

UNIVERSIDADE DE BRASÍLIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

Rafael Monteiro de Castro Nascimento

**Riscos fiscais judiciais:** usando metadados de processos judiciais para estimar o tempo de expedição de precatórios federais

BRASÍLIA  
2024

RAFAEL MONTEIRO DE CASTRO NASCIMENTO

**Riscos fiscais judiciais:** usando metadados de processos judiciais para estimar o tempo de expedição de precatórios federais

Dissertação apresentada à Universidade de Brasília, como parte das exigências do Programa de Pós-Graduação em Economia, para obtenção do título de Mestre.

Orientador: Prof. Dr. Daniel Oliveira Cajueiro

BRASÍLIA  
2024

RAFAEL MONTEIRO DE CASTRO NASCIMENTO

**Riscos fiscais judiciais:** usando metadados de processos judiciais para estimar o tempo de expedição de precatórios federais

Dissertação apresentada à Universidade de Brasília, como parte das exigências do Programa de Pós-Graduação em Economia, para obtenção do título de Mestre.

Trabalho aprovado. Brasília, 23 de dezembro de 2024.

---

**Daniel Oliveira Cajueiro**  
Orientador

---

**Maurício Soares Bugarin**  
Membro Interno

---

**Carlos Eduardo Gasparini**  
Membro Externo

BRASÍLIA  
2024

## **DEDICATÓRIA**

Dedico este trabalho à utopia de um Direito baseado em evidências e construído com consciência. Para que eu não deixe de caminhar.

## **AGRADECIMENTOS**

Agradeço, em primeiro lugar, ao meu filho e minha noiva, com quem vivo e a quem amo diariamente, pelo apoio ao meu desejo, compreensão dos meus momentos e escuta dos meus anseios, ao longo desses anos de mestrado.

Agradeço igualmente à minha mãe e à minha irmã, com quem compartilho a vida e o carinho mútuo todos os dias, por todo o incentivo e ajuda em meus passos.

Agradeço também ao meu orientador, pela inspiração que me desperta desde que o conheci, como pessoa, professor e pesquisador, e por toda a atenção que me dispensou durante esta dissertação.

Agradeço, ainda, a todos os professores, colegas, familiares e amigos, por todos os momentos e conversas, acadêmicas e pessoais, que me ajudaram neste processo.

Agradeço, por fim, à Advocacia-Geral da União e à Universidade de Brasília, instituições públicas que proporcionaram este estudo e às quais almejo retribuir com todo meu trabalho e esforço, em prol de uma sociedade melhor.

*"The appropriate question is: 'When the hell are they!?'"*

*Doc Brown, Back to the Future II (1989)*

## RESUMO

A presente dissertação explora o problema de previsão de riscos fiscais judiciais, com foco no tempo de duração dos processos, relevante para prever o momento de realização de despesas públicas e aprimorar a política fiscal. A literatura sobre previsão no contexto judicial é rica em estudos sobre desfechos e decisões, mas o tempo de duração dos processos ainda é um tema pouco explorado. O objetivo geral da pesquisa foi avaliar a utilidade de metadados de ações judiciais como variáveis independentes em modelos estatísticos e computacionais, a fim de prever o tempo de duração da fase de cumprimento do processo, compreendida entre o trânsito em julgado e a inclusão do precatório na Lei Orçamentária Anual. Foram utilizados dados de precatórios requisitados por Tribunais Regionais Federais e incluídos em leis orçamentárias federais nos anos de 2012 a 2024. A metodologia envolveu a criação de modelos de dados transversais e longitudinais, que fazem uso de algoritmos de *machine learning* para prever o tempo de duração das ações. As variáveis independentes consistiram em metadados processuais, como ano e mês de trânsito em julgado, tribunal e vara de origem, assunto, órgão público envolvido e, nos modelos longitudinais, também o tempo de duração do processo no momento fixado para previsão. Os resultados indicam que: a) ações com precatórios requisitados no mesmo ano apresentam alta correlação entre o ano de trânsito em julgado e o órgão público envolvido, sugerindo mecanismos de julgamento conjunto baseados nesses atributos; b) modelos longitudinais são mais eficazes do que transversais para prever o tempo de duração das ações, sendo o tempo acumulado de duração do processo uma variável essencial para aprimorar as previsões; c) metadados processuais são úteis para previsão do tempo de duração, destacando-se a data de trânsito em julgado, o órgão público envolvido e, em menor grau, o assunto, a vara de origem e o tribunal. Assim, a presente pesquisa contribui para a redução de incertezas associadas aos riscos judiciais, gerando informações para as partes dos processos e promovendo avanços para melhoria da gestão fiscal, além de incentivar pesquisas futuras sobre o tema.

**Palavras-chave:** Riscos fiscais; precatórios; previsão de tempo de duração; aprendizado de máquina; análise de sobrevivência; ações judiciais; dados processuais.

## ABSTRACT

### **Judicial Fiscal Risks: Using Lawsuit Metadata to Estimate the Time until Federal Payment Orders in Brazil**

This research explores the problem of predicting judicial fiscal risks, focusing on the duration of legal proceedings. This is a critical aspect for forecasting the timing of public expenditures and improving fiscal policies. Although the literature on judicial prediction is extensive, with numerous studies on outcomes and decisions, the duration of legal cases remains an underexplored topic. Our primary objective was to assess the usefulness of metadata from lawsuits as independent variables in statistical and computational models, aiming to predict the duration of the enforcement phase, which begins with the final judgment and ends with the inclusion of the judicial order in the Annual Budget Law. We analyzed data on judicial orders (*precatórios*) requested by Federal Regional Courts and included in federal budget laws from 2012 to 2024. We developed cross-sectional and longitudinal data models using machine learning algorithms to predict the duration of legal proceedings. We considered metadata such as the year and month of the final judgment, court and judicial chamber of origin, subject matter, and government agency involved. For longitudinal models, we also included duration at the time of prediction. Our findings reveal that: (a) judicial orders requested in the same year show high correlation with the year of final judgment and the public agency involved, suggesting mechanisms for grouping and adjudicating cases based on these attributes; (b) longitudinal models outperform cross-sectional models in predicting the total duration of cases, with the accumulated duration at the time of prediction proving to be essential for improving accuracy; and (c) metadata such as the date of final judgment and the public agency involved are highly predictive of case duration, while variables such as the subject, judicial division, and court also contribute, though to a lesser extent. This research advances the understanding of judicial risks, offering insights to improve fiscal management and providing valuable information for stakeholders, while also encouraging future studies.

**Keywords:** fiscal risks; court-ordered payments; forecasting models; duration; time to event prediction; survival analysis; machine learning; lawsuits.

## LISTA DE FIGURAS

Figura 1 - Fatores de riscos fiscais específicos .....	18
Figura 2 - Evolução das despesas federais com ações judiciais .....	18
Figura 3 – Tempo médio de tramitação de processos judiciais .....	23
Figura 4 - Distribuição das ações originárias em tribunais .....	41
Figura 5 - Distribuição das ações originárias em órgãos orçamentários .....	41
Figura 6 - Distribuição das ações originárias por ano de trânsito em julgado .....	42
Figura 7 - Distribuição das ações originárias por mês de trânsito em julgado .....	42
Figura 8 - Proporção de ações por duração total a cada ano .....	44
Figura 9 - Proporção de observações por duração total a cada ano.....	45
Figura 10 - Percentual de observações por duração restante.....	46
Figura 11 - Proporção de observações por duração restante a cada ano .....	47
Figura 12 - Duração média das ações originárias por tribunal .....	48
Figura 13 - Histograma do número de órgãos pela duração média das ações em anos*.....	49
Figura 14 - Duração média de ações originárias por ano de trânsito em julgado.....	51
Figura 15 - Duração média de ações originárias por mês de trânsito em julgado.....	51
Figura 16 - Proporção de observações por duração restante binária a cada ano .....	54
Figura 17 - Número de ações judiciais que geraram precatórios por ano .....	55
Figura 18 - Importância das variáveis no Modelo Transversal de Divisão Aletatória (MTA)	61
Figura 19 - Importância das variáveis no Modelo Transversal de Divisão Temporal (MTT)	.62
Figura 20 - Importância das variáveis no Modelo Longitudinal de Duração Total (MLT)	.....63
Figura 21 - Importância das variáveis no Modelo Longitudinal de Duração Restante (MLR)	65
Figura 22 - Comparação de importâncias de variáveis nos modelos transversais.....	70
Figura 23 - Comparação das importâncias das variáveis nos modelos longitudinais .....	70

## LISTA DE QUADROS

Quadro 1 - Variáveis independentes selecionadas para previsão .....	37
Quadro 2 - Variáveis independentes após transformações .....	39
Quadro 3 - Modelos preditivos e cenários de validação.....	55
Quadro 4 - Interpretação do coeficiente Kappa de Cohen.....	58
Quadro A. 1 - Bibliotecas <i>Python</i> utilizadas no estudo .....	80
Quadro A. 2 - Hiperparâmetros dos algoritmos selecionados em validação cruzada .....	81

## LISTA DE TABELAS

Tabela 1 - Duração média das ações originárias por vara federal* .....	49
Tabela 2 - Duração média de ações originárias por assunto*.....	50
Tabela 3 - Resultados do Modelo Transversal de Divisão Aleatória (MTA).....	60
Tabela 4 - Resultados do Modelo Transversal de Divisão Temporal (MTT) .....	62
Tabela 5 - Resultados do Modelo Longitudinal de Duração Total (MLT) .....	63
Tabela 6 - Resultados do Modelo Longitudinal de Duração Restante (MLR).....	64
Tabela 7 - Comparativo de Modelos Transversais de Divisão Aleatória e Temporal.....	66
Tabela 8 - Comparativo de Modelo Transversal (MTT) e Modelo Longitudinal (MLT) .....	68
Tabela 9 - Comparativo de melhores algoritmos por modelo .....	69

## **LISTA DE ABREVIATURA E SIGLAS**

AGU	Advocacia-Geral da União
CF/88	Constituição da República Federativa do Brasil de 1988
CNJ	Conselho Nacional de Justiça
EC	Emenda Constitucional
LOA	Lei Orçamentária Anual
LDO	Lei de Diretrizes Orçamentárias
MTA	Modelo Transversal de Divisão Aleatória
MTT	Modelo Transversal de Divisão Temporal
MLT	Modelo Longitudinal de Duração Total
MLR	Modelo Longitudinal de Duração Restante
RPV	Requisição de Pequeno Valor
STF	Supremo Tribunal Federal
STJ	Superior Tribunal de Justiça
STN	Secretaria do Tesouro Nacional
TRF	Tribunal Regional Federal

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>15</b>
<b>2. REVISÃO DE LITERATURA.....</b>	<b>17</b>
2.1. Finanças públicas, economia e riscos judiciais.....	17
2.2. Sistema judicial e precatórios no Brasil.....	19
2.3. Modelo institucional de análise de riscos fiscais judiciais.....	24
2.4. Modelos preditivos e <i>machine learning</i> .....	26
2.5. <i>Machine learning</i> aplicada a problemas jurídicos .....	29
2.6. Análise de sobrevivência e modelos de dados longitudinais .....	30
<b>3. METODOLOGIA.....</b>	<b>34</b>
3.1. Bases de dados .....	34
3.1.1. <i>Bases de precatórios</i> .....	34
3.1.2. <i>Criação da base de ações originárias</i> .....	35
3.1.3. <i>Criação da base de observações anuais</i> .....	36
3.2. Variáveis independentes .....	37
3.2.1. <i>Transformação de variáveis categóricas</i> .....	37
3.2.2. <i>Distribuição das variáveis independentes</i> .....	40
3.3. Variáveis dependentes .....	43
3.3.1. <i>Duração total</i> .....	43
3.3.2. <i>Duração restante</i> .....	45
3.4. Análise descritiva do tempo de duração das ações .....	47
3.5. Modelos e cenários de validação .....	52
3.6. Algoritmos e métricas de avaliação .....	56
3.6.1. <i>Algoritmos</i> .....	56
3.6.2. <i>Métricas de avaliação</i> .....	57
<b>4. RESULTADOS E DISCUSSÃO .....</b>	<b>60</b>
4.1. Resultados .....	60
4.1.1. <i>Modelo Transversal com Divisão Aleatória</i> .....	60
4.1.2. <i>Modelo Transversal com Divisão Temporal</i> .....	61
4.1.3. <i>Modelo Longitudinal de Duração Total</i> .....	62
4.1.4. <i>Modelo Longitudinal de Duração Restante</i> .....	64
4.2. Análise e discussão .....	66
4.2.1. <i>Comparativo de modelos transversais</i> .....	66

4.2.2.	<i>Comparativo de modelo transversal e modelo longitudinal</i> .....	67
4.2.3.	<i>Comparativo de algoritmos</i> .....	68
4.2.4.	<i>Comparativo de importância das variáveis</i> .....	69
<b>5.</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>72</b>
	<b>REFERÊNCIAS</b> .....	<b>76</b>
	<b>ANEXO A – BIBLIOTECAS E ALGORITMOS COMPUTACIONAIS</b> .....	<b>80</b>

## 1. INTRODUÇÃO

Nos últimos anos, as despesas do Estado Brasileiro com condenações em ações judiciais têm crescido significativamente, refletindo um ambiente jurídico cada vez mais complexo e uma judicialização crescente de políticas públicas, como previdência, saúde e infraestrutura. Em 2022, os riscos judiciais representaram aproximadamente 80% do estoque total de riscos fiscais específicos passivos da União, alcançando o montante de R\$ 2,9 trilhões (STN, 2022).

Diante desse cenário, mostra-se necessário aprimorar a gestão de riscos judiciais, para garantir maior segurança e estabilidade no planejamento orçamentário e na política fiscal. A previsão de quando e em que montante despesas judiciais ocorrerão pode auxiliar o planejamento de desembolsos futuros, reduzindo incertezas no orçamento e contribuindo para a alocação eficiente de recursos públicos.

Nesse contexto, a presente pesquisa busca responder à seguinte questão: quando uma ação judicial gerará despesa futura para o Estado? Para isso, levanta-se a hipótese de que metadados processuais, como vara e tribunal de origem, assunto, órgão público envolvido e data de trânsito em julgado, podem ser utilizados para prever o tempo de duração de processos, por meio de métodos estatísticos e de *machine learning*. O objetivo é avaliar a utilidade desses dados e técnicas na construção de modelos preditivos que reduzam a incerteza sobre o tempo de tramitação dos processos judiciais.

Estudos anteriores evidenciam o potencial do aprendizado de máquina na análise de problemas jurídicos. Katz, Bommarito e Blackman (2017) propuseram um modelo de *machine learning* para prever o comportamento da Suprema Corte dos Estados Unidos com base em dados processuais passados, o qual alcançou 70% de acurácia na previsão do desfecho dos processos. Aletras et al. (2016) aplicaram técnicas de processamento de linguagem natural para prever os resultados de julgamentos da Corte Europeia de Direitos Humanos, obtendo 79% de acurácia. No contexto brasileiro, Jacob de Menezes-Neto e Clementino (2022) desenvolveram um modelo de *deep learning* que superou especialistas humanos na previsão de apelações no Tribunal Regional Federal da 5ª Região.

A literatura corrobora amplamente o uso de *machine learning* para prever decisões judiciais e desfechos de ações. No entanto, o problema específico de previsão do tempo de duração dos processos ainda foi pouco explorado. Em uma revisão sistemática sobre jurimetria e análise preditiva aplicada no Direito, Silva et al. (2023) analisaram 40 artigos

publicados entre 2011 e 2021 e não identificaram estudos focados nesse tema específico. A presente pesquisa busca preencher essa lacuna, aplicando modelos de aprendizado de máquina para prever o tempo de duração de processos judiciais.

Este problema preditivo envolve desafios significativos devido à complexidade do sistema jurídico. O tempo de tramitação de um processo pode ser influenciado por uma ampla gama de fatores, como a matéria em debate, o volume de trabalho do Poder Judiciário, as estratégias processuais das partes e possíveis alterações legislativas. Assim, mais do que fornecer previsões peremptórias, a pesquisa realiza um estudo exploratório sobre as características do problema, avaliando a utilidade de dados processuais, técnicas de *machine learning* e diferentes modelagens para a previsão.

A presente dissertação está dividida em quatro partes, além desta introdução. No segundo capítulo, realizamos uma revisão de literatura em que destacamos trabalhos teóricos e empíricos relacionados com o estudo proposto. No terceiro capítulo, apresentamos a metodologia da pesquisa, descrevendo as bases de dados, o recorte de estudo, as variáveis envolvidas, os algoritmos empregados, as métricas de avaliação e os modelos preditivos desenvolvidos e testados. No quarto capítulo, expomos e discutimos os resultados alcançados à luz das hipóteses e objetivos iniciais. Nas considerações finais, apresentamos as conclusões, contribuições e limitações do trabalho, além de sugerir pesquisas futuras.

## 2. REVISÃO DE LITERATURA

### 2.1. Finanças públicas, economia e riscos judiciais

As finanças públicas consistem em relevante campo de estudo das Ciências Econômicas, sendo fundamental para compreender a distribuição do orçamento público e os impactos das ações estatais sobre a economia. Nesse sentido, Mugrave (1959) destaca o papel da política fiscal como instrumento para alcançar os objetivos do Estado, agrupando-os em três categorias: alocação eficiente de recursos; distribuição de renda e riqueza; e estabilidade econômica.

De fato, diversas correntes de pensamento econômico enfatizam a importância da política fiscal, ainda que o papel por ela exercido varie de acordo com seus objetivos. Para o keynesianismo, a política fiscal é fundamental para a estabilização econômica, especialmente durante recessões (Keynes, 1936). Já para a escola monetarista, a política fiscal deve ser exercida de forma a evitar desequilíbrios macroeconômicos e garantir estabilidade de preços (Friedman, 1962). Por sua vez, institucionalistas destacam sua relevância na promoção do desenvolvimento econômico por meio de instituições fiscais sólidas que assegurem estabilidade (North, 1990).

Independentemente dos objetivos e do enfoque da política fiscal traçada, é fundamental compreender os fatores de risco que podem influenciar os resultados das contas públicas e, portanto, o sucesso da política estabelecida.

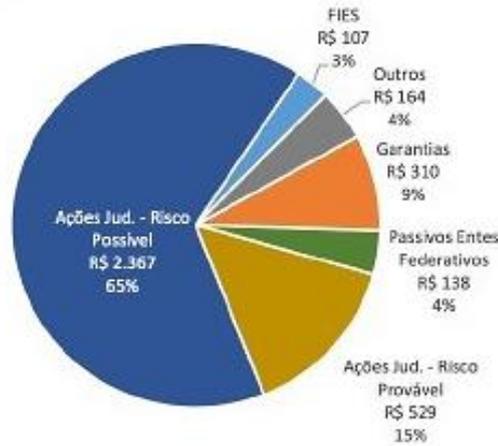
No Brasil, os riscos fiscais são analisados e classificados pela Secretaria do Tesouro Nacional (STN) em dois grupos: riscos macroeconômicos, que se relacionam com mudanças cíclicas ou estruturais na economia, como a dinâmica do PIB, da inflação e do desemprego; e riscos específicos, que possuem origens diversas, como condenações em ações judiciais, acionamento de garantias e desastres naturais. Ademais, os riscos fiscais também são classificados como ativos, se afetam as receitas públicas, ou passivos, se impactam as despesas públicas.

Nos últimos anos, as ações judiciais têm se destacado entre os riscos fiscais específicos do lado passivo. Em 2022, representaram aproximadamente 80% do estoque total de riscos fiscais específicos passivos aos quais a União está exposta, alcançando o montante de 2.896 bilhões de reais (STN, 2022, vide Figura 1).

Ademais, tanto o estoque de riscos fiscais judiciais como as despesas com ações

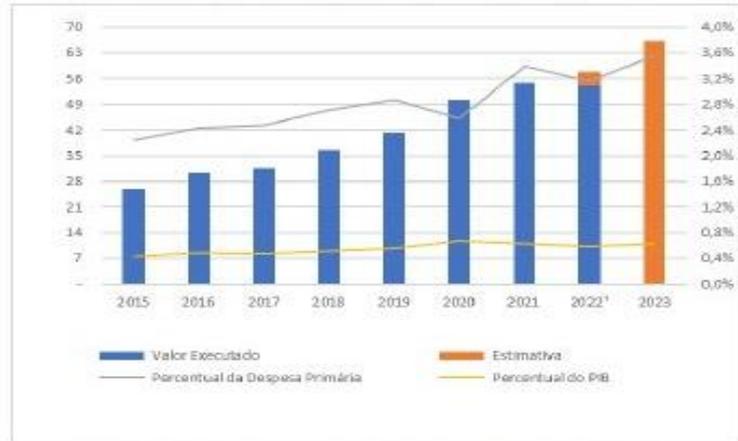
judiciais apresentaram crescimento recente, inclusive em relação ao PIB e à despesa primária da União (STN, 2022, vide Figura 2).

Figura 1 - Fatores de riscos fiscais específicos



Fonte: STN (2022).

Figura 2 - Evolução das despesas federais com ações judiciais



Fonte: STN (2022).

O elevado crescimento das despesas e dos riscos judiciais denota um ambiente jurídico complexo e uma crescente judicialização de temas sensíveis, como previdência, saúde e infraestrutura. Por exemplo, segundo Informe de Previdência Social nº 06/2021, a despesa com benefícios previdenciários decorrentes de decisões judiciais “passou de menos de R\$ 1 bilhão em 1995 para um patamar em torno de R\$ 80 bilhões nos anos de 2019 e 2020, em valores constantes de dezembro de 2020, o que representa um crescimento anual médio de quase 20% a.a” (BRASIL, 2021).

Diante desse contexto, surge evidente interesse social e econômico na previsão das despesas futuras com ações judiciais, isto é, da concretização dos riscos associados a essas ações, a fim de garantir maior segurança e previsibilidade à política fiscal.

A importância dessa previsibilidade foi destacada pelo Decreto nº 11.379, de 12 de janeiro de 2023, que criou o Conselho de Acompanhamento e Monitoramento de Riscos Fiscais Judiciais, com o objetivo de fomentar soluções que fortaleçam o acompanhamento de eventos judiciais capazes de afetar as contas públicas, ampliando a segurança e previsibilidade na gestão fiscal da União.

A bem da verdade, a previsão de riscos judiciais seria útil não apenas para as finanças públicas, mas para a economia como um todo, que ganharia eficiência com isso. Sob a ótica da Análise Econômica do Direito, a incerteza sobre os riscos judiciais representa um déficit de informação e um aumento dos custos de transação para as partes envolvidas, dificultando o alcance de um acordo. E como afirma Coase (1960), a redução dos custos de transação é um elemento crucial para que as partes negociem e alcancem um acordo mutuamente vantajoso, resultando em uma alocação eficiente dos recursos.

Nesse sentido, a previsibilidade de riscos judiciais contribuiria para estabilizar as expectativas dos litigantes, reduzindo a assimetria informacional e incentivando acordos que encerrem antecipadamente ou até mesmo evitem litígios judiciais. A clareza sobre os custos e benefícios da judicialização poderia facilitar a negociação consensual e a busca de meios alternativos de resolução de litígios, como conciliação e arbitragem. Assim, a previsibilidade do tempo de duração dos processos poderia contribuir até mesmo para reduzir os níveis de judicialização.

Portanto, os riscos judiciais impactam não somente as finanças públicas, mas a eficiência da economia como um todo. Sua maior previsibilidade, incluindo-se o tempo de tramitação dos processos judiciais, objeto da presente pesquisa, fortalece o sistema jurídico e as interações econômicas que dele dependem.

## **2.2. Sistema judicial e precatórios no Brasil**

O tema da presente pesquisa demanda uma contextualização normativa e fática para melhor compreensão do sistema judicial e dos precatórios no Brasil.

Existem diferentes formas de resolução de conflitos envolvendo o Estado, as quais

são chamadas “modelos de jurisdição administrativa”. Segundo Di Pietro (2021), esses modelos variam de acordo com a autonomia conferida ao contencioso administrativo para decidir litígios envolvendo o Estado. No modelo francês, por exemplo, a Administração Pública é dotada de um sistema próprio e autônomo para resolver disputas com cidadãos, não submetendo seus conflitos ao crivo do Poder Judiciário independente.

No Brasil, contudo, adota-se o modelo de jurisdição única, no qual as decisões administrativas podem ser revisadas pelo Poder Judiciário, garantindo que nenhum ato estatal esteja acima do controle judicial. Nesse contexto, o Estado atua como parte litigante nos processos judiciais, representado pela advocacia pública, que inclui a Advocacia-Geral da União (AGU), as Procuradorias-Gerais dos Estados e Municípios, entre outras instituições.

Esse modelo implica que o Estado, ao ser condenado judicialmente, está obrigado a cumprir as obrigações previstas na sentença, incluindo o pagamento de valores devidos a particulares por meio de precatórios ou requisições de pequeno valor (RPVs). Esse sistema reflete a submissão do Estado aos princípios da legalidade e da igualdade perante a lei, pilares fundamentais do ordenamento jurídico brasileiro.

O sistema processual brasileiro é marcado pela divisão do trâmite das ações judiciais em duas fases. A fase de conhecimento concentra-se na análise do mérito da demanda e na obtenção de uma decisão judicial que reconheça ou negue o direito pleiteado. A fase de cumprimento, por sua vez, tem por objetivo concretizar a decisão judicial, assegurando a execução da obrigação determinada na sentença.

O marco que separa essas duas fases é o trânsito em julgado, que ocorre quando a decisão judicial não pode mais ser alterada ou questionada por meio de recursos ordinários. Regulado pelo artigo 502 do Código de Processo Civil (Lei nº 13.105/2015)<sup>1</sup>, este conceito é central no presente estudo, pois sua data é utilizada como marco inicial da mensuração do tempo de duração das ações judiciais, restrita à fase de cumprimento.

Nesta altura, cumpre apontar a existência do regime de precatórios, instituído para regular os pagamentos judiciais devidos por entes públicos no Brasil. Introduzido no ordenamento jurídico brasileiro pela Constituição de 1934 e consolidado na Constituição

---

<sup>1</sup> Art. 502. "Denomina-se coisa julgada material a autoridade que torna imutável e indiscutível a decisão de mérito, não mais sujeita a recurso.

Federal de 1988 (art. 100)<sup>2</sup>, o regime preconiza que os referidos débitos devem ser objeto de requisições judiciais (precatórios), a fim de que sejam previstos em leis orçamentárias e pagos no exercício financeiro seguinte, em ordem cronológica da apresentação<sup>3</sup>.

O regime de precatórios constitui um ambiente propício para o presente estudo, na medida em que a necessidade de previsão em leis orçamentárias cria um fluxo de dados estruturados sobre ações judiciais que resultaram em pagamentos pelo Estado. No plano federal, Leis de Diretrizes Orçamentárias (LDOs) frequentemente demandam que os precatórios sejam acompanhados de diversos dados sobre as ações judiciais que lhes deram origem, como número identificador único, vara, tribunal, assunto, órgão, data de trânsito em julgado, entre outros, relevantes para o presente estudo<sup>4</sup>.

Cumprе ressaltar que a inclusão do precatório na Lei Orçamentária Anual (LOA) não é sinônimo de pagamento. Para que o credor receba os valores devidos, é necessário o depósito judicial e o posterior levantamento, eventos sujeitos a diversas intercorrências, como disputas entre beneficiários, não localização do credor ou herdeiros, bloqueios judiciais e inadimplência do ente devedor.

Ademais, alterações legislativas também podem influir sobre o pagamento efetivo de precatórios e até mesmo sobre a destinação de recursos orçamentários para a sua satisfação. Como exemplo, pode-se citar a Lei nº 13.463, de 6 de julho de 2017, que previu o cancelamento de precatórios não levantados, com possibilidade de solicitação de reexpedição pelo beneficiário. Outro exemplo consiste na Emenda Constitucional nº 114, de 16 de dezembro de 2021, que criou um limite para alocação recursos orçamentários destinados à satisfação de precatórios.

Nesse contexto, a presente pesquisa elegeu como marco final do tempo de duração

---

<sup>2</sup> Art. 100. Os pagamentos devidos pelas Fazendas Públicas Federal, Estaduais, Distrital e Municipais, em virtude de sentença judiciária, far-se-ão exclusivamente na ordem cronológica de apresentação dos precatórios e à conta dos créditos respectivos, proibida a designação de casos ou de pessoas nas dotações orçamentárias e nos créditos adicionais abertos para este fim.

<sup>3</sup> Cabe ressaltar que a própria CF/88 prevê em seu art. 100, § 3º, exceção ao regime de precatórios, relativa à “obrigações definidas em leis como de pequeno valor”. No plano federal, a Lei nº 10.259, de 12 de julho de 2001, estabelece o limite de 60 salários mínimos para obrigações de pequeno valor (arts. 3º e 17, § 1º).

<sup>4</sup> Conforme conceito estabelecido no art. 165 da CF/88, “a lei de diretrizes orçamentárias compreenderá as metas e prioridades da administração pública federal, estabelecerá as diretrizes de política fiscal e respectivas metas, em consonância com trajetória sustentável da dívida pública, orientará a elaboração da lei orçamentária anual, disporá sobre as alterações na legislação tributária e estabelecerá a política de aplicação das agências financeiras oficiais de fomento”. Para um exemplo, vide Lei nº 14.971, de 29 de dezembro de 2023, que “dispõe sobre as diretrizes para a elaboração e a execução da Lei Orçamentária de 2024 e dá outras providências”. Em seu artigo 31, a citada lei prevê os dados que devem acompanhar as relações de precatórios.

das ações judiciais o ano de previsão em lei orçamentária, conforme inclusão em relação anual de precatórios elaborada pelo Poder Judiciário.

Primeiramente, porque esse evento permite trabalhar diretamente com as relações anuais de precatórios do Poder Judiciário, não havendo dados estruturados semelhantes em relação aos pagamentos individualmente considerados. Em segundo lugar, pois é um evento menos afetado pelas intercorrências acima descritas em relação ao pagamento, cabendo destacar que a limitação proposta pela EC nº 114/2021 não afetou as relações de precatórios elaboradas pelo Poder Judiciário, mas apenas limitou os recursos incluídos em leis orçamentárias. Por fim, a inclusão em lei orçamentária é um dos marcos mais relevantes para planejamento orçamentário e fiscal.

Assim, o ano de inclusão do precatório em lei orçamentária consiste em um evento relevante e um marco útil para mensuração do tempo de duração das ações judiciais.

Para além do regime de precatórios, características próprias do sistema judicial brasileiro podem exercer influência direta sobre o tempo de tramitação de ações judiciais, sendo relevante expor seus principais aspectos para melhor compreensão do problema.

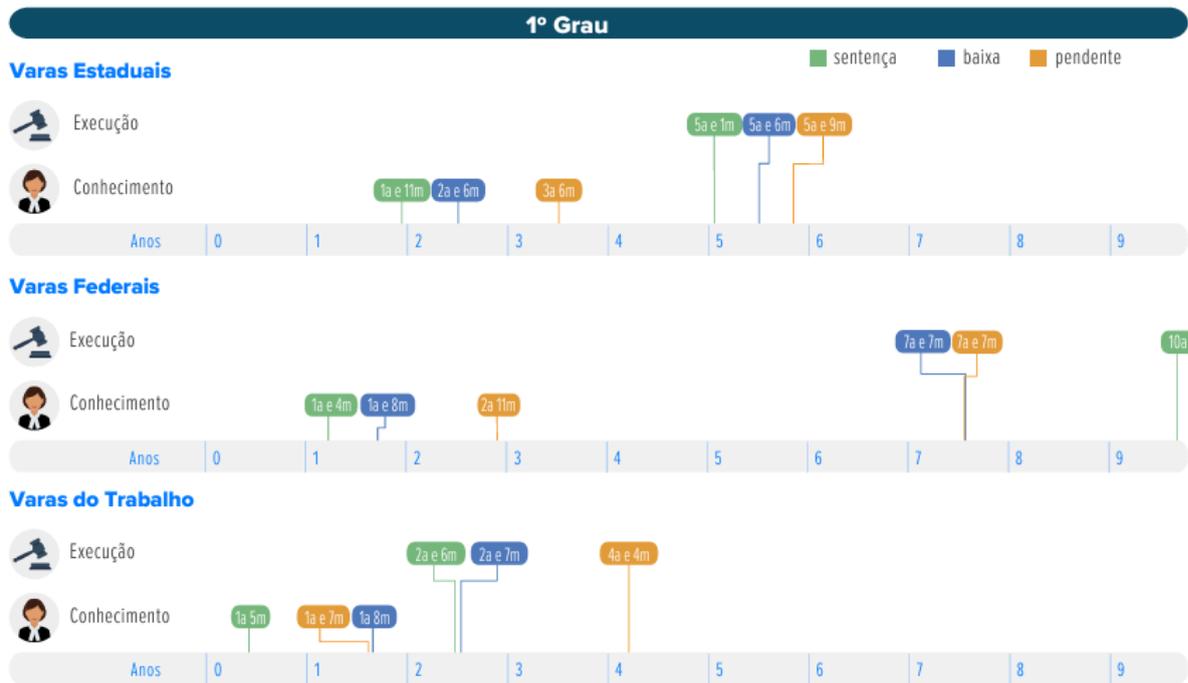
O elevado volume de ações judiciais é um dos fatores mais emblemáticos do sistema brasileiro. Conforme aponta Vasconcelos (2023), no Brasil são ajuizados 7 processos cíveis por ano para cada 100 habitantes, ao passo que a média na Europa é de 2,5 processos para cada 100 habitantes. Este cenário sobrecarrega o sistema, resultando em maior tempo de tramitação das ações.

Uma característica marcante do acervo pendente no Judiciário brasileiro é a grande participação de processos em fase de execução, que atingiu 52,8% no ano de 2023, segundo o Relatório Justiça em Números (CNJ, 2024). Ainda de acordo com o relatório, o tempo de tramitação da fase de execução tem se mostrado muito superior ao da fase de conhecimento, em especial na Justiça Federal, como se verifica na Figura 3. O cumprimento de sentenças é, portanto, um grande gargalo do sistema judicial.

Outro aspecto crucial a se ressaltar para a presente pesquisa consiste na presença do Estado como parte litigante. A União, estados, municípios e suas autarquias e fundações estão envolvidos em grande parte dos processos, como autores ou réus. Essa realidade decorre do fato de que a atuação estatal afeta diretamente inúmeros direitos e relações jurídicas, refletindo-se na diversidade de assuntos e órgãos envolvidos nas ações judiciais. Segundo o Painel de Grandes Litigantes do CNJ (2024), em 31/10/2024, o

segmento de atividade “Administração Pública, Defesa e Seguridade Social” respondia por 13,8% dos processos no polo passivo e 28,26% dos processos no polo ativo, em relação ao total de processos pendentes.

Figura 3 – Tempo médio de tramitação de processos judiciais



Fonte: CNJ (2024).

A estrutura do Poder Judiciário brasileiro também possui peculiaridades dignas de nota. Composto por diversas justiças especializadas, como a Justiça Federal, Justiça Estadual, Justiça do Trabalho e Justiça Eleitoral, o sistema divide-se ainda em múltiplas instâncias e jurisdições geográficas. Cada uma das divisões possui competências próprias e é dotada de grande autonomia, gerando um sistema altamente descentralizado e pouco coordenado, como bem descrito por Almeida (2015).

Nesse contexto, cumpre descrever algumas medidas e mecanismos do sistema judicial brasileiro criados para acelerar a tramitação processual, tendo em vista a sua possível influência sobre a variável de interesse da presente pesquisa.

No intuito de enfrentar o desafio do alto volume de processos e a morosidade judicial, o Conselho Nacional de Justiça (CNJ), órgão de controle e planejamento estratégico do Poder Judiciário, instituiu o sistema de metas judiciais. Criado em 2009,

esse sistema define metas anuais para os tribunais, buscando uniformizar o desempenho e reduzir os gargalos processuais.

É comum que as metas judiciais sejam definidas em função de características dos processos, como a data de ajuizamento e, no caso da fase de execução, a data de trânsito em julgado. Essas medidas tendem a uniformizar o tempo de tramitação e os acervos de diversas varas e tribunais, resultando em tempos de duração similares para processos com características semelhantes, o que pode ser explorado no problema preditivo em comento.

Outro mecanismo fundamental para promoção da celeridade processual consiste no sistema de precedentes, aqui designado como o conjunto de normas que atribuem força vinculante a julgamentos de Tribunais Superiores, como a sistemática de recursos extraordinários e especiais repetitivos<sup>5</sup>. Como destaca Marinoni et al. (2017), o sistema de precedentes desempenha um papel crucial na gestão da litigiosidade em massa, ao contribuir para a uniformidade e agilidade na resolução de questões jurídicas idênticas. Considerando que o sistema de precedentes permite o julgamento conjunto de ações que compartilham o mesmo objeto ou controvérsia jurídica, pode vir a gerar o encerramento concomitante de ações judiciais com assuntos ou órgãos semelhantes, o que também se mostra relevante para a hipótese levantada na presente pesquisa.

Portanto, o sistema judicial brasileiro apresenta características singulares que influenciam diretamente os prazos processuais. O alto volume de ações, a fragmentação da estrutura judiciária, o papel preponderante do Estado como parte litigante e as medidas e mecanismos criados para promover celeridade processual constituem fatores que devem ser considerados na análise sobre o tempo de duração das ações judiciais. Estes elementos oferecem uma base rica para compreender as dinâmicas do sistema e justificar a escolha de variáveis para estudos sobre a duração dos processos no Brasil.

### **2.3. Modelo institucional de análise de riscos fiscais judiciais**

A análise e classificação de riscos fiscais judiciais no Brasil está, historicamente, regulamentada em portarias da Advocacia-Geral da União (AGU), que estabelecem os critérios e procedimentos para avaliação de demandas judiciais que possam representar riscos financeiros à União, suas autarquias e fundações públicas.

---

<sup>5</sup> Vide artigo 1.036 e seguintes do CPC.

Atualmente, a Portaria Normativa AGU nº 68, de 18 de novembro de 2022, organiza o processo de classificação e estimativa desses riscos. As demandas judiciais são classificadas de acordo com a probabilidade de perda em três categorias:

1. **Risco provável:** Inclui ações judiciais com decisão desfavorável à Fazenda Pública em instâncias superiores, como o Supremo Tribunal Federal (STF) e o Superior Tribunal de Justiça (STJ), quando já não restam possibilidades relevantes de reversão. Estas ações são provisionadas no balanço patrimonial da União.
2. **Risco possível:** Abrange ações pendentes de julgamento em instâncias superiores ou cujas decisões desfavoráveis ainda podem ser revertidas, não sendo, portanto, objeto de provisão contábil. Essas demandas constam no Anexo de Riscos Fiscais da Lei de Diretrizes Orçamentárias (LDO) e em notas explicativas do Balanço Geral da União (BGU).
3. **Risco remoto:** Engloba ações com baixa probabilidade de perda para a Fazenda Pública, que não exigem provisionamento nem divulgação específica.

O atual modelo de análise de riscos fiscais judiciais também conta com um recorte baseado em valores, tendo o art. 2º da Portaria Normativa AGU nº 68/2022 especificado que “*serão consideradas as ações judiciais cujo eventual impacto financeiro seja estimado em valor igual ou superior a R\$ 1.000.000.000,00 (um bilhão de reais)*”. O parágrafo único acrescenta que o impacto pode ser apurado em relação a temas, cuja multiplicidade de ações com a mesma questão de direito alcancem o citado montante.

Outro ponto relevante a ser ressaltado consiste na forma de estimativa do impacto financeiro, que pode abranger tanto o impacto específico de ações efetivamente ajuizadas, quanto despesas administrativas futuras decorrentes da decisão judicial. Essa abordagem ampla permite uma visão mais abrangente dos potenciais efeitos financeiros de demandas judiciais sobre o orçamento público.

A presente pesquisa adota uma abordagem mais específica e focada no problema da previsão de despesas com precatórios. Nesse sentido, concentra-se exclusivamente em ações judiciais já ajuizadas e que se encontram em fase de execução, ou seja, aquelas em que já houve condenação transitada em julgado e cujo valor deve ser pago por meio de inclusão em lei orçamentária (LOA) na forma de precatórios. Essa delimitação exclui do escopo de análise passivos administrativos futuros ou ainda não judicializados, bem como ações que se encontram em fase de conhecimento.

A abordagem específica aqui proposta é particularmente adequada para a previsão de gastos com precatórios, uma vez que trabalha diretamente com dados sobre ações judiciais em estágio avançado. A inclusão em LOA e a expedição de precatórios dependem de informações concretas, como valores definidos e dados processuais, permitindo maior precisão nas estimativas de despesas futuras.

Por outro lado, essa escolha metodológica implica deixar de lado outros aspectos importantes das despesas com ações judiciais, como o impacto sobre a despesa corrente decorrente do cumprimento de obrigações de fazer ou eventuais quedas de arrecadação associadas a litígios tributários.

Embora limitada em escopo, essa estratégia se justifica pelo objetivo específico da pesquisa: analisar e prever despesas com precatórios. O foco em ações judiciais em fase de execução e com valores já definidos contribui para a obtenção de estimativas mais precisas, ainda que a exclusão de outros fatores de risco impeça uma análise mais ampla das implicações fiscais das demandas judiciais como um todo.

#### **2.4. Modelos preditivos e *machine learning***

A presente pesquisa se insere na literatura sobre previsão e análise de riscos com métodos estatísticos e computacionais, em especial algoritmos de *machine learning*.

Como aponta Varian (2014), o grande volume de dados da era digital transformou a econometria, exigindo novas ferramentas e abordagens para manipulação e análise de dados. Especificamente para problemas de previsão, algoritmos de aprendizado de máquina têm se mostrado métodos mais eficientes e flexíveis para capturar relações de diversas formas entre variáveis e alvo, propiciando previsões mais precisas.

Modelos econométricos tradicionais objetivam estimar parâmetros de variáveis independentes (X), que expliquem a variação observada na variável dependente (y), por meio de uma função de coeficientes, normalmente lineares. Um dos métodos mais usados para estimar os referidos parâmetros consiste nos “mínimos quadrados ordinários”, em que a relação linear entre as variáveis explicativas e o alvo é definida de forma a minimizar o quadrado do erro, tornando-o ortogonal à reta, ao plano ou ao hiperplano que define a solução do problema<sup>6</sup>.

---

<sup>6</sup> A ortogonalidade refere-se ao fato de que o resíduo (erro) resultante é perpendicular à superfície ajustada,

Bishop (2006) destaca que, ainda que modelos econométricos tradicionais, como regressão linear e logística, possam ser usados de forma a capturar relações não lineares entre variáveis preditoras e alvo (a linearidade é apenas nos parâmetros), a definição prévia de funções de base fixas<sup>7</sup> impõe restrições que muitas vezes resultam em previsões imprecisas, especialmente em casos de alta dimensionalidade dos dados.

Essa limitação se agrava devido à maldição da dimensionalidade (*curse of dimensionality*), fenômeno que descreve como o aumento das dimensões das variáveis independentes expande exponencialmente o espaço de possíveis combinações, tornando os dados "esparcos" e dificultando a generalização. Segundo Bishop (2006), modelos lineares enfrentam especial dificuldade nesse cenário, porque o aumento do espaço resulta em modelos superajustados ou incapazes de capturar as interações mais relevantes entre as variáveis, comprometendo a qualidade das previsões.

Já os modelos de *machine learning* apresentam diversas outras abordagens para tentar analisar a relação entre as variáveis independentes e dependente, podendo ser agrupados de acordo com sua arquitetura. Para ilustrar as diferentes abordagens, abaixo são elencadas algumas dessas categorias e uma breve descrição de seus métodos.

Modelos de regularização, como Ridge e LASSO, partem de modelos lineares tradicionais e introduzem penalizações para selecionar variáveis mais relevantes. Modelos bayesianos e probabilísticos, como redes bayesianas, utilizam inferência estatística para modelar incertezas e distribuições de probabilidade. Modelos de árvores criam sucessivas regras de decisões binárias, cada uma sobre uma única variável independente, de forma a reduzir incrementalmente a variância do alvo. Modelos mistos ou conjuntos (*ensemble*), como Random Forests e Gradient Boosting, combinam previsões de múltiplos modelos, utilizando subamostragem, para melhorar a precisão e a estabilidade. Modelos de redes neurais utilizam diferentes combinações lineares das variáveis independentes e exploram relações não lineares do alvo em função dessas combinações (HASTIE; TIBSHIRANI; FRIEDMAN, 2017).

Um dos motivos para a maior eficiência preditiva dos modelos de *machine learning* consiste na introdução de técnicas incompatíveis com hipóteses clássicas dos

---

garantindo que o ajuste seja ótimo dentro da suposição de linearidade.

<sup>7</sup> A definição prévia de funções de base fixas refere-se à necessidade de especificar, de forma antecipada, as transformações das variáveis independentes que serão usadas no modelo, como polinômios ou funções seno e cosseno. Essa abordagem, embora útil em cenários bem definidos, pode limitar a capacidade do modelo de se adaptar a padrões complexos ou desconhecidos nos dados.

modelos econométricos tradicionais, focados em inferir propriedades estatísticas dos parâmetros estimados. Embora as suposições tradicionais sejam necessárias para realização de inferência estatística, muitas vezes resultam em modelos que geram previsões mais imprecisas (Hastie; Tibshirani; Friedman, 2017).

De fato, Mullainathan e Spiess (2017) destacam a distinção entre o foco de modelos de *machine learning* em prever a variável dependente e o objetivo tradicional da econometria de inferir parâmetros que descrevem a relação entre variáveis. Assim, é preciso ter em mente que, embora métodos de aprendizado de máquina possam encontrar padrões complexos nos dados, eles não são ideais para estimar coeficientes com propriedades inferenciais robustas.

No mesmo sentido, Breiman (2001) identifica duas abordagens principais na modelagem estatística: a cultura tradicional, centrada em modelos probabilísticos para explicar os dados, e a cultura algorítmica, focada em métodos computacionais para prever com precisão. Segundo o autor, a abordagem tradicional privilegia modelos simples e interpretáveis (como regressão linear), mas muitas vezes não captura toda a complexidade dos dados, resultando em baixa acurácia preditiva.

No artigo “*To Explain or to Predict?*”, Shmueli (2010) demonstra como viés e variância são propriedades valoradas de forma distinta por modelos explicativos e preditivos, o que influencia o desempenho e a adequação de cada tipo de modelo. Em modelos explicativos, o foco está na minimização do viés, buscando estimativas precisas dos coeficientes e uma compreensão clara das relações causais entre as variáveis, mesmo que isso leve a uma maior variância nos resultados. Já em modelos preditivos, a prioridade é o equilíbrio entre viés e variância, pois o objetivo é maximizar a capacidade de generalização para dados fora da amostra. Isso muitas vezes implica aceitar um pouco mais de viés nos parâmetros para reduzir a variância e melhorar o desempenho preditivo em cenários futuros.

Dessa forma, a literatura acima exposta denota o potencial e a adequação dos modelos de *machine learning* para enfrentamento do problema da presente pesquisa, de caráter essencialmente preditivo. A sua utilização, porém, deve levar em conta vantagens e limitações impostas pelo referidos métodos, analisando com cautela a interpretabilidade e o potencial de realizar inferências a partir dos modelos.

## 2.5. *Machine learning* aplicada a problemas jurídicos

Estudos recentes demonstram como técnicas de aprendizado de máquina podem ser aplicadas para capturar padrões em dados históricos e fornecer previsões sobre ações judiciais, contribuindo diretamente para a gestão de riscos.

No livro *Artificial Intelligence and Legal Analytics: New Tools for Law Practice in the Digital Age*, Ashley (2017) descreve como *machine learning* e inteligência artificial estão sendo aplicados no âmbito jurídico, para gerar modelos computacionais que reproduzam o raciocínio jurídico e prever desfechos de ações judiciais.

Com efeito, é prolífica a literatura sobre modelos de *machine learning* que visam prever o desfecho de ações judiciais. Katz, Bommarito e Blackman (2017), por exemplo, propuseram um modelo para prever o comportamento da Suprema Corte dos Estados Unidos, usando o algoritmo *random forest* e dados de ações anteriores aos julgamentos, atingindo aproximadamente 70% de acurácia na previsão do desfecho do caso e 72% na previsão dos votos dos Ministros.

Aletras et al (2016) desenvolvem um modelo com propósito semelhante, para prever os resultados de julgamentos da Corte Europeia de Direitos Humanos, utilizando apenas conteúdos textuais como variáveis preditoras e técnicas de processamento de linguagem natural (PLN) e *machine learning*. O modelo apresentou 79% de acurácia média, denotando a robustez dos métodos aplicados.

Alarie, Nibblet e Yoon (2017) também se voltam para a previsão de desfechos de casos judiciais, focalizando em um tema específico, de grande divergência e variabilidade de julgamentos, a saber: qualificar um trabalhador como empregado ou contratante independente, distinção relevante para a incidência de normas tributárias e impostos. Os autores reportam uma acurácia de 90% das previsões nesse problema específico.

A literatura acadêmica brasileira também já apresenta contribuições sobre o tema. Recentemente, Jacob de Menezes-Neto e Clementino (2022) desenvolveram um modelo de *deep learning* para prever os resultados de julgamentos de apelações, direcionadas ao Tribunal Regional Federal da 5ª Região do Brasil. O modelo apresentou performance significativamente superior à de *experts* humanos, nos testes realizados pelos autores.

Outros exemplos de trabalhos semelhantes no contexto brasileiro consistem nas dissertações desenvolvidas por Barnabé (2022) e Sousa (2021). Os referidos trabalhos compararam a performance de diferentes modelos de *machine learning* para prever os

desfechos de ações judiciais em que instituições financeiras figuravam no polo passivo, com o objetivo de melhor constituir provisões para pagamento das condenações.

Como se vê, o problema de previsão do desfecho de ações tem sido bem explorado na literatura, que reporta bons resultados para a acurácia preditiva de modelos de *machine learning* nesses casos. No entanto, permanece pouco explorado o problema de previsão do tempo de duração do processo judicial, também relevante para a gestão de riscos.

A corroborar a existência da lacuna acima apontada, pode-se citar Silva et al. (2023) que em recente trabalho investigaram a utilização de jurimetria<sup>8</sup> e análise preditiva no contexto jurídico. Os autores realizam uma revisão sistemática de literatura, analisando 40 artigos publicados entre 2011 e 2021 sobre o tema. Os artigos foram classificados em categorias de acordo com os objetivos de utilização das novas tecnologias: identificação de padrões, tendências e fontes legais; previsão de resultados de decisões judiciais; mecanismos de automação e assistência para magistrados; avanços tecnológicos para a sociedade; e considerações éticas. Nenhum dos artigos revisados, porém, se debruça sobre a previsão do tempo de duração dos processos judiciais.

A ausência de estudos focados na previsão do tempo de duração de processos judiciais representa uma lacuna significativa na literatura, considerando que essa variável é essencial para a gestão de riscos judiciais e para a alocação eficiente de recursos em instituições públicas e privadas.

A presente pesquisa busca abordar essa lacuna utilizando modelos preditivos baseados em *machine learning*, já amplamente utilizados para prever os desfechos de ações judiciais e promover maior eficiência no processo legal. No entanto, o problema de previsão do tempo de duração do processos judiciais conta com desafios únicos, que tem sido explorados em outros campos por meio da literatura de análise de sobrevivência e modelos de dados longitudinais. Esse fundamentos serão detalhados no próximo tópico.

## **2.6. Análise de sobrevivência e modelos de dados longitudinais**

A análise de sobrevivência, também conhecida como análise de duração ou de tempo de vida, é uma área da estatística voltada para modelar o tempo até a ocorrência de um evento de interesse.

---

<sup>8</sup> Ciência que busca entender os processos legais e fatos jurídicos por meio de modelos estatísticos, segundo definição apresentada no artigo (Loevinger, 1949; Oliveira, 2017 apud Silva et al, 2023).

Essa metodologia tem sido amplamente utilizada em áreas como a medicina, onde o evento de interesse pode ser o tempo de sobrevivência de pacientes diagnosticados com uma doença, com ou sem um tratamento proposto. Na engenharia, essa técnica é aplicada ao estudo da durabilidade de componentes, com o objetivo de estimar o tempo até a falha dos equipamentos. Na sociologia, por sua vez, técnicas semelhantes são aplicadas para aferir a duração de casamentos e outros fenômenos sociais (Lawless, 2003).

Dois dos maiores desafios em análise de sobrevivência são os fenômenos de censura e truncamento de dados, que impactam diretamente a qualidade de inferências e previsões, dificultando até mesmo a avaliação dos modelos.

A censura ocorre quando não se observa o evento de interesse para algumas unidades da amostra, o qual ainda poderia ocorrer em algum momento no futuro (censura à direita), ou mesmo já ter ocorrido no passado (censura à esquerda), fora do período observacional. Por exemplo, em um estudo clínico interessado no tempo de cura, pacientes não curados até o final do período de observação estão censurados à direita; por outro lado, em um estudo sobre idade do primeiro uso de drogas, entrevistados que admitem o uso prévio, mas sem precisar a idade, estão censurados à esquerda (Klein; Moeschberger, 2006).

Já a truncagem ocorre quando certas observações estão completamente ausentes da amostra, por algum viés de seleção ou indisponibilidade de dados, sendo não observados indivíduos que experimentaram o evento antes (truncagem à esquerda) ou que ainda não chegaram a experimentar o evento (truncagem à direita). Por exemplo, em um estudo de tempo de vida de pacientes com uma doença grave, indivíduos sem diagnóstico prévio tornam a amostra truncada à esquerda; já em um estudo de tempo até a falha de equipamentos, a ausência de componentes que não chegaram a falhar torna os dados truncados à direita (Klein; Moeschberger, 2006).

A presença de censura e truncagem introduz vieses na amostra que dificultam a realização de inferências estatísticas robustas, previsões acuradas. Kaplan e Meier (1958) abordaram esses desafios e introduziram a estimativa não paramétrica da função de sobrevivência, que permite calcular a probabilidade de um evento não ter ocorrido até um determinado momento, mesmo na presença de dados censurados ou truncados. Esse método é amplamente utilizado para modelar dados com observações incompletas, como ocorre nos estudos sobre tempo de duração.

Os modelos de análise de sobrevivência evoluíram com a introdução dos modelos semiparamétricos por Cox (1972), cujo modelo de riscos proporcionais se tornou um dos mais utilizados na literatura sobre o tema. A flexibilidade desse modelo permite analisar a relação entre variáveis explicativas e o tempo de sobrevivência sem exigir pressupostos sobre a forma funcional da distribuição subjacente dos tempos de evento. Essa característica torna o modelo de Cox particularmente poderoso para aplicações em que a estrutura exata da distribuição de sobrevivência é desconhecida ou complexa demais para ser parametrizada de maneira prática.

Não obstante a flexibilidade do modelo de Cox, ele ainda pressupõe que a razão de riscos entre dois indivíduos permanece constante ao longo do tempo, o que facilita a realização de inferências estatísticas, mas pode limitar sua capacidade preditiva.

Nos últimos anos, métodos de aprendizado de máquina têm sido integrados à análise de sobrevivência para superar limitações de modelos tradicionais. Métodos como árvores de sobrevivência e *Random Survival Forests* foram projetados para incorporar censura e truncamento nos dados, adaptando conceitos clássicos de *machine learning* ao contexto de análise de sobrevivência. Esses modelos tendem a apresentar vantagens em cenários de dados de alta dimensionalidade ou necessidade de maior poder preditivo.

Impõe-se esclarecer que a base de dados da presente pesquisa é truncada à direita, pois inclui apenas processos judiciais que já se encerraram. Isso dispensa a necessidade de modelagens específicas para censura, já que todas as amostras tem tempo de duração conhecido, mas exige cautela na interpretação dos resultados, uma vez que os processos ainda em andamento não estão representados, o que pode limitar a generalização dos modelos desenvolvidos.

Assim, embora as técnicas de Kaplan-Meier, o modelo de Cox e os algoritmos de *machine learning* adaptados à análise de sobrevivência não sejam diretamente aplicados neste estudo, devido à natureza truncada dos dados, sua apresentação é relevante para situar a presente pesquisa na literatura e suscitar métodos aplicáveis a estudos futuros.

Além da análise de sobrevivência, modelos de dados longitudinais, também chamados de dados empilhados ou dados em painéis, fornecem um arcabouço teórico e técnicas importantes para analisar variáveis que mudam ao longo do tempo.

Diferentemente dos modelos transversais, que consideram uma única observação por unidade, os modelos longitudinais trabalham com múltiplas observações ao longo do

tempo para a mesma unidade, permitindo explorar a dinâmica temporal e a evolução das variáveis. Esses modelos são aplicados em áreas como economia, epidemiologia e ciências sociais, devido à sua capacidade de lidar com estruturas de dados que combinam observações repetidas para o mesmo indivíduo ou unidade ao longo do tempo.

Wooldridge (2010) e Hsiao (2022) destacam que a principal vantagem dos modelos de dados longitudinais é a capacidade de capturar simultaneamente a variação temporal e as diferenças entre indivíduos. Essa característica possibilita um controle mais robusto de heterogeneidade não observada, reduzindo potenciais vieses de estimação que surgem em análises baseadas apenas em dados transversais.

No contexto jurídico, os modelos longitudinais também permitem a análise de interações complexas entre variáveis temporais e estruturais. Por exemplo, é possível avaliar como o tempo de julgamento é impactado por mudanças no volume de processos na vara ou tribunal. Isso fornece informações valiosas para a gestão do sistema judiciário, permitindo identificar gargalos e propor intervenções baseadas em evidências.

Portanto, a combinação de análise de sobrevivência com modelos longitudinais apresenta um potencial significativo para ampliar a compreensão e a previsão de processos judiciais. A análise de sobrevivência foca no tempo até a ocorrência de eventos específicos e os modelos longitudinais complementam essa abordagem ao capturar a evolução de variáveis relacionadas ao longo do tempo. Essa integração permite uma abordagem analítica mais rica, adaptada à complexidade dos dados judiciais e às demandas do sistema jurídico moderno.

Os métodos descritos nesta seção oferecem uma base sólida para abordar o problema central da presente pesquisa: prever a duração de processos judiciais. A combinação de técnicas de análise de sobrevivência e modelos longitudinais, integrados a algoritmos de aprendizado de máquina, permite abordar de forma robusta a complexidade do problema de previsão da duração de processos judiciais.

### 3. METODOLOGIA

A presente seção expõe a metodologia de pesquisa adotada, de modo a descrever bases e fontes de dados, variáveis independentes e dependentes, modelos, cenários de validação, algoritmos e métricas avaliação.

#### 3.1. Bases de dados

##### 3.1.1. Bases de precatórios

Foram utilizadas bases de dados de precatórios requisitados pelos Tribunais Regionais Federais, para pagamento de valores devidos por entes públicos federais (União, Fazenda Nacional, autarquias e fundações públicas), incluídos em relações anuais do Poder Judiciário, para previsão em leis orçamentárias dos anos de 2012 a 2024.

As informações foram originalmente fornecidas pela Advocacia-Geral da União e pela Câmara dos Deputados como fontes independentes, o que possibilitou o cruzamento de dados para complementar informações, corrigir inconsistências e eliminar registros em duplicidades, construindo uma base unificada e robusta.

A base fornecida pela AGU compreendia os anos de 1999 a 2024, mas apenas os precatórios de 2012 em diante incluíam de forma consistente a data de trânsito em julgado da ação judicial correspondente ao precatório. O referido dado é essencial para a pesquisa, pois determina o marco inicial da variável de tempo que se pretende prever.

A base da Câmara dos Deputados compreendia os anos de 2012 a 2024 e, embora não contivesse dados sobre a data de trânsito em julgado, apresentava maior consistência nos dados de assunto, os quais estavam deteriorados em vários anos na base da AGU.

Considerando a disponibilidade de dados, o estudo optou por se restringir ao recorte temporal de 2012 a 2024, anos para os quais havia informações compartilhadas em ambas as bases e dados consistentes sobre a data de trânsito em julgado.

Inicialmente foi realizada uma limpeza nas bases de precatórios, a fim de eliminar registros duplicados, checar e corrigir contradições e complementar dados faltantes dos precatórios. Para tanto, a base da AGU foi utilizada como principal, por conter os dados essenciais de data de trânsito em julgado e apresentar menos duplicidades de registros. Assim, a base da Câmara dos Deputados foi utilizada de forma complementar, para aferir

contradições e preencher dados faltantes.

Ambas as bases indicavam o número de autuação do precatório, o que permitia identificar os mesmos precatórios em ambas as bases. Além desse identificador, os dados mais relevantes presentes em ambas as bases para cada precatório eram: tribunal, vara, assunto, órgão, valor, ação originária e ano do precatório.

O cruzamento de dados foi realizado e, para cada precatório, os dados de vara, assunto e órgão foram checados e atribuídos pelo critério de maior frequência, desde que não fossem uma categoria indefinida. Os dados contraditórios eram irrisórios, da ordem de 0,1% dos registros, tendo o procedimento sido mais útil para complementar dados faltantes de assunto e órgão na base da AGU.

Após os procedimentos iniciais acima descritos, a base de precatórios unificada apresentava 1.337.302 registros de precatórios federais, relativos ao período de 2012 a 2024, validados em duas fontes independentes.

### *3.1.2. Criação da base de ações originárias*

Neste ponto, é preciso esclarecer dois conceitos: precatório, que consiste em uma requisição de pagamento emitida dentro de uma ação judicial; e ação judicial originária, o processo judicial no âmbito do qual podem ser requisitados um ou mais precatórios, inclusive ao longo de anos diferentes.

A presente pesquisa visa a avaliar se metadados das ações judiciais podem ser úteis para prever o tempo de duração até ocorrência do evento precatório. Por esse motivo, a partir dos dados da base de precatórios, criou-se uma base de ações judiciais originárias correspondente, a fim de permitir o estudo de suas características e a previsão do tempo de duração até a ocorrência do evento de interesse.

Considerando que múltiplos precatórios podem se originar da mesma ação judicial, o número de ações é significativamente menor, atingindo 744.959 registros. Além disso, a correspondência de múltiplos precatórios à mesma ação ocasionou em alguns casos conflitos de classificação nos metadados, os quais foram resolvidos pelo critério de categoria mais frequente nos registros, desde que não fosse indefinida.

Considerando os objetivos da pesquisa, foram excluídas da formatação final da base de ações originárias os registros sem data de trânsito em julgado, pela inviabilidade

de aferir o marco inicial do tempo de duração, e ações que geraram precatórios em mais de um ano, pela multiplicidade de tempos de duração até a geração de cada precatório. As referidas exclusões alcançaram 60.780 ações, aproximadamente 8% do total.

Por fim, foram também excluídas as ações com precatório do ano de 2012, tendo em vista que a transformação de algumas variáveis independentes categóricas, descrita detalhadamente no tópico 3.2, utiliza dados de precatórios passados, inexistentes para o primeiro ano da série. Essa exclusão abrangeu 31.756 ações (cerca de 4% do total). Assim, a base de ações originárias possui 652.423 registros em sua versão final.

### *3.1.3. Criação da base de observações anuais*

O problema de previsão do tempo de duração dos processos não necessariamente se situa no início da linha temporal. De fato, é realista a situação em que se deseja prever a duração final de um processo que já se iniciou, de modo que, nesse caso, encontra-se disponível uma informação de grande valia e que não pode ser desprezada: a duração atual do processo no momento considerado.

Com efeito, sem considerar a variável de duração atual do processo, é possível que o modelo preditivo gere previsões absurdas para ações judiciais em curso, como tempo de duração final igual ou menor do que aquele já decorrido desde o início.

Para lidar com essa realista situação de previsão, foi criada uma base de observações anuais das ações originárias, onde cada registro representa uma observação da mesma ação judicial, a cada ano desde o seu trânsito em julgado.

A base de observações anuais incorpora dois novos dados para cada registro: o ano da observação, que serve apenas de índice complementar ao número da ação originária; e a duração da observação, que consiste na diferença entre o ano da observação e ano de trânsito em julgado, sendo tratada como variável independente nos modelos longitudinais.

A instanciação anual de cada ação originária, desde o ano de seu trânsito em julgado, ampliou o número de registros para 2.186.382. Após esse procedimento, foram excluídas as ações cujas observações fossem anteriores a 2012, pois, conforme explicado anteriormente, a transformação de algumas variáveis independentes categóricas, descrita detalhadamente no tópico 3.2, utiliza dados de precatórios pagos no passado, inexistentes para 2012. Assim, a base de observações anuais final possui 1.745.605 registros.

### 3.2. Variáveis independentes

As variáveis independentes dos modelos foram selecionadas com base em dois critérios: disponibilidade da informação no momento da previsão e potencial relação com o tempo de duração do processo. O Quadro 1 resume as variáveis selecionadas:

Quadro 1 - Variáveis independentes selecionadas para previsão

Variável	Descrição	Tipo	Variação
“ano_transito”	Ano de trânsito em julgado da ação judicial originária.	Discreta	1963 a 2023
“mes_transito”	Mês de trânsito em julgado da ação judicial originária.	Discreta	1 a 12
“tribunal”	Tribunal vinculado à vara ou ao juízo de origem da ação judicial.	Catégorica	6 categorias únicas
“vara”	Juízo de origem da ação judicial.	Catégorica	4012 categorias únicas
“órgão”	Órgão ou entidade relacionado com o objeto da ação judicial	Catégorica	172 categorias únicas
“assunto”	Tema da ação judicial, conforme classificação da Justiça Federal.	Catégorica	2916 categorias únicas
“duracao_obs”	Duração em anos da ação judicial, no ano de observação.	Discreta	0 a 57

Fonte: Elaborado pelo autor (2024).

#### 3.2.1. Transformação de variáveis categóricas

Variáveis categóricas precisam ser codificadas para valores numéricos, a fim de que sejam processadas pelos algoritmos de *machine learning*. Uma das estratégias mais comuns de codificação consiste na criação de variáveis binárias indicadoras para as categorias únicas. Essa codificação foi utilizada para a variável ‘tribunal’, que deu origem a 6 variáveis binárias indicadoras de cada categoria, sendo então uma delas descartada para evitar a multicolinearidade.

A codificação binária, contudo, não se mostrava viável para as demais variáveis

categóricas, por apresentarem alta cardinalidade de categorias únicas. Com efeito, a criação de milhares de novas variáveis binárias indicadoras aumentaria a complexidade do modelo, possivelmente causando problemas ligados à alta dimensionalidade<sup>9</sup>.

Assim, para evitar esse problema e codificar as referidas variáveis categóricas de uma forma útil para o objetivo preditivo, foi utilizada a estratégia de *Target Encoding* (codificação pelo alvo), a seguir descrita.

O *Target Encoding* é uma forma de codificação que consiste em transformar a variável categórica para uma medida ligada à própria variável dependente a ser prevista, condicional a cada categoria. Essa medida pode ser escolhida de acordo com a utilidade para o problema preditivo, podendo ser a média, a mediana, a probabilidade e outras grandezas ligadas ao alvo e mensuráveis de forma condicional a cada categoria, isto é, considerando apenas os registros nela classificados. Nessa codificação, há também a possibilidade de se incluir um termo de erro aleatório ou uma medida não condicionada à categoria, para suavizar a transformação.

A codificação proposta para as referidas variáveis se baseou na média do tempo de duração das ações judiciais da categoria, considerando para tanto apenas as ações que já haviam gerado precatórios ao tempo da observação. A transformação foi inicialmente realizada na base de observações anuais e condicionada ao ano da observação, por dois motivos: 1) utilizar apenas informações disponíveis ao tempo da previsão, não fazendo uso de informações futuras no modelos longitudinais; e 2) introduzir dinâmica temporal nos valores transformados para a mesma categoria, os quais variam de acordo com o ano de observação, pela incorporação de novas ações que geraram precatórios no passado.

A transformação específica realizada consiste em uma média aritmética das seguintes médias ponderadas pelos número de ações: duração média da categoria em todo o histórico passado; duração média da categoria no ano passado mais recente; e duração média geral no ano passado mais recente, da seguinte forma:

$$\frac{\mu_c(h) + \mu_c(1) + \mu_g(1)}{\eta}$$

---

<sup>9</sup> Ver a “maldição da dimensionalidade” (*curse of dimensionality*) no tópico 2.4 da revisão de literatura.

onde  $\mu$  é a média de duração, os subscritos 'c' e 'g' designam se a média é da categoria ou geral, os números entre parênteses indicam os anos anteriores considerados, sendo  $h$  igual a todo o histórico, e  $\eta$  é o número de médias não nulas. Observe que, caso não haja dados de duração média da categoria nos anos anteriores, a variável corresponde à duração média geral no ano anterior, o que evita valores nulos na base.

Codificadas as variáveis categóricas na base de observações anuais, passou-se à codificação na base de ações judiciais. Para esse caso, a transformação das variáveis de cada ação judicial correspondeu à média das transformações de todas as observações passadas daquela ação. Essa estratégia garantiu que as transformações das variáveis não utilizassem dados posteriores ao ano em que cada ação gerou precatórios, ao mesmo tempo em que capturou o tempo de duração médio de cada categoria ao longo de todos os possíveis anos de observação da ação, o que condiz com o corte transversal dessa base.

Quadro 2 - Variáveis independentes após transformações

Variável	Descrição	Tipo	Variação
“ano_transito”	Ano de trânsito em julgado da ação judicial originária.	Discreta	1963 a 2023
“mes_transito”	Mês de trânsito em julgado da ação judicial originária.	Discreta	1 a 12
“tribunal_12103”	Indicação de vinculação ao TRF2	Binária	0 e 1
“tribunal_12104”	Indicação de vinculação ao TRF3	Binária	0 e 1
“tribunal_12105”	Indicação de vinculação ao TRF4	Binária	0 e 1
“tribunal_12106”	Indicação de vinculação ao TRF5	Binária	0 e 1
“tribunal_12107”	Indicação de vinculação ao TRF6	Binária	0 e 1
“vara_transf”	Duração média, passada e suavizada, condicional ao juízo de origem da ação.	Contínua	2,34 a 25,73
“orgao_transf”	Duração média, passada e suavizada, condicional ao órgão ou entidade relacionado com o objeto da ação.	Contínua	2,34 a 17,25
“assunto_transf”	Duração média, passada e suavizada, condicional ao tema da ação, conforme classificação da Justiça Federal.	Contínua	2,34 a 25,73
“duracao_obs”	Duração em anos da ação judicial, no ano de observação.	Discreta	0 a 57

Fonte: Elaborado pelo autor (2024).

Cumpra ainda ressaltar dois pontos em relação à referida estratégia de codificação: 1) a utilização de dados de ações que geraram precatórios no passado impôs o descarte das observações do ano de 2011 e anteriores, como relatado anteriormente, pois o primeiro ano da série de precatórios é 2012; 2) pelo mesmo motivo, foram também descartadas as ações que geraram pagamentos em 2012, as quais serviram apenas para codificação das observações e ações que geraram precatórios de 2013 em diante.

Assim, após as codificações descritas, as variáveis independentes efetivamente utilizadas nos modelos são especificadas no Quadro 2.

Por fim, todas as variáveis independentes passaram por uma normalização Min-Max antes de serem fornecidas aos algoritmos, a fim de reduzir vieses causados por diferenças de escala e amplitude das variáveis.

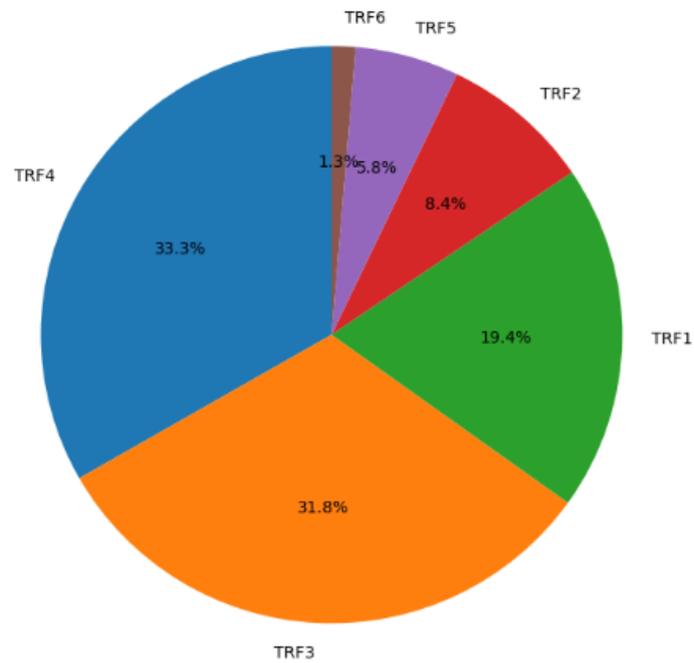
### 3.2.2. *Distribuição das variáveis independentes*

É relevante também descrever brevemente como se encontram distribuídas as variáveis independentes na base de ações originárias.

Geograficamente, verifica-se que as ações originárias do recorte amostral estão predominantemente situadas nos Tribunais Regionais Federais da 4ª, 3ª e 1ª Regiões, que concentram mais de 80% do total, conforme a Figura 4. Quanto às varas, embora sejam muito numerosas para visualização gráfica (cerca de 4 mil), convém ressaltar que a mais frequente na base apresenta 16.140 ações, aproximadamente 2,5% do total .

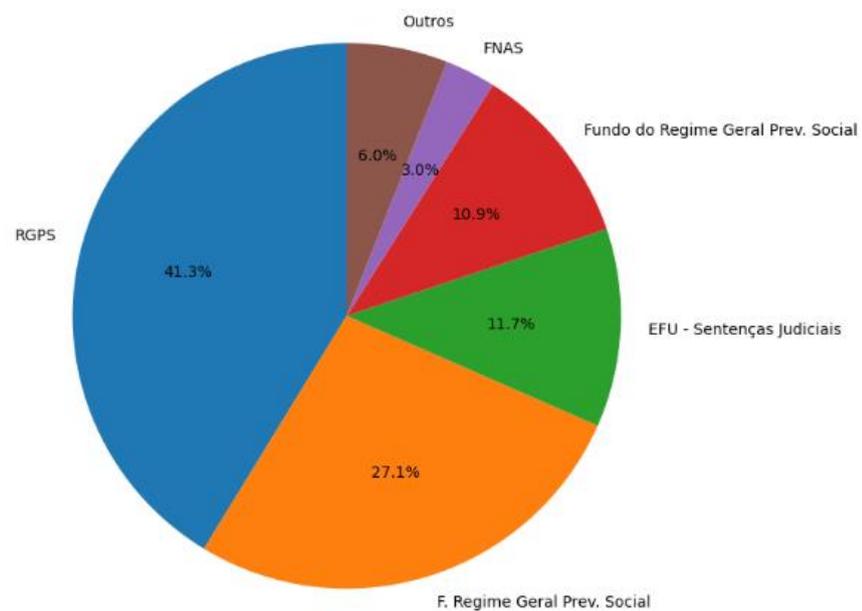
Já em relação aos órgãos públicos envolvidos na ações, nota-se que entidades relacionadas a Previdência Social prevalecem na amostra do estudo, abrangendo mais de 80% das ações. Ademais, cerca de 11% delas estão classificadas em órgãos fictícios, denominados “EFU – Sentenças Judiciais”, sigla para Encargos Financeiros da União, como bem demonstra a Figura 5. Quanto ao assunto, também se observa a prevalência daqueles ligados à Previdência Social, sendo o mais recorrente de Aposentadoria Especial, com 49.511 ações relacionadas.

Figura 4 - Distribuição das ações originárias em tribunais



Fonte: Elaborado pelo autor (2024).

Figura 5 - Distribuição das ações originárias em órgãos orçamentários

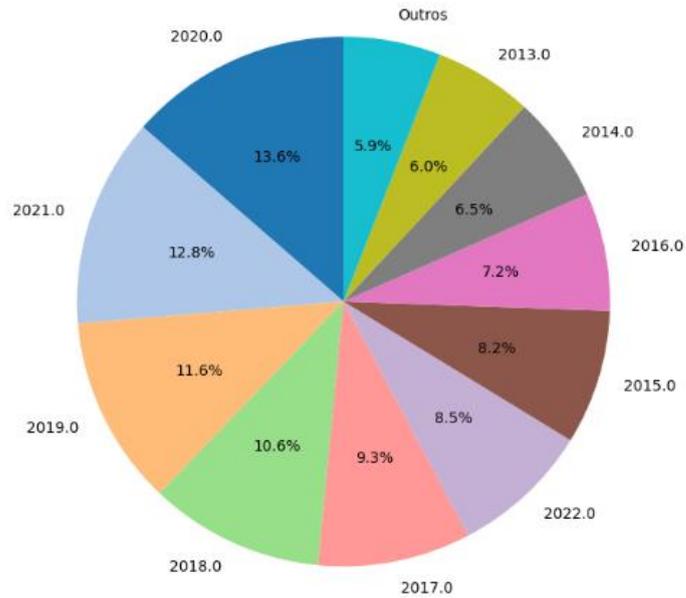


Fonte: Elaborado pelo autor (2024).

Por fim, no que concerne à data de trânsito em julgado, verifica-se que anos mais recentes predominam na base (Figura 6), o que era esperado, tanto pelo crescimento do

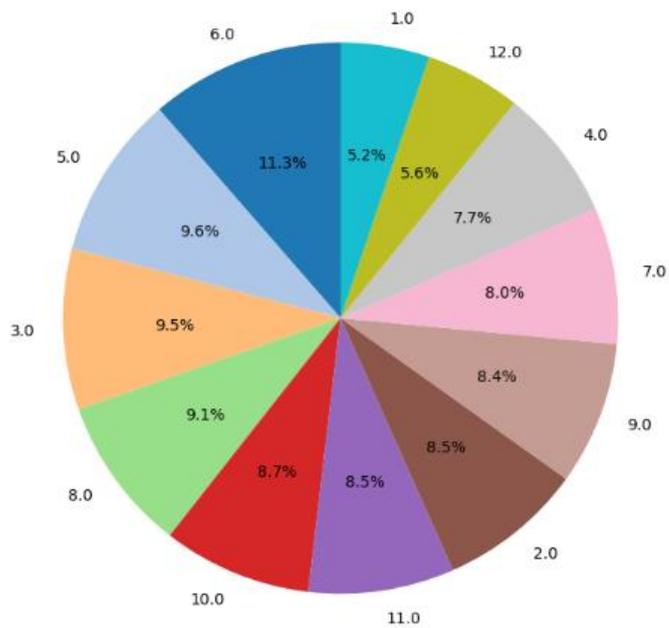
volume de ações, quanto pela qualificação dos dados prestados ao longo do tempo. Quanto ao mês de trânsito, há uma concentração das ações nos meses que antecedem o fim do primeiro semestre (Figura 7), o que também era de se esperar, dado o regime de emissão de precatórios com data limite para pagamento no ano seguinte (vide seção 2.2).

Figura 6 - Distribuição das ações originárias por ano de trânsito em julgado



Fonte: Elaborado pelo autor (2024).

Figura 7 - Distribuição das ações originárias por mês de trânsito em julgado



Fonte: Elaborado pelo autor (2024).

### 3.3. Variáveis dependentes

Considerando o objetivo de prever o tempo de duração de ações judiciais que resultaram na expedição de precatórios federais, a variável dependente do estudo é denominada ‘anos\_transito\_prec’ e corresponde à diferença entre o ano do precatório e o ano do trânsito em julgado da respectiva ação judicial.

A despeito da formulação clara e direta da variável dependente acima descrita, na base de observações anuais, é possível definir a variável dependente de forma ligeiramente distinta, mas ainda condizente com o objetivo do estudo, qual seja: a diferença entre o ano do precatório e o ano da observação. Trata-se da “duração restante” do processo, em oposição à “duração total” da primeira formulação.

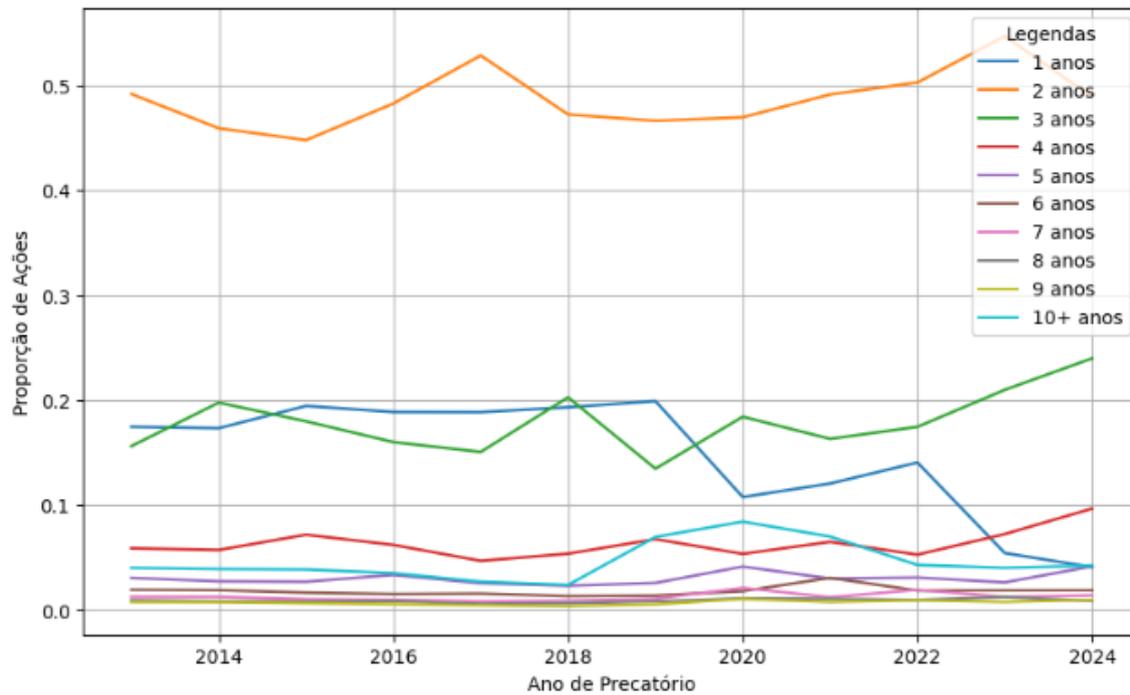
Esta seção discorre sobre características das citadas variáveis dependentes, tanto na base de ações originárias como na base de observações anuais, a fim de compreender melhor a distribuição e composição do alvo preditivo.

#### 3.3.1. *Duração total*

A variável “anos\_transito\_prec” possui uma distribuição de grande amplitude, variando de 1 a 58 anos, mas desbalanceada e com a maior parte dos registros de ações centrados entre 1 e 4 anos, o quais compreendem cerca de 87% do total na base de ações originárias. Cabe frisar que a distribuição se mantém relativamente estável ao longo do período amostral, a exceção da queda do valor de 1 ano, como indica a Figura 8.

Já na base de observações anuais, a distribuição da variável “anos\_transito\_prec” é distinta. Embora ainda centrada nos valores de 1 a 4 anos, estes concentram apenas 69% do total de registros, ao passo que os valores de 10 ou mais anos passam a conter 15% do total, em oposição a aproximadamente 5% na base de ações originárias.

Figura 8 - Proporção de ações por duração total a cada ano



Fonte: Elaborado pelo autor (2024).

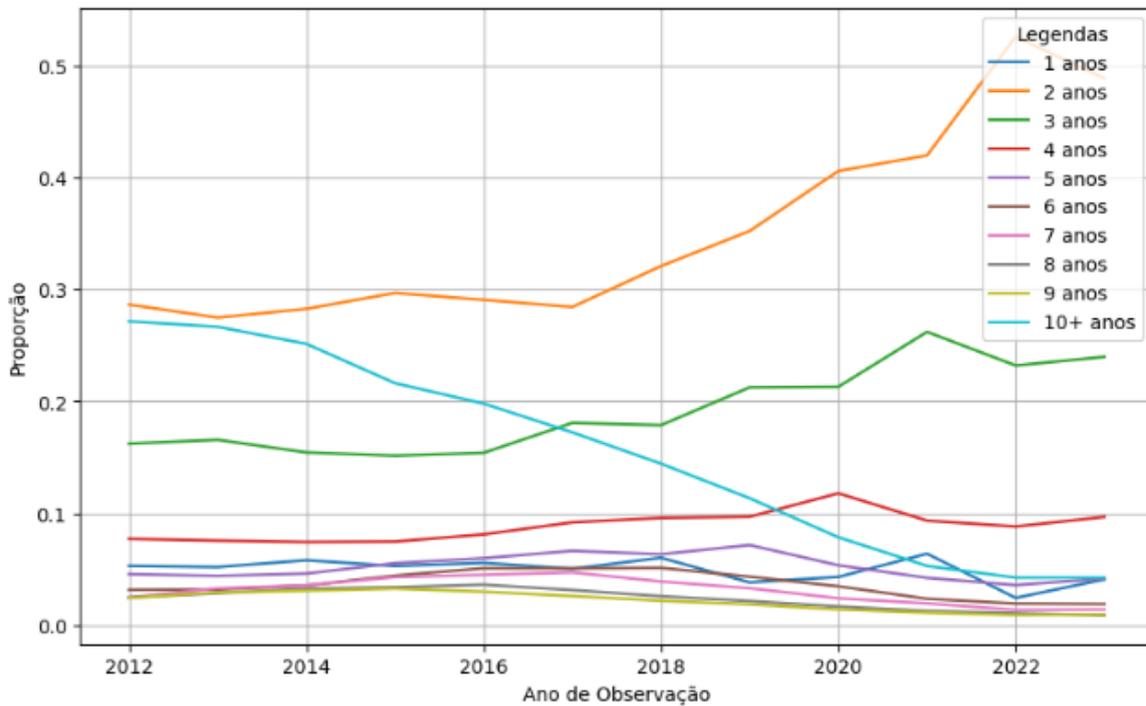
Isso ocorre porque a instanciação de observações anuais das ações enseja a criação de milhares de novos registros, em número diretamente proporcional a cada valor da variável “anos\_transito\_prec”. Assim, ações com valores maiores dão origem a mais observações anuais passadas, o que modifica a distribuição da variável nesta base.

Além disso, sua distribuição passa a sofrer modificações ao longo do tempo, pelo fato de que a base de dados é truncada à direita, isto é, contém apenas observações que efetivamente geraram precatórios até o limite do período observacional, no ano de 2024.

A truncagem dos dados enseja uma subrepresentação das ações de duração mais longa nos anos mais recentes de base de observações anuais, pelo fato de que esta não contém observações de ações que gerarão precatórios após 2024. Esse fenômeno é facilmente observável pela queda contínua na participação das observações de ações com duração de 10 ou mais anos na Figura 9.

Assim, é preciso levar em conta esse viés distributivo da base de observações anuais em anos mais recentes, na formulação dos modelos e definição dos cenários de validação, o que será objeto do próximo subcapítulo.

Figura 9 - Proporção de observações por duração total a cada ano



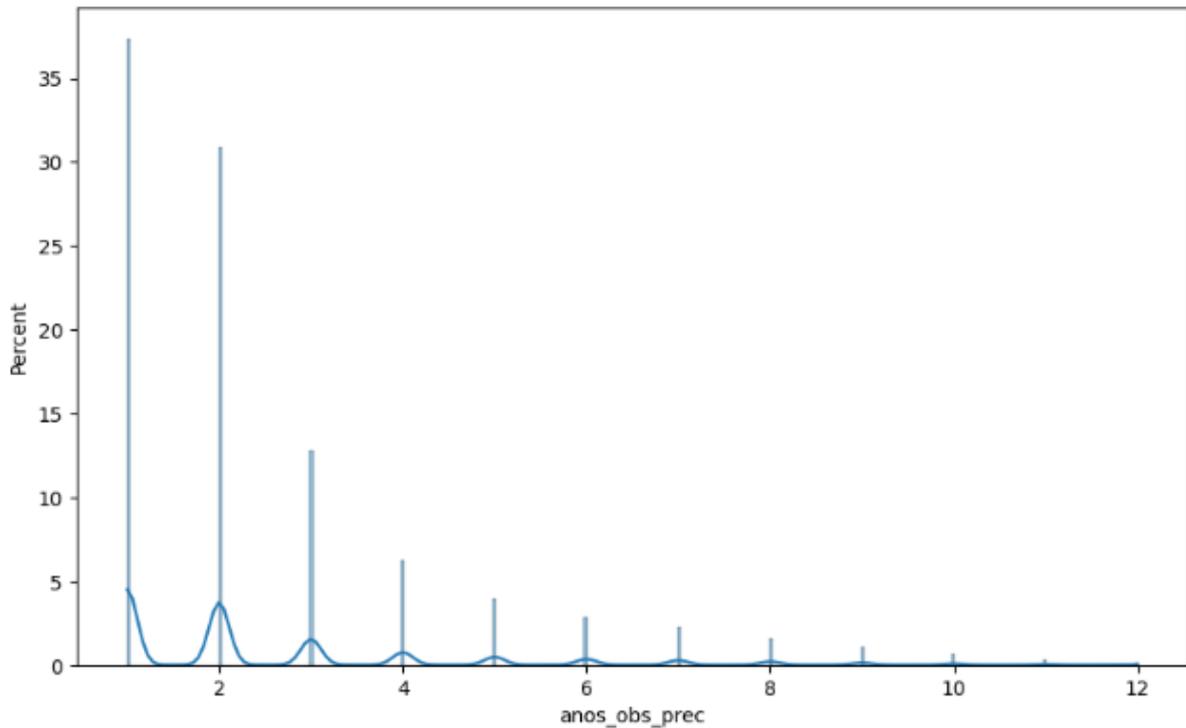
Fonte: Elaborado pelo autor (2024).

Por ora, cumpre ressaltar que a variável “anos\_transito\_prec” será classificada em 10 categorias distintas para aplicação do modelo preditivo, uma para cada ano de 1 a 9, e uma décima categoria para os valores de 10 ou mais anos. Essa classificação se baseou em um critério de utilidade prática da previsão, diferenciando os valores mais prevalentes nas bases de ações originárias e observações anuais.

### 3.3.2. Duração restante

Já a variável “anos\_obs\_prec” possui distribuição bastante distinta, por se aplicar somente à base de observações anuais e já ser definida em função da limitação temporal dos dados. Com efeito, seus valores variam apenas de 1 a 12, pois observações mais antigas, de 2012, antecedem em no máximo 12 anos os precatórios, limitados a 2024 na base. Ademais, a distribuição é desbalanceada e a participação decrescente para cada valor sequencial, como se vê na Figura 10.

Figura 10 - Percentual de observações por duração restante



Fonte: Elaborado pelo autor (2024).

Essa característica emerge por simples construção da base e definição da variável, na medida em que toda ação contará com o registro de 1 ano de duração restante, e cada vez menos ações contarão com registros de durações restantes maiores, pois estes são proporcionais ao número de ações de duração total equivalente.

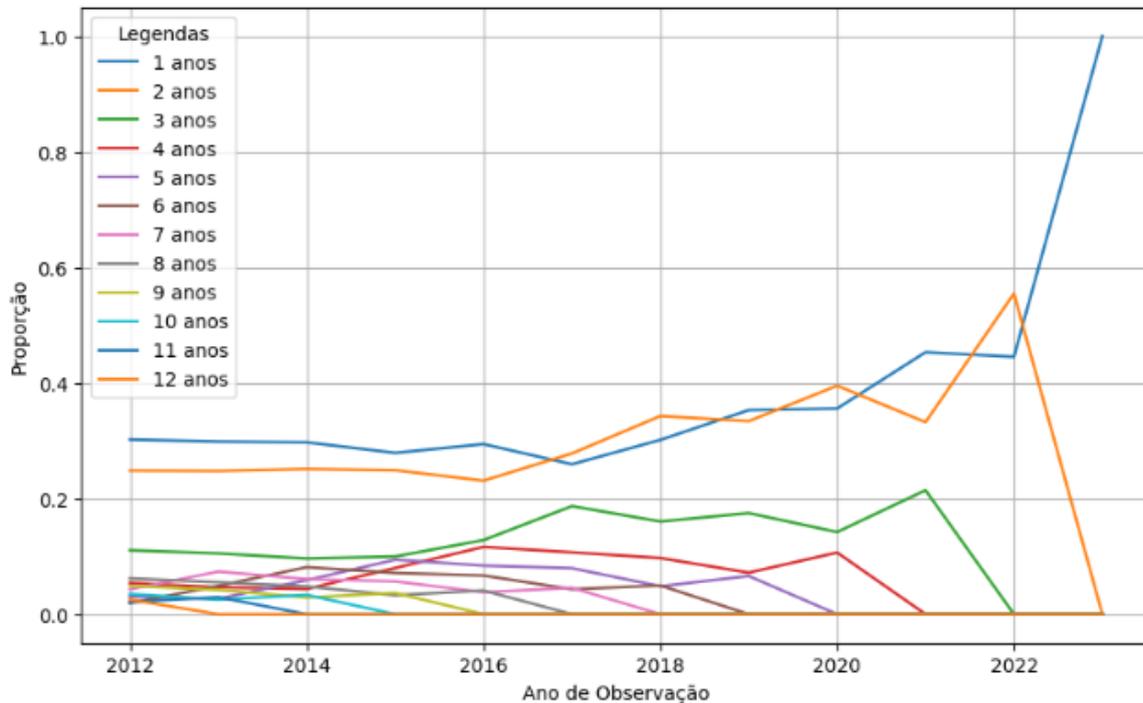
Outro ponto que merece ser destacado em relação à variável “anos\_obs\_prec” consiste no fato de que a truncagem a afeta mais fortemente, chegando a zerar os registros de cada valor da variável, à medida que se aproximam anos recentes. Confirma-se, a propósito, como a participação de cada valor  $n$  é zerada a partir de  $n - 1$  anos antes do ano de 2024, limite final da base de precatórios (Figura 11).

Como se vê, a distribuição da variável dependente “anos\_obs\_prec” difere significativamente da variável “anos\_transito\_prec”. Em razão da sua dependência do ano de observação, emergem duas características que a distinguem:

1. uma mesma ação possui diversos valores para essa variável dependente, uma para cada ano de observação, até o limite de sua duração final;
2. as observações de cada valor  $n$  podem ser consideradas completas até  $n$  anos

antes 2024, caindo abruptamente para zero no ano subsequente.

Figura 11 - Proporção de observações por duração restante a cada ano



Fonte: Elaborado pelo autor (2024).

Essas características tornam a variável “anos\_obs\_prec” muito difícil de ser prevista, na medida em que se quebra a monotonicidade da variável dependente com a duração da ação no ano de observação, bem como a relação direta com a codificação das variáveis categóricas (baseada na duração média final das categorias), pois todos os valores inferiores à duração final também serão alvo para a mesma ação.

As dificuldades impostas por esse problema ensejam a classificação dessa variável em apenas duas categorias mais gerais, “1 ou 2 anos” e “3 ou mais anos”, tornando-a uma classificação binária de geração de precatório nos dois anos seguintes à observação. Além disso, será necessário definir com cautela o cenário de validação do modelo, o que será objeto do próximo subcapítulo.

### 3.4. Análise descritiva do tempo de duração das ações

Para além da conceituação e descrição das distribuições das variáveis dependentes

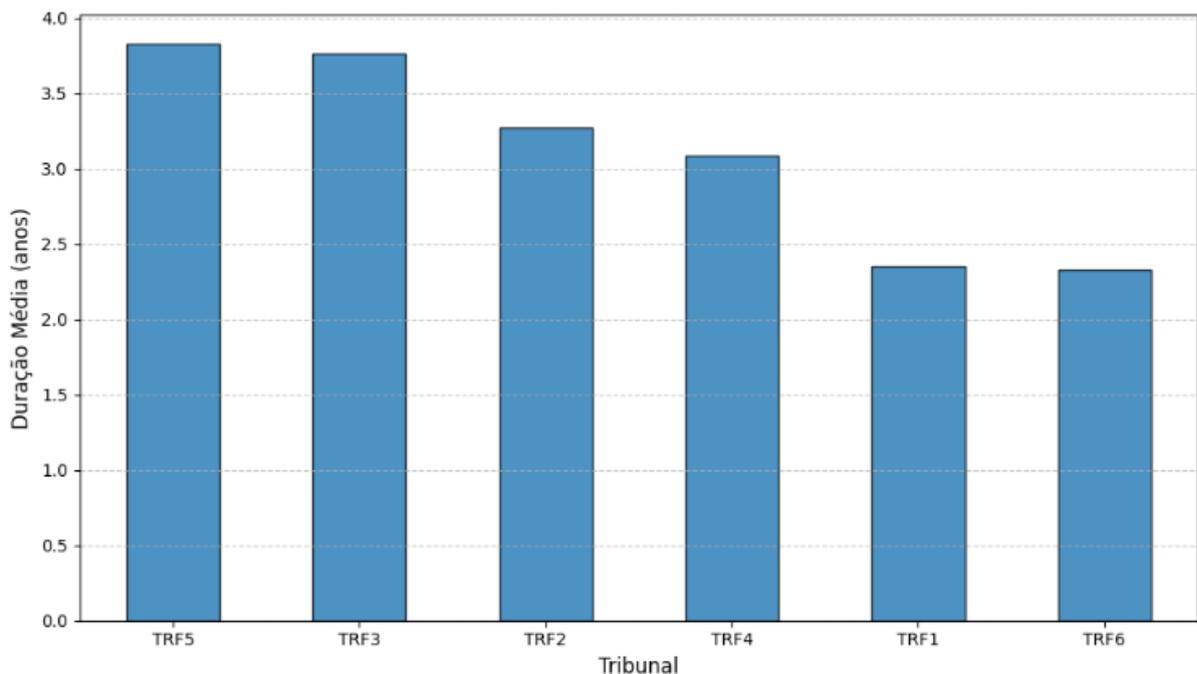
e independentes na base de ações originárias, mostra-se relevante também realizar uma breve análise descritiva do tempo de duração das ações, em relação às respectivas categorias em que se encontram classificadas.

Inicialmente, deve-se ter em mente que o tempo médio de duração das ações originárias em toda a base, medido em anos decorridos entre o trânsito em julgado e o ano de expedição do precatório, é de 3,2 anos. Como se verá adiante, as distribuições condicionais às categorias das variáveis independentes giram em torno desse valor.

Geograficamente, o tempo médio de duração das ações originárias não difere muito entre os Tribunais, oscilando entre 3,8 anos (TRF5) e 2,3 anos (TRF6), como mostra a Figura 12. No âmbito das varas federais, porém, já se verifica uma variabilidade muito maior da média de duração das ações, as mais longevas atingindo 15 anos de duração média, com as mais precoces se situando em 1 ano de duração (Tabela 1).

O tempo médio de duração das ações em relação aos órgãos públicos envolvidos está representado na Figura 13. Embora não seja possível extrair padrões ou regularidades evidentes na distribuição, nota-se que os processos associados à Previdência Social possuem duração inferior à média geral, ao passo que processos associados a órgãos e políticas públicas com menor judicialização possuem média de duração mais alta.

Figura 12 - Duração média das ações originárias por tribunal



Fonte: Elaborado pelo autor (2024).

Tabela 1 - Duração média das ações originárias por vara federal\*

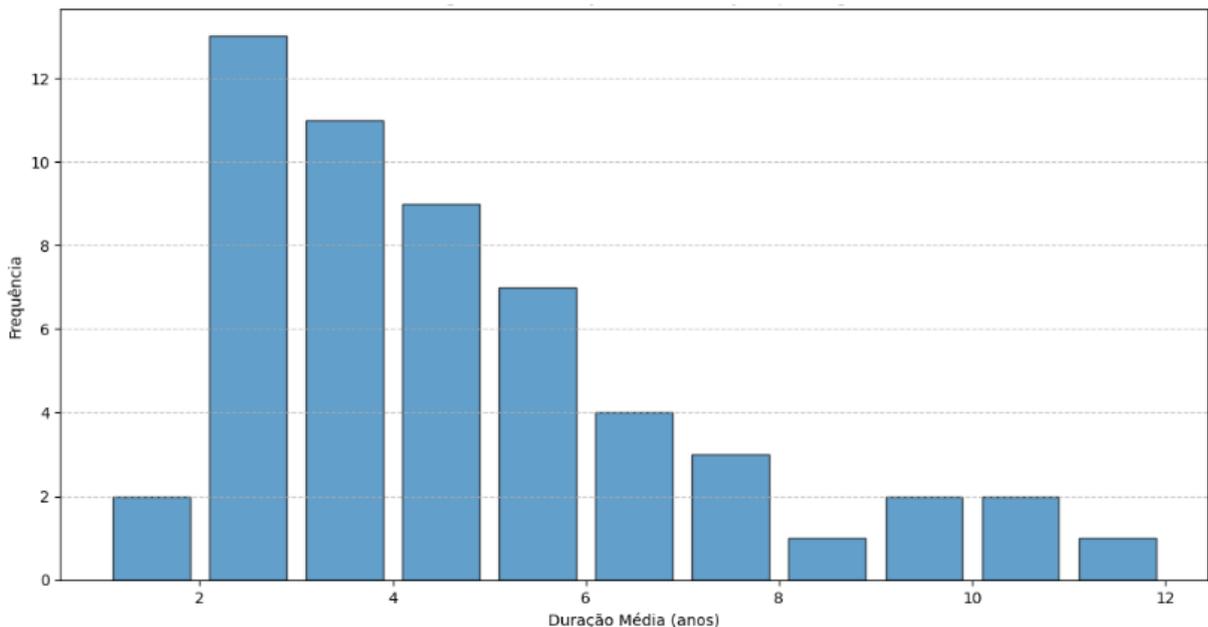
Vara Federal	Duração média (anos)
Juízo Federal da 10 Vara São Paulo Sec Jud SP	15.88
Juízo Federal da 9 Vara São Paulo Sec Jud SP	15.12
Juízo Federal da 21ª Vara São Paulo Sec Jud SP	14.88
Juízo Federal da 11ª Vara São Paulo Sec Jud SP	14.72
Juízo Federal da 5ª Vara São Paulo Sec Jud SP	14.25
...**	...**
Juízo Federal da 4ª Vara da Subseção Judiciária de Uberaba – MG	1.48
Primeiro Juizado Especial Federal de Nova Friburgo	1.46
Juízo Federal da 2ª Vara de Uberaba – MG	1.41
2ª Região 4ª Vara Cível e Criminal Volta Redonda – RJ	1.41
Juízo Federal da 6ª Vara – AP	1.34

\* Apenas varas federais com 100 ou mais ações originárias associadas.

\*\* Varas federais omitidas (1315 no total atenderam ao critério de 100 processos associados).

Fonte: Elaborado pelo autor (2024).

Figura 13 - Histograma do número de órgãos pela duração média das ações em anos\*



**Intervalo (1, 2]:** Univ. Fed. de Uberlândia, SUFRAMA;

**Intervalo (2, 3]:** Instituto Federal de SC, RGPS, Instituto Federal do Ceará, F. Regime Geral Prev. Social, FNAS, Fundo do Regime Geral Prev. Social, Instituto Federal do Espírito, ANS, Instituto Federal Catarinense, Inst. Fed. Sul-rio-grandense, Inst. F. Do Rio Grande do Sul, UFBA, Inst. Fed. Sertão Pernambucano;

**Intervalo (3, 4]:** UFPA, Instituto Federal de Pernambuc, UFR - PE, UFRN, FNDE, UFMG, Instituto Federal Farroupilha, UF Campina Grande, Fund. Univ. Fed. de Viçosa, DNIT, UFES;

**Intervalo (4, 5]:** UFRS, INSS, UFCE, UF - Fluminense/RJ, FUNAI, Fund. Univ. de Brasília, Fund. Univ. Fed. Rio Grande/RS, UFSC, CNEN;

**Intervalo (5, 6]:** INCRA, Colégio Pedro II, UFPB, Fund. Univ. Fed. de Pelotas, FUNASA, EFU - Sentenças Judiciais, UFRJ;

**Intervalo (6, 7]:** UFAL, Instituto Federal de Alagoas, Ibama, UF - Santa Maria/RS;

**Intervalo (7, 8]:** UTFP, IBGE, DNOCS;

**Intervalo (8, 9]:** UFPE;

**Intervalo (9, 10]:** Fund. Univ. Fed. MS, Banco Central do Brasil;

**Intervalo (10, 11]:** UFSP, FIOCRUZ

**Intervalo (11, 12]:** UFPR

\* Apenas órgãos com no mínimo 100 ações listadas na amostra.

Fonte: Elaborado pelo autor (2024).

No tocante ao assunto, ainda que a alta cardinalidade de categorias impeça análise mais detalhada dentro do escopo deste trabalho, a Tabela 2 denota que a matéria tributária prevalece nas categorias de assunto com maior tempo de duração, ao passo que o tema previdenciário se encontra entre as de menor tempo processual.

Tabela 2 - Duração média de ações originárias por assunto\*

<b>Assunto</b>	<b>Duração média (anos)</b>
PROAGRO - Incentivo - Intervenção no Domínio Econômico – Administrativo	24.83
FNT/Fundo Nacional de Telecomunicações/Tributos - Impostos e Contribuições Especiais - Tributário	24.32
Aquisição de Veículos Automotores - Empréstimo Compulsório - Tributário	23.04
FINSOCIAL - Contribuição Social - Contribuições - Direito Tributário	21.67
Crédito Complementar Precatório Liquidação Cumprimento Execução Direito Processual Civil e do Trabalho	17.37
...**	...**
Atos e Procedimentos Administrativos	1.52
Expedição/Liberação de Documentos(Exceto CND)	1.50
Benefício Previdenciário	1.48
Benefício Assistencial (Art. 203,V Cf/88), Benefícios em Espécie	1.45
Produção Antecipada Provas	1.34

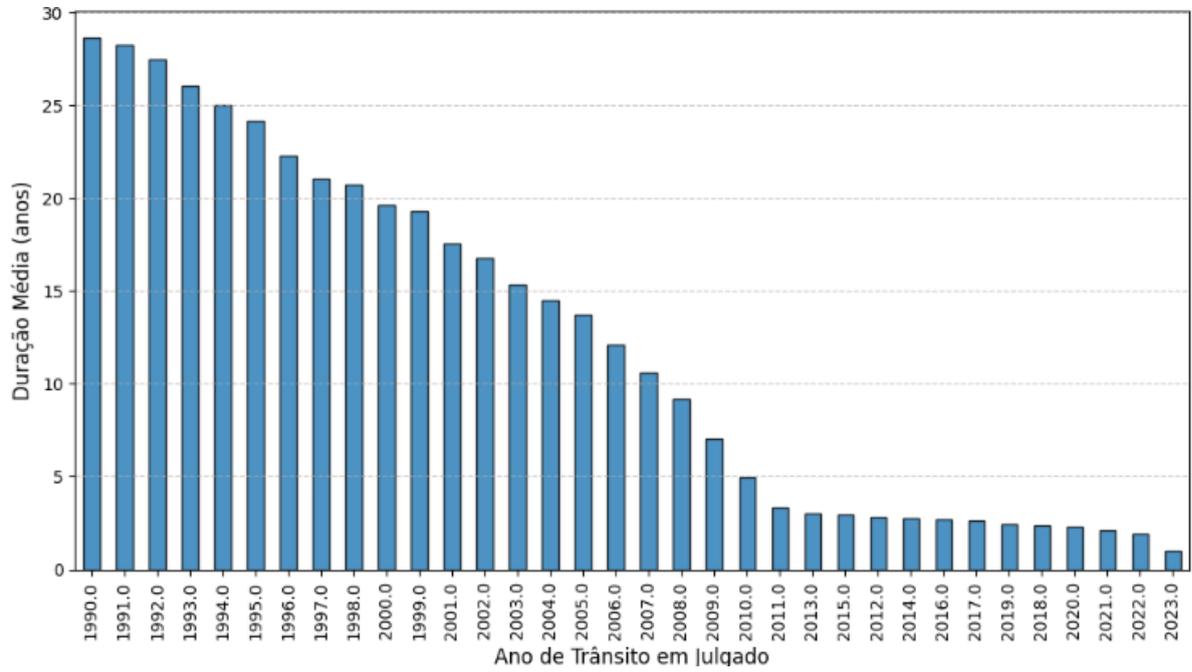
\* Apenas assuntos com 100 ou mais ações originárias associadas.

\*\* Assuntos omitidos (373 no total atenderam ao critério de 100 processos associados).

Fonte: Elaborado pelo autor (2024).

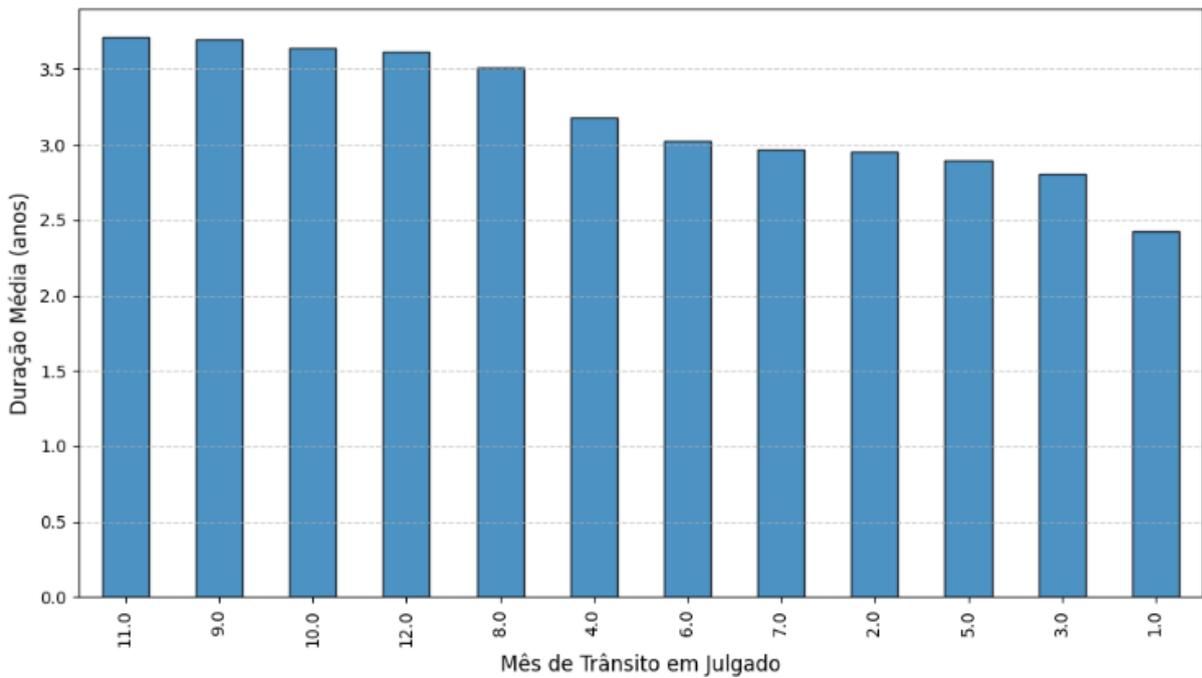
Por fim, em relação à data de trânsito em julgado, nota-se que as ações mais recentes apresentam tempo médio de duração em torno de 2 a 3 anos, ao passo que, de 2011 para trás, há uma proporcionalidade inversa entre o ano de trânsito e o tempo de duração, decorrência lógica do corte transversal do estudo (vide Figura 14). Quanto ao mês de trânsito em julgado, é possível notar que os do primeiro semestre apresentam, em geral, menor duração do que os do segundo, embora a variação seja pequena, conforme se verifica na Figura 15. Uma possível explicação para esse fenômeno consiste na aceleração de processos para atender ao limite temporal de inscrição de precatórios, como visto na distribuição das ações em relação ao mês de trânsito em julgado.

Figura 14 - Duração média de ações originárias por ano de trânsito em julgado



Fonte: Elaborado pelo autor (2024).

Figura 15 - Duração média de ações originárias por mês de trânsito em julgado



Fonte: Elaborado pelo autor (2024).

### 3.5. Modelos e cenários de validação

Conforme exposto na revisão de literatura, distintos modelos podem ser utilizados para abordar o problema de prever tempo de duração de eventos. Por um lado, *machine learning* tem sido aplicado com eficiência a problema preditivos diversos, inclusive em contextos jurídicos. A literatura clássica de análise de sobrevivência oferece modelos aptos a lidar especificamente com dados censurados. E modelos de dados longitudinais conseguem capturar variações temporais de observações da mesma unidade.

Na presente pesquisa, serão desenvolvidos e aplicados quatro modelos distintos, cada qual com uma abordagem específica para prever durações relacionadas ao trânsito em julgado e expedição de precatórios, abaixo descritos:

1. **Modelo Transversal de Divisão Aleatória (MTA):** Modelo de dados de corte transversal, sem variação temporal, destinado a prever a duração total (variável “anos\_transito\_prec”) dos registros da base de ações judiciais, com divisão aleatória das bases de treino e teste.
2. **Modelo Transversal de Divisão Temporal (MTT):** Também um modelo de dados de corte transversal, mas com divisão temporal das bases de treino e teste, buscando explorar cenários mais realistas.
3. **Modelo Longitudinal de Duração Total (MLT):** Modelo de dados longitudinais que incorpora variação temporal, voltado à previsão da duração total (variável “anos\_transito\_prec”) a partir de uma base de observações anuais.
4. **Modelo Longitudinal de Duração Restante (MLR):** Também um modelo de dados longitudinal, também com variação temporal, projetado para prever a duração restante (variável “anos\_obs\_prec”), representada pela geração ou não de precatório nos dois anos seguintes à observação.

As escolhas dos modelos acima visa a abordar o problema preditivo sob diversos ângulos, possibilitando explorar diferentes formas de avaliar a utilidade dos metadados das ações judiciais para prever tempo de duração, conforme objetivo de pesquisa traçado.

Os modelos transversais serão aplicados em dois cenários de validação distintos:

- **Cenário de validação do MTA (Divisão Aleatória):** A base de ações judiciais com precatórios dos anos de 2021 a 2024 será dividida aleatoriamente entre treino (80%) e teste (20%). Este cenário permite avaliar a performance preditiva quando

registros do mesmo ano de teste estão disponíveis no treino.

- **Cenário de validação do MTT (Divisão Temporal):** O treino será realizado com ações judiciais que geraram precatórios entre 2017 e 2020, ao passo que o teste será feito com ações que geraram precatórios de 2021 a 2024<sup>10</sup>. Este cenário busca simular uma situação preditiva mais realista.

Com esses diferentes cenários de validação, será possível comparar a performance de modelos preditivos em cenário de divisão aleatória (dados do mesmo ano de teste disponíveis no treino) e temporal (mais realista).

Já os modelos transversais serão aplicados nos seguintes cenários de validação:

- **Cenário de validação do MLT (Duração Total):** Este modelo será validado usando a base de observações anuais de 2020 como teste, enquanto o treino será realizado nas observações anuais de 2016 a 2019, que tenham gerado precatórios até 2020<sup>11</sup>. A escolha do ano de 2020 para o teste foi feita para minimizar o viés<sup>12</sup> da base de observações, mais pronunciado em anos recentes, e prover o modelo de dados passados suficientes para ajuste de hiperparâmetros em validação cruzada<sup>13</sup>.
- **Cenário de validação do MLR (Duração Restante):** Este modelo será validado com teste nas observações do ano de 2018 e treino nas observações de 2014 a 2016<sup>14</sup>. A escolha dos referidos anos também buscou conciliar as necessidades de minimizar o viés da base de observações anuais e prover o modelo de dados passados suficientes para ajuste de hiperparâmetros em validação cruzada<sup>15</sup>.

---

<sup>10</sup> Somente aquelas que possuíam observações no ano de 2020, para possibilitar a comparação com o modelo longitudinal, também testado na base de observações de 2020.

<sup>11</sup> A restrição às ações que geraram precatórios até 2020, ano da observação do teste, é essencial para evitar que dados “futuros” sejam utilizados no treino.

<sup>12</sup> Note que as ações com duração total de 1 a 4 anos, que possuem prevalência média de 87%, estão totalmente representadas na base de observações de 2020, já que se dispõe de dados de precatórios até 2024. Os processos de duração maior, embora esteja subrepresentados, possuem menor prevalência entre as ações, de modo que seu viés deve causar menos impactos sobre os modelos.

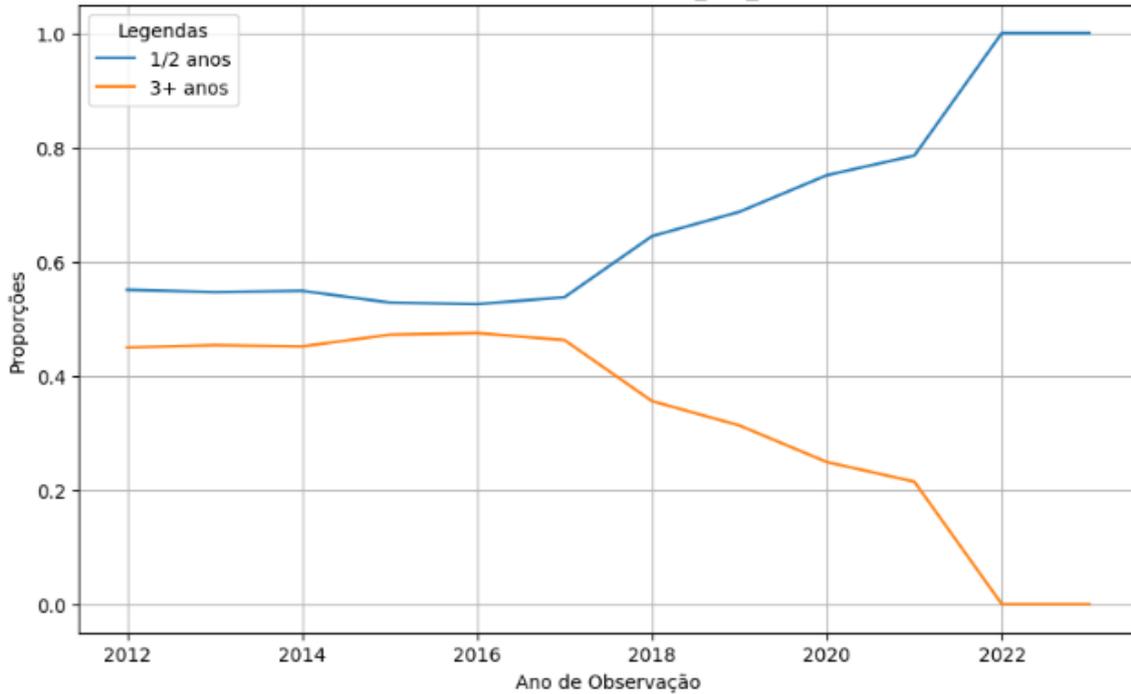
<sup>13</sup> Para definição dos hiperparâmetros do MTT e do MLT, foi realizada uma validação cruzada com dados de observações dos anos de 2012 a 2016, divididos temporalmente de forma análoga, isto é, validação no ano mais recente (2016) e treino nos 4 anos anteriores (2012 a 2015), sem dados “futuros”.

<sup>14</sup> Note que, ao retroceder a base de treino em 2 anos, não é necessário remover observações de ações que ainda não foram pagas em 2018, pois a categorização binária já permite classificar corretamente cada observação de 2016, sem dados futuros.

<sup>15</sup> Para definição dos hiperparâmetros do MLR, foi realizada uma validação cruzada com dados de observações dos anos de 2012 a 2016, divididos temporalmente de forma análoga, isto é, validação no ano mais recente (2016) e treino nos 3 anos anteriores ao antecedente imediato (2012 a 2014), sem dados “futuros”.

Ressalte-se que a definição do cenário de validação do último modelo acima descrito levou em conta a categorização distinta e a truncagem dos dados, que enviesam de forma mais rápida e intensa a distribuição temporal da variável a ser prevista, como se vê claramente na Figura 16.

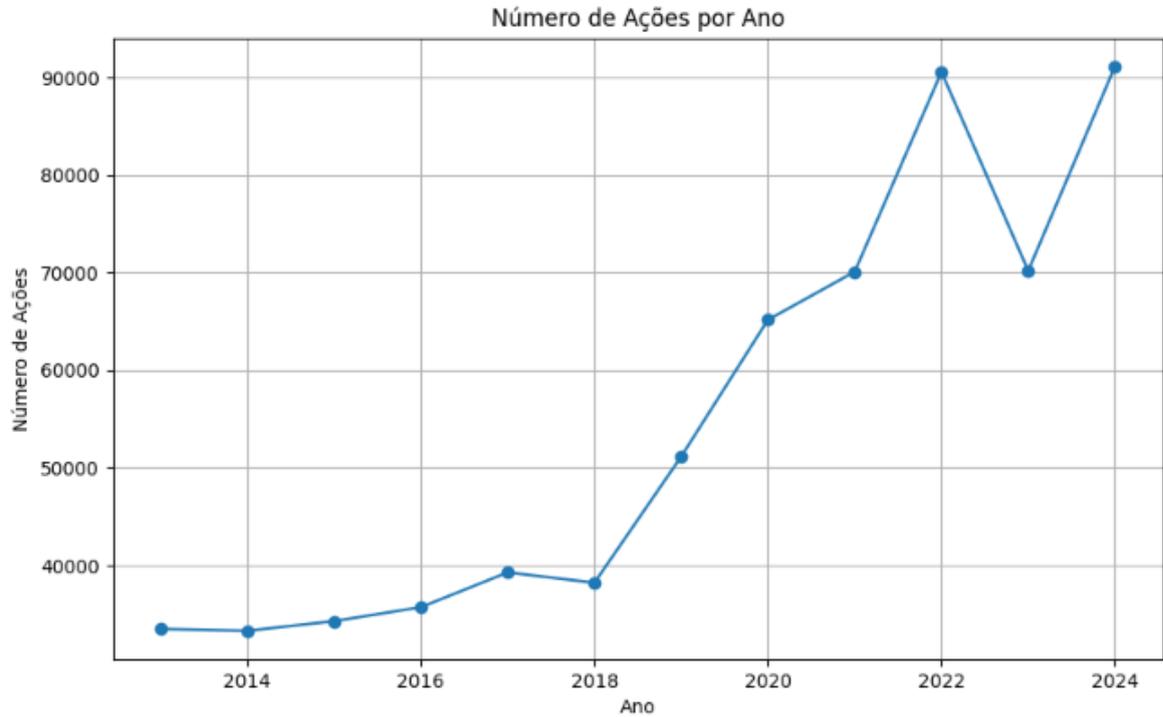
Figura 16 - Proporção de observações por duração restante binária a cada ano



Fonte: Elaborado pelo autor (2024).

Ressalte-se que o início do distanciamento das categorias já no ano de 2018 não implica o enviesamento da distribuição, pois em 2019 e 2020 houve um grande salto no número de ações que geraram precatórios, como se vê na Figura 17.

Figura 17 - Número de ações judiciais que geraram precatórios por ano



Fonte: Elaborado pelo autor (2024).

Quadro 3 - Modelos preditivos e cenários de validação

<b>Modelo</b>	<b>Base de dados</b>	<b>Variável dependente</b>	<b>Ano(s) de teste</b>	<b>Ano(s) de treino</b>
MTA	Ações originárias	“anos_transito_prec”	2021 a 2024 (amostra aleatória de 20%)	2021 a 2024 (amostra aleatória de 80%)
MTT	Ações originárias	“anos_transito_prec”	2021 a 2024	2017 a 2020
MLT	Observações anuais	“anos_transito_prec”	2020	2016 a 2019
MLR	Observações anuais	“anos_obs_prec”	2018	2014 a 2016

Fonte: Elaborado pelo autor (2024).

Assim, a tendência de crescimento do número de ações, também verificada em anos seguintes, já provoca por si só um distanciamento natural da participação relativa

das categorias definidas, o que é agravado pela truncagem da base de dados. De todo modo, o fenômeno corrobora a escolha de 2018 como ano de distribuição relativamente fidedigna para teste e validação do modelo. No Quadro 3 são sintetizados os modelos e os cenários de validação.

### 3.6. Algoritmos e métricas de avaliação

Nesta derradeira seção metodológica, são definidos os algoritmos a serem testados nos modelos preditivos, bem como explicitadas as métricas de avaliação dos modelos.

#### 3.6.1. Algoritmos

Os critério de seleção dos algoritmos de *machine learning* foram a adequação a grandes bases de dados, sendo um fator crucial a velocidade de processamento, e a performance em estudos preditivos semelhantes, citados na revisão de literatura. Assim, foram selecionados os algoritmos *Multinomial Logit*, *Gaussian Naive Bayes*, *Random Forest* e *Histogram Gradient Boosting*.

*Multinomial Logit* é uma extensão da regressão logística, capaz de lidar com variáveis dependentes com mais de duas categorias mutuamente exclusivas. Sua escolha se justifica pela ampla utilização em modelos de classificação, podendo ser considerado um *benchmark* de comparação.

*Gaussian Naive Bayes* é um algoritmo baseado no teorema de Bayes e assume a independência condicional entre as variáveis preditoras, modelando cada uma como uma distribuição Gaussiana (MURPHY, 2012). Escolhido pela sua simplicidade e velocidade de processamento em grandes bases de dados, além de aplicação em estudos semelhantes.

*Random Forest* é um algoritmo de conjunto de árvores de decisão, treinadas em amostras aleatórias dos dados, combinando as predições individuais para melhorar a precisão e reduzir o risco de *overfitting* (BREIMAN, 2001). Selecionado pela sua robustez e velocidade em grandes bases de dados, bem como pela sua performance acima de diversos outros algoritmos em estudos preditivos semelhantes.

*Histogram Gradient Boosting* também é um modelo de conjuntos de árvores de decisão, treinadas de forma sequencial para corrigir os erros de previsões das árvores

anteriores. Esta variante emprega histogramas para otimizar o tempo de treinamento e o uso de memória, sendo especialmente rápida em grandes bases de dados (KE et al., 2017), o que motivou sua inclusão no estudo.

Cumprido ressaltar os hiperparâmetros dos algoritmos foram realizados mediante validação cruzada. No caso do MTA, foram usados dois conjuntos aleatórios de validação pertencentes aos dados de treino. Para os demais modelos, que observam uma divisão temporal de dados de treino e teste, a validação cruzada foi realizada com dados da base de treino e anos anteriores, os quais foram divididos temporalmente de forma análoga, simulando as mesmas condições do teste. A especificação completa dos hiperparâmetros selecionados pode ser consultada no Anexo A.

### 3.6.2. Métricas de avaliação

A escolha das métricas de avaliação foi orientada pelos critérios de interpretação clara e adequação aos problemas de classificação, tanto para múltiplas categorias como para classes binárias. O objetivo é garantir que as métricas reflitam a qualidade preditiva dos modelos em diferentes cenários, dadas as características do problema real.

Nesse sentido, para os modelos que visam prever a duração total do processo – variável “anos\_transito\_prec”, dividida em 10 categorias – foram escolhidas como métricas de avaliação a acurácia, a acurácia no intervalo e os coeficientes Kappa de Cohen e Kappa de Cohen ponderado (linearmente).

A acurácia é uma medida da proporção de previsões corretas em relação ao total de previsões. É amplamente usada por sua simplicidade e fácil interpretação, sendo apropriada para uma visão inicial da performance do modelo.

Já a acurácia no intervalo, tal como definida no presente estudo, mede a capacidade do modelo de prever dentro de um intervalo aceitável de erro, de até um ano acima ou abaixo do valor real. É particularmente relevante para o presente problema de previsão de tempo de duração, onde previsões levemente imprecisas, mas próximas do alvo, ainda podem ser consideradas úteis em um cenário real.

O Kappa de Cohen ( $\kappa$ ) é uma métrica que mede o grau de concordância entre as previsões do modelo e os valores reais, ajustando-se pelo acaso. Ele é calculado como:

$$\kappa = \frac{(p_o - p_e)}{(1 - p_e)}$$

onde  $p_o$  é a proporção de observações em que o modelo e os valores reais concordam e  $p_e$  é a proporção esperada de concordância pelo acaso, considerando as distribuições dos valores reais e das previsões do modelo. O valor de  $\kappa$  varia de -1 (discordância perfeita) a 1 (concordância perfeita), sendo 0 o valor equivalente à concordância esperada por acaso.

Essa métrica é especialmente relevante para problemas de classificação com categorias desbalanceadas, pois fornece uma avaliação mais robusta do que a acurácia simples, possibilitando inferir que o modelo difere significativamente de um preditor aleatório. Valores positivos de  $\kappa$  são geralmente categorizados para interpretação mais clara, conforme especifica o Quadro 4, baseado em proposta de Landis e Koch (1977).

Quadro 4 - Interpretação do coeficiente Kappa de Cohen

Valor de $\kappa$	Grau de Concordância
< 0	Ruim (discordância)
0 – 0,20	Leve
0,21 – 0,40	Moderada
0,41 – 0,60	Substancial
0,61 – 0,80	Alta
0,81 – 1,00	Quase perfeita

Fonte: Adaptado de Landis e Koch (1977).

O Kappa de Cohen ponderado é uma extensão do Kappa que leva em consideração o grau de erro em previsões incorretas. Na ponderação linear, os erros são penalizados proporcionalmente à sua distância em relação à classe correta da seguinte forma:

$$\kappa_w = 1 - \frac{(\sum_{ij} w_{ij} \cdot o_{ij})}{(\sum_{ij} w_{ij} \cdot e_{ij})}$$

onde  $w_{ij}$  é peso associado ao erro entre as categorias  $i$  e  $j$ , dado por  $|i-j|$  no caso de ponderação linear;  $o_{ij}$  é o elemento correspondente da matriz de frequências observadas; e  $e_{ij}$  é o elemento respectivo da matriz de frequências esperadas pelo acaso.

Essa métrica é particularmente adequada para problemas de previsão de categorias ordinais (COHEN, 1968), pois reflete a gravidade de erros de previsão mais distantes das categorias reais, servindo como medida de concordância aproximada do preditor, de forma análoga à acurácia no intervalo.

Já para os modelos que visam a prever se a ação judicial gerará precatórios nos 2 anos seguintes ao da observação – variável “anos\_obs\_prec” – foram escolhidas como métricas de avaliação a acurácia, a precisão, o F1-Score e o coeficiente Kappa de Cohen. Isso porque neste problema há apenas uma classificação binária, perdendo o sentido as métricas de acurácia no intervalo e Kappa de Cohen ponderado já que o erro sempre terá a mesma magnitude.

A precisão mede a proporção de verdadeiros positivos entre todas as predições positivas, sendo crucial para problemas onde a minimização de falsos positivos é importante. Para a previsão de duração restante, essa métrica é particularmente valiosa, pois destaca a qualidade das predições para a classe positiva.

O F1-score é a média harmônica entre precisão e sensibilidade, equilibrando esses dois aspectos. É útil em cenários com classes desbalanceadas, onde um bom desempenho geral depende tanto de identificar corretamente as instâncias positivas quanto de evitar falsos negativos, como no caso problema da presente pesquisa.

Por fim, a utilidade das variáveis independentes para previsão será avaliada por meio da *Gini Importance*, também denominada *Mean Decrease Impurity*, como descrita por Breiman (2001) e implementada na biblioteca *scikit-learn* do *Python*. Trata-se, em linhas gerais, de métrica calculada com base no critério de redução da impureza da informação nos nós das árvores da floresta.

Um dos problemas no uso dessa métrica é o viés induzido pela alta cardinalidade de variáveis categóricas. Variáveis com muitas categorias únicas tendem a ser preferidas pelo modelo, mesmo que sua real utilidade preditiva seja baixa. No entanto, esse viés não ocorre no presente estudo, pois todas as variáveis categóricas foram transformadas para valores contínuos, tal como descrito na seção de variáveis independentes.

Assim, essa métrica é particularmente útil para o objetivo de avaliar a utilidade das variáveis no modelo de previsão. Ao mensurar o impacto de cada variável no desempenho preditivo, ela fornece *insights* valiosos sobre quais características do conjunto de dados estão mais fortemente associadas ao alvo.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Resultados

#### 4.1.1. Modelo Transversal com Divisão Aleatória

O MTA apresentou altíssima performance preditiva ao ser treinado e testado com amostras aleatórias, isto é, sem divisão temporal. Embora os algoritmos *Multinomial Logit* e *Gaussian Naive Bayes* não ultrapassem faixas intermediárias das métricas, os algoritmos *Random Forest* e *Histogram Gradient Boosting* apresentaram previsões quase perfeitas, com acurácias na casa do 98 a 99% e Kappas de Cohen no valor de 0.97 a 0.99, tanto na base de treino como na base de teste (Tabela 3).

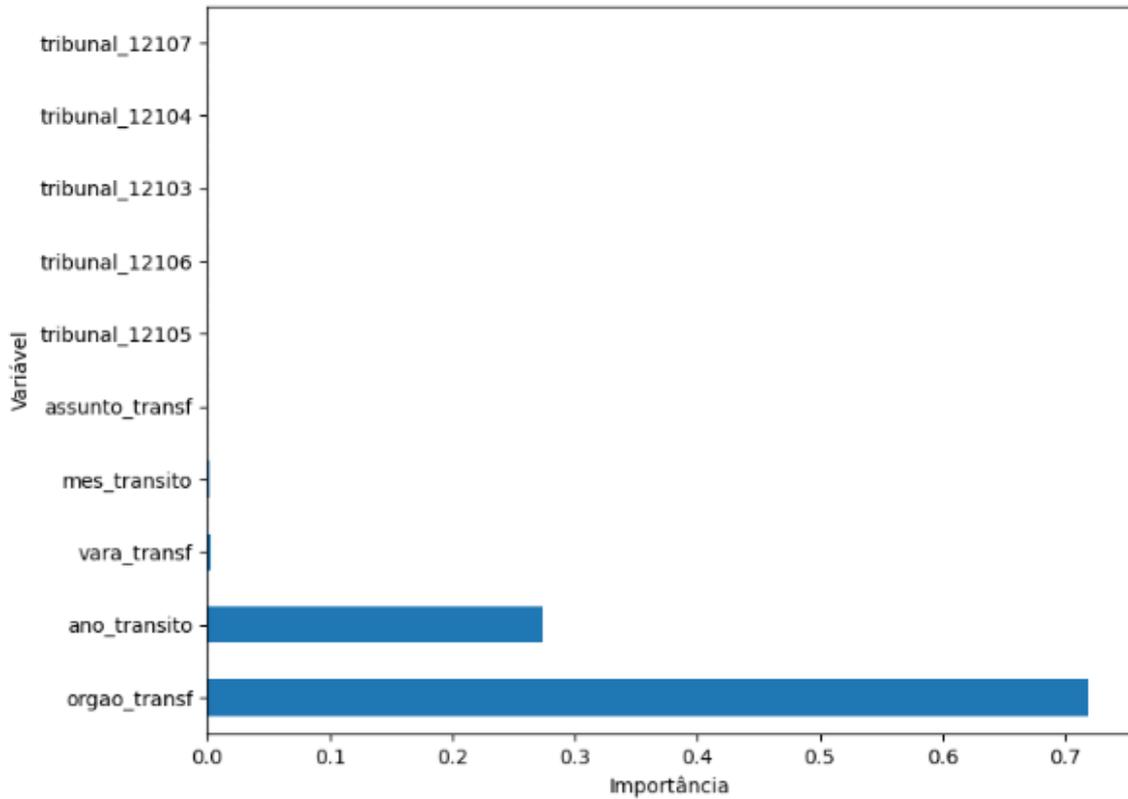
Tabela 3 - Resultados do Modelo Transversal de Divisão Aleatória (MTA)

Algoritmo	Dados	Acurácia (%)	Acurácia no Intervalo (%)	Kappa de Cohen	Kappa de Cohen Ponderado
<i>Multinomial Logit</i>	Treino	61.98	92.91	0.39	0.73
	Teste	61.67	92.85	0.38	0.73
<i>Gaussian Naive Bayes</i>	Treino	53.91	88.53	0.33	0.61
	Teste	53.54	88.51	0.33	0.61
<i>Random Forest</i>	Treino	99.44	99.79	0.99	1.00
	Teste	99.28	99.74	0.99	0.99
<i>Hist. Gradient Boosting</i>	Treino	98.46	99.65	0.98	0.99
	Teste	98.22	99.56	0.97	0.99

Fonte: Elaborado pelo autor (2024).

No que se refere à importância das variáveis, verifica-se que o órgão público envolvido foi a variável com maior relevância para a previsão do modelo, seguido pelo ano de trânsito em julgado. As demais variáveis apresentaram importância próxima a zero neste modelo transversal, como se verifica na Figura 18.

Figura 18 - Importância das variáveis no Modelo Transversal de Divisão Aleatória (MTA)



Fonte: Elaborado pelo autor (2024).

#### 4.1.2. Modelo Transversal com Divisão Temporal

Já no cenário de divisão temporal de bases de treino e teste, o MTT apresentou queda significativa de performance no conjunto de teste. As acurácias dos algoritmos *Random Forest* e *Histogram Gradient Boosting* caíram para em torno de 35 a 38% na base de teste, embora tenham se mantido relativamente altas na base de treino, no patamar de 80%. Os coeficientes Kappa de Cohen também sofreram quedas análogas, indicando a perda de concordância das previsões com valores reais. Interessa observar que o algoritmo com melhor performance no teste nesse cenário foi o *Multinomial Logit*, ainda que com métricas ligeiramente superiores aos demais (Tabela 4).

A importância das variáveis também sofreu significativas mudanças no modelo transversal com divisão temporal. Como demonstra a Figura 19, diversas variáveis desimportantes no Modelo Transversal de Divisão Aleatória passaram a ter utilidade preditiva. O ano de trânsito em julgado se tornou a variável mais relevante, seguida por órgão envolvido, vara e mês de trânsito em julgado. Assunto e variáveis indicadoras dos

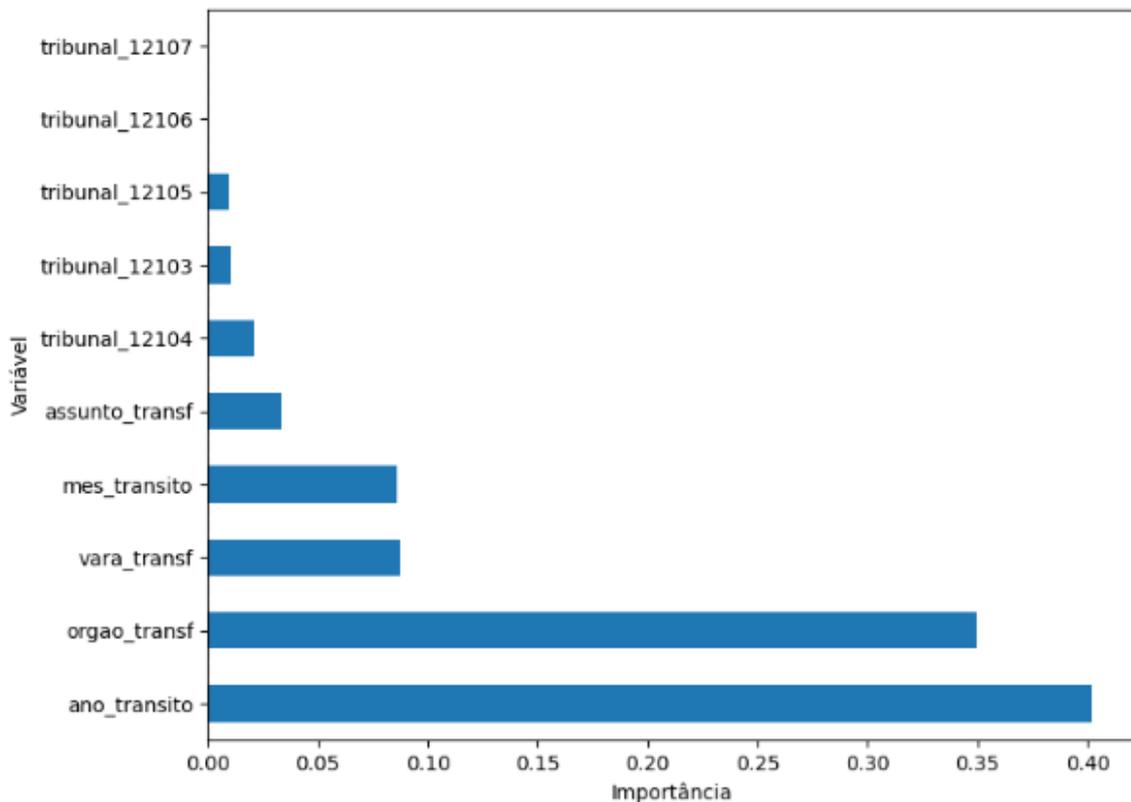
tribunais foram as variáveis de menor relevância, embora ainda úteis para a previsão.

Tabela 4 - Resultados do Modelo Transversal de Divisão Temporal (MTT)

Algoritmo	Dados	Acurácia (%)	Acurácia no Intervalo (%)	Kappa de Cohen	Kappa de Cohen Ponderado
<i>Multinomial Logit</i>	Treino	61.68	89.1	0.39	0.67
	Teste	43.95	70.92	0.16	0.43
<i>Gaussian Naive Bayes</i>	Treino	57.73	89.75	0.39	0.67
	Teste	38.12	66.38	0.16	0.41
<i>Random Forest</i>	Treino	83.87	92.89	0.76	0.85
	Teste	35.21	68.64	0.11	0.43
<i>Hist. Gradient Boosting</i>	Treino	89.2	95.74	0.84	0.91
	Teste	35.76	66.78	0.13	0.41

Fonte: Elaborado pelo autor (2024).

Figura 19 - Importância das variáveis no Modelo Transversal de Divisão Temporal (MTT)



Fonte: Elaborado pelo autor (2024).

#### 4.1.3. Modelo Longitudinal de Duração Total

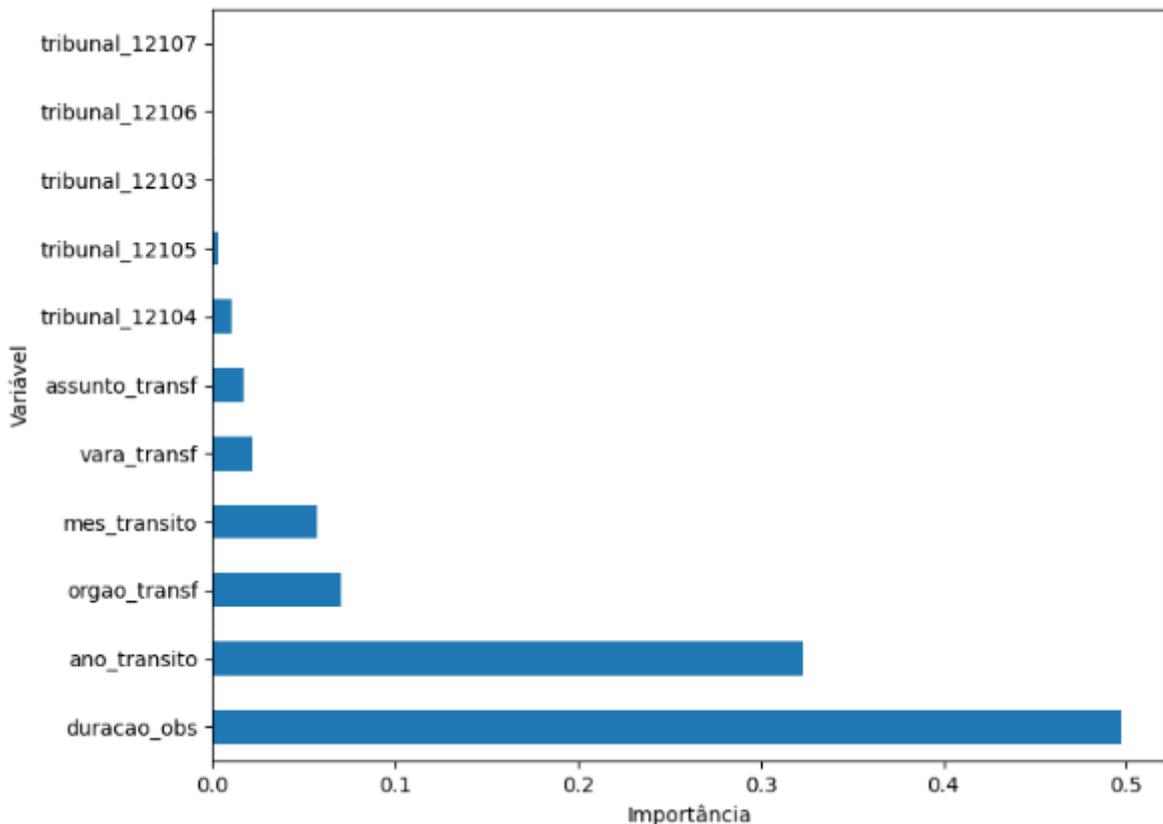
O MLT obteve métricas intermediárias de previsão, sendo os melhores algoritmos, mais uma vez, *Random Forest e Histogram Gradient Boosting*, com pequena vantagem para o primeiro. No conjunto de teste, as acurácias giraram em torno de 55%, as acurácias no intervalo atingiram 80% e os Kappas de Cohen, simples e ponderado, se situaram em 0,35 e 0,65, indicando uma concordância exata moderada e uma concordância aproximada substancial (Tabela 5).

Tabela 5 - Resultados do Modelo Longitudinal de Duração Total (MLT)

Algoritmo	Dados	Acurácia (%)	Acurácia no Intervalo (%)	Kappa de Cohen	Kappa de Cohen Ponderado
<i>Multinomial Logit</i>	Treino	59.75	89.55	0.41	0.77
	Teste	48.32	76.92	0.23	0.59
<i>Gaussian Naive Bayes</i>	Treino	62.32	93.62	0.51	0.81
	Teste	47.58	75.02	0.30	0.54
<i>Random Forest</i>	Treino	70.12	93.12	0.56	0.83
	Teste	55.80	81.15	0.35	0.66
<i>Hist. Gradient Boosting</i>	Treino	78.59	94.22	0.70	0.88
	Teste	54.12	80.01	0.35	0.63

Fonte: Elaborado pelo autor (2024).

Figura 20 - Importância das variáveis no Modelo Longitudinal de Duração Total (MLT)



Fonte: Elaborado pelo autor (2024).

Mais uma vez, os resultados quanto à importância das variáveis diferem bastante em relação aos modelos anteriores (Figura 20). Com a inclusão da variável duração da observação, esta passou a ter grande importância para a previsão, como era esperado e desejado ao se elaborar o modelo longitudinal.

O ano e o mês de trânsito em julgado permaneceram em patamares próximos aos do modelo transversal com divisão temporal, sinalizando que não foram afetados pela nova variável de duração. O mesmo não se pode dizer em relação às demais variáveis, como órgão, vara, assunto e tribunal, que tiveram importâncias reduzidas na presença da duração, inobstante ainda contribuam significativamente para melhorar as previsões.

#### 4.1.4. Modelo Longitudinal de Duração Restante

Por fim, o MLR também apresentou métricas que podem ser consideradas intermediárias, dado que o problema de previsão neste caso é binário, tendo por objetivo identificar ações judiciais que gerariam precatórios nos dois anos seguintes à observação. Novamente se destacaram os algoritmos *Random Forest* e *Histogram Gradient Boosting*, agora com ligeira vantagem para o segundo. Acurácia, precisão e F1-Score atingiram patamares próximos a 70% e o Kappa de Cohen se situou em 0,35, denotando uma concordância exata moderada da previsões com valores reais (Tabela 6).

Tabela 6 - Resultados do Modelo Longitudinal de Duração Restante (MLR)

Algoritmo	Dados	Acurácia (%)	Precisão Geral (%)	F1-Score Geral (%)	Kappa de Cohen
<i>Multinomial Logit</i>	Treino	69.96	70.76	69.22	0.39
	Teste	67.79	66.12	65.92	0.24
<i>Gaussian Naive Bayes</i>	Treino	64.03	71.43	59.13	0.25
	Teste	66.3	64.03	60.46	0.13
<i>Random Forest</i>	Treino	86.81	86.82	86.8	0.73
	Teste	68.2	71.44	68.86	0.35
<i>Hist. Gradient Boosting</i>	Treino	80.52	80.5	80.49	0.61
	Teste	68.42	70.89	69.03	0.35

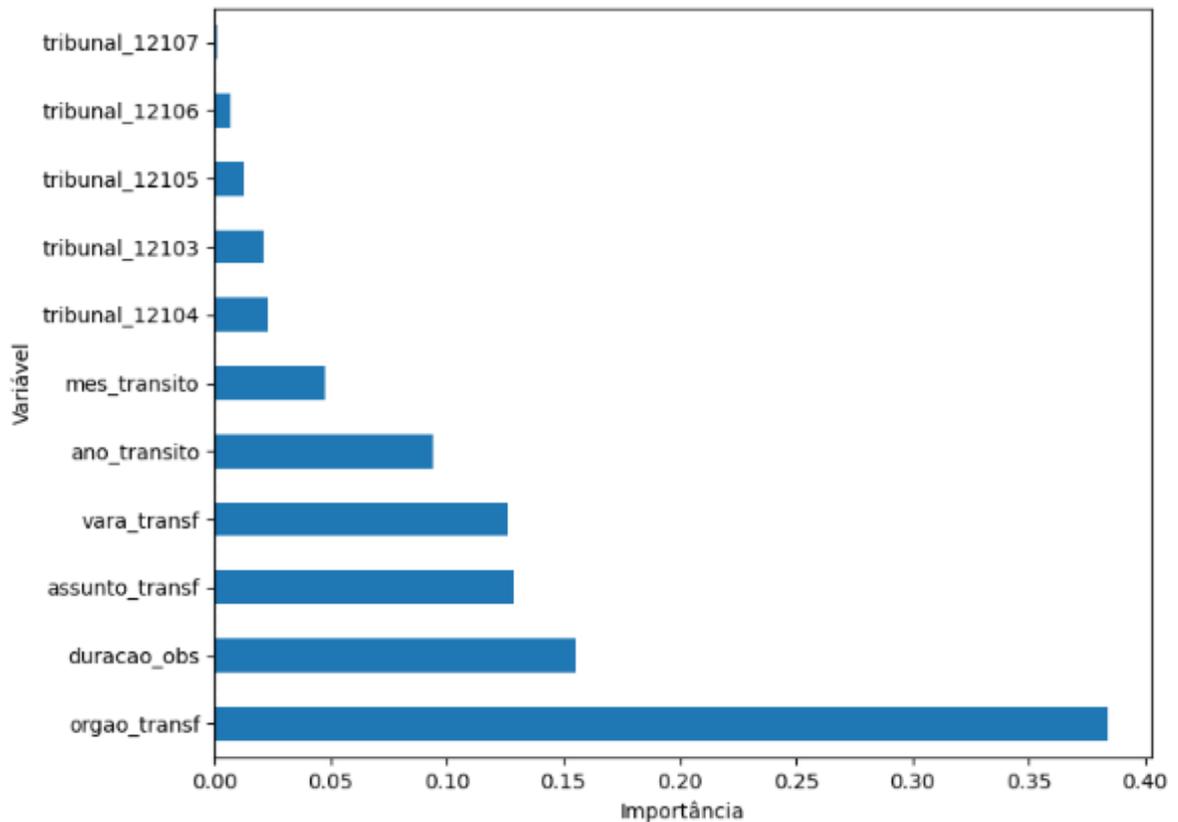
Fonte: Elaborado pelo autor (2024).

Pode-se destacar que, neste modelo, os algoritmos *Multinomial Logit* e *Gaussian*

*Naive Bayes* contam com métricas de teste bastante próximas às dos melhores algoritmos, à exceção do Kappa de Cohen, que ficou na casa de 0,25. Isso significa que, embora tais algoritmos estejam acertando previsões em níveis similares, seus acertos se devem mais ao acaso do que ao aprendizado efetivo, em comparação com os algoritmos de árvores de decisão. Essa constatação é corroborada pela métricas de treino bastante superiores dos algoritmos *Random Forest* e *Histogram Gradient Boosting*, em relação aos demais.

Por fim, as importâncias das variáveis no modelo longitudinal de duração restante parecem ser uma mistura de todos os modelos anteriores. O órgão envolvido voltou a ser a variável de maior relevância, como no modelo transversal de divisão aleatória. Todas as variáveis contribuem para a previsão, como no modelo transversal de divisão temporal. A duração da observação apresenta grande relevância, embora tenha caído para a segunda posição. Como resultado particular do presente modelo, vara e assunto passaram a ter maior importância preditiva do que ano e mês de trânsito em julgado (Figura 21).

Figura 21 - Importância das variáveis no Modelo Longitudinal de Duração Restante (MLR)



Fonte: Elaborado pelo autor (2024).

## 4.2. Análise e discussão

### 4.2.1. Comparativo de modelos transversais

Um dos achados mais relevantes da presente pesquisa pode ser visto mediante a comparação de performance dos modelos transversais, a depender da forma de divisão de conjuntos de treino e teste, se aleatória ou temporal.

Como visto anteriormente, no cenário de divisão aleatória os algoritmos *Random Forest* e *Histogram Gradient Boosting* obtiveram métricas extremamente altas, com a acurácia atingindo 99% e o Kappa de Cohen 0,99, tanto na base de treino como na base de teste. Contudo, ao dividir temporalmente os conjuntos de treino e teste, os resultados neste último pioraram substancialmente, como se verifica na Tabela 7.

Tabela 7 - Comparativo de Modelos Transversais de Divisão Aleatória e Temporal

Métrica	Algoritmo	Aleatória (MTA)	Temporal (MTT)	Diferença (%)
Acurácia (%)	<i>Multinomial Logit</i>	61.67	43.95	-28.74
	<i>Gaussian Naive Bayes</i>	53.54	38.12	-28.81
	<i>Random Forest</i>	99.28	35.21	-64.53
	<i>Hist. Gradient Boosting</i>	98.22	35.76	-63.59
Acurácia no Intervalo (%)	<i>Multinomial Logit</i>	92.85	70.92	-23.62
	<i>Gaussian Naive Bayes</i>	88.51	66.38	-25.00
	<i>Random Forest</i>	99.74	68.64	-31.18
	<i>Hist. Gradient Boosting</i>	99.56	66.78	-32.93
Kappa de Cohen	<i>Multinomial Logit</i>	0.38	0.16	-58.08
	<i>Gaussian Naive Bayes</i>	0.33	0.16	-50.62
	<i>Random Forest</i>	0.99	0.11	-89.07
	<i>Hist. Gradient Boosting</i>	0.97	0.13	-86.78
Kappa de Cohen Ponderado	<i>Multinomial Logit</i>	0.73	0.43	-41.11
	<i>Gaussian Naive Bayes</i>	0.61	0.41	-32.28
	<i>Random Forest</i>	0.99	0.43	-57.22
	<i>Hist. Gradient Boosting</i>	0.99	0.41	-58.72

Fonte: Elaborado pelo autor (2024).

Os resultados indicam que existe uma forte correlação entre as ações que se encerram no mesmo ano, de modo que a divisão aleatória permite que se preveja com grande acurácia o tempo de duração de ações que terminaram de forma concomitante.

Uma das possíveis explicações para essa correlação consiste na simultaneidade de julgamentos de ações semelhantes, induzida por mecanismos de aceleração de tramitação

processual, discutidos na revisão de literatura. De fato, o cumprimento de metas judiciais do CNJ, que agrupam processos de acordo com marcos processuais como a data de trânsito em julgado, bem como a aplicação conjunta de precedentes vinculantes, que incide sobre ações com o mesmo assunto ou órgão envolvido, pode explicar tamanha correlação entre os processos que geram precatórios no mesmo ano.

Assim, os resultados encontrados são consistentes com a literatura sobre o sistema judicial brasileiro, servindo de evidência concreta do julgamento conjunto de processos similares. Ainda que esse modelo de previsão não seja realista, por usar informação futura sobre ações que irão se encerrar, mostra que é possível prever com segurança o tempo de duração de processos que se encerram em determinado ano, a partir de uma amostra desses, fornecendo *insights* para possíveis modelagens alternativas.

#### 4.2.2. Comparativo de modelo transversal e modelo longitudinal

O segundo achado relevante da presente pesquisa se refere à performance superior do modelo longitudinal em relação ao transversal com divisão temporal, para previsão do tempo de duração total da ação.

A Tabela 8 mostra como o MLT, com múltiplas observações para uma mesma ação, supera o MTT em todas as métricas utilizadas e em todos os algoritmos testados, chegando a apresentar acurácia 60% maior e Kappa de Cohen 200% maior, aproximadamente, no algoritmo *Random Forest*.

Duas características dos modelos longitudinais ajudam a explicar essa diferença de performance: a introdução da duração da observação como atributo preditor e a dinâmica temporal das demais variáveis independentes, nas observações de uma mesma ação. Com efeito, a incorporação da duração atual ao modelo fornece uma informação extremamente útil para ajuste das previsões, ao passo que a dinâmica temporal das demais variáveis ajuda a tornar mais preciso o histórico de tempos de duração passados, ajustando-se para cada possível observação de uma mesma ação.

Esses resultados são consistentes com a literatura sobre modelos longitudinais, que sugere sua maior capacidade de capturar a variação temporal e as diferenças entre indivíduos. Outrossim, os achados fornecem uma abordagem alternativa e promissora para a literatura sobre previsão de tempo de vida, utilizando o tempo de duração parcial

como variável independente, ao invés de incorporá-lo apenas como dado censurado.

Tabela 8 - Comparativo de Modelo Transversal (MTT) e Modelo Longitudinal (MLT)

Métrica	Algoritmo	MTA (Transversal)	MLT (Longitudinal)	Diferença (%)
<b>Acurácia (%)</b>	<i>Multinomial Logit</i>	43.95	48.32	9.96
	<i>Gaussian Naive Bayes</i>	38.12	47.58	24.82
	<i>Random Forest</i>	35.21	55.80	58.48
	<i>Hist. Gradient Boosting</i>	35.76	54.12	51.32
<b>Acurácia no Intervalo (%)</b>	<i>Multinomial Logit</i>	70.92	76.92	8.47
	<i>Gaussian Naive Bayes</i>	66.38	75.02	13.02
	<i>Random Forest</i>	68.64	81.15	18.22
	<i>Hist. Gradient Boosting</i>	66.78	80.01	19.81
<b>Kappa de Cohen</b>	<i>Multinomial Logit</i>	0.16	0.23	44.22
	<i>Gaussian Naive Bayes</i>	0.16	0.30	85.28
	<i>Random Forest</i>	0.11	0.35	220.91
	<i>Hist. Gradient Boosting</i>	0.13	0.35	171.09
<b>Kappa de Cohen Ponderado</b>	<i>Multinomial Logit</i>	0.43	0.59	37.44
	<i>Gaussian Naive Bayes</i>	0.41	0.54	30.21
	<i>Random Forest</i>	0.43	0.66	54.49
	<i>Hist. Gradient Boosting</i>	0.41	0.63	55.71

Fonte: Elaborado pelo autor (2024).

#### 4.2.3. Comparativo de algoritmos

Acerca dos algoritmos de *machine learning*, os resultados do estudo indicam que o *Random Forest* foi o algoritmo com melhor performance geral, tendo apresentado métricas superiores no MTA e no MLT, como mostra a Tabela 9.

Embora outros algoritmos apresentem métricas superiores no MTA e no MLR, a análise mais aprofundada dos resultados revela que o *Random Forest* possui métricas bastante próximas às dos vencedores e, no caso do modelo transversal, métricas de treino muito superiores às do *Multinomial Logit*.

Cabe ressaltar que o *Random Forest* foi seguido de perto pelo *Histogram Gradient Boosting* na maior parte dos modelos, não sendo possível inferir diferenças significativas entre os dois algoritmos. Por outro lado, *Multinomial Logit* e *Naive Bayes* apresentaram resultados inferiores aos dois primeiros em quase todos os cenários.

Esses achados são consistentes com estudos semelhantes, como o de previsão de

desfecho de ação judicial, em que Barnabé (2022) obteve resultados preditivos melhores justamente para os algoritmos *Random Forest* e *Gradient Boosting*.

Tabela 9 - Comparativo de melhores algoritmos por modelo

Modelo	Melhor Algoritmo	Acurácia (%)	Acurácia no Intervalo (%)	Kappa de Cohen	Kappa Ponderado	Precisão (%)	F1-Score (%)
MTA	<i>Random Forest</i>	99.28	99.74	0.99	0.99	-	-
MTT	<i>Multinomial Logit</i>	43.95	70.92	0.16	0.43	-	-
MLT	<i>Random Forest</i>	55.8	81.15	0.35	0.66	-	-
MLR	<i>Hist. Gradient Boosting</i>	68.42	-	0.35	-	70.89	69.03

Fonte: Elaborado pelo autor (2024).

#### 4.2.4. Comparativo de importância das variáveis

Por fim, a comparação dos resultados quanto à importância das variáveis nos diferentes modelos também joga luz sobre as perguntas suscitadas na pesquisa.

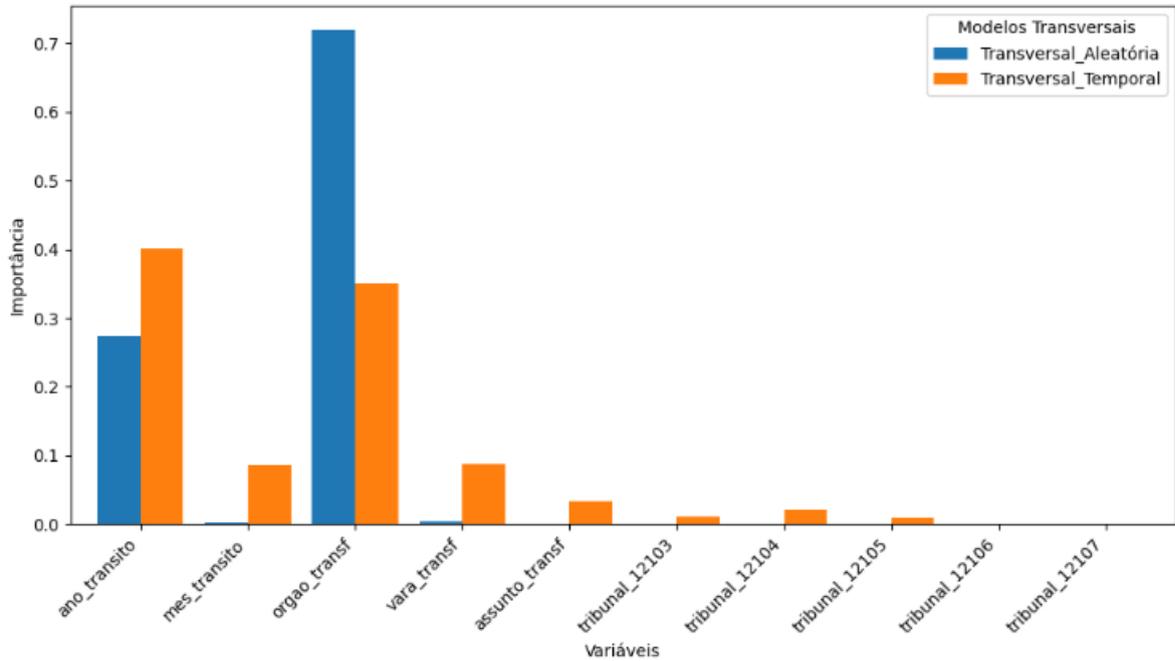
Inicialmente, constata-se que a performance preditiva do MTA se deve em nsuma às variáveis de órgão público envolvido e ano de trânsito em julgado. Essa constatação indica que a alta correlação entre ações que se encerram no mesmo ano se dá por meio das referidas variáveis, o que é consistente com a existência de mecanismos de aceleração de julgamento centrados nessas características, como as metas judiciais e os julgamentos de precedentes vinculantes, apontados na revisão de literatura.

Por outro lado, ao dividir temporalmente os conjuntos de treino e teste, tratando o problema de forma mais realista, diversas outras variáveis passam a ter importância no MTT. Isso pode ser explicado pelo fato de que, na ausência de informações sobre o julgamento de ações contemporâneas, o modelo é forçado a extrair informações das demais variáveis, a fim de melhor ajustar as previsões (Figura 22).

Nos modelos longitudinais, a elevada importância da variável independente de duração da observação demonstra como a modelagem com dados empilhados se mostrou útil para aprimorar a previsão. No MLT, a duração da observação possui a maior relevância entre todas as variáveis, na medida em que existe uma monotonicidade

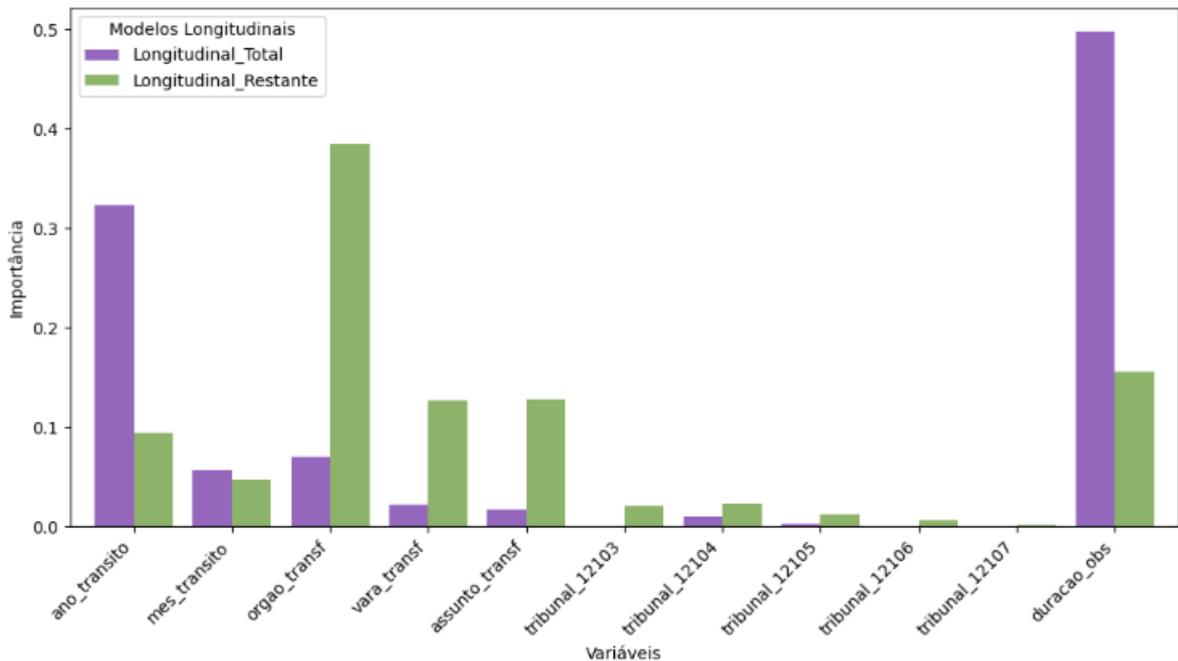
crecente entre seu valor e o da variável dependente. No MLR, com a quebra da referida monotonicidade, a duração da observação decresce em importância frente as demais variáveis, mas permanece como segunda variável mais útil para a previsão (Figura 23).

Figura 22 - Comparação de importâncias de variáveis nos modelos transversais



Fonte: Elaborado pelo autor (2024).

Figura 23 - Comparação das importâncias das variáveis nos modelos longitudinais



Fonte: Elaborado pelo autor (2024).

Assim, em consonância com a revisão de literatura e com a hipótese de pesquisa suscitada, os resultados corroboram a utilidade dos metadados processuais para previsão do tempo de duração das ações. Ademais, pode-se separá-los em duas categorias, de acordo com a importância relativa para os modelos testados: em primeiro lugar, com contribuição superior a 30% em pelo menos um dos modelos, encontram-se as variáveis duração do processo no momento fixado para observação, data de trânsito em julgado e órgão público envolvido; em segundo plano, com contribuições abaixo de 15% para previsões, figuram as variáveis assunto do processo, vara de origem e tribunal vinculado.

## 5. CONSIDERAÇÕES FINAIS

Entre os riscos fiscais, as ações judiciais têm se destacado no cenário brasileiro, devido ao crescimento expressivo das despesas dessa natureza e do estoque de processos com entes públicos. Diante disso, prever as despesas futuras associadas a ações judiciais tornou-se crucial para oferecer maior segurança e previsibilidade para a política fiscal.

Nesse contexto, a presente pesquisa se debruçou sobre problema ainda pouco explorado na literatura, buscando responder à seguinte questão: quando uma ação judicial gerará despesa futura para o Estado? Formulou-se a hipótese de que metadados de ações judiciais, como vara e tribunal de origem, assunto, órgão envolvido e data de trânsito em julgado, podem ser usados, por meio de métodos estatísticos e computacionais, para prever o tempo de duração das ações judiciais.

O estudo analisou dados de precatórios federais requisitados pela Justiça Federal no período de 2012 a 2024, com o objetivo de prever o tempo de duração das ações judiciais desde o trânsito em julgado até a inclusão do precatório em lei orçamentária. Para isso, foram criadas duas bases de dados: uma de ações judiciais originárias e outra de observações anuais, representando os processos ao longo dos anos. Essa estrutura possibilitou abordar o problema preditivo de forma transversal e longitudinal.

Variáveis categóricas foram codificadas por *Target Encoding*, considerando a média histórica do tempo de duração das ações judiciais com base em precatórios já expedidos. Cenários de validação foram definidos de forma a minimizar viés e truncagem da base de dados e a garantir sua representatividade e robustez para previsão. Algoritmos de *machine learning* foram selecionados com base em sua performance preditiva em estudos semelhantes e sua velocidade de processamento em grandes bases de dados.

Foram definidas duas variáveis dependentes discretas, uma referente ao tempo de duração total da ação e outra correspondente ao tempo de duração restante da ação, a partir da observação. A primeira foi dividida em 10 categorias, de 1 a 10 anos ou mais, e a segunda foi transformada em uma variável binária, indicando se houve expedição de precatório nos dois anos seguintes à observação.

Quatro modelos preditivos foram projetados: Modelo Transversal de Divisão Aleatória (MTA), Modelo Transversal de Divisão Temporal (MTT), Modelo Longitudinal de Duração Total (MLT) e Modelo Longitudinal de Duração Restante (MLR). Os modelos foram avaliados com métricas como acurácia e coeficiente Kappa de

Cohen, além da *Gini Importance*, que mediu a relevância das variáveis independentes. Essa abordagem metodológica permitiu explorar diferentes perspectivas do problema de previsão do tempo de duração das ações judiciais.

Os resultados desta pesquisa evidenciam importantes achados sobre a previsão do tempo de duração de ações judiciais e o papel dos metadados processuais.

A análise dos modelos transversais revelou que a divisão aleatória de treino e teste resulta em métricas preditivas extremamente altas, com acurácia próxima a 99%, devido à forte correlação entre ações que se encerram no mesmo ano. Esse fenômeno pode ser explicado por mecanismos de aceleração processual, como metas do CNJ e julgamentos conjuntos baseados no sistema de precedentes vinculantes. Contudo, ao adotar uma divisão temporal, mais alinhada às condições reais de previsão, o desempenho do modelo transversal caiu significativamente, com acurácia em torno de 35%.

A modelagem longitudinal demonstrou superioridade em relação à transversal, quando há divisão temporal do conjunto de teste. De fato, o MLT apresentou métricas de até 60% maiores em acurácia e até 200% superiores em Kappa de Cohen, comparado ao MTT. Essa vantagem pode ser atribuída à inclusão da duração da observação como variável preditora e à captura de dinâmicas temporais nas variáveis independentes.

Entre os algoritmos testados, o *Random Forest* teve o melhor desempenho geral, especialmente MTA e no MLT, seguido de perto pelo *Histogram Gradient Boosting*. Já *Multinomial Logit* e o *Naive Bayes* apresentaram resultados menos expressivos.

A análise da importância das variáveis permite inferir a utilidade dos metadados processuais para previsão do tempo de duração das ações judiciais. Destacaram-se variáveis como a duração do processo no momento da observação, a data de trânsito em julgado e o órgão público envolvido, contribuindo com mais de 30% para o desempenho preditivo em pelo menos um dos modelos. Variáveis como assunto do processo, vara de origem e tribunal vinculado tiveram relevância secundária, mas ainda contribuíram com até 15% para as previsões dos modelos.

Esses resultados confirmam a hipótese inicial de que metadados processuais, como vara de origem, órgão público envolvido e data de trânsito em julgado, são úteis para prever o tempo de duração das ações judiciais. Dessa forma, o objetivo geral da pesquisa foi alcançado, com uma análise robusta sobre a utilidade dos metadados processuais para previsão do tempo de duração de ações que resultaram em precatórios federais.

Este estudo apresenta contribuições tanto no âmbito prático quanto no teórico. No campo prático, para além da aplicação na análise de riscos fiscais judiciais em âmbito federal, os achados podem beneficiar estados, municípios e até mesmo entidades privadas que enfrentam altos níveis de judicialização. As metodologias propostas podem ser adaptadas para prever e gerenciar passivos judiciais, reduzindo incertezas e auxiliando no planejamento financeiro.

Além disso, litigantes individuais, como pessoas físicas e empresas, também podem se beneficiar da previsibilidade do tempo de duração dos processos. Sob a perspectiva da Análise Econômica do Direito, a maior clareza sobre os custos e tempos envolvidos nos processos judiciais pode facilitar acordos e incentivar o uso de meios alternativos de resolução de conflitos, como conciliação e arbitragem.

No âmbito teórico, a pesquisa avança o conhecimento sobre a previsão da duração de processos judiciais, um tema que reflete a complexidade do sistema jurídico e a interação de múltiplos fatores. Além de propor uma abordagem complementar para os atuais métodos de análise de riscos judiciais, o estudo usa uma modelagem alternativa para previsão e análise de sobrevivência sem dados censurados, incorporando a duração do processo como variável independente em modelos longitudinais.

Pesquisas futuras poderiam adaptar as metodologias propostas para outros contextos, como litígios em estados e municípios, disputas empresariais ou passivos de setores específicos. A extensão do uso de metadados processuais e ferramentas preditivas a esses novos cenários ajudaria a consolidar o papel dessas abordagens na gestão de riscos judiciais, ampliando ainda mais o impacto prático e científico deste estudo.

Apesar das contribuições, a pesquisa apresenta limitações inerentes à abordagem adotada. O foco em ações judiciais em fase de execução restringe a análise aos riscos fiscais associados a precatórios, deixando de fora outras dimensões importantes, como processos em fase de conhecimento, passivos administrativos ainda não judicializados, elevações de despesas correntes e quedas de arrecadação tributária. Essa delimitação reduz a abrangência dos resultados para outros aspectos dos riscos fiscais judiciais.

Convém lembrar que a indisponibilidade de dados mais detalhados sobre ações judiciais pode ter limitado o desempenho dos modelos preditivos. Assim, pesquisas futuras poderiam levantar dados complementares, como andamento processual, tipo de ação, valor da causa e características das partes litigantes, os quais poderia aumentar a

acurácia dos modelos. Da mesma forma, a inclusão de processos pendentes na base de estudo permitiria trabalhar com dados censurados e aplicar modelos clássicos de análise de sobrevivência, ampliando o escopo e a robustez dos resultados. Essas incorporações podem ser uma extensão promissora do presente estudo.

Outro caminho aberto se refere a estudos sobre inferência causal, com foco nos fatores estruturais e institucionais que determinam a variabilidade na duração dos processos judiciais. Técnicas de inferência estatística poderiam ajudar a identificar e quantificar os efeitos de variáveis específicas sobre o tempo de duração das ações, como recursos processuais, características das partes litigantes, acordos, assuntos dos processos e varas de origem. Essas análises ajudariam a aprofundar a compreensão sobre os mecanismos subjacentes que influenciam o tempo de tramitação processual.

Por fim, estudos no campo da economia política dos riscos judiciais poderiam explorar a relação entre instituições, incentivos e tempo de duração do processo judicial, como os perigos morais no adiamento de pagamentos de precatórios e na gestão de litígios. Questões como a influência de metas judiciais, práticas de aceleração processual e possíveis efeitos colaterais de políticas públicas poderiam oferecer *insights* relevantes para a formulação de estratégias mais eficazes de gestão fiscal e judicial.

Dessa forma, o presente estudo contribui para melhorar compreensão dos riscos fiscais judiciais, em especial do tempo de duração das ações. A pesquisa confirma a utilidade de metadados processuais e modelos de *machine learning* para previsão do tempo de tramitação dos processos, oferecendo perspectivas para futuras investigações e soluções mais eficazes na análise de riscos e na gestão fiscal e judicial.

## REFERÊNCIAS

ALETRAS, Nikolaos et al. Predicting judicial decisions of the European Court of Human Rights: A natural language processing perspective. *PeerJ Computer Science*, v. 2, p. e93, 2016. Disponível em: <https://peerj.com/articles/cs-93.pdf>. Acesso em: 03/12/2024.

ALARIE, Benjamin; NIBLETT, Anthony; YOON, Albert H. Using machine learning to predict outcomes in tax law. *Canadian Business Law Journal*, v. 58, p. 231, 2016.

ALMEIDA, Frederico de. Intelectuais e reforma do Judiciário: os especialistas em direito processual e as reformas da justiça no Brasil. *Revista Brasileira de Ciência Política*, p. 209-246, 2015.

ANGRIST, Joshua D.; PISCHKE, Jörn-Steffen. *Mostly harmless econometrics: An empiricist's companion*. Princeton University Press, 2009.

ASHLEY, Kevin D. *Artificial intelligence and legal analytics: new tools for law practice in the digital age*. Cambridge University Press, 2017.

BARNABÉ, Magnamara Acácio Pimentel. *Predição de risco jurídico de instituições financeiras*. 2022. 117 f., il. Dissertação (Mestrado em Economia) — Universidade de Brasília, Brasília, 2022. Disponível em: <http://repositorio2.unb.br/jspui/handle/10482/44215>. Acesso em: 10 jan. 2024.

BISHOP, Christopher M.; NASRABADI, Nasser M. *Pattern recognition and machine learning*. Suíça: Springer New York, 2006.

BRASIL. Constituição da República Federativa do Brasil de 1988. Brasília, DF: Presidência da República, 2016. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/constituicao/constituicao.htm](https://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm). Acesso em: 10 nov. 2024.

BRASIL. Conselho Nacional de Justiça (CNJ). *Justiça em números 2024*. Brasília: CNJ, 2024. Disponível em: <https://www.cnj.jus.br/wp-content/uploads/2024/05/justica-em-numeros-2024.pdf>. Acesso em: 02/12/2024.

BRASIL. Conselho Nacional de Justiça (CNJ). *Painel de Grandes Litigantes*. Brasília: CNJ, 2024. Disponível em: <https://justica-em-numeros.cnj.jus.br/painel-litigantes/>. Acesso em: 02/12/2024.

BRASIL. Decreto nº 11.379, de 12 de janeiro de 2023. Brasília, DF: Presidência da República, 2023. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2023-2026/2023/decreto/D11379.htm](https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2023/decreto/D11379.htm). Acesso em: 10 nov. 2024.

BRASIL. Lei nº 10.259, de 12 de julho de 2001. Brasília, DF: Presidência da

República, 2001. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/leis/LEIS\\_2001/L10259.htm](https://www.planalto.gov.br/ccivil_03/leis/LEIS_2001/L10259.htm). Acesso em: 10/11/2024.

BRASIL. Lei nº 13.105, de 16 de março de 2015. Código de Processo Civil. Brasília, DF: Presidência da República, 2015. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2015/lei/L13105.htm](https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/L13105.htm). Acesso em: 10/11/2024.

BRASIL. Lei nº 14.971, de 29 de dezembro de 2023. Brasília, DF: Presidência da República, 2023. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2023-2026/2023/lei/L14971.htm](https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2023/lei/L14971.htm). Acesso em: 10/11/2024.

BRASIL. Ministério do Trabalho e Previdência. *Informe de Previdência Social 06/2021. Vol. 33 – Nº 06*. Disponível em: <https://www.gov.br/previdencia/pt-br/assuntos/previdencia-social/informes-de-previdencia-social/2021/informe-de-previdencia-junho-2021.pdf>. Acesso em 23/11/2024.

BRASIL. Portaria Normativa AGU nº 68, de 18 de novembro de 2022. Brasília, DF: Advocacia-Geral da União, 2023. Disponível em: <https://www.gov.br/agu/pt-br/normas-da-agu/PORTARIANORMATIVA068INFORMAESDEAESJUDICIAISQUEREPRESENTAMRISCOSFISCAISUNIO.pdf>. Acesso em: 02/12/2024.

BRASIL. Secretaria do Tesouro Nacional. *Relatório de Riscos Fiscais da União: 2022 - Novembro*. Brasília, DF: Tesouro Nacional, 2022. Disponível em: <https://www.tesourotransparente.gov.br/publicacoes/relatorio-de-riscos-fiscais-da-uniao/2022/114>. Acesso em: 10/01/2024.

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

BREIMAN, Leo. Statistical modeling: The two cultures. *Quality Control and Applied Statistics*, v. 48, n. 1, p. 81-82, 2003.

COASE, R. H. The problem of social cost. *Journal of Law and Economics*, v. 3, n. 1, p. 1-44, 1960.

COHEN, J. Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. *Psychological Bulletin*, v. 70, n. 4, p. 213–220, 1968.

COX, David R. Regression models and life-tables. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 34, n. 2, p. 187-202, 1972.

DI PIETRO, M. S. Z. *Direito Administrativo*. 34. ed. São Paulo: Thomson Reuters Brasil, 2021.

FRIEDMAN, M. *Capitalism and freedom*. Chicago: University of Chicago Press,

1962.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. *The elements of statistical learning: data mining, inference, and prediction*. 2017.

HSIAO, Cheng. *Analysis of panel data*. Cambridge University Press, 2022.

JACOB DE MENEZES-NETO, Elias; CLEMENTINO, Marco Bruno Miranda. Using deep learning to predict outcomes of legal appeals better than human experts: A study with data from Brazilian federal courts. *PLOS ONE*, v. 17, n. 7, p. e0272287, 2022.

KALBFLEISCH, John D.; PRENTICE, Ross L. *The statistical analysis of failure time data*. John Wiley & Sons, 2002.

KAPLAN, Edward L.; MEIER, Paul. Nonparametric estimation from incomplete observations. *Journal of the American Statistical Association*, v. 53, n. 282, p. 457-481, 1958.

KATZ, Daniel Martin; BOMMARITO, Michael J.; BLACKMAN, Josh. A general approach for predicting the behavior of the Supreme Court of the United States. *PLOS ONE*, v. 12, n. 4, p. e0174698, 2017.

KE, G.; Meng, Q.; FINLEY, T.; WANG, T.; CHEN, W.; MA, W.; ... & LIU, T.-Y. LightGBM: A highly efficient gradient boosting decision tree. In: *Advances in Neural Information Processing Systems*, p. 3146-3154, 2017.

KEYNES, J. M. *The general theory of employment, interest and money*. London: Palgrave Macmillan, 1936.

KLEIN, John P.; MOESCHBERGER, Melvin L. *Survival analysis: techniques for censored and truncated data*. Springer Science & Business Media, 2006.

KUHN, Max; JOHNSON, Kjell. *Applied predictive modeling*. 2013.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159-174, 1977.

LAWLESS, Jerald F. *Statistical models and methods for lifetime data*. John Wiley & Sons, 2011.

MARINONI, L. G. *Precedentes obrigatórios*. 7. ed. São Paulo: Revista dos Tribunais, 2022.

MULLAINATHAN, Sendhil; SPIESS, Jann. Machine learning: an applied econometric approach. *Journal of Economic Perspectives*, v. 31, n. 2, p. 87-106, 2017.

MURPHY, Kevin P. *Machine learning: a probabilistic perspective*. MIT Press,

2012.

MUSGRAVE, Richard Abel; MUSGRAVE, Richard A. *The theory of public finance: a study in public economy*. New York: McGraw-Hill, 1959.

NORTH, D. C. *Institutions, institutional change, and economic performance*. Cambridge: Cambridge University Press, 1990.

SHMUELI, G. To explain or to predict?. *Statistical Science*, v. 25, n. 3, p. 289-310, 2010.

SILVA, Rwrsilany; BERNARDO, Cleice de P.; VIANA, Adriana B. N.; SANTOS, Rogerio P. dos. The role of jurimetrics and predictive analysis in judicial decision making: a current panorama. *Anais do XXVI Seminário em Administração*. São Paulo: EAD/FEA/USP, 2023. Disponível em: <https://login.semead.com.br/26semead/anais/arquivos/925.pdf>. Acesso em: 24 nov. 2024.

SOUSA, Tatiane A. O. de. Modelo de risco para provisão judicial: método quantitativo para aplicação em instituição financeira. 2021. 38 f., il. Dissertação (Mestrado em Economia) — Universidade de Brasília, Brasília, 2021. Disponível em: <http://repositorio2.unb.br/jspui/handle/10482/45098>. Acesso em: 10 jan. 2024.

VARIAN, Hal R. Big Data: New Tricks for Econometrics. *Journal of Economic Perspectives*, v. 28, n. 2, p. 3–28, 2014. Disponível em: <https://www.aeaweb.org/articles/pdf/doi/10.1257/jep.28.2.3>. Acesso em: 03/12/2024.

VASCONCELOS, Caio Castelliano de. Judicialização no Brasil e na Europa: uma Comparação com Base em Números. *Anais EnAJUS 2023*. Disponível em: <https://enajus.org.br/anais/assets/papers/2023/sessao-23/judicializacao-no-brasil-e-na-europa-uma-comparacao-com-base-em-numeros.pdf>. Acesso em: 02/12/2024.

WOOLDRIDGE, Jeffrey M. *Econometric analysis of cross section and panel data*. MIT Press, 2010.

## ANEXO A – BIBLIOTECAS E ALGORITMOS COMPUTACIONAIS

O estudo foi desenvolvido com uso de ferramentas computacionais na linguagem de programação *Python*. O Quadro A.1 apresenta as bibliotecas utilizadas, acompanhadas de descrição resumida de sua função.

Quadro A. 1 - Bibliotecas *Python* utilizadas no estudo

<b>Categoria</b>	<b>Biblioteca</b>	<b>Descrição</b>
<b>Manipulação de Dados</b>	<i>pandas</i>	Ferramenta para manipulação e análise de dados estruturados, como <i>dataframes</i> e séries temporais.
	<i>numpy</i>	Biblioteca para computação numérica, com suporte para <i>arrays</i> e funções matemáticas de alto desempenho.
<b>Visualização de Dados</b>	<i>matplotlib.pyplot</i>	Biblioteca para criação de gráficos estáticos e personalizáveis.
	<i>seaborn</i>	Extensão do <i>Matplotlib</i> que oferece gráficos estatísticos e visuais otimizados.
<b>Processamento de Dados</b>	<i>sklearn.preprocessing</i>	Ferramentas para pré-processamento, como padronização ( <i>StandardScaler</i> ), normalização ( <i>MinMaxScaler</i> ), e codificação ( <i>LabelEncoder</i> , <i>OneHotEncoder</i> ).
	<i>sklearn.compose</i>	Ferramentas para transformação em <i>pipelines</i> , como o <i>ColumnTransformer</i> , que aplica transformações específicas a colunas.
<b>Modelagem e Treinamento</b>	<i>sklearn.model_selection</i>	Módulo para dividir dados em treino e teste ( <i>train_test_split</i> ), realizar validação cruzada e busca de hiperparâmetros ( <i>GridSearchCV</i> ).
	<i>sklearn.linear_model</i>	Implementação de modelos lineares, como regressão linear ( <i>LinearRegression</i> ) e logística ( <i>LogisticRegression</i> ).
	<i>sklearn.naive_bayes</i>	Implementação do classificador <i>Naive Bayes</i> Gaussiano ( <i>GaussianNB</i> ).
	<i>sklearn.ensemble</i>	Modelos de ensemble, como <i>Random Forest</i> ( <i>RandomForestClassifier</i> , <i>RandomForestRegressor</i> ) e <i>Gradient Boosting</i> ( <i>HistGradientBoostingClassifier</i> ).
<b>Métricas e Avaliação</b>	<i>sklearn.metrics</i>	Ferramentas para avaliação de modelos, como acurácia ( <i>accuracy_score</i> ), precisão ( <i>precision_score</i> ), <i>F1-Score</i> ( <i>f1_score</i> ), Kappa de Cohen ( <i>cohen_kappa_score</i> ), entre outras.
<b>Outros</b>	<i>pickle</i>	Ferramenta que permite salvar e carregar objetos Python (como modelos e dados) para reutilização.
	<i>time</i>	Biblioteca padrão para medições de tempo e controle de execução.
	<i>tqdm</i>	Biblioteca para exibição de barras de progresso durante execuções iterativas

Fonte: Elaborado pelo autor (2024).

O Quadro A.2 apresenta os hiperparâmetros dos algoritmos de cada modelo, selecionados de acordo com o critério de melhor acurácia preditiva em procedimento de validação cruzada, descrito na seção “3.5.1 Algoritmos”.

Quadro A. 2 - Hiperparâmetros dos algoritmos selecionados em validação cruzada

<b>Modelo</b>	<b>Algoritmo</b>	<b>Hiperparâmetros</b>
<b>MTA</b>	<i>Logit</i>	{'C': 10, 'max_iter': 100, 'penalty': 'l2'}
	<i>Naive Bayes</i>	{'var_smoothing': 1e-05}
	<i>Random Forest</i>	{'max_features': None, 'min_samples_leaf': 10}
	<i>Hist. Grad. Boosting</i>	{'learning_rate': 0.1, 'max_features': 0.6, 'min_samples_leaf': 10}
<b>MTT</b>	<i>Logit</i>	{'C': 0.1, 'max_iter': 50, 'penalty': 'l2'}
	<i>Naive Bayes</i>	{'var_smoothing': 1e-05}
	<i>Random Forest</i>	{'max_features': 3, 'min_samples_leaf': 1000}
	<i>Hist. Grad. Boosting</i>	{'learning_rate': 0.1, 'max_features': 0.6, 'min_samples_leaf': 10000}
<b>MLT</b>	<i>Logit</i>	{'C': 0.1, 'max_iter': 50, 'penalty': 'l2'}
	<i>Naive Bayes</i>	{'var_smoothing': 1e-05}
	<i>Random Forest</i>	{'max_features': 6, 'min_samples_leaf': 10000}
	<i>Hist. Grad. Boosting</i>	{'learning_rate': 0.1, 'max_features': 0.3, 'min_samples_leaf': 10000}
<b>MLR</b>	<i>Logit</i>	{'C': 0.1, 'max_iter': 50, 'penalty': 'l1'}
	<i>Naive Bayes</i>	{'var_smoothing': 1e-05}
	<i>Random Forest</i>	{'max_features': 6, 'min_samples_leaf': 10}
	<i>Hist. Grad. Boosting</i>	{'learning_rate': 0.1, 'max_features': 0.6, 'min_samples_leaf': 1000}

Fonte: Elaborado pelo autor (2024).