

UNIVERSIDADE DE SÃO PAULO – USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

Maristela Silva dos Santos

**Desenvolvimento de Estimador de Preço e Demanda de
Energia Elétrica Baseado em Sistemas Inteligentes
aplicado para Smart Grids**

São Carlos

2016

UNIVERSIDADE DE SÃO PAULO – USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

Maristela Silva dos Santos

**Desenvolvimento de Estimador de Preço e Demanda de
Energia Elétrica Baseado em Sistemas Inteligentes
aplicado para Smart Grids**

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

Curso de Engenharia Elétrica com ênfase em Sistemas
de Energia e Automação.

Orientador: Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos

2016

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.

S237d Silva dos Santos, Maristela
Desenvolvimento de Estimador de Preço e Demanda de
Energia Elétrica Baseado em Sistemas Inteligentes
aplicado para Smart Grids / Maristela Silva dos
Santos; orientador Ricardo Augusto Souza Fernandes.
São Carlos, 2016.

Monografia (Graduação em Engenharia Elétrica com
ênfase em Sistemas de Energia e Automação) -- Escola de
Engenharia de São Carlos da Universidade de São Paulo,
2016.

1. estimação do preço da energia elétrica. 2.
estimação da demanda de energia elétrica. 3. sistemas
inteligentes. I. Título.

FOLHA DE APROVAÇÃO

Nome: Maristela Silva dos Santos

Título: “Desenvolvimento de estimador de preço e demanda de energia elétrica baseado em sistemas inteligentes aplicado para Smart Grids”

Trabalho de Conclusão de Curso defendido e aprovado
em 28 / 11 / 2016,

com NOTA 10,0 (Dez , Zero), pela Comissão Julgadora:

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

Prof. Associado Rogério Andrade Flauzino - SEL/EESC/USP

Prof. Dr. Arlindo Neto Montagnoli - UFSCar

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado José Carlos de Melo Vieira Júnior

*Dedico este trabalho aos meus pais,
cujo amor e sacrifício são a base da
minha existência.*

Agradecimentos

Aos meus pais, agradeço pelo amor e generosidade incondicionais. À minha irmã, por ser minha melhor amiga e fonte segura de apoio. Ao meu primo, pela irmandade e por acreditar nos meus sonhos comigo. Ao meu orientador. À Escola de Engenharia de São Carlos e aos seus colaboradores, agradeço a oportunidade e a estrutura fornecidas. Aos professores que tive ao longo da vida, que me fizeram acreditar em mim mesma e me ensinaram que a Educação é um instrumento de luta e transformação. Aos amigos da Engenharia Elétrica e da Engenharia de Computação, que levarei para a vida, especialmente à Luana, Pedro, Diana, Érica e Mayara, que dividiram as madrugadas de sorrisos, de cansaço e de estudos. E por fim, ao Daniel Manulak, por se fazer presente e por me inspirar a ser minha melhor versão.

Resumo

SANTOS, M. S., **Desenvolvimento de Estimador de Preço e Demanda de Energia Elétrica Baseado em Sistemas Inteligentes aplicado para Smart Grids**. Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

O Mercado Livre de Energia Elétrica emergiu para estimular a competição e reduzir os custos com a eletricidade. Os Consumidores Livres podem negociar os termos dos contratos de compra de energia, bem como quem será seu fornecedor. Dentre os benefícios deste ambiente, pode-se citar o poder de decisão, a redução de custos, a sustentabilidade e a previsibilidade orçamentária. Neste contexto, a previsão do preço e da demanda da energia elétrica é um assunto bastante estudado, principalmente por permitir maior assertividade no planejamento energético. Esta monografia tem como objetivo principal a implementação de metodologias baseadas em Redes Neurais Artificiais (RNA) com o intuito de se obter estimações tanto de preço quanto de demanda da energia elétrica. Além disso, este trabalho visa a identificação de atributos que sejam relevantes para estes estimadores. Por fim, verificam-se os desempenhos das ferramentas desenvolvidas frente ao horizonte de estimação de curto prazo.

Palavras-chave: Estimação do preço da energia elétrica, estimação da demanda de energia elétrica, sistemas inteligentes.

Abstract

SANTOS, M. S., “**Development of an Estimator for Electricity Price and Demand Based on Smart Systems Applied to Smart Grids**”. Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

The Free Energy Market has emerged in order to encourage competition and also reduce the cost of electricity. Free consumers are able to freely negotiate the terms of their electricity contracts, as well as choose their energy supplier. The benefits of this market include cost reduction, budget predictability, decision making power, and sustainability. As such, the electricity price and demand forecasts are a subject well studied in the literature, mainly because it can lead to more assertive energy planning. The main objective of this work is to implement a methodology based on Artificial Neural Networks (ANN) to estimate both the electricity price and demand. In addition, the attributes that are relevant for this matter will be identified. Lastly, these tools' performances will be evaluated.

Key words: Energy price forecasting, demand forecasting, smart systems.

Lista de Ilustrações

Figura 1: Série temporal da demanda de energia elétrica durante o ano de 2007.	27
Figura 2: Série temporal da demanda de energia elétrica durante o ano de 2007.	28
Figura 3: Série temporal da demanda de energia elétrica durante o ano de 2009.	28
Figura 4: Série temporal da demanda de energia elétrica durante o ano de 2010.	29
Figura 5: Série temporal da demanda de energia elétrica durante o ano de 2011.	29
Figura 6: Série temporal do preço da energia elétrica durante o ano de 2007.	30
Figura 7: Série temporal do preço da energia elétrica durante o ano de 2008.	30
Figura 8: Série temporal do preço da energia elétrica durante o ano de 2009.	31
Figura 9: Série temporal do preço da energia elétrica durante o ano de 2010.	31
Figura 10: Série temporal do preço da energia elétrica durante o ano de 2011.	32
Figura 11: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2007.	33
Figura 12: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2008.	33
Figura 13: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2009.	34
Figura 14: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2010.	34
Figura 15: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2011.	35
Figura 16: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2007.	35
Figura 17: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2008.	36

Figura 18: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2009.	36
Figura 19: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2010.	37
Figura 20: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2011.	37
Figura 21: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2007.	38
Figura 22: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2008.	38
Figura 23: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2009.	39
Figura 24: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2010.	39
Figura 25: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2011.	40
Figura 26: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2007.	40
Figura 27: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2008.	41
Figura 28: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2009.	41
Figura 29: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2010.	42
Figura 30: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2011.	42
Figura 31: Representação de um neurônio artificial comparado a um biológico [30]	51

Lista de Tabelas

Tabela 1: Dados organizados após a etapa de pré-processamento.....	45
Tabela 2: Resultados obtidos pelo algoritmo CFS considerando a estimação da demanda de energia elétrica.....	47
Tabela 3: Resultados obtidos pelo algoritmo CFS considerando a estimação do preço da energia elétrica.....	47
Tabela 4: Resultados obtidos pelo algoritmo RELIEF considerando a estimação da demanda de energia elétrica.....	48
Tabela 5: Resultados obtidos pelo algoritmo RELIEF considerando a estimação do preço da energia elétrica.....	49
Tabela 6: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar a demanda de energia elétrica.	54
Tabela 7: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar o preço da energia elétrica.	54
Tabela 8: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar a demanda de energia elétrica.....	55
Tabela 9: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS	55

Lista de Siglas

ACL - Ambiente de Contratação Livre

ACP - Análise por Componente Principal

ARIMA - Modelo Auto-Regressivo Integrado de Média Móvel

CAD - Dólar Canadense

CFS - Correlation-based Feature Selection

EAMP - Erro Absoluto Médio Percentual

GARCH - Generalized AutoRegressive Conditional Heteroskedasticity

IF - Informação Mútua

MAPE - Mean Absolute Percentage Error

MLP - Multilayer Perceptron

PJM - Pensilvânia - Nova Jersey - Maryland

RNA - Rede Neural Artificial

Sumário

1.	Introdução	21
1.1.	Panorama Geral e Motivação.....	21
1.2.	Metodologia.....	23
1.3.	Objetivos	24
1.4.	Estrutura do Trabalho.....	25
2.	Análise Estatística dos Dados.....	26
2.1.	Introdução.....	26
2.2.	Fundamentos de séries temporais	26
2.3.	Séries temporais das demandas e preços da energia elétrica	27
2.4.	Distribuições de probabilidade	32
3.	Pré-Processamento de Dados e Análise de Relevância dos Atributos.....	44
3.1.	Pré-processamento dos dados.....	45
3.2.	Seleção de atributos	46
3.3.	Resultados obtidos por meio da seleção de atributos	47
4.	Fundamentos de Sistemas Inteligentes.....	50
4.1.	Redes Neurais Artificiais	50
4.2.	Sistemas Neuro-Fuzzy.....	52
5.	Resultados e Discussões	53
5.1.	Resultados Obtidos Considerando Algoritmo Cfs.....	53
5.2.	Resultados Obtidos Considerando Algoritmo <i>Relief</i>	55
6.	Conclusões.....	56
7.	Referências Bibliográficas.....	57

1. Introdução

1.1. Panorama Geral e Motivação

A energia elétrica possui um papel crucial no desenvolvimento de um país, pois, influencia diretamente muitos setores da sociedade. Atualmente, a energia elétrica é comercializada como qualquer outra *commodity*, entretanto, é importante destacar suas peculiaridades. Neste sentido, pode-se destacar sua alta volatilidade, a qual está atrelada à sua dependência a diversos outros fatores, a saber: preço do combustível, variações na geração hidroelétrica, crescimento econômico do país, histórico de preços e de demanda da energia elétrica [1].

Além dos fatores supracitados, 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 [2]. É importante destacar que, diferente de outras commodities, ela não pode ser armazenada. Portanto, a oferta deve satisfazer a demanda de energia elétrica dos consumidores no momento em que for exigida [1]-[5].

Assim, uma boa estimação do preço da energia elétrica pode propiciar vantagens econômicas para o comprador (seja este uma concessionária de energia elétrica ou uma indústria), pois reduz os custos relacionados à energia elétrica, e consequentemente maximiza o lucro.

Em conformidade com o contexto previamente mencionado e tendo como base um cenário de alta instabilidade, a estimacão do preço da energia elétrica tem motivado diversas pesquisas [6-10], as quais podem ser baseadas tanto em métodos convencionais como em métodos inteligentes de estimacão. Desta forma, é possível notar que grande parte destes métodos fazem uso de ferramentas de auto-regressão [11], regressão dinâmica [12-13] e modelos auto-regressivos como o ARIMA [14] e o GARCH [15].

Dentre os métodos que se baseiam em ferramentas inteligentes, pode-se destacar a pesquisa realizada por [1], onde os autores empregam um algoritmo neuro-evolutivo em combinacão com uma ferramenta de seleçao de atributos, sendo a última baseada na técnica da Informacão Mútua (MI - *Mutual Information*). Nesta pesquisa, os autores utilizaram dados reais do mercado de energia da Pensilvânia-Nova Jersey-Maryland (PJM) e do mercado de energia espanhol. Os resultados obtidos

apresentaram significantes melhora quando comparados com a pesquisa realizada por [2], a qual emprega RNAs junto com o método dos dias similares.

Já em [4], os autores analisaram o preço da energia no Mercado Ibérico. Cabe comentar que tal análise foi feita com base nos modelos de Peña-Box e de Lee-Carter. A análise realizada nesta pesquisa considera a característica multivariável dos dados. Assim, empregou-se a Análise por Componentes Principais (PCA - *Principal Component Analysis*) para que houvesse a redução de dimensionalidade dos dados. Os resultados obtidos por esta metodologia foram considerados mais satisfatórios do que aqueles obtidos por [16], cujo método adotado não considera a característica multivariável dos dados, isto é, os dados são analisados a cada hora de forma isolada.

Os resultados obtidos em [17] demonstram que quando são empregados apenas métodos estatísticos na previsão da demanda, os resultados obtidos não são tão precisos. Em suma, o baixo desempenho está atrelado à não regularidade da demanda. Por outro lado, embora métodos inteligentes de previsão apresentem resultados mais satisfatórios quando comparados com a análise estatística pura, ainda existem alguns obstáculos, tais como a dificuldade de parametrização [18].

Já em [19], os autores desenvolveram um método para previsão de demanda no contexto de *smart grids*. Esta metodologia baseia-se em técnicas de agregação *top-down* para fazer composições individuais da demanda com o intuito de se obter a previsão global da demanda.

Por outro lado, em [6], desenvolveu-se uma técnica que define e prevê a “classe” de preços ao invés de valores pontuais. Os autores ressaltam que em algumas aplicações, como em um cenário de *smart grids*, não é necessário saber o valor exato da energia e sim, se ela está dentro de alguns limites (classes) ou não. Utilizou-se dados de Nova Iorque, Ontário e Alberta. E testaram-se combinações de diferentes métodos de seleção e classificação de atributos. Os seletores de atributos empregados foram o algoritmo *Relief* (que atribui uma relevância ponderada para cada atributo, cujo o propósito é denotar a relevância do atributo), o algoritmo CFS (*Correlation-based Feature Selection*) que classifica os subconjuntos de atributos de acordo com medidas de avaliação de correlação e, por último, o seletor de Informação Mútua (MI) que mede a independência mútua de duas variáveis aleatórias. Dentre os classificadores, usou-se uma Árvore de Decisão, um classificador Bayesiano e uma RNA do tipo MLP (*Multilayer Perceptron*). A comparação dos resultados numéricos

apontou o CFS como o melhor seletor de atributos e o classificador Bayesiano como mais preciso.

Em visto disso, pode-se notar que diversos países têm investido em ferramentas para a estimação de preço e/ou demanda da energia elétrica, as quais visam aprimorar o sistema, tornando-o mais confiável, seguro, inteligente e a um custo mais baixo [5].

No Brasil, há expectativa de que as regras de negociação dos contratos no mercado de energia firmados no Ambiente de Contratação Livre (ACL) sofrerão importantes modificações, pois, a portaria 455/2012 publicada em Agosto de 2012 pelo Ministério de Minas e Energia [20] apresenta alterações no que diz respeito às diretrizes relacionadas ao registro de contratos de compra e venda da energia. Deste modo, verifica-se que esta portaria passa a estabelecer que as contratações de energia deverão ser registradas semanalmente antes que haja o efetivo consumo da mesma. Além disso, torna possível a alteração dos montantes de energia previamente contratados, desde que tais alterações sejam realizadas antes do início da semana em que a energia será entregue. Atualmente, a compra de energia é mensal, portanto, pode-se contratar a energia consumida no mês anterior. Assim, deve-se destacar que o consumidor necessitará cada vez mais de uma previsão tanto da demanda/consumo como do preço da energia elétrica com alta precisão.

1.2. Metodologia

O presente Trabalho de Conclusão de Curso utilizou a base de dados de Ontário, Canadá, os quais são disponibilizados de forma pública e, por este motivo, têm sido empregados como *benchmark* nos estudos que visam à obtenção de novos métodos aplicados à estimação de preço e/ou demanda de energia elétrica. Os dados armazenados foram avaliados com a finalidade de separá-los em conjuntos menores e então aplicar ferramentas de seleção de atributos, as quais são provenientes do software Weka.

Na sequência, é averiguado o desempenho de algumas topologias de Redes Neurais Artificiais e, por fim, são obtidos e analisados os resultados com o intuito de validar a proposta deste trabalho.

Para tanto, a metodologia empregada é composta de quatro módulos, os quais são especificados a seguir.

Módulo 1. Obtenção e Organização da Base de Dados

Neste módulo foi feita toda a aquisição e organização da base de dados de forma que estes dados pudessem ser tratados pelos seletores de atributos e pelas ferramentas inteligentes. Todos os dados foram separados por:

- todos os dias,
- dias úteis;
- feriados e finais de semana.

Módulo 2. Seleção dos Atributos mais Relevantes

Depois de separados os dados, a primeira investigação consistiu em obter os atributos mais relevantes para cada uma das separações de dados proposta no Módulo 1.

Módulo 3. Aplicação de Sistemas Inteligentes

Com base nos atributos selecionados no Módulo 2, investigam-se as topologias de redes neurais mais adequadas para processar tais informações.

Módulo 4. Obtenção e Análise de Resultados

O objetivo deste módulo é validar a metodologia proposta, onde todos os resultados obtidos por meio dos sistemas inteligentes serão devidamente analisados.

1.3. Objetivos

Os objetivos gerais deste trabalho consistem na investigação, desenvolvimento, implementação e validação de arquiteturas de seletores de atributos e sistemas inteligentes para a estimação de preço e demanda de energia elétrica. Dentro desse contexto, os objetivos do projeto de iniciação científica são pautados em cinco itens principais, apresentados a seguir:

1. Gerar uma base de dados que possa armazenar os dados históricos de preços e demandas de energia elétrica;
2. Armazenar a maior quantidade possível de atributos para que estes possam ser analisados e selecionados;

3. Aplicar ferramentas de seleção de atributos com base no software Weka;
4. Verificar o comportamento de Redes Neurais Artificiais ao processo de estimação de preço e demanda da energia elétrica.

1.4. Estrutura do Trabalho

A fim de organizar o estudo e manter uma linha de raciocínio contínuo e sintético, o documento foi fragmentado em capítulos. O Capítulo 1 apresenta um breve resumo sobre o projeto e uma revisão bibliográfica. São destacadas também as justificativas, motivações, objetivos e etapas de execução.

O Capítulo 2 mostra uma análise estatística que foi realizada sobre os dados de demanda e preço da energia elétrica. Na sequência, o Capítulo 3 destina-se a apresentar as variáveis dadas como mais relevantes pelos seletores de atributos utilizados.

O Capítulo 4 apresenta os fundamentos de Redes Neurais Artificiais e Sistemas Neuro-Fuzzy, os quais foram analisados como possíveis ferramentas a serem empregadas para a estimação do preço e/ou demanda de energia elétrica. No Capítulo 5 discutem-se os resultados obtidos por meio dos estimadores baseados em sistemas inteligentes. Por fim, o Capítulo 6 traz as conclusões em relação aos resultados obtidos pela metodologia proposta neste projeto.

2. Análise Estatística dos Dados

2.1. Introdução

Os modelos de previsão de demanda e do preço da energia são bastante difundidos no setor de energia elétrica, pois, têm papel fundamental no auxílio às tomadas de decisão. Entretanto, não existe uma técnica que possa ser aplicada a todos os modelos de previsão, ou seja, não há um modelo estatístico generalista. Mas, de fato, existem muitas técnicas distintas que podem ser empregadas no âmbito da previsão de séries temporais, onde cada uma possui suas características e desempenhos.

Portanto, nas seções subsequentes, as séries temporais tanto da demanda quanto do preço da energia elétrica são apresentados e explanados em maiores detalhes. Além disso, este capítulo visa fornecer resultados da análise estatística que foi efetuada sobre os dados, os quais serão apresentados em formatos gráficos (funções densidade de probabilidade) com o intuito de melhor demonstrar a qualidade das análises realizadas.

É importante ressaltar que todas as análises estatísticas foram realizadas por meio do conjunto de ferramentas estatísticas do software Mathworks Matlab®.

2.2. Fundamentos de séries temporais

A previsão de séries temporais corresponde a um tema de pesquisa que se destina a resolver diversos problemas, principalmente, nas áreas de meteorologia, previsão de carga em redes de computadores e análise de mercado. Destaca-se que tais aplicações sempre têm como objetivo a minimização de riscos por meio de ferramentas que auxiliem o planejamento e as tomadas de decisão dos profissionais que se encontram envolvidos a estes problemas [21].

Desta forma, destaca-se que o objetivo supracitado é óbvio ao se idealizar ferramentas voltadas à análise de mercados. Assim, faz-se necessário garantir uma boa precisão na previsão deste tipo de série temporal. Portanto, o aperfeiçoamento dos modelos de previsão é de extrema importância, conforme comentado em [22]. Neste sentido, podem-se destacar os estudos de [23] que resultaram na criação do modelo ARIMA (Modelo Auto-Regressivo Integrado de Média Móvel), o qual se tornou um método bastante empregado para previsão de séries temporais.

No entanto, ao considerar a análise do comportamento de processos ou sistemas representados por séries temporais, é comum verificar que os dados apresentam um comportamento não linear. Neste contexto, as Redes Neurais Artificiais (RNA) e os Sistemas de Inferência *Fuzzy*, podem ser considerados como um conjunto de ferramentas muito úteis para abordar tal problema.

2.3. Séries temporais das demandas e preços da energia elétrica

Nesta seção, serão apresentados os gráficos das demandas e preços de energia elétrica considerados neste projeto de iniciação científica. Assim, para uma melhor análise do comportamento destes dados, os mesmos foram divididos em anos.

Na sequência, por meio das Figuras de 1 a 5 são mostrados os gráficos de demanda para os anos de 2007 a 2011.




Figura 1: Série temporal da demanda de energia elétrica durante o ano de 2007.




Figura 2: Série temporal da demanda de energia elétrica durante o ano de 2007.




Figura 3: Série temporal da demanda de energia elétrica durante o ano de 2009.




Figura 4: Série temporal da demanda de energia elétrica durante o ano de 2010.




Figura 5: Série temporal da demanda de energia elétrica durante o ano de 2011.

Observa-se que o comportamento da demanda entre os anos de 2007 e 2011 é muito semelhante assim, é provável que uma mesma distribuição de probabilidades poderá ser empregada para todos os anos.

Já os gráficos das séries temporais que representam o preço da energia elétrica para os anos de 2007 a 2011 são mostrados por meio das Figuras de 6 a 10.




Figura 6: Série temporal do preço da energia elétrica durante o ano de 2007.




Figura 7: Série temporal do preço da energia elétrica durante o ano de 2008.




Figura 8: Série temporal do preço da energia elétrica durante o ano de 2009.




Figura 9: Série temporal do preço da energia elétrica durante o ano de 2010.




Figura 10: Série temporal do preço da energia elétrica durante o ano de 2011.

Diferentemente das séries temporais da demanda, o comportamento do preço ao longo do ano é bastante volátil. Confrontando-se os gráficos das Figuras de 6 a 10, praticamente, não se observa nenhuma regularidade. Por exemplo, em 2009, os preços apresentaram um padrão estável, tendo somente alguns picos isolados no ano. Em contrapartida, os anos de 2007 e 2008 variaram amplamente, onde podem ser observados picos de preços em meses distintos.

Em decorrência deste cenário flutuante, a previsão do preço torna-se mais complexa. Dessa forma, serão analisados os comportamentos de mais do que uma distribuição de probabilidade.

Destaca-se que os anos de 2006 e 2012 não foram considerados na análise estatística, pois, a base de dados não contempla os dados de todos os meses para estes anos. Portanto, na sequência, são mostrados os resultados obtidos por meio das distribuições de probabilidade dos dados.

2.4. Distribuições de probabilidade

Nesta seção, serão apresentados os gráficos das diferentes funções de distribuição de probabilidade testadas, as quais tiveram o propósito de encontrar um padrão tanto na variação da demanda como do preço da energia elétrica. As análises

feitas para os dados de demanda podem ser visualizadas por meio das Figuras de 11 a 15.




Figura 11: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2007.




Figura 12: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2008.




Figura 13: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2009.




Figura 14: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2010.




Figura 15: Análise dos dados de demanda da energia elétrica por meio da distribuição normal para o ano de 2011.

As análises feitas para os dados do preço podem ser visualizadas por meio das Figuras de 16 a 20.




Figura 16: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2007.




Figura 17: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2008.




Figura 18: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2009.




Figura 19: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2010.




Figura 20: Análise dos dados do preço da energia elétrica por meio da distribuição normal para o ano de 2011.

Inicialmente, os dados foram analisados por meio de uma distribuição normal, a qual se mostrou adequada para a previsão de demanda, porém, inviável para descrever o preço da energia. Por meio dos gráficos que se referem à distribuição normal para os dados de preço da energia elétrica, é possível notar um *skew* positivo, ou seja, uma assimetria à esquerda. Por este motivo, também foram utilizadas as distribuições log-normal e de Weibull. Os resultados obtidos pelo uso da distribuição

log-normal são mostrados nas Figuras de 21 a 25 e os resultados da distribuição de Weibull são representados por meio das Figuras de 26 a 30.




Figura 21: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2007.




Figura 22: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2008.




Figura 23: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2009.




Figura 24: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2010.




Figura 25: Análise dos dados do preço da energia elétrica por meio da distribuição log-normal para o ano de 2011.




Figura 26: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2007.




Figura 27: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2008.




Figura 28: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2009.




Figura 29: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2010.




Figura 30: Análise dos dados do preço da energia elétrica por meio da distribuição de Weibull para o ano de 2011.

Comparando-se os gráficos obtidos para análise estatística do preço da energia elétrica, constata-se que, em geral, a distribuição log-normal mostrou-se mais apropriada para descrever o comportamento do preço ao longo do ano. Entretanto, o ano de 2009 se apresenta como uma exceção, pois, este é mais bem representado pela distribuição de Weibull.

Na sequência desta monografia serão apresentadas as técnicas de pré-processamento de dados utilizadas, bem como os aspectos fundamentais de seleção de atributos.

3. Pré-Processamento de Dados e Análise de Relevância dos Atributos

Conforme previamente comentado, a base de dados utilizada na análise estatística foi composta pelos dados de Ontário - Canadá. Estes dados contêm os seguintes atributos:

- Atributo #1 (Demanda) - demanda da região de Ontario, ou seja, uma das variáveis a ser estimada;
- Atributo #2 (Cotação) - cotação do dólar canadense em função do dólar americano;
- Atributo #3 (Energia Eólica) - quantidade de energia gerada pelos parques eólicos;
- Atributo #4 (Balanço) - balanço energético que representa as importações e exportações de energia elétrica;
- Atributo #5 (Preço) - preço da energia elétrica da região de Ontario, ou seja, uma das variáveis a ser estimada.

Ressalta-se que todos estes dados foram obtidos no intervalo de uma hora. Portanto, estes são dados que possibilitam a estimação do preço e da demanda de energia elétrica para um horizonte de curtíssimo prazo. Neste sentido, as análises de relevância dos atributos foram feitas considerando-se três bases de dados distintas, a saber:

- Base de dados #1 - conjunto de todos os dados (total de 26952 instâncias);
- Base de dados #2 - dados de dias úteis (total de 18720 instâncias);
- Base de dados #3 - dados de feriados e finais de semana (total de 8112 instâncias).

Deve-se comentar que para a seleção de atributos, os dados utilizados correspondem a um intervalo que se inicia em Julho de 2009 e tem seu término em Julho de 2012. Este intervalo foi considerado ao invés daquele intervalo previamente utilizado para as análises estatísticas (2007 a 2011), pois, nem todos os atributos estavam completos, havendo a necessidade de limitar a nova base de dados para que as análises fossem possíveis. Entretanto, a etapa de seleção de atributos é independente da análise estatística e, portanto, não houveram problemas que pudessem limitar a execução deste ferramental para o referido projeto de iniciação científica.

3.1. Pré-processamento dos dados

Os dados foram pré-processados de forma que os cinco atributos contidos na base de dados tornaram-se 145 a serem dados como entradas e mais 1 que foi utilizado como saída. Entretanto, para que esta quantidade de atributos fosse obtida, a organização dos dados mostrada por meio da Tabela 1.

Por meio da Tabela 1 é possível notar que foram considerados como entradas os dados de Preço, Demanda, Energia Eólica e Balanço Energético para a hora $h - i$, onde h corresponde à hora que se pretende estimar demanda ou preço e $i = 1, 2, \dots, 23$. Portanto, consideraram-se como entradas as últimas 23 horas anteriores ao valor de preço ou demanda a ser estimada. Além disso, o dólar foi considerado, no entanto, considerou-se que $i = [24, 48, 72, 96, 120]$, pois, os valores do dólar são obtidos para um dia e não para cada hora. Por fim, a nova base de dados ainda foi composta pelos cálculos de médias móveis que consideram 12 janelas móveis com intervalos de 24 horas.

Tabela 1: Dados organizados após a etapa de pré-processamento.

$h - i$	Preço
	Demanda
	Energia Eólica
	Balanço
	Dólar
Média Móvel de 12 horas	Preço
	Demanda
	Energia Eólica
	Balanço
Saída desejada para h	Preço
	Demanda

Cabe mencionar que o objetivo do cálculo da média móvel é o de filtrar eventuais flutuações demasiadas e mostrar mais explicitamente uma tendência, caso essa exista. Neste trabalho, foi usada a média móvel ponderada para n termos, cuja notação matemática é expressa pela Equação 1:

$$M_{Móvel}(n) = \frac{2}{n(n+1)} \sum_{i=1}^n P[t - (n - i)](i) \quad (1)$$

Destaca-se que foi usado $n = 24$ devido ao número de horas que compõem uma janela de média móvel. Assim, o objetivo desta média móvel é a de fornecer uma avaliação da série temporal no prazo de um dia completo.

Após esta etapa de pré-processamento, os dados foram devidamente organizados (conforme a Tabela 1) e separados em dois conjuntos de amostras (treinamento e validação), os quais foram posteriormente utilizados tanto pelos Seletores de Atributos como também pelos Sistemas Inteligentes. Portanto, ainda deve-se mencionar que estes conjuntos foram respectivamente divididos em 60% (treinamento) e 40% (validação).

3.2. Seleção de atributos

A princípio, é importante comentar que atributos são colunas de uma base de dados, as quais representam as diferentes características das diversas instâncias contidas nesta base [24]. Em conformidade com este conceito, em [25], os autores definem o processo de seleção de atributos como a determinação de um subconjunto de atributos ótimo que será responsável por generalizar a informação contida na base de dados, conforme a resposta que se espera obter da mesma. Assim, o subconjunto de atributos obtido deverá necessariamente possuir um tamanho igual ou menor ao conjunto de atributos original.

Neste sentido, algoritmos para seleção de atributos são muito empregados quando os métodos para mineração de dados (redes neurais artificiais, árvores de decisão, etc) não conseguem obter a generalização de padrões sem uma etapa de pré-processamento de dados ou quando estes algoritmos tornam-se inviáveis devido à grande quantidade de atributos que seriam fornecidos como entradas. De forma a evitar estes casos, a seleção de atributos tem sido empregada, pois, ao se reduzir o número de entradas, também será minimizado o espaço de busca pela melhor solução ou por uma solução ótima.

Com relação ao funcionamento dos algoritmos para seleção de atributos, estes normalmente escolhem os atributos por uma avaliação individual ou por subconjuntos de atributos. A avaliação individual de atributos ordena-os com relação às suas relevâncias. Desta forma, há a remoção de alguns atributos que poderiam ser considerados irrelevantes ao propósito da mineração de dados. Em se tratando de avaliação por subconjuntos de atributos, tanto os atributos redundantes quanto os irrelevantes serão removidos do conjunto de atributos.

De acordo com estes conceitos fundamentais de seleção de atributos, a literatura correlata divide os métodos em duas categorias: *wrappers* e filtros. Nesta

monografia serão empregados os filtros, pois estes são independentes da técnica a ser aplicada para a estimação de preço e demanda de energia elétrica.

Portanto, neste trabalho empregou-se tanto o método CFS (*Correlation-based Feature Selection*) proposto por [26] quanto o método *Relief* proposto por [27]. Assim, o CFS utilizou um método de busca que retornasse um subconjunto de atributos considerado otimizado para a estimação de preço ou demanda. Em contrapartida, o *Relief* empregou um método de busca por *ranking*, onde todos os atributos da base de dados foram ordenados por relevância e com seus pesos.

3.3. Resultados obtidos por meio da seleção de atributos

Os resultados obtidos por ambos os seletores de atributos (CFS e *Relief*) são devidamente reportados nesta seção. Desta forma, as Tabelas 2 e 3 apresentam, respectivamente, os resultados da obtidos pelo algoritmo CFS durante a etapa de seleção de atributos visando a estimação de demanda e preço da energia elétrica.

Tabela 2: Resultados obtidos pelo algoritmo CFS considerando a estimação da demanda de energia elétrica.

	Base de Dados #1	Base de Dados #2	Base de Dados #3
1º Atributo	Demanda $h-1$	Demanda $h-1$	Demanda $h-1$
2º Atributo	Demanda $h-12$	Demanda $h-12$	Demanda $h-23$
3º Atributo	Demanda $h-23$	Demanda $h-23$	Eólica $h-3$
4º Atributo	Eólica $h-4$	Eólica $h-4$	Balanço $h-13$

Tabela 3: Resultados obtidos pelo algoritmo CFS considerando a estimação do preço da energia elétrica.

	Base de Dados #1	Base de Dados #2	Base de Dados #3
1º Atributo	Demanda $h-23$	Demanda $h-23$	Demanda $h-23$
2º Atributo	Balanço $h-1$	Balanço $h-1$	Balanço $h-1$
3º Atributo	Preço $h-1$	Preço $h-1$	Preço $h-1$
4º Atributo	12ª Janela do WMA do Preço	12ª Janela do WMA do Preço	11ª Janela do WMA do Preço

Por meio dos resultados obtidos, é possível notar que para a estimação da demanda, independente da base de dados, tanto a demanda da hora anterior à que deverá ser estimada quanto a demanda de 23 horas prévias à demanda a ser estimada sempre foram selecionadas. Para a estimação do preço da energia elétrica, este tipo de ocorrência é ainda mais comum, pois, os três primeiros atributos selecionados foram sempre os mesmos, tendo uma pequena variação na janela de

média móvel selecionada para o preço. Ainda foi possível observar que o dólar não é um atributo relevante para se determinar tanto demanda quanto preço da energia elétrica na região de Ontário.

Em seguida, são apresentados os resultados obtidos ao se empregar o seletor de atributos *Relief*, o qual se difere do CFS por apresentar em sua saída uma lista dos atributos ordenados por relevância. Cabe comentar que foi estabelecido, de forma empírica, um limiar que considerava um atributo a ser selecionado desde que este apresentasse um mérito maior ou igual a de 0,01. Os resultados desse seletor podem ser observados por meio das Tabelas 4 e 5.

Ao analisar os resultados obtidos pelo algoritmo *Relief* para a estimação da demanda, nota-se que para a Base de Dados #1 (que contém os dados de todos os dias) foram selecionados somente 4 atributos, entretanto, somente as demandas para 1 hora e 23 horas anteriores à demanda a ser estimada são atributos correlatos àqueles selecionados pelo método CFS. Já para as Bases de Dados #2 e #3, foi selecionada uma maior quantidade de demandas horárias. Em relação à estimação do preço, nota-se que as janelas de médias móveis selecionadas são todas distintas daquelas selecionadas pelo CFS. Além disso, ao se considerar as Bases de Dados #2 e #3, o método *Relief* apontar o dólar como atributo relevante no processo de estimação do preço.

Tabela 4: Resultados obtidos pelo algoritmo RELIEF considerando a estimação da demanda de energia elétrica.

	Base de Dados #1	Base de Dados #2	Base de Dados #3
1º Atributo	Demanda $h-1$	Demanda $h-1$	Demanda $h-1$
2º Atributo	Demanda $h-23$	Demanda $h-23$	Demanda $h-23$
3º Atributo	Demanda $h-2$	Demanda $h-2$	Demanda $h-2$
4º Atributo	Demanda $h-22$	Demanda $h-22$	Demanda $h-22$
5º Atributo	-	Demanda $h-16$	Demanda $h-3$
6º Atributo	-	Demanda $h-17$	Demanda $h-15$
7º Atributo	-	Demanda $h-7$	Demanda $h-9$
8º Atributo	-	Demanda $h-8$	Demanda $h-16$
9º Atributo	-	Demanda $h-3$	Demanda $h-14$
10º Atributo	-	-	Demanda $h-8$

Tendo em mãos os atributos selecionados tanto pelo CFS quanto pelo *Relief*, estes serão submetidos às entradas dos Sistemas Inteligentes, onde serão estabelecidas suas respostas em termos do Erro Absoluto Médio Percentual (MAPE – *Mean Absolute Percentage Error*).

Tabela 5: Resultados obtidos pelo algoritmo RELIEF considerando a estimação do preço da energia elétrica.

	Base de Dados #1	Base de Dados #2	Base de Dados #3
1º Atributo	Preço h-1	Preço $h-1$	Preço h-1
2º Atributo	1ª Janela do WMA do Preço	1ª Janela do WMA do Preço	1ª Janela do WMA do Preço
3º Atributo	Preço h-2	Preço $h-2$	2ª Janela do WMA do Preço
4º Atributo	2ª Janela do WMA do Preço	2ª Janela do WMA do Preço	Preço h-2
5º Atributo	-	3ª Janela do WMA do Preço	3ª Janela do WMA do Preço
6º Atributo	-	Dólar $h-120$	Dólar h-120
7º Atributo	-	Dólar $h-24$	-

4. Fundamentos de Sistemas Inteligentes

O termo Sistemas Inteligentes pode ser entendido como ferramentas computacionais que buscam simular mecanismos inteligentes encontrados na natureza [28], os quais tentam imitar aspectos que normalmente são associados à inteligência humana, a saber: capacidade associativa, de aprendizagem, de evolução, de raciocínio e de interagir com o usuário. Estes sistemas referem-se às diversas aplicações comerciais de Inteligência Artificial e podem ser empregados na resolução de problemas de várias áreas na engenharia, tais como: controle de processos; otimização dos sistemas de potência; estimação de mercado de energia e ações, análise de sinais e imagens, etc.

O termo Inteligência Artificial foi criado por John McCarthy, professor da Universidade de Stanford, no ano de 1956. Segundo o qual, trata-se da ciência e a engenharia de fazer máquinas inteligentes. As pesquisas neste ramo utilizam conhecimentos de diferentes campos, incluindo ciência da computação, psicologia, neurociência, filosofia, ciência cognitiva, linguística, reconhecimento facial e de voz. Justamente por apresentar um caráter extremamente multidisciplinar aliado a um grande potencial de aplicações em vários setores da sociedade a Inteligência Artificial ainda é vista como uma promissora área de pesquisa.

Conforme supracitado, a estimação faz parte do rol de tarefas que podem ser realizadas por ferramentas baseadas em sistemas inteligentes e, portanto, é evidente que a estimação de preço e demanda de energia elétrica poderão ser executadas e avaliadas.

No próximo tópico são apresentados os conceitos fundamentais de Redes Neurais Artificiais e Sistemas Neuro-Fuzzy, os quais são tidos como possíveis ferramentas a serem empregadas neste trabalho.

4.1. Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA), de forma geral, “é uma técnica desenvolvida para modelar a maneira que o cérebro realiza uma dada função; esta rede normalmente é implementada com componentes eletrônicos ou em softwares de simulação em um computador digital” [29]. Em outras palavras, as RNAs são modelos computacionais inspirados nos mecanismos de aprendizagem do cérebro humano, ou seja, elas possuem algumas características de desempenho semelhantes às redes neurais biológicas, dentre as quais se ressaltam:

1. O conhecimento é obtido através de um processo de aprendizagem;
2. Capacidade de armazenamento do conhecimento.

O aprendizado e a generalização das informações figuram entre as propriedades mais úteis das RNAs. A generalização pode ser entendida como a capacidade da rede neural de fornecer saídas sensatas para entradas que não lhes foram mostradas durante seu processo de aprendizagem. São essas duas características que permitem que as RNAs sejam empregadas na resolução de problemas complexos.

A elaboração de uma rede neural, conforme supramencionado, é motivada pela analogia ao cérebro humano, por isso, na sequência ambos serão comparados de forma sucinta por meio da Figura 31.




Figura 31: Representação de um neurônio artificial comparado a um biológico [30].

De acordo com a Figura 31, os dendritos são responsáveis por receber estímulos de outros neurônios. Estes sinais, que partem tanto do corpo celular quanto do dendrito, são transmitidos pelo axônio. Portanto, analogamente, na formulação de um neurônio artificial, as entradas e saída do sistema podem ser comparadas aos dendritos e axônios dos neurônios, respectivamente. No entanto, como o funcionamento detalhado dos neurônios biológicos ainda não foi totalmente entendido, um modelo computacional é limitado e pode ser até considerada uma idealização das redes neurais reais.

De forma concisa, o modelo de um neurônio artificial possui múltiplas entradas e uma única saída, além disso, possui dois modos de operação, o modo de

treinamento e o modo de uso. Durante o treinamento, ele é ensinado a rejeitar ou não um dado conjunto de entradas. Posteriormente, na fase de uso, quando uma entrada conhecida é detectada a saída associada a ela torna-se a saída atual. Por outro lado, caso a entrada seja estranha à rede neural, baseado em seu treinamento, o sistema é capaz de decidir se descarta ou não esta entrada. Em outras palavras, trata-se da capacidade da rede neural de aprender e de melhorar seu desempenho.

4.2. Sistemas Neuro-Fuzzy

A Lógica *Fuzzy* representa uma expansão da lógica tradicional booleana a qual pode assumir apenas dois valores, verdadeiro ou falso. Historicamente, ela foi introduzida na década de 1960 pelo professor Lotfi Zadeh da Universidade de Berkeley no artigo “*Fuzzy Sets*” [31], de início sofreu objeções no meio acadêmico, pois seus aspectos matemáticos ainda não haviam sido bem delineados e, por esse motivo, nos primeiros anos suas aplicações foram se desenvolveram lentamente.

Cabe ainda mencionar que a Lógica *Fuzzy* traduz a maneira que um ser humano intrinsicamente pensa, pondera e percebe o mundo, pois lida com o conceito de verdade parcial, ao invés de definir algo como completamente verdadeiro ou completamente falso. Para um sistema *fuzzy*, existem graus de verdade o que o torna bastante flexível, haja vista a sua capacidade de manipular informações subjetivas. Esta propriedade é ideal para aplicações que necessitam de tolerância a dados imprecisos, ou que possuam características não lineares, de complexidade arbitrária, incertezas e imprecisões. Neste âmbito, enquanto outras abordagens requerem equações precisas para modelar um dado comportamento, os sistemas *Fuzzy* são mais complacentes com as ambiguidades do mundo real.

5. Resultados e Discussões

A partir dos fundamentos de Sistemas Inteligentes apresentados no Capítulo 5, verificou-se que os Sistemas Neuro-Fuzzy não seriam capazes de processar as bases de dados em um tempo computacional que pudesse garantir a obtenção e análises dos resultados, pois, ao utilizar tais sistemas com uma grande quantidade de entradas (maior do que duas), o mesmo torna-se computacionalmente inviável. Desta forma, optou-se por realizar todo o processo de estimação empregando Redes Neurais Artificiais com arquitetura *feedforward*, somente uma camada neural oculta e algoritmo de treinamento de *Levenberg-Marquardt*. Cabe mencionar que as RNAs foram avaliadas de forma que a quantidade de neurônios que compõem a camada oculta foram alterados de 5 a 50 com incremento de 5 neurônios.

Ressalta-se ainda que todos estes dados foram obtidos para prever a hora a frente tanto para a demanda quanto para o preço da energia elétrica, pois, este trabalho visava desde seu início estabelecer uma metodologia de estimação que pudesse ser empregada no âmbito de *Smart Grids*, onde o horizonte de curtíssimo prazo torna-se ideal.

5.1. Resultados Obtidos Considerando Algoritmo Cfs

Nesta subseção são apresentados os resultados obtidos pelas RNAs ao considerar como possíveis entradas os atributos selecionados pelo algoritmo CFS. Portanto, foram criadas três distintas redes neurais, sendo que cada uma delas passou a ser responsável por cada uma das bases de dados. Neste sentido, os resultados para cada uma das RNAs treinadas e validadas com o intuito de estimar a demanda de energia elétrica são apresentados por meio da Tabela 6.

É importante notar que apesar da separação dos dados entre dias úteis e finais de semana/feriados tornar o processo de estimação um pouco mais preciso, a não separação dos dados não resultou em uma diferença percentual considerável, visto que para a Base de Dados #1 obteve-se um MAPE máximo de 1,82 % e um MAPE mínimo de 1,75 % e para as Bases de Dados #2 e #3 foram obtidos MAPEs máximos de respectivamente 1,56 % e 1,70 % e MAPEs mínimos de respectivamente 1,44 % e 1,45 %. Desta forma, ao se considerar a estimação da demanda de energia elétrica, a etapa de seleção de atributos é extremamente útil e comprova uma possível não

necessidade em separar a base de dados, a menos que mesmo um pequeno desvio percentual possa ser determinante ao propósito para o qual a previsão de demanda será utilizada.

Tabela 6: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar a demanda de energia elétrica.

Neurônios da Camada Oculta	Base de Dados #1 MAPE (%)	Base de Dados #2 MAPE (%)	Base de Dados #3 MAPE (%)
5	1,820630	1,558763	1,545453
10	1,750685	1,444272	1,531015
15	1,774473	1,439652	1,515831
20	1,759444	1,462169	1,498833
25	1,756777	1,443802	1,467038
30	1,772587	1,446522	1,515579
35	1,786802	1,507552	1,457822
40	1,762435	1,482186	1,505644
45	1,789691	1,473116	1,445303
50	1,800245	1,473433	1,697669

Da mesma forma realizaram-se os testes das RNAs responsáveis por estimar o preço da energia elétrica considerando os atributos selecionados pelo CFS. Estes resultados podem ser visualizados por meio da Tabela 7.

Tabela 7: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar o preço da energia elétrica.

Neurônios da Camada Oculta	Base de Dados #1 MAPE (%)	Base de Dados #2 MAPE (%)	Base de Dados #3 MAPE (%)
5	27,219524	26,814467	34,908181
10	29,178534	29,351813	35,026817
15	27,589256	28,086854	33,064068
20	37,387276	27,256423	35,135862
25	27,508485	33,815667	37,676861
30	28,187309	28,813892	58,841897
35	27,793212	28,931904	42,366831
40	29,926946	32,229485	35,598204
45	26,453406	28,250326	43,086864
50	28,023059	32,130516	34,853200

Analisando-se os resultados obtidos para a estimação do preço da energia elétrica, é possível verificar que seus MAPEs são bastante elevados, entretanto, as RNAs responsáveis pelas Bases de Dados #1 (contém dados de todos os dias) e #2 (somente dias úteis) apresentaram maior estabilidade do que a RNA responsável pela Base de Dados #3, visto que esta última apresentou um MAPE mínimo de 33,1 % e um MAPE máximo de 58,8 %, ou seja, uma variação de 25,7 %.

5.2. Resultados Obtidos Considerando Algoritmo *Relief*

Por fim, esta subseção apresenta os resultados obtidos pelas RNAs ao considerar como possíveis entradas os atributos selecionados pelo algoritmo *Relief*. De forma semelhante ao que fora previamente mencionado, foram criadas 3 RNAs, sendo cada uma responsável por cada Base de Dados. Os resultados dessas RNAs podem ser analisados por meio das Tabelas 8 e 9.

Tabela 8: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar a demanda de energia elétrica.

Neurônios da Camada Oculta	Base de Dados #1 MAPE (%)	Base de Dados #2 MAPE (%)	Base de Dados #3 MAPE (%)
5	1,266670	0,974080	1,221568
10	1,129024	0,930477	1,095589
15	1,086372	0,876791	1,115472
20	1,106425	0,867948	1,070129
25	1,078370	0,884680	1,106612
30	1,094242	0,876770	1,102820
35	1,078963	0,876420	1,096833
40	1,095927	0,928326	1,130569
45	1,087000	0,898892	1,130299
50	1,077884	0,901222	1,159231

Tabela 9: Resultados obtidos pelas RNAs considerando os atributos selecionados pelo CFS para estimar o preço da energia elétrica.

Neurônios da Camada Oculta	Base de Dados #1 MAPE (%)	Base de Dados #2 MAPE (%)	Base de Dados #3 MAPE (%)
5	39,071759	29,111645	43,659662
10	36,099478	28,415427	36,499324
15	35,022723	28,413886	61,113118
20	35,259134	29,714370	41,716882
25	33,528400	28,527814	45,268980
30	39,291426	28,146620	36,316247
35	40,143619	28,930266	40,409673
40	38,417663	31,832074	81,804432
45	38,522276	28,558518	68,579708
50	41,536000	29,883219	174,939945

Analisando os resultados obtidos para a estimação da demanda de energia elétrica (Tabela 8), nota-se que os mesmos são ainda melhores do que aqueles obtidos com os atributos selecionados pelo CFS. Por outro lado, os resultados obtidos para a estimação do preço da energia elétrica (Tabela 9) são consideravelmente piores do que aqueles obtidos ao se considerar o CFS como seletor de atributos. Entretanto, notou-se que a seleção de atributos praticamente torna desnecessária a

separação dos dados entre dias úteis e finais de semana/feriados.

6. Conclusões

Nesta monografia, propôs-se um método, baseado em Sistemas Inteligentes, com o objetivo de se obter uma estimação do preço e da demanda de energia. Uma das motivações deste trabalho é a sua aplicação em um ambiente das tão faladas redes inteligentes.

Em um futuro próximo, o desenvolvimento e implantação das *smart grids* colocaria, de fato, em prática o conceito de resposta à demanda, a qual permite um ajuste no perfil de consumo em resposta a uma precificação dinâmica da tarifa de energia elétrica. Em outras palavras, a gestão da demanda otimizaria, de forma integrada, todos os recursos do sistema elétrico (medidores inteligentes, linhas de transmissão, a distribuição e a geração), uma vez que possibilita, por exemplo, o alívio do sistema em horários críticos de pico por meio da flexibilidade de muitas utilizações finais da energia elétrica.

Neste cenário, a estimativa do preço e da demanda da energia beneficia economicamente o consumidor, dado que esclarece o entendimento da relação entre os dois, e molda o padrão de uso da eletricidade de acordo com o preço estabelecido.

Devido aos resultados obtidos, pôde-se constatar que a demanda é uma variável que, apesar de não linear, apresenta menor complexidade do ponto de vista de sua estimativa quando comparada ao preço da energia elétrica. Em contrapartida, o preço da energia é mais volátil e susceptível a variações. Este comportamento pôde ser notado tanto por meio da análise estatística quanto por meio dos resultados obtidos pelas redes neurais.

Além disso, notou-se que a etapa de pré-processamento de dados e seleção de atributos foi de extrema importância à previsão da demanda de energia elétrica, pois, garantiu resultados satisfatórios. Mesmo com a má estimativa do preço da energia elétrica, foi possível constatar que a seleção dos atributos, de certa forma, garante que não seja necessária a separação dos dados entre dias úteis e finais de semana/feriados.

7. Referências Bibliográficas

- [1] Amjady, N. e Keynia, F., “Day-ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm”, *IEEE Transactions on Power Systems*, vol. 24, n.1, pp. 306-318, 2009.
- [2] Mandal, P., Srivastava, A. e Park, J-W., “An Effort to Optimize Similar Days Parameters For ANN-Based Electricity Price Forecasting”, *IEEE Transactions on Industry Applications*, vol. 45, n.5, pp. 1888-1896, 2009.
- [3] Mohsenian-Rad, A-H. e Leon-Garcia, A., “Optimal Residential Load Control with Price Prediction in Real-Time Electricity Pricing Environments”, *IEEE Transactions on Smart Grid*, vol. 1, n.2, pp. 120-133, 2010.
- [4] García-Martos, C., Rodríguez, J. e Sánchez, M. J., “Forecasting Electricity Prices by Extracting Dynamic Common Factors: Application to the Iberian Market”, *IET Generation, Transmission & Distribution*, vol. 6, n.1, pp. 11-20, 2012.
- [5] Amjady, N. e Hemmati, M., “Energy Price Forecasting – Problems and Proposals for such Predictions”, *IEEE Power & Energy Magazine*, vol. 24, n.1, pp. 20-29, 2006.
- [6] Huang, D., Zareipour, H., Rosehart, W. e Amjady, N., “Data Mining for Electricity Price Classification and the Application to Demand-Side Management”, *IEEE Transactions on Smart Grid*, vol. 3, n.2, pp. 808-817, 2012.
- [7] Wu, L. e Shahidehpour M., “A Hybrid Model for Day-Ahead Price Forecasting,” *IEEE Transactions on Power System*, vol. 25, no. 3, pp. 1519–1530, 2010.
- [8] Conejo, A. J., Contreras, J., Espinola, R. e Plazas, M. A., “Forecasting Electricity Prices for a Day-Ahead Pool-Based Electric Energy Market,” *International Journal of Forecasting*, vol. 21, no. 3, pp. 435–462, 2005.
- [9] Fan, S., Mao, C. e Chen, L., “Next-Day Electricity-Price Forecasting Using a Hybrid Network,” *IET Generation, Transmission & Distribution*, vol. 1, no. 1, pp. 176–182, 2007.
- [10] Bompard, E., Ciwei, G., Napoli, R. e Torelli F., “Dynamic Price Forecast in a Competitive Electricity Market,” *IET Generation, Transmission & Distribution*, vol. 1, no. 5, pp. 776– 783, 2007.
- [11] Fosso, O. B., Gjelsvik, A., Haugstad, A., Birger, M. e Wangensteen, I., “Generation Scheduling in a Deregulated System: The Norwegian Case,” *IEEE Transactions on Power System*, vol. 14, no. 1, pp. 75–81, 1999.
- [12] Nogales, F. J., Contreras, J., Conejo, A. J. e Espinola, R., “Forecasting Next-Day Electricity Prices by Time Series Models,” *IEEE Transactions on Power System*, vol. 17, no. 2, pp. 342–348, 2002.
- [13] Zareipour, H., Cañizares, C. A., Bhattacharya, K. e Thomson, J., “Application of Public-Domain Market Information to Forecast Ontario’s Wholesale Electricity Prices,” *IEEE Transactions on Power System*, vol. 21, no. 4, pp. 1707–1717, 2006.
- [14] Contreras, J., Espinola, R., Nogales, F. J. e Conejo, A. J., “ARIMA Models to Predict Next-Day Electricity Prices,” *IEEE Transactions on Power System*, vol. 18, no. 3, pp. 1014–1020, 2003.

- [15] Garcia, R. C., Contreras, J., Akkeren, M. V. e Garcia, J. B. C., "A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices," *IEEE Transactions on Power System*, vol. 20, no. 2, pp. 867–874, 2005.
- [16] García-Martos, C., Rodríguez, J. e Sánchez, M. J., "Mixed Models for Short-Run Forecasting of Electricity Prices: Application to the Spanish Market Case", *IEEE Transactions on Power System*, vol. 22, no. 2, pp. 544-552, 2007.
- [17] Alfares, H. e Nazeeruddin, M., "Electric Load Forecasting: Literature Survey and Classification of Methods", *International Journal of Systems Science*, vol. 33, no. 1, pp. 23-34, 2002.
- [18] Hinojosa, V. e Hoese, A., "Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 565-574, 2010.
- [19] Borges, C. E., Peña, Y. K. e Fernández, I., "Evaluating Combined Load Forecasting in Large Power Systems and Smart Grids", *IEEE Transactions on Industrial Informatics*, vol. 9, no. 3, pp. 1571-1576, 2013.
- [20] Ministério de Minas e Energia, "Portaria Nº 455 - 2012", DOU publicado em 03/08/2012, 2012.
- [21] Amorim, M. C., *Previsão de séries temporais usando séries exógenas e combinação de redes neurais aplicada ao mercado financeiro*, Dissertação de Mestrado, Centro de Informática, Universidade Federal de Pernambuco, 2008.
- [22] Zhang, G. P., "Times series forecasting using a hybrid ARIMA and neural network", *Neurocomputing*, vol. 50, pp. 159-175, 2003.
- [23] Box, G. E. P., Jenkins, G. M. e Reinsel, G. C., "Time Series Analysis, Forecasting and Control", *Wiley Series in Probability and Statistics*, 2008.
- [24] Witten, I. H. e Frank, E., *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd Edition, Morgan Kaufmann, 2005.
- [25] Liu, H. e Motoda, H., *Feature Selection for Knowledge Discovery and Data Mining*, Kluwer Academic Publishers, 1998.
- [26] Hall, M. A., *Correlation-based Feature Selection for Machine Learning*, Ph.D. Thesis, University of Waikato, Hamilton, New Zealand, 1999.
- [27] Kira, K. e Rendell, L., "The feature selection problem: traditional methods and new algorithm", *Proceedings of the AAAI'92*, 1992.
- [28] Silva, I. N., Spatti, D. H. e Flauzino, R. A., *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático*, Editora Artliber, 2010.
- [29] Haykin, S., *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 1999.
- [30] Fernandes, R. A. S., *Identificação de fontes de correntes harmônicas por redes neurais artificiais*, Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 2009.
- [31] Zadeh, L. A., "Fuzzy sets", *Information and Control*, vol. 8, no. 3, pp. 338-353, 1965.