

# Utilização de Técnicas de Aprendizado de Máquina na Formação de Grupos de Equivalência das Unidades Judiciais de Primeiro Grau de Jurisdição no Poder Judiciário de Santa Catarina

Daniel Moro de Andrade, Anita Maria da Rocha Fernandes

<sup>1</sup>Pós Graduação em Big Data – Universidade do Vale do Itajaí (UNIVALI) – São José – SC – Brasil

danielmoro@gmail.com, anita.fernandes@univali.br

***Abstract.** This article demonstrates the use of unsupervised machine learning techniques applied to the formation of Equivalence Groups of First Degree Judicial Units of Jurisdiction in the Judiciary of Santa Catarina. We analyzed two non-supervised learning algorithms, in this case, k-means and EM. The experiments were performed using the Weka tool and scripts in the Python language (with the Scikit-Learn library). Groups were generated automatically using these techniques and the results obtained could be used and, furthermore, subsidize the decision making in the definition of criteria for the promotion of magistrates.*

***Resumo.** Este artigo demonstra a utilização de técnicas de aprendizado de máquina não supervisionado aplicadas à formação de Grupos de Equivalência das Unidades Judiciais de Primeiro Grau de Jurisdição no Poder Judiciário de Santa Catarina. Foram analisados dois algoritmos de aprendizado não supervisionado, no caso, k-means e EM. Os experimentos foram realizados usando a ferramenta Weka e scripts na linguagem Python (com a biblioteca Scikit-Learn). Foram gerados grupos de forma automática usando estas técnicas e os resultados obtidos poderão ser utilizados e, ainda, subsidiar a tomada de decisão na definição de critérios para a promoção de magistrados.*

## 1. Introdução

Os constantes avanços na área de Tecnologia da Informação têm viabilizado o armazenamento de grande e múltiplas bases de dados. Tecnologias como a internet, ambientes virtuais de aprendizagem e sistemas de informação em geral são alguns exemplos de recursos que têm tornado possíveis a criação e o crescimento de bases de dados de natureza administrativa, governamental e social [Goldschmidt et al. 2015].

O valor dos dados armazenados está tipicamente ligado à capacidade de prover a extração de conhecimento de mais alto nível a partir deles, ou seja, informação que seja útil e que sirva para apoio à tomada de decisão. Ou até mesmo para exploração e melhor entendimento do fenômeno gerador dos dados em questão [Davenport 2017].

A análise de grandes volumes de dados pelo homem é inviável sem o auxílio de ferramentas computacionais apropriadas. Como citado por Grus (2016), vive-se num

mundo soterrado por dados e, sob esses mesmos dados, há respostas para inúmeras questões que ninguém nunca pensou em perguntar e que o uso da tecnologia apropriada pode ajudar a responder.

Com a evolução tecnológica cresceu também o número de alternativas de utilização da tecnologia em diversas áreas. Na área governamental, como no Poder Judiciário Catarinense, a cada dia que passa se busca a adaptação de tecnologias para as necessidades jurisdicionais.

Conforme a Resolução n. 06 [CNJ 2010], devem ser considerados critérios objetivos para aferição do merecimento para promoção de magistrados e acesso aos Tribunais de Segundo Grau. Porém, nota-se ser uma tarefa complexa a comparação entre Magistrados que atuam em Unidade Judiciais com competências (fixação das atribuições de cada um dos órgãos jurisdicionais, isto é, a demarcação dos limites dentro dos quais podem eles exercer a jurisdição) distintas, vista a comparação de desiguais na busca por similaridades. Para tanto, atualmente, é utilizado o conceito de grupos de equivalências. Conforme CGJ (2009), as tabelas de produtividade média por grupo de varas equivalentes, apuradas por período de dois anos e atualizadas anualmente, serão utilizadas para comparação com a produtividade dos magistrados inscritos para a movimentação na carreira. Hoje, no Poder Judiciário de Santa Catarina (PJSC), dentre as 451 Varas distribuídas nas 113 Comarcas do Estado de Santa Catarina, há 63 grupos de equivalências.

Este artigo tem como finalidade, demonstrar a aplicabilidade do Aprendizado de Máquina na formação de Grupos de Equivalências, utilizando os dados referentes à entrada de processos nas varas, agrupados por competências, de forma automatizada, a serem utilizados na promoção dos Magistrados do Poder Judiciário de Santa Catarina, além de fomentar o próprio uso de tais técnicas dentre o corpo técnico de Servidores e Magistrados do PJSC.

A seguir serão apresentados os referenciais teóricos do trabalho, bem como a metodologia utilizada, apresentados os resultados e as conclusões.

## 2. Fundamentação Teórica

O Aprendizado de Máquina pode ser descrito como o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. É uma subárea da Inteligência Artificial (IA), cujo objetivo é desenvolver métodos, técnicas e ferramentas para construir máquinas inteligentes, que se modificam para realizar cada vez melhor sua (s) tarefa (s). “Melhor” nesse sentido pode ser trabalhar com mais eficiência ou precisão, ou ainda de forma a abranger uma classe maior de problemas. Para tanto, essas máquinas devem ser capazes de aprender [Mitchell 1997].

Segundo Gabriel (2017) e Mitchell (1997), dentre outros autores, existem quatro tipos de estilo de Aprendizado de Máquina (do inglês *Machine Learning*). O primeiro é o aprendizado Supervisionado, onde existem dados de entradas com suas respectivas saídas, para serem apresentadas ao algoritmo de aprendizagem utilizado durante o processo de treinamento. O segundo é o aprendizado Não Supervisionado (*free learning*), que é quando não existem exemplos de dados com respostas conhecidas.

Neste caso supõe-se que o conjunto de exemplos não está rotulado e com isto o sistema tenta classificar estes conjuntos em agrupamentos de semelhantes em determinadas classes.

O terceiro estilo é o aprendizado semisupervisionado, que para a resolução de problemas, o modelo precisa aprender as estruturas e organizar os dados, bem como fazer previsões. Neste caso, em específico, uma parte dos dados é conhecida e categorizada, e outra é desconhecida, de forma que o sistema busca novos dados para categorizar. O quarto e último é o aprendizado por reforço, que consiste em mapear situações para ações de modo a maximizar um sinal de recompensa numérico. É baseado na experiência (tentativa e erro), usando psicologia comportamental, construída por observação de resultados de ações [Sanches 2003].

A partir do subsídio teórico supracitado, entende-se que o principal interesse do aprendizado não-supervisionado é desvendar a organização dos padrões existentes nos dados através dos agrupamentos (*clusters*) consistentes. Com isso, é possível descobrir similaridades e diferenças entre os padrões existentes, assim como derivar conclusões úteis a respeito deles. Sendo assim, a próxima seção trata especificamente sobre esse método de aprendizado, com destaque aos algoritmos *k-means* e EM.

## 2.1. Aprendizado Não Supervisionado

No aprendizado não supervisionado, também conhecido como aprendizado por observação e descoberta, a tarefa do algoritmo é agrupar exemplos não rotulados, i.e., exemplos que não possuem o atributo classe especificado. Nesse caso, é possível utilizar algoritmos de aprendizado para descobrir padrões nos dados a partir de alguma caracterização de regularidade, sendo esses padrões denominados clusters [Goldschmidt et al. 2015].

Criar um ou mais clusters consiste em agrupar objetos em conjuntos de dados de modo que objetos pertencentes a um mesmo cluster são mais similares entre si de acordo com alguma medida de similaridade pré-definida, enquanto que objetos pertencentes a clusters diferentes têm uma similaridade menor. O objetivo, portanto, é maximizar a homogeneidade dos objetos dentro de um mesmo cluster enquanto maximiza-se a heterogeneidade entre objetos de clusters diferentes [Sanches 2003].

O processo de *clustering* compara os objetos utilizando o conjunto de atributos que os caracterizam. Exemplos contidos em um mesmo cluster são mais similares, segundo alguma medida de similaridade, do que aqueles contidos em clusters diferentes. O processo de formação dos clusters é geralmente conhecido por *clustering*.

Segundo Brink et al. (2017) e Macedo et al. (2017), as etapas do processo de aprendizagem não supervisionada são a seleção de atributos, a medida de proximidade, o critério de agrupamento, o algoritmo de agrupamento, a verificação dos resultados e a interpretação dos resultados. A próxima seção trata especificamente dos algoritmos de agrupamento.

## 2.2 Algoritmos de Clustering

Nessa seção são descritos dois dos algoritmos de *clustering* mais conhecidos e utilizados pela comunidade: *k-means* e EM (Expectation-Maximization).

O algoritmo *k-means*, conforme pesquisa de Sanches (2003), utiliza a técnica de otimização, e é um dos algoritmos mais frequentemente utilizado. Como entrada, o especialista deve especificar o número  $k$  de partições. Inicialmente, o algoritmo escolhe, aleatoriamente,  $k$  pontos que serão os centros dos clusters iniciais - centróides. O próximo passo é determinar, para cada exemplo do conjunto de dados, o cluster ao qual ele pertence. Isso é feito calculando a distância entre o exemplo e o centro de cada cluster. O exemplo irá pertencer ao cluster do qual ele estiver mais perto do centro. Depois, é calculado um novo centróide para cada cluster, ou seja, os pontos iniciais não são os centros definitivos dos clusters, eles são apenas uma tentativa inicial. O centróide calculado, para cada cluster, passa a ser o novo centro. O processo se repete até que os centros dos clusters se estabilizem, i.e., o mesmo ponto é escolhido como centro durante algumas iterações. Porém, esse algoritmo apresenta alguns problemas. Os centros dos clusters finais nem sempre representam uma solução ótima. Isso porque diferentes configurações de clusters podem ser obtidas a partir de diferentes escolhas para os centros dos clusters iniciais.

O algoritmo EM, segundo Macedo et al. (2017), permite a aprendizagem de parâmetros que regem a distribuição dos dados da amostra com algumas características em falta. É uma ferramenta computacional utilizada para o cálculo do Estimador de Máxima Verossimilhança (EMV) de forma iterativa. Sanches (2003) complementa que o fato de, normalmente, não existirem evidências suficientes sobre os dados de forma a se tomar uma decisão determinística sobre qual exemplo deve pertencer a qual cluster, mostra a necessidade de se especificar a probabilidade dos exemplos de pertencer a um cluster ou outro. O algoritmo EM faz justamente isso.

Feito o embasamento teórico sobre o assunto, tratar-se-á à frente sobre a metodologia utilizada neste trabalho.

### 3. Metodologia

Esta seção tem por objetivo caracterizar os materiais e métodos utilizados para conduzir as atividades deste trabalho. De maneira geral, esta pesquisa seguiu o fluxo de atividades que a literatura preconiza no tocante ao processo de Aprendizagem de Máquina [Brink et al. 2017].

A pesquisa realizada foi de natureza aplicada, descritiva, conduzida sob a forma de estudo de caso. O estudo de caso é uma estratégia de pesquisa que visa ao entendimento da dinâmica presente em um dado ambiente, podendo, assim, ser utilizado para diversos propósitos, como descrever fenômenos, testar teorias ou gerar teorias [Eisenhardt 1989]. De acordo com Barros e Lehfeld (2000), a pesquisa aplicada tem como motivação a necessidade de produzir conhecimento para aplicação de seus resultados, com o objetivo de contribuir para fins práticos, visando à solução mais ou menos imediata do problema encontrado na realidade.

Assim, para a coleta de dados primários, utilizou-se técnicas de KDD (do inglês *knowledge-discovery in databases*). Dentre as muitas definições existentes para KDD, pode ser citado Fayyad et al (1996), que conceitua como sendo o processo, não trivial, de extração de informações implícitas, previamente desconhecidas e potencialmente úteis, a partir dos dados armazenados em um banco de dados. A complexidade (ou não trivialidade) do processo de KDD está na dificuldade em perceber e interpretar

adequadamente inúmeros fatos observáveis durante a realização de processo e na dificuldade em conjugar dinamicamente tais interpretações de forma a decidir que ações devem ser realizadas em cada caso. Fayyad et al (1996) ainda explicita que o processo de KDD, por sua vez, contém uma série de passos, a saber: seleção, pré-processamento e limpeza, transformação, mineração de dados (*data mining*) e interpretação/avaliação. O processo em si possui duas características relevantes: é interativo e iterativo. Interativo, pois o usuário pode intervir e controlar o curso das atividades. Iterativo, por ser uma sequência finita de operações onde o resultado de cada uma é dependente dos resultados das que a precedem.

Descrevendo sucintamente cada fase do processo, tendo como referência ainda os conceitos de Fayyad et al (1996), a fase de seleção dos dados é a primeira no processo de descobrimento de informação. Nesta fase é escolhido o conjunto de dados, pertencente a um domínio, contendo todas as possíveis variáveis. A segunda fase, ou pré-processamento e limpeza dos dados é uma parte crucial no processo, pois a qualidade dos dados vai determinar a eficiência dos algoritmos de mineração. Nesta etapa deverão ser realizadas tarefas que eliminem dados redundantes e inconsistentes, recuperem dados incompletos e avaliem possíveis dados discrepantes ao conjunto (*outliers*). Após serem selecionados, limpos e pré-processados os dados necessitam ser armazenados e formatados adequadamente para que os algoritmos de aprendizado possam ser aplicados.

Todas as etapas do processo de KDD possuem grau elevado de importância para o sucesso deste, pondera Goldschmidt et al. (2015). Entretanto, é a etapa de Mineração de Dados (*data mining*) que recebe o maior destaque na literatura. Conforme Berry et al (1997), *data mining* é a exploração e análise, de forma automática ou semiautomática, de grandes bases de dados com objetivo de descobrir padrões e regras. Por fim, porém não menos importante, a fase de interpretação e avaliação é a fase que deve ser feita em conjunto com um ou mais especialistas no assunto. O conhecimento adquirido através da técnica de data mining deve ser interpretado e avaliado para que o objetivo final seja alcançado.

Para fins deste estudo, a coleta de dados ocorreu na primeira quinzena de dezembro do ano de 2018, sendo que foram extraídos dados da base a partir de primeiro de janeiro do ano de 2015.

O total de dados coletado foi de 3.344.043 registros. Esses registros foram retirados na base de dados do sistema SAJ (Sistema de Automação da Justiça), solução atualmente utilizada pelo PJSC para todo o controle processual. Todos os dados são da Justiça de Primeiro Grau. Dentre as informações coletadas, estão as informações sobre Foro e Vara, Número do Processo, Ano de Entrada, Competência, Classe e Assunto e as Datas de Recebimento e Distribuição.

Tendo em vista o escopo do estudo, que visa ao uso das informações sobre o número de processos que entram na unidade judicial (vara), agrupados por competência, fez-se o agrupamento dos dados. O primeiro agrupamento foi pelo ano de entrada, seguido pela unidade e pela competência. Sobre as competências, estas se referem ao processo em si. Foram levantadas todas as competências únicas de todos processos contidos na base de dados coletada e chegou-se ao número de noventa e um registros únicos.

Após os agrupamentos anteriormente citados, foram sumarizados todos os dados referentes às competências, sendo que cada registro foi transformado em uma coluna. E para cada coluna, o registro correspondia ao total de número de processos (zero quando não havia processos daquela competência naquela unidade), com aquela competência, naquela unidade jurisdicional.

Utilizou-se como ferramenta de extração e tratamento dos dados o software *Pentaho* PDI (do inglês *Pentaho Data Integration*). Como resultado do processo de transformação dos dados, parte do processo de KDD, obteve-se um total de 1.651 linhas armazenadas num arquivo do tipo CSV (do inglês *comma-separated values*, ou Valores Separados por Vírgula), contendo noventa e quatro colunas. Destas, são noventa e uma colunas referentes ao total de processos de cada competência, somadas aos dados referentes aos anos dos processos, total de processos na unidade e nome das unidades jurisdicionais.

A seguir, na seção subsequente, serão apresentados os resultados obtidos, frutos da última fase do processo de KDD, bem como a análise realizada sobre o conjunto de dados.

#### **4. Apresentação e Análise dos Resultados**

Esta seção tem como objetivo apresentação dos dados utilizados nesta pesquisa, bem como descrever a análise dos resultados obtidos.

Importante ressaltar, para fins conceituais, sobre as variáveis do problema, também denominadas atributos. Podem ser classificadas sob dois aspectos distintos: quanto à representação de seus valores (tipo do dado) e quanto à natureza da informação (tipo de variável). De acordo com Goldschmidt et al. (2015), os tipos de dados indicam a forma em que os dados estão armazenados. Os tipos de variáveis expressam a natureza com que a informação deve ser interpretada.

Variáveis quantitativas são as características que podem ser medidas em uma escala quantitativa, ou seja, apresentam valores numéricos que fazem sentido. Podem ser contínuas ou discretas. As discretas, como descrevem Larson e Farber (2016), possuem características mensuráveis que podem assumir apenas um número finito ou infinito contável de valores e, assim, somente fazem sentido valores inteiros. As contínuas, por sua vez, possuem características mensuráveis que assumem valores em uma escala contínua (na reta real), para as quais valores fracionais fazem sentido. Já as variáveis qualitativas ou categóricas são as características que não possuem valores quantitativos, mas, ao contrário, são definidas por várias categorias, ou seja, representam uma classificação dos indivíduos. Podem ser nominais ou ordinais. As nominais não apresentam ordenação dentre as categorias, diferentemente das ordinais, nas quais existe uma ordenação entre as categorias.

Dos noventa e quatro atributos utilizados na pesquisa, apenas a variável denominada “Unidade” é nominal, sendo que se trata do nome da Unidade Judicial (composta por Nome do Foro, Nome da Vara e Ano). As outras todas são do tipo discretas, sendo uma dedicada ao Ano (ano referente à entrada do processo numa unidade judicial), quantitativo (somatório) total dos processos que entraram na unidade

judicial e quantitativo (somatório) dos processos que entraram na unidade judicial, desta vez por cada competência.

Durante a realização dos experimentos, utilizou-se tanto a ferramenta *Weka* (*Waikato Environment for Knowledge Analysis*, desenvolvida pela Universidade de Waikato, Nova Zelândia), por já apresentar implementados todos os algoritmos avaliados no presente trabalho, bem como *scripts* em linguagem *python*, usando a biblioteca *Scikit-Learn*. Segundo Géron (2017), o agrupamento (*clustering*) de dados é uma tarefa extremamente importante se tratando de Análise de Dados e Aprendizado de Máquina e a vantagem de se utilizar a biblioteca *Scikit-Learn* é que não é preciso, de fato, o desenvolvimento (codificação) dos algoritmos (*k-means* e EM, por exemplo), pois já estão implementados. Inclusive de maneira performática.

O algoritmo *k-means* exige como parâmetro de entrada o número desejado de clusters. Utilizou-se o método *Elbow* para esta definição e chegou-se ao número de dez agrupamentos. O método *Elbow*, de acordo com Brinks et al. (2017) calcula o chamado SSE (do inglês, *sum of squared error*). O SSE é a soma da distância ao quadrado entre cada membro do cluster e seu centroide. Já o algoritmo EM chegou, de maneira autônoma, a semelhantes dez agrupamentos. Ambos os resultados foram obtidos tanto na ferramenta *Weka*, quanto no uso de *scripts python*.

Em termos de conteúdo dos agrupamentos, os seguintes resultados foram obtidos, levando em consideração o resultado do algoritmo EM: no Cluster 0, estavam contidos os Juizados Especiais e CEJUSC (Centros Judiciários de Solução de Conflitos e Cidadania). No Cluster de número 1, as Varas Criminais e Execução Penal. No Cluster 2, por sua vez, Varas Cíveis, Execução Fiscal e Fazenda Pública. Quando o Cluster 3 foi analisado, lá estavam algumas das Varas de Fazenda Pública e algumas Varas Cíveis. No Cluster 4, apenas varas com competência de Direito Bancário e Plantões Judiciais.

Nos agrupamentos faltantes, o Cluster 5 continha varas da Família, Infância e Especial Cível, o Cluster 6, por sua vez, Cooperação e Recuperações Judiciais e Falências e Concordatas. Já no Cluster 7, foi formado em sua maioria por Varas Únicas. Os últimos dois, número 8 e número 9, respectivamente, continham Varas Cíveis e Varas Cíveis e Família.

Comparando os resultados entre os algoritmos, apesar de haver suaves diferenças nas varas contidas em cada agrupamento, o *k-means* acabou por juntar (ou mesclar) os clusters número 2 e 3, bem como agrupar parte do cluster 9 com parte do cluster 3.

Apesar de alguns agrupamentos conterem varas semelhantes e bem próximo do agrupamento manual atualmente utilizado, outros clusters apresentaram semelhanças nunca antes vistas. São informações que a utilização de tecnologia de análise de dados e aprendizagem de máquina podem proporcionar e que corrobora com o objetivo do presente estudo.

Percebeu-se ainda que, no decorrer do período analisado, várias varas trocaram de agrupamento, migrando entre os clusters. Tal efeito é explicado pelas mudanças de atribuição de competências nas varas (via de regra, por resolução específica), não presente no escopo de estudo deste artigo. Outro fenômeno analisado foi a constante mudança de tipo de competência nos processos. Isso ocasionou, por diversas vezes,

alterações nas análises feitas sobre os dados. Tais mudanças, por exemplo, se dão muitas vezes por erro no cadastro do processo do sistema ou por especificação da competência.

Demonstrados os resultados obtidos, bem como os métodos utilizados para se alcançar o fruto do trabalho, a próxima seção é destinada para apresentação dos aspectos finais do estudo.

## 5. Conclusão

O trabalho atingiu seus objetivos, uma vez que demonstrou a aplicabilidade do Aprendizado de Máquina na formação de Grupos de Equivalências, utilizando os dados referentes à entrada de processos nas varas, agrupados por competências, de forma automatizada, a serem utilizados na promoção dos Magistrados do Poder Judiciário de Santa Catarina. Tem-se, assim, uma grande contribuição do artigo como sendo a demonstração da utilidade das técnicas de Aprendizagem de Máquina no estudo da criação de Grupos de Equivalências, servindo de importante ferramenta para a percepção e tomada de decisões estratégicas no que se refere à promoção na carreira da Magistratura.

Quanto ao fomento do uso de técnicas de Aprendizado de Máquina dentre o corpo técnico de Servidores e Magistrados do PJSC, nota-se ser uma primeira iniciativa que tende a render e trazer ganhos num futuro de curto e médio prazo.

De outro modo, há que se reconhecer que o presente estudo não se encerra aqui, tornando possível a elaboração de futuras pesquisas sobre o tema em foco. Dentre as várias vertentes de pesquisa, por exemplo, está a utilização de outras variáveis contidas na base do PJSC. Sejam elas relacionadas à Comarca ou Vara, como a Entrância (Inicial, Intermediária, Final e Especial), sejam relacionadas às fases do processo em si, como tempo de duração de cada fase do processo judicial e medição do esforço dispendido na análise e julgamento, como dados referentes às pessoas envolvidas, citando-se o número de servidores lotados na Vara e análise do perfil do magistrado.

Outra vertente de pesquisa é o uso da Jurimetria. Apesar de ser um campo relativamente novo no estudo acadêmico, a Jurimetria é uma mistura de direito com estatística. Segundo Barbosa (2013), a partir da organização estatística das decisões judiciais (elemento qualitativo), e também dos temas tratados nos processos (elemento quantitativo) é possível obter parâmetros de tomada de decisão do Poder Judiciário e compará-los com outros indicadores sociais existentes, permitindo a análise de correlação entre eles. A metodologia de pesquisa da Jurimetria pode ser aplicada a qualquer levantamento estatístico nos três poderes da República, contribuindo para a formação de um novo método de pesquisa no Direito. Sendo assim, seu uso se mostra também possível no problema estudado no presente artigo.

Ainda no campo do enriquecimento da base dados com outras variáveis, cita-se o uso de variáveis exógenas do PJSC. Trazem-se à baila como exemplos os dados geopolíticos, bem como indicadores sociais. Dados referentes à atuação dos advogados ou escritórios de advocacia nas regiões pesquisadas podem ser exemplos destas variáveis.

No presente trabalho, o tema sazonalidade dos dados não foi abordado, o que o torna objeto de estudos futuros. Segundo Larson e Farber (2016), uma série temporal é

sazonal quando os fenômenos que ocorrem durante o tempo se repetem a cada período idêntico de tempo. Por serem dados referentes a entrada processual, agrupados por ano, infere-se ser salutar um estudo futuro que trate da possível correlação do fenômeno nos dados utilizados na presente pesquisa. Atualmente, para formação dos agrupamentos de forma manual é utilizada uma janela de dois anos (escolha por parte da equipe de forma empírica). No estudo, além dos dois anos somaram-se ainda os dez meses do corrente ano.

No que se refere aos algoritmos de aprendizagem de máquina, a utilização não deve ser restrita apenas aos estudados neste trabalho. Seja na utilização de outros algoritmos que permitam o agrupamento (*clustering*), seja na aplicação de outros estilos de Aprendizado de Máquina.

## Referências Bibliográficas

- Barbosa, C. M. (2013). Jurimetria: Buscando um Referencial Teórico. Revista Intellectus, Ano IX n°. 24
- Berry, M. J. A., Linoff, G. (1997). Data Mining Techniques: For Marketing, Sales, and Customer Support. Wiley Computer Publishing.
- Brink, H., Richards, J. W., and Fetherolf, M. (2017). Real-World Machine Learning. Manning Publications, Estados Unidos.
- CGJ. (2009). Provimento n. 14/2009: Adota nova sistemática para o cálculo da produtividade dos magistrados do primeiro grau de jurisdição.
- CNJ. (2010). Resolução n. 106 de 06 de abril de 2010: Dispõe sobre os critérios objetivos para aferição do merecimento para promoção de magistrados e acesso aos Tribunais de 2º grau.
- Davenport, T. H. (2017) Big Data no Trabalho: Derrubando Mitos e Descobrimo Oportunidades. Alta Books. 1ª Edição.
- Eisenhardt, K. (1989) Building theories from case study research. Academy of Management Review, v.14, n.4.
- Fayyad, U., Piatetsky-Shapiro, G.; Smyth, P. (1996) From data mining to knowledge discovery: An overview in Advances in Knowledge Discovery and Data Mining. AAAI Press/The MIT Press.
- Gabriel, M. (2017) Você, Eu e os Robôs: Pequeno Manual do Mundo Digital. Atlas. 1ª edição.
- Géron, A. (2017) Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media, Inc, 1ª edição.
- Goldschmidt, R., Passos, E. e Bezerra, E. (2015) Data Mining: Conceitos, Técnicas, Algoritmos, Orientações e Aplicações. Campus, 2ª edição.
- Grus, J. (2016) Data Science do Zero: Primeiras Regras com o Python. Alta Books. 1ª Edição.

- Larson, R e Farber, B. (2016) Estatística Aplicada. Pearson. 6ª edição.
- Mayer-Schonberger, V. e Cukier, K. (2013) Big Data: Como Extrair Volume, Variedade, Velocidade e Valor da Avalanche de Informação Cotidiana. Elsevier. 1ª edição.
- Macedo, H., Torres, E., Chella M. e Matos L. (2017) Otimização do Algoritmo Expectation Maximization para o Modelo de Misturas Gaussianas Usando Cuda. Revista de Sistemas e Computação, Salvador, v. 7, n. 1, p. 15-20, jan./jun.
- Mitchell, T. M. (1997). Machine Learning.
- Rêgo, B. L (2013) Gestão e Governança de Dados: Promovendo dados como ativo de valor nas empresas. Brasport. 1ª edição.
- Sanches, M. K. (2003) Aprendizado de máquina semisupervisionado: proposta de um algoritmo para rotular exemplos a partir de poucos exemplos rotulados. USP – São Carlos.