

AVANÇOS INICIAIS DO PROJETO CONCIL-IA: desafios e potenciais impactos¹

PRELIMINARY PROGRESS OF THE CONCIL-IA PROJECT: challenges and potential impacts

Isabela Cristina Sabo², Andressa Silveira Viana Maurmann³, Guilherme de Brito Santos⁴, Maykon Marcos Junior⁵, Maite Fortes Vieira⁶, Joao Gabriel Mohr⁷, Cristian Alexandre Alchini⁸, Luísa Bollmann⁹, Lucas de Castro Rodrigues Pereira¹⁰, Aires Jose Rover¹¹

Recebido em 08/11/2024. Aceito em 03/02/2025.

Resumo

O artigo explora os avanços iniciais do projeto Concil-IA, desenvolvido como uma resposta ao crescente volume de processos no Judiciário brasileiro. Esse cenário, que gera uma carga significativa de trabalho, impulsionou o Conselho Nacional de Justiça (CNJ) a implementar políticas para soluções autocompositivas e tecnologias baseadas em Inteligência Artificial (IA). O objetivo do projeto Concil-IA é criar um sistema de resolução de disputas online (ODR) com suporte de IA, especialmente focado em casos de Direito do Consumidor, para facilitar a conciliação de conflitos e reduzir a judicialização. O método de abordagem constitui no indutivo, uma vez que foi possível inferir conhecimento. Já os procedimentos adotados no projeto incluem a coleta de sentenças judiciais, identificação de variáveis-chave e uso do modelo GPT para extrair essas variáveis de forma automatizada, além do desenvolvimento de um modelo de classificação para prever faixas de indenização por danos

¹ Os autores expressam seu agradecimento à Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro ao projeto e pelas bolsas concedidas.

² Doutora em Direito pela Universidade Federal de Santa Catarina. E-mail: isabelasabo@gmail.com.

³ Mestranda em Direito pela Universidade Federal de Santa Catarina. E-mail: andressasmviana@gmail.com.

⁴ Graduando em Direito pela Universidade Federal de Santa Catarina. E-mail: guisapezal@gmail.com.

⁵ Graduando em Ciência da Computação pela Universidade Federal de Santa Catarina. E-mail: maykonmjuniorgmail.com.

⁶ Graduanda em Direito pela Universidade Federal de Santa Catarina. E-mail: fortesvieiramaite@gmail.com.

⁷ Graduando em Direito pela Universidade Federal de Santa Catarina. E-mail: mohr009gm@gmail.com.

⁸ Graduando em Ciência da Computação pela Universidade Federal de Santa Catarina. E-mail: alchinicristian@gmail.com.

⁹ Graduanda em Direito pela Universidade Federal de Santa Catarina. E-mail: luisa.bollmann@gmail.com.

¹⁰ Mestrando em Direito pela Universidade Federal de Santa Catarina. E-mail: lucascastrorp@gmail.com.

¹¹ Doutor em Direito pela Universidade Federal de Santa Catarina. Professor Associado da mesma Universidade, lotado no Departamento de Direito. E-mail: aires.rover@gmail.com.

morais, com previsões explicáveis. Os resultados iniciais mostram que o modelo GPT-4.5 alcançou uma acurácia superior a 90% na extração automatizada de variáveis das sentenças judiciais, enquanto o modelo de classificação para faixas de indenização obteve uma acurácia média de aproximadamente 50%, indicando a necessidade de ajustes e melhorias. Além disso, foi desenvolvida uma interface web para tornar o modelo acessível a mediadores e às partes envolvidas no processo de conciliação, oferecendo uma plataforma amigável que facilita a interação com o modelo preditivo e apoia a tomada de decisões em tempo real. Em conclusão, os avanços obtidos sugerem que a IA pode inovar e tornar o sistema judicial mais eficiente, promovendo uma justiça mais acessível e orientada à conciliação.

Palavras-chave

Inteligência Artificial; Conciliação Judicial; Resolução de Disputas Online; Direito do Consumidor.

Abstract

The article explores the initial progress of the Concil-IA project, developed as a response to the growing volume of cases in the Brazilian Judiciary. This scenario, which creates a significant workload, has prompted the National Council of Justice (CNJ) to implement policies for self-compositional solutions and technologies based on Artificial Intelligence (AI). The objective of the Concil-IA project is to create an AI-supported online dispute resolution (ODR) system, especially focused on consumer law cases, to facilitate conflict resolution and reduce litigation. The project's methodology includes collecting judicial rulings, identifying key variables, and using the GPT model to automatically extract these variables, as well as developing a classification model to predict ranges of compensation for moral damages, with explainable predictions. The initial results show that the GPT-4.5 model achieved an accuracy rate of over 90% in the automated extraction of variables from judicial rulings, while the compensation classification model obtained an average accuracy of approximately 50%, indicating a need for further adjustments and improvements. Additionally, a web interface was developed to make the model accessible to mediators and parties involved in the conciliation process, offering a user-friendly platform that facilitates interaction with the predictive model and supports real-time decision-making. In conclusion, the progress made suggests that AI can innovate and make the judicial system more efficient, promoting more accessible and conciliation-oriented justice.

Keywords

Artificial Intelligence; Judicial Conciliation; Online Dispute Resolution; Consumer Law.

1 Introdução

O Poder Judiciário brasileiro enfrenta um cenário de crescente litigiosidade, conforme aponta o último relatório "Justiça em Números", divulgado anualmente pelo Conselho Nacional de Justiça (CNJ, 2024). Diante desse aumento constante no ajuizamento de novas ações judiciais, o CNJ tem adotado políticas, das quais se verificam duas agendas principais para aprimorar o tratamento dos conflitos e minimizar a sobrecarga processual.

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. *Revista Democracia Digital e Governo Eletrônico*, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

A primeira agenda foca na promoção de meios autocompositivos de solução de conflitos antes e durante o processo judicial, com a centralização das estruturas judiciárias e a adequada formação de conciliadores e mediadores. Este cenário é representado pela implementação da Política Judiciária Nacional de Tratamento Adequado dos Conflitos de Interesses, através da Resolução nº 125 de 2010, com vista à boa qualidade dos serviços e à disseminação da cultura de pacificação social (CNJ, 2010).

A segunda agenda prioriza o uso intensivo de tecnologias da informação, criando aberturas e incentivos para promover soluções automatizadas baseadas em Inteligência Artificial (IA), incluindo o emprego de técnicas de Aprendizado de Máquina (*Machine Learning* – ML) e Aprendizado Profundo (*Deep Learning* – DL). Nessa linha, destaca-se a Resolução nº 332 de 2020, que instituiu o SINAPSES, plataforma nacional de armazenamento, treinamento supervisionado, controle de versionamento, distribuição e auditoria dos modelos de IA, além de estabelecer os parâmetros de sua implementação e funcionamento (CNJ, 2020).

Neste contexto, o projeto de pesquisa Concil-IA surge como uma resposta multidisciplinar a esses desafios. Desenvolvido pelo grupo de pesquisa Governo Eletrônico, Inclusão Digital e Sociedade do Conhecimento da Universidade Federal de Santa Catarina (EGOV/UFSC), em parceria com o Juizado Especial Cível (JEC) da instituição, o projeto tem como principal objetivo a criação de um sistema de resolução de disputas online (ODR) baseado em IA, que possa auxiliar na conciliação de conflitos.

Especificamente, o desenvolvimento do projeto abrange as seguintes frentes:

- (a) A coleta de sentenças condenatórias de indenização por danos morais envolvendo temáticas de Direito do Consumidor.
- (b) A identificação e extração automatizada de fatores preditivos das sentenças (variáveis do caso que impactam especialmente no arbitramento do valor da indenização por danos morais), com o auxílio do modelo de linguagem grande multimodal *Generative Pre-trained Transformer* (GPT).
- (c) A construção de modelo preditivo baseado em técnicas de Aprendizado de Máquina, especificamente de classificação, apresentando como saída predições de faixas de indenização por danos morais.
- (d) A aplicação de técnicas de Inteligência Artificial Explicável (*Explainable Artificial Intelligence* – XAI), com predições que sejam explicáveis ao usuário, relacionando o valor de indenização gerado pelo modelo com os fatores preditivos extraídos.
- (e) A disponibilização do modelo através de interface web para as partes e conciliadores.

A estrutura do artigo é organizada da seguinte forma: a Seção 2 apresenta os trabalhos relacionados ao projeto, com ênfase na construção e aplicação de modelos preditivos em contextos judiciais e extrajudiciais; a Seção 3 descreve a metodologia de desenvolvimento do projeto; a Seção 4 aborda os resultados iniciais; e, por fim, a Seção 5 traz as considerações finais e os próximos passos.

2 Revisão de Literatura

É uma tendência nos últimos tempos a busca por sistemas de automatização para auxiliar nas tarefas desempenhadas por instituições de Justiça no mundo todo. A IA, por exemplo, é utilizada para definir medidas estratégicas tanto para execução da atividade fim, mas também para decisões do ponto de vista da gestão e fluxo de trâmite de processos judiciais (PEIXOTO; SILVA, 2019). Para consolidar a relevância do tema abordado nesta pesquisa, destacam-se trabalhos que têm como objetivo o desenvolvimento de modelos preditivos baseados em ML e DL realizados a partir do manuseio de dados de ambientes judiciais e extrajudiciais. Para isso, expõem-se pesquisas no contexto mundial, nacional e estadual.

Em ambientes judiciais, diversos modelos preditivos têm sido aplicados em Cortes Superiores. Na Suprema Corte dos EUA, o modelo desenvolvido por Katz, Bommarito e Blackman (2014, 2017) prevê o comportamento do tribunal em determinados temas jurídicos. Para isso, foram utilizados os votos de uma parcela de juízes que integraram a Corte no decorrer dos anos, momento em que confirmaram a manutenção ou alteração da decisão da instância inferior. Neste caso, as variáveis utilizadas foram o ano do caso, a matéria discutida, o local da instância inferior, entre outras.

Na Corte Europeia de Direitos Humanos (CEDH), formada por 47 Estados-membros, o modelo de Aletras *et al.* (2016) prevê se um Estado-membro violou direitos civis e políticos previstos na Convenção Europeia de Direitos Humanos. O estudo destacou que a seção dos fatos é o fator preditivo mais relevante, o que demonstrou que a decisão judicial é significativamente influenciada pelas narrativas apresentadas pelas partes.

Modelos semelhantes foram aplicados em outros ambientes judiciais. Na Suprema Corte das Filipinas, o modelo de Virtucio *et al.* (2018) foi utilizado para prever decisões judiciais em processos criminais, a fim de reduzir a litigiosidade. Já na Suprema Corte da Índia, o modelo de Sharma, Shandilya e Sharma (2022) prevê o resultado de recursos judiciais, classificando-os em “aceitar”, “rejeitar” ou “descartar”. Esse modelo, implementado no sistema “eLeg-Predict”, processa automaticamente novos casos e gera previsões.

Além do contexto judicial, modelos preditivos também são empregados em ambientes extrajudiciais. Na Itália, o sistema “CLAUDETTE” identifica cláusulas abusivas em Termos de Serviço ao analisar contratos de empresas como Microsoft, Amazon e Facebook (LIPPI *et al.*, 2019). Na Alemanha, pesquisadores testaram a portabilidade de modelos de aprendizado de máquina em documentos jurídicos, a partir da aplicação de algoritmos treinados por um conjunto de dados sobre a Lei de Locação e aplicaram os melhores modelos em conjunto de dados sobre contratos de locação (GLASER; SCEPANKOVA; MATTHES, 2018). Outro exemplo é o sistema “CUAD”, que auxilia na revisão legal de contratos, ao destacar partes relevantes para revisão de um humano (HENDRYCKS *et al.*, 2021). Embora todos esses modelos apresentem alta precisão, nenhum deles é capaz de explicar de forma clara o raciocínio por trás de suas predições.

No âmbito nacional, o Supremo Tribunal Federal (STF) implementou o projeto “VICTOR”, que consiste na utilização de um modelo preditivo que identifica se os processos ingressados

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

na Corte estão relacionados a temas de repercussão geral (RG). A RG é um filtro recursal que permite ao STF selecionar recursos com base em critérios de relevância jurídica, política, social ou econômica. Esse projeto otimizou significativamente o tempo dos servidores nessa tarefa (SILVA *et al.*, 2018).

Outro modelo treinado com dados de processos tramitados pelo STF foi desenvolvido por Dal Pont *et al.* (2021). O modelo, baseado em ML e DL, analisa dados não estruturados e estruturados de decisões proferidas em *habeas corpus* sobre prisão preventiva, como categoria do crime, juiz relator e *status* do preso. A partir desses dados, se prevê, de forma binária, se o *habeas corpus* será concedido e, conseqüentemente, permitida a soltura do preso preventivo.

No Tribunal de Justiça do Estado do Rio de Janeiro (TJRJ), Fernandes *et al.* (2020) propuseram um modelo preditivo para analisar apelações referentes à negativação indevida e danos morais em casos envolvendo Direito do Consumidor. O sistema extrai informações sobre modificações feitas pelo Tribunal e pode ajudar advogados a entender como o TJRJ interpreta a lei, além de auxiliar juizes a verificar se suas decisões estão alinhadas com a jurisprudência, o que promove maior consistência judicial.

No Tribunal de Justiça do Estado de Goiás (TJGO), Júnior, Wainer e Calixto (2021) desenvolveram um modelo preditivo para associar novas ações judiciais a Incidentes de Resolução de Demandas Repetitivas (IRDRs), a fim de aplicar entendimentos judiciais conforme a reforma do CPC de 2015. Outro exemplo relevante é o CICIAR, da Defensoria Pública do Rio de Janeiro (DPRJ), a qual utiliza IA para priorizar e categorizar intimações, sem abrir seu conteúdo e iniciar o prazo para atendimento (PARREIRAS *et al.*, 2022).

No Tribunal de Justiça do Estado de Santa Catarina (TJSC), uma parceria entre o grupo de pesquisa e o Juizado Especial Cível da Universidade Federal de Santa Catarina (JEC/UFSC) resultou na criação de um modelo preditivo baseado em aprendizado de máquina (ML). Esse modelo prevê o resultado de ações relacionadas a falhas no transporte aéreo, em que consumidores demandam indenização por danos morais contra companhias aéreas. O modelo foi desenvolvido em quatro etapas: (i) extração de fatores preditivos (SABO *et al.*, 2021); (ii) análise da semântica e sintaxe das decisões judiciais (DAL PONT *et al.*, 2020); (iii) previsão categórica do resultado, ou seja, se o consumidor ganha ou não a causa (SABO *et al.*, 2019); e (iv) previsão do valor da indenização por danos morais (DAL PONT, 2021; DAL PONT *et al.*, 2023).

O modelo foi utilizado durante audiências de conciliação, nas quais as predições foram apresentadas às partes envolvidas - consumidores, companhias aéreas e seus advogados - para facilitar a negociação e a celebração de acordos. O sistema visava evitar o prolongamento do processo judicial. No entanto, assim como ocorre com outros modelos preditivos aplicados em diferentes contextos, ele não explica as razões por trás das previsões, o que representou uma dificuldade no momento da aplicação prática (SABO, 2022).

Para que um modelo preditivo seja confiável e efetivamente utilizado no ambiente judicial, é essencial que ele ofereça transparência ao apresentar os fatores e o raciocínio jurídico envolvidos na decisão. Sem essa explicabilidade, há resistência por parte das partes

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

interessadas, especialmente quando a indenização estimada pelo modelo não corresponde às expectativas do consumidor. Nesses casos, o consumidor pode preferir aguardar pela sentença judicial em vez de aceitar a previsão, ressaltando a importância de fornecer explicações claras que justifiquem as previsões.

Os estudos apresentados revelam que, tanto em contextos nacionais quanto internacionais, existem modelos preditivos baseados em ML e DL com alta acurácia na previsão de decisões judiciais. No Brasil, contudo, a utilização dessas tecnologias para prevenir a judicialização - por meio de soluções consensuais e preventivas - ainda é limitada, o que evidencia uma lacuna no uso desses modelos para fomentar práticas que reduzam a entrada de novos casos no sistema judiciário.

3 Metodologia de Desenvolvimento do Projeto

3.1 *Coleta de Sentenças Condenatórias de Indenização por Danos Morais e Identificação de Variáveis*

Os dados utilizados no treinamento do modelo a ser desenvolvido consiste em sentenças judiciais proferidas pelo JEC/UFSC. O Juizado Especial Cível é um órgão relevante no ordenamento jurídico pela ausência de custas no primeiro grau e a desnecessidade da presença de advogados, em causas que não excedam 20 salários mínimos. Isso, embora tenha facilitado o acesso à Justiça, também atraiu inúmeras demandas. Apenas em 2023, por exemplo, houve 6.155.368 ações ajuizadas perante o JEC em nível nacional (CNJ, 2024). Nesse sentido, a análise das sentenças contidas no JEC/UFSC é essencial para entender quais são as principais demandas propostas e de que maneira elas são julgadas.

A coleta dos documentos foi facilitada pela parceria existente entre a equipe de pesquisa e o Órgão judiciário. As palavras-chaves utilizadas nas buscas pelas sentenças foram “transporte aéreo” ou “voo”, nos períodos de 08/02/2011 a 22/05/2024. Atualmente o banco de dados do projeto é composto por 1861 sentenças. As decisões se referem a litígios envolvendo Direito do Consumidor, especificamente falhas no serviço prestado por companhias aéreas.

A partir da análise de um especialista da área jurídica, identificaram-se variáveis que influenciam no arbitramento de danos morais, isto é, quais critérios são utilizados no momento de julgamento e o que influencia na majoração ou minoração dos danos morais, conforme apresentado no Quadro 1.

Quadro 1 - Variáveis identificadas pelo especialista

Variável	Objetivo
Resultado do julgamento (procedente/improcedente)	Verificar se o pedido foi concedido ou não.
Dano moral	Verificar se houve o reconhecimento do dano moral em decorrência do infortúnio sofrido pela parte consumidora.
Valor do dano moral	Verificar qual o valor da condenação aplicado pelo juízo.
Direito de arrependimento	Verificar a ocorrência de arrependimento da compra que pode ser pedido pelo autor, no prazo de 7 dias, quando essa ocorrer pela internet ou telefone.
Descumprimento de oferta	Verificar se a empresa descumpriu alguma das ofertas realizadas ao cliente.

Extravio de bagagem (definitivo/temporário)	Verificar a ocorrência do extravio de bagagem. De forma definitiva, a bagagem não é recuperada. De forma temporária a bagagem fica extraviada por um determinado período.
Intervalo de extravio	Verificar qual o tempo de extravio da bagagem.
Atraso	Verificar se o autor chegou no seu destino, e se isso ocorreu após um tempo de atraso.
Intervalo de atraso	Verificar qual o tempo que o consumidor levou para efetivamente chegar ao seu destino, considerando o horário indicado de chegada no momento da compra da passagem.
Cancelamento	Verificar se o consumidor não chegou até o seu destino.
Violação/furto/avaria	Verificar a ocorrência de violação, furto ou avaria da bagagem do consumidor.
Culpa exclusiva	Verificar quando o infortúnio ocorreu em decorrência da culpa exclusiva do consumidor (compareceu após o horário de embarque), o que exime a empresa de responsabilidade.
Condições climáticas	Verificar quando a viagem foi impossibilitada em decorrência de condições climáticas desfavoráveis.
<i>No-show</i>	Verificar quando o consumidor não comparece para o embarque, sem aviso prévio.
<i>Overbooking</i>	Verificar quando são vendidos mais bilhetes do que suporta a aeronave.
Assistência da companhia aérea	Verificar quando a companhia aérea presta algum tipo de assistência (alimentação/hotel/transporte alternativo).
Hipervulnerabilidade	Verificar quando o consumidor é pessoa idosa, gestante, deficiente, faz uso de medicamentos ou é pessoa acompanhada de crianças com até 12 anos incompletos.

Fonte: Elaborado pelos autores.

As variáveis identificadas têm como objetivo refletir o impacto da lesão sofrida pelo consumidor na sentença judicial. Por exemplo, quando ocorre o reconhecimento de dano moral, geralmente há fatores que podem agravar a condenação, como o tempo de atraso para alcançar o destino desejado, cuja duração pode variar substancialmente. No banco de dados do projeto, há registros de atrasos que vão de 4 a 72 horas, o que certamente interfere no valor da indenização arbitrada.

É importante ressaltar que, na amostra selecionada, algumas variáveis são enfatizadas pelos magistrados em suas fundamentações. Ou seja, eles declaram expressamente que determinadas variáveis foram consideradas no arbitramento dos danos morais. Por exemplo, a ausência de assistência adequada ao consumidor, ou uma assistência prestada de forma insatisfatória. Outro exemplo é o entendimento de que atrasos inferiores a 4 horas são vistos como meros dissabores, o que leva à improcedência do pedido de danos morais.

3.2 *Uso do GPT para Extração de Variáveis e Estruturação das Sentenças*

A Inteligência Artificial Generativa é um campo da IA focado na criação de conteúdo novo e original, como textos, imagens, sons e vídeos. Essa área utiliza dados existentes ou instruções do usuário para produzir conteúdo diversificado. Um avanço significativo na IA generativa é o desenvolvimento dos Modelos de Linguagem de Grande Escala (LLMs), que são redes neurais artificiais com capacidade de compreender e gerar linguagem natural e código de programação. O GPT (*Generative Pre-trained Transformer*) é um exemplo notável de

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

LLM. Essa família de modelos é pré-treinada generativamente em grandes volumes de dados textuais e visuais, podendo se adaptar a diferentes tarefas e domínios através do método de aprendizado de poucos exemplos (LUK, 2023).

No contexto da aplicação prática desses avanços tecnológicos, a pesquisa utiliza o modelo de linguagem GPT, desenvolvido pela OpenAI, para a extração automatizada de variáveis identificadas na Seção 3.1. Este processo visa a construção de uma base de dados estruturados, conforme indicado no Quadro 1. Especificamente, aplicou-se a versão 4.5 do modelo, que apresenta avanços notáveis na compreensão e geração de linguagem natural. Para obter e classificar os dados, desenvolveu-se um *prompt* — ou comando — que orienta o modelo a identificar e classificar informações com base em critérios previamente definidos por especialistas da área jurídica. A versão principal do *prompt* (*main*) está disponível na Seção 6 (Apêndice).

Para instruir o modelo LLM a extrair os valores pertinentes das sentenças, foram desenvolvidos diversos *prompts* de instrução com a ajuda de especialistas. A estrutura básica dos *prompts* usados é que as primeiras linhas são instruções gerais sobre o que o LLM deve fazer e a formatação da saída. Depois, seguem-se uma linha por variável, onde o significado de cada atributo é descrito para que o modelo o procure no texto da sentença, que vem por último.

Durante o desenvolvimento, diferentes combinações de instruções foram testadas, resultando em variados níveis de acurácia. As instruções principais, no entanto, foram progressivamente aprimoradas, como demonstra a estratégia de numerar as variáveis extraídas, que se mostrou extremamente eficaz para evitar que o modelo ignore variáveis ou insira valores não solicitados.

Quanto às variáveis descritas na Seção 3.1, explorou-se diversas abordagens para explicar cada conceito, incluindo versões que integravam múltiplas variáveis em uma única instrução. Essas experimentações permitiram refinar a metodologia de extração.

A avaliação da acurácia do modelo seguiu três etapas fundamentais: (a) inicialmente, um especialista da área jurídica estruturou manualmente uma amostra de 1174 sentenças, criando um padrão de referência baseado nas variáveis identificadas; (b) em seguida, utilizou-se o *prompt* do Apêndice para extrair as variáveis através do modelo de linguagem; (c) por fim, comparou-se as respostas do modelo com as respostas do especialista.

É importante destacar que as limitações de acesso ao modelo da OpenAI, especialmente as restrições no número diário de tokens, condicionaram significativamente a realização dos experimentos. Consequentemente, os testes da etapa (b) foram realizados em dois conjuntos independentes, cada um composto por 300 sentenças distintas (Conjunto A e Conjunto B) pertencentes à amostra de 1174.

Para facilitar a etapa (c), um código foi elaborado para identificar erros nas respostas, alterando-se a cor das células incorretas (ou seja, células que diferem das respostas do

especialista da área jurídica). Além disso, a cor da célula contendo o número de identificação (a primeira em cada linha) também é alterada caso haja algum erro nessa linha (ou seja, se o modelo, nessa sentença, divergir do especialista em alguma variável). Essa etapa não só permite uma análise quantitativa, mas também favorece uma análise qualitativa pelo mesmo especialista que extraiu as variáveis.

Os resultados obtidos com as diferentes versões do *prompt* serão apresentados na Seção 4.1.

3.3 Construção de Modelo de Classificação de Faixas de Indenização por Danos Morais

Após a identificação, extração e estruturação das sentenças — realizadas manualmente pelo especialista jurídico ou automaticamente com o auxílio do modelo GPT da OpenAI —, a próxima etapa consiste na construção de um modelo de classificação. A tarefa de classificação consiste em aprender uma função alvo f que mapeie cada conjunto de atributos x para um dos rótulos de classes y pré-determinados. Essa função alvo também é conhecida como modelo de classificação, o qual pode ser descritivo (para distinguir quais atributos definem o rótulo de uma classe) ou preditivo (para prever o rótulo não conhecido de uma classe). Exemplos de técnicas de classificação incluem Árvores de Decisão, Redes Neurais Artificiais, *Support Vector Machine* (SVM) Naive Bayes, entre outros (TAN; STEINBACH; KUMAR, 2009).

Como discutido na Seção 2, a equipe de pesquisa já possui trabalhos prévios nesse campo (SABO *et al.*, 2019; DAL PONT *et al.*, 2023). Contudo, o modelo de classificação em desenvolvimento se distingue dos anteriores, pois é especificamente treinado com os dados estruturados conforme as variáveis descritas no Quadro 1 (atributos) para prever valores de condenação por danos morais nas faixas descritas no Quadro 2 (rótulos de classe), em casos futuros semelhantes.

Quadro 2 - Faixas de dano moral (rótulos de classe)

Faixa	Dano Moral Individual (R\$)
0	0
1	1,00 - 2.000,00
2	2.001,00 - 4.000,00
3	4.001,00 - 6.000,00
4	6.001,00 - 8.000,00
5	8.001,00 - 10.000,00
6	$\geq 10.001,00$

Fonte: Elaborado pelos autores.

Assim, os dados de entrada correspondem às variáveis extraídas de cada sentença em arquivo CSV (*comma-separated values*), juntamente com a faixa referente ao valor arbitrado para danos morais. Esse formato inclui o seguinte pré-processamento: (a) conversão das variáveis categóricas binárias ('S' ou 'N') em formato numérico (0 ou 1); (b) categorização das variáveis

numéricas (intervalo de extravio, intervalo de tempo e valor do dano moral) em faixas. O pré-processamento também abrange a normalização dos dados.

A versão desenvolvida até o momento do modelo de classificação inclui apenas os dados estruturados pelo especialista da área jurídica, que corresponde à amostra de 1174 sentenças mencionada na Seção anterior.

Em relação às técnicas de classificação, foi utilizado o *GradientBoosting Classifier* (ZHANG; HAGHANI, 2015) com parâmetros padrão, implementado através da biblioteca *Python Scikit-learn*. O método de amostragem para criação dos conjuntos de treino e teste foi a validação cruzada (*cross validation*). Tal técnica divide a base de dados em k conjuntos disjuntos com tamanhos aproximadamente iguais. A partir daí, a cada etapa do treinamento, um conjunto é utilizado para teste e os demais como treino, de tal maneira que, cada conjunto criado será utilizado tanto para treino quanto para teste (WONG, 2015). Neste trabalho foi utilizado um total de 5 divisões. Como resultado de cada rodada na validação cruzada, será verificada a medida de acurácia para as quatro classes. Tal métrica indica a proporção de acertos em relação ao total de classificações feitas. Ao final, a avaliação se dará através da média das k acurácias calculadas para cada classe, respectivamente (WONG, 2015).

Os resultados da versão inicial do modelo de classificação serão apresentados na Seção 4.2.

3.4 *Elaboração de Interface Web para Disponibilização do Modelo aos Conciliadores, às Partes Interessadas e aos Advogados*

A elaboração de interface web para disponibilização do modelo de classificação envolveu uma abordagem colaborativa entre as áreas de Direito e Ciências da Computação.

O primeiro passo foi mapear as funcionalidades essenciais que a interface web deveria fornecer para apoiar a conciliação, que é sustentada pelo modelo de classificação preditivo. Esta etapa incluiu reuniões com especialistas da área jurídica e desenvolvedores para identificar as principais necessidades dos usuários, como acessibilidade, facilidade de uso e integração com a base de dados dos processos conciliatórios. A equipe também considerou importante que o sistema fosse intuitivo e compatível com diferentes dispositivos, ampliando seu alcance.

Com as funcionalidades mapeadas, a fase seguinte foi o desenvolvimento da aplicação web, projetada para oferecer uma experiência amigável e eficiente. Esta aplicação inclui uma interface inicial visualmente atraente e de fácil navegação, com atenção à arquitetura da informação para organizar claramente as funcionalidades e opções do sistema, permitindo que pesquisadores, conciliadores, partes interessadas na conciliação e advogados possam utilizá-la de forma intuitiva.

Esta interface foi desenvolvida utilizando o *framework React* e oferece um formulário para que os usuários possam inserir as informações pertinentes ao seu caso. Após o preenchimento, os dados são enviados à API (Interface de Programação de Aplicações) da aplicação, que os

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

utiliza como entrada para o modelo de classificação. Esse modelo, por sua vez, retornará as informações relativas aos possíveis danos morais.

Esta aplicação web, incluindo tanto a interface quanto a API, foi hospedada no serviço de containers Docker da Superintendência de Governança Eletrônica e Tecnologia da Informação e Comunicação (SeTIC) da Universidade Federal de Santa Catarina (UFSC). É importante ressaltar que a ferramenta ainda se encontra em fase de testes e aprimoramento, com o objetivo de garantir a precisão dos resultados e a usabilidade do sistema.

Os resultados da versão inicial da interface web serão apresentados na Seção 4.3.

3.5 Validação do Modelo e da Interface Web em Audiências de Conciliação

Após a finalização do modelo de classificação e da interface web, pretende-se validar a sua utilidade em audiências de conciliação de processos em andamento no JEC/UFSC. Nessas sessões, o conciliador utilizará a interface, preenchendo as informações relevantes do caso em análise (que correspondem às variáveis extraídas) para obter a sua respectiva predição. A faixa preditiva de indenização por dano moral será então apresentada e explicada às partes interessadas e seus advogados, com o objetivo de apoiar a conciliação, incluindo as etapas de propostas e contrapropostas.

Para avaliar a eficácia do modelo de classificação e da interface web, serão realizadas entrevistas e aplicados questionários a todos os participantes da audiência de conciliação, incluindo conciliadores, partes e advogados.

4 Resultados Iniciais

4.1 Resultados Iniciais do Uso do GPT para Extração de Variáveis e Estruturação das Sentenças

O Quadro 3 apresenta a acurácia total obtida pelas diferentes versões do *prompt*, conforme detalhado na Seção 3.3.

Quadro 3 - Acurácia por *prompt*

Prompt (Iteração)	Descrição	Acurácia Total
<i>Prompt</i> 0 (Conjunto A)	Iteração anterior à principal	89,13%
<i>Prompt</i> 0 (Conjunto B)	Iteração anterior à principal	88,60%
<i>Prompt</i> 1 ((Conjunto A) 1)	Prompt Refinado, Principal (versão no Apêndice)	92,51%
<i>Prompt</i> 1 ((Conjunto A) 2)	Prompt Refinado, Principal	92,27%
<i>Prompt</i> 1 (Conjunto B)	Prompt Refinado, Principal	89,56%
<i>Prompt</i> 2 (Conjunto A)	Refinamento (em relação ao Prompt 1) nas Variáveis: Atraso, Intervalo de Atraso, Cancelamento	89,62%
<i>Prompt</i> 2.1 (Conjunto A)	Refinamento nas Variáveis: Atraso e Intervalo de Atraso	91,09%
<i>Prompt</i> 3 (Conjunto A)	União das variáveis Atraso e Cancelamento (usando -1 em Intervalo de Atraso para indicar cancelamento)	93,26%
<i>Prompt</i> 3 (Conjunto B)	União das variáveis Atraso e Cancelamento (usando -1 em Intervalo	89,07%

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

	de Atraso para indicar cancelamento)	
<i>Prompt 4</i> (Conjunto B)	União das variáveis Atraso e Intervalo de Atraso (usando 0 para indicar que não houve atraso)	90,14%
<i>Prompt 5</i> ((Conjunto A) 1)	União das variáveis Cancelamento, Atraso e Intervalo de Atraso (usando -1 para indicar cancelamento e 0 para viagem sem atraso)	93,41%
Atraso 5 ((Conjunto A) 2)	União das variáveis Cancelamento, Atraso e Intervalo de Atraso (usando -1 para indicar cancelamento e 0 para viagem sem atraso)	93,36%
Atraso 5 (Conjunto B)	União das variáveis Cancelamento, Atraso e Intervalo de Atraso (usando -1 para indicar cancelamento e 0 para viagem sem atraso)	89,92%
<i>Prompt 6</i> (Conjunto A)	Refinamento (em relação ao <i>Prompt 1</i>) nas Variáveis: Extravio Definitivo, Extravio Temporário e Intervalo de Extravio	92,87%
<i>Prompt 7</i> ((Conjunto A) 1)	União das variáveis Extravio Temporário e Intervalo de Extravio	90,60%
Extravio 2 ((Conjunto A) 2)	União das variáveis Extravio Temporário e Intervalo de Extravio	90,00%
Extravio 2 (Conjunto B)	União das variáveis Extravio Temporário e Intervalo de Extravio	88,88%

Fonte: Elaborado pelos autores.

Os resultados obtidos até o momento indicam que o uso do GPT-4.5 é eficaz na identificação e extração de variáveis em sentenças judiciais. O modelo tem demonstrado um desempenho promissor, sugerindo que, em breve, será possível automatizar com confiabilidade a tarefa de estruturação de dados textuais, desenvolvendo-se *prompts* também para outros documentos jurídicos e pelas processuais, relativos a diferentes subáreas do Direito.

Além disso, ao automatizar a identificação e extração variáveis de relevância em sentenças, reduz-se o tempo necessário para a preparação dos dados e aumenta-se a precisão das previsões sobre os resultados de processos judiciais. Este avanço pode transformar significativamente a aplicação de modelos de IA no ambiente jurídico.

4.2 Resultados Iniciais do Modelo de Classificação de Faixas de Indenização por Danos Morais

O Quadro 4 contém a acurácia média e por conjunto obtida pelo modelo de classificação desenvolvido a partir das técnicas descritas na Seção 3.4, e utilizando como entrada os dados estruturados pelo especialista da área jurídica.

Quadro 4 - Acurácia de cada subconjunto de dados

Conjunto (k)	Acurácia
1	43.46%
2	49.58%
3	44.92%
4	61.44%
5	53.39%
Média (Cross-Validation)	50.56%

Fonte: Elaborado pelos autores.

Os resultados obtidos até o momento indicam a necessidade de aprimoramentos, incluindo a experimentação com outras técnicas de classificação e ajuste de parâmetros, como *Support Vector Machines* (SVM), *K-Nearest Neighbors* (kNN) e Redes Neurais. Também serão aplicadas

métricas adicionais de avaliação, como Recall, Precisão e F1-Score, para uma análise mais abrangente e detalhada do desempenho do modelo.

Além disso, para possibilitar a explicabilidade do modelo — um dos objetivos do projeto —, pretende-se utilizar técnicas como o SHAP (*SHapley Additive exPlanations*), para avaliar como as variáveis identificadas pelos especialistas da área jurídica influenciam a predição do modelo de classificação.

4.3 Resultados Iniciais da Interface Web e Aplicação

A interface web já apresenta resultados iniciais positivos (disponível em <https://concilia.ufsc.br/>) oferecendo uma estrutura organizada que facilita o acesso ao conteúdo e às atualizações do projeto. Com o intuito de tornar a experiência do usuário intuitiva e informativa, a interface inicial permite que o público acompanhe os objetivos, os avanços e os detalhes do trabalho realizado.

A aba “Publicações” serve como um acervo acessível, reunindo documentos e artigos produzidos pela equipe de pesquisa. Dentro dessa aba, a subseção “Blog” traz postagens recentes, com atualizações e reflexões sobre o andamento do projeto, permitindo ao público acompanhar as atividades e as descobertas da equipe. A aba “Sobre o Projeto” oferece uma visão geral dos objetivos e desafios do Concil-IA no contexto da conciliação judicial; nela, a subseção “Pesquisadores” apresenta os membros do projeto e detalha as contribuições de cada um.

Para orientar o público no uso da plataforma, a aba “Guia do Usuário” oferece instruções detalhadas para navegação e funcionamento das ferramentas, garantindo uma utilização plena das funcionalidades. Por fim, a aba “Contato” estabelece um canal direto de comunicação com a equipe, incentivando o envio de dúvidas, sugestões e feedbacks, fortalecendo o engajamento e promovendo uma interação contínua com o público.

Figura 1 - Interface inicial do Projeto Concil-IA



SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

Fonte: Concil-IA (2024).

Já a página inicial do site do Projeto Concil-IA apresenta uma estética visual atraente, com imagens vibrantes do campus da UFSC, além de belas paisagens e vegetação da região. Essas imagens não apenas embelezam a interface, mas também refletem a conexão do projeto com o ambiente acadêmico e natural, criando um espaço acolhedor e inspirador para os visitantes.

Além disso, a construção da aplicação Concil-IA exigiu a implementação de uma interface específica (disponível em <https://app.concilia.ufsc.br/>) e de uma API para comunicação com o modelo de IA. Esta aplicação permite a interação entre os usuários e o modelo de classificação preditivo, com a apresentação de faixas de indenização aplicáveis em tempo real, com base nas sentenças utilizadas para treinamento e parâmetros previamente configurados. O desenvolvimento desta interface segue um processo iterativo, com testes e feedbacks contínuos da equipe e de potenciais usuários, garantindo que o sistema atenda às necessidades práticas de conciliação, alinhado aos objetivos do projeto.

Figura 2 - Interface da API do Projeto Concil-IA

The screenshot shows the Concil-IA interface. At the top, there is a header with the logo and the text "Concil-IA". Below the header, a message states: "Esta é uma ferramenta em fase de testes e desenvolvimento." The main content area contains a form with several sections, each with radio button options:

- Direito de arrependimento:** Sim Não
- Descumprimento de oferta:** Sim Não
- Extravio definitivo:** Sim Não
- Faixa intervalo extravio temporário:**
 - Não houve extravio
 - 1h - 24h
 - 25h - 72h
 - 73h - 168h
 - Acima de 169h
- Violação, furto ou avaria:** Sim Não
- Cancelamento ou alteração de destino:** Sim Não
- Culpa exclusiva do consumidor:** Sim Não
- Faixa de atraso:**
 - Não houve atraso
 - 1h - 3h59m
 - 4h - 7h59m
 - 8h - 11h59m
 - 12h - 15h59m
 - 16h - 23h59m
 - 24h - 27h59m
 - Acima de 28hr
- Condições climáticas do aeroporto:** Sim Não
- No show:** Sim Não
- Overbooking:** Sim Não
- Assistência companhia aérea:** Sim Não
- Hipervulnerável:** Sim Não

At the bottom right of the form, there is a blue button labeled "Consultar".

Fonte: Concil-IA (2024).

Esta interface oferece ao usuário um formulário com opções relevantes ao seu caso. Cada uma dessas opções define o valor de uma variável que será utilizada como entrada para o modelo de classificação. As próximas melhorias serão focadas em aprimorar a usabilidade, tornando as perguntas mais claras e oferecendo opções de ajuda ao usuário.

5 Considerações Finais e Trabalhos Futuros

O avanço tecnológico exige inovações no direito, especialmente com o uso da IA para modernizar e aprimorar práticas jurídicas. Em nível mundial e nacional, busca-se integrar IA ao setor jurídico, promovendo eficiência e acessibilidade. Nesse contexto, surge o projeto Concil-IA, desenvolvido na Universidade Federal de Santa Catarina, com participação de estudantes de Direito, Ciências da Computação e Engenharia da Automação, visando a compatibilização entre automação e prática jurídica.

O Concil-IA se destaca pelo desenvolvimento de um sistema de resolução de disputas online (ODR) voltado ao Direito do Consumidor. Utilizando o modelo GPT-4.5, o projeto implementou uma metodologia de coleta e análise de sentenças judiciais, que permite a extração automatizada de variáveis relevantes com alta precisão. Também desenvolveu um modelo de classificação para prever faixas de indenização por danos morais, cujos resultados iniciais apontam a necessidade de ajustes. Além disso, foi criada uma interface web para facilitar o uso do sistema por mediadores e partes envolvidas, promovendo uma plataforma acessível que apoia decisões em tempo real, o que pode reduzir a litigiosidade e incentivar a conciliação.

O projeto foi estruturado em três frentes: extração manual de variáveis por operadores do direito, criação de *prompts* para extração automatizada e previsão de indenizações, e desenvolvimento de um site para que consumidores estimem possíveis indenizações. A partir disso, formaram-se Grupos de Trabalho (GTs) para um desenvolvimento ágil e efetivo. Com os dados iniciais, já se observa o potencial de conjugar direito e IA para beneficiar a sociedade, e a equipe pretende aprimorar o modelo para torná-lo ainda mais preciso.

O uso de GPT-4.5 demonstra o potencial da IA generativa no direito ao estruturar dados de sentenças, possibilitando maior agilidade e objetividade na análise de grandes volumes de informações jurídicas. A IA também pode reduzir vieses humanos, promovendo decisões mais justas e baseadas em dados objetivos, além de contribuir para a pesquisa jurídica e educação, permitindo identificar padrões em decisões judiciais.

Para o futuro, o projeto prevê melhorias no modelo de classificação para predição de indenizações, utilizando técnicas como *Support Vector Machines* (SVM), *k-Nearest Neighbors* (kNN) e redes neurais. A explicabilidade do modelo será priorizada, aplicando o método SHAP (SHapley Additive exPlanations) para avaliar o impacto das variáveis jurídicas nas predições, e a interface web será validada em audiências para coletar as considerações de conciliadores e usuários. Além disso, o Concil-IA pretende expandir sua atuação para outras áreas do Direito, consolidando-se como uma solução abrangente para facilitar a conciliação e reduzir a litigiosidade no sistema judiciário brasileiro.

Portanto, o Concil-IA tem o potencial de transformar a resolução de conflitos no Brasil, tornando o sistema de justiça mais eficiente e acessível. Além disso, automatizando a análise de variáveis em sentenças e oferecendo predições de indenizações, o projeto visa reduzir a sobrecarga dos tribunais e oferecer uma ferramenta de negociação transparente. A longo prazo, essa inovação poderá fortalecer a cultura de autocomposição e mediação,

SABO, Isabela Cristina; MAURMANN, Andressa Silveira Viana; SANTOS, Guilherme de Brito; MARCOS JUNIOR, Maykon; VIEIRA, Maite Fortes; MOHR, João Gabriel; ALCHINI, Cristian Alexandre; BOLLMANN, Luísa; PEREIRA, Lucas de Castro Rodrigues; ROVER, Aires Jose. Avanços iniciais do projeto Concil-IA: desafios e potenciais impactos. **Revista Democracia Digital e Governo Eletrônico**, Florianópolis, v. 1, n. 24, p. 2-20, 2025. Seção B. Edição Especial do 33º Encontro Ibero Americano de Governo Eletrônico e Inclusão Digital.

promovendo uma sociedade em que a tecnologia facilita o acesso à justiça e incentiva uma resolução de conflitos rápida e justa.

6 Referências

ALETRAS, Nikolaos *et al.* Predicting judicial decisions of the European Court of Human Rights: a natural language processing perspective. **PeerJ Computer Science**, PeerJ Inc., v. 2, e93, 2016.

CONCIL-IA. IA Conciliadora: Transforme conflitos em soluções com a nossa ferramenta de conciliação judicial. 2024. Página inicial. Disponível em: <https://concilia.ufsc.br/>. Acesso em: 30 out. 2024.

CONSELHO NACIONAL DE JUSTIÇA (CNJ). **Justiça em números 2024**. Brasília: CNJ, 2024.

CONSELHO NACIONAL DE JUSTIÇA (CNJ). Resolução nº 125 de 29 de novembro de 2010. Dispõe sobre a Política Judiciária Nacional de tratamento adequado dos conflitos de interesses no âmbito do Poder Judiciário e dá outras providências. **Diário da Justiça eletrônico**, Brasília, DF, 29 nov. 2010. Disponível em: <https://atos.cnj.jus.br/atos/detalhar/156>. Acesso em: 18 out. 2024.

CONSELHO NACIONAL DE JUSTIÇA (CNJ). Resolução nº 332 de 21 de agosto de 2020. Dispõe sobre a ética, a transparência e a governança na produção e no uso de Inteligência Artificial no Poder Judiciário e dá outras providências. **Diário da Justiça eletrônico**, Brasília, DF, 21 ago. 2020. Disponível em: <https://atos.cnj.jus.br/atos/detalhar/3429>. Acesso em: 18 out. 2024.

DAL PONT, Thiago Raulino. **Representation, classification and regression techniques applied to legal judgments about immaterial damage due to failures in air transport services**. 2021. 120p: Dissertação (Mestrado em Engenharia de Automação e Sistemas) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2021.

DAL PONT, Thiago Raulino et al. Classification and Association Rules in Brazilian Supreme Court Judgments on Pre-trial Detention. *In: SPRINGER. INTERNATIONAL Conference on Electronic Government and the Information Systems Perspective*. [S.l.: s.n.], 2021. P. 131–142.

DAL PONT, Thiago Raulino et al. Impact of Text Specificity and Size on Word Embeddings Performance: An Empirical Evaluation in Brazilian Legal Domain. In: CERRI, Ricardo; PRATI, Ronaldo C (Ed.). **Intelligent Systems**. Cham: Springer International Publishing, 2020. P. 521–535.

DAL PONT, Thiago Raulino et al. Regression applied to legal judgments to predict compensation for immaterial damage. **PeerJ Computer Science**, v. 9, p. e1225, 2023.

FERNANDES, William Paulo Ducca et al. Appellate court modifications extraction for portuguese. **Artificial Intelligence and Law**, Springer, v. 28, n. 3, p. 327–360, 2020.

GLASER, Ingo; SCEPANKOVA, Elena; MATTHES, Florian. Classifying semantic types of legal sentences: Portability of machine learning models. In: PALMIRANI, Monica (Ed.). **Legal Knowledge and Information Systems (JURIX 2018)**. Amsterdam: IOS Press, 2018. p. 61–70.

HENDRYCKS, Dan et al. CUAD: An expert-annotated nlp dataset for legal contract review. **arXiv preprint arXiv:2103.06268**, 2021.

JÚNIOR, Antônio Pires Castro; WAINER, Gabriel A; CALIXTO, Wesley P. Application of Artificial Intelligence in the automatic identification and classification repetitive demand resolution incident in the Brazilian Court of Justice. **Revista da Faculdade de Direito da UFG**, v. 45, n. 2, 2021.

- 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**, Public Library of Science San Francisco, Califórnia, v. 12, n. 4, e0174698, 2017.
- KATZ, Daniel Martin; BOMMARITO, Michael J.; BLACKMAN, Josh. Predicting the behavior of the supreme court of the united states: A general approach. **arXiv preprint arXiv:1407.6333**, 2014.
- LIPPI, Marco et al. CLAUDETTE: an automated detector of potentially unfair clauses in online terms of service. **Artificial Intelligence and Law**, Springer, v. 27, n. 2, p. 117–139, 2019.
- LUK, M. Generative AI: overview, economic impact, and applications in asset management. *Economic Impact, and Applications in Asset Management*, 18 set. 2023.
- PARREIRAS, Marcus *et al.* Inteligência artificial aplicada para o aumento da produtividade no atendimento de intimações. *In: SBC. ANAIS do X Workshop de Computação Aplicada em Governo Eletrônico*. [S.l.: s.n.], 2022. P. 180–191.
- PEIXOTO, Fabiano Hartmann; SILVA, Roberta Zumblick Martins. **Inteligência Artificial e Direito**. Curitiba: Alteridade Editora, 2019.
- SABO, Isabela Cristina. **A Machine Learning-based model for judgement results prediction and support in Brazilian Special Court's conciliation hearings**. 2022. 150p: Tese (Doutorado em Direito) - Centro de Ciências Jurídicas, Universidade Federal de Santa Catarina, Florianópolis, 2022.
- SABO, Isabela Cristina; DAL PONT, Thiago Raulino; ROVER, Aires José *et al.* Classificação de sentenças de Juizado Especial Cível utilizando aprendizado de máquina. **Revista Democracia Digital e Governo Eletrônico**, v. 1, n. 18, p. 94–106, 2019.
- SABO, Isabela Cristina; DAL PONT, Thiago Raulino; WILTON, Pablo Ernesto Vigneaux *et al.* Clustering of Brazilian legal judgments about failures in air transport service: an evaluation of different approaches. **Artificial Intelligence and Law**, Springer Netherlands, n. 0123456789, p. 1–37, abr. 2021.
- SHARMA, Sugam K; SHANDILYA, Ritu; SHARMA, Swadesh. Predicting Indian Supreme Court Judgments, Decisions, or Appeals: eLegalls Court Decision Predictor (eLegPredict). **Statute Law Review**, 2022.
- SILVA, Nilton Correia da et al. Document type classification for Brazil's Supreme Court using a convolutional neural network. *In: INTERNATIONAL CONFERENCE ON FORENSIC COMPUTER SCIENCE AND CYBER LAW (ICOFCS)*, 10, 2018, SÃO PAULO, p. 29–30. Disponível em: https://cic.unb.br/~teodecampos/ViP/correiaDaSilva_etal_icofcs2018.pdf. Acesso em: 15 out. 2024.
- TAN, Pang-ning; STEINBACH, Michael; KUMAR, Vipin. **Introdução ao data mining: mineração de dados**. Rio de Janeiro: Ciência Moderna Ltda., 2009.
- VIRTUCIO, Michael Benedict L. *et al.* Predicting decisions of the Philippine Supreme Court using natural language processing and machine learning. *In: ANNUAL COMPUTER SOFTWARE AND APPLICATIONS CONFERENCE (COMPSAC)*, 42, 2018, TOKYO. **Proceedings...** v. 2. New York: IEEE, 2018. p. 130–135. Disponível em: <https://ieeexplore.ieee.org/document/8377844>. Acesso em: 15 out. 2024.
- WONG, Tzu-tsung. Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. **Pattern Recognition**. [s.l.], p. 2839-2846. set. 2015.
- ZHANG, Yanru; HAGHANI, Ali. A gradient boosting method to improve travel time prediction. **Transportation Research Part C: Emerging Technologies**, Elsevier, v. 58, p. 308–324, 2015.

Apêndice - *Prompt main*

Atue como um extrator de variáveis.

O texto-base utilizado para a extração das variáveis estará entre colchetes.

A sua resposta será os valores encontrados para as variáveis em um bloco csv, respeitando a ordem das variáveis.

Retorne apenas o bloco csv.

O bloco csv deverá ter 2 linhas, um cabeçalho com uma sequência com o id de cada variável (nada além dos números, e todos na mesma linha), e a segunda linha deverá conter o resultado das extrações de cada variável (nada além dos valores extraídos) em uma linha.

As variáveis serão as próximas instruções, as variáveis contêm um id numérico, de 1 a 15, e um nome, separados entre si por um hífen, cada variável tem uma forma específica de extração, a forma de extração é introduzida pelo sinal de dois pontos e terminada em ponto final.

1 - direito de arrependimento: indique "S" para sim ou "N" para não se o consumidor tentou cancelar ou alterar a compra no prazo de 7 dias.

2 - descumprimento de oferta: indique "S" para sim ou "N" para não se a empresa fornecedora não cumpriu com o ofertado ao consumidor(a), seja no valor da passagem, seja no assento no avião ou situações correlatas.

3 - extravio definitivo: indique "S" para sim ou "N" para não se houver a indicação de que uma bagagem foi extraviada e nunca foi recuperada.

4 - extravio temporário: indique "S" para sim ou "N" para não se houver a indicação de que uma bagagem foi extraviada e, posteriormente, foi recuperada.

5 - intervalo de extravio: se "S" para a variável "extravio temporário", indique através de formato numérico "horas:minutos" o tempo decorrido até recuperar a bagagem, se "N" para a variável "extravio temporário", indique o símbolo hífen "-".

6 - violação: indique "S" para sim ou "N" para não se houve adulteração da bagagem ou um item dela (violação, avaria ou furto).

7 - Cancelamento sem Realocação ou Alteração de Destino: Indique "N" (não) caso o consumidor tenha sido efetivamente levado ao destino final contratado, mesmo que por rotas alternativas ou meios de transporte adicionais. Isso significa que mesmo após o cancelamento, o consumidor chegou ao destino consistentemente com o que estava previsto de maneira a não comprometer significativamente os objetivos da viagem. Indique "S" (sim) se, mesmo após as tentativas de realocação ou alteração dos planos, o consumidor não foi levado ao destino inicial.

8 - atraso de voo: se "N" para a variável "cancelamento (sem realocação)/alteração de destino", indique "S" para sim ou "N" para não se houver a indicação de que o consumidor chegou ao destino contratado com atraso (do ponto de vista do translado do passageiro).

9 - Intervalo de Atraso: Dependendo do valor da variável 8 "Atraso de Voo": - Se S (Sim), extraia e indique o tempo de atraso do voo. O tempo deve ser expresso em formato numérico "horas:minutos" (HH:MM).

Diretrizes para Extração: Entradas como "2 horas e 30 minutos" devem ser formatadas como "02:30". Para valores mencionados apenas em minutos (exemplo: "90 minutos"), converta e formate como "01:30". Se o texto expressar o atraso de maneira vaga ou incompleta e não permitir uma conversão direta para o formato "horas:minutos", registre como "null". Certifique-se de interpretar corretamente diferentes maneiras de expressar atraso, incluindo contextos variados e estruturas de sentença. - Se N (Não) referente ao valor da variável 8 "Atraso de Voo", utilize o símbolo hífen "-" para indicar que não houve atraso de voo. Validação: Após a extração, confirme se o formato está correto como "HH:MM", Caso contrário, revise ou ajuste a entrada. Verifique se todas as descrições atendem aos padrões esperados e faça as correções necessárias antes de finalizar a entrada.

10 - culpa exclusiva do consumidor: indique "S" para sim ou "N" para não quanto a se todos os problemas relatados decorrem de ações ou inações do consumidor.

11 - inoperabilidade do aeroporto: indique "S" para sim ou "N" para não quanto a se houve um evento imprevisível e inevitável que comprovadamente impediu o aeroporto de operar.

12 - no show: indique "S" para sim ou "N" para não se houve o cancelamento automático do vôo de retorno em razão exclusiva do não comparecimento à viagem de ida, sem concordância do consumidor.

13 - overbooking: indique "S" para sim ou "N" para não se houve a venda de assentos em quantidade superior a comportada pela aeronave fazendo com que o consumidor não embarcasse.

14 - Assistência da Companhia Aérea: Indique "S" (Sim) se a companhia aérea forneceu auxílio concreto ao consumidor para enfrentar o problema de atraso de voo ou cancelamento sem realocação/alteração de destino, e essa assistência inclui hospedagem, alimentação, ou transporte alternativo. A indique "N" (Não) se apesar do atraso de voo ou cancelamento, a companhia aérea falhou em fornecer qualquer tipo de assistência mencionada ou suas ações foram insuficientes para resolver as necessidades básicas do consumidor durante o transtorno. Indique também "N" (Não) se o auxílio foi realizado posterior à propositura da ação judicial. Use o símbolo hífen "-" quando não houver atraso de voo nem cancelamento sem realocação ou alteração de destino.

15 - hipervulnerabilidade: indique "S" para sim ou "N" para não se o consumidor era idoso, gestante, possuía deficiência, fazia uso de medicamentos ou estava acompanhado de criança (entende-se criança a(o) infante que tem até 12 anos incompletos).