

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

RAFAEL VERGANI ABBADE

**ESTIMAÇÃO DE DEMANDA CONSIDERANDO VARIÁVEIS
CLIMATOLÓGICAS EM CURTO PRAZO**

São Carlos - SP

2018

Rafael Vergani Abbade

**ESTIMAÇÃO DE DEMANDA CONSIDERANDO VARIÁVEIS
CLIMATOLÓGICAS EM CURTO PRAZO**

Trabalho de Conclusão de Curso
apresentado à Escola de Engenharia de
São Carlos da Universidade de São Paulo.

Curso de Engenharia Elétrica – Ênfase em
Sistemas de Energia e Automação

ORIENTADOR: Prof. Dr. Ricardo A. S. Fernandes

São Carlos - SP

2018

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

A122e Abbade, Rafael Vergani
 Estimação de demanda considerando variáveis
 climatológicas em curto prazo / Rafael Vergani Abbade;
 orientador Ricardo Augusto Souza Fernandes. São Carlos,
 2018.

 Monografia (Graduação em Engenharia Elétrica com
 ênfase em Sistemas de Energia e Automação) -- Escola de
 Engenharia de São Carlos da Universidade de São Paulo,
 2018.

 1. Energia Elétrica. 2. Variáveis Climatológicas.
 3. Séries Históricas. 4. Mineração de Dados. 5. Redes
 Neurais Artificiais. I. Título.

FOLHA DE APROVAÇÃO

Nome: Rafael Vergani Abbade

Título: “Estimação de demanda considerando variáveis climatológicas em curto prazo”

Trabalho de Conclusão de Curso defendido e aprovado
em 18/06/2018,

com NOTA 8,5 (oito, cinco), pela Comissão Julgadora:

Prof. Dr. Ricardo Augusto Souza Fernandes - Orientador - DEE/UFSCar

Prof. Dr. Samuel Lourenço Nogueira - DEE/UFSCar

Mestre Thamyres Tânulla Cavalcante Palitó - Doutoranda - SEL/EESC/USP

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado Rogério Andrade Flauzino

RESUMO

ABBADE, R. V. (2018). Estimação de Demanda Considerando Variáveis Climatológicas em Curto Prazo. Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2018.

Previsão de cargas elétricas é imprescindível para planejamento e operação de sistemas elétricos, já que através dela é estabelecida quando e quanto de capacidade de geração e transmissão deve-se dispor para atender a carga sem interrupções no fornecimento e também para evitar o desperdício em despachos mal planejados ou compra de combustível. Neste trabalho, será apresentada uma metodologia que utiliza séries históricas de variáveis climatológicas de uma determinada região para predizer a demanda de Energia Elétrica. Será abordado temas como o processo de Descoberta de Conhecimento em Bancos de Dados e suas etapas, como mineração de dados e redes neurais artificiais com o treinamento realizado pelo algoritmo de Levenberg-Marquardt. Os resultados foram apresentados de forma a avaliar a consistência e acurácia da metodologia aplicada.

Palavras-chave: Energia Elétrica. Variáveis Climatológicas. Séries Históricas. Mineração de Dados. Redes Neurais Artificiais.

ABSTRACT

Load forecasting is indispensable for planning and operating the Electricity Sector, considering that most studies of electrical systems require a good estimative of the charge to be fulfilled without interruptions and also to avoid the waste of fuel and mistaken Power Plant Releases. The main objective of this work is to develop a methodology for load forecasting considering the influence of the climatic variables. The methodology involves subjects as Knowledge Discovery in Database and its steps, such as Data Mining and Neural Networks. The proposed method was applied using the Levenberg-Marquadt algorithm and real historical data from Ontario, Canada. The results were shown and discussed to evaluate the consistency and the accuracy of the applied method.

Keywords: Electrical Energy. Climatic Variables. Historical Series. Data Mining. Neural Network.

LISTA DE ILUSTRAÇÕES

Figura 1 - Visão Geral dos Passos que Constituem o Processo DCBD	19
Figura 2 - Mapa das Cidades Seleccionadas no Estado de Ontario	20
Figura 3 - Neurônio Artificial de McCulloch-Pitts	26
Figura 4 - Função de Ativação do Tipo Degrau.....	27
Figura 5 - Função de Ativação do Tipo Sigmoides.....	28
Figura 6 - Exemplo de Rede de Camada Simples Unidirecional	29
Figura 7 - Exemplo de Rede Alimentação à Frente de Camadas Múltiplas.....	30
Figura 8 - Estrutura da RNA Simulada.....	31
Figura 9 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Todos os Dias e Uma Camada Intermediária.....	40
Figura 10 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Todos os Dias e Duas Camadas Intermediárias	41
Figura 11 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Dias da Semana e Uma Camada Intermediária	41
Figura 12 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Dias da Semana e Duas Camadas Intermediárias.....	42
Figura 13 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Finais de Semana e Uma Camada Intermediária.....	42
Figura 14 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Finais de Semana e Duas Camadas Intermediárias	43

LISTA DE TABELAS

Tabela 1 - Organização dos Dados.....	22
Tabela 2 - Atributos Resultantes da Simulação no Software WEKA	24
Tabela 3 - Estrutura da RNA com Duas Camadas Intermediárias.....	32
Tabela 4 - Resultados Para Uma Camada.....	35
Tabela 5 - Resultados Para Duas Camadas	35
Tabela 6 - Comparativo dos Resultados das Simulações de Uma Camada.....	37
Tabela 7 - Comparativo dos Resultados das Simulações de Duas Camadas	38
Tabela 8 - Resultado das Simulações de Validação com Uma Camada.....	39
Tabela 9 - Resultado das Simulações de Validação com Duas Camadas	39

SUMÁRIO

1. INTRODUÇÃO	15
1.1. OBJETIVO	15
1.2. MOTIVAÇÃO.....	16
1.3. ORGANIZAÇÃO DO TRABALHO	16
2. METODOLOGIA	19
2.1. SELEÇÃO DE ATRIBUTOS	20
2.2. PRÉ-PROCESSAMENTO E LIMPEZA	21
2.3. TRANSFORMAÇÃO DOS DADOS	22
2.4. MINERAÇÃO DE DADOS	22
2.4.1. Redes Neurais Artificiais	25
2.4.1.1. Neurônio Artificial	25
2.4.1.2. Funções de Ativação.....	27
2.4.1.3. Arquiteturas de Redes Neurais Artificiais	28
2.4.1.4. Rede Neural Proposta Para Previsão de Demanda	30
2.4.1.5. Configuração da Rede Neural Proposta Para Previsão de Demanda.....	31
3. RESULTADOS OBTIDOS PARA PREVISÃO DE DEMANDA.....	35
4. CONCLUSÃO.....	45
REFERÊNCIAS.....	47

1. INTRODUÇÃO

O uso da energia elétrica não só contribui com a qualidade de vida, como também possui um papel importante no desenvolvimento de um país, pois, influencia diretamente muitos setores da sociedade. Nos dias de hoje, a energia elétrica é comercializada como qualquer outra *commodity*, entretanto, é um bem extremamente volátil, pois diversos fatores estão atrelados à sua dependência: preço do combustível, variações na geração hidroelétrica acarretada por períodos de mais secos, crescimento econômico do país, histórico de preços e de demanda da energia elétrica (AMJADY; KEYNIA, 2009).

Além dos fatores mencionados acima, o preço da energia elétrica também pode ser afetado por fatores externos que ocorrem durante os dias de uma semana, bem como pelas estações do ano (MANDAL; SRIVASTAVA; PARK, 2009). É importante destacar que, diferente de outras commodities, sua armazenagem ainda é inviável. Logo, a oferta e a demanda devem estar em equilíbrio, para que não falte energia e também para não haver geração sem finalidade (MOHNSENIAN-RAD; LEON-GARCIA, 2010; GARCÍA-MARTOS; RODRÍGUEZ; SÁNCHEZ, 2012; AMJADY; HEMMATI, 2006).

Tendo em vista esses fatos, quanto mais precisamente for feita a análise da estimativa da demanda da energia elétrica, mais possibilidades existem para efetuar estratégias de despacho e de compra de combustível, acarretando em um preço mais baixo (BRAGA, 2017; BORDIGNON, 2012). Vale ressaltar que essa previsão beneficiaria também concessionárias e comercializadoras de energia elétrica, bem como grandes indústrias, pois possibilita a otimização do lucro e a minimização dos custos relacionados à energia elétrica.

1.1. OBJETIVO

Considerando a importância de estimar a demanda de energia elétrica em um determinado espaço, este trabalho tem como objetivo principal encontrar uma metodologia de predição que utiliza séries históricas reais obtidos por meio de uma coleta de dados. Os passos a serem tomados para atingir o objetivo estão listados a seguir:

- Obter uma base de dados históricos da demanda de energia elétrica de uma determinada região;
- Armazenar, de maneira organizada, a maior quantidade possível de atributos para que estes possam ser analisados e selecionados;
- Aplicar ferramentas de seleção de atributos com base no software Weka;

- Verificar o comportamento de Redes Neurais Artificiais ao processo de estimação de demanda de energia elétrica.

1.2. MOTIVAÇÃO

A previsão de cargas elétricas de curto prazo é utilizada no planejamento e operação diários dos Sistemas Elétricos de Potência, para que os mesmos sejam seguros, confiáveis e econômicos. Os fatores temporais e climáticos exercem grande influência nas previsões de curto e médio prazo, pois se modificam em curto prazo (BORDIGNON, 2012). Por exemplo, se a temperatura aumenta ou diminui além de uma temperatura agradável, aquecedores ou aparelhos de ar-condicionado serão acionados, ocasionando um maior consumo. Atualmente, o uso das redes neurais é um método alternativo e eficiente e uma de suas vantagens é que não necessita da modelagem prévia da carga. A modelagem é uma tarefa trabalhosa e os métodos que necessitam da mesma nem sempre apresentam os melhores resultados. As RNAs são ferramentas versáteis capazes de realizar aproximação de funções não-lineares e previsão de séries temporais a partir de um treinamento adequado, devido às suas capacidades de aprendizagem e generalização (FILHO, 2011; ABREU et al., 2012). Com o avanço da tecnologia computacional, a quantidade de dados armazenados e a capacidade de processamento têm aumentado e os métodos que envolvem a mineração de dados têm se tornado uma alternativa cada vez mais confiável e capaz de prever variáveis num horizonte cada vez menor.

O Operador Nacional do Sistema Elétrico (ONS) utiliza ferramentas computacionais para estudos energéticos tanto de curto como médio prazo, como o DECOMP e o NEWAVE. Essas ferramentas utilizam como principais variáveis os possíveis cenários hidrológicos, como volume dos reservatórios, vazão dos rios e pluviosidade (OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2016). Este trabalho visa a utilização de uma metodologia de predição da demanda de energia elétrica utilizando variáveis diferentes das mencionadas acima, a fim de serem utilizadas em conjunto para obter maior acurácia nos resultados.

1.3. ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em quatro capítulos incluindo esta introdução. Segue a descrição do conteúdo abordado em cada capítulo.

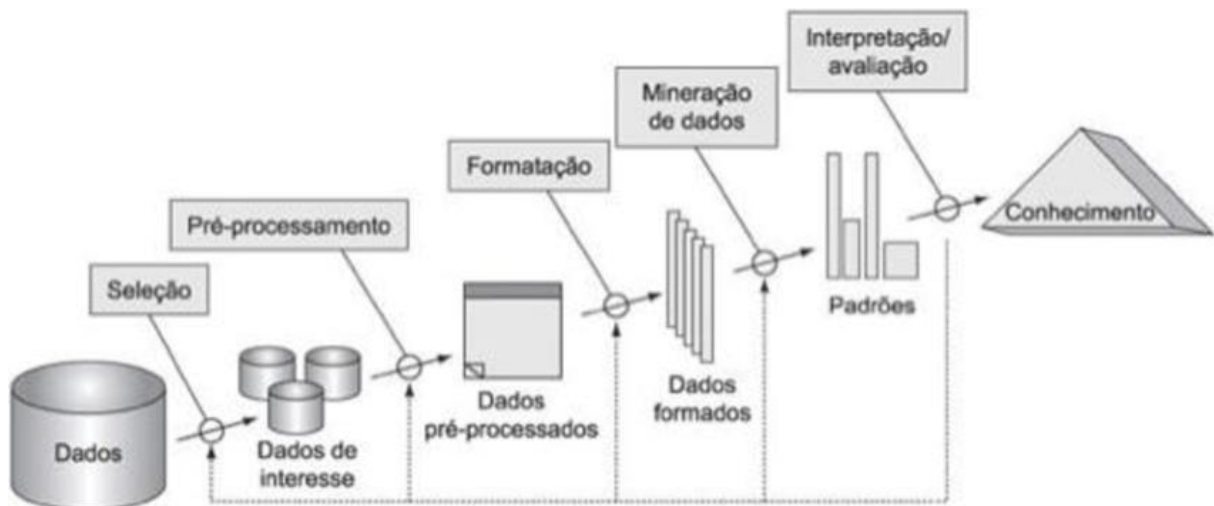
- Nesta introdução apresentou-se uma visão geral sobre a energia elétrica, bem como as motivações para a realização da previsão de demanda.

- No capítulo 2 é definida a metodologia utilizada na predição da demanda de energia elétrica. Ordenadamente são apresentadas cada etapa do processo seguida pela explicação de como foi feita a utilização destas no presente trabalho.
- No capítulo 3 são apresentados todos os resultados da simulação e na sequência é feita a análise desses resultados.
- No capítulo 4 são apresentadas as conclusões deste trabalho.

2. METODOLOGIA

Com a evolução da tecnologia, as áreas governamentais, corporativas e científicas têm promovido um aumento explosivo em seus bancos de dados, que supera a capacidade de interpretar e examinar esses dados. As instituições dos segmentos mencionados acima têm buscado recursos que agreguem valor aos seus negócios, que agilizem operações e gerem inovações (SILVA, 2004). Diariamente, pessoas e instituições, colhem e disponibilizam vários tipos de dados: tarefas cotidianas; perfis de consumo; variáveis climatológicas; comportamento de mercado e etc. Com esta disponibilidade de imensas e crescentes bases de dados e a necessidade de transformar tais dados em informação e conhecimento uteis, tem-se buscado novas ferramentas e técnicas para conseguir analisar de maneira automática e inteligente de bancos de dados. Assim, chegamos em um processo Descoberta de Conhecimento em Banco de Dados (DCBD). Este processo envolve a avaliação e interpretação de padrões para tomadas de decisões, já a mineração de dados é a aplicação de algoritmos para a extração desses padrões (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996; DAMASCENO, 2010). Para isto, a mineração está vinculada com a tecnologia computacional, que está em constante desenvolvimento, ajudando o processo a se tornar cada vez mais automatizado, rápido e eficiente nas buscas e previsões. Na Figura 1 é apresentado um fluxograma do DCBD.

Figura 1 - Visão Geral dos Passos que Constituem o Processo DCBD



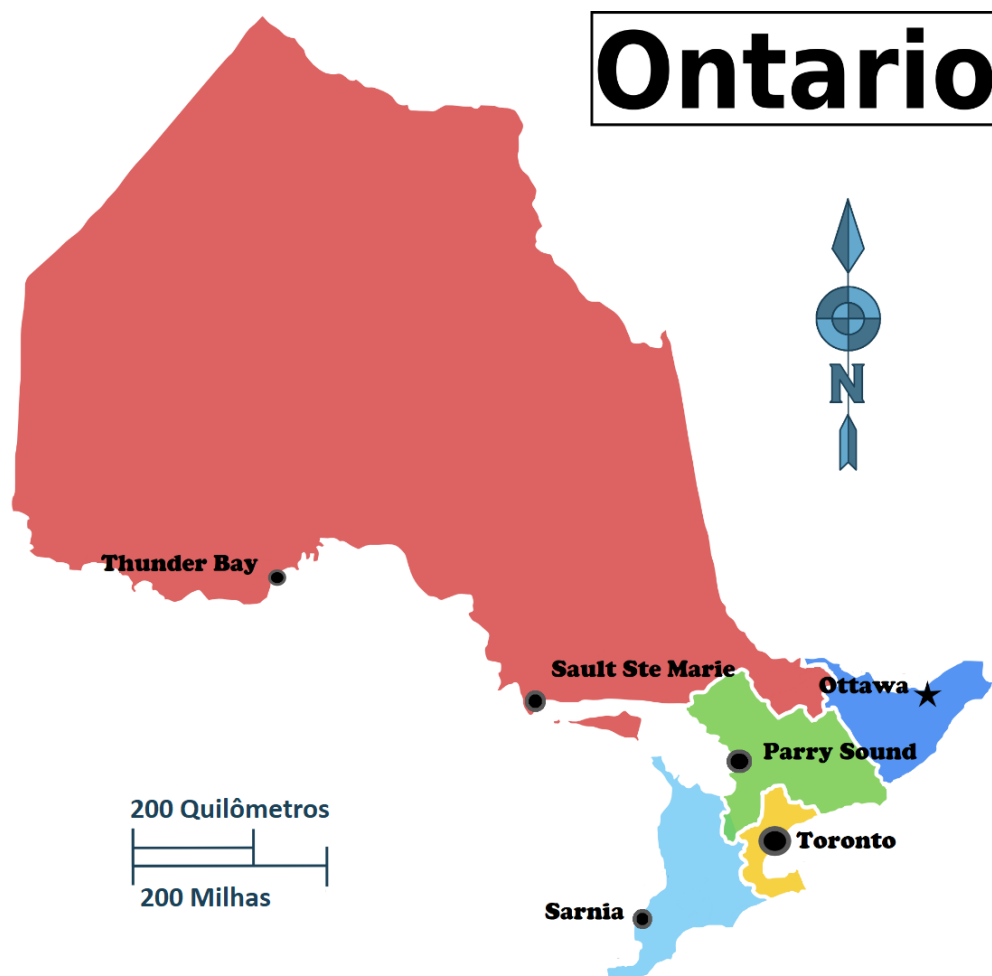
Fonte: Adaptado de Fayyada, Piatetsky-Shapiro e Smyth (1996)

2.1. SELEÇÃO DE ATRIBUTOS

A fase de seleção dos dados é a primeira no processo de descobrimento de informação e possui um impacto significativo sobre a qualidade do resultado final, visto que nesta fase é escolhido o conjunto de dados contendo todas as possíveis variáveis, que também podem ser chamadas de atributos, e de registros, que farão parte da análise.

Inicialmente, foi definido que a região a ser levada em consideração nessa pesquisa seria o estado de Ontario no Canadá, para continuação da pesquisa do Professor Orientador Ricardo Fernandes e pelo fato de já ter alguns dados coletados. O professor Ricardo disponibilizou uma planilha com a demanda de energia elétrica hora em hora de Ontario de maio de 2002 até dezembro de 2016. Por meio da análise do mapa de Ontario, foram selecionadas cidades canadense, levando em consideração o seu espaçamento geográfico e populacional, para verificar as variações climáticas no estado como um todo. As cidades escolhidas estão ilustradas na Figura 2, destaque para a capital do país indicada com uma estrela.

Figura 2 - Mapa das Cidades Selecionadas no Estado de Ontario



Fonte: Adaptado de WikiMedia Commons (2018)

Após essa definição, foi feita uma busca na internet por banco de dados com histórico de variáveis climatológicas e o site escolhido foi o Weather Underground (WEATHER UNDERGROUND, 2016), tanto pela grande quantidade de dados como pela praticidade ao exportá-los em forma de planilha. A escolha das variáveis foi feita com base em suposições de influência destas na demanda de energia elétrica. Tais variáveis são:

- Temperatura Máxima (°C)
- Temperatura Média (°C)
- Temperatura Mínima (°C)
- Umidade Média (%)
- Velocidade do Vento Máxima (km/h)
- Velocidade do Vento Média (km/h)
- Direção do Vento (°)
- Precipitação (mm)

O site Weather Underground, apesar de mostrar as variáveis climatológicas de hora em hora, apenas armazena tais dados por dia, tornando impossível, por hora, considerar uma janela móvel horária na previsão da demanda de energia elétrica.

2.2. PRÉ-PROCESSAMENTO E LIMPEZA

O pré-processamento e limpeza, que também é de extrema importância no processo de DCBD, pois a qualidade desses dados vai determinar a eficiência dos algoritmos de mineração que virão a seguir. O trabalho nesta etapa consiste na verificação desses dados para eliminar qualquer redundância ou inconsistência. A identificação de dados inapropriados é complicada e dificulta a automatização desse processo.

Após a exportação do banco de dados do Weather Underground, foi feita uma conferência e a variável precipitação apresentou algumas lacunas ao longo período pesquisado. Baseado nessa inconsistência, essa variável foi retirada.

2.3. TRANSFORMAÇÃO DOS DADOS

A transformação dos dados é a etapa de organização dos dados. Estes necessitam ser armazenados e formatados adequadamente para que os algoritmos possam ser aplicados. Os dados devem ser agrupados em um repositório único.

Devido ao fato do site Weather Underground apenas disponibilizar essas variáveis diariamente, foi necessário realizar uma somatória nos dados da demanda de hora em hora fornecidos pelo professor Ricardo Fernandes. Seguido a isso, tomou-se a decisão de considerar uma janela móvel de cinco dias. As variáveis foram organizadas de maneira sequencial e cronológica e a organização dos dados foi feita da seguinte maneira:

Tabela 1 - Organização dos Dados

Organização dos Dados por Cidade											...	Média Móvel da Demanda				Demanda		
V1 (D)	V2 (D)	...	Vk (D)	V1 (D-1)	V2 (D-1)	...	Vk (D-1)	...	V1 (D-5)	V2 (D-5)	...	Vk (D-5)	...	Dem (D-1)	Dem (D-2)	...	Dem (D-5)	Dem (D)

Fonte: O autor (2018)

A organização dos dados por cidade foi repetida para cada cidade, seguida pela demanda de até cinco dias anteriores e pela demanda do dia D em questão.

Essa organização foi repetida em três configurações diferentes: somente dias da semana; somente fins de semana e considerando todos os dias. A escolha de analisar estas três configurações distintas se deu pelo fato de analisar diferentes perfis de consumo, em dias úteis, não úteis e todos os dias.

2.4. MINERAÇÃO DE DADOS

Apesar da importância das etapas anteriores para esse processo, é a mineração de dados que requer maior atenção e é o maior destaque. A mineração de dados é a exploração e análise de grandes bases de dados com o objetivo de descobrir padrões e regras. Esta tem como objetivo fornecer informações que possibilitem adotar a melhor estratégia, seja qual for sua aplicação.

Etapas de mineração de dados utilizam técnicas e algoritmos de diferentes áreas do conhecimento: a inteligência artificial como a aprendizagem de máquina, a manipulação de grandes bancos de dados e a estatística. É importante ressaltar que devido ao volume, complexidade e peculiaridade de alguns eventos e dados, é necessário utilizar uma mescla das três áreas (SILVA, 2004).

Neste trabalho, foi utilizado o WEKA (WEKA, 2016), um software totalmente gratuito que contempla uma série de algoritmos de preparação de dados, de aprendizado de máquina

e de validação de resultados. Será apresentado a seguir uma breve descrição dos principais recursos do WEKA (DAMASCENO, 2010).

- **Classificação:** É um algoritmo de mineração de dados supervisionado, no qual já sabemos qual será nossa saída correta, tendo a ideia de que existe uma relação entre a entrada e saída. Após um treinamento com uma base de dados significativas, é possível mapear, através de suas entradas, cada amostra em uma categoria distinta. Por exemplo, é possível identificar tendências de comportamento de clientes que são maus pagadores, para que a empresa consiga discerni-las e diminuir o risco por meio da não aceitação das solicitações de crédito.

- **Seleção de atributos:** em base de dados, alguns atributos tem uma relevância maior do que outros. Também supervisionado, este método passa por todas as possíveis combinações de atributos para decidir quais deles tem maior peso na saída e consequentemente, funcionam melhor para a predição. Por exemplo, a renda de uma pessoa com certeza seria um atributo determinante em seus hábitos de consumo.

- **Associação:** Esta é uma técnica exploratória, capaz de gerar regras, elegendo uma dependência entre atributos determinantes e atributos resultantes, por intermédio de associações entre seus valores. É possível associar, clientes do sexo feminino, casadas, com renda superior a R\$ 2.000,00 têm o hábito de consumir maquiagens importadas, roupas de grife e bolsas nacionais.

- **Agrupamento:** Uma outra técnica exploratória. Este encontra uma maneira de agrupar automaticamente os dados em grupos que são de alguma forma semelhantes. Por exemplo, divide em grupos de faixas etárias diferentes, que são propensas a comprar carros de uma determinada cor, como, de 22-30 anos costumam comprar carros brancos e de 55-65 costumam comprar automóveis cinzas.

Quanto à aplicação do WEKA neste trabalho, foram considerados um total de 185 variáveis de entrada para cada organização, sendo necessária executar uma filtragem desta seleção, para obter uma lista menor de atributos. Para isso, foi selecionado um recurso de seleção de atributos.

Dentro desse recurso, foi selecionado o filtro *Relief-f* para realizar o processamento dos dados e ordenar quais os atributos mais influenciam na saída desejada. Esse filtro, proposto por Kira e Rendell em 1992 (KIRA; RENDELL, 1992), tem por objetivo destacar, por meio de uma amostragem aleatória, dentro de um conjunto de dados de duas classes distintas, os valores diferentes entre vizinhos próximos de classes diferentes e penalizar valores diferentes, para vizinhos próximos, dentro de duas classes iguais (SPOLAÔR, 2014).

Vale ressaltar que a base de dados deve ser normalizada entre zero e um para que o algoritmo possa ser utilizado de forma correta.

Tabela 2 - Atributos Resultantes da Simulação no Software WEKA

	Todos os dias	Dias de semana	Fim de semana
1º	Demanda em Ontario (D-1) (MWh)	Demanda em Ontario (D-1) (MWh)	Demanda em Ontario (D-1) (MWh)
2º	Demanda em Ontario (D-2) (MWh)	Demanda em Ontario (D-2) (MWh)	Demanda em Ontario (D-2) (MWh)
3º	Demanda em Ontario (D-3) (MWh)	Demanda em Ontario (D-3) (MWh)	Demanda em Ontario (D-3) (MWh)
4º	Demanda em Ontario (D-4) (MWh)	Demanda em Ontario (D-4) (MWh)	Demanda em Ontario (D-4) (MWh)
5º	Demanda em Ontario (D-5) (MWh)	Demanda em Ontario (D-5) (MWh)	Demanda em Ontario (D-5) (MWh)
6º	Toronto (D) Temperatura Máxima (°C)	Ottawa (D) Temperatura Máxima (°C)	Sarnia (D) Temperatura Média (°C)
7º	Toronto (D) Temperatura Mínima (°C)	Ottawa (D) Temperatura Média (°C)	Sarnia (D) Temperatura Mínima (°C)
8º	Sarnia (D) Temperatura Média (°C)	Toronto (D) Temperatura Máxima (°C)	Ottawa (D) Temperatura Máxima (°C)
9º	Sarnia (D) Temperatura Mínima (°C)	Toronto (D) Temperatura Média (°C)	Ottawa (D) Temperatura Média (°C)
10º	Toronto (D) Temperatura Mínima (°C)	Toronto (D) Temperatura Mínima (°C)	Sarnia (D) Temperatura Máxima (°C)

Fonte: O autor (2018)

Analisando a Tabela 2, nota-se que as variáveis que mais influenciam as saídas, foram as variáveis da própria demanda, porém em dias anteriores à previsão. Este resultado é condizente com o esperado, visto que o valor da demanda não costuma ter uma variação muito grande na comparação de um dia para o outro, apenas se houver um evento extraordinário que possa alterar sua estacionariedade. Outro fato a ser levado em

consideração é o atributo de temperatura nas maiores cidades do estado no dia da demanda, indicando uma possível ligação entre a temperatura do próprio dia e a demanda que está sendo prevista.

2.4.1. Redes Neurais Artificiais

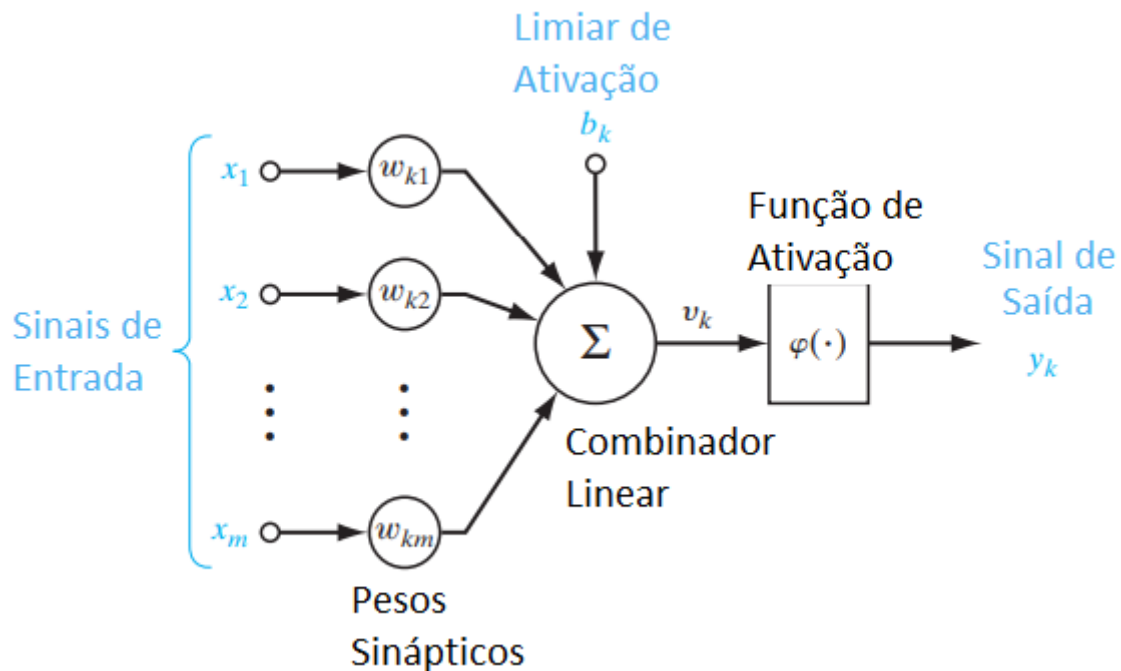
O cérebro humano é um sistema de processamento de informações paralelo altamente complexo e não linear. Sua estrutura de organização é capaz, utilizando dos neurônios, de realizar certos cálculos a fim de identificar padrões, processar percepções e suas respostas motoras, tudo isso mais rapidamente do que o computador digital mais avançado dos dias de hoje. O cérebro humano também é capaz de construir suas próprias regras através de experiências. Esse desenvolvimento demonstra plasticidade que permite que o sistema nervoso se adapte ao ambiente externo. Assim como o cérebro tem essa capacidade de alterar seu processamento de informações, as Redes Neurais Artificiais (RNA) também apresentam essas características. Uma RNA representa um modelo matemático e computacional inspirado nos mecanismos de aprendizagem do cérebro humano e como este realizada uma dada função. Suas unidades de processamento são os neurônios artificiais, que se interligam por meio de redes e são capazes de adaptar a forma com que processam, armazenam e transmitem informações provenientes do meio externo (HAYKIN, 2009; SOARES, 2008).

A adaptabilidade e a generalização das informações figuram entre as propriedades mais úteis das RNAs, pois as torna aplicáveis em diversas situações. Tais modelos matemáticos são capazes de ajustar seus parâmetros internos de cálculo a partir da inserção de amostras externas dentro da rede. Com isto, conseguem aprender, por meio de treinamentos, como melhor se adaptar ao modelo de dados proposto. O sistema também se torna mais tolerante a falhas nas entradas, pois caso esta seja estranha à rede neural, baseado em seu treinamento, o sistema é capaz de decidir se descarta ou não a entrada (DA SILVA; FLAUZINO; SPATTI, 2010).

2.4.1.1. Neurônio Artificial

O neurônio artificial é uma unidade de processamento de informação fundamental para a operação de uma rede neural. O modelo geral de um neurônio artificial foi proposto por McCulloch & Pitts em 1943 (HAYKIN, 2009; DA SILVA; FLAUZINO; SPATTI, 2010) e está demonstrado na Figura 3.

Figura 3 - Neurônio Artificial de McCulloch-Pitts



Fonte: Adaptado de Haykin (2009)

Os elementos básicos de um neurônio artificial são (HAYKIN, 2009) :

- Sinais de entrada $\{x_1, x_2, x_3, \dots, x_n\}$ – são provenientes do meio externo, eles são usualmente normalizados visando aumentar a eficiência computacional do algoritmo de aprendizagem.
- Pesos sinápticos $\{w_{k1}, w_{k2}, w_{k3}, w_{k2}, \dots, w_{km}\}$ – cada sinal de entrada é multiplicado por um peso w_n , que indica sua influência na saída do neurônio. Também são utilizados para armazenar o conhecimento adquirido na fase de aprendizagem.
- Combinador Linear $\{\Sigma\}$ – somar os sinais de entradas com seus respectivos pesos, para que o resultado da operação possa produzir um potencial de ativação.
- Limiar de Ativação $\{b_k\}$ – define se a saída será disparada.
- Potencial de Ativação $\{v_k\}$ – resultado produzido entre o combinador linear e o limiar de ativação.
- Função de Ativação $\{\varphi\}$ – limita o sinal de saída de acordo com os valores da imagem da própria função.
- Sinal de Saída $\{y\}$.

A partir disto, a saída de um neurônio artificial pode ser expressa conforme a Equação 1 (HAYKIN,2009).

$$y_k = \varphi\left(\sum_{k=1}^n w_{ki}x_i + b_k\right) \quad [1]$$

2.4.1.2. Funções de Ativação


Abaixo são demonstradas as funções de ativação mais utilizadas na construção das redes neurais (HAYKIN, 2009).

- Função Degrau

$$\varphi(v) = \begin{cases} y = 1, & \text{se } v \geq 0 \\ y = 0, & \text{se } v < 0 \end{cases} \quad [2]$$

Na função degrau, a saída de um neurônio toma o valor de 1 no caso do potencial de ativação ser atingido, caso contrário, este assume o valor de 0, conforme ilustrado na Figura 4.

Figura 4 - Função de Ativação do Tipo Degrau




Fonte: Adaptado de Haykin (2009)

- Função Sigmoidal

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad [3]$$

Figura 5 - Função de Ativação do Tipo Sigmoides



Fonte: Adaptado de Haykin (2009)


Segundo Haykin (2009), a função sigmoide é a função de ativação mais comum na construção de redes neurais artificiais. Esta é definida como uma função crescente que mostra um equilíbrio entre comportamentos linear e não linear. A variável α é o parâmetro de inclinação da função sigmoide.

2.4.1.3. Arquiteturas de Redes Neurais Artificiais

A aplicação e o algoritmo de treinamento de uma rede neural variam de acordo com a sua arquitetura, que é a maneira em que os neurônios estão conectados (HAYKIN, 2009; SOARES, 2008). Os tipos mais comuns de arquitetura podem ser divididos em duas classes: camada única ou multicamadas.

Nas redes de camada única, a forma mais simples de rede neural, os neurônios são organizados em uma única camada. A rede é sempre alimentada adiante, ou seja, o fluxo de informações segue no sentido da entrada para a saída, não existindo laços de realimentação (DA SILVA; FLAUZINO; SPATTI, 2010). O número de saídas será igual ao número de neurônios que existem na rede, assim como demonstrado na Figura 6.

Figura 6 - Exemplo de Rede de Camada Simples Unidirecional




Fonte: Adaptado de Haykin (2009)

As redes em geral são divididas em três camadas. A primeira é a camada de entrada, responsável por receber a informação externa que é normalizada para fornecer maior precisão nas operações matemáticas. Posteriormente, encontra-se as camadas intermediárias ou ocultas, onde quase todo processamento da rede é realizado com o intuito de extrair as características da série a ser analisada. Por fim, existe a camada de saída, que é responsável por apresentar o resultado das operações anteriores da rede (DA SILVA; FLAUZINO; SPATTI, 2010).

Quanto às redes multicamadas, estão divididas em dois tipos: as de alimentação adiante (*feedforward*) e as redes recorrentes. Ambas as redes apresentam uma ou mais camadas intermediárias e são utilizadas na resolução de problemas mais complexos. Neste tipo de estrutura o número de saídas não precisa ser igual ao número de neurônios da camada intermediária, mesmo porque a quantidade de neurônios é definida pela complexidade do problema analisado (DA SILVA; FLAUZINO; SPATTI, 2010). A Figura 7 apresenta uma rede de alimentação adiante:

Figura 7 - Exemplo de Rede Alimentação à Frente de Camadas Múltiplas



Fonte: Adaptado de Haykin (2009)

Já as redes recorrentes, se diferenciam das anteriores pois contém pelo menos um laço de realimentação, que ocasionam um grande impacto na sua capacidade de aprendizado e na sua performance (HAYKIN, 2009).

2.4.1.4. Rede Neural Proposta Para Previsão de Demanda

O problema proposto é relacionado à aproximação funcional, para tal, foi escolhido redes neurais de múltiplas camadas do tipo PMC (Perceptron de Múltiplas Camadas). Esta rede é uma das mais populares, sendo capaz de resolver problemas complexos e de natureza diversa. Segundo Da Silva, Flauzino e Spatti (2010) o processo de aprendizado da PMC segue um treinamento supervisionado chamado de *backpropagation*. Neste caso, utilizando a Figura 7 como exemplo, primeiro é apresentado um padrão à entrada e sua resposta é propagada como entrada para as camadas seguintes, até que a resposta seja produzida pela camada de saída, utilizando os pesos sinápticos atuais da rede. No segundo passo, a saída é comparada a saída desejada, caso o valor não seja o esperado, o erro é calculado e

propagado até a camada de entrada e os pesos sinápticos das camadas internas vão sendo modificados conforme o erro é retro-propagado.

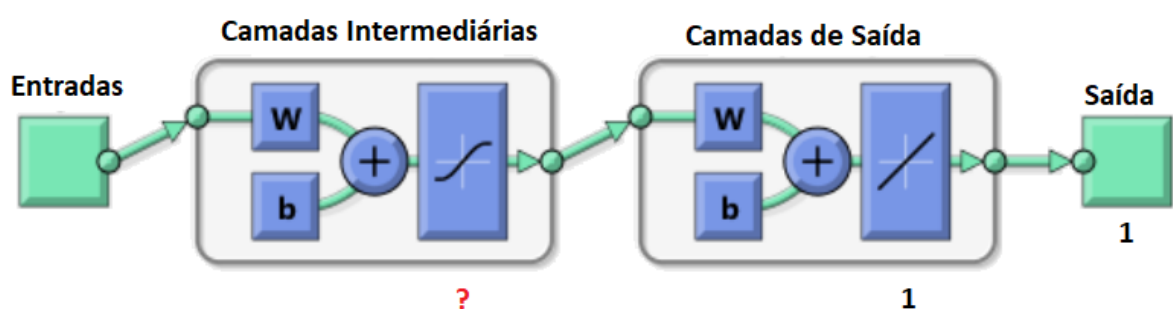
Contudo, de acordo com Leite (2016), esse método apresenta um elevado esforço computacional, pois, considera as derivadas de primeira ordem nos ajustes dos valores das matrizes de pesos. Em contrapartida, o algoritmo de treinamento de Levenberg-Marquardt, que é baseado na aceleração do treinamento em relação a determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, apresentando convergência em menos iterações (BARBOSA, 2004). Portanto, o algoritmo utilizado neste trabalho foi o de Levenberg-Marquardt.

2.4.1.5. Configuração da Rede Neural Proposta Para Previsão de Demanda

Após a organização e filtragem dos dados, as planilhas referentes às três diferentes configurações foram preparadas para as simulações no MATLAB. Deve-se mencionar que neste programa 60% dos dados foram utilizados para o treinamento da rede e os 40% para testes, sendo que, na seleção, esses percentuais foram divididos de maneira desordenada, a fim de contemplar diferentes períodos tanto no treinamento quanto na fase de teste. As simulações foram feitas em dois blocos distintos, primeiramente utilizando apenas uma camada de neurônios intermediária e a outra utilizando duas. Dentro destes blocos, simulou-se as redes neurais para dados contendo as três configurações definidas, considerando: todos os dias; fins de semana e dias da semana.

A estrutura da rede neural utilizada está indicada na Figura 8. A entrada é representada pelas dez variáveis determinadas anteriormente. O “?” indica o número de camadas e seus respectivos neurônios. Foram simuladas duas situações: uma utilizando apenas uma camada, na qual o número de neurônios variou de 5 a 50, com um passo de cinco a cada simulação; e uma com duas camadas, aplicando o mesmo raciocínio, conforme indicado na Tabela 3.

Figura 8 - Estrutura da RNA Simulada



Fonte: O autor (2018)

Tabela 3 - Estrutura da RNA com Duas Camadas Intermediárias

Neurônios na Primeira Camada	Neurônios na Segunda Camada
5	5
	10
	.
	.
	.
	45
10	50
	5
	10
	.
	.
	.
45	45
	50
	.
	.
	.
	.
50	5
	10
	.
	.
	.
	.

Fonte: O autor (2018)

A configuração da rede foi feita da seguinte forma:

- Algoritmo de treinamento: *Backpropagation* Levenberg-Marquardt;
- Valor do Erro quadrático médio a ser atingido pela rede: 10^{-15} ;
- Número máximo de épocas, cada apresentação completa do conjunto de treinamento: 500

- Taxa de aprendizado, parâmetro que interfere na convergência do processo de aprendizado, sua influência está relacionada à mudança dos pesos sinápticos: 10^{-6} ;
- Número de camadas: topologias com 1 e 2 camadas neurais intermediárias;
- Número de neurônios por camada: conforme explicado acima.

Segundo Laboissiere (2013), é necessário estabelecer critérios para avaliar os resultados gerados pelas RNAs. Logo, foram realizados cálculos de Erro Absoluto Médio (MAE - *Mean Absolute Error*), Erro Absoluto Percentual Médio (MAPE - *Mean Absolute Percentual Error*) e Erro Médio Quadrático (MSE - *Mean Square Error*) conforme respectivamente apresentados por meio das Equações 4 a 6.

$$MAE = \frac{1}{N} \sum_{i=1}^N |D_i - D_r| \quad [4]$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|D_i - D_r|}{D_i} \quad [5]$$

$$MSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (D_i - D_r)^2} \quad [6]$$

Nas equações indicadas acima, D_i representa a demanda desejada; D_r representa a demanda estimada pela RNA e N é o número de amostras usadas para validação da RNA.

3. RESULTADOS OBTIDOS PARA PREVISÃO DE DEMANDA

A Tabela 4 apresenta os resultados das três configurações distintas simulando com apenas uma camada, já a Tabela 5 mostra os resultados com duas camadas.

Tabela 4 - Resultados Para Uma Camada

Neurônios	Todos os dias			Dias da semana			Fim de Semana		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE
5	5.078531	3.331003	2.556323	0.550445	2.615994	2.140459	8.554667	2.086631	1.156728
10	6.84644	3.078172	8.309423	2.189855	2.461616	8.914818	0.520449	2.182692	9.401894
15	3.809958	3.385992	4.394017	9.477887	2.474746	0.115699	9.189199	2.146597	5.938272
20	8.814334	3.297514	5.020126	1.995595	2.387345	4.760297	2.775892	2.35799	6.495053
25	0.450275	3.355379	4.722135	4.029048	2.448353	0.417123	7.004285	2.200454	2.241901
30	1.104108	3.430291	7.236439	7.556686	2.436822	7.699672	1.884128	2.147262	6.857112
35	6.602099	3.536811	8.457342	0.331381	2.496153	3.326005	0.971075	2.201368	7.919103
40	5.821279	3.430158	4.338822	4.708829	2.461742	8.79415	4.928434	2.250412	6.545893
45	9.008504	3.402855	7.803348	7.064645	2.538359	5.97693	9.320991	2.373981	5.477823
50	6.119002	3.51189	2.795729	8.440923	2.528961	6.765959	9.162426	2.238988	4.775925

Fonte: O autor (2018)

Tabela 5 - Resultados Para Duas Camadas

Neurônios por camada		Todos os dias			Dias da semana			Fim de semana		
		MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE
5	5	6.07831	3.250389	4.89385	5.825804	2.597207	4.420968	9.026076	2.12246	9.184187
	10	5.728601	3.290196	1.674962	4.847354	2.391922	4.781748	5.95801	2.097134	9.449857
	15	1.036125	3.437186	0.986986	5.136997	2.308556	2.767108	2.211601	2.161476	3.033984
	20	3.084957	3.198198	9.269232	9.489391	2.474834	7.467647	4.953761	2.12399	7.163683
	25	9.51005	3.395594	5.620812	1.627898	2.406485	4.58615	2.99787	2.192133	9.750131
	30	2.398802	3.291616	0.008404	3.042941	2.48627	6.39427	1.962511	2.346388	9.450951
	35	1.97333	3.171704	8.467672	8.270972	2.267943	7.079179	6.830009	2.223099	2.642488
	40	5.010387	3.186746	3.616455	1.307235	2.442781	5.278226	5.424799	2.365189	0.510255
	45	6.168462	3.299323	2.371153	9.188975	2.445018	0.952904	1.114562	2.176628	4.070826
	50	9.03603	3.535569	1.682329	4.273227	2.602922	7.653692	2.904621	2.183893	8.009388
10	5	4.887125	3.464694	8.237871	7.410202	2.421671	7.47605	2.810923	2.147951	7.708965
	10	2.582764	3.296274	5.787858	6.804411	2.332265	9.264045	8.884779	2.189166	9.150834
	15	8.453923	3.35395	2.730126	1.191589	2.2838	4.406166	8.062418	2.309237	4.178842
	20	9.487443	3.300088	4.686598	2.19936	2.403006	4.646002	7.661963	2.613771	4.196613
	25	6.562149	3.361514	3.414787	0.828688	2.38759	6.062734	1.172727	2.19508	6.992829
	30	0.099791	3.248822	9.085032	8.960871	2.333708	7.60935	8.383009	2.274038	1.884974
	35	7.100485	3.381738	4.536309	0.479773	2.575034	9.348509	5.224345	2.41152	5.081476
	40	2.252842	3.471613	5.778285	6.61133	2.760068	0.588098	1.402047	2.154394	9.933165
	45	7.136206	3.520737	4.686782	4.728868	2.367512	7.322079	2.776075	2.449007	3.742076
	50	3.885607	3.589475	6.493801	8.907767	2.49664	5.317926	9.867086	2.226536	7.956146

Fonte: O autor (2018)

		Todos os dias			Dias da semana			Fim de semana		
Neurônios por camada		MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE
15	5	0.293105	3.436074	6.4413	7.104344	2.546386	4.078818	1.167093	2.10311	2.013037
	10	2.35792	3.393398	0.863412	4.172933	2.541977	6.125242	0.359475	2.072404	2.119374
	15	2.498626	3.324466	9.760916	7.926374	2.446734	6.414721	7.802941	2.406351	5.559305
	20	5.594888	3.405826	1.035784	9.771228	2.467968	5.646154	1.902447	2.174488	3.777605
	25	4.084275	3.29334	7.739578	3.070227	2.660598	5.051674	2.764781	2.490659	5.389627
	30	5.002237	3.366393	5.990841	5.174287	2.385337	1.300146	5.442858	2.192892	0.201023
	35	5.368611	3.26712	1.62526	0.295474	2.712493	5.428263	7.636984	2.119106	3.458456
	40	5.163679	3.389563	4.748977	6.918536	2.426895	2.859282	7.188868	2.301977	2.924266
	45	2.378643	3.443975	1.998715	7.894666	2.460815	9.504536	4.16482	2.349845	0.085122
	50	8.154671	3.476815	9.698112	3.768813	2.548861	7.215097	0.330524	2.413545	1.379883
20	5	1.54271	3.38524	1.071782	4.138882	2.43545	0.169906	6.741485	2.264176	0.459921
	10	4.185237	3.387468	5.253631	4.497442	2.423257	4.103136	3.973447	2.144316	7.845684
	15	4.656744	3.41542	6.7028	1.124223	2.636639	6.773451	2.876851	2.17304	5.351027
	20	0.865321	3.336927	3.475864	3.334562	2.551383	3.622558	5.846194	2.1556	7.801594
	25	5.643303	3.479639	7.76489	3.114588	2.487163	0.388253	0.515811	2.236736	1.213164
	30	8.979569	3.403781	4.097723	7.611792	2.424666	8.41738	8.270711	2.13837	1.389947
	35	4.006709	3.331879	9.261396	8.487494	2.55711	8.040027	5.233376	2.168131	5.523011
	40	3.017136	3.456171	1.242217	8.391605	2.407533	1.803293	3.336074	2.352563	9.517058
	45	6.495085	3.545251	0.809978	6.320223	2.612004	3.243323	9.742244	2.23875	0.240583
	50	8.306263	3.344588	3.295837	6.741219	2.446045	9.12402	4.376017	2.297618	4.506538
25	5	6.429552	3.489724	1.710016	0.841164	2.578389	7.718787	6.032172	2.171418	2.213573
	10	9.849304	3.451707	0.621095	4.985865	2.464723	3.365903	1.685955	2.250414	6.954622
	15	8.322108	3.306092	8.633773	7.56984	2.625968	3.965533	9.389756	2.24701	8.033889
	20	1.057355	3.533473	6.671755	4.423144	2.589554	0.493618	5.232329	2.129938	3.327033
	25	8.613364	3.383456	7.607364	4.058121	2.505194	2.550012	0.613683	2.242034	4.66832
	30	3.662098	3.463779	2.326383	0.340778	2.523551	0.572837	3.680291	2.358264	3.395561
	35	6.711108	3.446743	3.524863	9.371629	2.600202	2.196747	7.514136	2.222405	1.985032
	40	9.733404	3.424459	1.181652	7.00552	2.524358	4.647697	7.819357	2.368199	7.541418
	45	3.089497	3.549068	9.793344	9.245605	2.548582	7.858607	2.44639	2.227409	5.918643
	50	3.103702	3.383332	4.624707	4.946686	2.515336	2.704892	5.880433	2.378045	0.014477
30	5	9.700338	3.545612	5.406855	4.948387	2.506041	7.360171	7.540972	2.166901	7.518693
	10	6.565343	3.33138	0.993479	6.947049	2.394679	3.756573	7.402907	2.17629	2.704925
	15	0.967349	3.413892	6.953756	9.497168	2.463774	3.704802	0.430979	2.42473	9.049545
	20	6.073929	3.495457	4.51815	9.620649	2.496792	2.552133	3.410955	2.287009	2.127408
	25	2.349781	3.30115	4.764165	0.157681	2.417997	3.512123	9.464457	2.304604	3.285515
	30	0.420385	3.421161	7.504343	4.151709	2.406518	0.430807	4.485711	2.446541	8.028218
	35	7.13528	3.519162	3.021238	7.466335	2.519281	8.346067	3.664046	2.475314	8.041058
	40	1.414698	3.392798	6.543038	0.675819	2.444345	4.52531	1.201058	2.316369	1.01195
	45	2.940715	3.390181	2.769196	5.006668	2.647602	0.744627	0.964541	2.460062	7.478951
	50	7.774782	3.52383	1.464538	8.633239	2.473774	6.006031	7.749597	2.338225	5.170247
35	5	0.818008	3.448963	4.698334	1.803667	2.44263	0.756389	6.746441	2.209272	0.870227
	10	0.869702	3.466568	4.936727	7.002653	2.525943	5.672606	0.060241	2.172245	5.984888
	15	6.048755	3.480256	9.508397	3.592454	2.4468	4.021263	5.427598	2.226014	6.842792
	20	5.45532	3.359881	4.888748	3.156088	2.434717	8.22262	8.903901	2.253103	8.14724
	25	1.734686	3.57492	3.375651	9.682692	2.583416	0.092049	2.7576	2.266987	3.339883
	30	4.680059	3.429753	8.725137	0.743744	2.503392	9.977935	7.538187	2.175245	4.171724
	35	4.867697	3.592976	6.961462	4.73135	2.477633	1.056176	7.889244	2.453739	1.969701
	40	6.317028	3.383367	3.895276	4.093704	2.465631	0.385316	3.521884	2.283584	4.418622
	45	8.716216	3.472425	4.181701	4.348337	2.556767	8.660234	2.788389	2.249355	2.270867
	50	4.367368	3.509556	8.544467	3.08923	2.522795	6.981614	5.969153	2.296545	4.450428

		Todos os dias			Dias da semana			Fim de semana		
Neurônios por camada		MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE
40	5	1.254812	3.513637	4.574365	7.115267	2.448205	6.376635	7.713156	2.279448	0.764176
	10	9.910093	3.380424	1.412616	3.161987	2.477205	2.279042	6.272094	2.303816	5.142054
	15	5.200202	3.424955	6.878678	9.535919	2.559997	8.455679	9.09827	2.201686	2.862134
	20	7.807738	3.39285	2.30763	4.537387	2.550866	6.537709	8.30569	2.296358	9.433895
	25	0.227852	3.407813	6.123618	7.914848	2.511589	2.36671	4.460981	2.254401	3.177315
	30	8.04966	3.509658	8.702678	2.189595	2.557547	0.422683	0.656867	2.372126	7.672612
	35	8.474584	3.447882	8.111785	7.691107	2.497471	7.471128	9.380867	2.201052	0.864171
	40	6.79926	3.565922	2.712695	0.135321	2.444319	5.755369	8.884814	2.299523	7.07802
	45	8.861834	3.574945	7.800987	7.165789	2.512171	6.524663	4.1433	2.321891	7.078795
	50	6.577673	3.473048	9.318718	7.335437	2.519267	1.971581	6.838686	2.580848	0.144531
45	5	9.02596	3.437462	3.158596	0.590303	2.575561	0.319484	0.168	2.283568	7.231234
	10	1.797443	3.327276	0.396813	1.499619	2.494044	7.243089	0.966785	2.274746	9.517966
	15	9.589875	3.443586	2.96502	2.713689	2.508671	1.020322	1.558619	2.169236	3.661728
	20	4.400155	3.429615	0.854195	5.923142	2.490111	9.858866	9.638705	2.245788	3.794338
	25	0.273356	3.477221	2.637864	1.862279	2.645176	5.090855	2.954311	2.329021	5.117272
	30	5.506556	3.513388	2.600393	9.960995	2.552862	2.458508	2.961478	2.331162	9.068205
	35	9.058629	3.546566	3.113039	7.541062	2.603118	2.498288	7.503912	2.239847	7.603598
	40	7.724011	3.496478	6.166145	2.038305	2.521653	4.302299	1.421513	2.578467	8.667953
	45	1.47035	3.502254	9.412612	9.972445	2.539274	3.584119	3.212167	2.223444	3.889253
	50	2.56751	3.571223	4.21474	9.71565	2.540605	6.814849	6.251677	2.466721	2.121809
50	5	7.376542	3.529986	4.925715	5.307112	2.504485	5.373733	7.08812	2.364824	9.091955
	10	3.704411	3.47303	4.619785	9.435317	2.517673	5.527094	9.224294	2.231225	7.951605
	15	9.50256	3.481954	6.27267	4.820646	2.461837	9.239091	7.050154	2.284019	8.275402
	20	1.356095	3.491843	5.731076	4.183714	2.56105	6.237806	6.783664	2.240021	1.370286
	25	2.430872	3.508324	3.309556	7.925052	2.537448	0.21292	6.197996	2.261635	2.860724
	30	7.320215	3.469895	3.363552	7.009401	2.607	9.839234	8.649549	2.304665	9.059298
	35	2.523806	3.424227	8.333356	8.384301	2.546972	4.44154	5.588	2.229903	6.666411
	40	8.850926	3.454985	1.676266	2.518257	2.518442	6.978843	0.224952	2.232487	2.726033
	45	7.79016	3.581506	1.966473	3.769674	2.534969	3.013526	0.528889	2.295244	0.622009
	50	3.155183	3.568187	2.412404	1.135376	2.69141	6.325585	3.474975	2.454619	3.799079

Fonte: O autor (2018)

Para melhor visualização dos resultados obtidos das simulações da RNA, criou-se as Tabelas 6 e 7 que comparam os erros percentuais (MAPE) obtidos, sendo que os valores em amarelo são os maiores dentre os obtidos e os azuis os menores. Na última linha da tabela está demonstrado a variação de pontos percentuais para cada configuração.

Tabela 6 - Comparativo dos Resultados das Simulações de Uma Camada

	Todos os dias	Dias da semana	Fim de semana
Neurônios	MAPE	MAPE	MAPE
10	3.078172		
35	3.536811		
20		2.387345	
5		2.615994	
5			2.086631
45			2.373981
Δ p.p.	0.458639	0.228649	0.28735

Fonte: O autor (2018)

Tabela 7 - Comparativo dos Resultados das Simulações de Duas Camadas

		Todos os dias	Dias da semana	Fim de semana
Neurônios por camada		MAPE	MAPE	MAPE
5	35	3.171704		
35	35	3.592976		
5	35		2.267943	
10	40		2.760068	
15	10			2.072404
10	20			2.613771
Δ p.p.		0.421272	0.492125	0.541367

Fonte: O autor (2018)

Observa-se que os resultados apresentados mostram um erro percentual abaixo de 3.6%, sendo o menor deles 2.072404% para finais de semana utilizando duas camadas intermediárias na rede neural e o maior foi de 3.592976% considerando todos os dias, também utilizando duas camadas intermediárias. Isto evidencia que as simulações foram bem conduzidas e que, realmente os atributos analisados influenciam na previsão da demanda de energia elétrica. É possível notar também a estabilidade das simulações, visto que a variação de pontos percentuais para cada configuração não passa de 0.541367%, no caso em que encontramos o menor erro percentual.

Com o objetivo de avaliar os resultados, simulou-se mais 15 vezes as redes neurais que, dentro das estruturas destacadas acima, apresentaram o menor erro percentual, tanto para uma ou duas camadas intermediárias. As Tabelas 8 e 9 expressam os valores do MAPE encontrados para as novas simulações.

Tabela 8 - Resultado das Simulações de Validação com Uma Camada

Testes	Todos os dias		Dias da semana		Fim de semana	
	Neurônios	MAPE	Neurônios	MAPE	Neurônios	MAPE
1	10	3.461483	10	2.591999	5	2.158186
2	10	3.267392	10	2.569096	5	2.070918
3	10	3.234213	10	2.703143	5	2.082715
4	10	3.300063	10	2.623493	5	2.228958
5	10	3.29838	10	2.632797	5	2.097413
6	10	3.371784	10	2.589198	5	2.072227
7	10	3.392477	10	2.555362	5	2.113899
8	10	3.178371	10	2.684499	5	2.115075
9	10	3.392825	10	2.667531	5	2.075716
10	10	3.179274	10	2.765052	5	2.132538
11	10	3.166217	10	2.738394	5	2.197217
12	10	3.263957	10	2.694906	5	2.091156
13	10	3.326674	10	2.609511	5	2.15682
14	10	3.230018	10	2.705563	5	2.101318
15	10	3.148401	10	2.575761	5	2.078296

Fonte: O autor (2018)

Tabela 9 - Resultado das Simulações de Validação com Duas Camadas

Testes	Todos os dias			Dias da semana			Fim de semana		
	Neurônios		MAPE	Neurônios		MAPE	Neurônios		MAPE
	1ª camada	2ª camada		1ª camada	2ª camada		1ª camada	2ª camada	
1	5	35	3.331007	5	35	2.450459	15	10	2.27476
2	5	35	3.462295	5	35	2.459621	15	10	2.17706
3	5	35	3.429934	5	35	2.538528	15	10	2.121321
4	5	35	3.344146	5	35	2.552518	15	10	2.166927
5	5	35	3.537909	5	35	2.649281	15	10	2.096609
6	5	35	3.172738	5	35	2.446675	15	10	2.138233
7	5	35	3.207552	5	35	2.710262	15	10	2.126002
8	5	35	3.416447	5	35	2.594581	15	10	2.140773
9	5	35	3.367359	5	35	2.490162	15	10	2.235887
10	5	35	3.366699	5	35	2.691186	15	10	2.29655
11	5	35	3.540458	5	35	2.751133	15	10	2.261571
12	5	35	3.168372	5	35	2.87422	15	10	2.220512
13	5	35	3.410553	5	35	2.852327	15	10	2.232711
14	5	35	3.453656	5	35	2.811061	15	10	2.168457
15	5	35	3.331933	5	35	2.618006	15	10	2.194666


Fonte: O autor (2018)

A partir dos resultados expostos nas Tabelas 8 e 9, nota-se que nem todas as estruturas conseguiram atingir o mesmo erro percentual das Tabelas 6 e 7, porém, seus valores estiveram entre os valores máximos e mínimos da primeira simulação. É possível observar também uma padronização dos resultados, mesmo após essas 15 simulações. Isto

demonstra que as variáveis simuladas realmente influenciaram na precificação das ações e os resultados obtidos foram consistentes.


A seguir, estão apresentados gráficos de comparação para as três configurações, tanto para uma como duas camadas intermediárias. Estes são gráficos de validação, nos quais foram utilizadas as amostras de testes da rede neural que apresentou menor MAPE dentre as 15 simulações efetuadas, e que compara a saída desejada da rede neural com a saída real. É possível notar que existe uma diferença muito pequena entre as duas linhas, indicando a consistência das simulações.

Figura 9 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Todos os Dias e Uma Camada Intermediária




Fonte: O autor (2018)

Figura 10 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Todos os Dias e Duas Camadas Intermediárias




Fonte: O autor (2018)

Figura 11 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Dias da Semana e Uma Camada Intermediária




Fonte: O autor (2018)

Figura 12 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Dias da Semana e Duas Camadas Intermediárias




Fonte: O autor (2018)

Figura 13 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Finais de Semana e Uma Camada Intermediária



Fonte: O autor (2018)

Figura 14 - Comparação Entre Saída Desejada da Rede Neural com a Saída Real – Considerando Finais de Semana e Duas Camadas Intermediárias



Fonte: O autor (2018)

4. CONCLUSÃO

O objetivo deste trabalho foi estudar o impacto de variáveis climatológicas na previsão da demanda de energia elétrica no estado de Ontario no Canadá. Para isto, foi proposto o uso da mineração de dados combinada com ferramentas de sistemas inteligentes, através do algoritmo de Levenberg-Marquadt. Assim, os dados foram organizados no formato de séries temporais, para que fossem processados corretamente pelas ferramentas.

Na fase de seleção de atributos através do WEKA, foi possível observar que as variáveis que mais influenciavam na demanda de energia elétrica era a própria demanda, de maneira ordenada, tendo o dia anterior como maior influência. Além disso, notou-se que as temperaturas do dia da predição também apareceram como impactantes.

Cabe comentar que os resultados foram estáveis, com diferenças não maiores de 0.56% entre o erro máximo e mínimo para cada caso e que a utilização de duas camadas intermediárias ao invés de uma não alterou de maneira significativa os resultados. É possível perceber que os erros para as duas configurações da rede neural foram similares, demonstrando que, nesse caso, não há vantagem em utilizar uma rede mais complexa como a de duas camadas devido ao fato de ela exigir um esforço computacional maior. Além disso, os testes de consistências e os gráficos apresentados comprovaram que as estruturas de redes produziram resultados legítimos, indicando que as variáveis climáticas podem ser utilizadas para o estudo de previsibilidade de demanda de energia elétrica.

REFERÊNCIAS

- ABREU, Thays et al. Previsão de Cargas Elétrica Através de um Modelo Híbrido de Regressão com Redes Neurais Artificiais. **Simpósio Brasileiro de Sistemas Elétricos**. Goiânia - GO, 2012. Disponível em: <<http://www.swge.inf.br/anais/sbse2012/PDFS/ARTIGOS/96814.PDF>>. Acesso em: 22 mai. 2018.
- AMJADY, N.; HEMMATI, M.. Energy Price Forecasting: Problems and Proposals for such Predictions. **IEEE Power & Energy Magazine**, v. 24, p. 20-29, 2006.
- AMJADY, Nima; KEYNIA, Farshid. Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm. **IEEE Transactions on Power Systems**, v. 24, p. 306-318, 2009. Disponível em: <<http://eps.upo.es/troncoso/Citas/IEEE07/citaIEEE07-7.pdf>>. Acesso em: 13 mai. 2016.
- BARBOSA, Anderson Henrique. **Análise de Confiabilidade Estrutural Utilizando o Método de Monte Carlo e Redes Neurais**. Ouro Preto, 2004. 143p Dissertação (Engenharia Civil) - Universidade Federal de Ouro Preto, 2004. Disponível em: <http://www.repositorio.ufop.br/bitstream/123456789/6557/1/DISSERTA%C3%87%C3%83O_An%C3%A1liseConfiabilidadeEstrutural.pdf>. Acesso em: 22 mai. 2018.
- BORDIGNON, Sérgio. **Metodologia Para Previsão de Carga de Curtíssimo Prazo Considerando Variáveis Climáticas e Auxiliando na Programação de Despacho de Pequenas Centrais Hidrelétricas**. Alegrete, 2012 Dissertação (Engenharia Elétrica) - FUNDAÇÃO UNIVERSIDADE FEDERAL DO PAMPA - UNIPAMPA, 2012. Disponível em: <http://cursos.unipampa.edu.br/cursos/ppgee/files/2010/03/bordignon_dissertation.pdf>. Acesso em: 22 mai. 2018.
- BRAGA, Douglas de Oliveira Matos. **Previsão de Cargas Elétricas a Curto Prazo por Combinação de Previsões via Regressão Simbólica**. Juiz de Fora - MG, 2017. 74 p Dissertação (Modelagem Computacional) - UNIVERSIDADE FEDERAL DE JUIZ DE FORA, 2017. Disponível em: <<https://repositorio.ufjf.br/jspui/bitstream/ufjf/6093/1/douglasdeoliveiramatosbraga.pdf>>. Acesso em: 19 mai. 2018.
- DA SILVA, Ivan Nunes; FLAUZINO, Rogério Andrade; SPATTI, Danilo Hernane. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**: Curso Prático. Artliber, 2010. 399 p.
- DAMASCENO, Marcelo. Introdução a Mineração de Dados Utilizando o Weka. **Connepi**. 2010. Disponível em: <<http://connepi.ifal.edu.br/ocs/index.php/connepi/CONNEPI2010/paper/viewFile/258/207>>. Acesso em: 20 mai. 2018.
- FAYYAD, Usama; PIATETSKY-SHAPIO, Gregory; SMYTH, Padhraic. From Data Mining to Knowledge Discovery in Databases. **American Association for Artificial Intelligence**. 1996. 18 p. Disponível em: <<https://www.aaai.org/ojs/index.php/aimagazine/article/viewFile/1230/1131>>. Acesso em: 20 mai. 2018.

FERREIRA, Ricardo Vieira. **Previsão de Demanda: Um Estudo de Caso para o Sistema Interligado Nacional**. Belo Horizonte - MG, 2006. 142 p Dissertação (Engenharia Elétrica) - UNIVERSIDADE FEDERAL DE MINAS GERAIS, 2006. Disponível em: <<https://www.ppgee.ufmg.br/defesas/417M.PDF>>. Acesso em: 23 mai. 2018.

FILHO, Kenji Nose. **Previsão de Carga Multinodal Utilizando Redes Neurais de Regressão Generalizada**. Ilha Solteira - SP, 2011. 92 p Dissertação (Engenharia Elétrica) - UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO, 2011. Disponível em:<https://repositorio.unesp.br/bitstream/handle/11449/87097/nosefilho_k_me_ilha.pdf?sequence=1&isAllowed=y>. Acesso em: 20 mai. 2018.

GARCÍA-MARTOS, C.; RODRÍGUEZ, J.; SÁNCHEZ, M. J.. Forecasting Electricity Prices by Extracting Dynamic Common Factors: Application to the Iberian Market. **IET Generation, Transmission & Distribution**, v. 6, p. 11-20, 2012.

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. Hamilton, Ontario, Canada: Pearson Education, 2009. 823 p.

KIRA, Kenji; RENDELL, Larry A. The Feature Selection Problem: Traditional Methods and a New Algorithm. **The Association for the Advancement of Artificial Intelligence**. 1992. 6 p. Disponível em: <<https://www.aaai.org/Papers/AAAI/1992/AAAI92-020.pdf>>. Acesso em: 22 mai. 2018.

LABOISSIERE, Leonel Alejandro. **Estimação do Preço de Ações de Concessionárias de Energia Elétrica Brasileiras Por Meio de Redes Neurais Artificiais**. São Carlos - SP, 2013. 59 p TCC (Engenharia Elétrica) - UNIVERSIDADE DE SÃO PAULO, 2013. Disponível em:<<http://www.tcc.sc.usp.br/tce/disponiveis/18/180500/tce-20012014-113631/?&lang=br>>. Acesso em: 22 mai. 2018.

LEITE, Lucas de Oliveira Garrigós. **Mineração de Dados Aplicada à Previsão do Preço de Ações de Concessionárias de Energia Elétrica do Estado de São Paulo**. São Carlos - SP, 2016. 39 p TCC (Engenharia Elétrica) - UNIVERSIDADE DE SÃO PAULO, 2016. Disponível em:<<http://www.tcc.sc.usp.br/tce/disponiveis/18/180450/tce-06012017-173713/?&lang=br>>. Acesso em: 22 mai. 2018.

MANDAL, P.; SRIVASTAVA, A.; PARK, J-W.. An Effort to Optimize Similar Days Parameters For ANN-Based Electricity Price Forecasting. **IEEE Transactions on Industry Applications**, v. 45, p. 1888-1896, 2009.

MOHNSENIAN-RAD, A-H.; LEON-GARCIA, A.. Optimal Residential Load Control with Price Prediction in Real-Time Electricity Pricing Environments. **IEEE Transactions on Smart Grid**, v. 1, p. 120-133, 2010.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. Sistemas e Modelos Computacionais: Visao Geral. **Procedimentos de Rede**. 2016. Disponível em:<<http://www.ons.org.br/%2FProcedimentosDeRede%2FM%C3%B3dulo%2018%2FSubm%C3%B3dulo%2018.1%2FSubm%C3%B3dulo%2018.1%202016.12.pdf>>. Acesso em: 22 mai. 2018.

PIRES, Camilla Leimann. **Metodologia para Previsão de Carga e Geração no Horizonte de Curtíssimo Prazo**. Santa Maria - RS, 2016. 98 p Dissertação (Engenharia Elétrica) - UNIVERSIDADE FEDERAL DE SANTA MARIA, 2016. Disponível

em:<<http://repositorio.ufsm.br/bitstream/handle/1/8601/PIRES%2c%20CAMILLA%20LEIMANN.pdf?sequence=1&isAllowed=y>>. Acesso em: 20 mai. 2018.

SILVA, Marcelino Pereira dos Santos. **Mineração de Dados - Conceitos, Aplicações e Experimentos com Weka**. Belo Horizonte - MG, 2004 Monografia - UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/erirjes/2004/004.pdf>>. Acesso em: 21 mai. 2018.

SOARES, Anderson da Silva. **Predição de Séries Temporais Econômicas por Meio de Redes Neurais Artificiais e Transformada Wavelet**: Combinando Modelo Técnico e Fundamentalista. São Carlos - SP, 2008. 92 p Dissertação (Engenharia Elétrica) - Universidade de São Paulo, 2008. Disponível em:<<http://www.teses.usp.br/teses/disponiveis/18/18152/tde-11042008-111842/pt-br.php>>. Acesso em: 20 mai. 2018.

SPOLAÔR, Newton. **Seleção de Atributos para Aprendizado Multirótulo**. São Carlos - SP, 2014 Tese (Ciências de Computação e Matemática Computacional) - UNIVERSIDADE DE SÃO PAULO, 2014. Disponível em:<<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-25032015-160505/pt-br.php>>. Acesso em: 20 mai. 2018.

WEATHER UNDERGROUND. **Weather Underground**. Disponível em:<<https://www.wunderground.com/>>. Acesso em: 22 set. 2016.

WEKA. Weka 3: Data Mining Software in Java. **WEKA The University of Waikato**. Waikato. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 16 jan. 2017.

WIKIMEDIA COMMONS. **WikiMedia Commons**. 2018. Disponível em:<https://www.researchgate.net/figure/Figura-2-Processos-da-descoberta-de-conhecimento-em-base-de-dados-Na-figura-2-estao_fig2_318841394>. Acesso em: 20 mai. 2018.