

Classificação de processos judiciais segundo Objetivos de Desenvolvimento Sustentável da Agenda ONU 2030¹

Classification of lawsuits according to the Sustainable Development Goals of the UN 2030 Agenda

Clasificación de demandas según los Objetivos de Desarrollo Sostenible de la Agenda 2030 de la ONU

Luiz Fux², Pedro Felipe de Oliveira Santos³, Aline Carlos Dourado Braga⁴, Pamella Sada Dias Edokawa⁵ e Júlio Luz Sisson de Castro⁶

<https://doi.org/10.36428/revistadacgu.v14i26.548>

Resumo: O Supremo Tribunal Federal (STF), a partir de novembro de 2020, classifica alguns de seus processos em Objetivos de Desenvolvimento Sustentável (ODS) da Agenda 2030 da ONU. O objetivo desta classificação é integrar efetivamente a Agenda no dia a dia do tribunal. Neste contexto, uma ferramenta para apoio tecnológico à classificação tem imenso potencial para automatizar as tarefas manuais e repetitivas de ler as peças e registrar as etiquetas. A iniciativa RAFA 2030 surgiu com o objetivo de ajudar os servidores a melhor classificar os processos. Este artigo tem os objetivos de apresentar a integração entre a Agenda 2030 e a rotina da corte e a própria ferramenta tecnológica RAFA 2030, em seus aspectos técnicos de desenvolvimento. Atualmente, as principais entregas deste projeto consistem em ferramentas gráficas para processamento de linguagem natural (*co-occurrence graphs*, nuvem de palavras), algoritmos de aprendizagem de máquina, redes neurais, busca por contexto e contagem de palavras-chave, além de outras ferramentas disponíveis em R (*Shiny*) e Python (*Keras*, *Tensorflow* e *Pytorch*). Os resultados iniciais sugerem imenso potencial para aplicações de NLP e aprendizagem de máquina na classificação de documentos jurídicos em temas da Agenda 2030.

Palavras-chave: Agenda ONU 2030. Processamento de Linguagem Natural. Aprendizagem de Máquina. Redes Neurais.

Abstract: Since 2020, the Brazilian Federal Supreme Court has classified its cases according to the sustainable development goals (SDGs) of the the United Nations 2030 Agenda. In this context, a tool for technological support to classification has immense potential to automate the manual and repetitive tasks of reading the text and registering the labels. The RAFA 2030 initiative came up with the goal of helping to classify cases. This article aims to present an integration between Agenda 2030, the work routine in STF and technical aspects of development

1. Artigo submetido em 18/07/2022 e aceito em 01/12/2022.

2. Ministro do Supremo Tribunal Federal, jurista e professor universitário.

3. Desembargador Federal do Tribunal Regional Federal da 6ª Região

4. Analista Judiciário(a) do Supremo Tribunal Federal.

5. Analista Judiciário(a) do Supremo Tribunal Federal.

6. Analista Judiciário(a) do Supremo Tribunal Federal.

about RAFA 2030. Currently, the main results of this project consist of graphical tools for NLP (co-occurrence graphs, tool cloud), machine learning keys, neural networks, context search and keyword counting, in addition to other tools available in R. (Shiny) and Python (Keras, Tensorflow and Pytorch). Initial results indicate great potential for applications of NLP documents and machine learning of legal documents in Agenda 2030 themes.

Keywords: UN 2030 Agenda. Natural Language Processing. Machine Learning. Neural Network.

Resumen: El Supremo Tribunal Federal (STF), a partir de noviembre de 2020, clasifica algunos de sus procesos en los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de la ONU. El objetivo de esta clasificación es integrar la Agenda en el día a día del tribunal. En este contexto, una herramienta de apoyo tecnológico a la clasificación tiene un potencial inmenso para automatizar las tareas manuales y repetitivas de lectura de piezas y registro de etiquetas. La iniciativa RAFA 2030 surgió con el objetivo de ayudar a los funcionarios judiciales a clasificar mejor los procesos. Este artículo tiene como objetivo presentar la integración entre la Agenda 2030 y la rutina del STF y la propia herramienta tecnológica RAFA 2030, en sus aspectos técnicos de desarrollo. Actualmente, los principales productos intermedios de este proyecto consisten en herramientas gráficas para PNL (grafos de coocurrencia, nube de palabras), algoritmos de aprendizaje automático, redes neuronales, búsqueda de contexto y conteo de palabras clave, además de otras herramientas disponibles en R (Shiny) y Python (Keras, Tensorflow y Pytorch). Los resultados iniciales sugieren un inmenso potencial para las aplicaciones de PNL y aprendizaje automático en la clasificación de documentos legales en temas de la Agenda 2030.

Palabras clave: Agenda 2030 de la ONU. Procesamiento del Lenguaje Natural. Aprendizaje Automático.

1. INTRODUÇÃO

O Supremo Tribunal Federal (STF), Corte Constitucional e instância máxima do Poder Judiciário brasileiro produz uma quantidade expressiva de dados organizados em forma de texto, provenientes das petições recursais e das ações originárias que recebe, além das próprias decisões judiciais que profere. As ações que tramitam no STF são classificadas, a fim de permitir a indicação de assuntos e de outras etiquetas específicas de prioridade, como COVID-19 e parte maior de 65 anos, mas não havia, até setembro de 2020, qualquer catalogação relacionada com a Agenda 2030 da Organização das Nações Unidas (ONU).

No evento (*webinar*⁷) o Ministro Luiz Fux anunciou o início do trabalho de integração entre a Agenda 2030 e o STF, com o estabelecimento de diversas ações, das quais se destaca a classificação manual de ações de controle concentrado e de casos com reconhecida repercussão geral pelos objetivos de desenvolvimento sustentável (ODS) da Agenda 2030 da ONU.

A finalidade deste artigo é apresentar o projeto de integração entre a Agenda 2030 da ONU e o STF e a ferramenta RAFA 2030, desenvolvida para apoiar, via

aprendizagem de máquina e análise de dados, a classificação de ações por ODS da Agenda 2030. A questão que se quer responder é: Ferramentas tecnológicas podem ajudar na classificação de processos de acordo com ODS da Agenda 2030? Assume-se aqui que a aplicação de ferramentas tecnológicas no dia a dia dos tribunais se baseia em dois pontos centrais: o primeiro relacionado à melhoria dos fluxos de trabalho das cortes, que envolve, entre outras ações, a automatização de tarefas manuais e repetitivas realizadas por seus servidores; e o segundo referente à combinação das inteligências humana e artificial para a melhoria da prestação jurisdicional.

A aplicação de aprendizagem de máquina e ferramentas centradas em inteligência artificial nos tribunais recebeu impulsos importantes recentemente, conforme FGV (2021), muito embora ainda existam discussões éticas sobre soluções com este perfil. Ainda que o tempo decorrido entre as primeiras aplicações – como a ferramenta Victor (STF e UnB) iniciada em 2017 – e os dias atuais seja relativamente curto, é possível perceber que vários tribunais desenvolveram projetos de inteligência artificial, conforme apresentado em FGV (2021) e CNJ (2022).

7. *Webinar* disponível para acesso no portal eletrônico <https://portal.stf.jus.br/hotsites/webinar-cortes/>. Acesso em: 01 mai. 2022.

O panorama atual pode ser conferido a partir de pesquisa realizada pelo Conselho Nacional de Justiça (CNJ), que lançou, em junho de 2022, um painel⁸ com informações sobre os projetos de inteligência artificial no Poder Judiciário. Mesmo sem estudar profundamente cada uma das iniciativas, é possível afirmar que várias tarefas envolvem processamento de linguagem natural (NLP), como classificação e agrupamento de textos.

Sobre a iniciativa objeto deste artigo, é importante registrar que atualmente a ferramenta RAFA 2030 se encontra em fase de testes, etapa realizada em conjunto por várias secretarias do STF, e os resultados iniciais mostram imenso potencial para utilização em fluxos diários de trabalho. Conforme será apresentado a seguir, as principais entregas da iniciativa envolvem ferramentas gráficas para processamento de textos e apoio à tomada de decisão, algoritmos de redes neurais para classificação automática de peças em ODS da Agenda 2030 da ONU, busca de palavras e leis por contexto e contagem de palavras de interesse para cada ODS, definidas a priori por especialistas do tribunal.

2. ATIVIDADE DE CLASSIFICAÇÃO DE PROCESSOS POR ODS

Esta seção se dedica à atividade de classificar processos a partir de objetivos de desenvolvimento sustentável, que é uma tarefa bastante complexa e desafiadora. Desde 2021, tal tarefa é realizada por servidores destacados de quatro unidades do tribunal⁹ e envolve: a) o estudo da Agenda 2030 em seus objetivos e metas; b) a avaliação da correlação entre o conteúdo da Agenda 2030 e as questões submetidas a julgamento no tribunal e as teses firmadas pela Corte; e c) o registro do resultado dessa atividade em sistemas informatizados do tribunal. Cumpre informar que tal tarefa é realizada em diversos momentos do fluxo processual do STF, a saber: antes da distribuição de ações de controle concentrado, quando do ingresso do processo na pauta dirigida do Plenário, com a inclusão de temas pelo reconhecimento da repercussão geral no Plenário Virtual, ao haver divulgação da questão no Informativo STF e ao ser publicado acórdão na página de pesquisa de jurisprudência do tribunal¹⁰.

A entrega inicial, datada de outubro de 2020, já apresentava a quantidade de 348 etiquetas de ODS em 177 processos avaliados, como mostra a Figura 1.

FIGURA 1 - PAINEL STF E AGENDA ONU 2030 – OUTUBRO/2020



Fonte: Hotsite STF (2022).

8. Painel: Projetos com Inteligência Artificial no Poder Judiciário. 2022. Disponível em: <https://paineisanalytics.cnj.jus.br/single/?appid=29d-710f7-8d8f-47be-8af8-a9152545b771&sheet=b8267e5a-1f1f-41a7-90ff-d7a2f4ed34ea&lang=pt-BR&opt=ctxmenu,currsel/>. Acesso em: 11 mai. 2022.

9. Integraram a força tarefa para classificação de processos, em outubro de 2020, no STF: a Secretaria de Gestão de Precedentes (SPR), a Secretaria de Altos Estudos, Pesquisas e Gestão da Informação (SAE) e a Assessoria do Plenário (APL); a partir de 2021, também passou a realizar essa atividade a Secretaria Judiciária (SEJ).

10. Os dados decorrentes dessa identificação podem ser visualizados pelos usuários em diversos pontos do portal do Supremo, como, por exemplo, ao consultar processos no acompanhamento processual informatizado ou ao visitar a página de pesquisa de jurisprudência, ao ler informativo STF, ao acompanhar o calendário da pauta do plenário, ao estudar o boletim repercussão geral em pauta e até mesmo ao examinar o novíssimo programa de transparência do Tribunal, denominado Corte Aberta.

Importa dizer que o escopo do projeto de classificação por ODS foi delimitado a partir de recortes estratégicos, não abrangendo todas as ações em tramitação na Corte. Envolve a avaliação de ações de controle concentrado (Ação Direta de Inconstitucionalidade-ADI, Ação Declaratória de Constitucionalidade-ADC, Ação Direta de Inconstitucionalidade por Omissão-ADO e Ação de Descumprimento de Preceito Fundamental-ADPF), além dos casos em que o Tribunal reconhece a repercussão geral da questão constitucional objeto do recurso extraordinário, nos termos do art. 1.035 do Código de Processo Civil¹¹. Verificada a aderência de tal peça com um ou mais ODS da Agenda 2030 há o

registro das etiquetas. Dessa análise, pode-se, ainda, concluir que o processo não é correlacionado a ODS algum¹².

Essa nova atividade classificatória bem como a própria institucionalização da Agenda no STF foram objeto de normativo próprio: a Resolução STF n. 710, de 20 de novembro de 2020¹³. Em junho de 2022, pouco menos de dois anos do início desse trabalho, o STF já conta com mais de 3.300 etiquetas de ODS em processos monitorados (informações disponíveis em painel do hotsite¹⁴ da Agenda 2030 no STF, acessível no portal do Tribunal), cuja imagem segue abaixo:

FIGURA 2 - PAINEL STF E AGENDA ONU 2030 – JUNHO/2022

Processos Monitorados: 2108			Ocorrências de ODS: 3336		
Indicação de processos com aderência à Agenda 2030 no STF					
ODS1	ODS2	ODS3	ODS4	ODS5	ODS6
Erradicação da Pobreza	Fome Zero e Agricultura Sustent.	Saúde e Bem-Estar	Educação de Qualidade	Igualdade de Gênero	Água Potável e Saneamento
62	42	324	122	36	39
ODS7	ODS8	ODS9	ODS10	ODS11	ODS12
Energia Acessível e Limpa	Trabalho Decente e Cresc. Econ.	Indústria, Inovação e Infra	Redução das Desigualdades	Cidades e Comunidades Sust.	Consumo e Produção Respons.
53	441	104	325	92	66
ODS13	ODS14	ODS15	ODS16	ODS17	
Ação Contra Mud. Global Clima	Vida na Água	Vida Terrestre	Paz, Justiça e Instituições Eficazes	Parcerias e Meios de Implem.	
13	14	84	1.300	219	

Fonte: STF (2022).

11. Art. 1.035. O Supremo Tribunal Federal, em decisão irrecorrível, não conhecerá do recurso extraordinário quando a questão constitucional nele versada não tiver repercussão geral, nos termos deste artigo.

[...] 5º Reconhecida a repercussão geral, o relator no Supremo Tribunal Federal determinará a suspensão do processamento de todos os processos pendentes, individuais ou coletivos, que versem sobre a questão e tramitem no território nacional. (CPC, acessível em: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/113105.htm, acesso em 14 de julho de 2022).

12. No caso da classificação efetuada pela Coordenadoria de Jurisprudência, foram desenvolvidos critérios de pesquisa para cada uma das 169 metas, sendo utilizada a ferramenta da página de pesquisa de jurisprudência para auxílio na correlação dos acórdãos publicados pelos 17 ODS da Agenda 2030. A equipe já realizou a análise e classificação por ODS dos acórdãos publicados desde 2016, nos casos de ações de controle concentrado e nos casos em que reconhecida a repercussão geral.

13. A Resolução STF n. 710/2020, destacou grupo de trabalho coordenado pelo Secretário-Geral do STF para atuar em nas diversas ações ali elencadas e eleitas para serem executadas no biênio de 2020-2022 com o fito de integração da Agenda 2030 da ONU ao STF.

14. Hotsite disponível para acesso em <https://portal.stf.jus.br/hotsites/agenda-2030/>, com painel gerencial acessível conforme STF (2022).

É possível observar que alguns ODS têm maior número de etiquetas, como o ODS 16 - Paz, Justiça e Instituições Eficazes, cujo tema é fortemente relacionado com a atuação de cortes constitucionais, a exemplo do STF. Vale registrar que, com a classificação de processos estabelecida, foi aberta a possibilidade de priorização dos julgamentos de ações que impactem positivamente os objetivos e metas da Agenda 2030, tendo, já no primeiro semestre de 2021, 76% dos processos incluídos na pauta do Plenário com uma ou mais etiquetas de ODS da Agenda 2030, conforme informado pelo Ministro Luiz Fux no evento Suprema Corte e Diálogos sobre a Agenda 2030. A produção de dados sobre a classificação dos processos em ODS é importante para aferir a efetiva contribuição da Corte com a pauta da Agenda 2030 (*accountability*).

A alteração dos critérios de identificação dos processos submetidos ao STF e a consequente alteração na seleção de matérias a serem julgadas representam um avanço na internacionalização da Corte com equiparação a outros tribunais constitucionais de todo o mundo. Destaca-se, neste ponto, o caráter inédito e pioneiro da iniciativa de classificação dos processos por ODS em uma Corte Suprema.

A agregação da Agenda 2030 da ONU ao STF impactou, também, a própria jurisprudência da Corte, como são exemplos o julgamento da ADI 2.096, Rel. Min. Celso de Mello, em 13/10/2020 e o reconhecimento da repercussão geral no Tema 1.194 (ARE 1352872) apresentado pelo Ministro Luiz Fux.

2.1. Desenvolvimento inicial da ferramenta RAFA 2030

A decisão de desenvolver uma ferramenta tecnológica para apoio à atividade de classificação de processos em ODS da Agenda 2030 foi apresentada no início do projeto e da classificação manual, em setembro de 2020. A associação entre a classificação manual e a ferramenta tecnológica tem o objetivo de tornar a própria classificação mais aderente ao que julga o STF, usando como referência apenas as questões jurídicas em debate ou as teses firmadas pela Corte. Optou-se, assim, por não incluir na iniciativa assuntos já vinculados aos processos ou outros metadados disponíveis em sistemas informatizados.

A ideia inicial era desenvolver um simples contador de palavras cujos significados sugerissem etiquetas de ODS. A iniciativa RAFA começou, portanto, entregando o número de ocorrências de tais palavras

em cada peça jurídica de interesse. Ao longo do tempo, no entanto, a equipe técnica de desenvolvimento da ferramenta percebeu que apenas contar a ocorrência de palavras não era a solução adequada, uma vez que não é razoável ignorar o contexto das palavras descon siderando a posição destas em relação às palavras vizinhas (LIU; KUSNER; BLUNSOM, 2020).

Para ilustrar, anota-se que um texto pode trazer muitas ocorrências da palavra “segurança” sem ter relação ao ODS 16 - Paz, Justiça e Instituições Eficazes. A expressão segurança alimentar, por exemplo, guarda relação com o ODS 2 – Fome zero e Agricultura Sustentável e não com o ODS 16 já citado. A primeira decisão técnica no sentido de aumentar as funcionalidades da iniciativa foi a de ajustar gráficos sobre a disposição das palavras no texto, como nuvens de palavras e grafos de coocorrência, e os apresentar para os analistas.

2.2. Workshop - Grupo de Trabalho Agenda 2030

A primeira versão da iniciativa foi apresentada aos servidores do tribunal no Workshop do Grupo de Trabalho da Agenda 2030 no STF, evento realizado para tratar de questões relativas à classificação de processos e aos requisitos mínimos da iniciativa RAFA 2030.

Entre os dias 29 e 30 de abril de 2021, 60 servidores do tribunal se reuniram para: a) compartilhar experiências e lições aprendidas com a atividade de classificação manual, b) estabelecer critérios comuns para classificação de processos em ODS da Agenda 2030 e c) formular os requisitos básicos para a ferramenta tecnológica de apoio à classificação.

O evento foi constituído de apresentações sobre as estratégias utilizadas para classificação pelas equipes. Contou também com a apresentação inicial da ferramenta RAFA 2030, além de trazer painéis com a participação de assessoras de dois gabinetes do tribunal, que relataram a relevância da iniciativa de classificação.

Houve, ainda, uma parte prática, em que foram promovidas oficinas para classificar experimentalmente alguns processos, cujos acórdãos e petições foram enviados previamente. Tais oficinas contaram com a apresentação do que a RAFA 2030 podia fazer naquele ponto do desenvolvimento, como a contagem de palavras-chave e recursos visuais para ajudar na indicação de ODS da Agenda 2030.

A experiência foi considerada bastante positiva por dois motivos. Primeiro porque a primeira versão ferramenta foi bem avaliada no apoio à atividade de classificação. E segundo, porque os desenvolvedores puderam verificar, na prática, como era feita a classificação, bem como quais eram as dificuldades enfrentadas pelas equipes nessa tarefa. Essa proximidade com a classificação manual tornou mais fácil a identificação de pontos relevantes para o desenho definitivo da ferramenta RAFA 2030.

Após o evento, a equipe do projeto decidiu aumentar as funcionalidades da iniciativa. Alguns servidores procuraram espontaneamente o projeto para sugerir mudanças, ao mesmo tempo que os próprios gestores do projeto estudaram os melhores caminhos para aprimorar a ferramenta.

Como já haviam processos etiquetados em número suficiente para ajustar algoritmos mais sofisticados do que a contagem de palavras-chave, a iniciativa RAFA 2030 organicamente caminhou para utilização de processamento de linguagem natural (NLP) em tarefas de classificação, área da aprendizagem de máquina que experimentou enormes avanços recentemente (HOVY, 2021). Por outro lado, ficou claro para a equipe de desenvolvimento que os servidores do tribunal também desejavam uma interface gráfica associada à ferramenta. Em razão disso, a iniciativa RAFA 2030 passou a se preocupar com a experiência do usuário e com a apresentação visual dos resultados.

Por fim, a proximidade entre os servidores participantes do evento permitiu que parcerias internas fossem criadas com objetivo de testar a ferramenta e promover curadoria nos resultados, etapa fundamental para avaliação do desenvolvimento matemático e de programação realizado. O artigo segue com uma apresentação detalhada sobre as melhorias implementadas na ferramenta, produto das avaliações compartilhadas no workshop e de eventos externos com cunho interinstitucional, tais como Sextas Inteligentes¹⁵ e IX SPES - Seminário de planejamento estratégico sustentável do poder judiciário 2022¹⁶.

2.3. Aspectos gerais da ferramenta RAFA 2030

O primeiro protótipo funcional da ferramenta RAFA 2030 (Redes Artificiais Focadas na Agenda 2030 da ONU) foi lançado em evento promovido pelo STF, no 16 de maio de 2022¹⁷. Neste encontro, especialistas em ciência de dados e em direito registraram a importância da iniciativa, bem como seu enorme potencial para ajudar em tarefas de classificação processual nos objetivos de desenvolvimento sustentável da Agenda ONU 2030.

A ferramenta foi desenhada e construída por servidores da Secretaria de Gestão Estratégica e da Secretaria de Gestão de Precedentes do tribunal, sob coordenação da Secretaria Geral da Presidência do STF, com a participação da Secretaria Judiciária (curadoria) e, ainda, com o apoio da Secretaria de Tecnologia da Informação (disponibilização das peças).

A aplicação se concentra atualmente em duas tarefas específicas: a) classificação automática de grandes conjuntos (lotes) de processos judiciais via aprendizagem de máquina e *deep learning*; e b) apoio visual e estatístico para classificação individual de processos judiciais. A primeira tarefa consiste em utilizar algoritmos de redes neurais para verificar se textos de acórdãos e de petições iniciais apresentam aderência aos ODS 16 (paz, justiça e instituições eficazes), 10 (redução das desigualdades), 8 (trabalho decente e crescimento econômico) e 3 (saúde e bem-estar).

O fluxo é bastante simples: a área jurídica do tribunal indica conjuntos de peças e a RAFA 2030 utiliza textos etiquetados manualmente para treinar e etiquetar novas entradas. A entrega, nesta frente da iniciativa, são as classificações que resultam dos algoritmos ajustados.

A segunda tarefa é centrada no desenvolvimento de um aplicativo para apoiar a decisão de classificar novos processos de acordo com ODS da Agenda 2030. Este aplicativo conta com diversos gráficos utilizados em processamento de linguagem natural (NLP), além de contagem de palavras-chave e busca do contexto. A entrega, neste caso, é a interface que possibilitará aos servidores classificar mais processos jurídicos em menos tempo e com maior qualidade.

15. Evento realizado em 11 de março de 2022, denominado Sextas Inteligentes, pela plataforma Zoom, com a participação de integrantes dos Núcleos de Gerenciamento de Precedentes de todo o país.

16. O resultado de outros testes, efetuados em no final de 2021, foram compartilhados em notícia veiculada no portal do STF, acessível em: <https://portal.stf.jus.br/noticias/verNoticiaDetalhe.asp?idConteudo=481995&ori=1>.

17. Está no canal do YouTube do STF o vídeo do evento de lançamento da RAFA 2030, acessível em <https://www.youtube.com/watch?v=FhlosnROqfU>, acesso em 8 de junho de 2022.

Nenhuma das tarefas, no entanto, busca substituir os especialistas. A iniciativa RAFA pressupõe integração entre as inteligências artificial e humana, e por este motivo as sugestões de ODS feitas pelas redes neurais ou pelas ferramentas gráficas do aplicativo necessariamente serão revisadas por analistas do tribunal quando a ferramenta estiver em produção.

Sobre o conjunto de palavras-chave utilizado na ferramenta, importa registrar que ele foi elaborado pela equipe técnica da área judicial (Coordenadoria de Jurisprudência - COJU) e o objetivo foi reunir palavras que indicam forte relação da peça jurídica em tela com os objetivos da Agenda 2030, usando suas metas e indicadores. Uma alta ocorrência da palavra “feminicídio”, por exemplo, pode indicar que o processo em análise tem forte relação com o ODS 5 – Igualdade de Gênero.

A metodologia utilizada para construir a iniciativa RAFA 2030 em sua atual composição será melhor explicada no capítulo a seguir, que se ocupa de relacionar aspectos técnicos de programação, base de dados e processamento de linguagem natural (NLP) com o problema de classificar processos judiciais segundo ODS da Agenda 2030.

3. METODOLOGIA

A iniciativa RAFA foi desenvolvida em linguagem R e *Python*, prioritariamente. Isso significa que, com exceção de alguns poucos passos intermediários, tudo aquilo que será apresentado nesta seção envolve apoio computacional de alguma linguagem de programação (R ou *Python*, neste caso). O corpo técnico da iniciativa escolheu usar R e *Python* pois são as linguagens mais populares para ciência de dados, mas os registros deste artigo podem ser reproduzidos em outras linguagens de programação com algum esforço de código e pesquisa de pacotes/bibliotecas. Outras opções populares são: Scala, para utilização do Ecossistema *Hadoop*, Julia, Go e C++.

Dado que *Python* e R são linguagens com grandes comunidades de usuários, não é difícil encontrar informações sobre processamento de linguagem natural na

internet. Reproduzir códigos de fontes não oficiais, no entanto, pode ser complicado e até limitar o potencial de desenvolvimento. Neste contexto, um possível caminho envolve pesquisar algoritmos e estratégias para resolver a tarefa de interesse em boas plataformas (*Towards Data Science* e *Towards AI* do *Medium*, *Kaggle* e *MachineHack*)¹⁸ e partir para análise da documentação oficial dos frameworks/pacotes utilizados, como *Tensorflow*, *Keras* e *Pytorch* em *Python* ou *Quanteda* e *Text* em R. Evidentemente, tais pesquisas não excluem a necessidade de formação. Apesar de todos os membros técnicos da Secretaria de Gestão Estratégica envolvidos na iniciativa possuírem graduação/pós-graduação em estatística, houve necessidade de complementar a formação superior com cursos sobre aprendizagem de máquina, *deep learning* e inteligência artificial.

O primeiro desafio metodológico para aplicações de aprendizagem de máquina costuma ser a obtenção dos dados. Na maioria das vezes, limpar e manipular dados em texto é bem mais complexo do que a manipulação exigida por dados em formato numérico ou categórico e nem sempre os textos estão disponíveis publicamente para uso. Na iniciativa RAFA são utilizados dados do próprio tribunal, o que certamente torna esta etapa mais fácil. Explicações mais detalhadas sobre a base de dados serão dadas na seção subsequente.

3.1. Base de dados

Os principais dados de entrada da RAFA são textos de petições iniciais e de acórdãos de processos do STF. São arquivos em formato .PDF que podem ser nato digitais ou imagens. Imagens são típicas em processos digitalizados e exigem um passo de reconhecimento ótico de caracteres (OCR). Maiores informações sobre tarefas de OCR estão disponíveis em Ooms (2022). As peças em PDF estão disponíveis no site do STF. Basta pesquisar pelo processo de interesse na homepage, como mostra a figura a seguir:

18. Disponíveis em: *Towards Data Science* (<https://towardsdatascience.com/>); *Towards AI* (<https://towardsai.net/>); *Medium* (<https://medium.com/>); *Kaggle* (<https://www.kaggle.com/>); *MachineHack* (<https://machinehack.com/>), com acesso em: 04 de mai. 2022.

FIGURA 3 – CONSULTA PROCESSUAL NO PORTAL STF



Fonte: Homepage STF¹⁹.

O exemplo em tela mostra uma pesquisa referente ao processo ADPF-779. Clicando em pesquisar, abre-se a seguinte página:

FIGURA 4 – CONSULTA PROCESSUAL ADPF-779



Fonte: Homepage STF.

19. Homepage STF disponível em: <https://portal.stf.jus.br>. Acesso em: 10 jul. 2022.

Clicando-se no botão peças, os documentos estarão dispostos à esquerda e podem ser baixados facilmente, desde que não estejam em segredo de justiça. Para verificar quais processos foram classificados em ODS da Agenda 2030 basta entrar no *hotsite* da Agenda 2030 no STF e baixar um arquivo em .xlsx com os processos e os metadados de classificação. Combinando tal arquivo com a busca de peças no *site* do STF, é possível obter as peças de onde os textos podem ser extraídos, bem como as classificações manuais em ODS da Agenda 2030.

Com os textos devidamente extraídos dos processos de interesse, é possível começar a etapa de processamento de linguagem natural, que será apresentada na próxima seção. Boas referências em NLP são os livros dos autores Martin (2009), Vajjala *et al* (2020) e Hvitfeldt e Silge (2021), este último exclusivo para uso em linguagem R.

3.2. Processamento de Linguagem Natural

As ciências sociais receberam bem a análise de texto e o processamento de linguagem natural (NLP) em seu conjunto de técnicas, como mostram as referências Nay (2021), Jockers (2014) e Kulas (1988). Em resumo, as técnicas de NLP tem foco em processar o texto para, através de treinamento supervisionado ou não, realizar tarefas de predição, além de análise visual e descritiva. A tarefa mais conhecida de processamento de linguagem, talvez, seja a análise de sentimentos, que se concentra em, dado um conjunto grande de textos classificados e dicionários produzidos por especialistas, adivinhar se um extrato de texto é positivo, negativo ou neutro (LIU, 2020). Variações desta abordagem usam dicionários mais sofisticados e objetivam identificar sentimentos como alegria ou raiva²⁰. Na prática, as atividades de predição buscam, a partir de conjuntos de treinamento devidamente etiquetados, prever se um novo texto pertence ou não à uma determinada categoria. Atividades de análise descritiva e visual se concentram em buscar relações entre as palavras e extratos dos textos, sem fazer previsões ou tentar adiantar comportamentos em textos novos.

A iniciativa RAFA conta com a parte de predição, especificamente na sugestão de classificação para lotes de processos e com a parte de análise descritiva e visual, uma vez que o aplicativo apresenta contagens de palavras e inúmeros gráficos. A etapa de classificação

é, seguramente, mais pesada em termos de processamento e exige maiores conhecimentos técnicos. As funcionalidades utilizadas unicamente no aplicativo usam o texto bruto, isto é, sem o passo adicional de limpeza e manipulação, característico de atividades de estatística e programação.

As peças em PDF são processadas de forma a extrair apenas os textos importantes para tarefa de classificação. As principais etapas de pré-processamento (limpeza) são:

- Extração de textos em PDFs com imagens (OCR) e nato digitais;
- Remoção de palavras de parada (*stopwords*);
- Remoção de caracteres especiais, tais como #, @ e &;
- Remoção de espaços em branco desnecessários;
- Formatação das palavras em minúsculo.

Este processamento é feito para tornar os textos mais densos e melhorar a performance dos algoritmos de aprendizagem de máquina. A natureza dos documentos alvo de limpeza influenciam os resultados, dado que as próprias *stopwords* podem mudar de área para área. Textos jurídicos, por exemplo, possuem palavras de parada diferentes de textos literários, dado que os autores de literatura usam recursos de estilo não necessários em textos técnicos. Desta forma, é importante frisar que cada problema de NLP exige uma limpeza de texto específica.

A etapa seguinte transforma os textos em vetores de números e é conhecida pelo nome de *embedding* (GUPTA *et al.*, 2020). Máquinas não processam textos nativamente, sendo necessário um passo de codificação, para transformar coleções de palavras em conjuntos numéricos. Existem diversas formas de *embedding*, sendo as mais simples baseadas em dicionário (conjunto de todas as palavras de um texto) e as mais sofisticadas baseadas em contexto. Na construção dos modelos para predição de ODS, foram utilizadas as seguintes tecnologias de *embedding*: *one-hot encoding*, *bag of words* (BoW), *tf-idf* e *bert*. Maiores informações sobre tais métodos podem ser encontradas em Meijer, Truong e Karimi (2021) e David e Renjith (2021).

Com os textos limpos e convertidos em vetores de números, algoritmos podem ser ajustados para prever categorias, neste caso, etiquetas de ODS. Muitas

20. Detalhes em: <https://medium.com/towards-data-science/using-sentiment-analysis-to-explore-emotions-within-text-ae48e3e93999>. Acesso em: 12 mai. 2022.

abordagens são possíveis, mas as principais envolvem aprendizagem supervisionada e algoritmos de *machine learning* (aprendizagem de máquina), tais como SVM, *Naive Bayes*, *XGBoost* e *CatBoost*, além de redes neurais profundas, características de *deep learning*. Também é possível utilizar variações de abordagens não supervisionadas, tais como similaridade e agrupamento de textos. As redes neurais foram escolhidas pois apresentaram boa performance em diversas métricas, conforme seções subsequentes mostram.

3.3. Testes – Atividade de Classificação Automática

A primeira estratégia utilizada para classificação foi *multilabel*, o que significa que cada processo avaliado podia ter todas as etiquetas (17 ODS) ou nenhuma delas. Considerando cada combinação possível como um rótulo individual, seriam aproximadamente 131.071 etiquetas possíveis para cerca de 2 mil processos analisados, ou seja, existiriam mais categorias do que dados, um problema recorrente para modelos de previsão que envolvem treinamento e aprendizagem. Uma alternativa elegante para contornar este problema é a utilização de modelos com probabilidade de pertencimento. Modelos deste tipo, após o treinamento, devolvem não uma coleção de etiquetas, mas a probabilidade de cada etiqueta ser utilizada no registro que se quer prever a classificação.

Para tal modelo, uma possibilidade é utilizar o *framework StarSpace* do Facebook, cuja implementação em R pode ser encontrada no pacote *ruimtehol*. O *StarSpace* é, fundamentalmente, uma máquina de gerar *embeddings*. No caso de textos, bons *embeddings* possuem vetores parecidos para palavras de significado próximo em linguagem natural, considerando o contexto de utilização. A implementação em R do *StarSpace* inclui algoritmos de similaridade e redes neurais, que, no caso de problemas *multilabel*, geram saídas com probabilidade de pertencimento. Apesar do *StarSpace* produzir *embeddings* robustos, classificar com um único algoritmo todos os ODS se mostrou uma tarefa muito pesada para o método, principalmente nos objetivos mais gerais, como no caso do décimo sexto, relacionado à Paz, Justiça e Instituições Eficazes.

A consequência natural da utilização do *framework StarSpace* é um estudo sobre similaridade de processos judiciais. Algumas iniciativas do judiciário utilizam similaridade para agrupar processos com diferentes propósitos, a exemplo da Berna (TJGO, 2020) e Athos (STJ, 2020).

No início, a iniciativa RAFA se ocupou de empregar similaridade com objetivo de classificação posterior. Na prática, calculava a similaridade entre um novo processo candidato a receber etiquetas de ODS e as peças jurídicas da base já etiquetada, com objetivo de avaliar a similaridade média entre a peça nova e aquelas classificadas em cada um dos ODS. O ponto de corte para decidir se o novo processo receberia ou não uma determinada etiqueta era dado pela similaridade média entre os processos classificados na própria base. A continuidade desta abordagem se tornou difícil pela heterogeneidade dos textos (petições em especial) e pela falta de textos etiquetados para a maioria dos ODS. Para contornar a situação, o problema *multilabel* foi quebrado em problemas binários.

Essa estratégia permitiu tratar cada ODS de forma individual, separando aqueles com número suficiente de processos daqueles com registros insuficientes para aprendizagem de máquina. Também permitiu ajustar um modelo para cada ODS, escolhendo os algoritmos candidatos em uma coleção maior de modelos. Como consequência de haver mais opções de modelos, surgiram também mais opções de ensemble, abordagem que define o rótulo (etiqueta) por votação simples ou ponderada (GANAIÉ, 2021).

Alguns ODS possuem poucos processos etiquetados, o que naturalmente impede que máquinas aprendam a classificá-los usando poucos exemplos. Se existem, por exemplo, 2 mil processos classificados e apenas 3 etiquetados em um determinado ODS, a máquina pode classificar nenhuma peça em tal ODS e ainda assim performar bem em termos gerais. Por este motivo, foram selecionados apenas os ODS 16, 8, 10 e 3, respectivamente, os objetivos com maiores números de entradas. Considerando cada um destes 4 ODS como um problema único de aprendizagem, a iniciativa RAFA alcançou resultados satisfatórios usando redes neurais recorrentes (SHERSTINSKY, 2020).

O quadro resumo a seguir compara as abordagens utilizadas:

QUADRO 1 – SÍNTESE DAS ABORDAGENS TESTADAS

ABORDAGEM	OBJETIVO	RESULTADOS
Classificação <i>Multilabel</i> .	Etiquetar processos em múltiplos ODS da Agenda 2030.	Baixa performance em ODS gerais, tais como o 16.
Similaridade.	Calcular a similaridade entre novas entradas e processos já etiquetados.	Baixa performance em ODS com poucas entradas, tais como o 13 e o 14.
Classificação Binária.	Etiquetar processos em um único ODS da Agenda 2030.	Performance boa nos 4 ODS avaliados – 16, 8, 10 e 3.

Fonte: Elaboração própria.

Tendo justificado a escolha das redes neurais, resultados pormenorizados podem ser apresentados, como as métricas *F-score*, *recall* e precisão. O próximo capítulo demonstra os resultados obtidos com as redes e as principais notas sobre a utilização do aplicativo para apoio à classificação.

4. RESULTADOS E DISCUSSÕES

Os resultados obtidos no processamento de grandes lotes de processos estão disponíveis num painel gerencial para uso interno. Tal painel mostra a evolução da iniciativa nos testes realizados semanalmente, dado que ajustes são feitos nos algoritmos quando os especialistas fazem curadoria dos resultados anteriores. O fluxo é o seguinte: os algoritmos são executados em sua configuração e parâmetros atuais. Os resultados são enviados para especialistas do tribunal, que devolvem notas sobre as classificações feitas pela iniciativa RAFA 2030. As análises de tais notas motivam mudanças nos algoritmos e o ciclo de melhorias se repete, alternando curadoria e reajuste de algoritmos. Este movimento motivou, por exemplo,

a mudança na precedência entre os tipos de peças utilizados. No começo, a iniciativa RAFA utilizava preferencialmente acórdãos, usando petições apenas para processos sem informação útil mais recente. Ocorre que, apesar dos acórdãos serem mais fáceis de manipular, a classificação manual é feita, hoje, basicamente em petições. Essa troca de precedência (acórdão para petições) gerou aumento significativo da acurácia para as redes neurais dos ODS 16, 8, 10 e 3. Também há de se destacar que, em alguns momentos, as divergências observadas entre a marcação dos servidores e aquelas sugeridas pela RAFA geraram boas discussões sobre o processo de classificação em si, uma vez que a máquina enxerga padrões muitas vezes não perceptíveis rapidamente por humanos.

4.1 Performance Processamento em Lote

A performance das redes neurais recorrentes é avaliada através de métricas tradicionais de aprendizagem de máquina, tais como acurácia, sensibilidade, especificidade, precisão e F-score. O quadro 2 apresenta tais métricas e suas fórmulas:

QUADRO 2 – MÉTRICAS

MÉTRICA	FÓRMULA
Sensibilidade (<i>recall</i>)	$VP / (VP + FN)$
Especificidade	$VN / (FP + VN)$
Acurácia	$(VP + VN) / N$
Precisão	$VP / (VP + FP)$
F-Score	$2 \times (P \times S) / (P + S)$

Fonte: Elaboração própria.

No Quadro 2 as siglas e suas respectivas descrições correspondem a: verdadeiros positivos (VP), falsos negativos (FN), falsos positivos (FP), verdadeiros negativos (VN), precisão (P), sensibilidade (S) e total de elementos (N). Em outras palavras, VP ocorre quando o modelo prevê etiqueta e há etiqueta na realidade, isto é, os especialistas de fato etiquetaram aquele processo. VN ocorre quando não há etiqueta e o modelo não prevê etiqueta. FP ocorre quando o modelo prevê etiqueta e na verdade não há marcação. E, por fim, FN acontece quando o modelo não prevê etiqueta e os especialistas a identificam.

O Quadro 2 mostra que a acurácia é a métrica mais simples e avalia o percentual geral de acertos, entre marcações e não marcações. A sensibilidade (*recall*) avalia a capacidade do modelo classificar corretamente etiquetas de ODS. A especificidade, ao contrário, é indicada para avaliar não etiquetas. A precisão avalia a quantidade de verdadeiros positivos sobre a soma de todas as etiquetas (certas ou não). A métrica *F-Score* é uma média entre a precisão e a sensibilidade.

O Quadro 3 mostra a matriz de confusão, objeto que organiza as quantidades VP, VN, FP e FN:

QUADRO 3 – MATRIZ DE CONFUSÃO

MATRIZ DE CONFUSÃO		CLASSE PREDITA	
		POSITIVA	NEGATIVA
Classe original	Positiva	VP	FN
	Negativa	FP	VN

Fonte: Elaboração própria.

O Quadro 4 mostra as métricas observadas para a última execução das redes neurais recorrentes:

QUADRO 4 – MÉTRICAS RAFA 2030

	ACURÁCIA	SENSIBILIDADE	F-SCORE
ODS 16	77,5%	85,3%	69,9%
ODS 8	82,9%	84,1%	79,6%
ODS 10	91,9%	100%	30,8%
ODS 3	93,7%	83,3%	74,1%

Fonte: Elaboração própria.

O ODS 10 mostra o pior *F-Score* em razão da baixa precisão. Em síntese, neste ODS, a RAFA 2030 etiqueta muito mais processos do que deveria. Em contrapartida, as métricas de acurácia se mostram boas para todos os ODS e todas as sensibilidades estão acima de 80%. Estes resultados mostram que é possível utilizar aprendizagem de máquina e *deep learning* para sugerir classificações em ODS da Agenda 2030.

4.2. Utilização do aplicativo

A iniciativa RAFA também pretende apoiar analistas que buscam classificar um processo por vez. A execução em lote demanda esforço de código e computação, funcionando melhor para grandes conjuntos

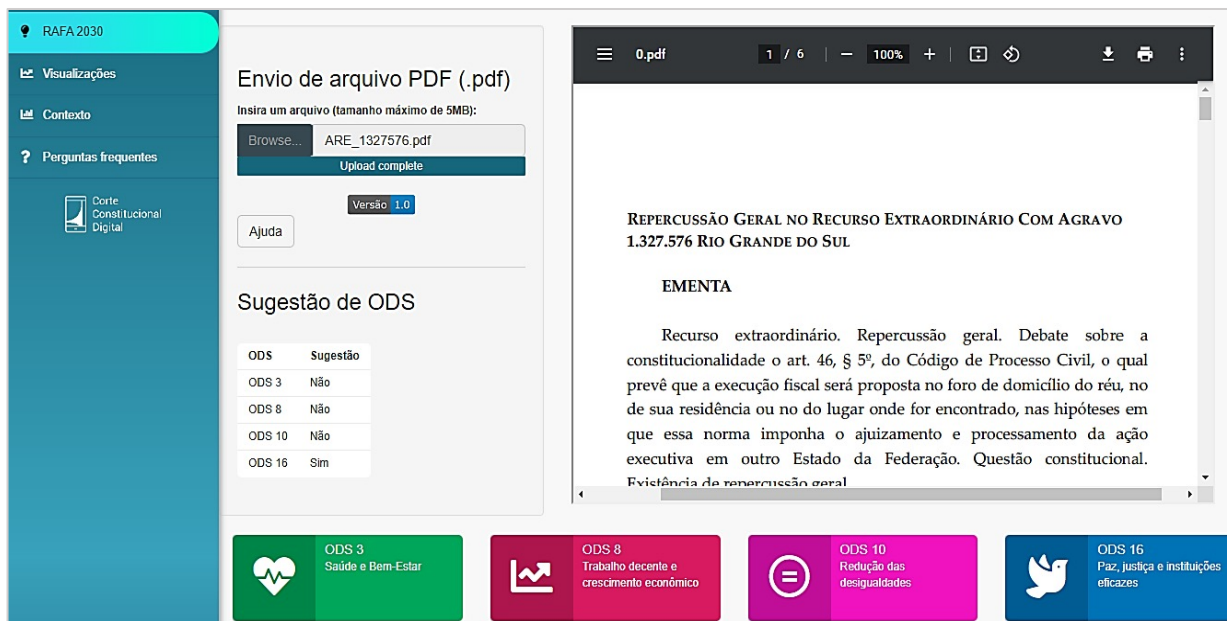
de processos. Por este motivo, foi desenvolvido um aplicativo em *Shiny*, pacote da linguagem R. São disponibilizadas ferramentas gráficas para NLP, tais como gráficos de coocorrência e de palavras mais frequentes, bem como nuvens de palavras e bigramas, além de pesquisas de palavras-chave e busca por contexto de palavras específicas.

O aplicativo fica disponível em um *link* similar a um endereço *web* e pode ser utilizado em qualquer navegador (*Google Chrome*, *Mozilla*, etc). Nenhum pré-requisito técnico ou de hardware é necessário, pois o aplicativo foi criado para ser útil, funcional e intuitivo aos servidores da área jurídica. O aplicativo pode ser utilizado até mesmo em celular, basta haver um navegador web e acesso à internet. A primeira aba do apli-

cativo tem informações sobre o seu uso e a segunda contém informações sobre a Agenda 2030, com *links* oficiais para a ONU e para o *hotsite* do STF. O usuário encontra um campo para *upload* do processo na terceira aba (chamada RAFA 2030). Depois que o aplicativo lê a peça em PDF, aparecem sugestões de clas-

sificações obtidas aprendizagem de máquina (ODS 16,10,8 e 3) e gráficos como a nuvem de palavras. Ainda nesta aba, o usuário pode baixar o texto limpo para utilização em algoritmos próprios. A figura a seguir mostra a aba RAFA 2030 do aplicativo:

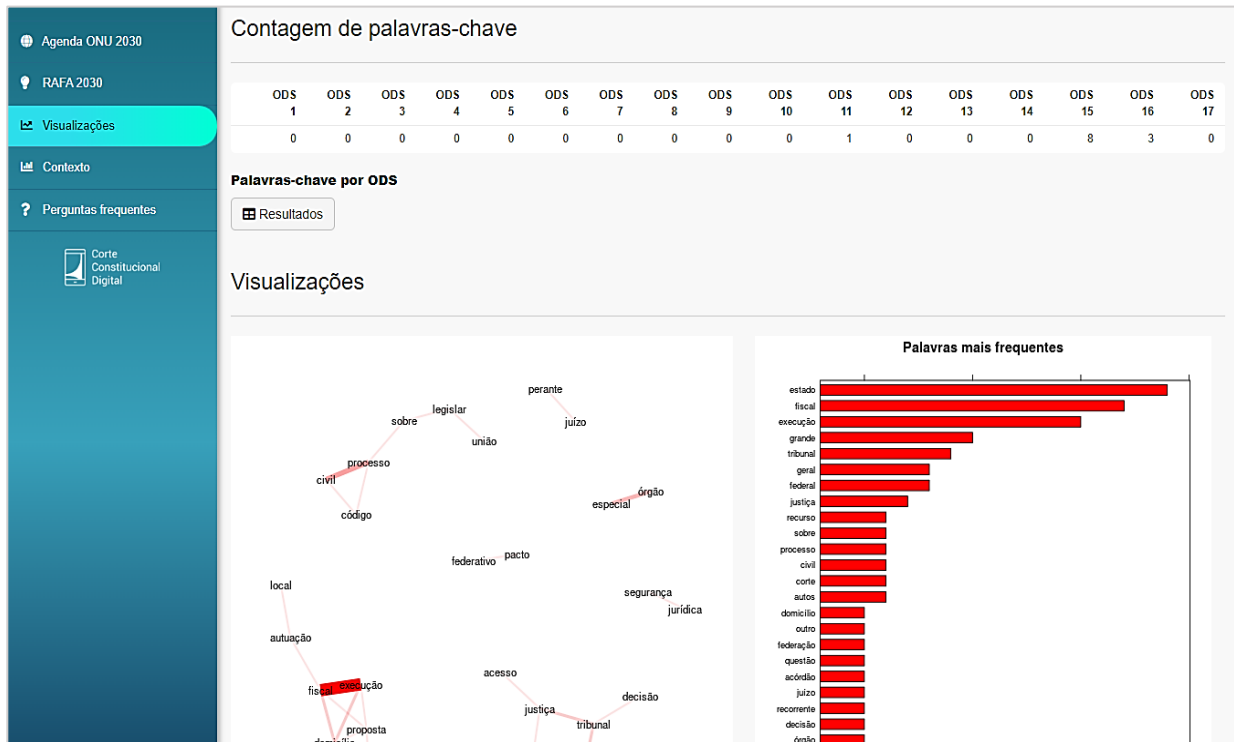
FIGURA 5 – ABA RAFA 2030 DO APLICATIVO



Fonte: Elaboração própria.

As demais abas mostram gráficos mais avançados, contagem e exibição das palavras-chave localizadas e um buscador de contexto, como mostram as figuras 6 e 7.

FIGURA 6 – ABA VISUALIZAÇÕES DO APLICATIVO



Fonte: Elaboração própria.

FIGURA 7 – ABA CONTEXTO DO APLICATIVO



Fonte: Elaboração própria.

Com esses recursos é possível mapear palavras importantes do documento e analisar o contexto de cada uma delas. Um exemplo clássico é dado pela palavra “Rio”, que pode ser curso de água ou palavra inicial de nomes de estados, como Rio de Janeiro e Rio Grande do Norte. Uma simples busca de contexto pode ajudar a não classificar um dado processo no ODS 14 – Vida na Água, por exemplo. Com o uso do aplicativo, analistas podem fazer um mapa geral do documento, de forma automatizada e em poucos segundos após o *upload* de uma peça jurídica. Espera-se que a ferramenta possa ajudar a diminuir o tempo para análise e classificação dos documentos, de forma a permitir que servidores sejam alocados em atividades menos manuais e repetitivas.

Alguns módulos ainda podem ser incluídos e o aplicativo encontra-se em fase de testes por usuários do próprio tribunal. O aumento de processos para treinamento tende a trazer mudanças nas redes neurais, contudo não deve impactar no processo de classificação, já que em última análise, esta avaliação será feita por um servidor. Até a estabilização do algoritmo espera-se que o aplicativo seja de grande utilidade na padronização das classificações, o que gera um efeito cíclico de melhoria na performance dos algoritmos.

5. CONCLUSÃO

O principal objetivo do artigo foi apresentar a ferramenta tecnológica RAFA 2030, desenvolvida dentro de projeto estratégico de institucionalização da Agenda 2030 no STF para apoiar a classificação de processos em objetivos de desenvolvimento sustentável. O trabalho não esgota todas as possibilidades de melhoria da iniciativa, dado que tanto o projeto quanto a ferramenta de apoio à classificação estão em constante avaliação e evolução.

As contribuições deste artigo envolvem a apresentação de algumas etapas para desenvolvimento do aplicativo, bem como para o ajuste de redes neurais. Extratos de código com exemplos estão disponíveis em repositório no *GitHub*²¹.

Possibilidades futuras envolvem o ajuste de algoritmos que combinam texto e metadados, a exemplo do *CatBoost*²² e também ajustes de *ensemble*, isto é, com a reunião de vários algoritmos de aprendizagem de máquina em um esquema de votação para melhor classificar processos em ODS. Sobre o aplicativo, módulos com buscas mais sofisticadas podem ser incluídos, como por exemplo, *queries* de distância entre pares de palavras em extratos de texto. Também podem ser adicionadas abas sobre a similaridade, de forma a apresentar para o analista exemplos de textos etiquetados parecidos com o de interesse. As principais soluções testadas e integradas à iniciativa são combinações de Inteligência Artificial propriamente dita com mecanismos de automação.

REFERÊNCIAS

CNJ - Conselho Nacional de Justiça. Programa Justiça 4.0. 2022. Disponível em: <https://www.cnj.jus.br/tecnologia-da-informacao-e-comunicacao/justica-4-0/>. Acesso em: 10 mai. 2022.

_____. Projetos com Inteligência Artificial no Poder Judiciário. 2022. Disponível em: <https://paineisanalytics.cnj.jus.br/single/?appid=29d710f7-8d8f-47be-8af8-a9152545b771&sheet=b8267e5a-1f1f-41a7-90ff-d7a2f4ed34ea&lang=pt-BR&opt=ctxmenu.currsel/>. Acesso em: 11 mai. 2022.

DAVID, M. S.; RENJITH, S. Comparison of word embeddings in text classification based on RNN and CNN. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, 2021. p. 012029. Disponível em: <https://doi.org/10.1088/1757-899x/1187/1/012029>. Acesso em: 12 mai. 2022.

FGV - Fundação Getúlio Vargas. Portal FGV. 2021. Artificial Intelligence in the Judiciary: the most complete research on the subject. Disponível em: <https://portal.fgv.br/en/news/artificial-intelligence-judiciary-most-complete->

21. Disponível em: <https://github.com/agenda2030rafa/rafa2030>.

22. Detalhes em: <https://catboost.ai/en/docs/>. Acesso em: 13 jul. 2022.

[-research-subject](#). Acesso em: 04 de mai. 2022.

GANAIÉ, M. A. et al. Ensemble *deep learning*: A review. **arXiv preprint arXiv:2104.02395**. 2021. Disponível em: <https://doi.org/10.48550/arXiv.2104.02395>. Acesso em: 12 mai. 2022.

GUPTA, S. et al. Task-optimized word embeddings for text classification representations. **Frontiers in Applied Mathematics and Statistics**, v. 5, p. 67, 2020. Disponível em: <https://doi.org/10.3389/fams.2019.00067>. Acesso em: 12 mai. 2022.

HOSSIN, M.; SULAIMAN, M. N. A review on evaluation metrics for data classification evaluations. **International journal of data mining & knowledge management process**, v. 5, n. 2, p. 1, 2015. Disponível em: <http://dx.doi.org/10.5121/ijdkp.2015.5201>. Acesso em: 06 jun. 2022.

HOVY, D. **Text Analysis in Python for Social Scientists: Prediction and Classification**. Cambridge University Press, 2021. Disponível em: <https://doi.org/10.48550/arXiv.2104.02395>. Acesso em: 06 jun. 2022.

HVITFELDT, E.; SILGE, J. **Supervised machine learning for text analysis in R**. Chapman and Hall/CRC, 2021.

JOCKERS, M. L. **Text analysis with R for students of literature**. Cham: Springer, 2014.

KULAS, Jack. Philosophy and Natural-Language Processing. In: Kulas, J., Fetzer, J.H., Rankin, T.L. (eds) Philosophy, Language, and Artificial Intelligence. Studies in Cognitive Systems, vol 2. Springer, Dordrecht. 1988. Disponível em: https://doi.org/10.1007/978-94-009-2727-8_1. Acesso em: 07 abr. 2022.

LIU, Bing. **Sentiment analysis: Mining opinions, sentiments, and emotions**. Cambridge university press, 2020.

LIU, Q.; KUSNER, M. J.; BLUNSOM, P. A survey on contextual embeddings. **arXiv preprint arXiv:2003.07278**, 2020. Disponível em: <https://doi.org/10.48550/arXiv.2003.07278>. Acesso em: 15 abr. 2022.

MARTIN, J. H. **Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition**. Pearson/Prentice Hall, 2009.

MEIJER, H. J.; TRUONG, J.; KARIMI, R. Document embedding for scientific articles: Efficacy of word embeddings vs TFIDF., 2021. Disponível em: <https://doi.org/10.48550/arXiv.2107.05151>. Acesso em: 12 mai. 2022.

NAY, J. Natural Language Processing for Legal Texts. In D. Katz, R. Dolin, & M. Bommarito (Eds.), **Legal Informatics** (pp. 99-113). Cambridge: Cambridge University Press. 2021. Disponível em: <https://doi.org/10.1017/9781316529683.011>. Acesso em: 07 abr. 2022.

OOMS, J. 2022. Tesseract: Open Source OCR Engine. Disponível em: <https://CRAN.R-project.org/package=tesseract>. Acesso em: 02 fev. 2022.

PEIXOTO, F. H. Projeto Victor: relato do desenvolvimento da inteligência artificial na repercussão geral do Supremo Tribunal Federal. **Revista Brasileira de Inteligência Artificial e Direito-RBIAD**, v. 1, n. 1, p. 1-22, 2020.

PYTHON SOFTWARE FOUNDATION. *Python* Language, 2022. Disponível em: <https://www.Python.org/>. Acesso em: 06 jun. 2022.

R CORE TEAM. R: **A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing, 2022. Disponível em: <https://www.R-project.org/>. Acesso em: 06 jun. 2022.

SHERSTINSKY, A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. **Physica D: Nonlinear Phenomena**, v. 404, p. 132306, 2020. Disponível em: <https://doi.org/10.48550/arXiv.1808.03314>. Acesso em: 06 jun. 2022.

STF - Supremo Tribunal Federal. Hotsite Agenda 2030 STF. 2022. Disponível em: <http://portal.stf.jus.br/hotsites/agenda-2030/>. Acesso em: 11 abr. 2022.

_____. Painel: STF e Agenda 2030. 2022. Metadados de processos. Disponível em: <https://transparencia.stf.jus.br/single/?appid=bc086310-9ce5-4b55-9a8a-e420a907ccca&sheet=db127d33-d4c1-47e0-8bab-3079214719c6&opt=c->

[txmenu](#). Acesso em: 11 abr. 2022.

STJ - Superior Tribunal de Justiça. Revolução tecnológica e desafios da pandemia marcaram gestão do ministro Noronha na presidência do STJ. 2020. Disponível em: <https://www.stj.jus.br/sites/portalp/Paginas/Comunicacao/Noticias/23082020-Revolucao-tecnologica-e-desafios-da-pandemia-marcaram-gestao-do-ministro-Noronha-na-presidencia-do-STJ.aspx>. Acesso em: 14 mai. 2022.

TJGO - Tribunal de Justiça do Estado de Goiás. Lançamento Oficial da ferramenta Berna - Sistema de Inteligência Artificial. Youtube, 26 mai. 2020. Disponível em: <https://www.youtube.com/watch?v=MY8OG7UGdhM>. Acesso em: 14 mai. 2022.

VAJJALA, S. et al. **Practical natural language processing: a comprehensive guide to building real-world NLP systems**. O'Reilly Media, 2020.



Luiz Fux

ORCID: <https://orcid.org/0000-0003-1996-7572>

Ministro do Supremo Tribunal Federal, jurista e professor universitário.

E-mail: gabinete@stf.jus.br

Foi ministro do Tribunal Superior Eleitoral de 2014 a 2018 e ministro do Superior Tribunal de Justiça de 2001 a 2011, promotor de justiça do Ministério Público do Estado do Rio de Janeiro de 1979 a 1982 e juiz de direito fluminense de 1982 até 1997, quando foi promovido a desembargador do Tribunal de Justiça do Rio de Janeiro. É bacharel (1976) e doutor (2009) em direito pela Faculdade de Direito da Universidade do Estado do Rio de Janeiro (UERJ). Desde 1995 é professor titular da UERJ, além de ter lecionado na Escola de Magistratura do Estado do Rio de Janeiro e na Pontifícia Universidade Católica do Rio de Janeiro. É membro da Academia Brasileira de Letras Jurídicas e da Academia Brasileira de Filosofia. Presidiu a comissão de juristas que elaborou o anteprojeto do Código de Processo Civil, em vigor desde 2016.



Pedro Felipe de Oliveira Santos

ORCID: <https://orcid.org/0000-0003-4600-3760>

Desembargador Federal do Tribunal Regional Federal da 6ª Região.

E-mail: pedro.felipe@trf1.jus.br

Vice-Diretor da Escola de Magistratura Federal da Sexta Região. Magistrado de Enlace no Brasil para a Convenção de Haia de 1980. Atuou como Secretário Geral da Presidência do Supremo Tribunal Federal, Juiz Instrutor e Juiz Auxiliar do Supremo Tribunal Federal. Atuou como Juiz Auxiliar do Conselho Nacional de Justiça. Atuou como Defensor Público Federal. Doutorando em Direito pela Universidade de Oxford. Mestre em Direito pela Universidade de Harvard. Graduado em Direito pela Universidade de Brasília. Professor de Direito Constitucional.



Aline Carlos Dourado Braga

ORCID: <https://orcid.org/0000-0002-1713-3833>

Analista Judiciária do Supremo Tribunal Federal.

E-mail: alinecd@stf.jus.br

É graduada em Direito pelo Uniceub-Centro de Ensino Unificado de Brasília, pós-graduada em Direito Público pela Universidade Cândido Mendes e responsável pela interlocução para a execução das ações do Projeto Agenda 2030 no STF. Secretária de Gestão de Precedentes do STF.



Pamella Sada Dias Edokawa

ORCID: <https://orcid.org/0000-0001-7387-8533>

Analista Judiciária do Supremo Tribunal Federal.

E-mail: pamella.edokawa@stf.jus.br

Coordenadora do Escritório de Gestão da Estratégia do Supremo Tribunal Federal. Graduada em Estatística pela UnB e especialista em regulação financeira. É responsável pelo núcleo de Análise Estatística e pela gerência de Gestão da Estratégia. É analista no STF desde 2016.



Júlio Luz Sisson de Castro

ORCID: <https://orcid.org/0000-0002-7755-850X>

Analista Judiciário do Supremo Tribunal Federal.

E-mail: juliols@stf.jus.br

Analista judiciário desde 2005, atualmente ocupa o cargo de Supervisor do Núcleo de Gerenciamento de Precedentes do STF, tendo trabalho na 12ª Vara Federal de Brasília e no Superior Tribunal de Justiça. É pós-graduado em Processo Civil pelo UniCeub-Centro de Ensino Unificado de Brasília. Atua no projeto Agenda 2030 no STF.