

Utilização de Técnicas de Inteligência Artificial na tarefa de Classificação Jurisprudencial do Tribunal Regional do Trabalho 2ª. Região São Paulo

Thiago Ferauche¹
Maurício Amaral de Almeida 2²

Sumário: 1. Introdução; 2. Mineração de Textos; 3. Metodologia; 4. Resultados; 5. Conclusão; 6. Referências Bibliográficas

Resumo: Este artigo apresenta resultados obtidos durante o processo de aplicação de técnicas de Inteligência Artificial na tarefa de classificação das ementas que compõe a jurisprudência do Tribunal Regional do Trabalho da 2ª. Região – São Paulo. Utilizando-se de técnicas de aprendizado de máquina, foi possível estabelecer um modelo que aprendeu com as classificações anteriores, e foi possível realizar a classificação de ementas desconhecidas pelo modelo, possibilitando a criação de futuros modelos que aprendam com o conhecimento explícito jurídico.

Palavras-chave: Mineração de Textos; Aprendizado de Máquina; Jurisprudência; Classificação de documentos.

1. Introdução

A jurisprudência é um conjunto de decisões de magistrados, que expressam aplicação da legislação em casos práticos, formando assim o conhecimento jurídico de um Tribunal.

Conforme a obra de De Plácido e Silva (2009) jurisprudência é um derivado da conjugação dos termos, em latim, *jus* (Direito) e *prudencia* (sabedoria), o que entende-se como a Ciência do Direito vista com sabedoria, ou, simplesmente, o Direito aplicado com sabedoria. Já Oliveira (2006) diz que a jurisprudência pode ser encarada em sentido amplo ou restrito. Em sentido amplo, significa a ciência ou o conhecimento do Direito. Já no sentido restrito, jurisprudência significa a interpretação dada pelos tribunais (*rerum perpetuo similiter iudicatorum auctoritas*).

A jurisprudência não tem força de lei, porém expressa a aplicabilidade da lei, que pode ser alterada de acordo com o momento sócio-econômico em que a sociedade se encontra. Por isso, pode ser utilizada tanto por magistrados quanto advogados para basear suas interpretações da legislação.

Resumidamente, a jurisprudência, possui um importante papel como fonte do Direito, e o seu conteúdo auxilia na interpretação da lei e sua aplicação na solução de um problema jurídico. Jurisprudência é o conjunto uniforme e constante das decisões judiciais sobre casos semelhantes (MONTORO, 2000). É uma ótima fonte de conhecimento explícito da aplicação das leis. Este trabalho contribui para a construção de aplicativos que venham a trabalhar o conhecimento jurídico de forma a auxiliar os operadores do Direito.

¹ Centro Estadual de Educação Tecnológica Paula Souza – CEETEPS – SP. Laboratório de Pesquisa em Ciência de Serviços Email: thiago.ferauche@gmail.com.

² Centro Estadual de Educação Tecnológica Paula Souza – CEETEPS – SP. Laboratório de Pesquisa em Ciência de Serviços Email: madealmeida@gmail.com.

1.1.A Jurisprudência do Tribunal Regional do Trabalho 2ª. Região São Paulo

As decisões de 2ª. Instância do Tribunal do Trabalho da 2ª. Região – São Paulo, são proferidas durante as sessões de julgamento. As ementas são citadas dentro do documento que explicita a decisão tomada em colegiado (Acórdão). A secretaria de Turma transcreve as ementas dentro do Sistema Informatizado, para posterior classificação por parte do Serviço de Gestão de Normas e Jurisprudencial.

Após a classificação, o sistema informatizado gera documentos em formato de hipertexto (HTML) a partir de informações do banco de dados, conforme a Figura 1.

TIPO: RECURSO ORDINÁRIO

DATA DE JULGAMENTO: 16/11/2004

RELATOR(A): RICARDO ARTUR COSTA E TRIGUEIROS

REVISOR(A): CARLOS ROBERTO HUSEK

ACÓRDÃO Nº: [20040643829](#)

PROCESSO Nº: 01152-1998-445-02-00-5 **ANO:** 2004 **TURMA:** 4ª

DATA DE PUBLICAÇÃO: 26/11/2004

PARTES:

RECORRENTE(S):

INSTITUTO NACIONAL DO SEGURO SOCIAL INSS

RECORRIDO(S):

RODRIMAR S/A TRANSP EQUIPS INDS ARM GER
GENILSON ALMEIDA GOIS

EMENTA:

INSS. RECURSO ORDINÁRIO. NÃO CONHECIMENTO. INADEQUAÇÃO, AUSÊNCIA DE INTERESSE E IRREGULARIDADE DA REPRESENTAÇÃO. Recurso do INSS que não se conhece em razão de: (1) inadequação, vez que é notória a impropriedade do recurso ordinário (art. 895, CLT), cabível apenas na fase cognitiva, para atacar decisão terminativa em sede de execução, para a qual o recurso específico é o agravo de petição (art. 897, CLT), sendo inaplicável à espécie o princípio da fungibilidade; (2) ausência de interesse porquanto o valor previdenciário já foi quitado, configurando sanha arrecadatória a pretensão do Instituto de receber o que já lhe foi pago; (3) irregularidade da representação, em vista da subscrição do apelo por advogado particular e não por procurador autárquico.

ÍNDICE:

PREVIDÊNCIA SOCIAL, Recurso do INSS

[Serviço de Jurisprudência e Divulgação](#)

Figura 1: Exemplo de uma ementa retirada do site do TRT da 2ª Região – São Paulo.
(Fonte: <http://www.trtsp.jus.br/Geral/Consulta/Jurisprudencia/Ementas/020040643829.html>, 2010)

O índice é a classificação da jurisprudência. O índice utilizado foi elaborado pelo Desembargador Valentin Carrion e aprimorado, ao longo dos anos, pelo Serviço de Jurisprudência e Divulgação, atualmente chamado de Serviço de Gestão Normativa Jurisprudencial. A partir de dezembro de 2009, o índice passou a trabalhar conjuntamente com a Tabela de Assuntos Processuais da Justiça do Trabalho (CNJ Resolução N° 46, de 18 de dezembro de 2007). A lista completa com todas as categorias utilizadas como índice totaliza 187 categorias, elas são fruto de anos de trabalho, aonde através da tentativa e do erro chegou-se à estrutura atual.

A tarefa de classificação é realizada pelos servidores públicos do Serviço de Gestão Normativa Jurisprudencial. Não é um processo automático e requer conhecimentos específicos no âmbito do Direito. Os servidores públicos deste serviço podem ser identificados como os especialistas do conhecimento jurídico, pois são eles que lêem a ementa, identificam relações na área do Direito, e depois classificam a jurisprudência. Esta classificação é utilizada para organizar e facilitar a busca da jurisprudência.

1.2.Objetivo

Esta pesquisa possui o seguinte objetivo geral: avaliar e analisar os resultados de técnicas de mineração de textos específicas para a classificação de documentos, tendo como objeto de estudo as ementas de 2º. grau que compõe a jurisprudência do Tribunal Regional do Trabalho de São Paulo, verificando a sua eficiência através da validação dos resultados junto a um especialista e comparando com ementas previamente classificadas.

Como objetivos específicos, esta pesquisa exploratória apresenta um método em etapas para realizar a classificação das referidas ementas, de maneira assistida por computador utilizando-se de uma área da Inteligência Artificial conhecida como aprendizado de máquinas supervisionado, onde o programa de computador (algoritmo) aprende com as ementas classificadas no passado, e cria modelos de aprendizado que são utilizados para classificar ementas futuras. Além de discutir a utilização de Inteligência Artificial para auxiliar tarefas puramente humanas da área do Direito, como a classificação da Jurisprudência Trabalhista.

2.Mineração de Textos

A Mineração de Textos (MT) tem como objetivo descobrir informações relevantes através de dados não-estruturados, contidos em formato texto. Uma definição genérica inclui todos os tipos de processamento de texto que tratam de encontrar, organizar e analisar informação (KONCHADY, 2006). A MT é semelhante à Mineração de Dados (MD), porém a diferença encontra-se no tipo de dado a ser minerado, no caso da MD os dados encontram-se armazenados nos chamados Banco de Dados Relacionais, onde as informações estão localizadas em formatos de tabelas com linhas e colunas definidas.

A mineração de textos é uma técnica para a descoberta de conhecimento em textos não-estruturados, o que se aplica obviamente aos textos jurídicos. Existem duas maneiras de analisar o texto não-estruturado: a análise semântica, baseada no significado dos termos no texto; e a análise estatística, baseada na frequência com que os termos aparecem no texto. Estes dois modos podem ser aplicados separados ou em conjunto.

A análise estatística de textos demonstra ser a mais interessante para se aplicar a textos jurídicos, pois os textos empregam uma linguagem técnica com muitos termos em latim. Nesse tipo de análise, a importância dos termos é dada basicamente pelo número de vezes que eles aparecem nos textos. É interessante ressaltar que este tipo de estratégia pode ser conduzido independentemente do idioma (EBECKEN; LOPES; COSTA, 2003).

Indiferente ao tipo de análise, o processo de mineração de texto pode ser dividido em quatro etapas, conforme (GONÇALVES; REZENDE, 2002):

- Coleta de Documentos:** nesta fase, os documentos relacionados com o domínio da aplicação final são coletados.
- Pré-processamento:** consiste de um conjunto de ações realizadas sobre o conjunto de textos obtido na etapa anterior, com o objetivo de prepará-los para a extração de conhecimento.
- Extração de Conhecimento:** utilizam-se alguns algoritmos de aprendizado com o objetivo de extrair, a partir de documentos pré-processados, conhecimento na forma de regras de associação, relações, segmentação, classificação de textos, entre outros.
- Avaliação e Interpretação dos Resultados:** nessa etapa os resultados obtidos são analisados, filtrados e selecionados para que o usuário possa ter um melhor entendimento dos textos coletados. Esse entendimento maior pode auxiliar em algum processo de tomada de decisão.

2.1.A Tarefa de Classificação de Textos

A classificação, em Mineração de Textos, visa a identificar os tópicos principais em um documento e associar este documento a uma ou mais categorias predefinidas (Yang; Pedersen, 1997, *apud* EBECKEN; LOPES; COSTA, 2003).

Conforme Feldman e Sanger (2007), assim como em outras tarefas de inteligência artificial, existem duas principais abordagens para a classificação de textos. A primeira é a abordagem da engenharia do conhecimento (*knowledge engineering*) onde o conhecimento de especialistas sobre as categorias está codificado no sistema, seja declarativamente ou na forma de regras procedimentais de classificação. A outra abordagem é o aprendizado de máquina (*machine learning*) onde geralmente através de um processo indutivo é construído um classificador aprendendo a partir de um conjunto de exemplos pré-classificados. A principal desvantagem da abordagem da engenharia do conhecimento é o que pode ser chamado de “gargalo da aquisição de conhecimento” (*knowledge acquisition*

bottleneck) – a enorme quantidade de trabalhadores altamente qualificados e especialistas no domínio do conhecimento, necessária para manter as regras do conhecimento implementadas no sistema. Portanto, a maioria dos trabalhos recentes sobre classificação está concentrada na abordagem de aprendizado de máquina, que requer apenas um conjunto de instâncias de treinamento manualmente classificadas, o que é bem menos custoso para se produzir.

Conforme Russell e Norving (2004), o campo do aprendizado de máquina geralmente pode ser distinguido em 3 casos: **aprendizado supervisionado**, **não-supervisionado** e **por reforço**. O problema do aprendizado supervisionado envolve aprender uma função a partir de exemplos de suas entradas e saídas. O problema do aprendizado não-supervisionado envolve aprender padrões de entradas sem que haja o fornecimento de valores de saídas especificadas. Por último, o problema do aprendizado por reforço envolve aprender através de um retorno indicativo que um determinado comportamento não é desejável, o que implica um subproblema de aprender como o ambiente funciona.

O aprendizado supervisionado utiliza a inferência indutiva, ou indução. A tarefa da inferência indutiva pura (ou indução) é essa: “Dada uma coleção de exemplos de f , retorne uma função h que se aproxima de f ”. A função h é chamada de hipótese. A razão da dificuldade do aprendizado, do ponto de vista conceitual, é que não é fácil dizer quando uma função h é uma boa aproximação de f . Uma boa hipótese irá generalizar bem, ou seja, irá prever exemplos não vistos anteriormente (RUSSEL; NORVING, 2004).

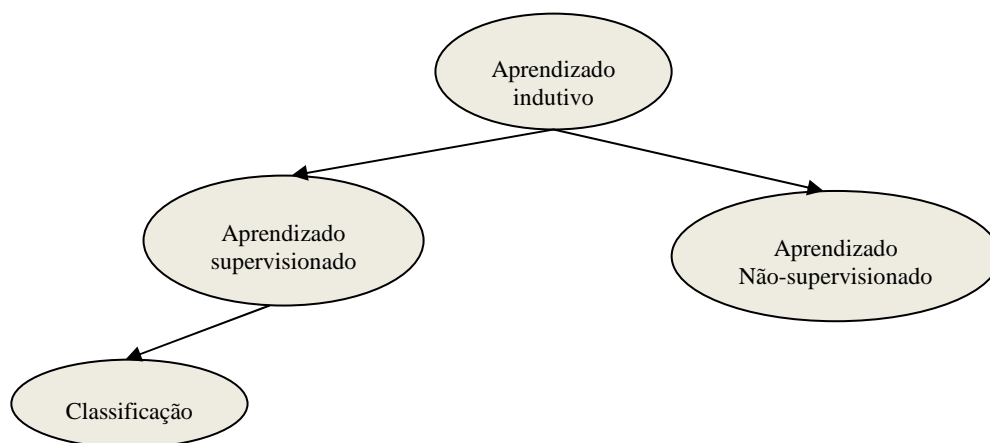


Figura 2: A hierarquia do aprendizado de máquina
Fonte: (MONARD; BARANAUSKAS, 2003)

As hipóteses geradas através da inferência indutiva podem ou não preservar a verdade. Ainda Monard e Baranauskas (2003) lembram que mesmo assim, a inferência indutiva é um dos principais métodos utilizados para derivar conhecimento novo e prever eventos futuros, que foi pelo meio da indução que Arquimedes descobriu a primeira lei da hidrostática e o princípio da alavanca, que Kepler descobriu as leis do movimento planetário, que Darwin descobriu as leis da seleção natural das espécies.

Utilizando o aprendizado supervisionado, através do método da inferência, é possível montar programas (algoritmos) classificadores que possam aprender com documentos previamente classificados, como pode ser visto na Figura 2.

3. Metodologia

A pesquisa foi realizada dividindo o trabalho em 4 fases: a Fase de Extração das Ementas, a Fase de Pré-Processamento, a Fase de Processamento das Ementas e por último a fase de Avaliação dos Resultados, adaptando o processo de mineração de textos anteriormente citado de Gonçalves e Rezende (2002).

Na fase de Extração das Ementas é formada a coleção de documentos. Os documentos são agrupados por suas respectivas categorias previamente classificadas pelos especialistas humanos. Foram utilizadas as ementas de janeiro de 2008 a janeiro de 2011. Com o objetivo de restringir o espaço de exemplos, para esta pesquisa foram escolhidas 10 categorias que possuem no mínimo 500 documentos, distribuídos da seguinte maneira: uma categoria que possui até 1000 documentos, duas categorias que possuem entre 1000 e 2000 documentos, duas categorias que possuem entre 2000 e 3000 documentos, uma categoria que possuem entre 3000 e 4000 documentos, duas categorias que possuem entre 4000 a 5000 documentos e duas categorias que possuem acima de 5000 documentos. Porém não foram selecionados todos os documentos das categorias escolhidas, pelo mesmo motivo de não haver poder computacional disponível. Foram selecionados aleatoriamente 500 documentos de um categoria, confrontados com mais 500 documentos de 5 das 177 categorias restantes, selecionadas também aleatoriamente respeitando a distribuição proporcional da quantidade de documentos real das 187 categorias, como pode ser notado na Tabela 1.

| Categoria | Real³ | Selec⁴ | Outras | Real¹ | Selec² |
|------------------|-------------------------|--------------------------|--|-------------------------|--------------------------|
| EXECUÇÃO | 5370 | 500 | EMBARGOS DECLARATÓRIOS | 4248 | 181 |
| | | | RELAÇÃO DE EMPREGO | 2922 | 125 |
| | | | SINDICATO OU FEDERAÇÃO | 2094 | 89 |
| | | | MANDADO DE SEGURANÇA | 1612 | 69 |
| | | | RESPONSABILIDADE SOLIDÁRIA/SUBSIDIÁRIA | 895 | 39 |
| | | | Total de Outros | 11771 | 503 |
| MÃO-DE-OBRA | 4308 | 500 | PROVA | 3689 | 212 |
| | | | SINDICATO OU FEDERAÇÃO | 2094 | 121 |
| | | | RECURSO | 1297 | 75 |
| | | | RESPONSABILIDADE SOLIDÁRIA/SUBSIDIÁRIA | 895 | 52 |
| | | | PROCESSO | 726 | 42 |
| | | | Total de Outros | 8701 | 502 |
| EMBARGOS | 4248 | 500 | PRESCRIÇÃO | 2834 | 171 |

³ Quantidade real de exemplos presentes na categoria

⁴ Quantidade de exemplos selecionados aleatoriamente

| | | | | |
|---------------|--|---------------------------|-------------|------------|
| DECLARATÓRIOS | | SINDICATO OU FEDERAÇÃO | 2094 | 126 |
| | | CONCILIAÇÃO | 1377 | 83 |
| | | HORAS EXTRAS | 1136 | 69 |
| | | NORMA COLETIVA (EM GERAL) | 885 | 54 |
| | | Total de Outros | 8326 | 503 |

Tabela 1 - Exemplo de 3 categorias utilizadas e a quantidade de exemplos selecionados
Fonte: (Os autores, 2011)

A fase de Pré-Processamento é onde ocorre a preparação dos documentos e extração de um conjunto de características dos mesmos, chamado atributo-valor, onde cada termo é um atributo do vetor, com um valor para cada atributo. Foi utilizado o método *bag of words* com o critério de medida *Term Frequency – Inverse Document Frequency* (tf-idf), e critérios de suavização e normalização quadrática por atributo (coluna), com o objetivo de amenizar o problema da irregularidade de distribuição da quantidade de documentos e de informação presentes nas categorias, capturando assim o máximo das características relevantes dos documentos. A ferramenta PRETEXT II (SOARES *et al*, 2008 *apud* SOARES, 2009) foi utilizada para gerar os 10 vetores atributo-valor, um para cada categoria utilizada neste trabalho.

O Processamento das Ementas é a fase onde os algoritmos classificadores são treinados utilizando o aprendizado supervisionado. Os classificadores utilizados em outras pesquisas que trouxeram melhores resultados foram: SVM, AdaBoost, kNN e métodos de regressão. Naive Bayes apesar de não ter apresentado bons resultados, é muito utilizado em conjunto com outros classificadores. As árvores de decisão foram pouco utilizadas como classificadores, e em alguns resultados foram quase tão bem quanto o SVM (FELDMAN; SANGER, 2007).

Como cada algoritmo classificador possui sua característica própria, sendo seu desempenho dependente das características extraídas dos textos, e dos dados utilizados para treinar o algoritmo, é possível elaborar um método utilizando algoritmos classificadores em conjunto de maneira a formar uma combinação de classificadores. Segundo Dietterich (2000) e Breiman (2000) *apud* Monard e Baranauskas (2003), técnicas de combinação de classificadores tem sido objeto de pesquisas com o intuito de construir um classificador mais preciso pela combinação de vários outros. O resultado dessa combinação é chamado *ensemble*. E ainda, a utilização de *ensembles* tem obtido melhores resultados que a utilização de um único classificador. Portanto, foi montado um comitê classificador, utilizando 3 algoritmos de aprendizado (J4.8, Naive Bayes e SMO) presentes na Ferramenta WEKA - *Waikato Environment for Knowledge Analysis* (WITTEN; FRANK, 2000), para cada uma das 10 categorias selecionadas, combinando seus resultados, sendo que o resultado dos comitês se dá por voto majoritário. Foram usados exemplos de janeiro de 2008 a dezembro de 2010.

Por fim, a fase de Avaliação dos Resultados é onde ocorre a acuidade da predição do comitê classificador, comparando com a classificação realizada anteriormente por um especialista humano. Foram utilizados exemplos de janeiro de 2011 para serem preditos. Foram selecionados aleatoriamente, 5 exemplos, desconhecidos para os modelos aprendidos, de cada uma das categorias usadas em treinamento, totalizando 50 documentos a serem preditos. Os documentos foram pré-processados, porém sem informar a categoria a que pertencem, para que os algoritmos façam a predição de suas categorias. Assim, os

classificadores binários, devidamente treinados, receberão 50 documentos desconhecidos para realizarem a sua predição individual. O resultado da predição de cada algoritmo por categoria, forma o resultado do comitê de classificadores, que utilizou como critério a maior votação entre os algoritmos.

4.Resultados

A taxa de acertos durante os testes do treinamento foram altas, com poucas variações entre os algoritmos, sendo que na maioria das vezes o algoritmo SMO obteve melhores taxas, porém a diferença dele para os outros algoritmos foi muito pouca, o que dificulta afirmar qual o algoritmo que teve melhor índice de acerto, como pode ser visto na Tabela 2.

| Categorias | Acertos durante treinamento (cross-validation) | | |
|--|--|-------------|--------|
| | J4.8 | Naïve Bayes | SMO |
| EXECUÇÃO | 92,30% | 93,90% | 95% |
| PREVIDÊNCIA SOCIAL | 97,30% | 98,30% | 98,20% |
| MÃO-DE-OBRA | 92,91% | 91,91% | 93,21% |
| EMBARGOS DECLARATÓRIOS | 99,20% | 97,70% | 98,50% |
| PROVA | 90,90% | 87,93% | 94,50% |
| RELAÇÃO DE EMPREGO | 93,50% | 94,40% | 97,60% |
| SINDICATO OU FEDERAÇÃO | 97,10% | 97,90% | 97,40% |
| HONORÁRIOS | 97,40% | 97,30% | 97,30% |
| NULIDADE PROCESSUAL | 96,30% | 92,10% | 95,40% |
| RESPONSABILIDADE SOLIDÁRIA/SUBSIDIÁRIA | 98% | 97,70% | 98,40% |

Tabela 2 - Taxa de acertos dos algoritmos durante o treinamento.

Fonte: (Os autores, 2011)

Para analisar a acuidade da predição do comitê classificador, foi realizada a contagem do total de verdadeiros positivos (Tp), documentos classificados como pertencentes à categoria do comitê classificador, e verdadeiros negativos (Tn), documentos classificados como não pertencentes ao comitê classificador, e levando em consideração que foram testados 50 exemplos, sendo 5 exemplos de cada categoria, ou seja, o máximo de verdadeiros positivos por categoria é 5 e o máximo de verdadeiros negativos é 45. Os valores de Tp e Tn de cada categoria foram normalizados e colocados no gráfico apresentado na Figura 3, onde é possível analisar a acuidade do comitê em predizer verdadeiros positivos e verdadeiros negativos.

É possível verificar que o comitê de classificadores conseguiu prever corretamente todos os verdadeiros positivos e negativos da categoria “Previdência Social”, ou seja, possuiu 100% de acertos, reconhecendo todos os 5 documentos da categoria “Previdência Social” como sendo desta categoria, e os outros 45 documentos como não pertencentes a esta categoria. Conseguiu prever todos os verdadeiros positivos de todas as categorias, isso quer dizer que todos os comitês de classificadores conseguiram reconhecer os documentos de suas respectivas categorias, exceto das categorias “Execução” e “Prova”, sendo que a categoria “Execução” teve a menor índice de reconhecimento pelo seu comitê classificador. Porém o comitê classificador desta mesma categoria predito corretamente todos os verdadeiros negativos, ou seja o comitê classificador da categoria “Execução” conseguiu identificar os outros 45 documentos como não sendo da categoria “Execução”. As categorias “Embargos Declaratórios”, “Honorários”, “Mão-de-obra” e “Nulidade Processual” obtiveram a quantidade de verdadeiros negativos muito próximos do total por categoria, ou seja, além de conseguirem reconhecer os todos os documentos de suas categorias, também conseguiram reconhecer quase 100% dos outros documentos como não pertencentes a suas respectivas categorias.

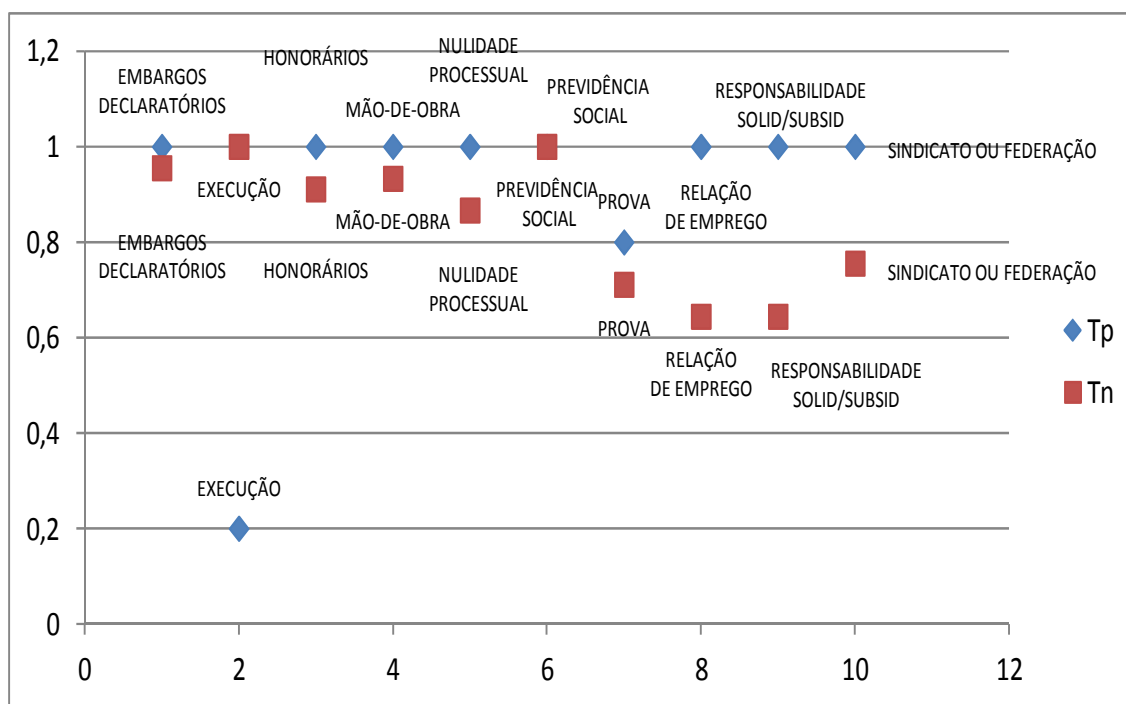


Figura 3: Gráfico normalizado dos Verdadeiros Positivos (Tp), documentos reconhecimentos corretamente como pertencentes à categoria, e os Verdadeiros negativos (Tn), documentos reconhecidos como não pertencentes à categoria
 Fonte: (Os autores, 2011)

Sinteticamente, os resultados dos comitês classificadores apontam dificuldades em prever os documentos das categorias: “Execução”, “Prova”, “Relação de Emprego”, “Responsabilidade Solidária/Subsidiária” e “Sindicato ou Federação”.

Através da tabela de predição do comitê classificador, onde são mostrados os documentos e o resultado individual do comitê classificador para cada documento, foi realizada a análise dos falsos positivos, documentos que o comitê classificador reconheceu

como sendo de uma categoria quando na verdade eram de outra categoria. Notou-se que para alguns comitês classificadores classificavam todos os documentos de uma outra categoria como sendo de sua categoria, como foi o caso dos comitês classificadores das categorias “Prova”, “Relação de Emprego”, “Responsabilidade Solidária/Subsidiária” e “Sindicato ou Federação” e foi constatado que:

- O comitê classificador da categoria “Prova” classificou todos os exemplos da categoria “Nulidade Processual” e “Responsabilidade Solidária/Subsidiária” como falsos positivos, ou seja, como sendo da categoria “Prova”, o que a princípio seria um erro do comitê classificador;
- O comitê classificador da categoria “Relação de Emprego” e “Responsabilidade Solidária/Subsidiária”, ambos classificaram todos os exemplos da categoria “Mão-de-obra” como falsos positivos, ou seja, classificou os documentos da categoria “Mão-de-obra” como sendo das categorias “Relação de Emprego” e “Responsabilidade Solidária/Subsidiária”, que seria um erro do comitê classificador.

A unanimidade do comitê classificador da categoria “Prova” em classificar os documentos das categorias “Nulidade Processual” e “Responsabilidade Solidária/Subsidiária”, fez com que documentos de ambas as categorias fossem submetidas à nova classificação pelo especialista humano. Assim como, a unanimidade dos comitês classificadores das categorias “Relação de Emprego” e “Responsabilidade Solidária/Subsidiária”, em classificar todos os documentos da categoria “Mão-de-obra” como falsos positivos, fez com que documentos da categoria “Mão-de-Obra” fossem relacionados para nova classificação do especialista humano.

Os resultados da reclassificação realizada pelo especialista, no total, divergiram pouco da classificação anterior realizada pelo mesmo. Porém, alguns resultados podem ser destacados:

- Um dos documentos da categoria “Execução”, foi reclassificado pelo especialista humano, como pertencente à outra categoria diferente das 10 selecionados para o experimento. Analisando as predições dos comitês classificadores para este documento, é possível notar que apenas o comitê classificador da categoria “Nulidade Processual” induziu este documento como sendo da categoria “Nulidade Processual”. Todos os outros comitês de classificadores induziram como verdadeiro negativo, exceto o comitê da categoria “Execução” que induziu como falso negativo, ou seja, não identificaram o referido documento como sendo de suas respectivas categorias;
- Um dos documentos da categoria “Mão-de-obra”, foi classificado desta vez pelo especialista humano, como pertencente à categoria “Responsabilidade Solidária/Subsidiária”, que foi o comportamento do comitê classificador da categoria “Responsabilidade Solidária/Subsidiária” para todos os documentos da categoria “Mão-de-obra”;
- Um dos documentos da categoria “Responsabilidade Solidária/Subsidiária”, foi reclassificado pelo especialista como pertencente à categoria “Mão-de-obra”. Analisando o comitê classificador da categoria “Mão-de-obra”, o referido documento foi induzido como pertencente a esta categoria;

•Outro documento da categoria “Responsabilidade Solidária/Subsidiária” foi reclassificado como sendo da categoria “Relação de Emprego”. O comitê classificador da categoria “Relação de Emprego” induziu o documento como sendo pertencente à categoria;

O especialista reportou que os textos inseridos no formulário não são textos de fácil interpretação, e que muitas vezes existe a incerteza em classificar estes textos nas categorias existentes. Informou também que é possível ocorrer a troca de categoria de documentos, principalmente documentos pertencentes às categorias semanticamente mais genéricas como “Mão-de-Obra” e “Relação de Emprego”.

Por tanto, os documentos indicados como erro na predição das categorias “Execução”, “Mão-de-Obra”, “Responsabilidade Solidária/Subsidiária” e “Relação de Emprego”, não necessariamente eram erros, e sim documentos com probabilidades grandes de poderem estar entre duas ou mais categorias, que após uma releitura o especialista humano acabou reclassificando o documento em uma das categorias que os comitês classificadores já haviam indicado.

Isso se dá pelo fato dos textos muitas vezes tratarem de assuntos correlatos, o que é comum na área do Direito, ainda mais em uma área específica como o Direito do Trabalho. Isto faz com que termos semelhantes sejam utilizados com muita frequência em mais de uma categoria, e a abordagem da análise estatística utilizada neste trabalho acaba dificultado a tarefa de distinguir em qual categoria o documento pertence. Por outro lado, essa dificuldade também foi encontrada pelo especialista humano, que obviamente utiliza uma abordagem semântica para distinguir as categorias, diferentemente da abordagem dos algoritmos utilizados nos comitês classificadores. Os algoritmos classificadores poderiam sinalizar ao especialista humano quais os documentos de difícil classificação, para que o mesmo fique atento e faça as releituras necessárias para indicar a categoria mais correta.

5. Conclusão

O processamento aplicando as implementações dos algoritmos J4.8, Naive Bayes e SMO obtiveram excelente desempenho durante o treinamento dos modelos de aprendizagem. Todavia, não é possível afirmar qual o melhor, pois a diferença entre eles foi mínima. Os testes de predição demonstraram que apesar de não apresentarem muita diferença durante o treinamento, durante a predição os resultados obtidos pelos algoritmos foram bem distintos, onde o algoritmo Naive Bayes obteve o pior desempenho e o J4.8 obteve melhor desempenho quanto à acuidade total em todas as categorias, exceto a categoria “Relação de Emprego” onde o SMO obteve o maior desempenho. A formação do comitê classificador por categoria, unindo os resultados dos classificadores binários, não trouxe grande benefício na acuidade total, porém na acuidade por categoria auxiliou na redução da taxa de erro por categoria, fazendo com que um número maior de verdadeiros positivos fosse predito. Desta forma, é possível afirmar que a combinação dos resultados de algoritmos classificadores, forma um classificador mais preciso para esta aplicação. A análise dos falsos positivos preditos pelo comitê classificador permitiu identificar documentos que poderiam estar classificados em mais de uma categoria. A identificação destes documentos e a reclassificação realizada pelo especialista possibilitam concluir que ou existe um problema na ontologia das categorias das ementas, havendo categorias muito próximas que dificulta a classificação até mesmo do especialista humano, ou que os textos possuem características muito generalistas

que dificultam a interpretação semântica do mesmo, o que é comum em textos jurídicos. Para trabalhos futuros, com intuito de se chegar a uma conclusão mais profunda seria interessante utilizar uma abordagem semântica para a análise dos termos encontrados com maior frequência, pois este trabalho apenas utilizou a abordagem estatística. O processo de aplicação de técnicas de Inteligência Artificial na tarefa de classificação de documentos jurisprudenciais se mostrou não só uma ferramenta de automatização de uma tarefa intelectual, mas também uma ferramenta que pode ser utilizada para a descoberta de conhecimento, possibilitando a ajuda na tomada de decisão, por parte de um especialista humano, na escolha de categorias em textos de difícil interpretação semântica.

6. Referências

- EBECKEN, N. F. F.; LOPES, M. C. S.; COSTA, M. C. A. *Mineração de Textos*. In: REZENDE, S. O. *Sistemas Inteligentes: fundamentos e aplicações*. Barueri, SP: Manole, 2003. ISBN 85-204-1683-7.
- FELDMAN, R; SANGER, J. *The Text Mining Handbook*: Cambridge University Press, 2007. ISBN 0-521-83657-3
- GONÇALVES, L. S. M.; REZENDE, S. O. *Categorização em Text Mining*. Disponível em: <http://www.icmc.usp.br/~std-cd/Artigos/Computacao/IC/LeaSilviaMG.pdf>. Acesso em: 05/09/2007
- KONCHADY, M. *Text Mining Application Programming*: Charles River Media, 2006. ISBN 1-58450-460-9.
- MONARD, M. C.; BARANAUSKAS, J. A. *Indução de Regras e Árvores de Decisão*. In: REZENDE, S. O. *Sistemas Inteligentes: fundamentos e aplicações*. Barueri, SP: Manole, 2003. ISBN 85-204-1683-7.
- MONTORO, A. F. *Introdução a ciência do direito*. 25ª Ed. São Paulo: Revista dos Tribunais, 2000.
- OLIVEIRA, J. M. L. L. *Introdução ao Direito*: 2ª ed. Rio de Janeiro: Lumen Juris, 2006. ISBN 8573879327.
- RUSSELL, S.; NORVIG, P. *Inteligência Artificial*: trad. da 2ª ed. Rio de Janeiro: Elsevier, 2004. ISBN 85-352-1177-2.
- SILVA, O. J. P. *Vocabulário Jurídico*: 28ª ed. São Paulo: Forense, 2009. ISBN 9788530927424.
- SOARES, M. V. B. *Aprendizado de máquina parcialmente supervisionado multidescrição para realimentação de relevância em recuperação de informação para a WEB* 2009. 95 f. Dissertação (Mestrado em Ciência de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Paulo, 2009
- WITTEN, I. H.; FRANK E. *Data Mining – Pratical Machine Learning Tools e Techniques with JAVA Implementations*: Morgan Kaufmann, 2000. ISBN 1-55860-552-3.