

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**Aplicação de Redes Neurais Artificiais à Previsão do  
Preço da Energia Elétrica para Distintas Zonas de  
Mercados Desregulamentados**

**CAMILA KAMIMURA SILVA**

**ORIENTADOR: PROF. DR. RICARDO AUGUSTO SOUZA FERNANDES**

São Carlos - SP  
Agosto/2018

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**Aplicação de Redes Neurais Artificiais à Previsão do  
Preço da Energia Elétrica para Distintas Zonas de  
Mercados Desregulamentados**

**CAMILA KAMIMURA SILVA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Inteligência Artificial

Orientador: Dr. Ricardo A. S. Fernandes

São Carlos - SP  
Agosto/2018

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

---



**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Ciência da Computação

---

**Folha de Aprovação**

---

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado da candidata Camila Kamimura Silva, realizada em 10/08/2018:

---

Prof. Dr. Ricardo Augusto Souza Fernandes  
UFSCar

---

Prof. Dr. Danilo Hernane Spatti  
USP

---

Prof. Dr. Marcelo Suetake  
UFSCar

# AGRADECIMENTOS

É uma tarefa importante nomear a todos que contribuíram de alguma forma, diretamente ou indiretamente, na realização deste trabalho.

Agradeço imensamente ao professor Dr Ricardo Augusto Souza Fernandes, que me orientou durante esta caminhada, motivando sempre que necessário e auxiliando durante todo o processo.

Agradeço a meus pais José Carlos e Aparecida pelos ensinamentos e meu marido Silas pelo apoio incondicional. Também agradeço as amigadas que São Carlos me trouxe, e que levarei para a vida. A todos amigos que em momentos de fraqueza, de uma forma ou de outra estavam lá e não me deixaram fraquejar.

Aos professores do programa de pós-graduação em Ciência da Computação do Departamento de Computação da UFSCAR e todos os técnicos administrativos e demais funcionários.

Enfim, agradeço a todos que de uma maneira ou outra contribuíram com uma palavra de motivação.

# RESUMO

A estimação do preço da energia elétrica desempenha um papel crucial no atual modelo de comercialização de energia de muitos países. Uma melhor capacidade de estimação torna possível identificar estratégias adequadas para os participantes do mercado. Dessa forma, este trabalho possui como objetivo determinar uma metodologia para estimar valores pontuais diários para o mercado de energia Pennsylvania – New Jersey – Maryland por meio de Mineração de Dados, onde serão considerados Seletores de Atributos e Redes Neurais Artificiais. Neste sentido, as respostas de redes neurais do tipo *Multilayer Perceptron* e também de redes neurais recorrentes são analisadas, considerando distintas topologias.

**Palavras-chave:** Mercado de energia, Redes neurais artificiais, Preço da Energia Elétrica, Previsão de séries temporais.

# ABSTRACT

The estimation of the energy price plays a crucial role in the current model of commercialization of energy in many countries. Better estimation capacity makes it possible to identify appropriate strategies for market players. Thus, this work aims to determine a methodology to estimate point values and intervals (maximum and minimum) for a day for the Pennsylvania - New Jersey - Maryland energy market through Data Mining, where they will be considered Attribute Selectors and Artificial Neural Networks. In this sense, the responses of neural networks of the Multilayer Perceptron type and of Recurrent Neural Networks will be analyzed, considering different topologies.

**Keywords:** Energy market, Artificial neural networks, Energy Price, Time-series forecasting.

# LISTA DE FIGURAS

|  |    |
|--|----|
| Figura 1: Modelo matemático do neurônio artificial. ....   | 27 |
| Figura 2: Zonas do Mercado PJM .....   | 30 |
| Figura 3: Configuração da Entrada de Dados ao Modelo Neural. ....  | 32 |
| Figura 4: Arquitetura <i>feedforward</i> utilizada nas RNA de cada uma das zonas/regiões selecionadas para o Mercado PJM ..... | 33 |
| Figura 5: Valores Reais X Valores Previstos (Outubro/2014) para a Zona AECO. ...   | 35 |
| Figura 6: Valores Reais X Valores Previstos (Outubro/2017) para a Zona AECO. ...   | 36 |
| Figura 7: Valores Reais X Valores Previstos (Outubro/2014) para a Zona AEP .....   | 37 |
| Figura 8: Valores Reais X Valores Previstos (Outubro/2017) para a Zona AEP .....   | 38 |
| Figura 9: Valores Reais X Valores Previstos (Outubro/2014) para a Zona PECO. ...   | 39 |
| Figura 10: Valores Reais X Valores Previstos (Outubro/2017) para a Zona PECO..   | 39 |
| Figura 11: Valores Reais X Valores Previstos (Outubro/2014) para a Zona APS .....  | 40 |
| Figura 12: Valores Reais X Valores Previstos (Outubro/2017) para a Zona APS .....  | 41 |

# LISTA DE TABELAS

|   |    |
|---|----|
| Tabela 1: Erros obtidos pela literatura correlata para o Mercado Espanhol. ....                 | 20 |
| Tabela 2: Erros obtidos pela literatura correlata para o Mercado Australiano .....              | 22 |
| Tabela 3: Erros obtidos pela literatura correlata para os Mercados dos Estados Unidos.<br>..... | 24 |
| Tabela 4: Erros obtidos pela literatura correlata para o Mercado Canadense .....                | 26 |
| Tabela 5: Descrição do Mercado PJM.....   | 31 |
| Tabela 6: Erros calculados para a Zona AECO.....  | 34 |
| Tabela 7: Erros calculados para a Zona AEP .....  | 36 |
| Tabela 8: Erros calculados para a Zona PECO.....  | 38 |
| Tabela 9: Erros calculados para a Zona APS.....   | 40 |

# SUMÁRIO

|  |           |
|--|-----------|
| <b>CAPÍTULO 1 - INTRODUÇÃO</b> .....   | <b>13</b> |
| 1.1 Justificativas e Motivações .....  | 15        |
| 1.2 Objetivos .....  | 16        |
| 1.3 Organização do Trabalho .....  | 16        |
| <b>CAPÍTULO 2 - ANÁLISE DA PRODUÇÃO CIENTÍFICA PARA DISTINTOS<br/>MERCADOS</b> ..... | <b>18</b> |
| 2.1 Mercado Espanhol .....   | 18        |
| 2.2 Mercado Australiano.....   | 21        |
| 2.3 Mercados dos Estados Unidos.....   | 22        |
| 2.4 Mercado Canadense .....  | 25        |
| <b>CAPÍTULO 3 - METODOLOGIA PROPOSTA</b> .....                                       | <b>27</b> |
| 3.1 Introdução .....   | 27        |
| 3.2 Base de Dados.....   | 28        |
| <b>CAPÍTULO 4 - ANÁLISE DE RESULTADOS</b> .....                                      | <b>34</b> |
| 4.1 Zona AECO .....  | 34        |
| 4.2 Zona AEP.....  | 36        |
| 4.3 Zona PECO .....  | 38        |
| 4.4 Zona APS.....  | 40        |
| <b>CAPÍTULO 5 – CONCLUSÕES</b> .....   | <b>42</b> |
| 5.1 Agradecimentos .....   | 40        |
| <b>REFERÊNCIAS</b> .....   | <b>44</b> |

# Capítulo 1

## INTRODUÇÃO

---

A energia elétrica apresenta grande importância no contexto econômico de um país, sendo vital para o funcionamento industrial e também no cotidiano da população. Atualmente, a energia elétrica é comercializada como uma *commodity*, visto que apresenta dependência em relação a diversos fatores como demanda, dia da semana que é comercializada, taxa de crescimento econômico do país, preço do combustível para manter geradores operando, regime de chuvas e temperaturas, entre outros (Amjady, Daraeepour e Keynia, 2010; Mandal, Srivastava e Park, 2009).

Um desses fatores é o preço da energia elétrica, que será abordado nesse trabalho. A estimação do preço desempenha um papel crucial no atual modelo de comercialização de muitos países, uma vez que influencia diretamente na economia de produtores e consumidores. De acordo com o cenário mundial descrito em Suganthi e Anand (2011) e Amjady e Hemmati (2006), pode-se notar que, em diversos países, múltiplas organizações investem em ferramentas para a previsão de preço da energia elétrica. Uma melhor capacidade de previsão de preço torna possível identificar estratégias adequadas para participar do mercado de comercialização de energia, além de uma melhor utilização dos recursos empregados na geração, transmissão, distribuição e operação de sistemas elétricos. Tal capacidade de previsão também possibilita uma abordagem estratégica de venda de energia para maximizar os lucros dos produtores e auxiliar os compradores a minimizarem o custo da aquisição (Amjady, Daraeepour e Keynia, 2010; Mandal, Srivastava e Park, 2009; Suganthi e Anand, 2011; Amjady e Hemmati, 2006; Aggarwal, Saini e Kumar, 2008a). Como apresentado em Amjady, Daraeepour e

Keynia (2010) e Garcia-Martos, Rodriguez e Sanchez (2012), pode-se dizer que o problema da previsão do preço da energia elétrica é complexo devido à sua não linearidade e alta volatilidade, necessitando de métodos mais precisos e robustos.

O presente estudo visa o desenvolvimento de um método para tratar dados considerando apenas o preço da energia no mercado PJM, ou seja, com uma base de dados sólida e considerando apenas um fator, o método tende a ser mais preciso e com baixo índice de volatilidade, será mostrado nos capítulos posteriores o resultado do método. Para o desenvolvimento do método é necessário o estudo e uso das séries temporais. Em Aggarwal, Saini e Kumar (2008b), os autores dividem os principais métodos de previsão de preço de energia elétrica em três grandes vertentes: teoria dos jogos, séries temporais e modelos de simulação. Logo se fará uso das séries temporais, aonde os autores destacam dentro desse contexto os modelos estocásticos, como por exemplo, o de média móvel (MA), auto regressivo (AR) e auto regressivo de média móvel (ARMA). Os autores também apresentam modelos baseados em inteligência artificial destacando-se os modelos que utilizam Redes Neurais Artificiais (RNA) e demais técnicas de aprendizado de máquina. Assim sendo, o método proposto irá fazer uso além de séries temporais o uso também de Redes Neurais Artificiais.

Cabe salientar ainda que além do trabalho ser baseado usando os modelos descritos acima o horizonte de previsão escolhido será o de curto prazo que recebe esse nome, pois trata-se de previsão para o próximo dia. No trabalho proposto por Sahay e Tripathi (2014), os autores apresentam métodos para previsão do preço da energia para horizontes de curto ou curtíssimo prazo. Conforme descrito em Aggarwal,

Saini e Kumar (2008b), o horizonte de previsão possui grande importância ao selecionar os dados utilizados como entradas para o método escolhido, implicando em um melhor tratamento dos dados, fato que também será mostrado posteriormente.

Nesse trabalho, é proposta uma metodologia baseada em Mineração de dados que faz uso de Seletores de Atributos e RNA para a previsão diária atingida pelo preço da energia elétrica no mercado Pennsylvania – New Jersey – Maryland (PJM) que é considerado desregulamentado.

Entretanto, é importante frisar que um mercado desregulamento não corresponde a um mercado sem regras e sim a um mercado simplificado, onde

existem poucas regras e regimentos governamentais para garantir seu correto funcionamento.

## 1.1 Justificativas e Motivações

De acordo com o contexto previamente mencionado, pode-se notar que diversos países têm investido em ferramentas para a estimação de preço energia elétrica, a qual visa aprimorar o sistema, tornando-o mais confiável, seguro, inteligente e a um custo mais baixo (Amjady e Hemmati, 2006).

No Brasil, as regras de negociação dos contratos no mercado de energia firmados no Ambiente de Contratação Livre (ACL) sofreram importantes modificações, pois, a portaria 455/2012 publicada em Agosto de 2012 pelo Ministério de Minas e Energia (2012) 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 passou a estabelecer, a partir de julho de 2013, 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 do preço da energia elétrica com alta precisão.

O processo de contratação de energia no Brasil, deve ser compreendido em função do despacho, pois está diretamente ligado ao preço da energia. O processo de despacho (quantidade de energia que uma usina irá gerar em um determinado momento) das usinas no Brasil é centralizado, cabendo ao ONS (Operador Nacional do Sistema Elétrico) a definição de quais usinas irão gerar. Neste sentido, o despacho e o preço do mercado de curto prazo são definidos pela minimização dos custos de geração.

No Brasil existem dois ambientes de contratação, o ACR (Ambiente de Contratação Regulada) e o ACL (Ambiente de Contratação Livre), em que os contratos são puramente financeiros e o Sistema Interligado Nacional (SIN) se responsabiliza

pela entrega da energia. Para esse trabalho será proposta uma metodologia de previsão do preço da energia elétrica que poderá vir a ser aplicada no contexto nacional, porém devido aos poucos dados publicamente disponibilizados, a metodologia proposta será testada em relação ao Mercado PJM.

## 1.2 Objetivos

Os objetivos gerais desta dissertação consistem na investigação, desenvolvimento, projeto, implementação e validação de arquiteturas de seletores de atributos e redes neurais artificiais para a previsão de preço da energia elétrica. Dentro desse contexto, os objetivos específicos são pautados em quatro itens principais apresentados a seguir:

1. Gerar uma base de dados que possa armazenar os dados históricos de preços da energia elétrica;
2. Armazenar atributos para que estes possam ser analisados e selecionados;
3. Permitir que as redes neurais possam ser testadas e validadas fazendo-se uso das bases de dados geradas por este projeto;
4. Verificar o comportamento de redes neurais configuradas com distintas quantidades de neurônios.

## 1.3 Organização do Trabalho

Além do capítulo introdutório em questão, a dissertação está estruturada nos seguintes capítulos subsequentes:

- Capítulo 2 – apresenta uma análise das produções científicas em função dos mercados de energia encontrados;
- Capítulo 3 – discute os principais métodos de previsão de séries temporais;

- Capítulo 4 – apresenta a metodologia idealizada e aplicada à previsão das séries temporais do mercado PJM;
- Capítulo 5 – apresenta as conclusões da pesquisa.

# Capítulo 2

## ANÁLISE DA PRODUÇÃO CIENTÍFICA PARA DISTINTOS MERCADOS

---

Este capítulo visa demonstrar o estado da arte na área de previsão de séries temporais, onde a bibliografia consultada está relacionada ao preço da energia elétrica. Nas seções subsequentes será apresentado o referencial teórico em função dos mercados de energia comumente empregados pelos grupos de pesquisa proeminentes.

### 2.1 Mercado Espanhol

Até a década de 70, as concessionárias de energia elétrica realizavam o planejamento de sua capacidade de distribuição de energia de acordo com o crescimento da demanda, uma vez que o consumo de energia elétrica apresentava um comportamento de grande previsibilidade (GELLINGS, 1985). Todavia, a partir dos anos 80 – devido a diversos fatores econômicos, políticos, sociais e tecnológicos (GELLINGS, 2017) – a demanda começou a se tornar cada vez menos previsível e, ao mesmo tempo, o setor energético enfrentou a escassez de fontes de fornecimento de baixo custo. Conseqüentemente, estas variáveis contribuíram de maneira significativa para o aumento da complexidade em integrar metodologias de operação e planejamento tradicionais com o objetivo de influenciar deliberadamente a demanda de energia elétrica (GELLINGS, 1985).

Atualmente, as pesquisas realizadas para a previsão do preço da energia no Mercado Espanhol fazem uso de diversas metodologias e ferramentas. Cada um com uma previsão direcionada, exemplo disso é a previsão para o dia seguinte, dia atual, ou em períodos do dia.

Esse trabalho estudará as diversas metodologias do Mercado Espanhol para compará-las com os resultados encontrados pelo método desenvolvido, sendo assim o trabalho tem como objetivo, além de desenvolver um método de previsão do preço de eletricidade para o dia seguinte, também objetiva a comparação de métodos para mostrar sua qualidade no resultado final.

Para a análise do Mercado Espanhol, a base de dados usada foi fundamentada no Operador do Mercado Ibérico de Energia (OMEL) – Espanha, operador que regula o preço da eletricidade do mercado espanhol.

Em Contreras et al. (2003), os autores propõem modelos ARIMA para prever os preços da eletricidade do próximo dia. As técnicas ARIMA (*Autoregressive Integrated Moving Average*) são usadas para analisar séries temporais e, no passado, foram usadas principalmente para previsão de carga, devido à sua precisão e solidez matemática. No referido trabalho, a técnica ARIMA é usada da seguinte forma:

- Uma classe de modelos é formulada assumindo certas hipóteses;
- Depois um modelo é identificado para os dados observados;
- Na sequência, os parâmetros do modelo são estimados;
- Se as hipóteses do modelo forem validadas, então o modelo está pronto para a previsão;
- Caso contrário, é necessário reformular uma classe de modelos com outras hipóteses a fim de refinar o modelo.

Ademais, os autores ainda estimaram a Raiz do Erro Médio Quadrático (RMSE, do inglês *Root Mean Square Error*) de previsão para as 168 horas de cada semana, sendo necessárias, ao modelo ARIMA, 5 horas anteriores para prever um valor de preço futuro. Assim, obteve-se um RMSE igual a 10.

Em Garcia et al. (2005) é usado um modelo de previsão GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*) para prever os preços de energia para o dia seguinte. Esse tipo de modelo pode medir a volatilidade implícita de uma série temporal devido a picos de preços. O artigo fornece uma abordagem baseada em GARCH para prever os preços da energia do próximo dia. Os autores demonstram

que houve melhora significativamente tanto da capacidade preditiva como também da capacidade de estimar os picos de preços de energia. O erro estimado nessa pesquisa foi o RMSE. As previsões atingiram RMSE igual a 9, dependendo do mês estudado do ano. Todas as previsões foram derivadas de um modelo GARCH aplicado tanto ao mercado Espanhol como também ao mercado Americano do Estado da Califórnia, incluindo todas as horas, dias, fins de semana e feriados. O modelo GARCH proposto supera um modelo ARIMA. Além disso, adicionar a demanda ao modelo GARCH como uma variável explicativa melhora o desempenho do método.

A metodologia proposta por Garcia et al. (2005) pode ser considerada melhor do que a de Contreras et al. (2003). Entretanto, durante os meses de baixa volatilidade, como fevereiro e maio (no mercado Espanhol) e fevereiro, março e novembro (no mercado da Califórnia), o modelo ARIMA mostra um desempenho um pouco melhor do que o GARCH.

No trabalho proposto por Garcia-Martos, Rodriguez e Sanchez (2012) emprega-se uma técnica de redução de dimensionalidade dos dados como ferramenta de pré-processamento. Os autores propuseram a extração de características comuns de 24 vetores de preços, as quais foram usadas para a previsão de um dia a frente. A metodologia permite modelar a estrutura multivariada dos preços da energia elétrica, combinando linearmente as características extraídas para 24 horas. Os dados analisados são de janeiro de 2007 a janeiro de 2009. Notou-se que o valor e a variabilidade dos preços dependem da hora do dia. Isto se deve à relação instantânea entre carga/demanda e preço. O erro estimado nessa pesquisa foi o Erro Absoluto Médio Percentual (MAPE, do inglês *Mean Absolute Percentage Error*), onde os autores calcularam uma previsão para cada hora e obteve-se um MAPE médio de 7,39%.

Na Tabela 1, são apresentados os erros calculados para cada um dos métodos supramencionados.

**Tabela 1: Erros obtidos pela literatura correlata para o Mercado Espanhol.**

| Ano  | Autor                       | MAPE  | RMSE  |
|------|-----------------------------|-------|-------|
| 2003 | Contreras <i>et al.</i>     | -     | 10,00 |
| 2005 | Garcia <i>et al.</i>        | -     | 9,00  |
| 2012 | Garcia-Martos <i>et al.</i> | 7,39% | -     |

Fonte: Autor.

## 2.2 Mercado Australiano

Com a necessidade de previsões cada vez mais precisas, são propostos novos métodos de estudo para melhorias nas previsões. O mercado australiano é interessante para estudo, pois também é desregulamentado.

Para a análise do Mercado Australiano, a base de dados usada foi fundamentada no Operador do Mercado de Energia Australiano (AEMO, do inglês *Australian Energy Market Operator*). Esse trabalho estudará as metodologias já aplicadas ao Mercado Australiano para compará-las com os resultados encontrados pelo método desenvolvido.

No trabalho desenvolvido por Zhao et al. (2008) é proposta uma nova abordagem baseada na mineração de dados que faz a previsão de intervalo. Nesse tipo de predição, busca-se estabelecer uma faixa valoral à variável predita. Para fazer essa previsão, o autor demonstra a necessidade de um modelo não linear devido à volatilidade dos dados. Para tanto, empregou-se uma Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machines*) que é um conjunto de métodos do aprendizado supervisionado que analisam os dados e reconhecem padrões, usado para classificação e/ou regressão. A SVM é empregada diretamente na previsão do intervalo de preço. Também utilizaram o MAPE como métrica de avaliação da metodologia proposta, sendo possível obter 8,40%.

Em Motamedi, Zareipour e Rosehart (2012) emprega-se uma estrutura de previsão híbrida que leva em consideração as relações preço-demanda. Modelos de previsão híbridos combinam as capacidades de diferentes abordagens de modelagem, melhorando o desempenho em relação a outros métodos. É proposto um mecanismo de previsão modular de múltiplas entradas e múltiplas saídas (MIMO, do inglês *Multiple In Multiple Out*) que é utilizado em sistemas de comunicação sem fio para multiplicar a capacidade de transmissão e recepção de dados. Esse mecanismo é usado para previsão simultânea de preço e demanda usando um algoritmo auxiliar baseado em mineração de dados por meio de associações para detectar e extrair o comportamento dinâmico de preço e demanda. Ao final, com base nos Sistemas de Inferência *Fuzzy* (FIS), são ajustadas as previsões do mecanismo MIMO. Os autores utilizaram o MAPE para análise dos resultados, onde para previsões horárias de preço

obteve-se um MAPE de 12,81%. Apesar de o valor de MAPE não ser baixo, a metodologia proposta disponibiliza previsões que são de fácil compreensão ao usuário, pois o algoritmo cria regras de associação do tipo Se...então.

Por fim, Chen et al. (2012) faz uso de um método de previsão de intervalo de preços com base em Redes Neurais Artificiais do tipo ELM (*Extreme Learning Machines*). As redes ELM são do tipo *feedforward*. A nova abordagem também melhorou a precisão da previsão de intervalos de preços, incorporando um método de *bootstrapping* (método que permite atribuir medidas de precisão definidas em termos de variância, intervalos de confiança e erro de previsão) para estimativas de incertezas. Novamente, o erro foi calculado por MAPE. Entretanto, expandiram a análise para o Erro Absoluto Médio (MAE, do inglês *Mean Absolute Error*) e o RMSE. Assim, obteve-se MAPE de 8,33%, MAE de 2,02 e RMSE de 2,93. Essa metodologia permite que o usuário quantifique o nível de incerteza associado às previsões pontuais, ou seja, qual se adequa melhor às necessidades de operações de mercado. Por conta dos resultados obtidos, é considerado o melhor modelo de regressão para o mercado australiano.

A Tabela 2 apresentada uma comparação entre os erros calculados por cada um dos trabalhos analisados.

**Tabela 2: Erros obtidos pela literatura correlata para o Mercado Australiano.**

| Ano  | Autor                   | MAPE   | RMSE | MAE  |
|------|-------------------------|--------|------|------|
| 2008 | Zhao <i>et al.</i>      | 8,40%  | -    | -    |
| 2012 | Chen <i>et al.</i>      | 8,33%  | 2,93 | 2,02 |
| 2012 | Montamedi <i>et al.</i> | 12,81% | -    | -    |

Fonte: Autor.

## 2.3 Mercados dos Estados Unidos

O Mercado Norte Americano tem como marco a reforma do setor elétrico com a publicação feita pelo *Federal Energy Regulatory Commission* (FERC) intitulada pro “Energy Policy Act”. Essa publicação auxiliou no estímulo à competição nos mercados

de energia elétrica e o livre acesso aos sistemas de transmissão de energia. Os estados americanos apresentam diferentes modelos de mercado de energia elétrica, sendo algumas experiências consideradas como referências importantes para o desenvolvimento de mercado de energia, como o Mercado PJM, mercado escolhido para estudo no presente trabalho.

Para a análise do Mercado dos Estados Unidos, a base de dados usada foi fundamentada nos Operadores *California Power Exchange* (Calpx), California ISO e New England–United States. Esse trabalho estudará as diversas metodologias do Mercados dos Estados Unidos para compará-las com os resultados encontrados pelo método desenvolvido.

Conforma já apresentado para o Mercado Espanhol, o trabalho de Contreras et al. (2003) propõe modelos ARIMA para prever os preços da energia para o dia a frente. Além de considerarem o Mercado Espanhol, também fazem testes da metodologia proposta ao Mercado Californiano. Em Garcia et al. (2005), os autores consideram o mesmo mercado, porém, fazem uso de um modelo GARCH. Estas previsões apresentam MSE aproximadamente igual a 9. Outro trabalho que considerada o Mercado Californiano foi publicado por Montamedi et al. (2012), empregando uma estrutura de previsão híbrida que leva em consideração as relações preço-demanda. Entretanto, obtiveram MAPE de 28,19%, considerado extremamente elevado quando comparado à previsão que haviam realizado para o mercado espanhol.

Em Zhang e Luh (2005), os autores propõem um método baseado no Mercado de Curto Prazo, onde a previsão de preço de compensação de mercado é feita com dados estimados em um intervalo de tempo confiável. Essa estimação é realizada por meio de Redes Neurais Artificiais e um estimador de Kalman modificado. Para essa pesquisa, a metodologia proposta foi capaz de atingir um MAPE de 7,30%. Essa abordagem ainda fora comparada a um estimador Bayesiano e às previsões disponibilizadas pela ISO New England (operador do sistema das regiões de Connecticut, Maine, New Hampshire, Vermont, Rhode Island e Massachusetts). Por meio dessa comparação foi possível perceber a eficácia da metodologia proposta.

Para o trabalho de Amjady, Daraeepour e Keynia (2009), os autores utilizam uma nova técnica de seleção de recurso baseada no método *Mutual Information* (quantidade de incerteza que é reduzida em uma dada variável, a partir do conhecimento provido pela outra). Esse método pode classificar cada uma das

variáveis independentes analisadas de acordo com seu valor de informação para a previsão da variável dependente, ou seja, o preço da energia. A partir das classificações das variáveis, emprega-se um método de previsão baseado em Algoritmo Neuroevolutivo em Cascata (CNEA, do inglês *Cascaded Neural Evolutionary Algorithm*). O modelo de regressão baseado em CNEA faz uso de 24 horas de cada dia. Entretanto, sua parametrização precisa ser ajustada em função do horizonte de previsão, onde um algoritmo evolutivo faz uma busca com o intuito de definir tais parâmetros antes de as redes neurais realizarem a tarefa de previsão do preço de liquidação no Mercado PJM. Foram considerados 24 modelos de regressão, sendo um para cada hora do dia. O MAPE obtido pelos autores foi de 12,80%.

Mandal, Srivastava e Park (2009) apresentam um método de seleção de dias similares para compor a entrada de Redes Neurais Artificiais, ou seja, apresenta uma análise de sensibilidade de parâmetros de dias semelhantes para aumentar a precisão da rede neural na previsão de preços de curto prazo. Nesse trabalho, os autores também consideram o mercado PJM. Para avaliar o desempenho da metodologia proposta, foram calculados MAPE e MAE, obtendo respectivamente 5,41% e 2,68. Neste sentido, os autores confirmam que a demanda de energia é a variável mais importante, ou seja, é aquela que mais afeta o preço da energia. Além disso, os autores definem uma sistemática para a identificação/seleção de variáveis mais relevantes para a previsão de preço de energia em dias similares. Consequentemente, essa sistematização proporciona a redução significativa do custo computacional, visto que dessa forma ocorre a redução de dimensionalidade dos dados que serão apresentados como entradas ao modelo de regressão.

Na sequência, a Tabela 3 apresenta os erros obtidos por cada uma das metodologias propostas.

**Tabela 3: Erros obtidos pela literatura correlata para os Mercados dos Estados Unidos.**

| Ano  | Autor                   | MAPE  | MSE  | MAE  |
|------|-------------------------|-------|------|------|
| 2003 | Contreras <i>et al.</i> | -     | 5,00 | -    |
| 2005 | Garcia <i>et al.</i>    | -     | 9,00 | -    |
| 2005 | Zhang <i>et al.</i>     | 7,30% | -    | -    |
| 2009 | Mandal <i>et al.</i>    | 5,41% | -    | 2,68 |

|      |                        |        |   |   |
|------|------------------------|--------|---|---|
| 2009 | Amjady <i>et al.</i>   | 12,80% | - | - |
| 2012 | Motamedi <i>et al.</i> | 28,19% | - | - |

Fonte: Autor.

## 2.4 Mercado Canadense

O mercado de energia elétrica da província de Ontário adotou um modelo livre e atacadista a partir de 1º de Maio de 2002. O Canadá possui várias empresas independentes responsáveis pela transmissão de eletricidade, destacando a IESO (*Independent Electricity System Operator*), uma empresa sem fins lucrativos que tem como principal responsabilidade operar o mercado atacadista de Ontário, a OPG (*Ontario Power Generation Inc.*) responsável pela maior parte da capacidade de geração instalada em Ontário (composta de usinas nucleares, hidroelétricas, eólicas e termoelétricas convencionais) e ainda a Hydro One Inc. maior empresa de transmissão de energia elétrica (estatal) em Ontário (com tarifas definidas e reguladas pelo governo). O preço em Ontário é uniforme perante toda a província e varia a cada cinco minutos. Este valor recebe o nome de *Market Clearing Price* ou preço de liquidação de mercado.

Aggarwal *et al.* (2008) apresenta um modelo de Rede Neural junto à Transformada Wavelet para prever o perfil de preços em um mercado de energia desregulamentado. Wavelet é uma função capaz de decompor e descrever ou representar outra função para que, ao final, possibilite analisar essa função em diferentes escalas de tempo. A decomposição de uma função com o uso de Wavelets é chamada de Transformada Wavelet. Para o autor, o uso da função em seu trabalho e o uso da Transformada Wavelet é considerada eficaz quando se fala em previsão do preço de energia de Ontário. O MAPE obtido para a previsão foi de 22,62%.

Amjady *et al.* (2010) desenvolveu um método de previsão de preços que é composto por um algoritmo de redução para seleção de características (variáveis mais relevantes) e uma rede neural híbrida para predição. Obteve-se um MAPE de 9,23% e MAE de 7,60.

Assim como mostrado para os demais mercados, na sequência, a Tabela 4 apresenta os erros obtidos por cada uma das metodologias analisadas para o mercado canadense.

**Tabela 4: Erros obtidos pela literatura correlata para o Mercado Canadense.**

| Ano  | Autor                  | MAPE   | MAE  |
|------|------------------------|--------|------|
| 2008 | Aggarwal <i>et al.</i> | 22,62% | -    |
| 2010 | Amjady <i>et al.</i>   | 9,23%  | 7,60 |

Fonte: Autor.

# Capítulo 3

## METODOLOGIA PROPOSTA

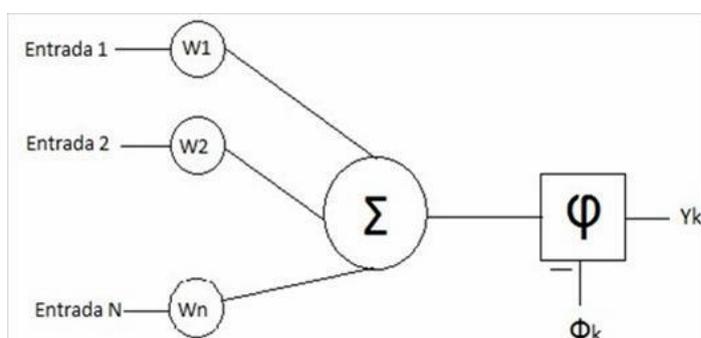
---

### 3.1 Introdução

As RNA têm sido utilizadas em diversas aplicações devido a sua adaptabilidade, capacidade de identificar padrões e tolerância a falhas. Cabe mencionar que esta classe de algoritmos de aprendizado de máquina é inspirada no sistema nervoso de seres vivos. Portanto, assim como o cérebro, a arquitetura de uma RNA possui neurônios como unidade fundamental de processamento.

Os neurônios possuem três elementos fundamentais, a saber: um conjunto de pesos sinápticos capaz de quantificar a força de cada conexão neural, um somador capaz de agregar todos os sinais de entrada e uma função de ativação (Haykin, 1999). Na Figura 1, é apresentado o modelo de um neurônio artificial.

**Figura 1: Modelo matemático do neurônio artificial.**



Fonte: Adaptado de Haykin (1999).

É importante destacar que nas RNA é possível variar tanto o número de neurônios como o número de camadas neurais intermediárias. Entretanto, na camada neural de saída a quantidade de neurônios é estabelecida em função da quantidade de saídas que se deseja (Haykin, 1999). É cabível destacar que uma RNA é responsável por construir uma relação entre entradas e saídas para um determinado processo, onde é empregado um algoritmo de aprendizado. Esse algoritmo é responsável pelo treinamento da RNA, o qual tem o objetivo de minimizar a diferença entre as saídas obtidas e os valores de referência (saídas desejadas).

Neste sentido, esta dissertação irá empregar Redes Neurais Artificiais do tipo *Multilayer Perceptron* (MLP) contendo uma ou duas camadas neurais intermediárias e uma camada neural de saída. Assim, tal RNA será empregada na previsão do preço da energia elétrica.

Assim, o número de neurônios será iniciado em 5, com incremento de 5, até atingir 50. Portanto, a parametrização será realizada por meio de um processo combinatorial para que todas as possíveis configurações sejam atendidas.

Com base na definição da ferramenta a ser utilizada no modelo de regressão, a base de dados foi selecionada em função da quantidade de dados, pois a RNA necessita de uma grande quantidade de dados para que os processos de treinamento e validação sejam feitos de forma adequada.

As predições são feitas considerando o preço da energia elétrica para a próxima hora (ou seja, a hora a frente). Além disso, considerou-se quatro zonas do mercado PJM, com o objetivo de fazer uma análise comparativa e averiguar o comportamento das predições frente a regiões de dimensões variadas.

Por fim, as RNA foram treinadas e validadas. Os resultados obtidos foram analisados em relação ao MAE, MAPE e RMSE, bem como fora feito pelos demais estudos que compõem o estado da arte, seja para o mercado PJM ou para outros mercados de energia.

### **3.2 Base de Dados**

Como uma organização de transmissão de energia elétrica regional, a PJM opera um mercado de energia que abrange todo ou parte do Delaware, Illinois,

Kentucky, Maryland, Michigan, Nova Jersey, Carolina do Norte, Ohio, Pensilvânia, Tennessee, Virginia, West Virginia e o Distrito de Columbia. Atuando de forma independente. O mercado PJM é responsável por coordenar a venda e a compra de energia, bem como realizar o balanço energético (entre geradoras, consumidores e demais agentes do mercado).

O mercado PJM é desregulamentado. A desregulamentação dos mercados de energia foi um passo importante na história, já que comparado ao mercado regulado é visto como a liberdade nos meios de produção e distribuição da energia. Com a desregulamentação do mercado, foi possível o investimento no setor energético, bem como a abertura da concorrência entre as empresas produtoras e distribuidoras, garantindo redução de custos para os consumidores. As medidas de privatização, desverticalização e abertura para a concorrência são consideradas o avanço quanto às deficiências no mercado regulado.

O PJM opera mercados de energia elétrica nos quais os geradores vendem e os serviços públicos ou fornecedores de compram energia para entrega imediata. Esses mercados de energia operam todos os dias e os participantes no mercado estabelecem um preço da energia, combinando a oferta (o que os geradores querem vender) e a demanda (o que os serviços públicos e os clientes desejam comprar). O PJM Energy Market adquire energia elétrica para satisfazer as demandas dos consumidores em tempo real e no curto prazo.

Optou-se então, após o estudo de funcionamento do Mercado PJM, pelo uso de seus dados. Além disso, há uma semelhança com o funcionamento do mercado brasileiro, pois sua previsão de preços é feita em curto prazo o que seria vantajoso para o mercado brasileiro, embora a matriz de geração e tamanho do mercado PJM sejam diferentes.

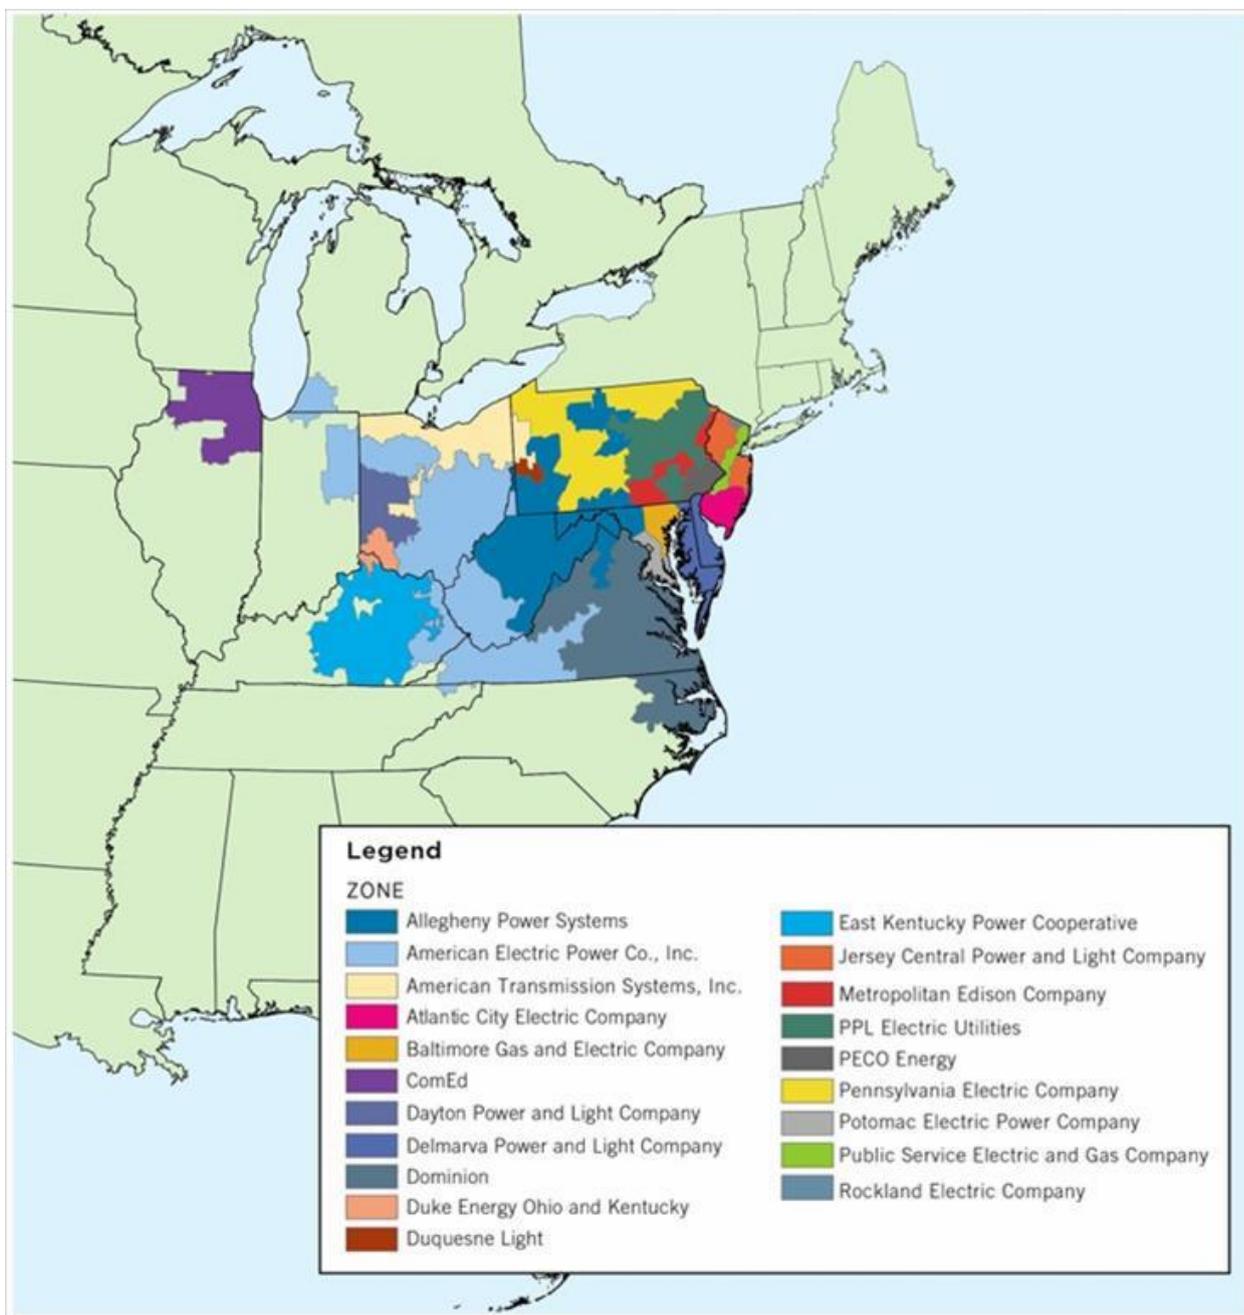
A base de dados é analisada entre outubro de 2004 e outubro de 2017 com estimativa para a previsão de preços para o dia seguinte (também chamado de *day-ahead*). A base apresenta os valores de preços marginais locais diários de média ponderada utilizados nos cálculos de cobrança do mercado PJM. Os dados atributos como: data, nome, tensão, equipamento e zona de atuação. Além disso, são disponibilizados hora a hora durante todo o dia.

Para a análise são usados os dados de quatro zonas, a saber: AEP (American Electric Power), AECO (Atlantic City Electric), PECO (PECO Energy) e APS

(Allegheny Power Systems). As zonas do mercado PJM são geograficamente apresentadas na Figura 2 e seus detalhes na Tabela 5.

As variáveis usadas foram extraídas da base de dados PJM (disponível em: <http://www.pjm.com/>) e transformadas/organizadas em uma planilha de dados. Dessa forma, criou-se uma planilha para cada zona do PJM escolhida. As variáveis são respectivas aos valores de preço para cada hora, a data e o nome da zona de atuação.

**Figura 2: Zonas do Mercado PJM.**



Fonte: PJM Market (2017).

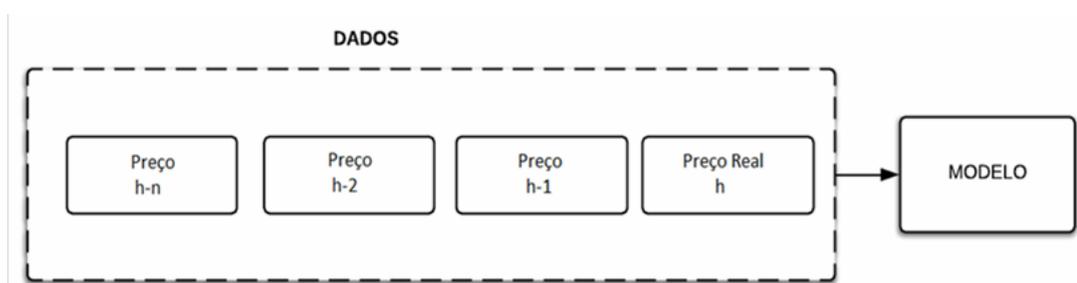
Tabela 5: Descrição do Mercado PJM.

| Companhias                                | Siglas                    | Tipo                | Estados  |
|---|---------------------------|---------------------|--|
| Allegheny Power                           | APS ou AP ou<br>FE South  | Área de controle    | Maryland, Pensilvânia,<br>Virgínia, Oeste-Virgínia                           |
| American Electric Power                   | AEP                       | Área de controle    | Indiana, Kentucky, Michigan,<br>Ohio, Tennessee, Virgínia,<br>Oeste-Virgínia |
| Atlantic City Electric                    | AECO ou AE                | Zona de transmissão | Nova Jersey  |
| American Transmission<br>Service Inc (FE) | ATSI                      | Área de controle    | Ohio   |
| Baltimore Gas and<br>Electric             | BGE ou BC                 | Zona de transmissão | Maryland,  |
| Commonwealth Edison                       | COMED                     | Área de controle    | Illinois   |
| Dayton Power and Light                    | DAY ou<br>DAYTON          | Área de controle    | Ohio   |
| Delmarva Power and<br>Light               | DPL                       | Zona de transmissão | Delaware, Maryland,  |
| Duke Energy Ohio and<br>Kentucky          | DEOK                      | Área de controle    | Kentucky, Ohio   |
| Duquesne Light                            | DUQ ou DLCO               | Área de controle    | Pensilvânia  |
| East Kentucky Power<br>Cooperative        | EKPC                      | Área de controle    | Kentucky   |
| Jersey Central Power<br>and Light         | JCPL ou JC                | Zona de transmissão | Nova Jersey  |
| Metropolitan Edison                       | Met Ed ou ME              | Zona de transmissão | Pensilvânia  |
| PECO Energy                               | PECO ou PE                | Zona de transmissão | Pensilvânia  |
| Pennsylvania Electric                     | PENELEC ou PN             | Zona de transmissão | Pensilvânia  |
| PPL Electric Utilities                    | PPL ou PL                 | Zona de transmissão | Pensilvânia  |
| Potomac Electric Power                    | Potomac ou<br>PEPCO       | Zona de transmissão | Maryland,  |
| Public Service Electric<br>and Gas        | PSEG ou PS                | Zona de transmissão | Nova Jersey  |
| Rockland Electric                         | RECO ou O&R               | Zona de transmissão | Nova Jersey  |
| Virginia Electric and<br>Power            | Dominion ou<br>DOM or DVP | Área de controle    | Carolina do Norte, Virgínia  |

Fonte: Autor.

Os dados foram utilizados para treinar e validar a RNA destinada a prever o comportamento do preço de cada zona selecionada. Mesmo que outros trabalhos já tenham demonstrado que modelos de previsão de preços de energia são mais eficientes ao considerar a demanda como uma variável independente, para este trabalho considerou-se apenas o próprio preço para que não houvesse interferência de outras variáveis nos modelos de regressão, visto que busca-se verificar o comportamento da previsão em função de distintas zonas/regiões do mercado PJM. A estrutura dos dados antes de ser apresentada para o ajuste dos modelos de regressão é mostrada na Figura 3.

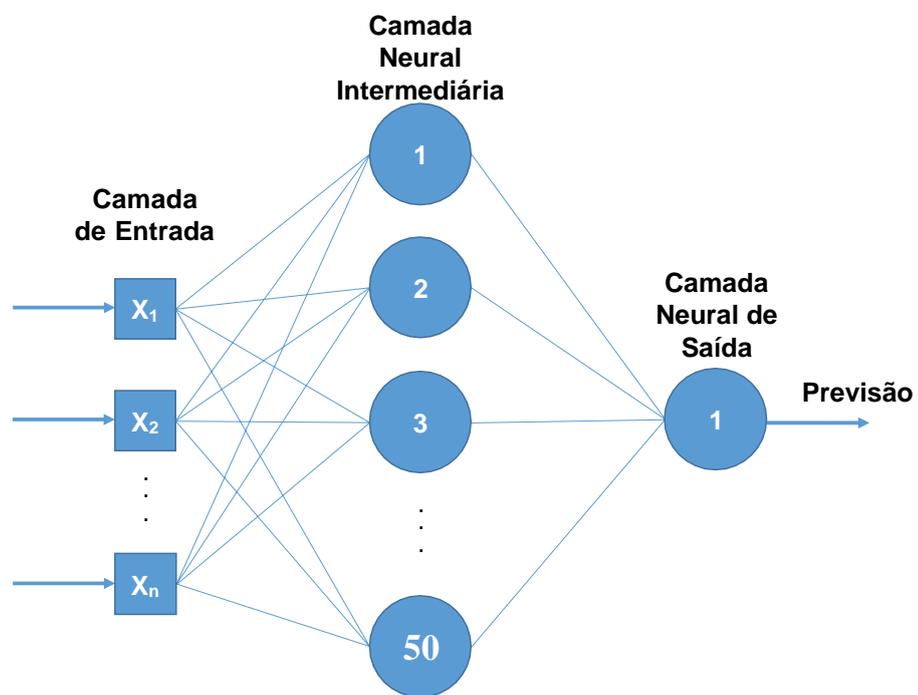
**Figura 3: Configuração da Entrada de Dados ao Modelo Neural.**



Fonte: Autor.

A arquitetura das RNA que irão representar cada uma das zonas pode ser visualizada na Figura 4. Destaca-se que foi utilizada uma RNA do tipo MLP com algoritmo de treinamento de Levenberg-Marquardt. Tal RNA fora composta por 50 neurônios na camada intermediária (com função de ativação tangente hiperbólica) e 1 neurônio na camada de saída (com função de ativação linear). Assim, a base de dados fora dividida em 70% dos dados para treinamento e os 30% restantes foram mantidos para a validação. Após ajustadas as RNA e obtidos os modelos neurais com os menores Erros Quadráticos Médios de treinamento, estes foram validados.

Figura 4: Arquitetura *feedforward* utilizada nas RNA de cada uma das zonas/regiões selecionadas para o Mercado PJM.



Fonte: Autor.

# Capítulo 4

## ANÁLISE DE RESULTADOS

---

---

A seguir, serão apresentados os resultados obtidos com a implementação do modelo. Além disso, tais resultados serão discutidos em função dos demais mercados de energia analisados e também em função das zonas escolhidas dentro no mercado de energia PJM.

### 4.1 Zona AECO

Para análise da zona AECO (Atlantic City), foram considerados o período entre 2004 a 2017, priorizando apenas o preço e descartando demais variáveis. Os resultados alcançados pelas RNA demonstraram os erros apresentados por meio da Tabela 7.

Tabela 6: Erros calculados para a Zona AECO.

| ZONA AECO |         |
|-----------|---------|
| ERROS     | VALORES |
| MAE       | 3,13    |
| MAPE      | 5,90%   |
| RMSE      | 17,75   |

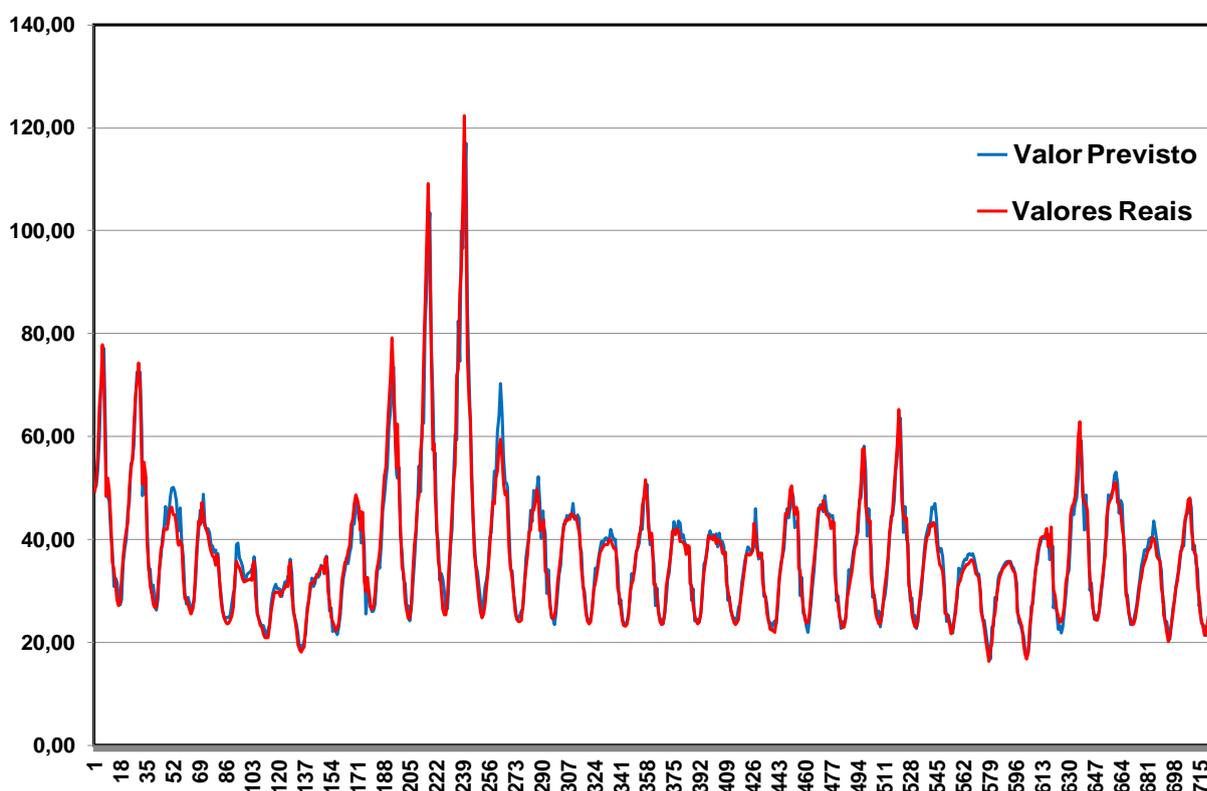
Fonte: Autor.

Após a análise dos erros, foram separados os meses de outubro de 2014 e de 2017 para que fossem verificados graficamente (Figuras 5 e 6). Assim, comparou-se

os valores estimados pelo modelo de regressão neural com os valores reais aferidos pela AECO.

Em termos de MAPE, nota-se que o mesmo é melhor do que a maioria dos resultados obtidos na literatura, perdendo somente para aquele obtido por Mandal et al. (2009) que fez uso de dados do mesmo mercado de energia, porém, com uma base de dados de menor porte.

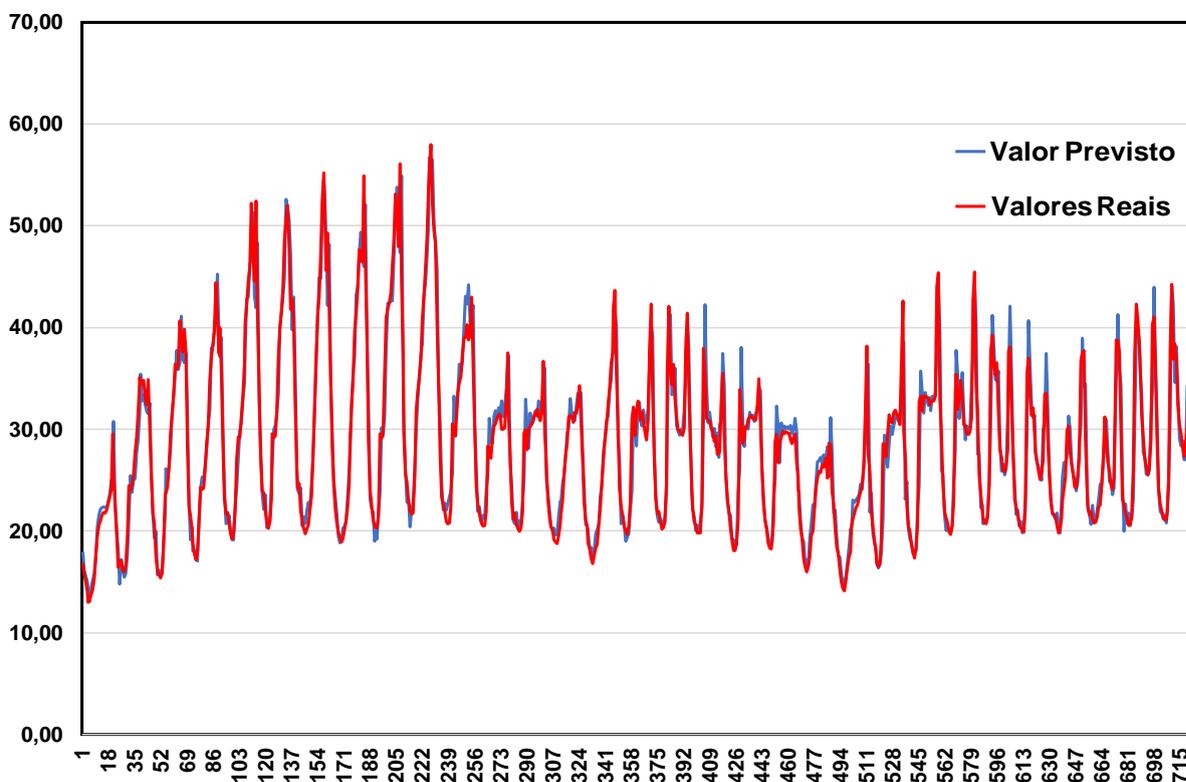
Figura 5: Valores Reais X Valores Previstos (Outubro/2014) para a Zona AECO.



Fonte: Autor.

Os gráficos apresentados nas Figuras 5 e 6 apontam que os valores Reais e Previstos são muito próximos, mostrando que o resultado final da análise é bom e vai de encontro ao que era esperado.

Figura 6: Valores Reais X Valores Previstos (Outubro/2017) para a Zona AECO.



Fonte: Autor.

## 4.2 Zona AEP

Para análise da zona AEP (American Electric Power), foi considerado o período entre 2004 a 2017, priorizando apenas o preço e descartando demais variáveis, assim como a zona AECO previamente analisada. Os resultados são apresentados por meio da Tabela 8.

Tabela 7: Erros calculados para a Zona AEP.

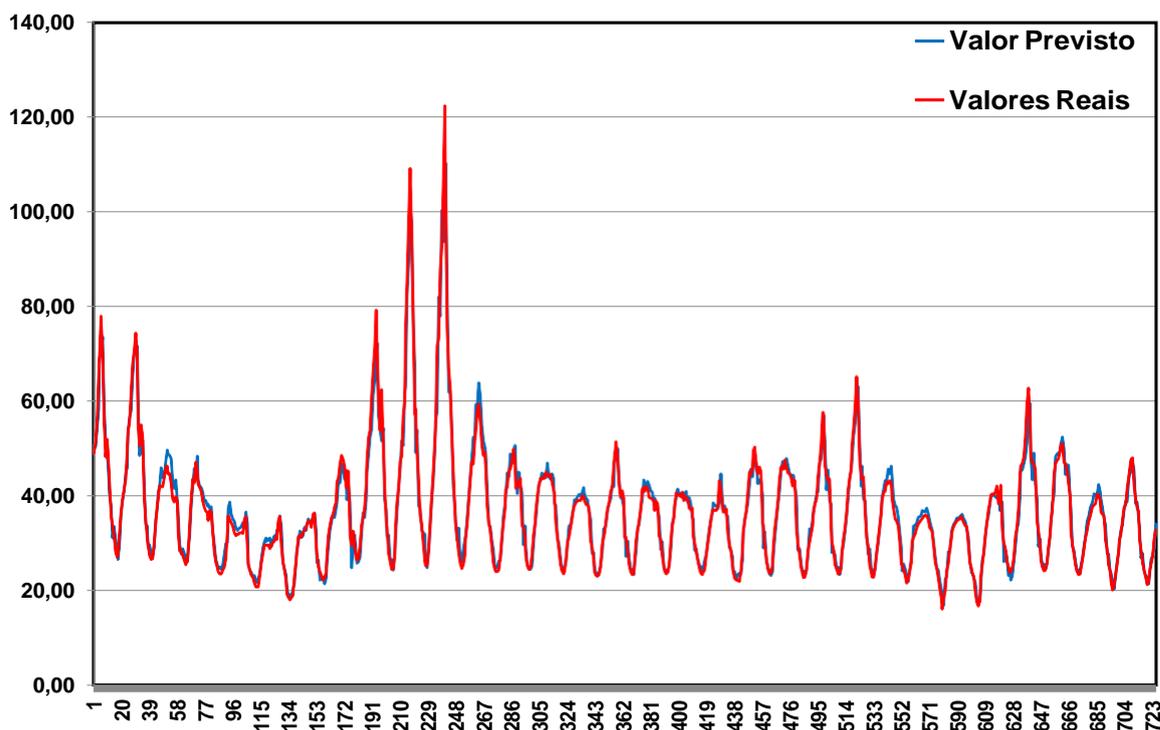
| ZONA AEP |         |
|----------|---------|
| ERROS    | VALORES |
| MAE      | 3,06    |
| MAPE     | 5,65%   |
| RMSE     | 22,25   |

Fonte: Autor.

Pode-se notar que os valores de erro obtidos para MAE e MAPE não sofrem grandes alterações em relação à zona AECO. Portanto, a mesma análise feita para a zona AECO em relação aos resultados apresentados na literatura correlata pode ser considerada.

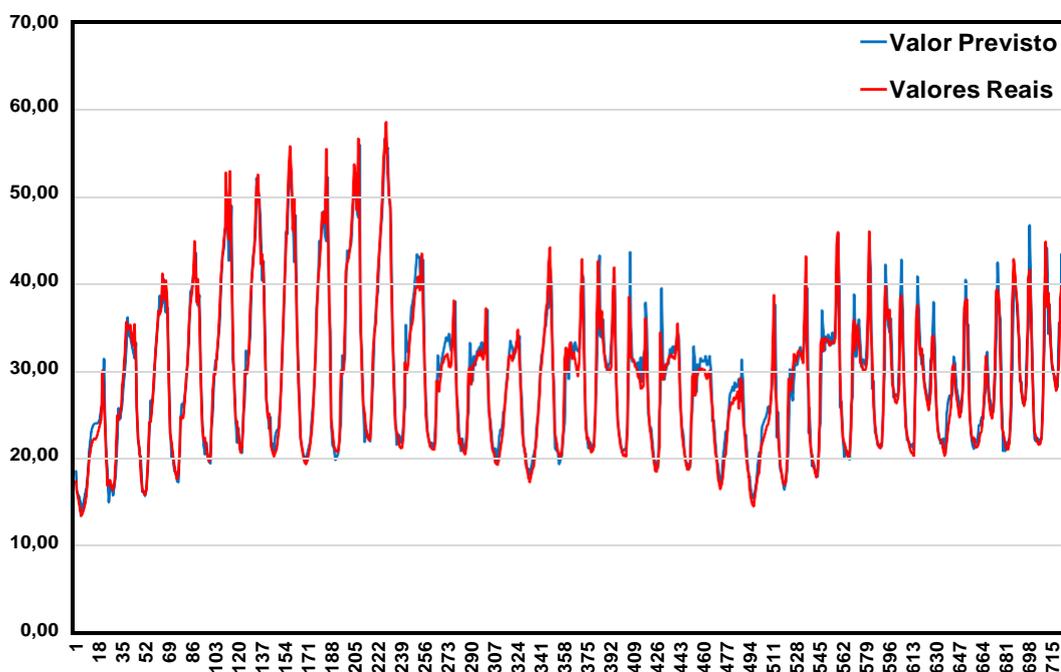
Assim, da mesma forma, foram obtidos os resultados para os meses de outubro nos anos de 2014 e 2017. Tais resultados podem ser visualizados por meio das Figuras 7 e 8.

**Figura 7: Valores Reais X Valores Previstos (Outubro/2014) para a Zona AEP.**



Fonte: Autor.

Figura 8: Valores Reais X Valores Previstos (Outubro/2017) para a Zona AEP.



Fonte: Autor.

### 4.3 Zona PECO

Para análise da zona PECO (PECO Energy), foram considerados o período entre 2004 a 2017, priorizando apenas o preço e descartando demais variáveis. Obteve-se, após aplicar o modelo neural, os resultados mostrados na Tabela 9.

Tabela 8: Erros calculados para a Zona PECO.

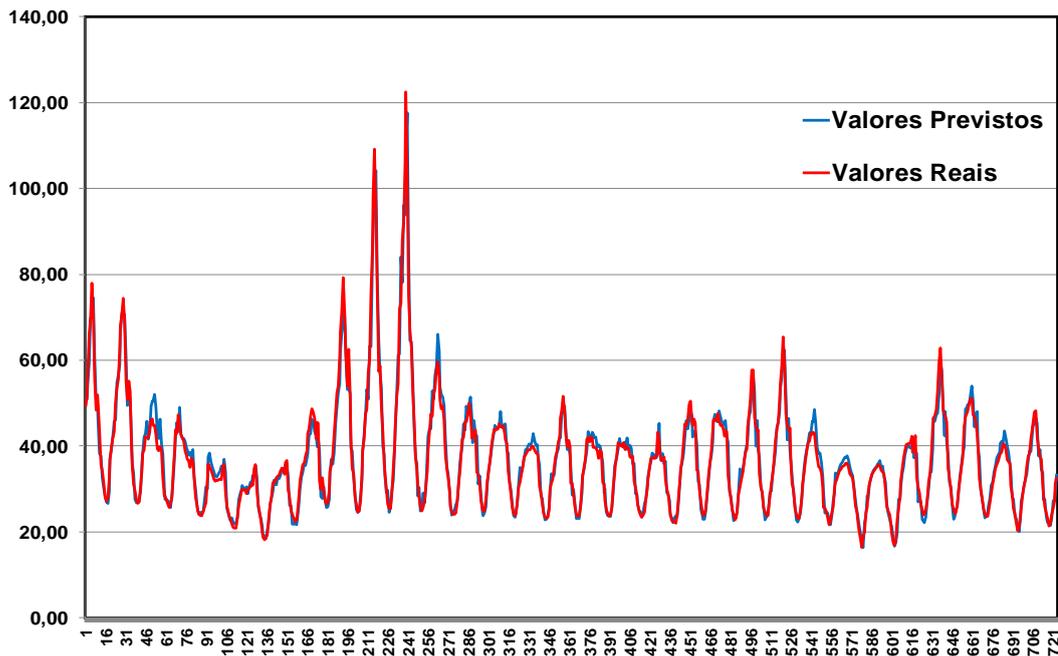
| ZONA PECO |         |
|-----------|---------|
| ERROS     | VALORES |
| MAE       | 2,65    |
| MAPE      | 5,74%   |
| RMSE      | 11,34   |

Fonte: Autor.

Pode-se notar que, apesar de o valor de MAPE manter-se próximo daqueles obtidos para as zonas AEP e AECO, o MAE apresenta um valor melhor do que aquele

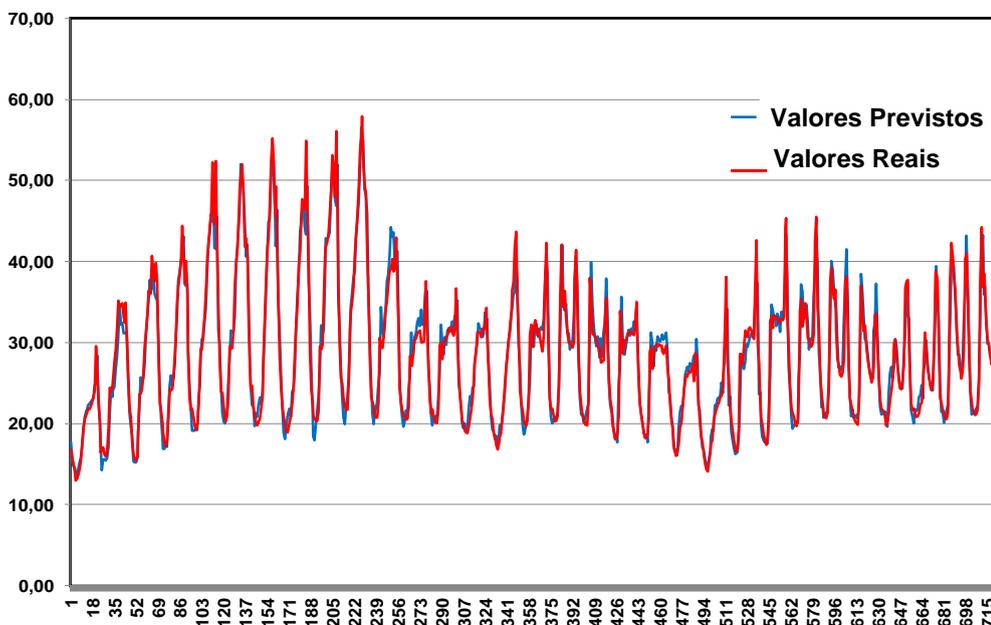
apresentado por Mandal et al. (2009). Comparações gráficas entre os valores estimados e reais podem ser visualizadas por meio das Figuras 9 e 10.

**Figura 9: Valores Reais X Valores Previstos (Outubro/2014) para a Zona PECO.**



Fonte: Autor.

**Figura 10: Valores Reais X Valores Previstos (Outubro/2017) para a Zona PECO.**



Fonte: Autor.

### 4.4 Zona APS

Por fim, a última zona considerada foi a APS (Allegheny Power Systems), onde empregou-se o mesmo período, ou seja, entre 2004 e 2017, priorizando apenas o preço e descartando demais variáveis. Os resultados podem ser observados por meio da Tabela 10.

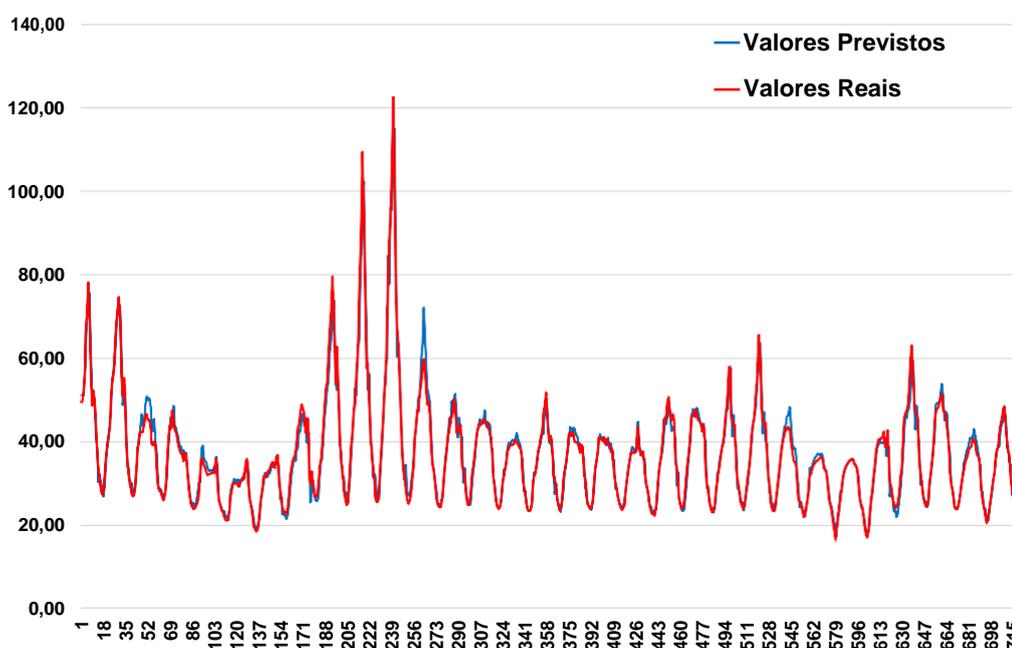
Tabela 9: Erros calculados para a Zona APS.

| ZONA APS |         |
|----------|---------|
| ERROS    | VALORES |
| MAE      | 3,52    |
| MAPE     | 6,26%   |
| RMSE     | 22,43   |

Fonte: Autor.

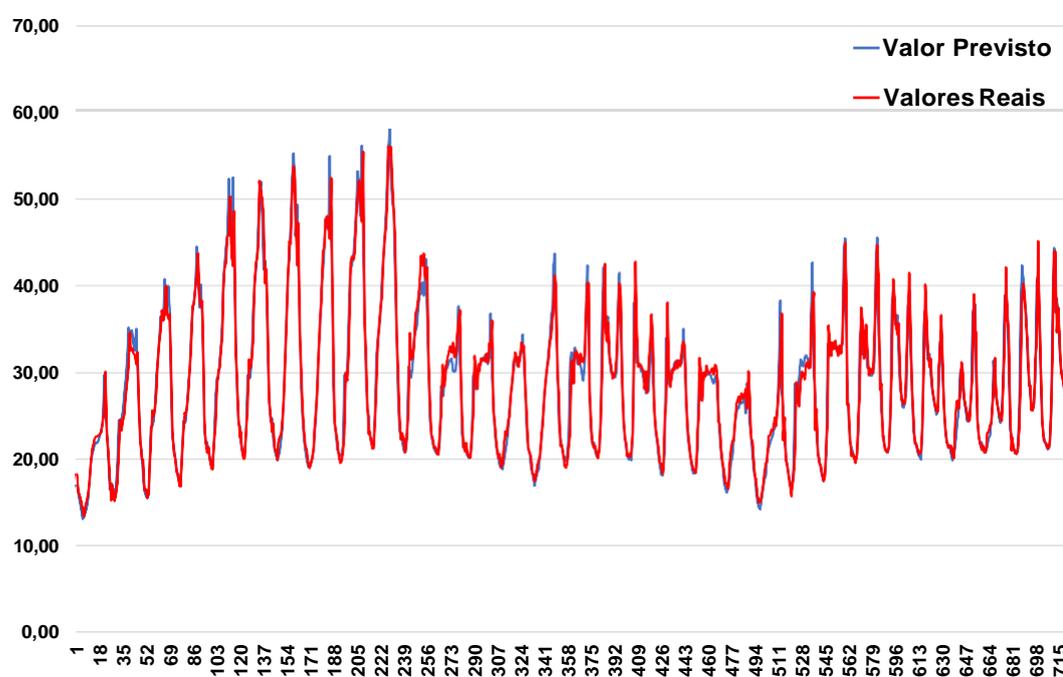
Nesse último caso, percebe-se que tanto o MAE como o MAPE aumentam significativamente. As previsões, em formato gráfico, podem ser visualizadas por meio das Figuras 11 e 12.

Figura 11: Valores Reais X Valores Previstos (Outubro/2014) para a Zona APS.



Fonte: Autor.

Figura 12: Valores Reais X Valores Previstos (Outubro/2017) para a Zona APS.



Fonte: Autor.

É importante mencionar que, após analisar os resultados para cada uma das zonas consideradas, notou-se que o modelo de regressão neural da AEP mostrou-se mais eficaz, visto que apresentou um MAPE de 5,65%. Esse valor pode ser considerado um bom resultado, já que não foi empregado qualquer pré-processamento aos dados. Assim, empregou-se somente os dados do próprio preço para horários anteriores ao que se desejava prever. Esse resultado, além de mostrar o potencial da RNA do tipo MLP, ainda demonstra que a previsão do mercado de energia PJM pode obter melhores resultados do que aqueles mostrados na literatura ao considerar a desagregação do mercado em suas diversas companhias. Nota-se que os resultados das quatro zonas consideradas são bastante semelhantes e, provavelmente, ao aplicar técnicas de pré-processamento de dados já conhecidas pela literatura, estes resultados seriam ainda melhores.

Além disso, o fato de algumas zonas, delimitadas pelas companhias, cobrirem poucos ou muitos estados não foi um fator que afetou a predição das séries temporais. Portanto, acredita-se que companhias que cubram grandes áreas não tenham séries temporais do preço da energia com maior ou menor volatilidade.

# Capítulo 5

## CONCLUSÕES

---

Este trabalho apresentou um modelo de estimação baseado em redes neurais do tipo *feedforward* para auxiliar na tomada de decisão em torno de mercado de energia, visando planejamento de curtíssimo prazo (hora a frente).

As regiões como APS e AEP demonstraram melhores ajustes do modelo, visto que os erros obtidos nos testes foram menores. Apesar da volatilidade dos dados do mercado PJM, os erros analisados a partir do método possuem bons resultados, sendo em alguns casos semelhantes aos melhores apresentados na literatura correlata.

Cabe notar que diversas regiões (cada uma com seu preço diário) foram testadas considerando-se somente o valor histórico do preço da energia, porém há ainda muitas outras possibilidades que poderiam ser averiguadas, como a inclusão de dados de demanda.

Há a possibilidade também de averiguar em quais épocas do ano (inverno, primavera, outono e verão) há um aumento do valor da energia elétrica e quais variáveis impactam na variação do preço. Logo, seria uma oportunidade para demais trabalho do Laboratório de Inteligência Artificial Aplicada (LIAA).

### 5.1 Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior-Brasil (CAPES) – Código de Financiamento 001”. Os autores também agradecem ao apoio financeiro da Rede Nacional de Pesquisa e Ensino (RNP).

# REFERÊNCIAS

---

Aggarwal, S. K., Saini, L. M., e Kumar, A. (2008a). Electricity price forecasting in Ontario electricity market using wavelet transform in artificial neural network based model. **International Journal of Control, Automation, and Systems**, vol 6, no. 5, pp.639– 650.

Aggarwal, S. K., Saini, L. M. e Kumar, A. (2008b). Electricity Price Forecasting in Deregulated Markets: A Review and Evaluation, **International Journal of Electrical Power and Energy Systems**, vol. 31. no 1, pp. 13 -22.

Amjady, N., Daraeepour, A. e Keynia, F. (2010). Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network. **IET Generation, Transmission & Distribution**, vol. 4, no. 3, pp. 432-444.

Amjady, N. e Hemmati, M. (2006). Energy Price Forecasting – Problems and Proposals for such Predictions, **IEEE Power & Energy Magazine**, vol. 2, no. 1, pp. 20- 29.

Amjady, N. e Keynia, F. (2009). Day-ahead price forecasting of electricity markets by a new feature selection algorithm and cascaded neural network technique. **Energy Conversion and Management**, vol. 50, no. 1, pp. 2976–2982.

Chen, X., Dong, Z. Y., Meng, K., Xu, Y., Wong, K. P., e Ngan, H. W. (2012). Electricity price forecasting with extreme learning machine and bootstrapping. **IEEE Transactions on Power Systems**, vol. 27, no. 4, pp. 2055–2062.

Conejo, A. J., Contreras, J., Espínola, R. e Plazas, M. A. (2005a). Forecasting Electricity Prices for a Day-Ahead Pool Based Electric Market, **International Journal of Forecasting**, vol. 21. no. 3, pp. 435-462.

Conejo, A. J., Plazas, M. A., Espínola, R., & Molina, A. B. (2005b). Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models. **IEEE Transactions on Power Systems**, vol. 20, no. 2, pp. 1035–1042.

---

Contreras, J., Espínola, R., Nogales, F. J., e Conejo, A. J. (2003). ARIMA models to predict next-day electricity prices. **IEEE Transactions on Power Systems**, vol. 18, no. 3, pp. 1014–1020.

Garcia-Martos, C., Rodriguez, J., e Sanchez, M. J. (2012). Forecasting electricity prices by extracting dynamic common factors: application to the Iberian Market. **IET Generation, Transmission & Distribution**, vol. 6, no. 1, pp. 11–20.

Garcia, R. C., Contreras, J., Van Akkeren, M., Batista, J., e Garcia, C. (2005). A GARCH Forecasting Model to Predict Day - Ahead Electricity Prices. **IEEE Transactions on Power Systems**, vol. 20, no. 2, pp. 867–874.

Haykin, S. (1999). *Neural Networks - A Comprehensive Foundation*, Prentice Hall.

Mandal, P., Srivastava, A. K., e Park, J. W. (2009). An effort to optimize similar days parameters for ANN-based electricity price forecasting. **IEEE Transactions on Industry Applications**, vol. 45, no. 5, pp. 1888-1896.

Ministério de Minas e Energia (2012). Portaria N° 455 - 2012”, DOU publicado em 03/08/2012.

Motamedi, A., Zareipour, H., e Rosehart, W. D. (2012). Electricity Price and Demand Forecasting in Smart Grids. **IEEE Transactions on Smart Grid**, vol. 3, no. 2, pp. 664–674.

Sahay, K. B. e Tripathi, M. M. (2014). Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Networks, **IEEE Innovative Smart Grid Technologies Conference (ISGT)**, pp 1-5.

Suganthi, L. e Anand, A. S. Energy models for demand forecasting – A review. **Renewable and Sustainable Energy Reviews**, vol. 16, no. 2, pp. 1223-1240, 2011.

Wu, H. C., Chan, S. C., Tsui, K. M. e Hou, Y. (2013). A new recursive dynamic factor analysis for point and interval forecast of electricity price. **IEEE Transactions**

**on Power Systems**, vol. 28, no. 3, pp. 2352–2365.

Wu, L. e Shahidehpour, M. (2010). A hybrid model for day-ahead price forecasting. **IEEE Transactions on Power Systems**, vol. 25, no. 3, pp. 1519–1530.

Zhang, L. e Luh, P. B. (2005). Neural network-based market clearing price prediction and confidence interval estimation with an improved extended Kalman filter method. **IEEE Transactions on Power Systems**, vol. 20, no. 1, pp. 59–66.

Zhao, J. H., Dong, Z. Y., Xu, Z. e Wong, K. P. (2008). A statistical approach for interval forecasting of the electricity price. **IEEE Transactions on Power Systems**, vol. 23, no. 2, pp. 267–276.