



ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Aprimorando a Eficiência na Fabricação de Televisores: Análise de Dados com Weka

Andrei da Silva Campos

Pós-Graduação em Processos Produtivos Inteligentes - CESP

Lucas Farias da Cruz

Pós-Graduação em Processos Produtivos Inteligentes - CESP

Manoel Ferreira Neto

Pós-Graduação em Processos Produtivos Inteligentes – CESP

Dr. Sandro Breval Santiago

Universidade Federal do Amazonas - UFAM

Resumo: A análise de dados é essencial para aprimorar processos na indústria eletroeletrônica, especialmente na produção de televisores, onde eficiência e qualidade são determinantes para a competitividade. Este artigo examina as pontuações de desempenho extraídas de uma tabela que reúne indicadores de uma fábrica, utilizando a ferramenta Weka para sua análise. A questão central se refere à variabilidade nas pontuações, que indica possíveis ineficiências nos processos produtivos. O objetivo deste estudo é identificar essas ineficiências e sugerir estratégias de melhoria para elevar a eficiência operacional e a qualidade do produto final. A metodologia utilizada incluiu a coleta de dados quantitativos e a aplicação de algoritmos de mineração de dados disponíveis no Weka, facilitando a identificação de padrões e correlações entre os indicadores. Os resultados revelam que, embora algumas áreas apresentem desempenhos adequados, existem variações significativas que afetam a produtividade geral. A análise indica que intervenções específicas nas áreas identificadas podem resultar em melhorias consideráveis na eficiência e na satisfação do cliente. Este estudo oferece insights importantes sobre as dinâmicas operacionais da fábrica e serve como base para futuras ações de otimização na produção de televisores.

Palavras-chave: Análise de dados, indicadores, eficiência e qualidade.

Improving Efficiency in Television Manufacturing: Data Analysis with Weka

Abstract: Data analysis is essential for improving processes in the electronics industry, especially in the production of televisions, where efficiency and quality are key to competitiveness. This article examines the performance scores extracted from a table that brings together a factory's indicators, using the Weka tool to analyze them. The central issue is the variability in scores, which indicates possible inefficiencies in production processes. The aim of this study is to identify these inefficiencies and suggest improvement strategies to increase operational efficiency and the quality of the end product. The methodology used included the collection of quantitative data and the application of data mining algorithms available on Weka, facilitating the identification of patterns and correlations between indicators. The results show that although some areas perform adequately, there are significant variations that affect overall productivity. The analysis indicates that specific interventions in the areas identified can result in considerable improvements in efficiency and customer

satisfaction. This study offers important insights into the plant's operational dynamics and serves as a basis for future optimization actions in TV production.

Keywords: Data analysis, indicators, efficiency, quality.

1. Introdução

A indústria de eletrônicos enfrenta desafios contínuos, incluindo a necessidade de diminuir custos, elevar a qualidade dos produtos e acelerar o processo de produção. A eficiência do processo de produção pode ser melhorada por meio da análise de dados, que possibilita a identificação de gargalos e oportunidades de melhoria. Essa análise também pode ser útil para detectar falhas recorrentes, otimizar a utilização de recursos e prever futuras demandas. A análise de dados tem se tornado uma prática cada vez mais importante em várias áreas, permitindo que decisões sejam tomadas com base em informações precisas e organizadas.

As organizações produzem uma grande quantidade de dados e, devido a isso, muitas vezes não conseguem processá-los ou interpretá-los, o que resulta na falta de respostas rápidas para a tomada de decisões (TURBAN; VOLONINO, 2013). Devido ao grande volume de dados, a extração dessas informações não é uma tarefa simples. Isso gera uma demanda significativa por teorias e ferramentas que ajudem os analistas na extração e análise dos dados. No âmbito da avaliação de desempenho dos colaboradores, a aplicação de técnicas de machine learning e análise preditiva pode aprimorar processos como promoções, demissões e treinamentos, oferecendo insights fundamentados em dados históricos.

No contexto da mineração de dados e aprendizado de máquina, a ferramenta Weka (Hall et al. 2009) proporciona recursos importantes para esse tipo de análise. Amplamente utilizada, a Weka permite o processamento de conjuntos de dados em diversos formatos, como o Arquivo de Relacionamento de Atributos (ARFF). O formato ARFF é uma representação textual de dados comumente utilizada em experimentos de aprendizado de máquina, que inclui atributos, instâncias e rótulos vinculados a classes.

Neste caso, a base de dados inclui registros sobre o desempenho dos funcionários, em que cada variável representa uma característica do colaborador, enquanto as variáveis de qualidade rotulam as instâncias com base nas notas atribuídas a cada funcionário. Essas notas refletem, por exemplo, o nível de produtividade, a colaboração em equipe e outras métricas importantes para a avaliação de desempenho.

Por meio da aplicação de algoritmos de classificação ou regressão na ferramenta Weka, é possível explorar a relação entre as variáveis e a qualidade do funcionário, identificando padrões e gerando previsões valiosas para a gestão de recursos humanos. Pesquisas anteriores mostram que a utilização de modelos preditivos em contextos de avaliação de desempenho pode não apenas aumentar a eficiência do processo de

avaliação, mas também minimizar potenciais vieses subjetivos que podem influenciar as decisões administrativas (J. Smith et al., 2020; Oliveira & Souza, 2021).

Assim, este estudo visa explorar uma base de dados estruturada no formato ARFF, utilizando a ferramenta Weka para analisar as variáveis que influenciam o desempenho dos funcionários. O objetivo é identificar padrões que possam ser aplicados para otimizar a avaliação da qualidade no ambiente organizacional.

2. Referencial Teórico

Nesta seção, apresentaremos as bases teóricas que sustentam a estrutura deste trabalho. A revisão da literatura abrangerá conceitos essenciais de mineração de dados, abordagens de aprendizado de máquina e métodos de gestão da produção, que são fundamentais para entender como esses aspectos se interconectam e influenciam a eficiência operacional.

2.1 Machine Learning

O Machine Learning possibilita a análise preditiva dos dados de produção. Os algoritmos de aprendizado de máquina são capazes de reconhecer padrões e tendências nos dados históricos e atuais, antecipando possíveis falhas ou gargalos antes que se manifestem. Essa abordagem permite a manutenção preditiva, diminuindo o tempo de inatividade e elevando a eficiência. O ML pode ser definido como a criação de técnicas computacionais voltadas para o aprendizado, além da construção de sistemas que conseguem adquirir conhecimento de maneira automática (MITCHELL et al., 2006).

2.2 Análise Preditiva

A Análise Preditiva é uma área da mineração de dados que auxilia na previsão de tendências e na estimativa das probabilidades de ocorrência de eventos. A crescente demanda por essa capacidade de previsão surgiu da insatisfação com os sistemas de BI (Business Intelligence), que apenas permitiam aos executivos entender o que já havia acontecido, enquanto eles buscavam ferramentas que pudessem prever o que estava por vir e a direção do seu negócio (MONK, 2013, p. 438).

2.3 Análise de Dados ou Data Analysis

A Análise de Dados, também conhecida como Data Analysis, diz respeito ao processo de examinar, limpar e modelar dados com a finalidade de identificar informações valiosas, auxiliar na tomada de decisões e validar hipóteses. Esse processo abrange uma variedade de técnicas e ferramentas que possibilitam a conversão de dados brutos em

insights significativos. Conforme afirmam Hand, Mannila e Smyth (2001), a análise de dados é essencial para compreender padrões e tendências que podem influenciar decisões estratégicas em várias áreas.

2.4 Mineração de Dados

Data Mining é uma técnica de análise de informações em bancos de dados que busca identificar padrões ocultos nos dados, os quais podem ser utilizados para prever comportamentos futuros (TURBAN, 2009). Essa prática envolve a seleção, exploração e modelagem de grandes volumes de dados para descobrir relações e padrões desconhecidos ou empíricos, com o objetivo de gerar resultados consistentes e úteis a partir de um banco de dados (GIUDICI, 2003).

2.5 Arquivo de Relacionamento de Atributos (ARFF)

ARFF (Attribute-Relation File Format) é um tipo de arquivo empregado na representação de conjuntos de dados em aprendizado de máquina, particularmente em plataformas como a Weka. Esse formato consiste em uma descrição textual que abrange detalhes sobre os atributos dos dados e as instâncias, facilitando a leitura e a manipulação dos dados para análise. De acordo com Witten e Frank (2005), o formato ARFF é frequentemente utilizado em experimentos de aprendizado de máquina por sua simplicidade e eficiência.

2.6 Weka

A suíte Weka (Waikato Environment for Knowledge Analysis) consiste em um conjunto de implementações de algoritmos para diversas técnicas de Mineração de Dados (UNIVERSITY OF WAIKATO, 2010). É uma ferramenta de software de mineração de dados amplamente utilizada para análise de dados e aprendizado de máquina. Ela oferece uma coleção de algoritmos para tarefas como classificação, regressão, clustering e seleção de atributos, além de suporte para visualização de dados (Hall et al. 2009).

3. Metodologia

Nesta seção, serão detalhados o banco de dados utilizado, os métodos de pré-processamento aplicados, as ferramentas de desenvolvimento, os sensores utilizados e a arquitetura geral do sistema.

3.1 Configuração dos Equipamentos para Desenvolvimento

Para o desenvolvimento do projeto, utilizou-se um computador para executar todas as fases, incluindo coleta de dados, construção das bases, pré-processamento,

treinamento dos modelos e testes de desempenho. Foi utilizado o notebook Lenovo Ideapad 320 como ambiente de desenvolvimento. A ferramenta de mineração de dados WEKA (Waikato Environment for Knowledge Analysis) desempenha um papel central na manipulação e análise dos dados, facilitando o processo de modelagem e treinamento por meio de sua interface gráfica e recursos de processamento de dados. Essa escolha se deu pelo fato de o WEKA oferecer uma ampla gama de algoritmos de aprendizado de máquina, além de ser amplamente utilizado para análise de dados, principalmente em contextos acadêmicos e de pesquisa, devido à sua robustez e versatilidade.

3.2 Base de Dados

A base de dados foi obtida por meio da coleta de sinais digitais gerados por sensores de pressão posicionados em locais estratégicos, visando monitorar o desempenho de funcionários em uma linha de produção. Os dados foram coletados em intervalos controlados de 15 minutos, proporcionando uma visão detalhada e contínua das atividades desempenhadas durante esse período.

Os dados foram organizados em quatro situações principais, com cada situação sendo representada por uma letra, a fim de facilitar a análise e o processamento. As classificações de desempenho foram distribuídas de acordo com as seguintes situações:

Tabela 1: Rótulo da Base de

Situação	Classificação
A	Ruim
B	Atenção
C	Regular
D	Ótimo

Dados

Fonte: dados coletados pelos autores

Para a categorização dos dados, foram realizadas análises detalhadas do desempenho do funcionário da fábrica, considerando aspectos como variação da pressão registrada e o tempo de duração de cada ação. Essas classificações foram definidas a partir de critérios de desempenho específicos, com o objetivo de auxiliar na identificação de padrões de comportamento dos funcionários ao longo do período de coleta. A situação "Ruim" reflete um desempenho abaixo do esperado, indicando a necessidade de melhorias e ajustes no processo. A situação "Atenção" identifica condições intermediárias, que sugerem a necessidade de observação e ajustes pontuais. A situação "Regular" representa um desempenho satisfatório, mas ainda com possibilidades de otimização. Por fim, a situação "Ótimo" reflete o melhor cenário, indicando uma performance eficaz e alinhada aos padrões esperados.

Durante o desenvolvimento dos modelos de classificação, o pré-processamento foi fundamental para a adequação da base de dados, eliminando ruídos e organizando as informações de forma estruturada, possibilitando um aprendizado mais eficiente. O pré-processamento incluiu a normalização dos dados, a remoção de outliers e o ajuste dos dados coletados para uma análise mais precisa, facilitando o desempenho do classificador ao identificar padrões específicos associados a cada situação de desempenho.

Além disso, o uso de filtros permitiu refinar a base de dados para que informações irrelevantes ou com baixo ganho de informação fossem omitidas, melhorando assim a eficácia dos modelos. A utilização de algoritmos de validação cruzada e percentagem split com diferentes divisões (50%, 70% e 80% para treinamento) ajudou a avaliar o comportamento dos classificadores e identificar a melhor abordagem para o aprendizado do modelo. Esses processos, juntos, contribuíram para uma análise robusta dos dados, tornando a base de dados adequada para treinar algoritmos que possam futuramente auxiliar na previsão e monitoramento do desempenho dos funcionários da fábrica, buscando otimizar operações e melhorar continuamente o ambiente de trabalho.

4. Resultados

4.1 Configuração dos Experimentos

Os experimentos foram configurados de duas maneiras: inicialmente, adotou-se a abordagem de dividir a base de dados em conjuntos de treinamento e de teste (Percentagem Split), alocando 70% dos dados para o treinamento e 30% para os testes, conforme descrito por Hall et al. (2009). Em seguida, repetiram-se os experimentos utilizando a técnica de validação cruzada (HALL et al., 2009).

A abordagem de Percentagem Split consiste em separar a base de dados em subconjuntos, onde uma fração pré-definida é destinada ao treinamento, buscando aprimorar a capacidade do modelo de reconhecer padrões e melhorar os resultados estatísticos. Isso permite realizar comparações entre diferentes versões de treinamento da base de dados (HALL et al., 2009).

Na validação cruzada, executam-se várias repetições, nas quais a base de dados é dividida em i iterações de subconjuntos chamados "folds". Cada fold serve como pares de treinamento e teste alternados, e o número de folds pode influenciar nos resultados, devendo ser ajustado para encontrar a melhor performance possível (HALL et al., 2009).

4.2 Base de Dados e Ferramenta de Mineração

A base de dados foi gerada a partir da captura de sinais digitais de sensores de pressão em situações de movimento humano. Os testes foram realizados em um ambiente

real, resultando em uma precisão de 63,16% com um total de 684 dados coletados. Utilizou-se a ferramenta de mineração de dados WEKA nesta fase para auxiliar na construção do modelo de árvore de decisão, que seria aplicado na camada de decisão da arquitetura. A Figura 1 exibe a estrutura dos dados em um arquivo de texto com a extensão “.arff”, que a ferramenta de mineração utiliza para a extração de características.

Figura 1 Parte da base de dados preparada para os experimentos

```
@relation produtos_e_servicos

@attribute customizacao numeric
@attribute valores_digitais numeric
@attribute orientacao_a_servico numeric
@attribute analise_e_tratamento_de_dados numeric
@attribute fontes_receitas numeric
@attribute situation {'ruim', 'atencao', 'regular', 'otimo'}


@data

1,1,1,2,1, 'ruim'
3,3,3,4,2, 'regular'
1,1,3,2,2, 'ruim'
1,2,2,1,1, 'ruim'
4,3,3,3,4, 'regular'
3,4,4,4,4, 'regular'
2,4,2,2,2, 'atencao'
3,2,2,1,1, 'ruim'
1,4,2,3,1, 'atencao'
1,3,2,3,2, 'atencao'
2,2,2,2,2, 'atencao'
2.3.2.2.2, 'atencao'
```

Fonte: dados coletados pelos autores

O arquivo de dados é organizado com anotações específicas, onde o símbolo “@” marca o início da declaração de atributos. Na linha 6, o atributo "situation" (situação) define as categorias pré-classificadas, tais como 'ruim', 'atencao', 'regular' e 'otimo'. A partir da anotação @data, na linha 8, cada linha subsequente representa uma instância, permitindo ao classificador treinar e gerar os modelos de árvore de decisão e regras. Por exemplo, a linha 10 ajuda o algoritmo a identificar corretamente a classificação do desempenho do funcionário.


Figura 2 Interface Gráfica da ferramenta de mineração de dados



Fonte: dados coletados pelos autores.

Na Figura 2, observa-se que a ferramenta WEKA realiza a leitura do dataset e, em seguida, carrega as estatísticas principais, como a distribuição dos dados, a contagem de instâncias e o peso dos atributos, elementos essenciais para análise de desempenho do classificador. A Figura 3 reflete esse contexto ao ilustrar a configuração do conjunto de dados com seus atributos e distribuições específicas, facilitando a visualização das características e do comportamento dos dados. Um aumento no tamanho da amostra poderia contribuir para uma precisão mais elevada, permitindo ao classificador captar padrões mais robustos e, assim, melhorar a qualidade das previsões.

Figura 3 Arquitetura da aplicação




Fonte: dados coletados pelos autores

4.3 Execução dos Experimentos

Nos experimentos iniciais, foram realizados testes com quatro classificadores usando a mesma base de dados, composta por 684 dados sem aplicação de filtros ou ajustes. Foram utilizados os algoritmos de divisão de dados Percentagem Split com proporções de 50%, 70% e 80% para treinamento, além da abordagem de validação cruzada (Cross-Validation) com 5 folds. O melhor desempenho foi obtido ao usar 80% dos dados para treinamento e 20% para testes. As avaliações completas desses experimentos estão detalhadas nas subseções a seguir.

Antes de iniciarmos as avaliações, é importante destacar que a ferramenta de mineração fornece informações essenciais para a análise de desempenho dos classificadores, incluindo Acurácia, Precisão, Recall e F1 Score, como exemplificado na Figura 4 a seguir.

Figura 4 Imagem Weka



Fonte: dados coletados pelos autores

4.4 Métricas de Qualidade

A matriz de confusão é representada por uma tabela de contingência, onde as linhas indicam os valores previstos e as colunas indicam os valores verdadeiros observados. A acurácia (ACC), Precisão, verdadeiro positivo (ou Recall), e verdadeiro negativo (VPN) são calculados conforme as equações (1), (2), (3) e (4), conforme descrito por Powers (2011) e Fawcett (2006).

$$Acurácia = \frac{Verdadeiros\ Positivos\ (TP) + Verdadeiros\ Negativos\ (VN)}{Total} \quad (1)$$

$$Precisão = \frac{Verdadeiros\ Positivos\ (TP)}{Verdadeiros\ Positivos\ (TP) + Falsos\ Positivos\ (FP)} \quad (2)$$

$$Recall = \frac{Verdadeiros\ Positivos\ (TP)}{Verdadeiros\ Positivos\ (TP) + Falsos\ Negativos\ (FN)} \quad (3)$$

$$F1 = \frac{2 * precisão * recall}{precisão + recall} \quad (4)$$

4.5 Treino e Validação

Para o treino e validação do modelo, foram utilizados três algoritmos de classificação em duas configurações distintas. Na primeira, todos os atributos coletados foram incluídos, resultando em uma precisão de 100%, o que gerou um cenário de overfitting. Esse comportamento se deu porque a base de dados incluía apenas exemplos pré-definidos para cada situação de classificação, sem dados adicionais que

representassem variações ou exceções. Na segunda configuração, ajustamos a base de dados, introduzindo contraexemplos para cada situação, o que trouxe resultados mais realistas e satisfatórios, alcançando uma precisão de 94,8% com o algoritmo RandomTree. Esse percentual alto reflete uma aproximação bastante precisa dos resultados reais, o que possibilita uma análise consistente do desempenho do funcionário da fábrica.

Os algoritmos testados com a ferramenta WEKA incluíram RandomTree, J48, RepTree e NaiveBayes. Para avaliar os modelos, utilizou-se validação cruzada com 5 folds, onde 4 folds eram dedicados ao treinamento e 1 fold aos testes, permitindo assim uma análise equilibrada das porcentagens de acerto de cada algoritmo. Os resultados das precisões obtidas estão apresentados na Tabela 2.


Tabela 2 Porcentagem Algoritmos

Algoritmo	Porcentagem (%)
RandomTree	94.8
J48	93.22
RepTree	93.22
NaiveBayes	68.71

Fonte: Dados coletados pelos autores.

O algoritmo RandomTree, com uma precisão superior aos demais, foi selecionado como o mais indicado para a aplicação devido à sua habilidade de classificação e à construção de uma árvore de decisão clara. Os algoritmos baseados em árvores, como RandomTree e RepTree, demonstraram ser eficazes neste contexto, pois além de fornecerem alta precisão, também geram árvores de decisão que facilitam a interpretação dos dados e a implementação de processos de decisão automatizados, como ilustrado na Figura 32.

Figura 5 Árvore de Decisão



Fonte: dados coletados pelos autores.

Com a árvore de decisão gerada pelo algoritmo RandomTree na ferramenta WEKA, torna-se possível implementar um modelo que, ao receber os dados coletados, identifica automaticamente a situação de desempenho do funcionário da fábrica.

5. Conclusões

Este trabalho apresentou o desenvolvimento de um modelo de classificação de desempenho em um ambiente fabril, com foco na identificação de padrões de atividade dos funcionários. Utilizando uma base de dados coletada diretamente das atividades dos trabalhadores, foi possível categorizar o desempenho em situações como “Ruim,” “Atenção,” “Regular,” e “Ótimo.” A análise dos dados foi realizada com o auxílio da ferramenta WEKA, permitindo a aplicação de diferentes algoritmos de classificação. O algoritmo RandomTree foi selecionado como o mais eficaz, alcançando uma precisão de 94,8% após o ajuste da base com contra-exemplos para cada situação.

A metodologia incluiu o pré-processamento dos dados e a aplicação de validação cruzada, o que aumentou a qualidade dos dados e a capacidade dos modelos de generalizar os resultados, minimizando o impacto de ruídos e dados irrelevantes. Os algoritmos baseados em árvores, como RandomTree e RepTree, se destacaram tanto em precisão quanto em facilidade de interpretação, com a construção de uma árvore de decisão que possibilita uma implementação prática do modelo para monitoramento contínuo de desempenho.

A abordagem proposta demonstrou ser eficaz ao transformar dados brutos em informações valiosas para a avaliação de desempenho no contexto industrial. Ao alinhar precisão e aplicabilidade, este trabalho sugere que técnicas de mineração de dados são uma ferramenta poderosa na gestão de desempenho, com potencial para otimizar a eficiência operacional.

Perspectivas futuras incluem a ampliação da amostra de dados e o teste de novos algoritmos para melhorar a precisão do modelo. Em resumo, esta pesquisa mostrou que é viável aplicar análise de dados para aprimorar a avaliação de desempenho industrial, estabelecendo uma base sólida para diagnósticos e decisões mais informadas, contribuindo para um ambiente de trabalho mais produtivo e orientado para o desenvolvimento contínuo.

REFERÊNCIAS

ALOEE. **Relatórios de eficiência da indústria eletrônica.** Disponível em: <<https://www.aloee.it/blog/relatorio-de-producao-industrial>> Acesso em: 12 jun. 2024.

FAWCETT, T. "An introduction to ROC analysis." Pattern Recognition Letters, v. 27, n. 8, p. 861-874, 2006.

GIUDICI, P. – Applied Data Mining: statistical methods for business and Industry. John Wiley & Sons Ltd. 2003.

HALL, M. et al. "The WEKA data mining software: an update." ACM SIGKDD explorations newsletter, v. 11, n. 1, p. 10-18, 2009.

HAND, D. J.; MANNILA H.; SMYTH P. Principles of Data Mining (Adaptive Computation and Machine Learning). Cambridge, MA: MIT Press, 2001.

J. Smith, A. Johnson, & P. Adams. (2020). "Machine Learning for Employee Performance Evaluation." *Journal of Data Science*, 15(2), 100-120.

Oliveira, F., & Souza, M. (2021). "Aplicações de Mineração de Dados em Recursos Humanos." *Revista Brasileira de Inteligência Artificial*, 7(3), 45-60.

MITCHELL, T. M. et al. Machine learning. 1997. Burr Ridge, IL: McGraw Hill, v. 45, n. 37, 2006.

MONK, S. – Tecnologia da Informação para Gestão - 8ed: Em Busca de um Melhor Desempenho Estratégico e Operacional, 2013.

TURBAN, E; SHARDA, R; ARONSON, J, E; KING, D. – Business Intelligence: Um Enfoque Gerencial para a Inteligência de Negócio. Porto Alegre: Bookman, 2009.

TURBAN, E.; VOLONINO, L. Tecnologia da Informação para Gestão-: Em Busca de um Melhor Desempenho Estratégico e Operacional. [S.l.]: Bookman Editora, 2013.

UNIVERSITY OF WAIKATO. Weka 3 – Machine Learning Software in Java. Disponível no site da University of Waikato (2010). URL: <http://www.cs.waikato.ac.nz/ml/weka>.

WITTEN, I. H.; FRANK, E. Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. Morgan Kaufmann Publishers, 2nd edition, San Francisco, California, 2005.

POWERS, D.M.W. "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation." Journal of Machine Learning Technologies, v. 2, n. 1, p. 37-63, 2011.