

RESEARCH ARTICLE

OPEN ACCESS

PRAZO MÉDIO DE PROCESSOS NO SEGUNDO GRAU DE JURISDIÇÃO: UM ESTUDO BASEADO EM MINERAÇÃO DE DADOS EM UMA ORGANIZAÇÃO JURÍDICA

*Luiz Henrique Tacconi and Denise Fukumi Tsunoda

Universidade Federal do Paraná - Brasil - Programa de Pós-Graduação em Gestão da Informação

ARTICLE INFO

Article History:

Received 10th July, 2019
Received in revised form
17th August, 2019
Accepted 21st September, 2019
Published online 16th October, 2019

Key Words:

Data Mining, Knowledge Discovery in
Databases, KDD, Artificial Intelligence, AI.

*Corresponding author:

Luiz Henrique Tacconi

ABSTRACT

This paper presents a data mining study based on the process time average in the second instance in a Brazilian law organization. First, a review of knowledge discovery in databases and data mining concepts was performed, and after, some data mining techniques were applied on a database with 51,052 records relating to pending processes in the second instance. The obtained results covered a discretization of the amount of time in which the processes were pending, in which internal areas the process was, as well as the procedural class that defined it. Association and classification tasks were performed, and they presented correlations between the time of processes and the internal areas of the organization, demonstrating in which there was a shorter period, and in which the pendency was higher. Subsequent works suggested deepening data mining in other phases and process classifications.

Copyright © 2019, Luiz Henrique Tacconi and Denise Fukumi Tsunoda. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citation: Luiz Henrique Tacconi and Denise Fukumi Tsunoda, 2019. "Prazo médio de processos no segundo grau de jurisdição: um estudo baseado em mineração de dados em uma organização jurídica", *International Journal of Development Research*, 09, (10), 30274-30279.

INTRODUCTION

A democratização da tecnologia proporciona aos cidadãos facilidades de acesso em suas rotinas pessoais e de trabalho. Entretanto, estas otimizações ocasionam também o crescimento exponencial de dados, trazendo ao convívio conceitos como *big data*, mineração de dados e inteligência artificial. Nas áreas jurídicas esse fenômeno ocorre da mesma forma, pois quanto mais conscientização a sociedade possui de seus direitos, maior a quantidade de processos nos Tribunais brasileiros. Este crescimento de dados, porém, não é acompanhado pelo aumento de recursos aos órgãos públicos, ocasionando a diminuição da celeridade, o crescimento no acervo e a complexidade no julgamento destes processos, cenário que torna favorável a utilização de ferramentas que possam maximizar o aproveitamento dos recursos. Esta alta quantidade de dados tornou não apenas inviável o tratamento das informações de forma manual, mas também, impossível de serem obtidos dados estratégicos para a tomada de decisões. A descoberta de conhecimento em base de dados, do inglês *Knowledge Discovery in Databases (KDD)*, propõe auxiliar as análises estratégicas de informações de forma automática e com resultados satisfatórios. Este processo é composto pelas etapas de seleção de dados, pré-processamento, transformação, mineração dos dados e interpretação dos resultados.

As organizações mais ágeis, como por exemplo empresas do ramo financeiro, estão na vanguarda desta aplicação de conhecimento, na qual realizam a mineração de dados em grande volume de dados (*big data*) como o cerne de seus objetivos de negócio. A estratégia destas organizações está extremamente centrada nos processos de descoberta de conhecimento em base de dados, como por exemplo, análise de padrões de consumo, aferição de riscos e inadimplência, possibilidade de oferecer novos serviços com mais precisão aos clientes que tendem a usufruí-los e gerar maior retorno financeiro, dentre tantos outros. Nas áreas jurídicas, os processos judiciais eletrônicos (PJe) permeiam todos os ramos da justiça: Estadual, Federal, Militar, Eleitoral e do Trabalho. Esta introdução tecnológica trouxe o aumento na efetividade e celeridade da justiça, fazendo com que os processos antigos, que eram físicos, com alto risco de informações serem perdidas e com a dificuldade de mobilidade, se tornassem processos digitais ágeis, com cópias de segurança e com tramitação sem morosidade entre as instâncias. Embora o avanço seja claro, houve também o aumento do acesso à informação, e nos últimos anos é notável a grande quantidade de ações judiciais, conforme demonstrado na Tabela 1. É considerada também a dificuldade na uniformização jurisprudencial, resultando não apenas em diferentes decisões para solicitações similares, mas em processos de trabalho mais onerosos, nos quais magistrados e servidores necessitam

recorrer à diversas fontes para uma melhor prestação jurisdicional. Este artigo apresenta a utilização de ferramentas e métodos de mineração de dados em uma base jurídica. A base de dados foi solicitada à uma organização do ramo jurídico brasileiro e cedida por meio de sua unidade de ouvidoria. O objetivo desta verificação foi analisar os processos pendentes de baixa no segundo grau de jurisdição, o qual, segundo o Conselho Nacional de Justiça por meio de seu relatório anual denominado Justiça em Números (CNJ, 2018), é a instância que demanda maior tempo na duração de um processo. A utilização das técnicas de mineração de dados visa a extração automatizada de informações, as quais não seriam possíveis manualmente.

Tabela 1. Casos novos no Judiciário brasileiro em 2017

Casos novos no Judiciário brasileiro em 2017	
Justiça Estadual	20.207.585
Justiça do Trabalho	4.321.842
Justiça Federal	3.865.182
Justiça Eleitoral	169.190
Justiça Militar Estadual	5.150
Auditorias Militares da União	1.572
Tribunais Superiores	543.058
Total	29.113.579

Fonte: Relatório Justiça em Números (CNJ, 2018)

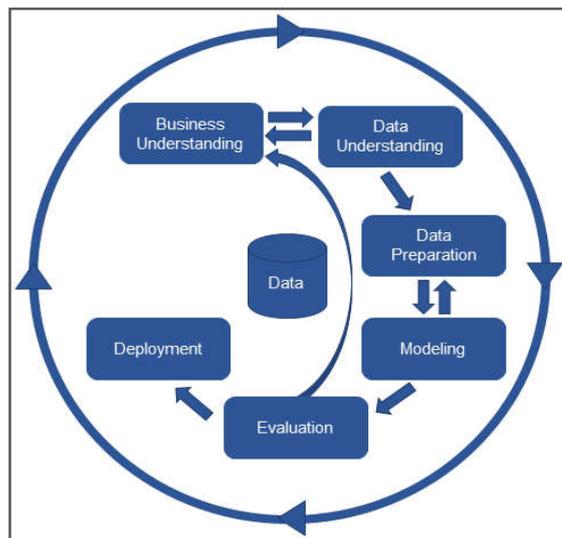
REFERENCIAL TEÓRICO

A Descoberta de Conhecimento em base de dados é um processo de identificação de padrões e tendências por análise de grandes quantidades de dados. A principal etapa deste processo é a mineração de dados, a qual consiste na execução métodos e algoritmos específicos que produzem uma relação de padrões a partir de dados (FAYYAD *et al.*, 1996). A descoberta de conhecimento em base de dados apresenta melhores resultados do que métodos tradicionais de recuperação de dados, pois converte de forma automática dados brutos em informação relevantes (TAN *et al.*, 2009). O processo de KDD é de natureza interdisciplinar, pois agrega conceitos e técnicas de áreas como aprendizado de máquinas, reconhecimento de padrões, banco de dados e estatística (FAYYAD *et al.*, 1996). A metodologia CRISP-DM, *Cross-Industry Standard Process for Data Mining*, é uma técnica de mineração de dados criada na década de 90 para atender a necessidade da elaboração de modelos com foco na tomada de decisões (Pádua e Souza, 2018). Segundo Chapman (2000), a metodologia CRISP-DM é composta por 6 fases, organizadas de maneira cíclica de fluxo não unidirecional, possibilitando alternar entre as suas fases e tarefas. As fases da metodologia CRISP-DM são:

- Entendimento do Negócio (Business Understanding): definição dos objetivos da utilização de mineração de dados considerando a perspectiva do negócio da organização;
- Entendimento dos Dados (Data Understanding): fase de familiarização e interpretação da coleção de dados, buscando avaliar a qualidade e construir hipóteses sobre os possíveis resultados da mineração;
- Preparação dos Dados (Data Preparation): fase que compreende a seleção de tabelas, registros e atributos, bem como limpeza, transformação e discretização dos dados para utilização nas ferramentas de mineração;
- Modelagem (Modelling): fase de utilização de técnicas de modelagem. Nesta fase é comum retornar à fase de Preparação dos Dados para ajustes, de modo a obter melhores resultados;

- Avaliação (Evaluation): avaliação dos resultados da fase de Modelagem, para verificar se foram atendidos os objetivos de negócio na mineração;
- Implantação (Deployment): utilização dos conhecimentos resultantes das fases anteriores nas tomadas de decisões das áreas de negócio.

A Figura 1 apresenta as fases da metodologia CRISP-DM e o fluxo de sua aplicação.



Fonte: Pádua e Souza, 2018

Figura 1. Metodologia CRISP-DM

O objetivo da mineração de dados é a extração de conhecimento implícito por meio da descoberta de padrões e regras significativas, a partir de grande quantidade de dados armazenados, utilizando algoritmos para descobrir novos entendimentos e padrões de relacionamento entre os dados. Este processo pode ser compreendido como iterativo, uma vez que necessita de intervenção do usuário ao longo das etapas, bem como é também um processo iterativo, posto que possui uma sequência finita de passos (FAYYAD *et al.*, 1996). O termo mineração de dados é alusivo ao processo de mineração de pedras preciosas, uma vez que se explora uma base de dados (mina) usando algoritmos (ferramentas) adequados para obter conhecimento (minerais preciosos) (Castro e Ferrari, 2016).

METODOLOGIA

Este trabalho objetiva a análise de dados quantitativa, na qual foram executados métodos de mineração de dados em uma base real de uso visando a obtenção de informações que possam auxiliar na tomada de decisão a partir de um conjunto de dados já definidos. Para tal estudo, foi solicitada à uma organização governamental do ramo jurídico uma quantidade de dados com determinado foco específico. Tal qual uma organização privada possui seus objetivos de negócio visando atender seus clientes, oferecendo um produto ou serviço com valor agregado, as organizações públicas também visam entregar ao cidadão um serviço de qualidade. No segmento jurídico, a prestação jurisdicional com celeridade aos cidadãos é um dos melhores exemplos de entrega de valor ao cliente. Desta forma, a solicitação à organização visou a obtenção de dados sobre os tempos médios de duração de processos no segundo grau de jurisdição. A base de dados analisada, que possui mais de cinquenta mil registros de processos pendentes

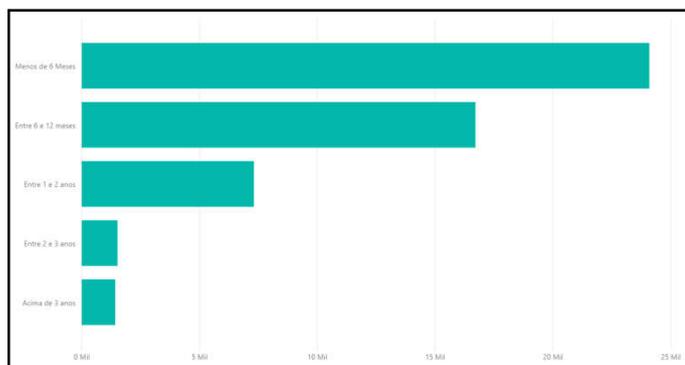
de baixa no segundo grau de jurisdição, foi solicitada formalmente à Ouvidoria do órgão e recebida conforme as orientações da Lei de Acesso à Informação. A etapa de pré-processamento compreendeu a verificação e a análise inicial dos dados, de modo a identificar os tipos de atributos contidos na base e quais métodos de mineração de dados pudessem gerar resultados que melhor extraia conhecimento. Para executar a mineração foi escolhido o software *Weka*, desenvolvido na Universidade de Waikato, Nova Zelândia, pelos motivos de este ser muito utilizado no meio acadêmico e por não ser necessária a aquisição de licenças.

RESULTADOS

A base de dados analisada contém 51.052 processos pendentes de baixa no segundo grau de jurisdição. Devido ao fato destes processos estarem uma base que tem por objetivo apenas o registro, sem qualquer compromisso com análises *a posteriori*, foi necessário elaborar um atributo meta, adicionando-o a base de dados. Os atributos oriundos da base possuíam, dentre várias informações, especificações sobre qual a unidade interna da organização o processo estava, o sistema utilizado (por haver um sistema legado, e um sistema atual, de utilização nacional), a classificação do processo junto ao Conselho Nacional de Justiça, e a data em que este processo se tornou pendente de baixa. Como há restrições em utilizar campos em formato de data na mineração de dados, previamente foi criado um atributo denominado “Dias pendentes de baixa”, na qual foi utilizada uma função de cálculo baseada no dia da consulta da base e no dia em que o processo se tornou pendente de baixa. Após, foi adicionado um atributo discretizado, ou seja, foi criado um atributo em formato de texto, denominado “Período pendente de baixa”, no qual houvesse classificações possíveis de serem mineradas. Por se tratar da necessidade em auxiliar a tomada de decisões quanto aos processos que estão há mais tempo pendentes de baixa, o atributo foi discretizado com as seguintes categorias:

- Menos de 6 Meses;
- Entre 6 e 12 meses;
- Entre 1 e 2 anos;
- Entre 2 e 3 anos;
- Acima de 3 anos.

A Figura 2 apresenta a quantidade de processos classificados por período pendente de baixa.



Fonte: Elaborado pelos autores

Figura 2. Quantidade de processos pendentes de baixa por período

O atributo “Período pendente de baixa” foi definido como o atributo meta da mineração de dados realizada. Cabe ressaltar

que estes registros são cumulativos, ou seja, é um agregado de todos os processos que ficaram pendentes de baixa e ainda se encontram nesta situação em junho de 2019 (data de solicitação da base), independentemente do momento em que passaram a ser classificados como pendentes. Todos os registros desta base de dados possuíam as seguintes informações:

- Município Origem: município em quem foi originado o processo;
- Unidade: área interna da organização na qual se encontra o processo;
- Fonte: sistema eletrônico no qual existe a movimentação do processo. Neste campo havia apenas duas possibilidades: “legado” e “PJe”;
- Data Ocorrência: data em que o processo se tornou pendente de baixa (campo em formato de data, no qual foi necessária a discretização);
- Classe CNJ: classificação dos processos perante o Conselho Nacional de Justiça;
- Processo CNJ: código único em todo o Judiciário para identificar o processo. O código é composto conforme apresentado na tabela a seguir (CNJ, 2008).

Tabela 2. Estrutura do código de um processo no PJe

Exemplo de código de processo: NNNNNNN-DD.AAAA.J.TR.0000	
NNNNNNN	Número sequencial do processo por unidade de origem
DD	Dígito verificador
AAAA	Ano de ajuizamento
J	Órgão do Poder Judiciário
TR	Tribunal de origem
0	Unidade de origem do Processo

Fonte: Conselho Nacional de Justiça

E os novos atributos que passaram a compor a base:

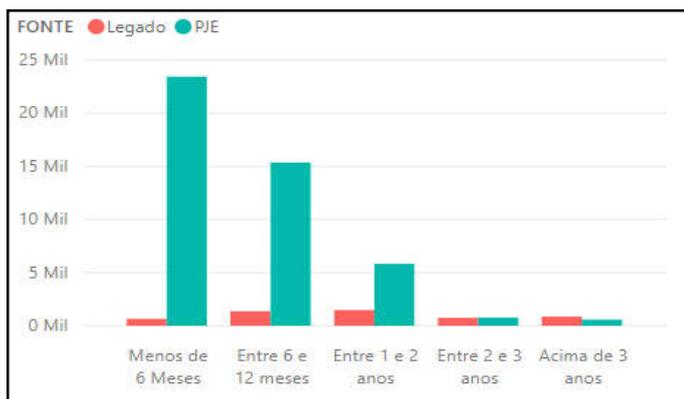
- Dias pendentes de baixa: quantidade de dias (campo numérico) em que o processo está pendente de baixa;
- Período pendente de baixa: discretização do atributo Dias pendentes de baixa. Este campo é armazenado em formato de texto.

Em toda a base de dados, nos mais de cinquenta mil registros, todos estes dados estavam presentes em todos os registros, não havia dados nulos. Para a mineração dos dados, e visando o auxílio na tomada de decisão, foram utilizados apenas os atributos: Unidade, Fonte, Classe CNJ e Período pendente de baixa. Os outros atributos não exerceram influência nos resultados e consequentemente não foi visualizado que estes auxiliariam nas possíveis tomadas de decisão. No atributo “Unidade” foram preservadas as identificações de cada Turma, apresentando apenas genericamente o termo “Secretaria da Turma” e um código aleatório composto por duas letras, ao invés de ser descrito o número da Turma. Os tipos de registros possíveis para este atributo são:

- Tribunal;
- Seção Especializada;
- Órgão Especial;
- Tribunal Pleno;
- Núcleo de Gerenciamento de Precedentes;
- Uniformização de Jurisprudência;
- Secretaria da Turma *XR*;
- Secretaria da Turma *FV*;

- Secretaria da Turma *TK*;
- Secretaria da Turma *DW*;
- Secretaria da Turma *HS*;
- Secretaria da Turma *NZ*;
- Secretaria da Turma *LQ*.

Já no atributo “Fonte” são possíveis apenas dois tipos de registros: “Legado”, que se trata de um sistema desenvolvido pela própria organização e que está em desuso, e o sistema nacional, atualmente utilizado, “PJe”. Cabe ressaltar que a grande maioria dos processos hoje tramita no sistema PJe, sistema padrão do Judiciário. A Figura 3 apresenta o quantitativo de processos por período pendente de baixa e sistema.



Fonte: Elaborado pelos autores

Figura 3. Quantidade de processos por período e sistema

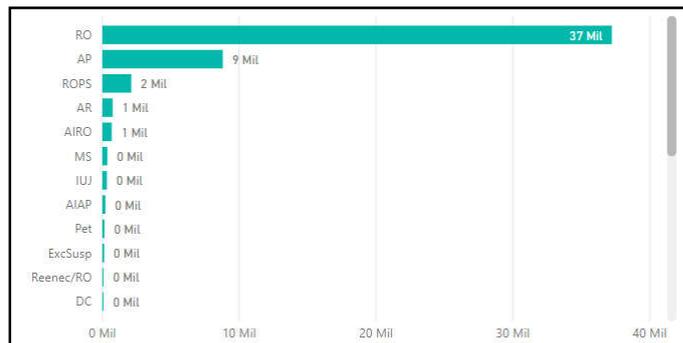
O atributo “Classe CNJ” possui categorizações elaboradas pelo Conselho Nacional de Justiça. Nesta base de dados é encontrado apenas o código de cada uma destas classes, porém, é apresentado neste estudo, para elucidação, quais as descrições de cada classe contida na base. Tais dados são apresentados na Tabela 3 e mais detalhadamente descritos no endereço eletrônico do Conselho Nacional de Justiça.

Tabela 3. Tipos de classes processuais

Classes Processuais	Descrição
AACC	Ação Anulatória de Cláusulas Convencionais
AgR	Agravo Regimental
AIAP	Agravo de Instrumento em Agravo de Petição
AIRO	Agravo de Instrumento em Recurso Ordinário
AP	Agravo de Petição
AR	Ação Rescisória
Atent	Atentado
Caulnom	Cautelar Inominada
CC	Conflito de competência
DC	Dissídio Coletivo
DCG	Dissídio Coletivo de Greve
ExcSusp	Exceção de Suspeição
IAC	Incidente de Assunção de Competência
IncResDemRept	Incidente de Resolução de Demandas Repetitivas
IUJ	Incidente de Uniformização de Jurisprudência
MS	Mandado de Segurança
MSCol	Mandado de Segurança Coletivo
Pet	Petição
Protes	Protesto
Rcl	Reclamação
ReeNec	Reexame Necessário
Reenec/RO	Reexame Necessário / Recurso Ordinário
RO	Recurso Ordinário
ROPS	Recurso Ordinário - Rito Sumaríssimo
TutAntAnt	Tutela Antecipada Antecedente
TutCautAnt	Tutela Cautelar Antecedente

Fonte: Conselho Nacional de Justiça

Na Figura 4 é possível verificar a quantidade de processos em algumas classes processuais.



Fonte: Elaborado pelos autores

Figura 4. Quantidade de processos por classe processual

Em continuidade à análise dos dados foram escolhidas as tarefas de associação (descritiva) e classificação (preditiva) na mineração dos dados. Na tarefa de associação foi escolhido o algoritmo *Apriori*, o qual viabiliza a identificação de regras de associação na base de dados. Já na tarefa de classificação foram escolhidos os métodos que utilizam árvores de decisão (PART e J48).

Algoritmo *Apriori*

A execução do algoritmo *Apriori* (Agrawal e Srikant, 1994) com os parâmetros nas configurações padrão, com exceção do número máximo de regras que foi aumentado para 100, resultou em 25 regras. Destas 25, as 7 primeiras tiveram o valor máximo no parâmetro de confiança da regra, $\langle \text{conf:}(1) \rangle$. Foi possível identificar, por exemplo, que os processos com a classe processual “Agravo de Petição” estão na Sessão Especializada, no sistema PJe e pendentes de baixa há menos de 6 meses.

Na Tabela 4 são apresentadas e explicadas algumas regras encontradas com o algoritmo *Apriori*.

Tabela 4. Regras de associação na base de dados

1. CLASSE_CNJ=AP 8807 \implies UNIDADE=Seção Especializada 8802 $\langle \text{conf:}(1) \rangle \text{lift:}(4.98) \text{lev:}(0.14)$
2. FONTE=PJE CLASSE_CNJ=AP 8649 \implies UNIDADE=Seção Especializada 8644 $\langle \text{conf:}(1) \rangle \text{lift:}(4.98) \text{lev:}(0.14)$
3. CLASSE_CNJ=AP PERIODO_PENDENTE_DE_BAIXA=Menos de 6 Meses 5630 \implies UNIDADE=Seção Especializada 5626 $\langle \text{conf:}(1) \rangle \text{lift:}(4.98) \text{lev:}(0.09)$
4. CLASSE_CNJ=AP PERIODO_PENDENTE_DE_BAIXA=Menos de 6 Meses 5630 \implies FONTE=PJE 5626 $\langle \text{conf:}(1) \rangle \text{lift:}(1.11) \text{lev:}(0.01)$
5. FONTE=PJE CLASSE_CNJ=AP PERIODO_PENDENTE_DE_BAIXA=Menos de 6 Meses 5626 \implies UNIDADE=Seção Especializada 5622 $\langle \text{conf:}(1) \rangle \text{lift:}(4.98) \text{lev:}(0.09)$

Fonte: Elaborado pelos autores

É possível identificar, na 5ª regra, que os processos no sistema PJe, na classe processual “Agravo de Petição” e com “Período pendente de baixa” menor do que 6 meses estão na unidade “Seção Especializada”. Aumentando o suporte da regra para 0,3 (ao invés do padrão 0,1) e definindo a métrica para o parâmetro *lift no valor padrão* 0,9 foi identificado que aproximadamente metade dos processos que estão pendentes de baixa no sistema PJe estão pendentes há menos de 6 meses. O parâmetro *lift* apresenta o grau de interesse da regra. Os resultados desta tarefa de mineração de dados podem ser utilizados para entender como a base de dados é disposta,

demonstrando um quantitativo de processos que estão em determinadas unidades ou classes processuais.

Algoritmo J48

Utilizando o algoritmo J48, uma implementação do proposto c4.5 (Quinlan, 1993), com seus parâmetros *default* do software *Weka*, foi gerada uma árvore com 226 folhas (ramificações) utilizando o atributo meta “Período pendente de baixa”. Desta forma, a árvore resultante apresenta visibilidade comprometida pela profundidade e amplitude. Nesta aplicação do algoritmo, utilizando a opção de teste de validação cruzada de 10 partições e realizada em 0.12 segundos, foram classificados corretamente 26.465 registros (51,83%) e 24.587 registros foram classificados incorretamente (48,16%). Estes valores são apresentados na matriz de confusão na Figura 5.

Figura 5. Matriz de confusão de algoritmo J48

a	b	c	d	e	<== classificado como	
20833	3066	186	2	2	24089	86% a
11943	4365	400	1	1	16710	26% b
3291	2874	1130	6	7	7308	15% c
587	380	452	96	6	1521	6% d
524	477	374	8	41	1424	3% e
Total:					51052	

Fonte: Elaborado pelos autores

Na Figura 5 observa-se na diagonal principal os acertos e fora desta, os erros de classificação. Por meio de uma análise mais detalhada desta matriz, pode-se verificar que existe 86% de acerto na previsão para os “menos de 6 meses”, mas o modelo apresenta acerto menores que 50% para os demais valores do atributo meta.

Algoritmo PART

Considerando a dificuldade de visualização da árvore do J48 e para facilitar a extração das regras de classificação da árvore, foi utilizado o método PART (Frank e Witten, 1998). Este método utiliza a árvore de decisão gerada pelo C4.5 para extrair e apresentar as regras de classificação. Após sua execução foram descobertas 36 regras utilizando o atributo meta “Período pendente de baixa”. Nesta aplicação do algoritmo, utilizando a opção de teste de validação cruzada de 10 partições e realizada em 0.16 segundos, foram classificados corretamente 26.445 registros (51,80%) e 24.607 registros foram classificados incorretamente (48,19%). Estes valores são apresentados na matriz de confusão na Figura 6.

Figura 6. Matriz de confusão de algoritmo J48

a	b	c	d	e	<== classificado como	
20778	3102	189	0	20	24089	86% a
11904	4399	402	0	5	16710	26% b
3278	2885	1122	5	18	7308	15% c
581	380	451	96	13	1521	6% d
518	477	370	9	50	1424	4% e
Total:					51052	

Fonte: Elaborado pelos autores

A Tabela 5 apresenta algumas regras encontradas após a execução do algoritmo PART. A primeira regra apresenta: se um processo está no sistema “PJe”, na unidade “Núcleo de Gerenciamento de Precedentes” e com a classe processual “Incidente de Uniformização de Jurisprudência”, é possível prever que este processo está pendente de baixa entre 2 e 3

anos. Na sétima regra é possível verificar que os processos tramitando no “PJe”, na unidade “Uniformização de Jurisprudência” e na classe processual “Incidente de Uniformização de Jurisprudência”, os processos estão pendentes de baixa entre 1 e 2 anos.

Tabela 5. Regras de classificação com o algoritmo PART na base de dados

FONTE = PJE AND UNIDADE = Núcleo de Gerenciamento de Precedentes AND CLASSE_CNJ = IUJ: Entre 2 e 3 anos
FONTE = PJE AND UNIDADE = Seção Especializada: Menos de 6 Meses
FONTE = PJE AND UNIDADE = Secretaria da Turma DW: Menos de 6 Meses
FONTE = PJE AND UNIDADE = Secretaria da Turma TK: Menos de 6 Meses
FONTE = PJE AND UNIDADE = Secretaria da Turma NZ: Menos de 6 Meses
FONTE = PJE AND CLASSE_CNJ = ROPS: Menos de 6 Meses
FONTE = PJE AND UNIDADE = Uniformização de Jurisprudência AND CLASSE_CNJ = IUJ: Entre 1 e 2 anos

Fonte: Elaborado pelos autores

CONSIDERAÇÕES FINAIS

O aumento exponencial na quantidade de dados das organizações traz consigo a necessidade de técnicas avançadas para o tratamento e interpretação destes dados. Áreas de conhecimento como a inteligência artificial e mineração de dados auxiliam não somente na classificação e utilização destes dados, mas também objetiva este tratamento para a tomada de decisões e gestão da informação. Este trabalho teve como objetivo apresentar um ponto de partida do uso de mineração de dados em uma área tão complexa quanto à jurídica, principalmente no que tange à celeridade da prestação jurisdicional. A tarefa de associação realizada neste estudo permitiu uma análise simplificada de como a base de dados está distribuída, embora este fator não seja determinante para a tomada de decisão. Já nas tarefas de classificação, as árvores de decisão permitem uma visualização mais objetiva de como os dados estão dispostos na base dados, facilitando a compreensão e auxiliando, numa etapa inicial, a decisão de um aprofundamento de estudos nos processos que estão pendentes de baixa há mais tempo. Este trabalho, demonstrou, mesmo que uma forma empírica e inicial, como a mineração de dados pode ser utilizada para auxiliar no alcance das metas estabelecidas pelos conselhos superiores do Judiciário. Na realização dos trabalhos futuros sugere-se o aprofundamento da mineração de dados em demais fases e classificações dos processos, não somente nos que estão pendentes de baixa. Desta forma será possível prever o tempo estimado e a duração razoável do processo judicial em cada fase de tramitação. Por fim, é destacada a importância da mineração de dados visando auxiliar o alcance das metas das organizações, fornecendo às áreas de estratégia e alta administração um embasamento para a tomada de decisão.

REFERÊNCIAS

- AGRAWAL, Rakesh; SRIKANT, Ramakrishnan. Fast Algorithms for Mining Association Rules in Large Databases. 20th International Conference on Very Large Data Bases. 1994.
- CASTRO, Leandro Nunes; FERRARI, Daniel Gomes. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. Saraiva. 2016.
- CHAPMAN, Pete. CRISP-DM 1.0: Step-By-Step Data Mining Guide. [S.I.]: 2000. Disponível em <https://bit.ly/2srmK1m>. Acesso em 28 jul. 2019.

- CONSELHO NACIONAL DE JUSTIÇA. Selo justiça em Números 2018. Disponível em <https://bit.ly/317buG5>. Acesso em 10 jul. 2019.
- CONSELHO NACIONAL DE JUSTIÇA. Resolução n.º 65 de 16/12/2008. Disponível em <https://bit.ly/2DOeBtv>. Acesso em 15 jul. 2019.
- FAYYAD, Usama; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic. From data mining to knowledge discovery in databases. AI magazine. 1996.
- FAYYAD, U. M., Piatetsky Shapiro, G., Smyth, P. & Uthurusamy, R. Advances in Knowledge Discovery and Data Mining. AAAI Press, The Mit Press. 1996.
- FRANK, Eibe; WITTENS, Ian H. Generating Accurate Rule Sets Without Global Optimization. Fifteenth International Conference on Machine Learning. 1998.
- PÁDUA, Antonio Francisco Lima de Oliveira. SOUSA, Fabiana Araújo. Metodologia CRISP-DM: Potencialidades na descoberta do conhecimento em dados educacionais. XVI Congresso Internacional de Tecnologia na Educação. 2018.
- QUINLAN, Ross. C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers. 1993.
- RAMPAO, Talita de Souza. Mineração de dados em bases jurídicas: um estudo de caso. Revista Brasileira de Educação em Ciência da Informação. 2019.
- TAN, Pang-Ning; STEINBACH, Michael; KUMAR, Vipin. Introdução ao data mining: mineração de dados. Ciência Moderna. 2009.
