFC - e utilizou-se da estatística descritiva da base de dados dos convênios para aplicar testes de confiabilidade nas notas de risco geradas pelo algoritmo de inteligência artificial. Adicionalmente, as notas de risco geradas pelo sistema foram triadas e confrontadas em um mecanismo de teste cego, em que os setores de auditoria de cada área temática do governo (Educação, Saúde, Infraestrutura, Turismo, Esportes, Assistência Social, entre outros) foram instados a indicar quais os convênios possuem maior criticidade conforme sua percepção assimilada de auditorias pretéritas. Dessa forma, foi construída uma maneira de comparação entre as notas de risco atribuída pelo algoritmo e a criticidade apontada subjetivamente pelos auditores da Secretaria Federal de Controle Interno.

A quarta etapa deu início com a apresentação do sistema e dos testes de validação ao extinto Departamento de Transferências Voluntárias do também extinto Ministério do Desenvolvimento, Planejamento e Gestão. Ao ilustrar a proposta de solução do gargalo operacional das prestações de contas houve imediato acolhimento dos gestores da política pública das repasses da União ao Entes subnacionais. A sinergia entre as equipes da CGU e ME floresceu e novos aprimoramentos foram incorporadas na solução que compõem o algoritmo classificador de riscos dos convênios. O SERPRO, empresa responsável pelo desenvolvimento e operação da Plataforma +Brasil, foi integrado ao processo de implementação do sistema Malha Fina de Convênios, na medida em que era imprescindível a promoção de adaptações no fluxo da Plataforma +Brasil para viabilizar a análise de prestação de contas automatizada. O trabalho conjunto culminou na edição das portarias (a) Instrução Normativa MP/MF/CGU nº 05, de 06/11/2018, e (b) Instrução

Normativa ME/CGU nº 1, de 14.

A essência do “*Malha Fina de Convênios*” reside na aplicação de um algoritmo que atribui um *score* individual para cada convênio, variando entre 0 e 1. Quanto mais próximo de 0 estiver o *score*, maior a chance de o convênio ter suas contas reprovadas. Alternativamente, quanto mais próximo de 1, maior as chances de o convênio ter suas contas rejeitadas. Conseqüentemente, a rejeição das contas de um convênio enseja o concedente a tomar as medidas cabíveis para a recuperação do dano ao Erário, como por exemplo, a instauração de uma Tomada de Contas Especial (TCE).

Com o intuito de aferir a assertividade das notas atribuídas pelo algoritmo aos convênios, a CGU procedeu com uma verificação, comparando as notas com o resultado da análise das prestações de contas feita pelos concedentes. Em 31/12/2017, conforme exibido na Tabela 2, havia 13.992 convênios aguardando análise de prestação de contas, configurando um estoque com um passivo de mais de R\$ 15,3 bilhões.

O algoritmo foi executado para que aprendesse com o histórico de convênios cujo ciclo de vida estava encerrado, ou seja, havia o resultado conclusivo da análise da prestação de contas, rejeitando ou aprovando-as. Logo, todos os convênios encerrados que constavam na base de dados da Plataforma +Brasil até a data limite de 31/12/2017 foram usados como sequência de treinamento no algoritmo de aprendizado de máquina. Conseqüentemente, por meio da utilização do algoritmo gerado, foi possível atribuir uma nota de risco para todos os 13.992 convênios cujas contas estavam pendentes de análise. Por sua vez, esse *score* excursiona entre 0 e 1. Quanto mais próximo de 0, maiores são as chances de aprovação das contas, enquanto mais próximo 1, maiores são as chances de sua reprovação.

Dessa forma, o algoritmo atribuiu um *score* para todos os 13.992 convênios do estoque, conforme a Tabela 4. A técnica de verificação da CGU foi aguardar o decurso de tempo até que as prestações de contas de alguns convênios do estoque fossem analisadas pelos órgãos concedentes, sem que esses soubessem da existência do algoritmo de IA que classificava os convênios. Proceder-se-ia o cotejamento entre a nota atribuída pelo algoritmo e o efetivo resultado da análise das contas. Assim, em 18/04/2018, 1.948 convênios tiveram suas prestações de contas analisadas. Os resultados dessa análise pelos órgãos concedentes perfizeram 1.305 instrumentos aprovados, 336 aprovados com ressalvas e 307 rejeitados (1.948 no total).

Situação Convênio	Intervalo de <i>Score</i>							Total
	[0,0 a 0,4)	[0,4 a 0,5)	[0,5 a 0,6)	[0,6 a 0,7)	[0,7 a 0,8)	[0,8 a 0,9)	[0,9a 1,0]	
Em Análise	102	209	310	645	910	797	1348	4321
Em Complementação	135	115	173	261	353	389	408	1834
Enviada para Análise	505	866	1017	1453	1732	1095	700	7368
Iniciada Por Antecipação	124	113	89	76	62	5	0	469
Total	866	1303	1589	2435	3057	2286	2456	13992

Tabela 4 - Distribuição da nota atribuída pelo algoritmo aos 13.992 convênios aguardando análise da prestação de contas em 31/12/2017.

A confiabilidade do algoritmo foi mensurada mediante a confrontação da nota atribuída aos convênios cujas prestações de contas foram avaliadas pelos órgãos concedentes entre 01/01/2018 e 18/04/2018 (1.948). Naturalmente, observou-se que o algoritmo não é infalível e atribui notas relativamente próximas de 0 para convênios com prestação de contas reprovadas.

Contudo, essa classificação inadvertida de convênios reprováveis ocorre a uma taxa baixa, conforme observado na Tabela 5. Os resultados demonstram que dos 307 convênios com prestação de contas rejeitadas, apenas 12 encontram-se classificados com nota até o intervalo 0,7. Esses 12 convênios constituem-se em 1 convênio no intervalo [0,4 a 0,5), 5 convênios no intervalo [0,5 a 0,6) e 6 convênios no intervalo [0,6 a 0,7). Logo, os 295 convênios restantes cujas contas foram reprovadas estão classificados com nota acima de 0,7. Mais de 70% dos convênios reprovados foram classificados pelo algoritmo com nota acima de 0,9.

Resultado Análise	Intervalo de Score							Total
	[0,0 a 0,4)	[0,4 a 0,5)	[0,5 a 0,6)	[0,6 a 0,7)	[0,7 a 0,8)	[0,8 a 0,9)	[0,9 a 1,0]	
Aprovada	201	235	203	203	170	180	113	1.305
Aprovada com Ressalvas	9	12	23	40	78	102	72	336
Rejeitada	0	1	5	6	10	68	217	307
Total	210	248	231	249	258	350	402	1.948

Tabela 5 - Distribuição do *score* atribuído pelo algoritmo do sistema "Malha Fina de Convênios" aos convênios analisados entre 01/01/2018 e 18/04/2018.

Adicionalmente, cabe registrar que o sistema “Malha Fina de Convênios” vai ao encontro das premissas estabelecidas no modelo “*Digital-Era Governance*” e endossa a ruptura em relação ao “*New Public Management*” (DUNLEAVY et al., 2006). Há um ganho de eficiência ao implementar o “Malha Fina de Convênios”, ao passo que o trabalho rotineiro do servidores públicos que analisam convênios passa a ser racionalizado weberianamente, em seu sentido estrito, já que a partir dos resultados oriundos do processamento de dados realizado pelo sistema, serão determinados quantos e quais convênios devem ser avaliados mais detidamente pelas pessoas.

Logo, o “*Malha Fina de Convênios*” não se reveste apenas de uma inovação tecnológica que oportuniza, por exemplo, a digitalização das prestações de contas, e que torna o trabalho mais eficiente por agilizar a prestação de contas por meio do tratamento e a análise dos dados (outrora visão do *New Public Management*); mas sim, de um novo papel dado à tecnologia que faz parte da política pública em si, neste caso das Transferências Voluntárias da União (BRESSER PEREIRA, 1998; MARGETTS; DUNLEAVY, 2002; BARZELAY, 2018).

3.3. Descrição do problema

O “*Malha Fina de Convênios*” permitiria auxiliar o trabalho de análise das prestações de contas, uma vez que esse sistema reveste-se de todas as qualidades do que Huang e Vasarhelyi (2019), Sun (2019) e Zhang (2019b) denominam *Robotic Process Automation* (RPA). Um RPA serve para automatizar tarefas bem-definidas e repetitivas, neste caso a análise de prestação de contas de convênios pelos órgãos concedentes. Basta que o órgão estipule uma nota mínima ante a qual todos os convênios classificados abaixo

dela sejam aprovados. Contudo, existem hipóteses e condicionantes em que a adoção do “*Malha Fina de Convênios*” na análise de prestação de contas seja mais assertiva?

Uma objeção contundente contra a lógica da sistemática do “*Malha Fina de Convênios*” desponta: em que medida a precisão do algoritmo de inteligência artificial (SUN, 2019; ZHANG, 2019a) inviabilizaria sua adoção para a análise de contas automática, sem a necessidade de avaliação convencional por um servidor público do órgão concedente?

Primeiramente, para responder a essa pergunta é imprescindível medir a precisão do algoritmo conforme a variação do intervalo das notas (*scores*), as quais podem excursionar entre 0 e 1. Invariavelmente, a adoção do Malha Fina para análise das prestações de contas incidirá sobre a definição de um limiar de *score* em que se admitiria convênios aprovados. Todos os convênios com *score* acima desse limiar seriam considerados reprováveis, carecendo uma análise convencional. Dessa forma, torna-se muito relevante a distribuição das notas por seu intervalo acumulado, uma vez que a taxa de erro do algoritmo deve ser considerada em todo o intervalo a partir de um determinado limiar.

Como exemplo, observando os dados exibidos na Tabela 6 e a ilustração da Figura 9, se um determinado órgão estipular a nota 0,8 como seu limiar, significa que 79,4% dos seus convênios poderão ser passíveis de aprovação tácita, sendo que entre esses, 4,62% seriam aprovados inadvertidamente, na medida em que o algoritmo de classificação não é perfeito. Notadamente, o estabelecimento de limiar de nota por parte de órgão concedente reflete o seu apetite ao risco. Conforme as curvas da Figura 9, quanto maior o apetite ao risco, maior será nota de limiar e maior serão as chances de aprovar tacitamente convênios reprováveis.

Situação da Prestação de Contas	Intervalo Acumulado de <i>Score</i>						
	[0,0 a 0,4)	[0,0 a 0,5)	[0,0 a 0,6)	[0,0 a 0,7)	[0,0 a 0,8)	[0,0 a 0,9)	[0,0 a 1,0]
Aprovada	201	436	639	842	1.012	1.192	1.305
Aprovada com Ressalvas	9	21	44	84	162	264	336
Rejeitada		1	6	12	22	90	307
Total	210	458	689	938	1.196	1.546	1.948

Tabela 6 - Distribuição do intervalo acumulado de notas atribuídas pelo “*Malha Fina de Convênios*” dos convênios analisados entre 01/01/2018 e 18/04/2018.

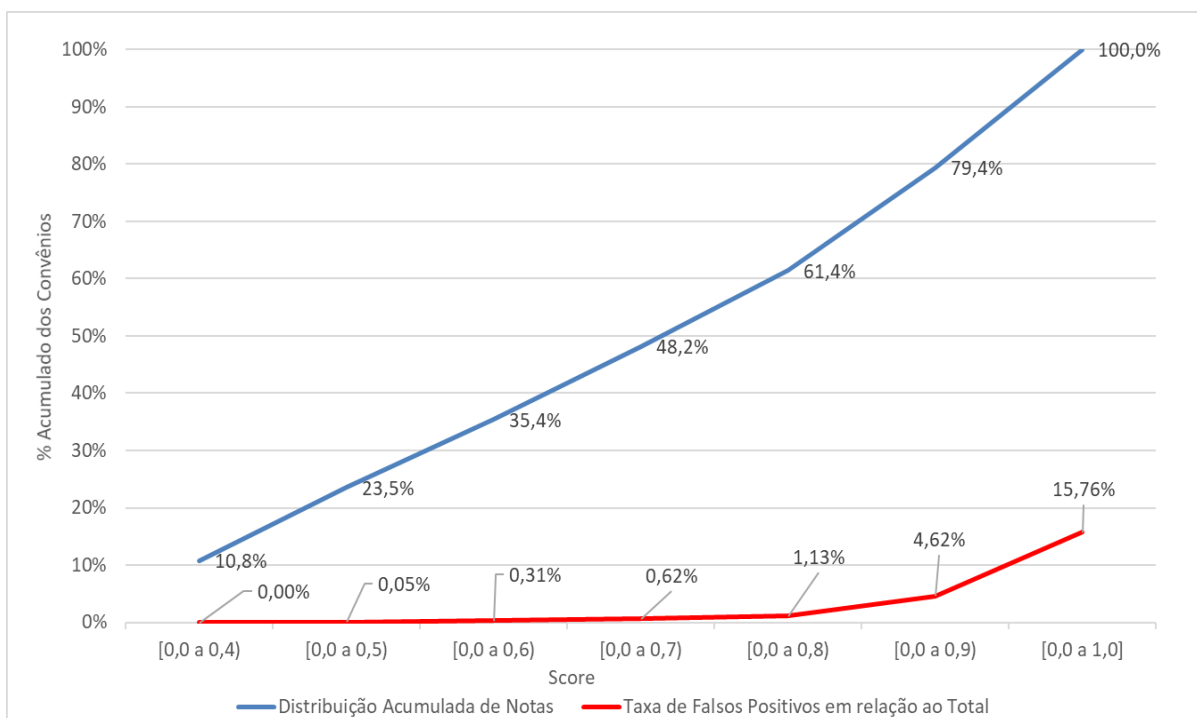


Figura 9 – Precisão do "Malha Fina de Convênios". Posição: convênios analisados entre 01/01/2018 e 18/04/2018. Elaborado pelo Autor.

Porém, a natureza de atuação de políticas públicas dos órgãos repassadores de recursos é plural e muito distinta entre si. As curvas apresentadas na Figura 9, contemplam todo o espectro de instrumentos celebrados na Plataforma +Brasil por órgãos da esfera federal, de maneira agregada. Ou seja, as taxas de erro exibidas não levam em consideração as qualidades intrínsecas do órgão repassador, da política pública que lhe é competente, muito menos o contexto em que se insere. Conseqüentemente, essas variáveis suscitam a possibilidade de as taxas de erro serem diferentes conforme a identidade do órgãos concedente, o que motiva a proposição de 2 hipóteses:

Hipótese 1: a precisão do algoritmo seria melhor caso o aprendizado de máquina fosse aplicado para cada órgão concedente, separadamente?

Hipótese 2: o desempenho do algoritmo apresentaria comportamento diferente caso houvesse segregação por órgão concedente?

Por sua vez, os dados obtidos sobre as taxas de reprovação de contas de convênios apresentadas pelos convenientes, restringiu-se a um período de menos de 4 meses,

repercutindo entre 01/01/2018 e 18/04/2018. O algoritmo aprendeu a classificar os convênios com base em todos aqueles com contas analisadas (aprovadas, aprovadas com ressalva ou rejeitadas) desde o início de registro de dados na base da Plataforma +Brasil entre setembro de 2008 até o dia 31/12/2017.

Após a constatação que os algoritmos baseados em aprendizado de máquina por *Random Forest* erram, ao encontro do que é argumentado por Alpaydin (2020), Issa, Sun e Vasarhelyi (2016) e Sun (2019), uma questão central se estabelece sobre a volumetria da sequência de treinamento usada para o algoritmo aprender. Trata-se do ponto ótimo do tamanho da sequência de treinamento que conferiria segurança na adoção do sistema, minimizando o risco de aprovação de contas de convênios reprováveis (falsos positivos) e maximizando a análise automática, sem a necessidade de avaliação convencional por um servidor público do órgão concedente. Conforme observado na Figura 9, nos casos de avaliação realizada de maneira automática pelo sistema há uma taxa inerente de probabilidade de “erros de diagnóstico”, ou seja, convênios reprováveis, mas classificados com nota abaixo do limiar estipulado para aprovação tácita.

Nesse sentido, há a possibilidade de realizar simulações em que seria possível aferir e medir o desempenho de fidedignidade da aprendizagem conforme a agregação de dados ao longo do tempo. Por exemplo, o algoritmo poderia ser executado em lotes anuais considerando o estado da base na data de 31/12. Posteriormente, verificar-se-ia o resultado da análise das prestações de contas no ano subsequente e a comparação com as notas atribuídas pelo sistema. Logo, a perspectiva de esclarecer essas incertezas, justifica a proposição de mais duas hipóteses:

Hipótese 3: a precisão de classificação do algoritmo de aprendizado de máquina aumenta à medida que há mais dados no universo de aprendizagem?

Hipótese 4: é possível prever a existência de ponto de saturação em que a quantidade de dados não seja mais relevante para que o algoritmo de aprendizado de máquina classifique convênios?

Constructo Associado

Hipóteses

Hipótese 1: a precisão do algoritmo seria melhor caso o aprendizado de máquina fosse aplicado para cada órgão concedente (ANEXO II), separadamente?

Identidade do repassador de recurso

Hipótese 2: o desempenho do algoritmo apresentaria comportamento diferente caso houvesse segregação por órgão concedente?

Hipótese 3: a precisão de classificação do algoritmo de aprendizado de máquina aumenta à medida que há mais dados no universo de aprendizagem?

Tamanho de treinamento de dados

Hipótese 4: é possível prever a existência de ponto de saturação em que a quantidade de dados não seja mais relevante para que o algoritmo de aprendizado de máquina classifique convênios?

Tabela 7 - Relacionamento entre Constructos e Hipóteses de Pesquisa. Fonte: Elaborado pelo autor.

3.4. Importância do Problema

O contínuo incremento da quantidade de prestações de contas pendentes de análise conclusiva possui impactos negativos gravíssimos. A existência de uma grande quantidade de convênios aguardando análise de suas prestações de contas gera consequências como: a criação de um estoque; inépcia na avaliação e no monitoramento de recursos públicos repassados aos entes subnacionais; incapacidade de a União aferir a efetividade da política pública de transferências voluntárias; e descumprimento do dever legal de prestar contas, o que reflete em total ausência de *accountability* (SCHEDLER, 1999). Com efeito, o “*Malha Fina De Convênios*” ataca frontalmente a causa dos problemas (Figura 10), o que proporcionará uma reversão dos efeitos deletérios que o estoque de prestação de contas gera na política pública das transferências voluntárias da união.

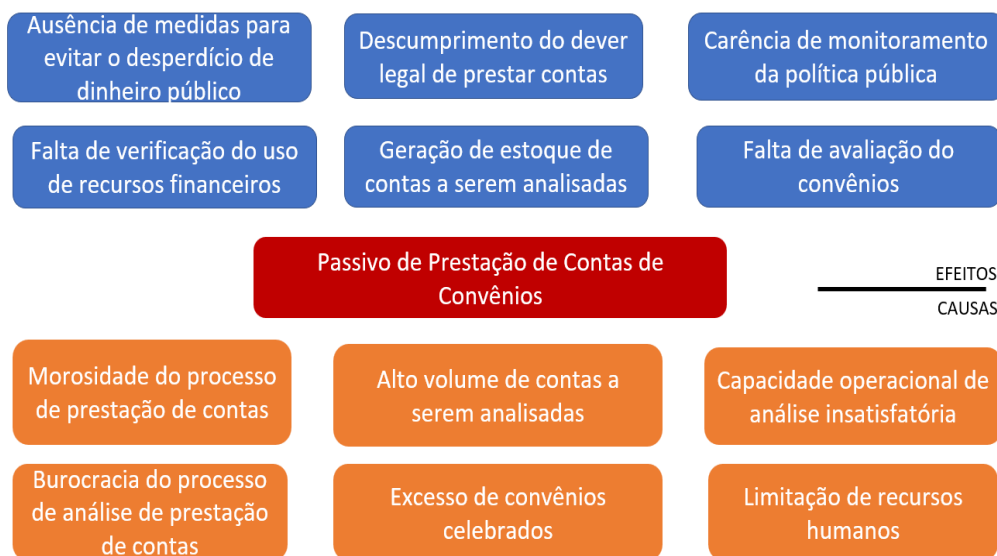


Figura 10 – Árvore de problemas da fase de prestação de contas do ciclo de vida de um convênio.
Fonte: Elaborado pelo próprio autor.

Admitindo-se que o sistema “*Malha Fina de Convênios*” pode ser visto como um projeto, é de se esperar que ofereceu um resultado visando solucionar o problema do passivo mediante o emprego de um esforço temporário. Dessa forma, os meios e os recursos empregados nesse esforço temporário foram relacionados aos problemas ilustrados na Figura 10. A metodologia da árvore de objetivos aplica-se adequadamente no projeto de desenvolvimento do Malha Fina. Segundo Silva e Bernardes (2014) a árvore de objetivos é uma metodologia sugerida na literatura que permite, mediante a discussão de determinados problemas, a definição e estratégias de ação (JACKSON, 1997). Por sua vez, Jackson (1997) afirma que uma vez definidos os objetivos, a análise da estratégia de ação do projeto pode se tornar mais lógica, evidenciando a relação entre os problemas elencados e os objetivos propostos. Consequentemente, as mudanças provocadas com o propósito de solucionar o problema em tela visaram a consecução de objetivos substanciais tais como: a eliminação do estoque; aptidão na avaliação e no monitoramento de recursos públicos repassados aos entes subnacionais; capacidade de a União aferir a efetividade da política pública de transferências voluntárias tempestivamente; e, por último, mas não menos importante, a observância de *accountability* por meio do cumprimento do dever legal de prestar contas (Figura 11).

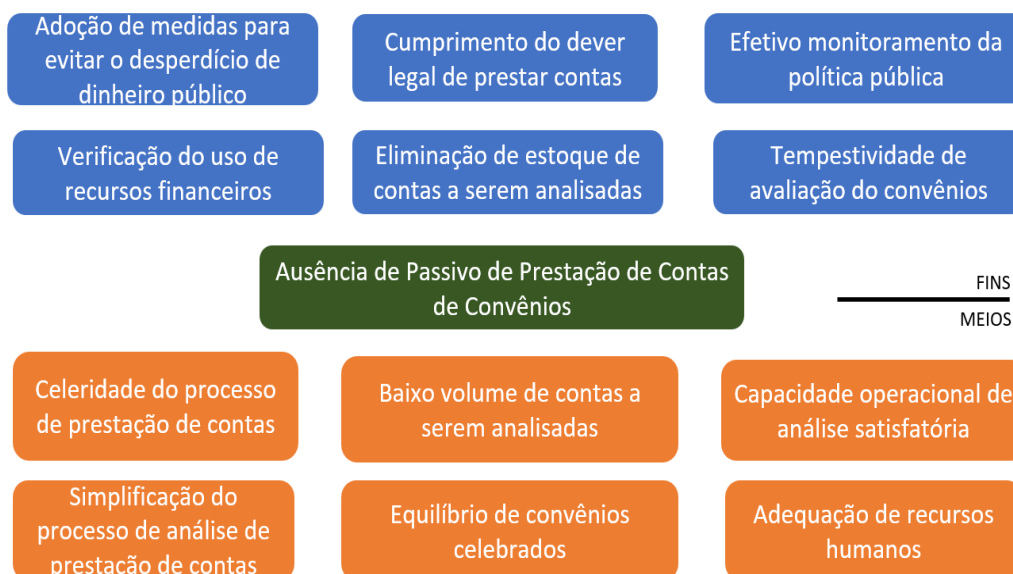


Figura 11 - Árvore de objetivos para solucionar o gargalo da fase de prestação de contas no ciclo de vida de um convênio. Fonte: Elaborado pelo próprio Autor

Logo, a validação do método de prestação de contas automatizada é fundamental para a continuidade da abordagem inovadora proposta pelo “*Malha Fina de Convênios*”. Ao esclarecermos as condicionantes em que a adoção do Malha Fina na análise de prestação de contas seja mais assertiva, notadamente por meio dos constructos *Identidade do repassador de recurso* (H1 e H2) e *Tamanho de treinamento de dados* (H3 e H4), possíveis objeções contra sua implantação serão descartadas.

Ademais, os benefícios advindos do uso do Malha Fina são muito relevantes para minimizar o risco da atividade de auditoria, fato que robustece ainda mais a importância do teste dos constructos propostos. Com efeito, a atividade de auditoria, como qualquer outra operação de uma organização, está suscetível ao risco de insucesso (BRASIL, 2017a). Ademais, os auditores precisam tomar decisões visando a segurança na emissão de opinião daquilo que está sendo avaliado (HUANG; VASARHELYI, 2019; STANISIC; RADOJEVIC; STANIC, 2019). Todavia, essas decisões são contrapostas entre a escassez de insumos e a pressão por assegurar e certificar operações cujo universo auditável consumiria escopo, tempo e recursos muito maiores que os disponíveis (GAO, 2011;ZHANG, 2019b). Essa dicotomia gera o risco de auditoria.

Por sua vez, o risco de auditoria é a incapacidade do auditor em detectar um erro em uma amostra (AL-QUDAH; BANIAHMAD; AL-FAWAERAH, 2013). A não detecção de um erro de amostra pode ser causado por fadiga ou desatenção do auditor, como também pode ser causada pela aplicação de um procedimento de auditoria inadequado (IIA, 2012). À luz desse cenário, os mecanismos de automação robotizada e

inteligência artificial que usufruem o reconhecimento de padrões para definição de eventos recorrentes configura-se em uma solução para equacionar o problema entre os escassos recursos de auditoria versus a segurança na emissão de opinião sobre a operação auditada (POWER, 2009). Nesta perspectiva, o “*Malha Fina de Convênios*” consiste em uma mecanismo de auditoria dessa categoria.

4. METODOLOGIA

No presente capítulo será abordada a estratégia metodológica, inspirada em Bao et al. (2020), Cecchini et al. (2010), Grover, Bauhoff e Friedman (2019), Hooda, Bawa e Rana (2020), Stanistic, Radojevic e Stanic (2019) e Zhang(2019a). Por sua vez, essa estratégia valeu-se preponderantemente da implementação empírica de um ambiente computacional em linguagem *python*. Por conseguinte, avaliar-se-á o desempenho do algoritmo do “*Malha Fina de Convênios*” (*Random Forest*) diante de diversos cenários concebidos exclusivamente para testar os constructos *Identidade do repassador de recurso* (H1 e H2) e *Tamanho de treinamento de dados* (H3 e H4).

Naturalmente, o alcance dos objetivos desta pesquisa foi viabilizado por meio das seguintes atividades:

- ✓ Mapeamento do ciclo de vida de um convênio operacionalizado no Plataforma +Brasil e relacionar todas as situações que aguardam a análise do órgão federal concedente na prestação das contas apresentada pelo ente subnacional convenente (BRASIL, 2019b), bem como descrição do universo de convênios na Plataforma +Brasil, incluindo o corte temporal.
- ✓ Configuração de um ambiente de testes, cujo desempenho computacional fosse satisfatório, com bases de dados de diferentes datas para que o algoritmo do sistema “*Malha Fina De Convênios*” treine com diferentes séries de dados, conforme sublinha Stanistic, Radojevic e Stanic (2019) e Zhang (2019a).
- ✓ Identificação dos requisitos necessários à construção de um modelo de análise que demonstre a relação dos diferentes cenários a serem testados nas hipóteses, garantido que os recursos computacionais disponíveis não sejam empecilho para o desempenho (BREIMAN, 2001; DOMINGOS, 2012). Logo, há a necessidade de elaborar uma arquitetura viável para a execução dos cenários de testes, haja vista que esses são muito numerosos, na ordem de centenas;
- ✓ Análise e interpretação dos resultados do modelo adotado, fornecendo elementos necessários às conclusões consignadas na presente pesquisa, à luz do roteiro sugerido na pesquisas conduzida por Sun (2019).

Segundo Creswell (2007), existem três técnicas de pesquisa: Quantitativa, Qualitativa, ou Métodos Mistos. A técnica de pesquisa mais adequada para estudar as

hipóteses propostas é a Quantitativa, na medida em que essa técnica emprega a coleta de dados e instrumentos estatísticos. Necessariamente, a utilização de dados comparativos, oriundos dos diferentes algoritmos de aprendizado de máquina supervisionados *Random Forest* desenvolvidos no ambiente computacional em linguagem *Python* com o propósito de testar as hipóteses, será um ponto chave para o desdobramento da pesquisa.

O maior risco inerente ao processo do sistema “*Malha Fina De Convênios*” é a classificação inadvertida de convênios cujas contas foram rejeitadas com uma *score* próximo de zero (falso positivo). Assim, o desempenho dos algoritmos de IA concebidos para testar as hipóteses será mensurado pela taxa de ocorrência de falsos positivos ao longo do domínio do *score* entre 0 e 1. Por seu turno, a precisão do algoritmo é aferida verificando-se a distribuição de convênios reprovados ao longo do intervalo [0, 1].

Conquanto os algoritmos de aprendizagem supervisionados *Random Forest* sejam de alto desempenho (BAO et al., 2020; HOODA; BAWA; RANA, 2020; BREIMAN, 2001; GROVER; BAUHOFF; FRIEDMAN, 2019;), isso tem pouco valor nos constructos propostos. O principal objetivo nos testes das hipóteses propostas nesta pesquisa é detectar com precisão o maior número possível de convênios reprovados, sem classificá-los erroneamente como aprovados, ou seja, a taxa de falso positivos em relação ao total. Nesse aspecto, é importante destacar uma peculiaridade em relação às métricas especificidade e sensibilidade, na medida em que essas métricas não são relativas ao total da população, mas às categorias convênios aprovados(sensibilidade) e reprovados(especificidade).

Ademais, as métricas para mensuração de desempenho geralmente utilizadas (acurácia, sensibilidade e especificidade) não são apropriadas para o enfrentamento deste problema de pesquisa haja vista o desequilíbrio no balanceamento da sequência de treinamento (ALPAYDIN, 2020; BAO et al., 2020). Os convênios reprovados representam menos de 3% do total. Naturalmente, a estratégia de aferir a especificidade por meio da taxa de acerto de classificação de convênios reprovados levaria a uma precisão muito alta, o que seria ingênuo para avaliar o desempenho.

O desequilíbrio das sequências de treinamento, conforme retratado na literatura (BAO et al., 2020; BREIMAN, 2001; FAWCETT, 2006; DOMINGOS, 2012; STANISIC; RADOJEVIC; STANIC, 2019), pode ser observado na Tabela 8, abaixo. Enquanto a extinta Secretaria de Desenvolvimento Agropecuário e Cooperativismo não rejeitou nenhuma prestação de conta dos 1.815 convênios em que essa Secretaria figurou

como repassadora de recursos, o Ministério do Turismo reprovou 779 prestações de contas entre os 6.796 convênios celebrados por este Ministério na condição de repassador de recursos.

Descrição do Órgão	Prestações de Contas			Total
	Rejeitada	Aprovada	Aprovada com Ressalvas	
Secretaria de Desenvolvimento Agropecuário e Cooperativismo	0	1795	20	1815
Ministério das Cidades	2	9012	233	9247
Ministério da Justiça e Segurança Pública	7	688	151	846
Fundação Nacional de Saúde	16	677	297	990
Ministério do Esporte	29	3553	273	3855
Ministério da Agricultura, Pecuária e Abastecimento	46	12453	249	12748
Ministério da Saúde	84	2295	3148	5527
Ministério da Defesa	134	1104	206	1444
Ministério da Cidadania	137	2274	377	2788
Ministério do Turismo	779	4972	1045	6796
Total 10 órgãos	1234	38823	5999	46056
Total Todos os Órgãos	1533	43575	6737	51845

Tabela 8 – Distribuição da situação das prestações de contas dos convênios dos 10 órgãos mais representativos da população. Fonte: Plataforma +Brasil. Data base: novembro de 2019.

Igualmente, a Figura 12 ilustra a diferença de rigor na análise das prestações de contas entre os 10 órgãos eleitos (Tabela 9) para o teste das hipóteses do constructo “*Identidade do repassador de recurso*”. Os Ministérios do Turismo, Cidadania e Defesa, nitidamente, rejeitam mais prestações de contas do que a extinta Secretaria de Desenvolvimento Agropecuário e Cooperativismo e os Ministérios das Cidades e Justiça e Segurança Pública. Presume-se que os primeiros órgãos são mais austeros e comedidos nas análises de prestações de contas, enquanto os segundos são mais lenientes. Entretanto, frise-se que tal afirmação é meramente sugestiva, pois seria necessário avaliar o mérito de cada prestação de contas apresentada àqueles órgãos com baixa taxa de reprovação para embasar qualquer alegação sobre o zelo e diligência acerca da sua análise, afinal de contas as transferências de recursos aos entes subnacionais são cercadas de idiosincrasias (ABRUCIO; FRANZESE, 2007; AMORIM NETO; SIMONASSI, 2013; FAJARDO,

2016). O fato de que os convênios celebrados nesses órgãos sejam conduzidos com a boa e regular aplicação dos recursos públicos não pode ser afastada, razão pela qual as contas de seus convênios nunca são rejeitadas.

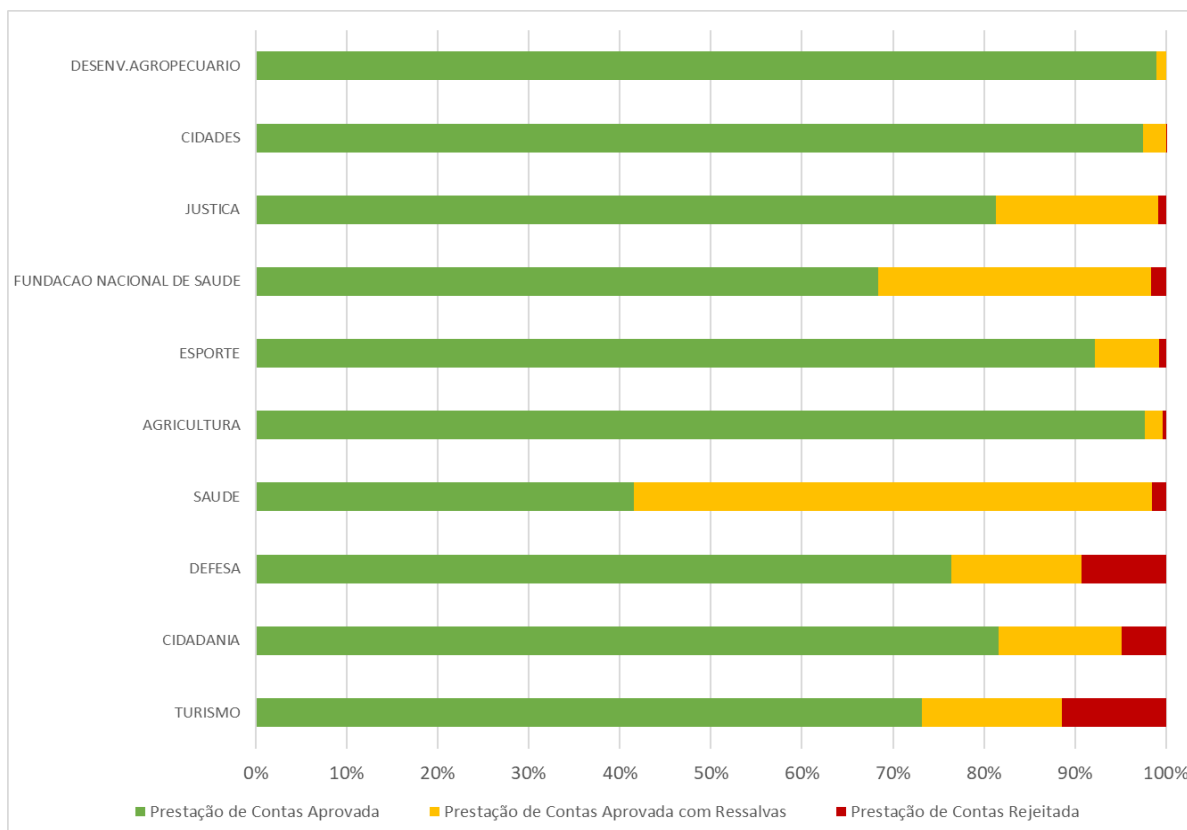


Figura 12 - Distribuição percentual do resultado da análise das prestações de contas dos convênios dos 10 órgãos mais representativos da população. Fonte: Plataforma +Brasil. Data base: novembro de 2019.

Logo, esta metodologia de pesquisa se valerá da métrica AUC, obtida pelo cômputo da área da curva ROC, além da proposição de uma nova métrica escalar derivada da acurácia (ALPAYDIN, 2020), a qual denominamos inexatidão (ϵ). O valor da inexatidão (ϵ) de um algoritmo treinado por uma amostra de convênios em um determinado intervalo é:

$$\epsilon_{ij} = \frac{FP_{ij}}{VP_{ij} + VN_{ij} + FN_{ij} + FP_{ij}}$$

No qual:

FP é Falso Positivo;

VP é Verdadeiro Positivo;

VN é Verdadeiro Negativo;

FN é Falso Negativo;

i: intervalos de score [0,0 a 0,1); [0,1 a 0,2); [0,2 a 0,3); [0,3 a 0,4); [0,4 a 0,5); [0,5 a 0,6); [0,6 a 0,7); [0,7 a 0,8); [0,8 a 0,9); e [0,9 a 1,0];

j: algoritmo treinado por uma determinada amostra de convênios, conforme a volumetria ou identidade do concedente;

Logo, a inexactidão (ε) de um algoritmo para uma faixa acumulada no intervalo de score é:

$$\varepsilon_j = \sum_0^i \frac{FP_{ij}}{VP_{ij} + VN_{ij} + FN_{ij} + FP_{ij}}$$

Adicionalmente, a métrica AUC para determinado algoritmo treinado por uma amostra de convênios é calculada pela integral da curva ROC, calculando a função da taxa de verdadeiros positivos em relação aos falsos positivos:

$$AUC_j = \int_0^1 \frac{VP_j}{VP_j + U - (VP_j + VN_j + FP_j)} dFP_j$$

No qual:

FP é Falso Positivo;

VP é Verdadeiro Positivo;

VN é Verdadeiro Negativo;

U é o Universo de Convênios, $U - (VP + VN + FP)$ é igual a FN;

j: algoritmo treinado por uma determinada amostra de convênios, conforme a volumetria ou identidade do concedente;

Encorajados por Cecchini et al. (2010), Fawcett (2006) e Grover, Bauhoff e Friedman (2019), a proposição da métrica inexactidão (ε) visa mensurar o real desempenho do algoritmo sobre as condições de testes impostas pelos constructos *Identidade do repassador de recurso* (H1 e H2) e *Tamanho de treinamento de dados* (H3 e H4) com foco na taxa de falsos positivos em relação ao total de convênios. Isso se deve porque a métrica especificidade reflete a proporção da categoria convênios aprovados, enquanto a métrica sensibilidade retrata a proporção da categoria convênios reprovados, ou seja, são métricas que abordam o desempenho isoladamente em subconjuntos do universo da população. Por seu turno, a métrica acurácia mede taxa de verdadeiros positivos e negativos conjuntamente sob as duas categorias de convênios aprovados e

reprovados, tornando-a inapropriada, já que se pretende analisar o desempenho sob a ótica de falsos positivos em relação ao total.

Diante do exposto, o desempenho dos algoritmos gerados mediante a parametrização da identidade dos órgãos concedentes e da volumetria da sequência de treinamento será avaliada pelas métricas AUC e inexatidão (ϵ). A métrica AUC refletirá a qualidade intrínseca do algoritmo gerado em relação a sua sequência de treinamento (LARCKER; ZAKOLYUKINA, 2012) e a métrica inexatidão (ϵ) repercutirá a precisão do algoritmo quando esse classifica convênios diferentes daqueles usados em seu treinamento (CECCHINI et al., 2010). Em todos os cenários desta pesquisa os dados de teste foram aqueles convênios com ciclo de vida encerrado na Plataforma +Brasil.

Por outro lado, cabe destacar que a tomada de decisão nesta pesquisa pelas métricas AUC e inexatidão (ϵ) para avaliar o desempenho dos algoritmos de *Machine Learning* se pautou em uma problemática recorrente do campo de pesquisa de Controle e Auditoria. Dentro da ciência social Administração (FAYOL, 1949; TAYLOR, 1911), as pesquisas com enfoque na precisão de algoritmos de IA empreendem esforços para esclarecer a eficácia da substituição da intervenção humana, notadamente um auditor, por um mecanismo computacional para emitir a opinião sobre uma operação de negócio das organizações. Essas operações incluem os relatórios de demonstrações contábeis, regularidade de processos ou comprovação de despesas. Nesse aspecto, Bao et al. (2020), Cecchini et al. (2010), Grover, Bauhoff e Friedman (2019), Fawcett (2006), Hooda, Bawa e Rana (2020), Larcker, Zakolyukina (2012), Stanistic, Radojevic e Stanic (2019) e Zhang(2019a) utilizam em suas pesquisas a métrica AUC e uma derivação da métrica inexatidão (ϵ) em detrimento de outras métricas utilizadas em pesquisas das ciências exatas como aquelas retratadas por Domingos (2012).

4.1. Relevância para o algoritmo de IA em distinguir a identidade dos repassadores de recursos

Evidentemente, cada órgão concedente possui seu próprio processo de análise de prestação de contas, com suas características e propriedades inerentes. Logo, ao universalizar o processo de aprendizagem de máquina indistintamente entre todos os repassadores de recursos, órgãos mais rigorosos na análise de prestação de contas podem sofrer uma atenuação indesejada na classificação de risco de seus convênios ao agregar órgãos menos rigorosos na análise.

O constructo “*Identidade do repassador de recurso*” da Tabela 7 foi concebido

com o intuito de dirimir a dúvida erigida sobre a precisão (ZHANG, 2019a; BAO et al., 2020) em circunstâncias diferentes quanto ao órgão concedente, uma vez que as métricas de desempenho do algoritmo foram estabelecidas uniformemente para todos os órgãos repassadores de recursos.

Nesses termos, o algoritmo de IA foi treinado separadamente para aqueles órgãos concedentes com a maior representatividade do universo dos convênios da Plataforma +Brasil cujo ciclo de vida encontra-se encerrado. Isso implica que a prestação de contas desses convênios foi analisada pelo órgão concedente, recebendo uma classificação como: a) prestação de contas aprovada; b) prestação de contas aprovada com ressalvas; ou c) prestação de contas rejeitada. O ANEXO II apresenta o universo dos convênios celebrados entre os anos de 2008 e 2017 com seu ciclo de vida encerrado, detalhados por quantidade e materialidade.

A população em estudo consiste em um quantitativo de 51.845 convênios que totalizam mais de R\$ 24 bilhões (R\$ 24.481.496.942,56). Na medida em que os convênios celebrados pelos órgãos concedentes da amostra da Tabela 9 espelham aproximadamente 90% do quantitativo e 80% de materialidade, a representatividade estatística dessa amostra em relação à população está satisfeita.

Órgão Concedente	Quantidade		Valor	
	#	% do Universo	R\$ Milhões	% do Universo
Ministério da Agricultura, Pecuária e Abastecimento	12828	24,74%	R\$ 4.103,58	16,76%
Ministério das Cidades	9306	17,95%	R\$ 3.632,21	14,84%
Ministério do Turismo	6838	13,19%	R\$ 2.997,27	12,24%
Ministério da Saúde	5642	10,88%	R\$ 2.616,30	10,69%
Ministério do Esporte	3883	7,49%	R\$ 1.307,82	5,34%
Ministério da Cidadania	2820	5,44%	R\$ 2.252,18	9,20%
Secretaria de Desenvolvimento Agropecuário e Cooperativismo	1816	3,50%	R\$ 466,27	1,90%
Ministério da Defesa	1447	2,79%	R\$ 849,52	3,47%
Fundação Nacional de Saúde	991	1,91%	R\$ 516,64	2,11%

Ministério da Justiça e Segurança Pública	861	1,66%	R\$ 967,54	3,95%
Total Amostra	46432	89,56%	R\$ 19.709,34	80,51%
Universo	51845	100%	R\$ 24.481,50	100%

Tabela 9 - Amostra utilizada para realizar os testes do construto “Identidade do repassador de recurso”.

Fonte: elaborado a partir do ANEXO II .

Dessa forma, o algoritmo foi treinado separadamente com 10 séries de dados diferentes, uma para cada órgão concedente. Conseqüentemente, o mesmo procedimento utilizado para gerar o algoritmo do “*Malha Fina de Convênios*” será retomado, porém, com uma diferença substancial. Esse novo procedimento tem por objetivo treinar o algoritmo de aprendizado de máquina, exclusivamente, conforme a identidade do repassador dos recursos, ou seja, serão gerados 10 algoritmos diferentes, cada um refletindo a maneira que os órgãos repassadores de recursos analisam as prestações de contas apresentadas. Assim, haverá um balizador que permitirá o cotejamento das métricas AUC e inexatidão (ϵ) (BAO et al., 2020; ZHANG, 2019a;) entre a(i) a aplicação do algoritmo gerado por todo o universo de convênios em cada um dos órgãos repassadores de recursos e (ii) a aplicação do algoritmo gerado por convênios de um determinado órgão repassador em seus próprios convênios.

Essa estratégia permitirá avaliar o comportamento do aprendizado de máquina separadamente por órgão concedente. Pretende-se detectar se sequências de treinamento diferenciadas pela identidade do órgão concedente, produziriam algoritmos com desempenhos distintos a ponto de inviabilizar a extrapolação de um único algoritmo gerado a partir do aprendizado do universo.

A Figura 13, abaixo, ilustra a estratégia para testar a hipótese do constructo “*Identidade do repassador de recurso*”. Dez algoritmos diferentes serão gerados conforme o órgão repassador de recursos para ser comparado com o algoritmo gerado por uma sequência de treinamento que contempla o universo de convênios registrados na Plataforma +Brasil.

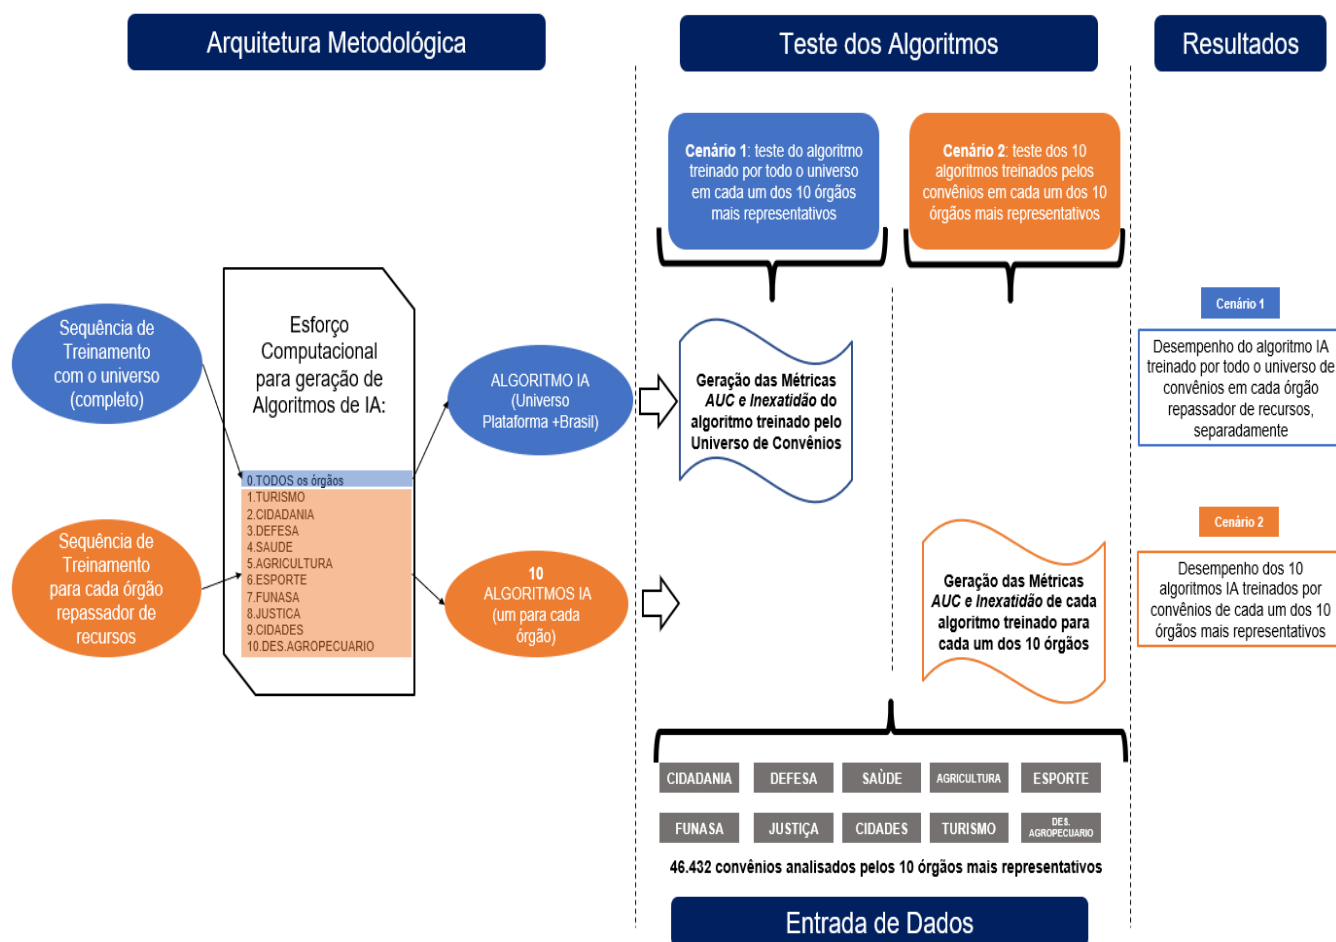


Figura 13 - Metodologia para verificar o impacto da identidade do repassador de recursos na precisão (métricas AUC e inexatidão) do algoritmo de inteligência artificial. Elaborado pelo autor.

Os resultados esperados eram a obtenção de dados que possibilitem a aferição da precisão dos algoritmos de IA por meio de duas métricas: inexatidão (ϵ) e AUC, conforme disciplinado em Bao et.al (2020), Breiman (2001), Fawcett (2006) e Zhang (2019a). Essas métricas foram utilizadas para aferir a precisão em duas configurações envolvendo a identidade dos órgãos concedentes. A primeira configuração, cenário 1, é aquela decorrente da aplicação do algoritmo gerado por todo o universo de convênios em cada um dos órgãos repassadores de recursos. A segunda, cenário 2, é aquela em que o algoritmo gerado por convênios de um determinado órgão repassador foi aplicado para classificar seus próprios convênios (Tabela 9).

4.2.Relevância do tamanho da série de treinamento para o algoritmo de IA

O constructo “*Tamanho de treinamento de dados*” (Tabela 7) foi estabelecido com o intuito de averiguar o impacto que a volumetria da série de treinamento possui na precisão do algoritmo de aprendizado de máquina. O cerne da intervenção proposta está

na verificação do comportamento da precisão de diferentes algoritmos, os quais foram gerados por sequências de treinamento incrementais, segmentadas por ano de celebração dos convênios. O comportamento dos resultados dos algoritmos será analisado à medida que mais convênios servem de insumo para o aprendizado de máquina (BREIMAN, 2001; ZHANG, 2019a).

No aprendizado supervisionado, os algoritmos precisam ser treinados primeiramente no conjunto de dados de treinamento e depois testados no conjunto de dados de teste. A regra geral na divisão entre conjunto de treinamento e teste é escolher cerca de 75% da amostra como dados de treinamento e o restante como dados de teste (ALPAYDIN, 2020; HOODA; BAWA; RANA, 2020; ZHANG, 2019a;). Todavia, isso não é uma regra consagrada, uma vez que a garantia de desempenho do aprendizado de máquina depende da disponibilidade de rotulação dos dados (SUN, 2019). Outra questão importante, conforme sublinha Cecchini et al. (2010), Grover, Bauhoff, Friedman (2019) e Zhang (2019a) é como garantir o desempenho do aprendizado de máquina, dada a disponibilidade e o balanceamento de dados que estão rotulados, no caso em epígrafe contas aprovadas ou rejeitadas. Nesse contexto, as potencialidades do uso do Malha Fina de Convênios, seus impactos já demonstrados e suas limitações ainda não são claros e definitivos. Logo, a motivação para a proposição do constructo “*Tamanho de treinamento de dados*” visa a compreensão desse cenário.

Em janeiro de 2020, a Plataforma +Brasil contava com 175.456 convênios cadastrados. Desses, 53.002 completaram seu ciclo de vida, ou seja, o órgão repassador de recursos avaliou a prestação de contas apresentada pelo conveniente definitivamente, aprovando-a, aprovando-a com ressalvas, ou rejeitando-a, conforme exibido na Tabela 10. A essência de avaliação desse construto está na verificação do comportamento da precisão do algoritmo do sistema “*Malha Fina de Convênios*” ao longo do tempo.

Ano	Qtd Acumulado Convênios	Prestação de Contas					
		Aprovada	Aprovada com Ressalvas	Rejeitada	Total	Acumulado	% Acumulado
2008	2746	797	165	182	1144	1144	2,16%
2009	26643	10515	1711	631	12857	14001	26,42%
2010	50186	9918	1495	462	11875	25876	48,82%
2011	63833	5855	1038	84	6977	32853	61,98%

2012	76465	4727	635	40	5402	38255	72,18%
2013	92712	6044	562	67	6673	44928	84,77%
2014	106225	3491	719	30	4240	49168	92,77%
2015	116386	1541	313	19	1873	51041	96,30%
2016	131413	1535	133	9	1677	52718	99,46%
2017	151931	200	22	1	223	52941	99,88%
2018	170683	55	6		61	53002	100,00%
2019	175418	0	0	0	0	53002	100,00%
Total	175418	44678	6799	1525	53002	53002	100,00%

Tabela 10 - Amostra utilizada para realizar os testes do construto “*Tamanho de treinamento de dados*”.
Data base janeiro de 2020. Fonte: Plataforma +Brasil.

Dessa forma, o algoritmo foi treinado com diferentes segmentos de dados conforme o ano de celebração do convênio, admitindo-se, dessa forma, 9 séries de dados diferentes entre os anos 2008 a 2016. Essas séries serão analisadas especificamente quanto ao comportamento da precisão do algoritmo.

Adicionalmente, é importante delimitar que a sequência de treinamento do algoritmo deve corresponder apenas aos convênios cujo seu ciclo de vida foi encerrado, ou seja, perpassou pelas fases da celebração, execução e prestação de contas. Conseqüentemente, isso exige uma fonte fidedigna e estável da base de dados da Plataforma +Brasil, que reflita uma perenidade das situações dos convênios. Na medida em que o processo das transferências voluntárias da união é inerentemente volátil (BROLLO; NANNICINI, 2012; MEIRELES, 2019), alterações nas situações dos convênios podem ocorrer, principalmente, naqueles celebrados recentemente. Por conseguinte, adotou-se o ano de 2017 como ponto de corte da população de convênios a serem usados como sequência de treinamento.

Entretanto, mediante a observação da Tabela 10, percebe-se que após 2017 apenas 284 convênios tiveram seus ciclos de vida estão encerrados. Por sua vez, esse baixo quantitativo não possui significância para a sequência de treinamento. Esse fato acarretou a delimitação do escopo em 9 séries entres os anos de 2008 e 2016, excluindo a série de 2017.

A Figura 14 ilustra o processo realizado para determinar diferentes algoritmos de inteligência artificial com o incremento gradual das sequências de treinamento. As 9

séries utilizadas como sequência de treinamento produziram 9 algoritmos distintos entre si, capazes de classificar qualquer convênio da Plataforma +Brasil quanto à probabilidade de as contas serem aprovadas ou rejeitadas. Por seu turno, os 9 algoritmos gerados foram testados mediante a análise das métricas AUC e inexatidão (ϵ) (BAO et al., 2020; FAWCETT, 2006; ZHANG, 2019a).

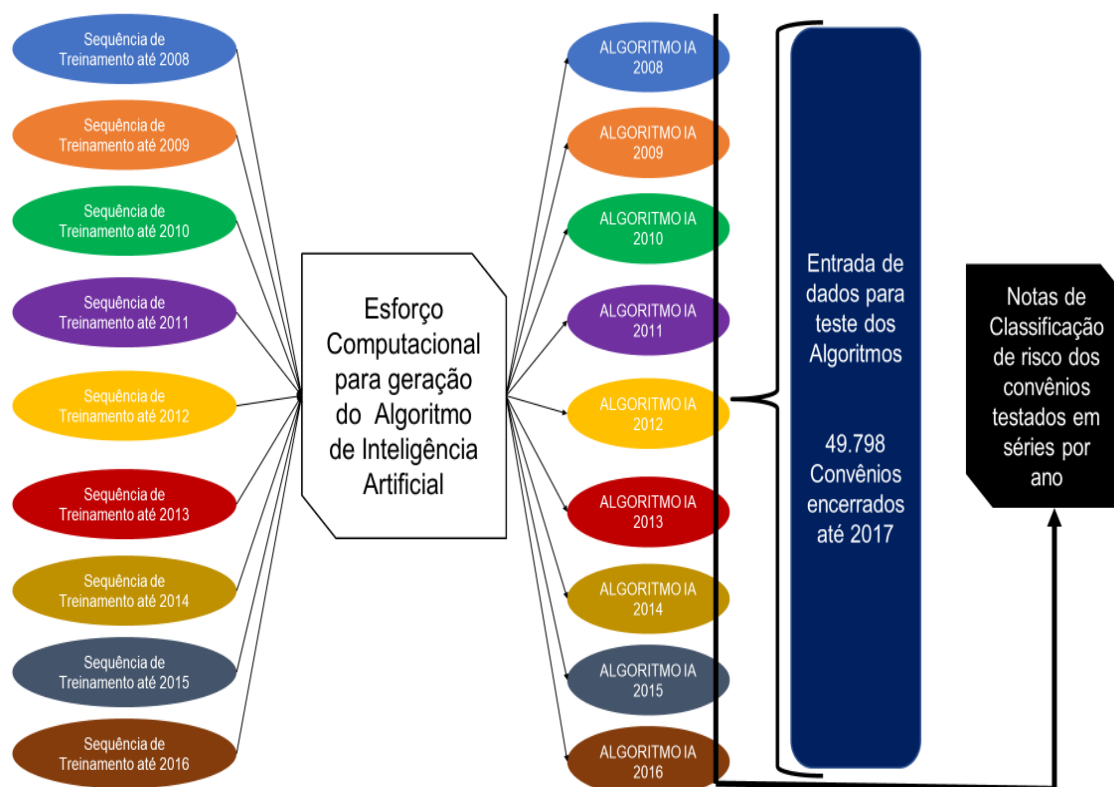


Figura 14 – Metodologia para teste para verificar o impacto da volumetria sequência de treinamento na precisão (métricas AUC e inexatidão) do algoritmo de inteligência artificial. Elaborado pelo autor.

Por fim, o teste dos algoritmos só poderia ser executado com os convênios cujo ciclo de vida se encerrou, analogamente à população usada para a sequência de treinamento. Ora, a forma mais assertiva de testar a precisão de algoritmos de aprendizado de máquina é a comparação com o resultado real do convênio. Da mesma forma, o algoritmo aprende com os convênios encerrados, ou seja, com as variáveis que os levaram a ter suas contas rejeitadas ou encerradas. Assim, o teste dos 9 algoritmos consistiu em classificar a completude dos convênios da Tabela 10.

5. ANÁLISE DOS RESULTADOS

A seguir são apresentados os resultados obtidos e a sua análise. Os resultados consistem nas métricas *AUC* e *inexatidão* (ϵ) geradas nos diferentes cenários de aprendizado de máquina, os quais foram concebidos por meio da parametrização da identidade do repassador de recursos e da volumetria da sequência de treinamento.

5.1.1. Métricas *AUC* e *inexatidão* (ϵ) conforme a identidade do órgão concedente

A avaliação do desempenho da precisão dos algoritmos treinados conforme a identidade do órgão concedente sob a perspectiva da métrica *AUC* permite concluir que alguns possuem desempenho melhor do que o algoritmo treinado com a população completa dos convênios. Entretanto, a avaliação sob a perspectiva da métrica *inexatidão* (ϵ) aponta que nenhum algoritmo possui desempenho melhor do que aquele treinado pelo universo. Na medida em que a superação de desempenho sob o ponto de vista da métrica *AUC* ocorre em apenas 4 algoritmos, de maneira residual, e sob o ônus de resultar em 6 algoritmos com desempenho inferior, sendo 2 desses muito insatisfatórios, a *H1* do constructo *Identidade do repassador de recurso* não é confirmada sob certas circunstâncias, as quais não ensejam a adoção da estratégia de treinar algoritmos separadamente conforme o órgão repassador de recursos. Por seu turno, a *H2* é confirmada porque o desempenho é diferente conforme a identidade do órgão concedente.

5.1.1.1. Cenário 1: algoritmo de IA treinado com o universo e aplicado em cada órgão concedente separadamente

O desempenho do algoritmo treinado a partir do universo é satisfatório sob o ponto de vista da métrica *AUC*, uma vez que assume o valor 0,96, conforme demonstrado na Figura 15. Essa inferência é corroborada por Fawcett (2006) e Zhang (2019a), porque esses afirmam que quanto mais a *AUC* se aproxima de 1, melhor é o desempenho de um algoritmo classificador. Entretanto, a análise da métrica *inexatidão* (ϵ) indica que o algoritmo possui desempenho diferente ao longo do intervalo [0 a 1], na medida em que ocorre aumento de probabilidade de falsos positivos nos órgãos cujo histórico de reprovação de contas de convênios é maior que a média⁸, conforme demonstrado na Tabela 11. Por outro lado, ocorre o inverso nos órgãos com histórico de reprovação de

⁸ A média de rejeição de prestação de contas da amostra dos 10 órgãos da Tabela 9 (Ministério do Turismo, Ministério da Cidadania, Ministério da Defesa, Ministério da Saúde, Ministério da Agricultura, Ministério do Esporte, Funasa, Ministério da Justiça, Ministério das Cidades, Desenvolvimento Agropecuário) é 137,111.

contas abaixo da média, pois há diminuição de falsos positivos. Não obstante, a métrica inexatidão (ϵ) apresenta discrepância apenas a partir do intervalo (0,8 a 1].

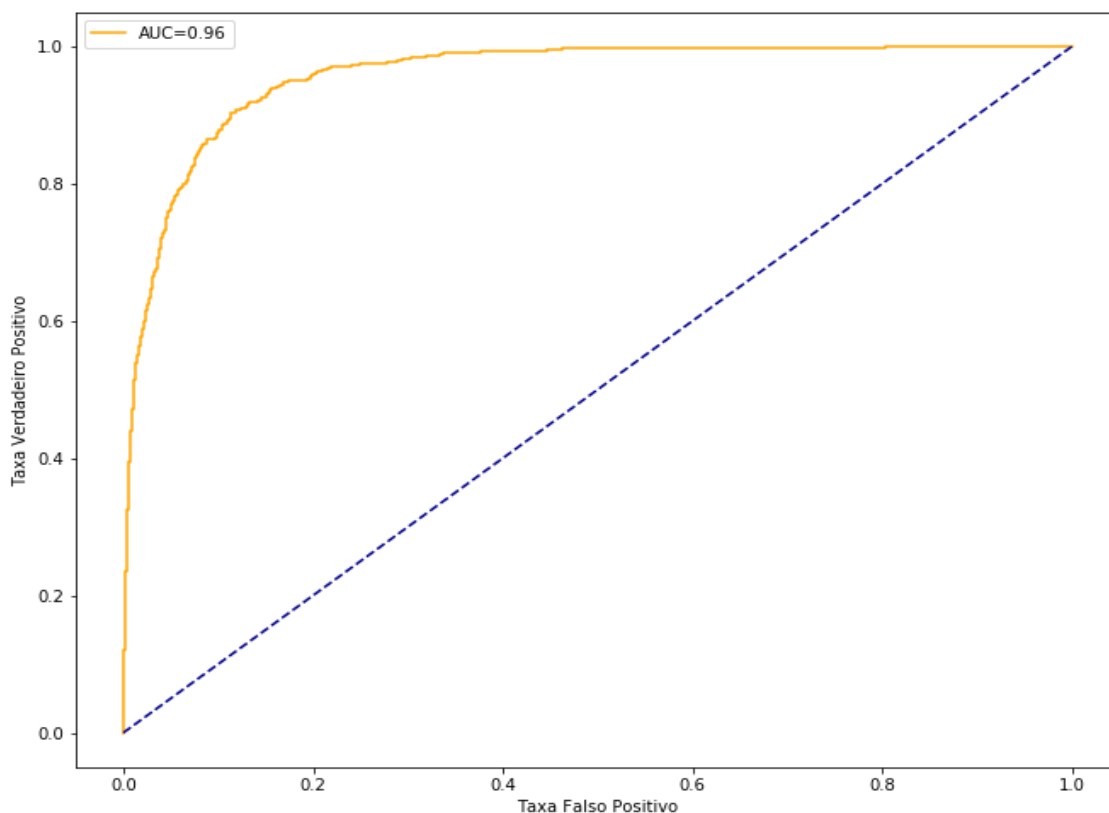


Figura 15 - Curva ROC e métrica AUC do algoritmo de IA treinado com o universo.

A constatação de que a métrica inexatidão (ϵ) apresenta valores deficientes apenas a partir do intervalo (0,8 a 1] é inferida por meio da análise das curvas da Figura 16, gerada a partir da Tabela 11. Observa-se que a inexatidão (ϵ) apresenta valores muito bons entre o intervalo [0 a 0,8). Porém, a discrepância da inexatidão (ϵ) observada a partir do score 0,8 decorre da superestimação e da subestimação de falsos positivos em diferentes identidades dos órgãos concedentes. As curvas “DEFESA”, “TURISMO” e “CIDADANIA”, associadas aos convênios celebrados pelos Ministérios da Defesa, Turismo e Cidadania, respectivamente, estão notadamente superiores à curva “Todos os Órgãos” a partir do intervalo (0,8 a 1]. Infere-se, portanto, que o comportamento discrepante das curvas da métrica imprecisão, quando o algoritmo é aplicado nesses 3 órgãos, decorre da maior rejeição de contas de convênios promovidas por esses órgãos em relação à média, fazendo com que a sequência de treinamento seja menos desbalanceada. Essa conclusão vai ao encontro do que preconiza Alpaydin (2020) e os achados das pesquisas de Bao et al. (2020) e Cecchini et al. (2010).

Órgão Concedente	Prestação de Contas Rejeitadas	Intervalo Acumulado de Score						
		[0,0 a 0,4)	[0,0 a 0,5)	[0,0 a 0,6)	[0,0 a 0,7)	[0,0 a 0,8)	[0,0 a 0,9)	[0,0 a 1,0]
Todos os Órgãos	1490	0,00000%	0,00195%	0,02140%	0,03890%	0,10310%	0,27428%	2,89838%
Ministério do Turismo	779	0,00000%	0,01471%	0,04414%	0,07357%	0,17657%	0,44144%	11,46263%
Ministério da Cidadania	137	0,00000%	0,00000%	0,03587%	0,03587%	0,17934%	0,86083%	4,91392%
Ministério da Defesa	134	0,00000%	0,00000%	0,00000%	0,00000%	0,00000%	0,27701%	9,27978%
Ministério da Saúde	84	0,00000%	0,00000%	0,01809%	0,03619%	0,05428%	0,21712%	1,51981%
Ministério da Agricultura	46	0,00000%	0,00000%	0,00000%	0,01569%	0,04707%	0,07844%	0,36084%
Ministério do Esporte	29	0,00000%	0,00000%	0,00000%	0,02594%	0,05188%	0,15564%	0,75227%
Funasa	16	0,00000%	0,00000%	0,20202%	0,20202%	0,20202%	0,30303%	1,61616%
Ministério da Justiça	7	0,00000%	0,00000%	0,11820%	0,11820%	0,11820%	0,23641%	0,82742%
Ministério das Cidades	2	0,00000%	0,00000%	0,01081%	0,01081%	0,01081%	0,01081%	0,02163%
Desenvolvimento Agropecuário	0	0,00000%	0,00000%	0,00000%	0,00000%	0,00000%	0,00000%	0,00000%

Tabela 11 – Métrica Inexatidão (ϵ) do Algoritmo de IA treinado a partir do universo (Probabilidade de Falso Positivo).

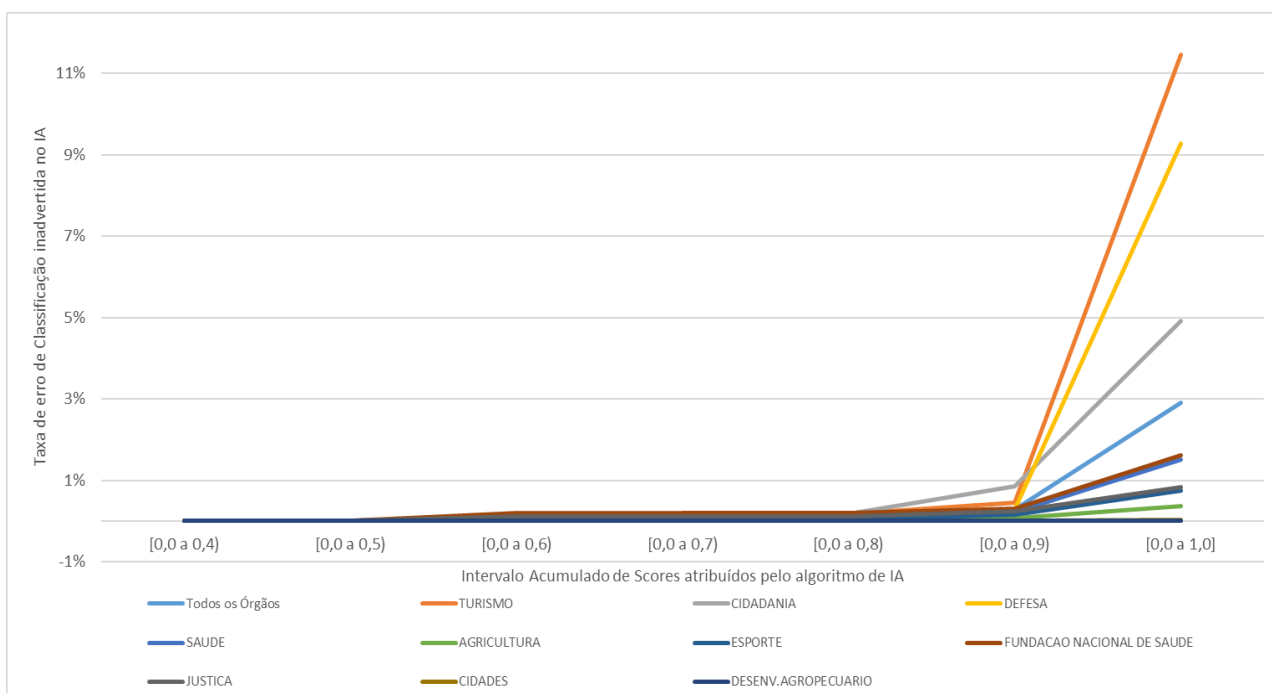


Figura 16 – Métrica Inexatidão (ϵ) do Algoritmo de IA treinado a partir do universo (Probabilidade de Falso Positivo).

Resumidamente, a análise dos resultados empíricos da métrica inexatidão (ϵ) permite concluir que o algoritmo treinado a partir da população completa da Plataforma +Brasil, quando aplicado separadamente em cada órgão concedente, apresenta desempenho inferior para os Ministérios da Defesa, Turismo e Cidadania a partir do score 0,8, com acentuação da degradação do desempenho a partir do score 0,9. Adicionalmente, os resultados indicam que o desempenho do algoritmo nos convênios do Ministério da Cidadania apresenta um início de degradação moderado a partir do score 0,8. Essa observação implica que a probabilidade de ocorrência de falsos positivos nesse Ministério possui um espectro mais abrangente do que os Ministérios da Defesa e Turismo.

A Figura 17, a seguir, evidencia a ocorrência de duas vertentes da métrica inexatidão (ϵ): a subestimação ou a superestimação de falsos positivos em cada intervalo de score, conforme a identidade do órgão conveniente, demonstrado pela convergência. A convergência, conforme proposto por Fawcett (2006), é o desvio da métrica acurácia. Entretanto, a estratégia metodológica sugerida nesta pesquisa, utiliza a métrica inexatidão (ϵ), derivada da acurácia. Então, a convergência é calculada por meio da diferença da inexatidão (ϵ) entre: (a) uso do algoritmo treinado a partir do universo para classificar todo o estoque de convênios pendentes de análise; e (b) uso do algoritmo treinado a partir do universo para classificar convênios separadamente por órgão concedente. Assim é

possível realizar uma comparação em que o balizador é a identidade do órgão repassador de recursos. O cálculo da convergência (φ) é:

$$\varphi_{ik} = \sum_0^{k=10} \varepsilon_{ik} - \varepsilon_{ik}$$

No qual:

FP é Falso Positivo;

i: intervalos de score [0,0 a 0,1); [0,1 a 0,2); [0,2 a 0,3); [0,3 a 0,4); [0,4 a 0,5); [0,5 a 0,6); [0,6 a 0,7); [0,7 a 0,8); [0,8 a 0,9); e [0,9 a 1,0];

k: amostra da Tabela 9 com os 10 algoritmos treinados conforme a identidade do órgão concedente;

Comprova-se, nitidamente, por meio da análise da Figura 17, ilustrada abaixo, que não há degradação da desempenho do algoritmo treinado pela população de todos os convênios da Plataforma +Brasil até o intervalo [0 a 0,8) . Em que pese o algoritmo de IA ser aplicado com ou sem a identidade do órgão conveniente, o desempenho satisfatório até o intervalo [0 a 0,8) continua sendo corroborado, ou seja, o grau de assertividade (métrica inexatidão ε) é alto dentro desse intervalo. Ocorre uma breve discrepância a partir do score 0,8, mas dentro de limites seguros que não ultrapassam -1% para subestimativa e 1% para superestimativa.

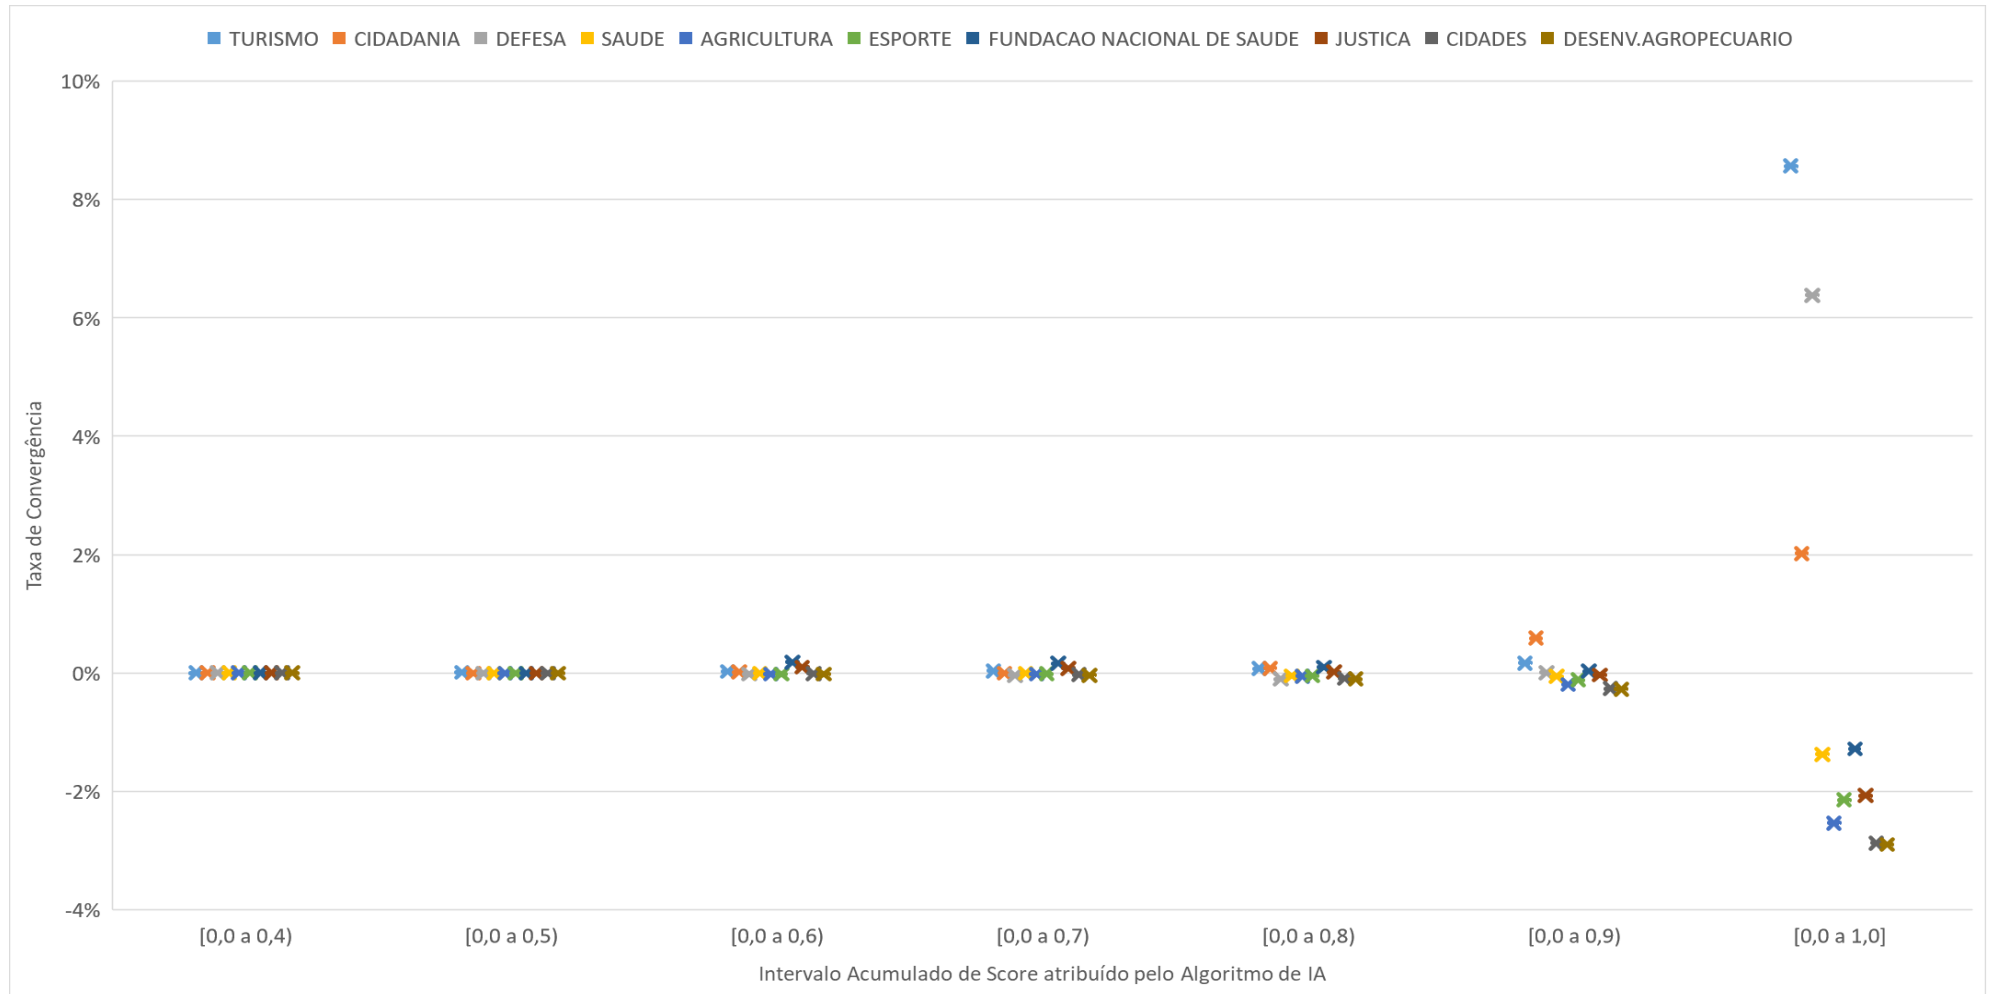


Figura 17 – Convergência (φ) entre algoritmos treinados conforme o órgão concedente e a partir da população completa.

Ademais, existe uma discrepância a partir do score 0,9, implicando em duas perspectivas. A primeira delas é que a inexatidão (ϵ) de 7 órgãos está subestimada em torno de -2%, significando um desvio moderado que não gera consequências adversas, na medida em que acarretará uma imposição de conservadorismo a esses órgãos na análise das contas de seus convênios. Ora, a subestimação de risco consiste na indicação pelo algoritmo de IA de mais falsos positivos, ou seja, mais convênios seriam reprovados do que realmente são. Contudo, a superestimação de erro gera consequências adversas, haja vista que ocorre a classificação de convênios reprováveis como possivelmente aprovados pelo algoritmo. Essa subestimação ocorre para os Ministérios da Defesa, Turismo e Cidadania, atingindo taxas de divergência aproximadas de 6%, 8% e 2%, respectivamente.

5.1.1.2. Cenário 2: algoritmo de IA treinado com convênios conforme a identidade do órgão concedente

Os desempenhos dos algoritmos treinados a partir dos convênios de cada órgão concedente apresentam comportamentos distintos sob a perspectiva da métrica AUC, alguns apresentando desempenho muito satisfatório, enquanto outros bastante insatisfatórios. Considerando o algoritmo treinado a partir do universo como *benchmarking*, cujo AUC é 0,96, os algoritmos treinados por convênios dos Ministérios do Turismo, Agricultura, Esporte e Cidades, cujas métricas AUC assumiram 0,97, 0,97, 0,99 e 0,98, respectivamente (Figura 18), obtiveram desempenho muito satisfatório. A superioridade de desempenho do algoritmo treinado pelos convênios do Ministério do Turismo se deve pela melhor qualidade no balanceamento da sequência de treinamento entre todos os Ministérios, corroborando com os achados das pesquisas conduzidas por Bao et. al (2020) e Zhang (2019a). Por seu turno, o desempenho superior dos algoritmos treinados pelos convênios dos Ministérios da Agricultura e Cidades se justificam pela volumetria da sequência de treinamento, na medida em que são os dois órgãos concedentes com maior quantidade de prestação de contas analisadas, 24,74% e 17,95% respectivamente, indo ao encontro do que afirmam Cecchini et al. (2010) e Larcker e Zakolyukina (2012). Por outro lado, o desempenho quase ideal do algoritmo do Ministério do Esporte, com AUC assumindo o valor 0,99, não possui embasamento na volumetria ou no equilíbrio da sequência de treinamento, já que esse Ministério é apenas o quinto em volumetria, com 7,49% do total, e a quantidade de prestação de contas rejeitada, 29, é bem abaixo da média de 137. Essa singularidade é explicada por Alpaydin

(2020), Breiman (2001) e Domingos (2012) quando alguma característica da sequência de treinamento permite a identificação inequívoca das instâncias a serem classificadas, fazendo com que os falsos positivos e falsos negativos sejam reduzidos a quase zero.

Ademais, a Figura 18 ilustra o desempenho dos algoritmos treinados pelos convênios dos Ministérios da Cidadania, Defesa e Saúde, cujas métricas AUC assumiram respectivamente 0,91, 0,91 e 0,92. Conforme sublinha Fawcett (2006), seu desempenho é satisfatório em virtude de a AUC ser maior que 0,9, mas os dados empíricos obtidos nesta pesquisa demonstram que seu desempenho não superou aquele obtido no algoritmo treinado pelo universo ($AUC=0,96$). Em contrapartida, os algoritmos da Funasa e do Ministério da Justiça obtiveram desempenho muito insatisfatório, pois sua AUC foram 0,63 e 0,77, respectivamente. Esses resultados endossam as conclusões de Bao et al. (2020) e Zhang (2019a), na medida em que a volumetria dos convênios desses dois órgãos são as duas menores entre todos os órgãos (1,91%, Funasa, 1,66%, Ministério da Justiça) e o balanceamento é muito desequilibrado (16 reprovações para a Funasa e 7 para o Ministério da Justiça). Por sua vez, não houve possibilidade de produzir um algoritmo para a Secretaria de Desenvolvimento Agrário na medida em que esse órgão nunca reprovou uma prestação de contas. Consequentemente, não há métricas para a mensuração de desempenho para esse órgão.

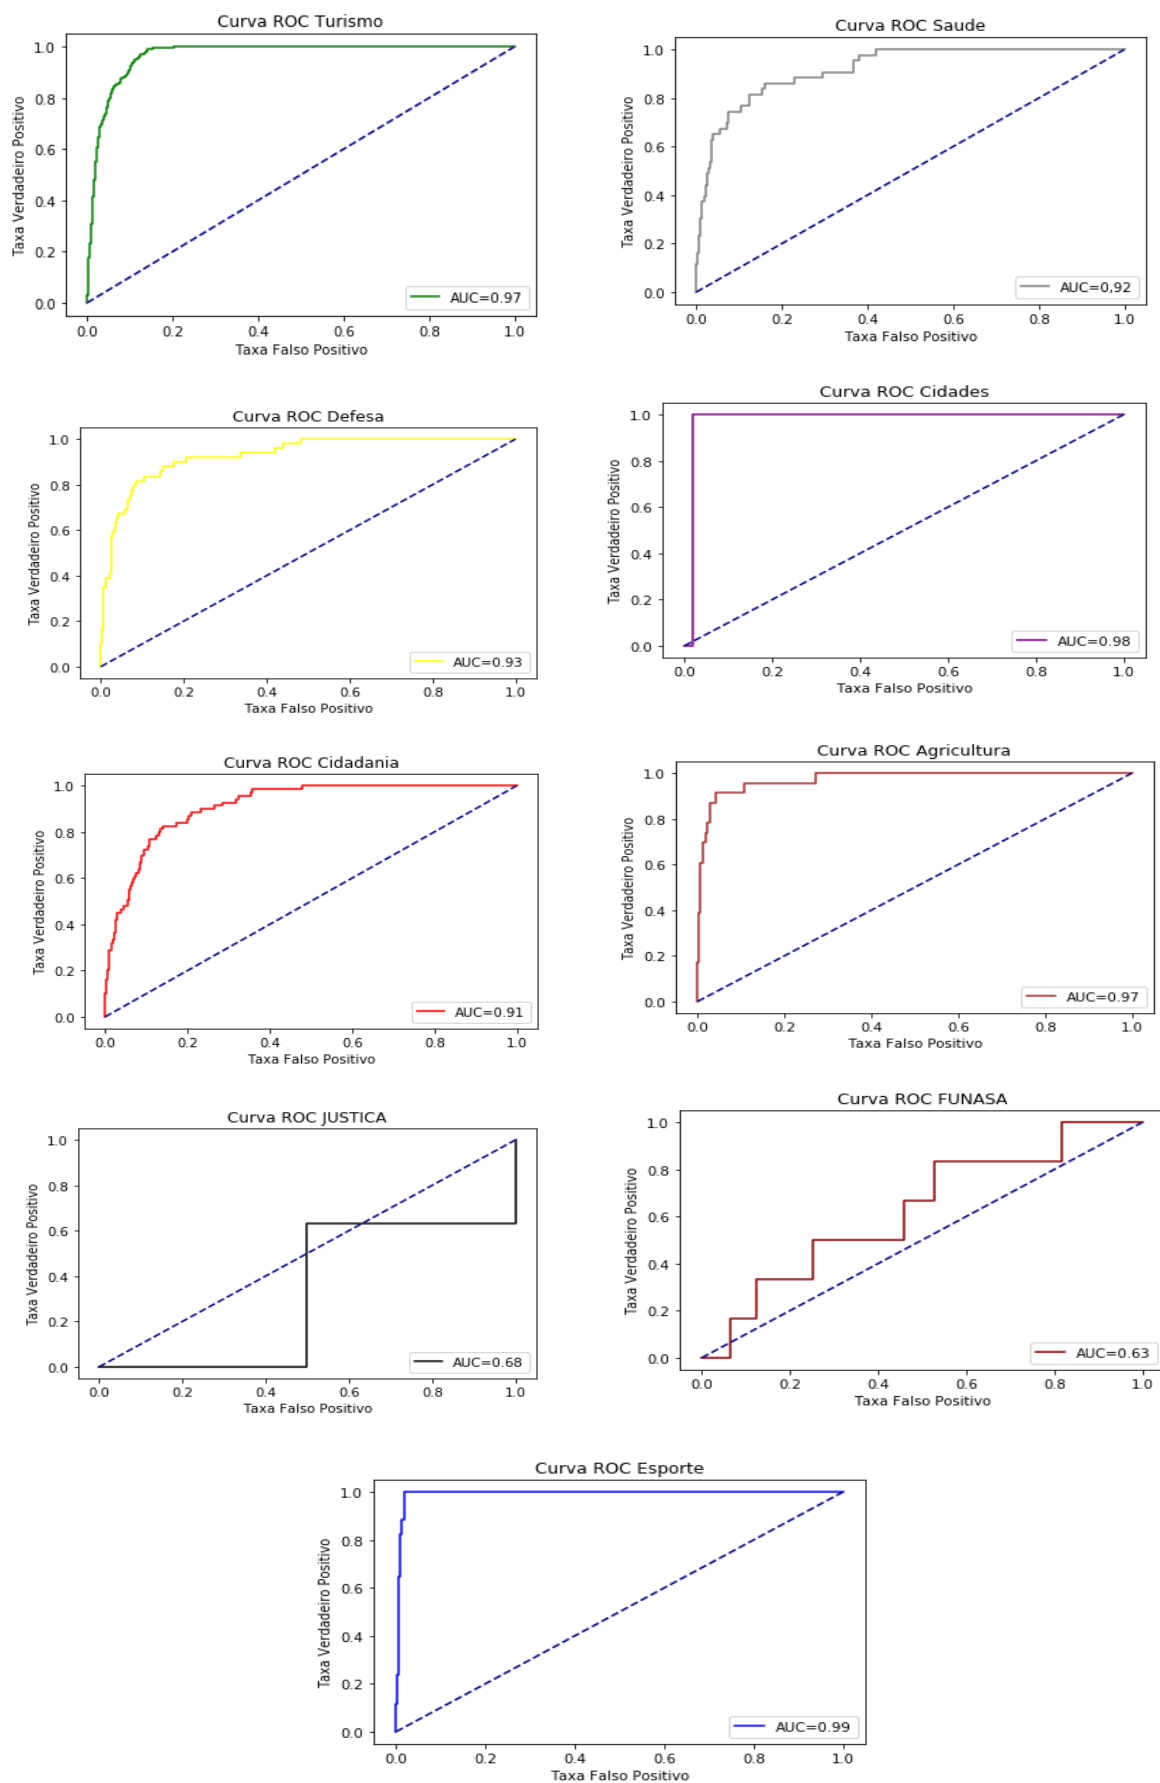


Figura 18 – Métrica AUC. Curva ROC dos algoritmos treinados conforme a identidade do órgão concedente.

A Tabela 12 permite inferir que, sob a perspectiva da métrica inexatidão (ϵ), os algoritmos de IA treinados a partir dos convênios de cada órgão concedente separadamente possuem desempenho muito inferior ao algoritmo treinado com a população completa de convênios.

Sequência de treinamento	Intervalo Acumulado de Score						
	[0,0 a 0,4)	[0,0 a 0,5)	[0,0 a 0,6)	[0,0 a 0,7)	[0,0 a 0,8)	[0,0 a 0,9)	[0,0 a 1,0]
Todos os Órgãos	0,000%	0,067%	0,738%	1,342%	3,557%	9,463%	100,000%
Ministério do Turismo	5,570%	12,953%	19,329%	27,181%	38,054%	46,107%	100,000%
Ministério da Cidadania	37,785%	49,060%	59,463%	70,537%	82,013%	91,477%	100,000%
Ministério da Defesa	85,772%	89,933%	91,477%	92,349%	92,819%	93,826%	100,000%
Ministério da Saúde	90,470%	94,362%	95,302%	95,570%	95,705%	95,839%	100,000%
Ministério da Agricultura	17,114%	34,698%	53,020%	73,826%	90,537%	97,315%	100,000%
Ministério do Esporte	14,094%	24,430%	50,134%	74,832%	92,349%	98,054%	100,000%
Funasa	99,262%	99,329%	99,329%	99,329%	99,329%	99,329%	100,000%
Ministério da Justiça	99,530%	99,597%	99,597%	99,664%	99,664%	99,664%	100,000%
Ministério das Cidades	99,933%	99,933%	99,933%	99,933%	99,933%	99,933%	100,000%
Desenvolvimento Agropecuário	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Tabela 12 – Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios de cada órgão concedente. (Probabilidade de Falso Positivo).

Essa constatação é evidenciada por meio da Figura 19, a seguir. A análise a ser feita reside na comparação da métrica inexatidão (ϵ) entre o (a) algoritmo treinado a partir da população completa, curva “Todos os órgãos”, e (b) os algoritmos treinados a partir dos convênios de cada órgão concedente. A Figura 19 ilustra o comportamento da métrica inexatidão (ϵ) entre os 11 algoritmos treinados, oportunidade em que é possível observar

a quantidade de convênios categorizados em cada intervalo acumulado de score entre [0 a 1]. Assim, o algoritmo que consegue concentrar uma quantidade maior de convênios em intervalos acumulados mais próximos de 1 possuem desempenho melhor. Infere-se, portanto, que o algoritmo representado pela curva “Todos os órgãos” é o que possui a melhor métrica inexatidão (ϵ).

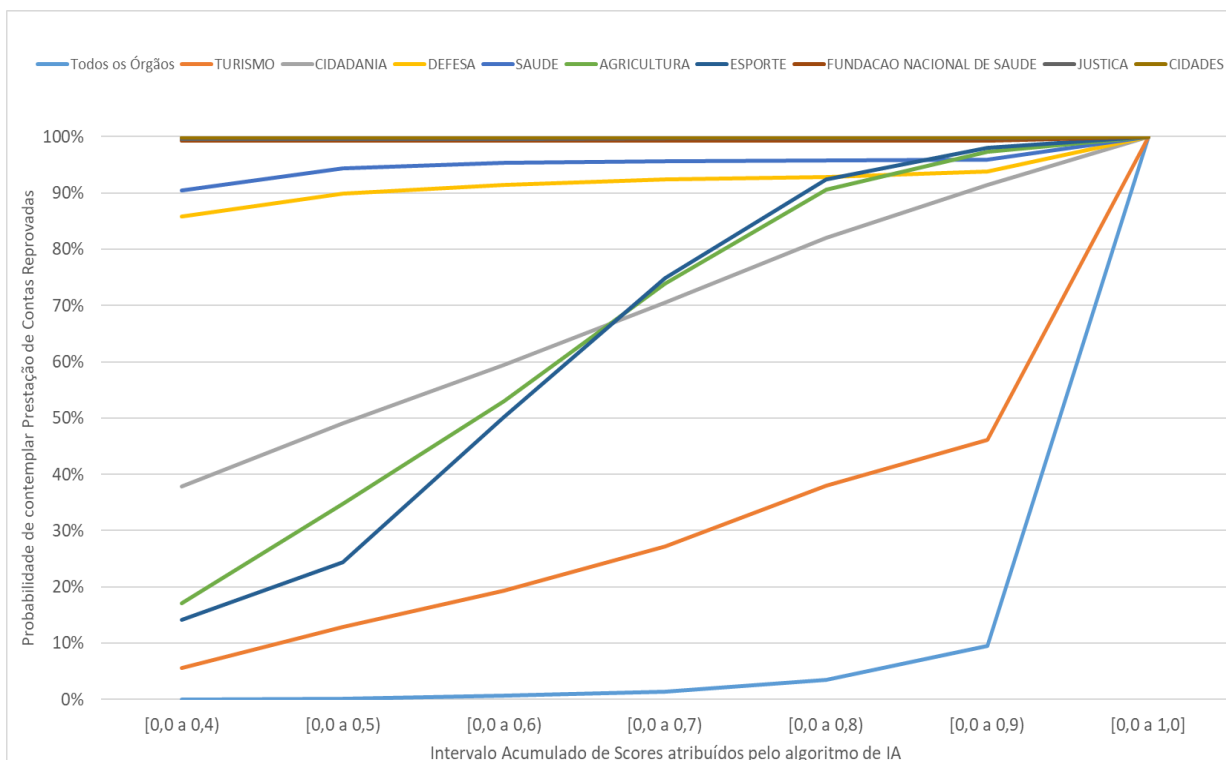


Figura 19 – Curvas da Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios de cada órgão concedente.

Adicionalmente, observa-se, sob o ponto de vista da métrica inexatidão (ϵ), que o algoritmo treinado pelos convênios do Ministério do Turismo, curva “Turismo”, possui desempenho melhor que os demais algoritmos, entretanto sem superar aquele treinado com a população completa. Isso se deve ao fato de o Ministério do Turismo ter o maior histórico de reprovação de contas de convênios entre todos os órgãos, 779 convênios reprovados entre 2008 e 2017, fazendo com que a sequência de treinamento seja a menos desequilibrada (BAO et al., 2020; ZHANG, 2019a). Os algoritmos estampados nas curvas “Cidades” e “Desenvolvimento Agrário” endossam esse argumento. As sequências de treinamento desses algoritmos possuem, respectivamente, 2 e 0 convênios com prestação de contas rejeitadas, proporcionando sequências de treinamento com intenso desequilíbrio e desempenho ruim.

Não obstante, destaca-se que uma sequência de treinamento equilibrada é condição necessária, mas não suficiente para prover bom desempenho. Observa-se que o

desempenho da curva "Turismo" sobressai em virtude do desequilíbrio moderado da sequência de treinamento aliado a sua alta volumetria, uma vez que a quantidade relativa de convênios com prestação de contas concluída no Ministério do Turismo é de 13,19% do total (Tabela 9), fazendo com que seja a terceira maior. Isso reforça as alegações de Alpaydin (2020), Breiman (2001) e Domingos (2012) que sequências de treinamento maiores proporcionam melhores desempenho.

A ambiguidade entre volumetria e balanceamento da sequência de treinamento é retratada nas curvas "Agricultura", "Esporte" e "Cidadania". Conquanto o Ministério da Agricultura tenha a maior quantidade de convênios celebrados entre todos os órgãos (24,74% do total), isso não foi suficiente para gerar um algoritmo com bom desempenho. O Ministério da Agricultura carece de equilíbrio em sua sequência de treinamento, uma vez que possui apenas 46 convênios com prestações de contas rejeitadas. A mesma situação ocorre com o Ministério do Esporte, que possui uma grande volumetria relativa (7,49 % do total) da sequência de treinamento, mas também um severo desbalanceamento pois reprovou apenas 29 convênios.

Por outro lado, observa-se algumas situações em que os algoritmos possuem baixo desempenho, embora tenham sido gerados com sequências de treinamento relativamente balanceadas. Nessas situações, o baixo desempenho da métrica inexatidão (ϵ) é provocado pela baixa volumetria da sequência de treinamento. O algoritmo representado pela curva "Defesa" foi gerado com uma sequência de 134 convênios reprovados, proporcionado um balanceamento relativamente alto, mas a volumetria representa apenas 2,79% do total.

Outrossim, há aqueles algoritmos com desempenho bastante degradado porque suas sequências de treinamento congregam nuances de baixa volumetria e alto desequilíbrio. Os algoritmos representados pelas curvas "Funasa", "Saude", "Justica" inserem-se nesse contexto. Por sua vez, não houve possibilidade de produzir um algoritmo para a Secretaria de Desenvolvimento Agrário na medida em que esse órgão nunca reprovou uma prestação de contas.

5.1.2. Métricas *AUC* e *inexatidão* (ϵ) conforme a volumetria da sequência de treinamento.

A avaliação do desempenho da precisão dos algoritmos treinados mediante o incremento gradual da sequência de treinamento, sob a perspectiva da métrica *AUC*, permite concluir que o desempenho melhora à medida que aumenta a volumetria de dados para treinamento. Todavia, a melhoria atinge um patamar em que qualquer incremento no

tamanho da sequência de treinamento não implica em melhoria de desempenho. Da mesma forma, a avaliação, sob o ponto de vista da métrica inexatidão (ϵ), permite inferir as mesmas conclusões obtidas sob o prisma da métrica AUC: quanto mais volumetria, melhor o desempenho, e existe um limite em que o incremento na volumetria não produz melhoria no desempenho. Logo, a *H3* do constructo *Tamanho de treinamento de dados* é confirmada, assim o a *H4*, que versa acerca do ponto de saturação, não obstante a saturação na métrica AUC (ano de 2012) ter sido ligeiramente diferente da métrica inexatidão (ϵ) (ano de 2014).

Sob a perspectiva da métrica AUC, conforme ilustrado na Figura 20, os desempenhos dos algoritmos treinados a partir do incremento gradual do tamanho da sequência de treinamento apresentam comportamento de melhoria contínua até atingirem o mesmo patamar de desempenho do algoritmo treinado pelo universo, esse último convencionado como *benchmarking*, cujo AUC assumiu o valor de 0,96. Esse patamar limítrofe foi obtido com o algoritmo treinado com os convênios celebrados até o ano de 2012, na medida em que a AUC dessa instância assumiu o valor 0,96. A partir do algoritmo de 2012, todos os subsequentes obtiveram o mesmo desempenho, ou seja, ocorreu um ponto de saturação quando a sequência de treinamento atingiu aproximadamente 72% do tamanho da população (Tabela 10). Esse achado vai ao encontro do que alegam Alpaydin (2020) e Zhang(2019a) sobre o tamanho ideal de 75% do total da população a ser utilizada como amostra para treinamento do algoritmo.

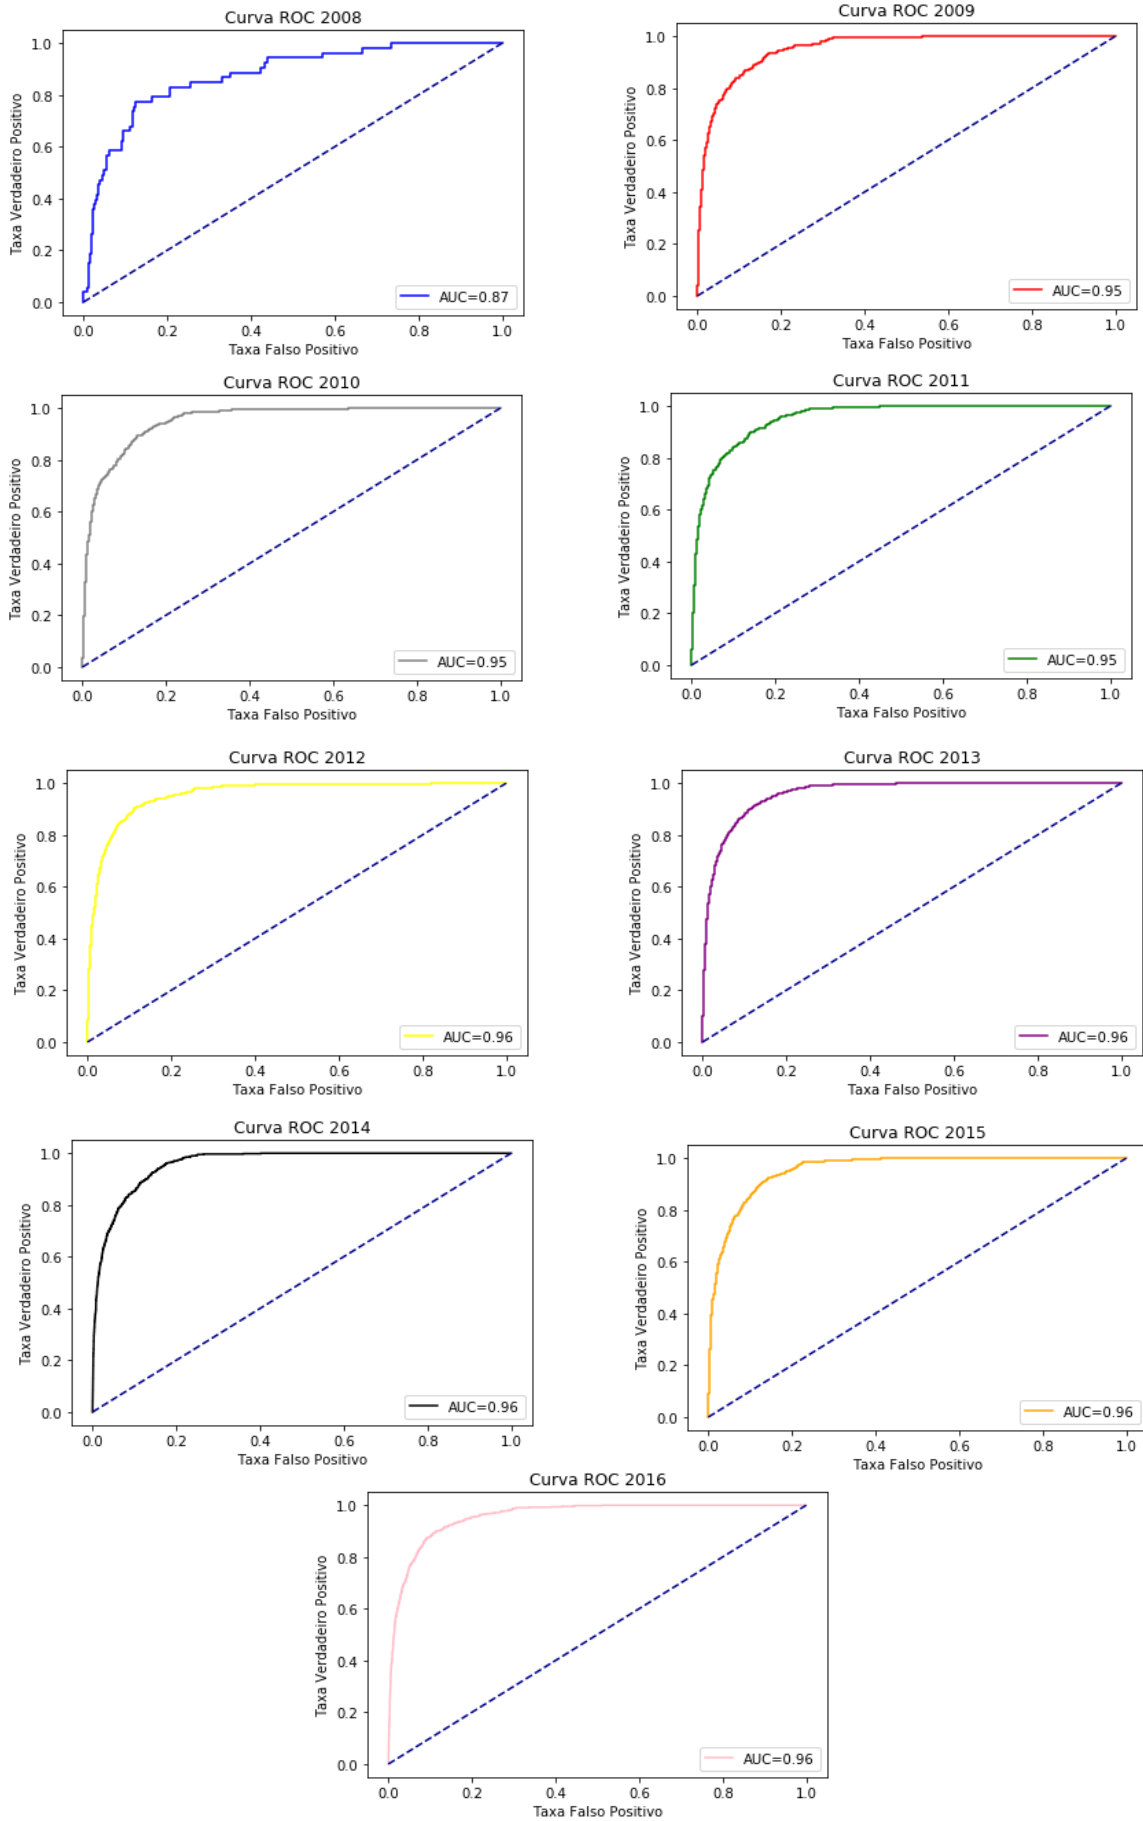


Figura 20 – Métrica AUC. Curva ROC dos algoritmos treinados a partir do incremento da volumetria.

Por outro lado, a Tabela 13 exhibe o desempenho sob a perspectiva da métrica inexatidão (ϵ) mediante a variação da volumetria da sequência de treinamento, incrementada sequencialmente a cada ano a partir de 2008. A observação dessa tabela permite inferir que o algoritmo treinado com os convênios celebrados em 2008 possui um desempenho muito insatisfatório sob a perspectiva da inexatidão (ϵ).

Ano Alcance	Intervalo Acumulado de <i>Score</i>						
	[0,0 a 0,4)	[0,0 a 0,5)	[0,0 a 0,6)	[0,0 a 0,7)	[0,0 a 0,8)	[0,0 a 0,9)	[0,0 a 1,0]
2008	85,55%	87,05%	88,26%	89,61%	90,68%	91,74%	100,00%
2009	0,93%	3,56%	12,53%	24,98%	36,01%	45,34%	100,00%
2010	0,07%	0,93%	2,21%	8,75%	17,94%	22,28%	100,00%
2011	0,00%	0,93%	3,56%	9,61%	11,74%	17,37%	100,00%
2012	0,00%	0,21%	1,14%	4,27%	9,82%	16,73%	100,00%
2013	0,00%	0,14%	1,28%	2,57%	5,49%	11,90%	100,00%
2014	0,00%	0,14%	0,36%	1,85%	4,13%	9,54%	100,00%
2015	0,00%	0,14%	0,57%	1,71%	4,20%	11,32%	100,00%
2016	0,00%	0,21%	0,57%	1,28%	4,13%	9,40%	100,00%

Tabela 13 – Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios separados por ano de celebração. (Probabilidade de Falso Positivo).

Seguidamente, o algoritmo treinado com os convênios celebrados até 2009 produziu um modelo melhor que o anterior, porém ainda insatisfatório porque a métrica inexatidão (ϵ) continua muito degradada. Ato contínuo, infere-se que o algoritmo treinado pelos celebrados convênios até 2010 é pior que o de 2011, que por sua vez é pior que o de 2012, que por sua vez é pior que o de 2013. Conseqüentemente, essa inferência endossa a hipótese suscitada de que o desempenho do algoritmo de aprendizado de máquina aumenta à medida que há mais dados no universo de aprendizagem, o que vai ao encontro da literatura recente (BAO et al., 2020; CECCHINI et al., 2010; LARCKER; ZAKOLYUKINA, 2012; HOODA; BAWA; RANA, 2020). Todavia, merece destaque o fato de que o algoritmo de 2010 é melhor que o algoritmo de 2011 até o intervalo acumulado [0 a 0,6), apesar de este algoritmo ter sido gerado com uma volumetria de sequência de treinamento maior que aquele, o que de certa forma contraria o que assevera Alpaydin (2020). No entanto, Breiman (2001) assevera que essas situações que escapam

à dicotomia mais volumetria e melhor desempenho podem ocorrer quando alguma característica da sequência de treinamento faz com que o algoritmo identifique as classes explicitamente, nesse caso convênios reprovados e aprovados.

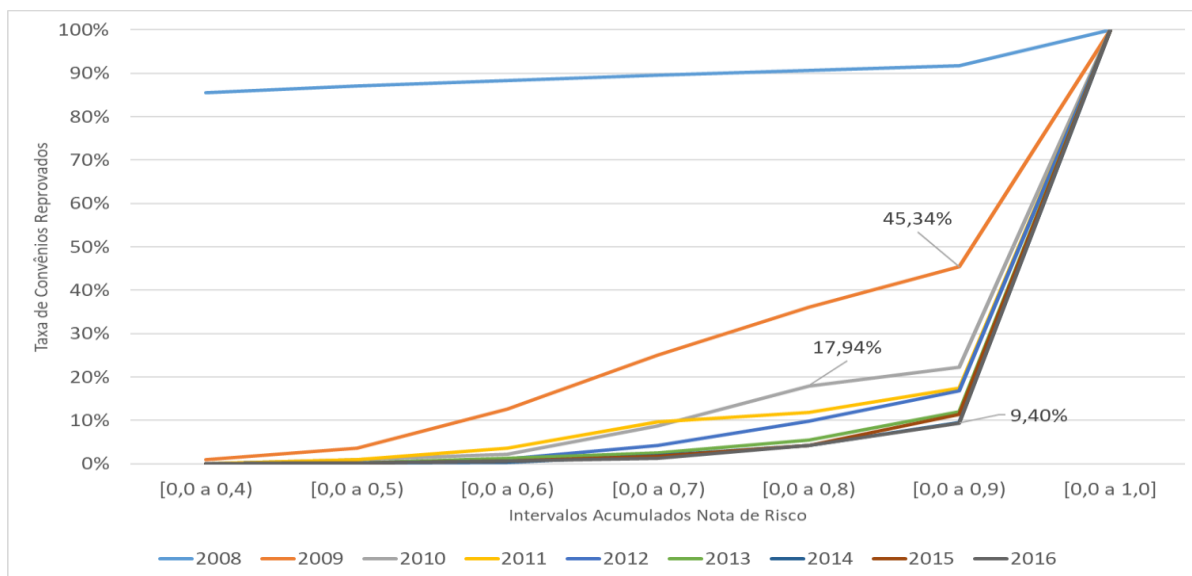


Figura 21 - Curva da Métrica Inexatidão (ϵ) dos Algoritmos de IA treinados a partir dos convênios separados por ano de celebração. (Probabilidade de Falso Positivo).

Outrossim, infere-se que o aprimoramento do desempenho dos algoritmos treinados com volumetria incremental a cada ano, possui uma estagnação a partir do algoritmo treinado com os convênios celebrados até o ano de 2013. A Figura 21, gerada a partir dos dados da Tabela 13, evidenciam uma melhoria tímida na métrica inexatidão (ϵ) dos algoritmos treinados a partir do ano de 2014, quase insignificante.

Tal fato permite responder a hipótese 4, na medida em que existe um ponto de saturação e que foi possível estabelecer o tamanho da sequência de treinamento para aprendizagem de máquina em que o incremento da volumetria não é mais significativo para a melhoria do desempenho. Por sua vez, a ocorrência de ponto de saturação no aprendizado de máquina supervisionado é corroborada por Alpaydin (2020) e Breiman (2001), Zhang(2019a). Adicionalmente, os algoritmos treinados com a volumetria saturada, ou seja, a partir de 2013 em diante, estabelecem um limiar ótimo de taxas de falsos positivos a partir do score 0,8. A Figura 21 permite afirmar que as curvas desses algoritmos possuem um ponto de inflexão precisamente a partir do *score* 0,8, uma vez que a probabilidade de ocorrência de falsos positivos permanece abaixo de 10% até esse limiar, aumentando drasticamente após esse limite.

6. CONSIDERAÇÕES FINAIS

O ciclo de vida do repasse de recursos discricionários se encerra com sua prestação de contas e consequente análise pelo órgão repassador, o qual opina pela aprovação ou rejeição das contas. A análise de prestação de contas é um processo moroso e exorta o emprego de recursos para sua realização, além de servidores públicos capacitados (FERREIRA; BUGARIN, 2008; MEIRELES, 2019). Por sua vez, o sistema “Malha Fina de Convênios” apresenta uma alternativa célere e racional para a análise de prestação de contas, configurando-se em inovação.

O objetivo desta pesquisa foi, a partir da comparação entre resultados gerados por algoritmos de Inteligência Artificial e os resultados das prestações de contas de convênios, identificar de que maneira a identidade do órgão repassador de recursos e o tamanho das sequências de treinamento são determinantes na precisão de classificação do algoritmo de aprendizado de máquina. O resultado da análise da prestação de contas de um convênio poderá ser classificada como aprovada ou rejeitada. Destarte, foi possível esclarecer as circunstâncias em que a adoção do “*Malha Fina de Convênios*” é mais assertiva por meio dos constructos *Identidade do repassador de recurso* (H1 e H2) e *Tamanho de treinamento de dados* (H3 e H4), afastando objeções contra sua implantação e validando o método dessa abordagem inovadora.

No aprendizado de máquina supervisionado *Random Forest*, os algoritmos precisam ser treinados primeiramente no conjunto de dados de treinamento e depois testados no conjunto de dados de teste. A regra geral na divisão entre conjunto de treinamento e teste é escolher cerca de 75% da amostra como dados de treinamento e o restante como dados de teste (ALPAYDIN, 2020). Todavia, isso não é uma regra consagrada, uma vez que a garantia de desempenho do aprendizado de máquina depende da disponibilidade de rotulação dos dados (ISSA; SUN; VASARHELYI, 2016; SUN, 2019) e o balanceamento dos rótulos dentro da sequência de treinamento (BAO et al., 2020; ZHANG, 2019a). Diante desses preceitos, os testes desta pesquisa foram realizados em duas partes, contemplando as propriedades intrínsecas de cada órgão repassador e a fidedignidade da aprendizagem conforme a agregação de dados na sequência de treinamento.

Primeiramente, investigou-se o desempenho da precisão dos algoritmos por meio da parametrização de 10 sequências de treinamento conforme a identidade do órgão concedente. Demonstrou-se, empiricamente, que, sob certas circunstâncias, alguns algoritmos treinados exclusivamente com convênios de um determinado órgão

concedente possuem desempenho melhor do que o algoritmo treinado com a população completa dos convênios (BAO et al., 2020; CECCHINI et al., 2010; TIWARI; HOODA, 2018). Por sua vez, essas circunstâncias se materializam sob a métrica a ser utilizada para a avaliação do desempenho, AUC ou inexatidão (ϵ). Enquanto a métrica AUC aponta 4 algoritmos com desempenho superior em relação àquele treinado com a população total de convênios, a métrica inexatidão (ϵ) não indica nenhum algoritmo treinado apenas com convênios de um determinado órgão com superioridade de desempenho em relação ao *benchmarking*. Contudo, o desempenho superior dos 4 algoritmos sob o ponto de vista da métrica AUC apresenta-se de maneira residual, quase insignificante, e sob o ônus de resultar em 6 algoritmos com desempenho inferior na perspectiva da métrica inexatidão (ϵ), sendo 2 desses muito insatisfatórios. Logo, os achados sugerem que a adoção da estratégia de treinar algoritmos separadamente conforme o órgão repassador de recursos não é vantajosa.

Em seguida, foi investigado o comportamento da precisão dos algoritmos mediante o incremento do tamanho da sequência de treinamento para a aprendizagem de máquina. Dessa forma, avaliou-se a eventual ocorrência de discrepância nos 9 algoritmos distintos gerados. Constatou-se que à medida que o tamanho da sequência de treinamento cresce, a precisão do algoritmo produzido aumenta. Ademais, o diagnóstico dos resultados obtidos indica que a adoção do modelo preditivo para estimar os resultados de um convênio não será problemática caso o tamanho da sequência de treinamento seja maior ou igual ao ponto de saturação (BREIMAN, 2001; DOMINGOS, 2012). Nesta pesquisa, observaram-se dois pontos de saturação ligeiramente diferentes para as métricas AUC e inexatidão (ϵ). De um lado, a métrica AUC indica que a saturação ocorre com uma sequência de treinamento com convênios celebrados até o ano de 2012, consistindo em 72,18% do total (Figura 20 e Tabela 10), enquanto a métrica inexatidão (ϵ) indica a sequência composta até o ano de 2013, consistindo em 84,77% do total (Figura 21 e Tabela 10).

Com efeito, os achados dessa pesquisa validam a atual metodologia do “*Malha Fina de Convênios*”, visto que contém resultados satisfatórios baseados em testes empíricos do modelo preditivo. O Malha Fina apresenta-se como uma alternativa célere e racional para a análise de prestação de contas. Para Barzelay (1997), Bresser-Pereira (1998, 2008), Fukuyama (2004) e Power (1997, 2003a, 2003b), as tomadas de decisão em uma organização burocrática devem ser pautadas pelo custo de transação dos processos. Nessa linha, esse sistema racionaliza a utilização da força de trabalho na análise de prestações

de contas pelos órgãos concedentes mediante a adoção de um limiar de apetite a risco em que os prováveis convênios com contas rejeitáveis estariam inadvertidamente aprovados (falsos positivos). O presente trabalho mostra uma inflexão nesse limiar de risco em 0,8 (Figura 16).

Outrossim, futuras pesquisas podem avançar na aplicabilidade da metodologia do “*Malha Fina de Convênios*” em duas vertentes. A primeira vertente consiste em utilizar outras métricas, além da AUC e inexatidão (ϵ), para avaliar o desempenho do algoritmo de Inteligência Artificial. A segunda, consiste em validar a implementação da metodologia do “*Malha Fina de Convênios*” em outras modalidades de transferências de recursos da União para Entes subnacionais que não são operacionalizadas na Plataforma +Brasil. Esse campo de pesquisa mostra-se fértil, na medida em que as transferências voluntárias são quantitativamente inferiores ao volume financeiro que envolve as transferências obrigatórias (AMORIM NETO; SIMONASSI, 2013). Dados extraídos do SIAFI em maio de 2020 demonstram que, do total de recursos transferidos pela União, apenas cerca de 3% correspondem a transferências voluntárias.

Oportunamente, as pesquisas futuras poderão tirar proveito das limitações enfrentadas nesta pesquisa, adotando uma estratégia para lidar com a baixa disponibilidade de dados rotulados em classes de forma balanceada (ALPAYDIN, 2020; SUN, 2019), no caso em tela, prestações de contas de convênios aprovadas ou rejeitadas. A outra grande limitação foi a configuração de infraestrutura com grande capacidade computacional para executar as simulações.

Como qualquer disciplina, há muita “sabedoria popular” em torno da Inteligência Artificial e como seu uso pode gerar benefícios práticos. Esta pesquisa demonstrou que é possível extrair resultados dentro do arcabouço weberiano racional-legal da Administração Pública brasileira por meio de ferramentas da Ciência da Computação (NEWELL; SIMON, 1976). Isso remonta a uma situação renascentista que combina tecnologia, ciência cognitiva e necessidade humana para produzir algo que o mundo não sabia que estava faltando, constituindo um novo campo de conhecimento.

As transferências voluntárias da união não figuram como uma política pública isolada, muito menos um fim em si mesmas, haja vista que sua finalidade primordial é possibilitar, a título de cooperação, o financiamento dos serviços públicos nos entes subnacionais. Torna-se imprescindível que os critérios de equidade sobreponham-se aos objetivos políticos nos repasses decorrentes de transferências voluntárias, pois assim esse recurso contribuiria para a diminuição das desigualdades inter-regionais na federação

brasileira, conforme apontam Abrucio (2005), Arretche (2010) e Fajardo (2016). Destarte, o controle e a fiscalização dos recursos repassados precisam ser tempestivos e ágeis, concomitantes à execução da política pública, de forma a garantir a equidade e o *accountability* (SCHEDLER, 1999).

O “*Malha Fina de Convênios*”, apresenta-se como um instrumento poderoso para modificar o paradigma em que os entes subnacionais com alinhamento político com o mandatário da União, ou com maior representatividade no Congresso Nacional, recebem mais recursos, indiferentemente de outros critérios (AMORIM NETO; SIMONASSI, 2013; BROLLO; NANNICINI; 2012; FERREIRA; BUGARIN, 2008; LIMONGI; FIGUEIREDO, 2005; MEIRELES, 2019; SOARES; MELO, 2016).

Em linha com os resultados já apresentados no setor privado, a difusão de métodos aplicados ao controle e mitigação de riscos na Administração Pública têm grande chance de impactar positivamente a gestão (AL-QUDAH; BANIAHMAD; AL-FAWAERAH, 2013; HUANG; VASARHELYI, 2019). A digitalização de serviços públicos, com o uso intensivo de Inteligência Artificial poderá se tornar prática corrente na Administração Pública como meio para enfrentar as crescentes demandas de ampliação da eficiência, oportunizando que servidores qualificados possam lidar com tarefas mais sofisticadas (KIM; MANNINO; NIESCHWIETZ, 2009). Ressalta-se que os resultados desta pesquisa poderão ser incorporados no processo de trabalho dos repasses voluntários da União aos entes subnacionais, ensejando, inclusive, alterações normativas que regram o processo das transferências voluntárias da União, além de afastar o medo na adoção do “*Malha Fina de Convênios*”. Neste sentido reside a principal colaboração deste trabalho.

REFERÊNCIAS

- ABRUCIO, F. L. Reforma do Estado no federalismo brasileiro: a situação das administrações públicas estaduais. **Revista de Administração Pública**, v. 39, n.2, p. 401-420, 2005
- ABRUCIO, F. L.; FRANZESE, C. Federalismo e políticas públicas: o impacto das relações intergovernamentais no Brasil. In: ARAÚJO, M.; BEIRA, L. (Org.). **Tópicos da Economia Paulista para Gestores Públicos**. São Paulo: Fundap, v. 1, p. 13-31, 2007.
- ABRUCIO, Fernando Luiz; LOUREIRO, Maria Rita; Burocracia e políticas Públicas no Brasil - interseções analíticas - Capítulo 1. Brasília: IPEA, 2018. E-book. Disponível em: [https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/180705_livro_burocra](https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/180705_livro_burocra%20cia_e_pol%C3%ADticas_publicas_no_brasil.pdf)
[cia e políticas publicas no brasil.pdf](https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/180705_livro_burocra%20cia_e_pol%C3%ADticas_publicas_no_brasil.pdf). Acesso em: 10 jan. 2020.
- ADAM, M. B. Agency Theory and the Internal Audit. **Managerial Auditing Journal**, v. 9, n. 8, p. 8–12, 1994.
- AHRENS, T.; FERRY, L.; KHALIFA, R. The hybridising of financial and service expertise in English local authority budget control: A practice perspective. **Qualitative Research in Accounting and Management**, v. 15, n. 3, p. 341–357, 2018.
- ALPAYDIN, Ethem. **Introduction to machine learning**. MIT press, 2020.
- AL-QUDAH, A. A.; BANIAHMAD, A. Y.; AL-FAWAERAH, N. The Impact of Information Technology on the Auditing Profession. **Management and Administrative Sciences Review**, v. 430, p. 423–430, 2013.
- ALVES, M. F. C.; CALMON, P. C. Du P. Múltiplas Chibatas? – Governança da Política de Controle da Gestão Pública Federal. In: ENCONTRO DE ADMINISTRAÇÃO PÚBLICA E GOVERNANÇA, 2008, Salvador. ANPAD, 2008
- AFONSO, J.R; ARAÚJO, E.; FAJARDO, B.G. The role of fiscal and monetary policies in the Brazilian economy: understanding recent institutional reforms and economic

changes. **The Quarterly Review of Economics and Finance**, (no prelo), 2016.

ARRETCHE, M. Federalismo e igualdade territorial: uma contradição em termos? **Dados**, v. 53, p. 587-620, 2010.

AMORIM NETO, Octavio. Gabinetes presidenciais, ciclos eleitorais e disciplina legislativa no Brasil. **Dados**, v. 43, n. 3, p. 479-519, 2000.

AMORIM NETO, O.; SIMONASSI, A. G. Bases políticas das transferências intergovernamentais no Brasil (1985-2004). **Revista de Economia Política**, v. 33, n. 133, p. 704–725, 2013.

BAO, Y. et al. Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach. **Journal of Accounting Research**, v. 58, n. 1, p. 199–235, 2020.

BARZELAY, M. Central Audit Institutions and Performance Auditing: A Comparative Analysis of Organizational Strategies in the OECD. **Governance: An International Journal of Policy, Administration, and Institutions**, 10: 235-260, 1997.

_____. **Public Management as a Design-Oriented Professional Discipline**. Cheltenham, Reino Unido: Edward Elgar Publishing Limited The Lyptatts. 2019.

_____. The Study of Public Management : Conceptualizing a Design-Oriented Social Science. **Revista do Serviço Público**, v. 69, n. 1, p. 33–56, 2018.

BARZELAY, M.; GALLEGU, R. From “New Institutionalism” to “Institutional Processualism”: Advancing Knowledge about Public Management Policy Change. **Governance: An International Journal of Policy, Administration, and Institutions**, 19: 531-557, 2006.

BRASIL. Controladoria-Geral da União, Secretaria Federal de Controle Interno. **Instrução Normativa nº 03, de 09.06.2017**. Aprova o Referencial Técnico da Atividade de Auditoria Interna Governamental do Poder Executivo Federal. 2017a. Disponível em

https://www.cgu.gov.br/sobre/legislacao/arquivos/instrucoes-normativas/in_cgu_03_2017.pdf. Acesso em 25 mai. 2020.

_____. Controladoria-Geral da União, Secretaria Federal de Controle Interno. **Portaria nº 378, de 07.02.2017**. Constitui Grupo de Trabalho para avaliar as transferências voluntárias da união. 2017b.

_____. Controladoria-Geral da União, Secretaria Federal de Controle Interno. **Relatório de Avaliação da Gestão das Transferências Voluntárias da União**. 2018a. Disponível em <https://auditoria.cgu.gov.br/download/11014.pdf>. Acesso em 25 mai. 2020.

_____. Controladoria-Geral da União e Ministério da Economia. **Instrução Normativa Interministerial nº 1, de 14 de fevereiro de 2019**. Estabelece diretrizes e parâmetros para a análise de prestação de contas simplificada. 2019a. Disponível em <http://portal.convenios.gov.br/analise-informatizada>. Acesso em 25 mai. 2020.

_____. Controladoria-Geral da União e Ministério do Planejamento, Desenvolvimento e Gestão. **Instrução Normativa Interministerial nº 5, de 6 de novembro de 2018**. Estabelece diretrizes e parâmetros para a análise de prestação de contas simplificada. 2018b. Disponível em <http://portal.convenios.gov.br/analise-informatizada>. Acesso em 25 mai. 2020.

_____. Ministério da Economia. **Plataforma +Brasil**. 2019b. Disponível em <http://plataformamaisbrasil.gov.br/>. Acesso em 25 mai. 2020.

_____. Tribunal de Contas da União. **Transferências Governamentais Constitucionais**. 2008. Disponível em: <<https://portal.tcu.gov.br/>>. Acesso em: 25 mai. 2020.

BREIMAN, Leo. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

BRESSER-PEREIRA, L. C. Da administração burocrática à gerencial. **Revista do Serviço Público**, v. 47, n. 1, 1996.

_____. A reforma do estado dos anos 90: lógica e mecanismos de controle. **Lua Nova: Revista de Cultura e Política**, (45), 49-95, 1998

_____. O modelo estrutural de gerência pública. **Revista de Administração Pública**, v. 42, n. 2, p. 391–410., 2008

BROLLO, F.; NANNICINI, T Tying Your Enemy's Hands in Close Races : The Politics of Federal Transfers in Brazil. **American Political Science Review**, 106(4), 742–761, 2012.

BROWN-LIBURD, H.; VASARHELYI, M. A. Big data and audit evidence. **Journal of Emerging Technologies in Accounting**, v. 12, n. 1, p. 1–16, 2015.

CAMPANA, P. de S. P. A cultura do medo na administração pública e a ineficiência gerada pelo atual sistema de controle. **Revista de direito**, (09), 189–216, 2017.

CAMPOS, O. S. T. **Data Analytics Transparente para Descoberta de Padrões e Anomalias na Realização de Convênios e Contratos de Repasse Federais**. 2018. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Sergipe, Sergipe, Brasil. São Cristóvão, Sergipe, 2018.

CASTRO, Alvaro Ballejo Fiuza de. **Implicações das Transferências Intergovernamentais na Gestão da Educação no Âmbito Municipal**. 2019. Dissertação (Mestrado em Administração Pública) - Fundação Getúlio Vargas, Rio de Janeiro, 2019.

CECCHINI, Mark et al. Detecting management fraud in public companies. **Management Science**, v. 56, n. 7, p. 1146-1160, 2010.

COMMITTEE OF SPONSORING ORGANIZATIONS OF THE TREADWAY COMMISSION – COSO. **Controle Interno – Estrutura Integrada. Sumário Executivo**. Traduzido por PwC. Instituto dos Auditores Internos do Brasil, 2013.

CRESWELL, J.W. **Projeto de Pesquisa: métodos qualitativo, quantitativo e Misto**. Porto Alegre: Artmed, 2007.

DALLAVERDE, A. K. **As transferências voluntárias no modelo constitucional brasileiro**. São Paulo: Blucher, 2016. Disponível em <https://www.blucher.com.br/livro/detalhes/as-transferencias-voluntarias-no-modelo-constitucional-brasileiro-1236>. Acesso em 13 mai 2020.

DIAS, Valmir Gomes. **Auditorias de Obras Públicas: Variáveis Determinantes do Atendimento de Recomendações da Controladoria-Geral da União**. 2018. Dissertação (Mestrado em Administração Pública) – Universidade Federal da Bahia, Salvador, 2018.

DOMINGOS, Pedro. A few useful things to know about machine learning. **Communications of the ACM**, v. 55, n. 10, p. 78-87, 2012.

DUNLEAVY, P. et al. New public management is dead - Long live digital-era governance. **Journal of Public Administration Research and Theory**, v. 16, n. 3, p. 467–494, 2006.

FAJARDO, B. de A., G. **Viagem Ao Centro Da Denúncia : Explorando As “ Camadas ” Que Influenciam As Denúncias De Fraudes**. 2012. Dissertação (Mestrado em Administração Pública) - Fundação Getúlio Vargas, Rio de Janeiro, Brasil, 2012.

FAJARDO, B. de A., G.. **Vieses orçamentários em entes subnacionais: uma análise sob a ótica da estimação das receitas estaduais**. 2016. Tese (Doutorado em Administração Pública) - Fundação Getúlio Vargas, Rio de Janeiro, Brasil, 2016.

FAYOL, H. *General and industrial management*. London, Pitman, 1949.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.

FERREIRA, I. F. S.; BUGARIN, M. S.. Transferências voluntárias e ciclo político-

orçamentário no federalismo fiscal brasileiro. **Revista Brasileira de Economia**, 61(3), 271–300, 2008.

FILGUEIRAS, F. Burocracias do controle, controle da burocracia e accountability no Brasil. In: PIRES, R.; LOTTA, G.; OLIVEIRA, V. E. (Org.) **Burocracia e políticas Públicas no Brasil - interseções analíticas**. Brasília: IPEA, 2018. E-book. Disponível em: https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/180705_livro_burocracia_e_politicas_publicas_no_brasil.pdf. Acesso em: 10 jan. 2020.

FUKUYAMA, F. **A Construção de Estados. Governo e Organização no Século XXI.** Rio de Janeiro, RJ : Rocco. 2004.

GROVER, D.; BAUHOFF, S.; FRIEDMAN, J. Using supervised learning to select audit targets in performance-based financing in health: An example from Zambia. **PLoS ONE**, v. 14, n. 1, p. 1–13, 2019.

HEBER, F. O Diálogo entre Burocracia e Inovação. **ANPAD**, 1–10., 2014

HOOD, C.; JAMES, O.; SCOTT, C. Regulation of government: Has it increased, is it increasing, should it be diminished? **Public Administration**, v. 78, n. 2, p. 283–304, 2000.

HOODA, N.; BAWA, S.; RANA, P. S. Optimizing Fraudulent Firm Prediction Using Ensemble Machine Learning: A Case Study of an External Audit. **Applied Artificial Intelligence**, v. 34, n. 1, p. 20–30, 2020.

HUANG, F.; VASARHELYI, M. A. Applying robotic process automation (RPA) in auditing: A framework. **International Journal of Accounting Information Systems**, v. 35, p. 100433, 2019.

IMONIANA, J. O.; NOHARA, J.J. Cognição da estrutura de controle interno: uma pesquisa exploratória. **Revista de Administração e Contabilidade da Unisinos**, 2(1), 37-46, 2005.

Instituto Brasileiro de Geografia Estatística – IBGE – (2020). **Código dos Municípios IBGE**. Disponível em <https://www.ibge.gov.br/explica/codigos-dos-municipios.php>. Acesso em: 12 abr. 2020

ISMAEL, H. R.; ROBERTS, C. Factors affecting the voluntary use of internal audit: evidence from the UK. **Managerial Auditing Journal** .Vol. 33, 2018.

ISSA, H.; SUN, T.; VASARHELYI, M. A. Research ideas for artificial intelligence in auditing: The formalization of audit and workforce supplementation. **Journal of Emerging Technologies in Accounting**, v. 13, n. 2, p. 1–20, 2016.

JACKSON, B. Designing projects and project evaluations using the logical framework approach. **Monitoring and Evaluation Initiative: IUCN**, (October), 1–11, 1997.

JENKINS-SMITH, H. C. Professional Roles for Policy Analysts: A Critical Assessment. **Journal of Policy Analysis and Management**. Vol. 2, No. 1, pp. 88-100, 1982.

JR., Eudes Moacir Toscano; LEITÃO, Carla Renata Silva. Os desafios do controle interno governamental diante da re-forma do Estado: o caso do Programa de Modernização do Controle Interno do Estado da Paraíba (Promocin). **Cadernos EBAPE.BR**, Rio de Janeiro, v. 4, n. 1, p. 1 a 14, jan. 2006. ISSN 1679-3951. Disponível em: <<http://bibliotecadigital.fgv.br/ojs/index.php/cadernosebape/article/view/4962>>. Acesso em: 15 Mai. 2020.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **International joint Conference on artificial intelligence**. [S.l.: s.n.], 1995. v. 14, p. 1137–1145.

KIM, H. J.; MANNINO, M.; NIESCHWIETZ, R. J. Information technology acceptance in the internal audit profession: Impact of technology features and complexity. **International Journal of Accounting Information Systems**, 10(4), 214–228, 2009.

LARCKER, D.; ZAKOLYUKINA, A. A. Detecting Deceptive Discussions in

Conference Calls. **Journal of Accounting Research**, v. 50, n. 114, p. 495–540, 2012.

LÉLIS, D. L. M.; PINHEIRO, L. E. T. Percepção de auditores e auditados sobre as práticas de auditoria interna em uma empresa do setor energético. **Revista Contabilidade & Finanças**, 23(60), 212–222, 2012.

LIMONGI, F.; FIGUEIREDO, A. Processo Orçamentário e Comportamento Legislativo: Emendas Individuais, Apoio ao Executivo e Programas de Governo. **Dados**, 48(4), 737-776, 2005

LOUREIRO, M. R; ABRUCIO, F. L. Política e reformas fiscais no Brasil recente. **Revista de economia política**, v. 24, n. 1, p. 50-72, 2004.

LOUREIRO, M. R et. al. Do Controle Interno ao Controle Social: A Múltipla Atuação da CGU na Democracia Brasileira. *Cadernos Gestão Pública e Cidadania*, 17(60), 54–67, 2015.

MACIEJEWSKI, M. To do more, better, faster and more cheaply: using big data in public administration. **International Review of Administrative Sciences**, 83(1_suppl), 120–135, 2017

MATLAND, R. E. Synthesizing the Implementation Literature: The Ambiguity-Conflict Model of Policy Implementation. **Journal of Public Administration Research and Theory**, 5(2), 1995.

MARGETTS, H.; DUNLEAVY, P. Better Public Services through e-government: Academic Article in support of Better Public Services through e-government - Report by the Comptroller and Auditor General HC 704-III Session. n. April, p. 1–21, 2002. Disponível em: http://www.governmentontheweb.org/sites/governmentontheweb.org/files/Cultural_Barriers.pdf. Acesso em: 15 abr. 2020.

MEIRELES, F. Alinhamento partidário e demanda por transferências federais no Brasil. **Revista de Administração Pública**, 53(1), 173–194, 2019

MICHENER, G.; BERSCH, K. (2013). Identifying Transparency. **Information Polity**, 18(3), 233–242, 2013.

MINTZBERG, H. **The structuring of organizations: A synthesis of the research**. Englewood Cliffs, N.J: Prentice-Hall, 1979

MONTEIRO, R. P. Análise do sistema de controle interno no Brasil: objetivos, importância e barreiras para sua implantação. **Revista Contemporânea de Contabilidade**, 12(25), 159, 2015

NEWELL, A.; H. SIMON. Computer science as empirical inquiry: symbols and search. **Communications of the ACM** . 19 (3), pp. 113–126, 1976

OLIVEIRA, Antonio. Burocratas da linha de frente: executores e fazedores das políticas públicas. **Revista de Administração Pública**, Rio de Janeiro, v. 46, n. 6, p. 1551 a 1573, dez. 2012.

OLIVIERI, C. **Política e burocracia no Brasil: o controle sobre a execução das políticas públicas**. Tese (Doutorado em Administração Pública e Governo) - Fundação Getúlio Vargas, São Paulo, Brasil, 2008.

_____, C. Os controles políticos sobre a burocracia. **Revista de Administração Pública**, Rio de Janeiro, v. 45, n. 5, p. 1395 a 1424, dez. 2011.

OTLEY, David. Performance management: a framework for management control systems research. **Management Accounting Research**, 10(4), 363–382, 1999.

PARKER, L. D.; JACOBS, K.; SCHMITZ, J. New public management and the rise of public sector performance audit. **Accounting, Auditing & Accountability Journal**, v. 32, n. 1, p. 280–306, 2018.

PIETRO, Maria Sylvia Zanella di. Direito administrativo. 28. ed. São Paulo: Atlas, 2015, p. 386.

POWER, M. **The Audit Society: Rituals of Verification**. Oxford, United Kingdom: Oxford University Press., 1997.

_____. Evaluating the audit explosion. **Law and Policy**, 25(3), 185–202, 2003a

_____. The Audit Society - Second Thoughts. **International Journal of Auditing**, 4(1), 111–119, 2003b

_____. The risk management of nothing. **Accounting, Organizations and Society**, 34(6–7), 849–855, 2009.

RAMOS, A. G. *Administração e contexto brasileiro: esboço de uma teoria geral da administração*. Rio de Janeiro: FGV, 1983.

RAMOS, M. P., SCHABBACH, L. M. O estado da arte da avaliação de políticas públicas: conceituação e exemplos de avaliação no Brasil. **Revista de Administração Pública**, v. 46, n. 5, p. 1271–1294.out., 2012.

SECCHI, L. Modelos organizacionais e reformas da administração pública. **Revista de Administração Pública**, 43(2), 347 a 369, 2009

SILVA, E. H. F. M. da; BERNARDES, E. M. Estrutura lógica como metodologia para avaliação de políticas públicas: uma análise do Pronaf. **Revista de Administração Pública**, v. 48, n. 3, p. 721–743, 2014.

SCHEDLER, A. **Conceptualizing Accountability**. In Diamond, L. J.; Plattner, M. F.; (Eds.), *The Self-Restraining State: Power and Accountability in New Democracies* (pp. 13–28). Boulder Colorado: Lynne Rienner Publishers, 1999.

SOARES, M. M.; MELO, B. G. De. Condicionantes políticos e técnicos das transferências voluntárias da União aos municípios brasileiros. **Revista de Administração Pública**, 50(4), 539–561, 2016.

SUN, T. S. Applying deep learning to audit procedures: An illustrative framework. **Accounting Horizons**, 33(3), 89–109, 2019.

SUNSTEIN, C. R. **Output Transparency vs. Input Transparency**. In Pozen, D. E.; & Schudson, M.:(Eds.), *Troubling Transparency*. New York: Columbia University Press, 2018.

TENÓRIO, F. G. "Weber e a burocracia". **Revista de Serviço Público**. Brasília: DASP, out./dez. 1981, ano 38, vol. 109, no 4, p. 79-88.

TIWARI, A.; HOODA, N. Machine Learning Framework for Audit Fraud Data Prediction. **ResearchGate**, v. 7, n. 6, p. 164–167, 2018.

TAYLOR, F. W. **The principles of scientific management**. New York: Harper & Brothers, 1911.

The Institute of Internal Auditors – IIA (2012). *International Standards for The Professional Practice of Internal Auditing (Standards)*. Disponível em de <https://na.theiia.org/standards-guidance/Public%20Documents/IPPF%202013%20English.pdf>. Acesso em: 10 jan. 2020.

TREVISAN, A. P.; BELLEN, H. M. V. Avaliação de políticas públicas: uma revisão teórica de um campo em construção. **Revista de Administração Pública**, v. 42, n. 3, p. 529–550, jan., 2008.

United States Government Accountability Office – GAO (2011). **Government Auditing Standards**. Disponível em <http://gao.gov/assets/590/587281.pdf>. Acesso em 25 abr. 2020.

VASARHELYI, M. A.; HARPER, F. The Continuous Audit of Online Systems. **Auditing: A Journal of Practice and Theory**. 10(1) 110-125, 1991.

VASARHELYI, M. A.; KOGAN, A.; TUTTLE, B. M. Big data in accounting: An

overview. **Accounting Horizons**, v. 29, n. 2, p. 381–396, 2015.

WIRTZ, B. W.; WEYERER, J. C.; GEYER, C. Artificial Intelligence and the Public Sector—Applications and Challenges. **International Journal of Public Administration**, v. 42, n. 7, p. 596–615, 2019.

WREN, D. A.; BEDEIAN, A. G.; **The Evolution Of Management**, United States, Sixth Edition, WILEY, 2009.

WREN, D. A.; BEDEIAN, A. G.; D.BREEZE, J. The foundation of Henri Fayol's administrative theory. **Medizinische Welt**, 26(45), 2033–2034, 1975.

ZHANG, C. Predict Audit Quality Using Machine Learning Algorithms. **SSRN Electronic Journal**, p. 1–40, 2019a.

ZHANG, C. Intelligent process automation in audit. **Journal of Emerging Technologies in Accounting**, v. 16, n. 2, p. 69–88, 2019b.

ANEXO I - CÓDIGO PHYTON UTILIZADO NAS SIMULAÇÕES

Código para treinamento do Algoritmo de Machine Learning:

```

+*In[1]:*+
[source, ipython3]
----
import pyodbc
from math import floor
from sklearn.tree import DecisionTreeClassifier
import numpy as np
import functools
from sklearn.model_selection import train_test_split
from sklearn.metrics import confusion_matrix
from sklearn.metrics import f1_score
from sklearn.metrics import recall_score
import matplotlib.mlab as mlab
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.ensemble import ExtraTreesClassifier
from sklearn.model_selection import cross_validate
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import cross_val_predict
import pickle
import importlib
----
+*In[2]:*+
[source, ipython3]
----
# Connection to database to retrieve the covenants
conn = pyodbc.connect(
    r'DRIVER={ODBC Driver 13 for SQL Server};'
    r'SERVER=sdh-die-bd.cgu.local;'
    r'DATABASE=mdl_prestacao_siconv;'
    r'Trusted_Connection=yes;'
    #r'UID=;'
    #r'PWD=;'
)
query = """
    SEQUENCIA DE TREINAMENTO BANCO DE DADOS PLATAFORMA +BRASIL
    PARAMETRIZADA CONFORME O TAMANHO DA SEQUENCIA DE
TREINAMENTO E A          IDENTIDADE DO ORGAO CONCEDENTE
    """
data = pd.read_sql(query, conn)
conn.close()
----
+*In[1]:*+
[source, ipython3]
----
columns = [column for column in data.columns if column not in
['classes_num', 'num_convenio']]
labels = data["classes_num"].values
features = data[list(columns)].values
----
+*In[5]:*+

```

```

[source, ipython3]
----
sample_weight = np.random.RandomState(1234).rand(labels.shape[0])
f_train, f_test, c_train, c_test, sw_train, sw_test =
train_test_split(features, labels, sample_weight, test_size=0.40,
random_state=1234)
----
+*In[6]:*+
[source, ipython3]
----
#Recurso Computacional - Esforço
forest = ExtraTreesClassifier(n_estimators=1000, max_depth=None,
min_samples_split=0.02, random_state=1234, n_jobs=3,
class_weight={0: 1, 1: 1000}, max_features='log2')
#A variavel et_pred é o modelo criado a partir da sequencia de
treinamento da query anterior
et_pred = forest.fit(f_train, c_train, sample_weight=sw_train)
----
+*In[7]:*+
[source, ipython3]
----
#Matrizes de Confusao para geracao das notas de predicao --> risco
# Matris 2 X 2 -> linha sequencia de treinamento /coluna nota
atribuida pelo sistema
predictions = et_pred.predict(f_test)
print(f1_score(c_test, predictions, average=None))
confusion_matrix(c_test, predictions, labels=[0,1])

+*In[8]:*+
[source, ipython3]
----
predictions_prob = et_pred.predict_proba(f_test)
+*In[9]:*+
[source, ipython3]
----
# Connection to database to retrieve the covenants
conn = pyodbc.connect(
    r'DRIVER={ODBC Driver 13 for SQL Server};'
    r'SERVER=sdh-die-bd.cgu.local;'
    r'DATABASE=mdl_prestacao_siconv;'
    r'Trusted_Connection=yes;'
    #r'UID=Trusted_Connection;'
    #r'PWD=Trusted_Connection;'
)
query = """
        SEQUENCIA DE TREINAMENTO BANCO DE DADOS PLATAFORMA +BRASIL

        """
data2 = pd.read_sql(query, conn)
conn.close()
----
+*In[10]:*+
[source, ipython3]
----
columns2 = [column for column in data.columns if column not in
['classes_num', 'num_convenio']]
labels2 = data2["classes_num"].values
features2 = data2[list(columns)].values

```



```
+*In[11]:*+
[source, ipython3]
----
#Matrizes de Confusao para geracao das notas de predicao --> risco
# A Variavel et_pred eh aquela que contem o modelo criado a partir
do bloco da primeira query
predictions2 = et_pred.predict(features2)
print(f1_score(labels2, predictions2, average=None))
confusion_matrix(labels2, predictions2, labels=[0,1])
+*In[12]:*+
[source, ipython3]
----
#Imprimindo as variaveis do teste feito no modelo
predictions_prob2 = et_pred.predict_proba(features2)
+*In[14]:*+
[source, ipython3]
----
data2['scores0']=predictions_prob2[:,0]
data2['scores1']=predictions_prob2[:,1]
data2.to_csv('Modelo_Todos_Orgaos_resultado_para_todos_orgaos.csv')
----
```

Código para cálculo da integral das curvas ROC (Métrica AUC):

```

+*In[13]:*+
[source, ipython3]
----
import pyodbc
from math import floor
from sklearn.tree import DecisionTreeClassifier
import numpy as np
import functools
from sklearn.model_selection import train_test_split
from sklearn.metrics import confusion_matrix
from sklearn.metrics import f1_score
from sklearn.metrics import recall_score
from sklearn.metrics import roc_auc_score
from sklearn.metrics import roc_curve
import matplotlib.mlab as mlab
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.ensemble import ExtraTreesClassifier
from sklearn.model_selection import cross_validate
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import cross_val_predict
import pickle
import importlib
----
+*In[72]:*+
[source, ipython3]
----
# Connection to database to retrieve the covenants
conn = pyodbc.connect(
    r'DRIVER={ODBC Driver 13 for SQL Server};'
    r'SERVER=sdh-die-bd.cgu.local;'
    r'DATABASE=mdl_prestacao_siconv;'
    r'Trusted_Connection=yes;'
    #r'UID=;'
    #r'PWD=;'
)
query = """
    SEQUENCIA DE TREINAMENTO BANCO DE DADOS PLATAFORMA +BRASIL
    PARAMETRIZADA CONFORME O TAMANHO DA SEQUENCIA DE
TREINAMENTO E A          IDENTIDADE DO ORGAO CONCEDENTE
    """

data = pd.read_sql(query, conn)
conn.close()
----
+*In[16]:*+
[source, ipython3]
----
columns = [column for column in data.columns if column not in
['classes_num', 'num_convenio']]
labels = data["classes_num"].values
features = data[list(columns)].values
+*In[74]:*+
[source, ipython3]
----
sample_weight = np.random.RandomState(1234).rand(labels.shape[0])

```

```

f_train, f_test, c_train, c_test, sw_train, sw_test =
train_test_split(features, labels, sample_weight, test_size=0.40,
random_state=1234)
----
+*In[75]:*+
[source, ipython3]
----
#Esforco Computacional
forest = ExtraTreesClassifier(n_estimators=100, max_depth=None,
min_samples_split=0.02, random_state=1234, n_jobs=3,
class_weight={0: 1, 1: 1000}, max_features='log2')
#A variavel et_pred é o modelo criado a partir da sequencia de
treinamento da query anterior
et_pred = forest.fit(f_train, c_train, sample_weight=sw_train)
----
+*In[76]:*+
[source, ipython3]
----
#Matrizes de Confusao para geracao das notas de predicao --> risco
# Matris 2 X 2 -> linha sequencia de treinamento /coluna nota
atribuida pelo sistema
predictions = et_pred.predict(f_test)
print(f1_score(c_test, predictions, average=None))
confusion_matrix(c_test, predictions, labels=[0,1])
----
+*In[77]:*+
[source, ipython3]
----
predictions_prob = et_pred.predict_proba(f_test)
+*In[78]:*+
[source, ipython3]
----
#Calculo da Integral - Curva ROC
probs = et_pred.predict_proba(f_test)[: , 1]
auc = roc_auc_score(c_test, probs)
print('AUC: %.2f' % auc)
----
+*Out[78]:*+
----
AUC: 0.99
----
+*In[80]:*+
[source, ipython3]
----
def plot_roc_curve(fpr, tpr):
    plt.plot(fpr, tpr, color='blue', label='AUC=0.99')
    plt.plot([0, 1], [0, 1], color='darkblue', linestyle='--')
    plt.xlabel('Taxa Falso Positivo')
    plt.ylabel('Taxa Verdadeiro Positivo')
    plt.title('Curva ROC Esporte')
    plt.legend()
    plt.show()
----
+*In[81]:*+
[source, ipython3]
----
fpr, tpr, thresholds = roc_curve(c_test, probs)
plot_roc_curve(fpr, tpr)

```

ANEXO II – CONVÊNIOS ENCERRADOS

Quantidade Total = 51845

Valor Total = R\$ 24.481.496.942,56

Fonte: Base de dados da Plataforma +Brasil.

Órgão Concedente	Órgão Superior	Quantidade	% Qtd Acumulada	Valor	% Valor Acumulado
Ministério da agricultura, Pecuária e Abastecimento	Sem informação de órgão superior	12828	24,74%	R\$ 4.103.577.614,43	16,76%
Ministério das Cidades	Sem informação de órgão superior	9306	42,69%	R\$ 3.632.208.556,57	31,60%
Ministério do Turismo	Sem informação de órgão superior	6838	55,88%	R\$ 2.997.267.993,45	43,84%
Ministério da Saúde	Sem informação de órgão superior	5642	66,76%	R\$ 2.616.303.489,66	54,53%
Ministério do Esporte	Sem informação de órgão superior	3883	74,25%	R\$ 1.307.816.519,40	59,87%
Ministério da Cidadania	Sem informação de órgão superior	2820	79,69%	R\$ 2.252.182.888,98	69,07%
Secretaria de Desenvolvimento Agropecuário e Cooperativismo	Ministério da Agricultura, Pecuária e Abastecimento	1816	83,20%	R\$ 466.273.344,88	70,97%
Ministério da Defesa	Sem informação de órgão superior	1447	85,99%	R\$ 849.524.203,53	74,44%
Fundação Nacional de Saúde	Ministério da Saúde	991	87,90%	R\$ 516.641.303,05	76,55%
Ministério da Justiça e Segurança Pública	Sem informação de órgão superior	861	89,56%	R\$ 967.542.999,64	80,51%

Ministério do Desenvolvimento Regional	Sem informação de órgão superior	638	90,79%	R\$ 363.160.522,05	81,99%
Instituto Nacional de Colonização e Reforma Agrária	Ministério do Desenvolvimento Agrário	519	91,79%	R\$ 511.376.644,26	84,08%
Superintendência de Desenvolvimento do Centro-Oeste	Ministério do Desenvolvimento Regional	404	92,57%	R\$ 179.561.247,21	84,81%
Ministério da Ciência, Tecnologia, Inovação e Comunicações	Sem informação de órgão superior	372	93,29%	R\$ 228.022.805,04	85,74%
Secretaria de Direitos Humanos da Presidência da República	Presidencia da república	348	93,96%	R\$ 174.457.157,20	86,46%
Companhia de Desenvolvimento do Vale do São Francisco	Ministério do Desenvolvimento Regional	268	94,48%	R\$ 157.323.052,54	87,10%
Ministério da Cultura	Sem informação de órgão superior	227	94,91%	R\$ 80.858.483,84	87,43%
Secretaria Especial de Políticas para as Mulheres	Presidencia da república	215	95,33%	R\$ 66.747.608,87	87,70%
Fundação Nacional de Artes	Ministério da cidadania	204	95,72%	R\$ 45.736.624,31	87,89%
Instituto Nacional de Estudos e Pesquisas Educacionais	Ministério da Educação	173	96,06%	R\$ 61.402.149,00	88,14%
Instituto Brasileiro de Turismo	Ministério do Turismo	153	96,35%	R\$ 70.417.309,90	88,43%
Instituto do Patrimônio Histórico e Artístico Nacional	Ministério da Cidadania	146	96,63%	R\$ 45.266.820,71	88,61%
Ministério do Desenvolvimento Agrário	Sem informação de órgão superior	139	96,90%	R\$ 47.675.751,24	88,81%
Ministério da Indústria, Comércio Exterior e Serviços	Sem informação de órgão superior	130	97,15%	R\$ 109.285.672,48	89,25%
Superintendência do Desenvolvimento da Amazônia	Ministério do Desenvolvimento Regional	116	97,37%	R\$ 64.416.317,41	89,52%

Ministério do meio ambiente	Sem informação de órgão superior	101	97,57%	R\$ 54.298.505,88	89,74%
Ministério da Mulher, Família e Direitos Humanos	Sem informação de órgão superior	100	97,76%	R\$ 36.440.845,55	89,89%
Superintendência da Zona Franca de Manaus	Ministério da Indústria, Comércio Exterior e Serviços	88	97,93%	R\$ 201.004.536,71	90,71%
Conselho Nacional de Desenvolvimento Científico e Tecnológico	Ministério da Ciência, Tecnologia, Inovação e Comunicações	83	98,09%	R\$ 336.392.860,27	92,08%
Fundo Nacional Antidrogas	Ministério da Justiça e Segurança Pública	77	98,24%	R\$ 31.261.582,49	92,21%
Ministério do Trabalho e Emprego	Sem informação de órgão superior	65	98,37%	R\$ 182.843.029,76	92,96%
Universidade Federal de Santa Maria	Ministério da Educação	49	98,46%	R\$ 22.254.037,56	93,05%
Universidade Federal do Rio Grande do Sul	Ministério da Educação	45	98,55%	R\$ 24.616.901,19	93,15%
Fundação Cultural Palmares	Ministério da cidadania	42	98,63%	R\$ 13.416.218,56	93,20%
Secretaria de Políticas de Promoção da Igualdade Racial	Presidência da República	39	98,70%	R\$ 8.220.472,56	93,24%
Ministério da Educação	Sem informação de órgão superior	38	98,78%	R\$ 21.468.299,62	93,32%
Ministério de Minas e Energia	Sem informação de órgão superior	36	98,85%	R\$ 69.722.352,15	93,61%
Fundação Universidade do Rio Grande - RS	Ministério da Educação	30	98,90%	R\$ 13.591.433,63	93,66%
Presidência da República	Presidencia da república	27	98,96%	R\$ 11.625.672,66	93,71%
Fundo Nacional do Meio Ambiente	Ministério do Meio Ambiente	26	99,01%	R\$ 9.600.064,68	93,75%

Hospital de Clínicas de Porto Alegre	Ministério da Educação	23	99,05%	R\$ 110.303.735,83	94,20%
Fundo Nacional para a Criança e o Adolescente	Ministério da Mulher, Família e Direitos Humanos	22	99,09%	R\$ 13.358.305,64	94,26%
Universidade federal de minas gerais	Ministério da Educação	22	99,14%	R\$ 117.324.468,20	94,74%
Superintendência do Desenvolvimento do Nordeste	Ministério do Desenvolvimento Regional	21	99,18%	R\$ 8.264.200,69	94,77%
Instituto Brasileiro de Museus	Ministério da Cidadania	21	99,22%	R\$ 16.141.554,67	94,84%
Secretaria de Políticas Públicas de Emprego-SPPE	Ministério do Trabalho e Emprego	21	99,26%	R\$ 65.100.000,00	95,10%
Departamento Nacional de Obras Contra as Secas	Ministério do Desenvolvimento Regional	21	99,30%	R\$ 15.699.227,02	95,17%
Secretaria de Aviação Civil	Presidencia da república	20	99,34%	R\$ 176.190.122,18	95,89%
Agência Nacional de Aviação Civil	Presidencia da República	18	99,37%	R\$ 5.610.642,42	95,91%
Empresa Brasileira de Pesquisa Agropecuária	Ministério da Agricultura, Pecuária e Abastecimento	17	99,40%	R\$ 16.776.831,82	95,98%
Agência Nacional de Águas	Ministério do Desenvolvimento Regional	17	99,44%	R\$ 17.765.759,84	96,05%
Ministério da Economia	Sem informação de órgão superior	17	99,47%	R\$ 14.241.192,22	96,11%
Universidade Federal De Pernambuco	Ministério da Educação	16	99,50%	R\$ 4.362.892,87	96,13%
Fundação universidade federal de mato grosso	Ministério da Educação	14	99,53%	R\$ 9.219.890,88	96,16%
Fundação universidade do amazonas	Ministério da Educação	13	99,55%	R\$ 6.703.670,12	96,19%

Universidade Federal do Paraná	Ministério da Educação	13	99,58%	R\$ 2.412.978,22	96,20%
Ministério do Planejamento, Desenvolvimento e Gestão	Sem informação de órgão superior	13	99,60%	R\$ 20.738.011,55	96,29%
Fundo nacional de Segurança Pública	Ministério da Justiça e Segurança Pública	13	99,63%	R\$ 5.100.685,75	96,31%
Fundação de coordenação de Aperfeiçoamento de pessoal Nível Superior	Ministério da Educação	12	99,65%	R\$ 4.191.815,17	96,32%
Empresa Brasil de Comunicação	Presidência da República	11	99,67%	R\$ 9.911.099,99	96,36%
Fundação Oswaldo Cruz	Ministério da Saúde	11	99,69%	R\$ 5.854.091,25	96,39%
Comando da Aeronáutica	Ministério da Defesa	11	99,71%	R\$ 252.924.070,34	97,42%
Agência Nacional do Petróleo	Ministério de Minas e Energia	9	99,73%	R\$ 3.490.941,02	97,43%
Secretaria Especial de Aquicultura e Pesca	Presidência da República	8	99,75%	R\$ 3.410.679,20	97,45%
Agência Espacial Brasileira	Ministério da Ciência, Tecnologia, Inovação e Comunicações	8	99,76%	R\$ 126.544.118,47	97,97%
Fundação Universidade Federal de Mato Grosso do sul	Ministério da Educação	7	99,78%	R\$ 6.646.172,74	97,99%
Universidade Federal de Ouro Preto	Ministério da Educação	6	99,79%	R\$ 3.167.192,82	98,01%
Fundação Biblioteca Nacional	Ministério da cultura	6	99,80%	R\$ 2.058.960,00	98,01%
Companhia Brasileira de Trens Urbanos	Ministério das cidades	6	99,81%	R\$ 146.358.732,42	98,61%
Secretaria de Agricultura Familiar e do Desenvolvimento Agrário	Sem informação de órgão superior	6	99,82%	R\$ 1.846.905,48	98,62%

Fundação universidade federal de pelotas	Ministério da Educação	5	99,83%	R\$ 2.618.148,18	98,63%
Universidade federal do triangulo mineiro	Ministério da Educação	4	99,84%	R\$ 3.684.299,00	98,65%
Ministério da infraestrutura	Sem informação de órgão superior	4	99,85%	R\$ 3.409.129,73	98,66%
FNI	Ministério da Mulher, Família e Direitos Humanos	4	99,86%	R\$ 1.444.927,96	98,67%
Universidade Federal de Juiz de Fora	Ministério da Educação	4	99,86%	R\$ 49.413.983,76	98,87%
Tribunal Regional Eleitoral de Minas Gerais	Justica Eleitoral	4	99,87%	R\$ 3.440.128,12	98,88%
Justica Eleitoral	Sem informação de órgão superior	4	99,88%	R\$ 3.403.116,45	98,89%
Instituto Nacional de Pesquisas Espaciais	Ministério da Ciência, Tecnologia, Inovação e Comunicações	3	99,88%	R\$ 3.978.985,00	98,91%
Instituto Federal de Ciência e Tecnologia do Espírito Santo	Ministério da Educação	3	99,89%	R\$ 401.565,89	98,91%
Universidade federal rural do Semi-Árido/RN	Ministério da Educação	3	99,90%	R\$ 63.112,20	98,91%
Null	Null	3	99,90%	R\$ 8.228.712,13	98,95%
Fundação Universidade Federal do Acre	Ministério da Educação	2	99,91%	R\$ 1.978.767,22	98,95%
Fundo Aeronáutico	Comando da Aeronáutica	2	99,91%	R\$ 136.626.544,03	99,51%
Comando da Marinha	Ministério da Defesa	2	99,91%	R\$ 762.061,50	99,52%
Fundação Universidade Federal da Grande Dourados	Ministério da Educação	2	99,92%	R\$ 329.400,00	99,52%

Instituto Federal de Ciência e Tecnologia do Paraná	Ministério da Educação	2	99,92%	R\$ 34.989.890,94	99,66%
Indústrias Nucleares do Brasil S/A	Ministério de Minas e Energia	2	99,92%	R\$ 1.388.193,57	99,67%
Tribunal Regional Eleitoral de Goiás	Justica Eleitoral	2	99,93%	R\$ 1.507.613,40	99,67%
Agência Nacional de Transportes Terrestres	Ministério da Infraestrutura	2	99,93%	R\$ 1.137.042,40	99,68%
Ministério do Trabalho e Previdência Social	Sem informação de órgão superior	2	99,94%	R\$ 3.258.380,30	99,69%
Universidade Federal de Roraima	Ministério da Educação	2	99,94%	R\$ 3.438.028,60	99,70%
Tribunal Regional Eleitoral de Tocantins	Justica Eleitoral	2	99,94%	R\$ 699.757,50	99,71%
Servico Florestal Brasileiro	Ministério do Meio Ambiente	2	99,95%	R\$ 786.400,00	99,71%
Departamento Nacional de Infraestrutura de Transportes	Ministério da Infraestrutura	1	99,95%	R\$ 3.614.999,10	99,72%
Instituto Federal de Educação, Ciência e Tecnologia do Ceará	Ministério da Educação	1	99,95%	R\$ 500.000,00	99,73%
Ministério das Relações Exteriores	Sem informação de órgão superior	1	99,95%	R\$ 13.373.840,00	99,78%
Universidade federal do rio de janeiro	Ministério da Educação	1	99,96%	R\$ 300.000,00	99,78%
Agência Nacional de Transportes Aquaviários	Presidencia da República	1	99,96%	R\$ 884.100,00	99,79%
Fundo nacional de desenvolvimento da Educação	Ministério da Educação	1	99,96%	R\$ 4.121.422,65	99,80%
Valec-Engenharia, Construções e Ferrovias S/A	Ministério da Infraestrutura	1	99,96%	R\$ 10.288.659,50	99,85%

Tribunal Regional Eleitoral da Bahia	Justica Eleitoral	1	99,96%	R\$ 1.086.800,00	99,85%
Fundo Nacional de Segurança e Educação do Trânsito	Ministério das Cidades	1	99,97%	R\$ 2.469.144,00	99,86%
Instituto de Pesquisa Econômica Aplicada	Presidência da República	1	99,97%	R\$ 450.000,00	99,86%
Agência Nacional de Saúde Suplementar	Ministério da Saúde	1	99,97%	R\$ 698.400,00	99,86%
Agência Nacional de Vigilância Sanitária	Ministério da Saúde	1	99,97%	R\$ 189.000,00	99,87%
Companhia nacional de abastecimento	Ministério da Agricultura, Pecuária e Abastecimento	1	99,97%	R\$ 1.349.489,33	99,87%
Departamento Nacional de Produção Mineral	Ministério de Minas e Energia	1	99,97%	R\$ 155.430,00	99,87%
Universidade Federal Rural do Rio de Janeiro	Ministério da Educação	1	99,98%	R\$ 1.410.911,12	99,88%
Instituto Chico Mendes de Conservação da Biodiversidade	Ministério do Meio Ambiente	1	99,98%	R\$ 300.000,00	99,88%
Instituto Federal de educação, Ciência e Tecnologia Sul-Rio-Grandense	Ministério da Educação	1	99,98%	R\$ 602.977,36	99,88%
Fundação Universidade Federal de São Carlos	Ministério da Educação	1	99,98%	R\$ 294.755,81	99,88%
Fundação Universidade Federal de Ciências da Saúde de Porto Alegre	Ministério da Educação	1	99,98%	R\$ 1.500.000,00	99,89%
Fundação Universidade Federal do Tocantins	Ministério da Educação	1	99,99%	R\$ 380.967,20	99,89%
Fundação Nacional do Índio	Ministério da Justiça e Segurança Pública	1	99,99%	R\$ 168.000,00	99,89%
Agência Nacional do Cinema	Ministério da cultura	1	99,99%	R\$ 272.000,00	99,89%

Secretaria de Políticas para as Mulheres	Presidencia da república	1	99,99%	R\$ 497.368,36	99,89%
Superintendência do Desenvolvimento do Centro-Oeste	Ministério do Desenvolvimento Regional	1	99,99%	R\$ 105.200,00	99,89%
Instituto Nacional de Metrologia Qualidade e Tecnologia	Ministério da Indústria, Comércio Exterior e Serviços	1	100,00%	R\$ 22.728.364,34	99,99%
Universidade Federal do Sul da Bahia	Ministério da Educação	1	100,00%	R\$ 3.229.084,17	100,00%
Comissão Nacional de Energia Nuclear	Ministério da Ciência, Tecnologia, Inovação e Comunicações	1	100,00%	R\$ 15.000,00	100,00%