

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
**CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA URBANA**

**Aplicação de Redes Neurais Artificiais para Previsão de Demanda e  
Preço de Energia Elétrica no Contexto de Cidades Inteligentes**

Leonel Alejandro Laboissiere

Tese apresentada ao Programa de Pós-Graduação em Engenharia Urbana da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Urbana.

Orientação: Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos

2009

Laboissiere, Leonel

Aplicação de Redes Neurais Artificiais para Previsão de Demanda e Preço de Energia Elétrica no Contexto de Cidades Inteligentes / Leonel Laboissiere. -- 2019.

102 f. : 30 cm.

Dissertação (mestrado)-Universidade Federal de São Carlos, campus São Carlos, São Carlos

Orientador: Ricardo Augusto Souza Fernandes

Banca examinadora: Tatiane Fernandes, Fabbio Borges

Bibliografia

1. Redes neurais artificias. 2. Previsão de séries temporais. 3. Mercado de energia elétrica,. I. Orientador. II. Universidade Federal de São Carlos. III. Título.

Ficha catalográfica elaborada pelo Programa de Geração Automática da Secretaria Geral de Informática (SIn).

DADOS FORNECIDOS PELO(A) AUTOR(A)

Bibliotecário(a) Responsável: Ronildo Santos Prado – CRB/8 7325

## AGRADECIMENTOS

Ao Prof. Dr. Ricardo Augusto Souza Fernandes por ter visto potencial acadêmico em mim e pediu para que eu participasse do processo seletivo no Programa de Pós-Graduação em Engenharia da Urbana (PPGEU). O resultado desse pedido pode ser lido nas próximas páginas.

À Profª Drª Léa Cristina por conceder acesso ao CONFFEE (Laboratório de Conforto e Eficiência Energética do Ambiente Construído) onde esta pesquisa teve um progresso considerável.

Aos professores da PPGEU que me possibilitaram uma melhor compreensão do “universo” que é a cidade. Em especial ao Prof. Dr. Érico Masiero, a quem eu tenho como referência de docente.

Ao meu colega doutorando Prof. Me. André da Fonseca pelo empréstimo do livro *Demand Forecasting in the Electric Utility Industry*, de C. W. Gellings. Além de suas sugestões que veem em qualidade e, principalmente, em abundância.

Ao Prof. Dr. Douglas Barreto por ter me aceitado no PESCD (Programa de Estágio Supervisionado de Capacitação Docente) como estagiário na disciplina de Instalações Elétricas. Sou grato por ter me mostrado como avaliações podem ser conduzidas, com certeza me ajudará na minha futura docência.

Aos meus amigos Matheus Ortiz, Gustavo Rossi e Luís Mazini por terem sempre me recebido na casa deles quando eu precisava de um lugar para ficar. E proporcionarem várias conversas que me fizeram me sentir bem.

Aos meus amigos e engenheiros Rafael Mattazio e Maicon Polizeli quem sempre me socorreram em diversas urgências e por sempre expor seus pontos de vistas e fazerem qualquer diálogo agregador e proveitoso.

Aos colegas do PPGEU pelas conversas e favores que tornaram possível a realização deste trabalho.

À minha família, em especial a minha mãe Flor quem dedicou um amor infinito a mim e minhas duas irmãs. Nunca me esquecerei de sua celebre frase sobre o poder de estudar “se você não acreditar nos livros, no que você acreditará?”.



## RESUMO

Esta pesquisa apresenta uma metodologia baseada em Redes Neurais Artificiais (RNA) para a previsão de demanda e de preço de energia elétrica, considerando o horizonte de curtíssimo prazo. Estimar com acurácia os valores da demanda e do preço é importante aos agentes que participam de mercados de energia. Inclusive, tais previsões podem ser empregadas para aprimorar o planejamento e operação de *Smart Grids* e, conseqüentemente, garantir maior eficiência no uso dos recursos energéticos de Cidades Inteligentes. Como estudo de caso, empregou-se uma base de dados proveniente do estado australiano de *New South Wales*. A base de dados contém valores históricos de demanda, preço da energia e variáveis climatológicas. Cabe mencionar que todas essas variáveis foram pré-processadas por meio de Média Móvel Ponderada (WMA, do inglês *Weighted Moving Average*) para minimizar o efeito de ruído nos dados e auxiliar a identificar tendências. Assim, há um total de 66 variáveis/atributos de entradas das RNAs relacionadas ao preço e a demanda de energia elétrica. Na seqüência, empregou-se o algoritmo *Correlation-based Feature Selection* (CFS), responsável por selecionar um conjunto de variáveis de maior relevância à previsão da demanda e do preço para o horizonte de curtíssimo prazo. Por conseqüência, houve redução de 84 a 90% do número de variáveis consideradas. Ademais, constatou-se que aplicar WMA nas variáveis meteorológicas permitiu que estas pertencentes ao conjunto de dados formado pelo uso do CFS. RNAs com arquitetura *feedforward*, do tipo *Multilayer Perceptron* foram treinadas e validadas por 20 execuções. Os resultados obtidos apresentaram Erros Médios Absolutos Percentuais entre 2,68% e 4,84% para a demanda e 7,06% a 19,01% para o preço.

**Palavras-chave:** Redes neurais artificias, Previsão de séries temporais, Mercado de energia elétrica, Cidades Inteligentes.



## ABSTRACT

This research proposed a very short-term forecasting framework electricity price and demand based on Artificial Neural Networks (ANN). Effectiveness forecasting tools are essential to facilitate the decision making process of the stakeholders in the deregulated electricity market. Besides, accurate short-term load forecasting (STLF) and electricity price forecasting (EPF) play a significant part for controlling and scheduling of smart grids, consequently, to ensure effectiveness energy resources of smart cities. For case study, a dataset from Australian National Electricity Market was used. The dataset is formed by historical from climate variables, demand and prices series. It should be mentioned that all of these variables were preprocessed using the Weighted Moving Average (WMA) to minimize the effect of noise on the data and help identify trends. Therefore, ANN input set are made by 66 variables/attributes. Correlation-based Feature Selection (CFS) algorithm was applied to form the most relevant variable set to STLF and EPF. As a consequence, reduction of 84 to 90% of the number of variables considered. Moreover, WMA of meteorological variables were selected applying CFS. In sequence, 20 executions of training and validation of *Multilayer feedforward* ANN were made. The best results have mean absolute percentage error (MAPE) from 2.68% to 4.84%, for STLF, and MAPE from 7.06% to 19.01%, for EPF.

**Keywords:** Artificial Neural Networks, forecasting of time series, energy market, smart cities.



## LISTA DE ILUSTRAÇÕES

Figura 1 - Ilustração de uma <i>Smart Grid</i> .....	3
Figura 2 - Ilustração de um Sistema Elétrico de Potência.....	13
Figura 3 - Estrutura horizontalmente integrada de um mercado de energia. ....	15
Figura 4 - Estados que compõem o Mercado Nacional de Eletricidade da Austrália. ...	16
Figura 5 - Consumo anual de eletricidade das regiões do Mercado Nacional de Eletricidade da Austrália – Período de início de 1999 ao fim de 2017.....	17
Figura 6 - Cadeia de fornecimento de eletricidade e agentes dos mercados atacadista e varejista do NEM. ....	18
Figura 7 - Consumo anual de eletricidade dos submercados do Mercado Nacional de Eletricidade do Brasil – Período de início de 2009 ao fim de 2017. ....	20
Figura 8 - Arquitetura com $n$ entradas. ....	27
Figura 9 - Comparação entre neurônios biológico e artificial. ....	29
Figura 10 - Arquitetura <i>feedforward</i> de camada única neural. ....	30
Figura 11 - Arquitetura neural recorrente. ....	31
Figura 12 - Esquema das etapas da metodologia utilizada.....	33
Figura 13 - Destaque das estações meteorológicas de NSW.....	35
Figura 14 - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da madrugada. ....	43
Figura 15 - Resultados de previsões de demanda com a base de dados de dias úteis para o período da madrugada. ....	44
Figura 16 - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da manhã. ....	45
Figura 17 - Resultados de previsões de demanda com a base de dados de dias úteis para o período da manhã.....	46
Figura 18 - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da tarde.....	47

Figura 19 - Resultados de previsões de demanda com a base de dados de dias úteis para o período da tarde. ....	48
Figura 20 - Melhores resultados das previsões com a base de dados de dias não úteis - Período da Noite. ....	49
Figura 21 - Resultados de previsões de demanda com a base de dados de dias úteis para o período da noite. ....	50
Figura 22 - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da madrugada. ....	51
Figura 23 - Resultados de previsões de preço com a base de dados de dias úteis para o período da madrugada. ....	52
Figura 24 - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da manhã. ....	53
Figura 25 - Resultados de previsões de preço com a base de dados de dias úteis para o período da manhã. ....	54
Figura 26 - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da tarde. ....	55
Figura 27 - Resultados de previsões de preço com a base de dados de dias úteis para o período da tarde. ....	56
Figura 28 - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da tarde. ....	57
Figura 29 - Resultados de previsões de preço com a base de dados de dias úteis para o período da noite. ....	58

## LISTA DE TABELAS

Tabela 1 - Estações meteorológicas usadas para a formação da base de dados. ....	34
Tabela 2 - Significado do tempo de atraso para as variáveis. ....	36
Tabela 3 - Atributos com as saídas desejadas para as regiões de NSW.....	37
Tabela 4 - Quantidade de neurônios nas camadas intermediárias. ....	38
Tabela 5 - Atributos selecionados da mineração de dados para previsão do Preço. ....	41
Tabela 6 - Atributos selecionados da mineração de dados para previsão da Demanda. .	41
Tabela 7 - Melhores resultados para o período da madrugada de finais de semana e feriados. ....	43
Tabela 8 - Melhores resultados para o período da madrugada de dias úteis. ....	44
Tabela 9 - Melhores resultados para o período da manhã de finais de semana e feriados. ....	45
Tabela 10 - Melhores resultados para o período da manhã de dias úteis. ....	46
Tabela 11 - Melhores resultados para o período da tarde de finais de semana e feriados. ....	47
Tabela 12 - Melhores resultados para o período da tarde de dias úteis. ....	48
Tabela 13 - Melhores resultados para o período da noite de finais de semana e feriados. ....	49
Tabela 14 - Melhores resultados para o período da noite de dias úteis. ....	50
Tabela 15 - Melhores resultados para o período da madrugada de finais de semana e feriados. ....	51
Tabela 16 - Melhores resultados para o período da madrugada de dias úteis. ....	52
Tabela 17 - Melhores resultados para o período da manhã de finais de semana e feriados. ....	53
Tabela 18 - Melhores resultados para o período da manhã de dias úteis. ....	54
Tabela 19 - Melhores resultados para o período da tarde de finais de semana e feriados. ....	55
Tabela 20 - Melhores resultados para o período da tarde de dias úteis. ....	56

Tabela 21 - Melhores resultados para o período da noite de finais de semana e feriados. .....	57
Tabela 22 - Melhores resultados para o período da noite de dias úteis. ....	58
Tabela 23 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Madrugada. ....	67
Tabela 24 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Madrugada. ....	68
Tabela 25 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Manhã. ....	69
Tabela 26 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Manhã. ....	70
Tabela 27 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Tarde. ....	71
Tabela 28 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Tarde. ....	72
Tabela 29 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Noite. ....	73
Tabela 30 - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Noite. ....	74
Tabela 31 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Madrugada. ....	75
Tabela 32 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Madrugada. ....	76

Tabela 33 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Manhã.....	77
Tabela 34 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Manhã. ....	78
Tabela 35 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Tarde. ....	79
Tabela 36 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Tarde.....	80
Tabela 37 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Noite.....	81
Tabela 38 - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Noite. ....	82

## LISTA DE SIGLAS E ABREVIATURAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
AEMO	<i>Australian Energy Market Operator</i>
ARIMA	Modelo Autoregressivo Integrado de Médias Móveis
CFS	<i>Correlation-Based Feature Selection</i>
CSRМ	<i>Clear Sky Solar Radiation CSRМ</i>
$Dem(t)$	Demanda da energia, em <i>MW</i> , no instante de tempo $t$
DNU	Dias Não Úteis
DU	Dias Úteis
EMD	Método de Decomposição Empírica
EML	Aprendizado de Máquina Extremo
FWM	<i>Fixed Weight Method</i>
GRNN	<i>Generalized Regression Neural Network</i>
$I_{plu}$	<i>Índice Pluviométrico</i>
MAE	Erro Absoluto Médio
MAPE	Erro Absoluto Percentual Médio
MCP	Mercado de Curto Prazo
MIMO	<i>Multi-Input Multi-Output</i>
MLP	<i>Perceptron</i> de Múltiplas Camadas
$M_M$	<i>Média Móvel Ponderada</i>
$N_1$	Número de neurônios na 1ª camada neural intermediária
$N_2$	Número de neurônios na 2ª camada neural intermediária
NEM	<i>National Electricity Market</i>
NSW	<i>New South Wales State</i>
PACF	<i>Partial Auto Correlation Function</i>

PLD	Preço Líquido de Diferenças
$Pr(t)$	Preço da energia, em AU\$/MW, no instante de tempo $t$
QLD	<i>Queensland State</i>
RBF	<i>Radial Basis Function</i>
RMSE	Erro Quadrático Médio
RNA	Redes Neurais Artificiais
RTP	<i>Real-Time Pricing</i>
SEP	Sistema Elétrico de Potência
<i>Sol</i>	<i>Incidência Solar</i>
SVR	<i>Support Vector Regression</i>
$T_A$	<i>Tempo de atraso anual</i>
$T_D$	<i>Tempo de atraso diário</i>
TIC	Tecnologias de Informação e Comunicação
$T_{max}$	<i>Temperatura Máxima</i>
$T_{min}$	<i>Temperatura Mínima</i>
$T_S$	<i>Tempo de atraso semanal</i>
VIC	<i>Victorian State</i>
$V_{RA}$	<i>Varição Anual</i>
$V_{RH^{1/2}}$	<i>Varição de Meia Hora</i>
$V_{RS}$	<i>Varição Semanal</i>
VWM	<i>Varying Weight Method</i>

## SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	Justificativa.....	2
1.2	Objetivos .....	5
1.3	Organização.....	6
2	REVISÃO BIBLIOGRÁFICA.....	7
2.1	Métodos Baseados para Previsão de Curto e curtíssimo Prazos em <i>Smart Grids</i> .....	7
2.2	Métodos Baseados em Redes Neurais Artificiais para Previsão de Demanda de Curto e curtíssimo Prazos.....	8
2.3	Métodos Baseados em Redes Neurais Artificiais para Previsão de Preços de Curto e curtíssimo Prazos.....	10
3	Mercado de Energia .....	13
3.1	Mercado de Energia da Austrália .....	16
3.2	Mercado de Energia do Brasil .....	19
4	Técnicas de análise de SÉRIES TEMPORAIS .....	23
4.1	Fundamentos de mineração de dados .....	24
4.1.1	Seleção de atributos .....	25
4.2	Redes Neurais Artificiais .....	26
4.2.1	Neurônio Artificial - <i>Perceptron</i> .....	28
4.2.2	Funções de Ativação .....	29
4.2.3	Arquiteturas.....	30
5	METODOLOGIA.....	33
5.1	formação da base de dados.....	33
5.2	Pré-processamento de dados .....	35
5.3	Parametrização das Redes neurais artificiais.....	38
5.4	Treinamento/Validação das redes neurais artificias .....	39
6	RESULTADOS .....	40

6.1	Seleção de Atributos .....	40
6.2	Resultados da Previsão de Demanda de Energia Elétrica.....	42
6.2.1	Base de Dados de Finais de Semana e Feriados – Período da Madrugada.....	42
6.2.2	Base de Dados de Dias Úteis – Período da Madrugada.....	43
6.2.3	Base de Dados de Finais de Semana e Feriados – Período da Manhã.....	44
6.2.4	Base de Dados de Dias Úteis – Período da Manhã.....	45
6.2.5	Base de Dados de Finais de Semana e Feriados – Período da Tarde .....	46
6.2.6	Base de Dados de Dias Úteis – Período da Tarde .....	47
6.2.7	Base de Dados de Finais de Semana e Feriados – Período da Noite.....	48
6.2.8	Base de Dados de Dias Úteis – Período da Noite.....	49
6.3	Resultados da Previsão DO PREÇO da Energia Elétrica .....	50
6.3.1	Base de Dados de Finais de Semana e Feriados – Período da Madrugada.....	51
6.3.2	Base de Dados de Dias Úteis – Período da Madrugada.....	52
6.3.3	Base de Dados de Finais de Semana e Feriados – Período da Manhã.....	53
6.3.4	Base de Dados de Dias Úteis – Período da Manhã.....	54
6.3.5	Base de Dados de Finais de Semana e Feriados – Período da Tarde .....	55
6.3.6	Base de Dados de Dias Úteis – Período da Tarde .....	56
6.3.7	Base de Dados de Finais de Semana e Feriados – Período da Noite.....	57
6.3.8	Base de Dados de Dias Úteis – Período da Noite.....	58
7	CONCLUSÕES .....	59
	REFERÊNCIAS BIBLIOGRÁFICAS.....	61
	ANEXO I.....	67



# 1 INTRODUÇÃO

O crescimento das cidades é acompanhado pela expansão do consumo de recursos naturais. Em 2015, a população urbana era de aproximadamente 4 bilhões, ou seja, em torno de 54% da população global. Estima-se que em 2030, a população urbana de países desenvolvidos dobre, os quais são os maiores consumidores de recursos naturais (UN-HABITAT, 2016). Além disso, projeta-se que, em 2050, 70% da população mundial viverá em regiões urbanas (MOHANTY; CHOPPALI; KOUGIANOS, 2016).

Ainda é cabível mencionar que 600 cidades representam 25% da população mundial, enquanto somente um décimo das pessoas habitam as 30 maiores metrópoles do globo. Apesar das cidades ocuparem menos de 3% da área terrestre, seus residentes consomem mais de  $\frac{3}{4}$  dos recursos naturais e são os principais responsáveis pelas emissões dos gases de efeito estufa (NAM; PARDO, 2011).

Segundo Un-Habitat (2016), estima-se que a demanda global por energia e água será respectivamente incrementada em 40% e 50% em 2030. Por esta ótica, a expansão das cidades deve seguir pelo viés da sustentabilidade e o uso da inteligência nas cidades pode ser a resposta para concretizar esse desenvolvimento.

Nos últimos anos, também ocorreu um massivo crescimento das Tecnologias da Informação e Comunicação (TIC) para otimizar a operação de serviços das cidades (MOHANTY; CHOPPALI; KOUGIANOS, 2016). A utilização das TIC nas cidades é impulsionada pela busca por uma melhor gestão dos problemas decorrentes da expansão urbana. Conseqüentemente, criou-se um novo conceito denominado de Cidade Inteligente (proveniente do termo em inglês, *Smart City*). Basicamente, uma Cidade Inteligente apresenta três características fundamentais: instrumentação, inteligência e interconectividade. Entende-se por instrumentação a obtenção de dados em tempo real, provenientes de distintas fontes. A inteligência é voltada às tomadas de decisões, visando aprimorar a operacionalização das cidades. Já a interconectividade representa a junção/fusão dos dados coletados das múltiplas fontes (HARRISON *et al.*, 2010).

No contexto das Cidades Inteligentes, um recurso fundamental é a energia elétrica, a qual deve ser confiável e com preço acessível a seus habitantes (CRAMTON, 2017). Acrescenta-se que o sétimo objetivo da Agenda 2030 (UN, 2015) é garantir o acesso à energia elétrica, à sustentabilidade energética e à modernização dos sistemas elétricos. Portanto, pode-

se dizer que a Agenda 2030 reflete o conceito de *Smart Grids*, o qual está inserido no contexto das Cidades Inteligentes. Salienta-se que a energia elétrica das Cidades Inteligentes é idealizada por meio do conceito de *Smart Grids*.

*Smart Grid* permite que o setor de energia promova melhor gerenciamento de fornecimento e transmissão de eletricidade e empodera os consumidores a terem mais controle sobre suas decisões relacionadas à energia (HOSSAIN; ALI, 2013). Esse maior poder de decisão se deve ao fato de que nas *Smart Grids* há integração de consumidores, geradores e os chamados *prosumers* (que são produtores e consumidores de energia elétrica) (MOHANTY; CHOPPALI; KOUKIANOS, 2016). Essa integração traz benefícios socioeconômicos, ambientais e técnicos. Ainda é importante mencionar que outro elemento caracterizador das *Smart Grids* é a informação, a qual deve colaborar com a confiabilidade e a eficiência do sistema (BHAROTHU; SRIDHAR; RAO, 2014). Neste sentido, observa-se que, assim como as Cidades Inteligentes, as *Smart Grids* necessitam de TIC.

Com a expectativa de que haja uma gestão de recursos energéticos de forma sustentável em um ambiente de mercado não regulado. Segundo Yang *et al.* (2017), a nível mundial, setores de geração e comercialização de eletricidade vem se estruturando para estarem adaptados em um mercado no qual a comercialização de energia se dá por meio de esquemas de preços flexíveis. O objetivo de agentes/instituições não reguladas é fornecer um suprimento confiável e adequado de eletricidade aos consumidores a preços razoáveis (GELLINGS; BARRON, 1996). Acrescenta-se que aos agentes de mercados de energia modernos, a previsão da demanda é crucial para otimizar seu gerenciamento energético de forma sustentável e lucrativa (YANG *et al.*, 2017).

Neste sentido, estimar a demanda e o preço da energia elétrica é essencial para obter uma gestão energética sustentável e uma operação confiável de mercados de energia modernos.

## **1.1 JUSTIFICATIVA**

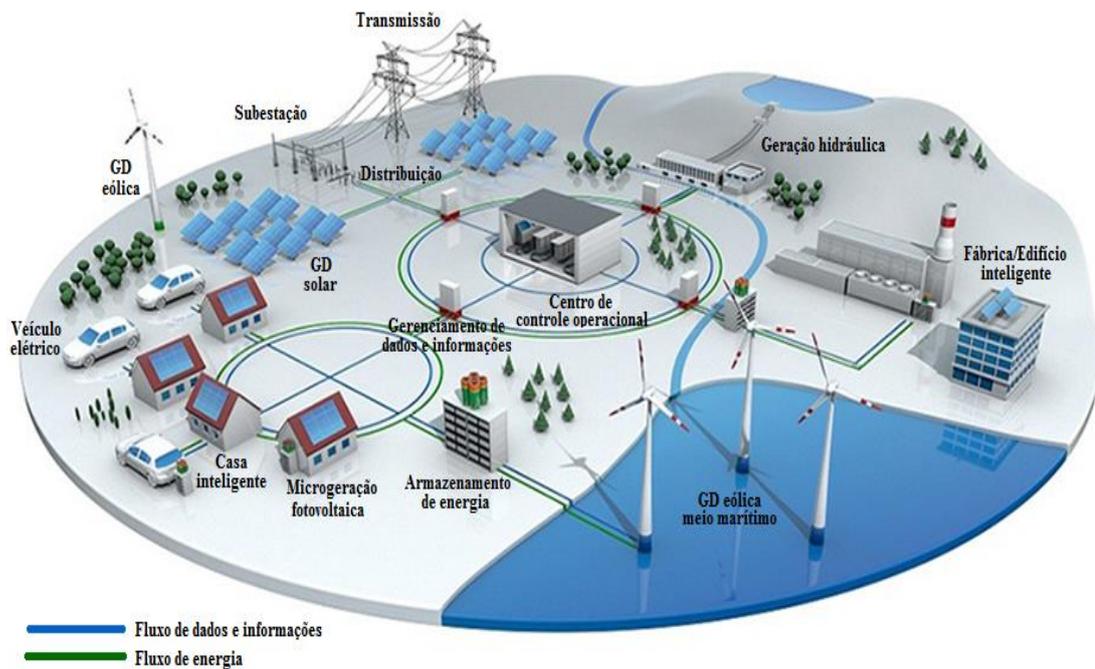
Conforme Mohanty; Choppali e Koukianos (2016), uma Cidade Inteligente é onde os recursos e serviços são flexíveis, eficientes e sustentáveis. Adiciona-se que as vantagens das *Smart Grids* são: melhorias em qualidade e confiabilidade do suprimento de energia; utilização de fontes de energias renováveis; acréscimo de opções de escolha do consumidor; e ambientação para novos produtos, serviços e mercados (BHAROTHU; SRIDHAR; RAO,

2014). Neste sentido, observa-se que, assim como as Cidades Inteligentes, as *Smart Grids* necessitam de ferramenta de Inteligência Computacional para garantirem flexibilidade, eficiência e sustentabilidade aos seus usuários.

Gerenciar os problemas decorrentes da Cidade Inteligente, e/ou *Smart Grids*, requer informação como o futuro preço e futura demanda de determinado recurso. Neste contexto, pode-se destacar as RNAs, as quais podem ser aplicadas em abordagens que visam as previsões de demanda e de preço de energia elétrica. A eletricidade de uma cidade inteligente é proveniente de uma *Smart Grid*, cuja informação é crucial para uma eficiente operação.

Como conceito aplicado no âmbito de sistemas elétricos de potência, uma *Smart Grid* transformará a rede de interconexão entre consumidores e produtores de energia elétrica no sentido tecnológico. Em outras palavras, uma *Smart Grid* utilizará fluxo bidirecional de eletricidade e informação a fim de proporcionar para as redes de distribuição de energia elétrica uma melhor gestão em termos de planejamento e operação (BHAROTHU; SRIDHAR; RAO, 2014). Ilustra-se na Figura 1 o fluxo bidirecional, que permite empoderar os consumidores a terem mais controle sobre suas decisões relacionadas à energia (HOSSAIN; ALI, 2013)

**Figura 1** - Ilustração de uma *Smart Grid*



**Fonte:** <https://profgandhiferrari.files.wordpress.com/2013/05/mc3b3dulo-i.pdf>.

Pode ser afirmado que *Smart Grid* é tão conceitual quanto *Smart City*. Assim, é questionado o que está sendo feito em geração distribuída que possa tornar a *Smart Grid* presente. *Microgrid* pode ser a resposta. Conforme Bharothu; Sridhar; Rao (2014), *Microgrid* é um fundamento essencial para o progresso da *Smart Grid*, pois a combinação de *Microgrids* é o que resultará na formação de *Smart Grids*.

Os usuários de uma *Microgrid* podem produzir eletricidade por meio de painéis fotovoltaicos, turbinas eólicas e células combustíveis a tal ponto que pode estar em operação ilhada. Dessa maneira, uma *Microgrid* possui uma autonomia devido à presença de geradores elétricos, acumuladores de eletricidade e cargas (BHAROTHU; SRIDHAR; RAO, 2014). Dito de outra forma, a *Microgrid* pode operar desconectada do Sistema Elétrico de Potência (SEP). Contudo, mesmo na operação ilhada, os usuários da rede continuarão trocando informações com o SEP (BHAROTHU; SRIDHAR; RAO, 2014).

Todos os usuários de uma *Microgrid* ou *Smart Grid* serão participantes de um mercado de comercialização de energia. Para os participantes de um mercado de livre comercialização de energia elétrica, como comentado por Panapakidis e Dagoumas (2017), é crucial uma precisa estimativa do preço e da demanda de energia elétrica. Porém, tais séries temporais apresentam complexas características, tais como não-linearidade, não-estacionaridade e volatilidade, que dificultam a previsão.

Contudo, uma precisa estimativa do preço e da demanda de energia garantem informação essencial para uma operação eficiente das *Smart Grids* (WANG *et al.*, 2017). Conforme relatado em OGLIARI *et al.* (2014), métodos de previsão baseados em Inteligência Computacional podem dar suporte para a produção de eletricidade e administração do consumo.

Em Gellings; Barron (1996) é questionado o porquê da dificuldade da predição da demanda e a resposta é que o consumo da eletricidade é determinada pelo comportamento de milhões de consumidores. Cada um toma inúmeras decisões que influenciam os níveis de consumo. Naturalmente, o preço para suprir esse consumo é influenciado por tais decisões, as quais estão relacionadas com variáveis, também difíceis de prever, que se alteram com a passagem do tempo.

O preço da eletricidade é uma das mais importantes variáveis, que mudam com a passagem do tempo, que influencia o comportamento dos consumidores de energia elétrica (GELLINGS; BARRON, 1996). Acrescenta-se que os preços das fontes de energia influenciam as tomadas de decisões de consumidores. Neste sentido há incertezas perante o preço futuro da

energia e a futura demanda dos consumidores. Ademais, ao considerar a ambientação proporcionada por cidades inteligentes, outro fator que torna mais complexo a dinâmica da estimação do preço e da demanda é o *prosumer*.

Ao se fazer uma previsão há quatro janelas temporais empregadas: curtíssimo, curto, médio e longo prazos. Longo prazo representa uma janela temporal de 1 a 10 anos, médio prazo está no intervalo de uma semana até um ano, curto prazo de uma hora até uma semana, enquanto curtíssimo prazo denota uma escala temporal de um minuto a uma hora (LAOUAFI *et al.*, 2017), (SETIAWAN; KOPRINSKA; AGELIDIS, 2009) e (SEIFI; SADEGH SEPASIAN, 2011). Há autores como Shao *et al.* (2017) que consideram a previsão com escala temporal inferior a horária como de curto prazo, isto é, não utiliza a terminologia curtíssimo prazo.

Conforme exposto no Capítulo 2, nota-se que metodologias de previsão baseadas em RNA têm apresentando resultados expressivos e podem oferecer uma informação valiosa (a previsão) para os participantes de mercados de livre comercialização de energia elétrica. Neste sentido, justifica-se a utilização das RNAs para a previsão de demanda e de preço da eletricidade na janela temporal de curtíssimo prazo.

## 1.2 OBJETIVOS

Em vista do exposto, é estabelecido que o objetivo geral desta pesquisa de mestrado está vinculada à obtenção e aplicação de uma metodologia baseada em Redes Neurais Artificiais (RNA) que possibilite uma adequada estimação de demanda e do preço da energia elétrica, em uma janela temporal de curtíssimo prazo, para região de *New South Wales* (NSW) do Mercado Nacional de Eletricidade da Austrália.

Dentro dessa ambientação, os objetivos específicos desta pesquisa de mestrado são:

- Formação de uma consolidada base de dados com intuito de gerar uma fonte de entradas relevantes para a previsão do preço e da demanda de energia elétrica;
- Implementação de um método de previsão, do qual espera-se um Erro Absoluto Percentual Médio (MAPE, do inglês *Mean Absolute Percentage Error*) inferior ou igual a 5% para demanda e inferior ou igual a 10% para o preço;
- Análise da viabilidade da aplicação do método no contexto de cidades inteligentes.

### 1.3 ORGANIZAÇÃO

A dissertação está organizada em capítulos, os quais apresentam as seguintes informações:

- O Capítulo 1 apresentou as considerações iniciais, objetivos e justificativas da pesquisa;
- No Capítulo 2 é apresentado o estado da arte relacionado à aplicação de ferramentas de inteligência computacional, principalmente RNAs, para a previsão de séries temporais no âmbito da eletricidade, destacando-se aquelas que se demonstram aderentes ao contexto de *Smart Cities* e/ou *Smart Grids*;
- No Capítulo 3 é mostrado um panorama geral do mercado de energia, dando-se maiores detalhes ao mercado australiano, visto que esse é alvo da pesquisa;
- No Capítulo 4 são tratados conceitos fundamentais sobre previsão de séries temporais, incluindo uma abordagem inicial de modelos de estimação empregados no contexto de mercado de energia. Posteriormente, são apresentados os conceitos de seleção de atributos e também de RNA;
- O Capítulo 5 é destinado aos aspectos metodológicos aplicados para previsão de demanda e de preço da energia de regiões australianas;
- No Capítulo 6 são apresentados os resultados obtidos e discussões;
- Por fim, o Capítulo 7 apresenta as conclusões da dissertação.

## 2 REVISÃO BIBLIOGRÁFICA

Apresenta-se nas seções subsequentes uma revisão bibliográfica na qual há o emprego de metodologias para a previsão de séries temporais baseadas em sistemas inteligentes, no contexto de *Smart Grids* e/ou de mercados de comercialização de energia.

No levantamento do estado da arte foram considerados trabalhos com foco em curto e curtíssimo prazos (escala temporal de um minuto a uma hora), pois o presente trabalho aborda a janela temporal de curtíssimo prazo (30 minutos). Assim, as três seções subsequentes abordam trabalhos de relevância científica no contexto de *Smart Grids* e/ou Cidades Inteligentes.

### 2.1 MÉTODOS BASEADOS PARA PREVISÃO DE CURTO E CURTÍSSIMO PRAZOS EM *SMART GRIDS*

Previsão de demanda pode ser definida como a medida da exatidão da diferença entre os valores atual e previsto de uma futura demanda (BALIYAN; GAURAV; MISHRA, 2015). Métodos de previsão robustos são fundamentais para uma eficiente operação de um sistema de potência moderno. Neste ambiente, é presente a geração de energia solar e eólica, as quais são fortemente influenciadas pelo clima. Perante as incertezas climatológicas, modelos de previsão baseados em sistemas inteligentes, conforme exposto pela literatura, podem desempenhar funções vitais para despacho econômico e fluxo de potência que, conseqüentemente, implicam no planejamento das *Smart Grids*.

Um modelo de previsão proposto por Zameer *et al.* (2017), implementa um sistema híbrido entre Algoritmo Genético e RNA a fim de estimar a potência fornecida pelo vento para cinco parques eólicos localizados na Europa, considerando um horizonte de curto prazo.

Ainda no contexto de estimação de séries temporais associadas a parques eólicos, encontra-se em Chang *et al.* (2017) a utilização de um modelo de Rede Neural de Base Radial (RBF, do inglês *Radial Basis Function*) com retroalimentação do erro (IRBFNN-EF) para fazer a previsão da demanda e da velocidade do vento de um parque eólico em Taiwan, considerando o horizonte de 72 horas. Por outro lado, em Quan; Srinivasan e Khosravi (2014) é desenvolvido um modelo baseado em RNA para a construção de intervalos de previsão utilizando dados da demanda de energia elétrica de Singapura e de *New South Wales* (NSW, Austrália) para a previsão de potência do vento.

Percebe-se que a combinação de modelos é comum. Outra tipologia de hibridização de modelos para previsão de séries temporais é a combinação de modelos de sistemas físicos como se adota em Gandelli *et al.* (2014), Dolara *et al.* (2015) e Leva *et al.* (2017). Basicamente, nesses trabalhos, há o emprego de uma RNA do tipo *Multilayer Perceptron* (MLP) combinada com o modelo físico *Clear Sky Solar Radiation* (CSRSM) para a previsão de produção de energia solar. Esse modelo híbrido tem seu desempenho comparado a um modelo baseado somente em MLP. Dessa forma, em todos os trabalhos foi possível verificar que o modelo híbrido é mais preciso.

Em Ogliari *et al.* (2014), os autores fazem uso de uma MLP com treinamento *backpropagation* para prever, nas próximas 24 horas, a potência produzida por uma planta fotovoltaica localizada no Norte da Itália. Neste estudo, a base de dados de entrada foi dividida em três subgrupos de dias (ensolarados, parcialmente nublados e nublados), além de fazer testes com diferentes números de neurônios nas camadas intermediárias. Assim, os autores puderam avaliar a eficácia de distintas topologias da RNA do tipo MLP, bem como o impacto de cada subgrupo de dados de entrada no desempenho do modelo.

## **2.2 MÉTODOS BASEADOS EM REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE DEMANDA DE CURTO E CURTÍSSIMO PRAZOS**

Em Hernández *et al.* (2014) é apresentada a previsão de demanda de curto prazo utilizando dados históricos de 1º de Janeiro de 2008 a 31 de Dezembro de 2010 da capital da província de Sória, Espanha. Neste estudo, foi considerado um modelo que mapeia padrões dos dias que compõem os dados históricos, agrupados pelo algoritmo de clusterização *k-means*. Assim, cada grupo é dado como entrada de RNAs do tipo MLP que, por sua vez, estimam a demanda em um ambiente de *Microgrids*.

A presença de fontes de energia renováveis em *smart grids* garante maior volatilidade à produção da energia elétrica. Somada esta característica ao uso de cargas de grande incerteza (como é o caso do carregamento de veículos elétricos), torna a demanda uma variável de difícil previsão. Para lidar com tais incertezas, em Quan; Srinivasan; Khosravi, (2014), um modelo baseado em RNA de arquitetura *feedforward* foi empregada à previsão de curto prazo da demanda de *New South Wales*, Austrália. Em comparação com resultados de métodos clássicos (suavização exponencial e ARIMA), a metodologia proposta foi capaz de obter considerável melhora, com MAPEs entre 2,14% e 2,15%.

Para a estabilidade de um sistema de potência é essencial a previsão da carga no curto prazo. Por este motivo, em Hu *et al.* (2017) é usado o modelo de Rede Neural com Regressão Generalizada (GRNN, do inglês *Generalized Regression Neural Network*) para a previsão de curto prazo da região de Dalian, Taiwan. Em Sepasi *et al.* (2017), verifica-se a utilização de uma RNA para prever a carga de uma subestação que encontra-se conectada em paralelo com um sistema de baterias, ambos localizados na ilha de Maui, no estado de Hawaí (Estados Unidos). Destaca-se que a estimação é no horizonte de curtíssimo prazo (15 min).

Uma combinação de modelos SARIMA-ARIMA Sazonal, HWT-Holt-Winters, RNA do tipo MLP e Sistema de Inferência Neuro-*Fuzzy* Adaptivo é proposta para prever a demanda no mercado francês e também para o mercado de *New South Wales*. Considerou-se um horizonte de curtíssimo prazo (uma hora), em que obteve-se MAPEs inferiores a 1% para ambas as bases de dados analisadas (LAOUAFI *et al.*, 2017).

Conforme relatado em Li *et al.* (2017), métodos clássicos de previsão não são eficazes ao abordarem uma série temporal de demanda de energia elétrica, a qual é caracterizada por não-linearidade. Os autores propuseram um processamento das séries temporais por meio da técnica PACF (*Partial Auto Correlation Function*) e do ajuste Sazonal, com o intuito de servirem de entradas às ferramentas GRNN e SVR (*Support Vector Regression*). O modelo híbrido foi responsável pela previsão da demanda de energia das regiões australianas de *New South Wales* (NSW) e *Victorian* (VIC), obtendo MAPEs inferiores a 1,2%.

Com o crescente interesse no desenvolvimento de *Smart Grids* cuja infraestrutura facilitará a mudança da dinâmica de preços e tarifas não fixas de energia elétrica, ocorrerá mudanças no comportamento do consumidor de energia. Nesta nova contextualização, há a necessidade de considerar o preço e a demanda intrinsecamente relacionados. Assim, ao considerar essa relação, em Motamedi; Zareipour e Rosehart (2012), é proposto um modelo híbrido de três estágios: (1) módulo *Multi-Input Multi-Output* (MIMO) para prever demanda e preço; (2) utilização de algoritmo que extrai relações da dinâmica entre preço e demanda e as ordena em regras *se-então* usadas para formar uma lógica *fuzzy*; e (3) aprimora a estimação calculada pelo módulo MIMO.

Em Xiao *et al.* (2016), os autores propõem um modelo híbrido que integra as seguintes redes neurais: MLP com algoritmo de treinamento *backpropagation*, MLP hibridizada com *backpropagation* e algoritmo genético, rede neural ponderada e GRNN. Utilizaram-se dados das regiões australianas de *Victoria*, *Queensland* e *New South Wales* no período de 2006 a 2008.

De forma comparativa, notou-se que o modelo híbrido apresenta melhores resultados do que os modelos individuais, com MAPEs inferiores a 1,25%.

Propor métodos eficazes na previsão de curto prazo para demanda de eletricidade é desafiante, mas é indispensável para o gerenciamento de sistemas elétricos. Em Chen *et al.* (2018), os autores propõem uma metodologia que combina o método de decomposição empírica (EMD, do *Empirical Mode Decomposition*) e aprendizado de máquina extremo (ELM, do inglês *Extreme Learning Machine*) para prever meia hora adiante as demandas das regiões australianas de *Victoria*, *Queensland* e *New South Wales*. Entretanto, utiliza subconjuntos de dados com 8 dias e obtêm MAPEs entre 0,4003% e 5,1306%.

Nota-se, por meio da literatura analisada, o emprego de técnicas de tratamento de sinais. Em Shao *et al.* (2017), os autores apresentam uma revisão de trabalhos que aplicam técnicas de decomposição no domínio da frequência para a previsão de demanda. Nos trabalhos com escalas temporais de curto prazo, minuto a hora, foi verificada a identificação de tendências e ciclos, sendo que os principais fatores são meteorológicos e o preço da eletricidade. Ademais, as técnicas de aprendizado de máquina mais aplicadas são RNA e SVM (*Support Vector Machines*).

Uma minuciosa revisão da literatura sobre previsão de demanda/carga é apresentada e discutida em Hong e Fan (2016), na qual os autores comentam a falta de reprodução e de compreensão de alguns estudos, além de apontar a confiabilidade de previsão em análises empíricas.

## **2.3 MÉTODOS BASEADOS EM REDES NEURAIIS ARTIFICIAIS PARA PREVISÃO DE PREÇOS DE CURTO E CURTÍSSIMO PRAZOS**

Com o passar dos anos e também devido às tecnologias desenvolvidas em torno de fontes alternativas e armazenamento de energia, muitos consumidores estão se tornando *prosumers*, o que evidencia que todas as partes envolvidas no ambiente de *Smart Grids* deverão interagir entre si, principalmente, em um ambiente onde a energia elétrica é negociada como *commodity*. Por esta ótica, a previsão do preço da energia elétrica também se faz necessária.

Woon e Aung (2017) propõem um método de previsão de preço para a hora a frente dos mercados de energia da Espanha, Austrália e Estados Unidos. Para tanto, são considerados dois modelos, a saber: *Fixed Weight Method* (FWM) e *Varying Weight Method* (VWM). A base de

dados é formada por valores de 2006 a 2012 com um total de 36 variáveis/atributos representados por preços de horas anteriores, anos e semanas anteriores, dias úteis, finais de semana, feriados e temperatura.

Cabe mencionar que há uma tendência de os mercados de energia tornarem-se não regulamentados. Portanto, os mesmos serão mais competitivos, pois contaram com a inserção de novos participantes, cuja viabilidade econômica depende fortemente do reconhecimento de padrões do preço *spot* da energia elétrica. Em Panapakidis e Dagoumas (2016) são desenvolvidos seis modelos baseados em RNA com arquitetura MLP, as quais são treinadas pelo algoritmo de Levenberg-Marquardt para prever preços da região sul da Itália. Os seis modelos apresentaram MAE (*Mean Absolute Error*) entre 6 a 6,2.

Ao analisar a literatura correlata, percebe-se que dificilmente é feita uma estimação direta da série temporal, seja para o preço ou para a demanda de energia elétrica. Neste sentido, é comum dividir a série temporal em outras séries temporais menores e com dados mais correlatos, a partir das quais se realiza a previsão. Em Yong *et al.* (2017), as séries da demanda e do preço de energia elétrica do estado australiano *Queensland* (QLD) são divididas em sete conjuntos, de acordo com os sete dias da semana. Cada conjunto serve como entrada de dados de uma RNA com três camadas neurais. Já em Wan *et al.* (2017), são criados intervalos de predição de preços para a região australiana de *New South Wales* (NSW) utilizando uma janela temporal de três anos: Janeiro de 2007 a Dezembro de 2009.

Segundo Foruzan; Scott e Lin (2015), a previsão precisa do preço é uma informação crucial para produtores e consumidores de energia elétrica, pois torna-se possível formar estratégias de redução de riscos e alavancagem de lucros no mercado de energia, visto que o mesmo passa a se assemelhar a mercados financeiros. Os referidos autores desenvolvem três modelos de previsão de preço para o mercado de energia de Nova Iorque, sendo um deles baseado em SVM e outros dois baseados em RNA com arquitetura MLP. Os modelos propostos apresentaram RMSEs inferiores a 6,5.

Em Keles *et al.* (2016) afirma-se que modelos de previsão baseados em RNA requerem uma apropriada seleção e preparação dos dados de entrada. Deste modo, uma adequada topologia de RNA pode ser definida e testada a fim de verificar as predições sobre preço da eletricidade. Os dados de entrada, além serem compostos por valores históricos de preço, também possuem valores históricos de demanda, de preços de combustíveis, de dados climáticos e de dados referentes a calendário, exemplo feriados. Em relação à preparação dos dados, foi feita análise de autocorrelação e cálculos indicadores sobre tendências e

sazonalidade. Ademais, foram testadas as funções de ativação logarítmica e tangente hiperbólica em conjunto com diversos valores de *momentum* e taxa de aprendizado. Por fim, obteve-se RMSEs entre 8,23 e 170,69 utilizando dados do mercado *European Power Exchange* (EPEX).

Em Dudek (2016), utiliza-se uma RNA de arquitetura MLP com cinco neurônios na camada intermediária, ativados por função sigmoide. Além disso, empregou-se na camada de saída um neurônio, ativado por função linear. Buscou-se prever o preço da eletricidade para um dia adiante. Os dados foram obtidos na *Global Energy Forecasting Competition 2014* (GEFCom2014), os quais correspondem a um intervalo de três anos e contém informações históricas sobre preço, demanda e regiões. Os autores utilizaram o método de regularização de Bayes no algoritmo de Levenberg-Marquardt para evitar a memorização excessiva (*overfitting*).

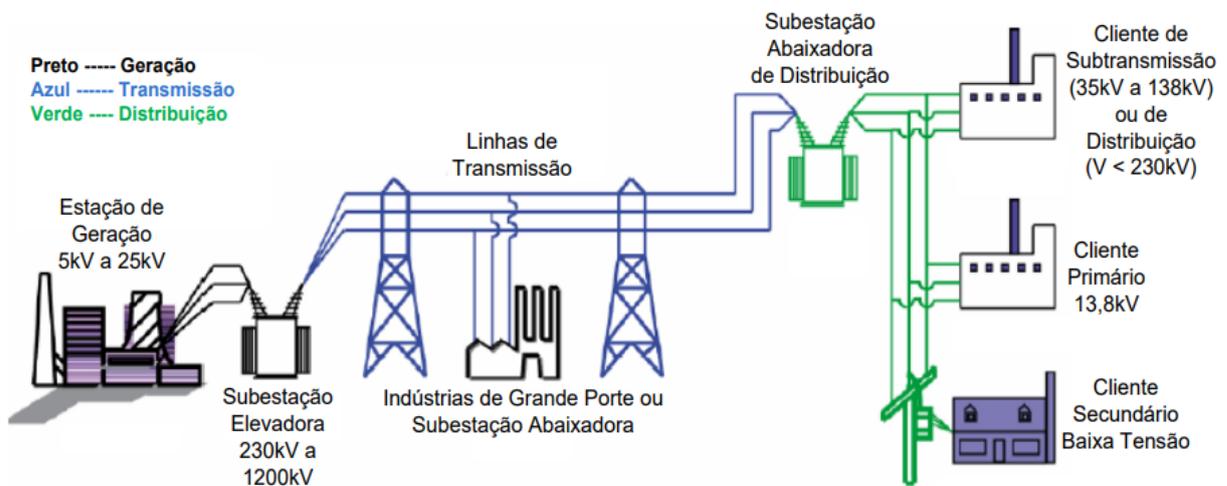
Em Bento *et al.* (2018), é proposto um modelo de previsão de curto prazo baseado em RNA com uso de transformada *wavelet*. Além disso, realizou-se a seleção de atributos mais relevantes por meio do algoritmo de otimização *bat*. Dados históricos foram utilizados, provenientes dos mercados de energia da Espanha e Pennsylvania-New Jersey-Maryland (PJM). Os resultados apresentaram valores de MAPE médios inferiores a 1%.

### 3 MERCADO DE ENERGIA

Mercados de energia são elaborados para fornecer eletricidade com confiabilidade a um baixo custo aos consumidores. Globalmente, os mercados de energia possuem significativas particularidades, o que reflete conjecturas políticas e econômicas distintas. Porém, os mercados de energia estão em um processo de transição de fontes de energia baseadas em combustíveis fósseis para fontes de energia renováveis (CRAMTON, 2017).

O objetivo de fornecer energia elétrica a um baixo custo aos consumidores não é tarefa simples, pois a cada segundo, demanda e produção devem ser balanceados. Para tanto, o mercado deve proporcionar sinais de preços corretos para possibilitar uma geração e investimentos eficientes com o passar do tempo (CRAMTON, 2017).

**Figura 2 - Ilustração de um Sistema Elétrico de Potência.**



**Fonte:** <https://profghandhiferrari.files.wordpress.com/2013/05/mc3b3dulo-i.pdf>.

Na Figura 2, é mostrada uma representação de um Sistema Elétrico de Potência (SEP), a qual ilustra a conexão entre os equipamentos responsáveis pela produção, transmissão e fornecimento da energia elétrica aos consumidores. Pela ilustração, é possível notar que o consumidor não possui alternativa a não ser adquirir eletricidade da distribuidora de energia da região onde se encontra (BEGGS, 2002a).

Segundo Gellings; Barron (1996), concessionárias de energia visam o fornecimento adequado e confiável de eletricidade aos consumidores a preços razoáveis. Na descrição do

mercado de energia realizado pela Empresa de Pesquisa Energética acrescenta-se que o planejamento do SEP é essencial para garantir o abastecimento e/ou suprimento de energia ao menor custo, com o menor risco e com os menores impactos socioeconômicos e ambientais para a sociedade (EPE, 2005). Conforme Beggs (2002a), os monopólios previnem a competição no mercado de energia.

Nos primórdios, a comercialização de eletricidade era por monopólios, os quais eram configurados em um sistema regulatório baseado sobre uma taxa fixa, além de toda a operação de geração, transmissão e distribuição ser administrada por uma única organização (CRAMTON, 2017). Devido as edificações terem somente uma única conexão física para o fornecimento de energia, espera-se que monopólio como fornecedor de energia (BEGGS, 2002a).

Segundo Beggs (2002b), as consequências em um ambiente no qual não se pode escolher o fornecedor de energia, além de comprar eletricidade a preço fixo, são:

- Não há competição – o consumidor situa-se em uma posição desfavorável, pois os preços são estabelecidos pela distribuidora de energia;
- Não há mercado – preços da eletricidade sobre uma taxa fixa não refletem as oscilações da demanda;
- A possibilidade de haver subsídio cruzado – a concessionária de energia elétrica oferece preços menores aos grandes consumidores industriais, e a fim de recuperar perdas, aumenta a tarifa aos pequenos consumidores domésticos. Em resumo, subsídio cruzado ocorre quando uma classe de consumidores paga mais caro para subsidiar outro grupo específico.

Dito de outra forma, monopólios são vantajosos às concessionárias e não beneficiam os consumidores (BEGGS, 2002b). Logo, a estrutura presente na Figura 2 é dita como verticalmente integrada se somente existir uma única organização que faz toda sua operação e administração, conseqüentemente, impossibilita-se a existência de um mercado de energia competitivo.

Desde o início da década de 90, os participantes do setor energético continuamente reestruturaram seus processos para tornarem os mercados não regulados. Por consequência, o sistema de taxa fixa foi considerado uma limitação para a evolução da operação da rede elétrica (YANG *et al.*, 2017).

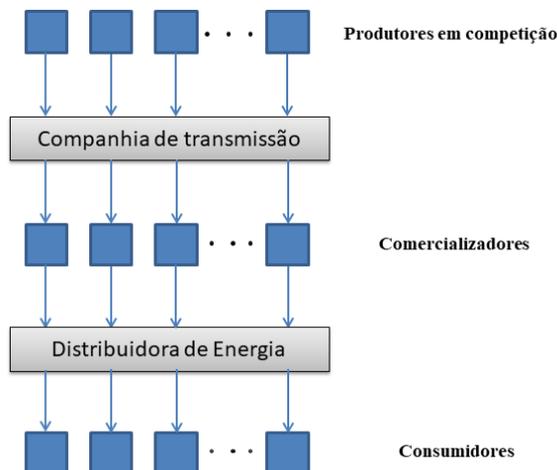
A adoção de novas estruturas de preço acarreta em modificações no mercado. Conforme Beggs (2002b), um mercado de energia competitivo apresenta as seguintes características:

- Permitir que vários produtores possam competir entre si para vender a eletricidade diretamente aos clientes;
- Permitir que os consumidores negociem contratos com vários agentes comercializadores;
- Ser transparente para permitir que produtores, consumidores e demais agentes percebam que o mercado é justo e igualitário.
- Criação de um mercado *spot* o qual represente adequadamente tanto a demanda quanto o custo da produção de energia. Tal mercado indica o preço real do custo de produção.

Um mercado competitivo é impossível de existir em uma estrutura de fornecimento integralmente integrada. Para tanto, é necessária uma estrutura horizontalmente integrada, conforme representado pela Figura 3 (BEGGS, 2002b).

Ademais, a reestruturação do sistema energético para mercado não regulado é fundamental para o desenvolvimento de *smart grids* (HASSAN *et al.*, 2014). Outra consequência da reestruturação é a formação de mercados *spot*, nos quais a quantidade de energia elétrica gerada e consumida, assim como os preços estabelecidos são negociados em tempo real. Nesse contexto, o preço pode ser denominado como RTP (*Real-Time Pricing*), em que consumidores respondem a sinais de preço em tempo real (GELLINGS; BARRON, 1996).

**Figura 3** - Estrutura horizontalmente integrada de um mercado de energia.



**Fonte:** Adaptado de BEGGS (2002).

Em mercados *spot*, os produtores de eletricidade competem entre si, de forma que suas tomadas de decisão podem gerar ganhos ou perdas financeiras. Portanto, ferramentas que auxiliem nas suas operações são de significativa importância. Tais ferramentas podem ser baseadas em técnicas de aprendizado de máquina, tais como as RNAs.

### 3.1 MERCADO DE ENERGIA DA AUSTRÁLIA

O Mercado Nacional de Eletricidade da Austrália (NEM, do inglês *The National Electricity Market*) é composto por cinco estados que estão interligados e são regiões de preços denominadas por: *New South Wales* (NSW), *Queensland* (QLD), *South Australia* (SA), *Victoria* (VIC) e *Tasmânia* (TAS). Estas regiões podem ser visualizadas na Figura 4. Há mais de 300 participantes registrados no NEM, incluindo produtores de energia, agentes de transmissão e distribuidores de eletricidade, comercializadores e clientes residenciais e industriais (NEM, 2018).

**Figura 4** - Estados que compõem o Mercado Nacional de Eletricidade da Austrália.

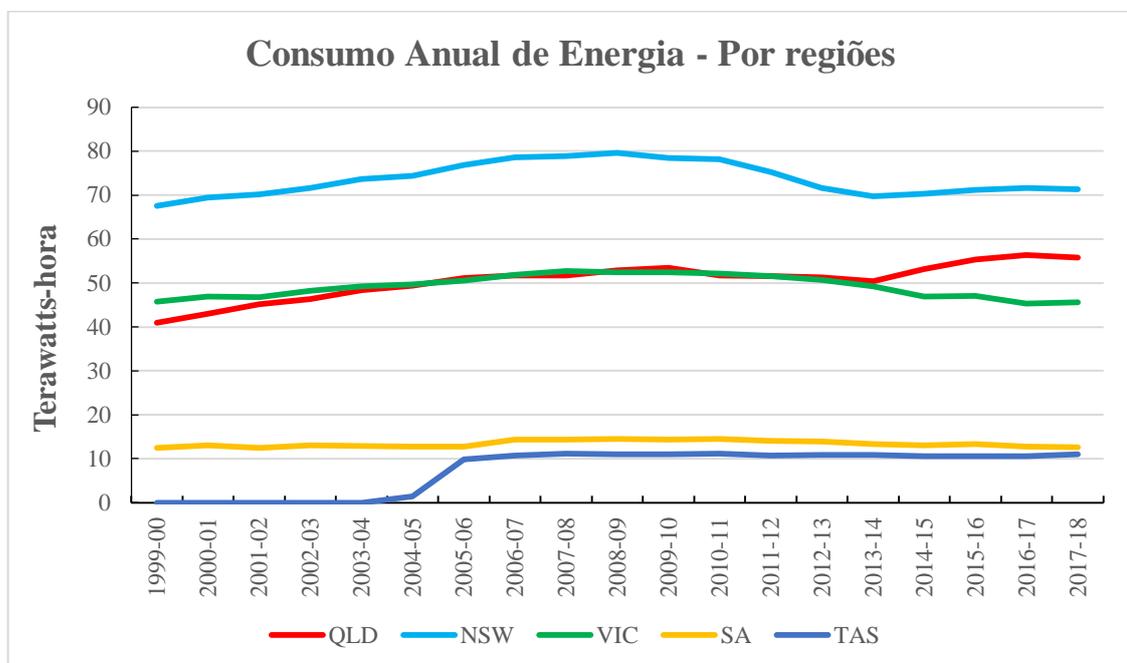


**Fonte:** Adaptado de NEM (2018).

A operação do NEM foi iniciada em dezembro 1998, entretanto, o estado da Tasmânia entrou no NEM em maio de 2004 (NEM, 2018). Desde então, fornece aproximadamente 200 TWh de eletricidade por ano. No ano financeiro 2016-2017, comercializou \$16,6 bilhões. Como pode ser observado na Figura 5, os três estados com maior consumo energético são *New South Wales* (NSW), *Queensland* (QLD) e *Victoria* (VIC), pois representam praticamente 90% do consumo anual médio dos cinco estados componentes do NEM. Ademais, ressalta-se que o estado de *New South Wales* é o maior consumidor e representa quase 40% do NEM. Esta é a região que é avaliada no presente trabalho.

Na Figura 6, é mostrada a cadeia de fornecimento de energia elétrica do NEM com destaque aos agentes que formam os mercados atacadista e varejista de eletricidade. No mercado atacadista, os produtores de energia elétrica competem entre si para vender sua eletricidade a comercializadores ou a grande consumidores, por meio de um mercado *spot* (AEMC, 2018). Neste sentido, percebe-se que a estrutura do NEM assemelha-se à horizontalmente representada na Figura 3.

**Figura 5** - Consumo anual de eletricidade das regiões do Mercado Nacional de Eletricidade da Austrália – Período de início de 1999 ao fim de 2017.



**Fonte:** Adaptado de AER, 2017.

Entretanto, é permitida integração verticalizada entre os agentes produtores (em inglês, *generators*) e agentes comercializadores (em inglês, *retailers*), formando assim os “*gentailers*”. Essa integração permite que ambos os agentes se protejam da volatilidade do mercado atacadista. Em contrapartida, tal integração reduz a liquidez dos mercados e forma uma potencial barreira na entrada e expansão de produtores e comercializadores não integrados (AER, 2017).

Já no mercado varejista, os comercializadores não revendem a energia elétrica aos consumidores finais (AEMC, 2018). Os consumidores cativos (usuários residenciais e pequenos comércios) são aqueles que consomem menos de 100 MWh ao ano de eletricidade. Apesar de formarem 98% das ligações da rede elétrica, contabilizam menos da metade do volume de vendas do NEM (AER, 2017).

A demanda e o fornecimento de eletricidade são instantaneamente balanceados por um processo controlado de despacho (NEM, 2018). O preço do despacho é determinado a cada cinco minutos e o preço *spot* é a média de seis preços de despacho, calculada a cada meia hora para cada região de preço do NEM (NEM, 2018). Esse processo também ocorre com a demanda de energia. Por meio do *website* do Operador do Mercado de Energia da Austrália (OMEA) é possível obter os valores do preço *spot* e da demanda de eletricidade.

**Figura 6** - Cadeia de fornecimento de eletricidade e agentes dos mercados atacadista e varejista do NEM.



**Fonte:** Adaptado de AEMC (2018).

No NEM, as ordens de compra de energia devem ser submetidas ao dia anterior do despacho. Porém, o volume de compra pode ser revisado até os 5 minutos anteriores ao despacho sem qualquer restrição (WERON, 2014).

O OMEA utiliza o valor do preço *spot* para estabelecer as transações financeiras de todas as negociações no mercado de energia australiano (NEM, 2018). Por exemplo, todos os

agentes produtores que tiveram suas ofertas de venda aceitas são pagos pelo preço *spot* calculado pelo OMEA, independentemente do valor de sua oferta (AER, 2017). Ademais, os valores do preço *spot* devem estar no intervalo de -\$ 1.000,00 a \$ 14.000,00 por MWh (AER, 2017).

Pelo que foi supracitado, torna-se perceptível a importância de estimar o RTP, pois é uma informação vital para os participantes de um mercado de energia para formarem sua estratégia de operação. Ademais, a estimação do preço *spot* ou RTP deve ser feita em conjunto com a demanda.

Até então, parte majoritária dos contratos do mercado varejista de energia destinado aos clientes cativos é do tipo taxa fixa. Porém, com a expansão da gama de ofertas, por exemplo, as tarifas de tempo de uso são uma alternativa que permite uso de *smart meters*, que medem a energia de um cliente em tempo real. Outras possibilidades aos clientes são negociar por meio de derivativos (em que o cliente assume o risco de volatilidade do mercado atacadista) ou por meio de contratos de preço fixo (é paga uma quantia fixa, independentemente da quantidade de energia utilizada). Algumas ofertas são adaptadas para clientes com necessidades específicas, como por exemplo, as residências com piscinas (AER, 2017).

Algumas iniciativas como a aplicação de resposta à demanda (que é o ajuste ao uso da energia em resposta ao preço, geração residencial e tecnologias de armazenamento de energia) e o emprego de TICs (*smart meters*, dispositivos interativos e plataformas de gerenciamento e comercialização de energia) permitem aos consumidores acesso à informação em tempo real. Em resumo, essas iniciativas estão tornando as redes de distribuição de energia ambientes multilaterais de negociação de produtos de energia (AER, 2017).

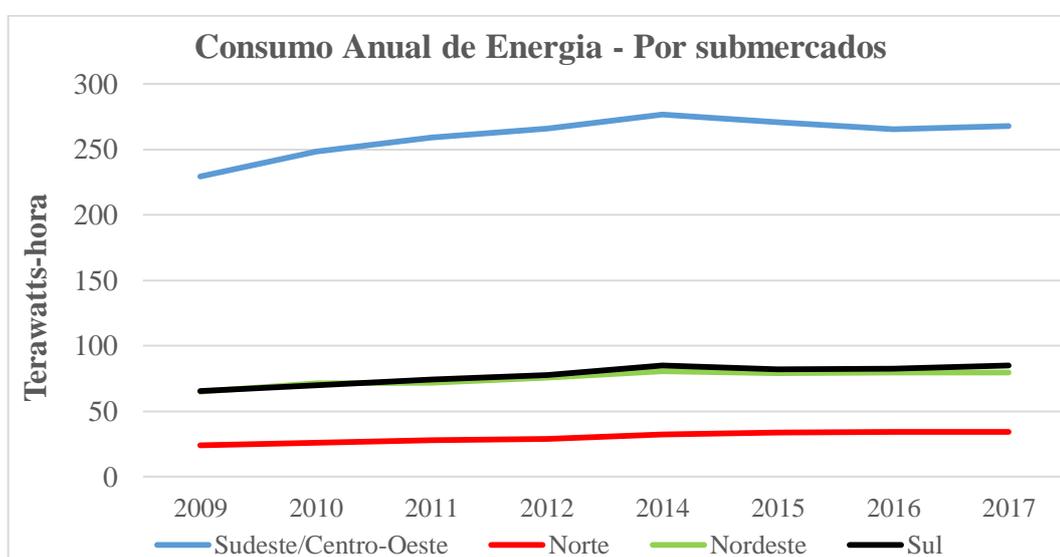
Do exposto nesta seção, apesar de ter características de estrutura verticalizada (*gentailer*) é possível concluir que o NEM apresenta uma estrutura adequada para um mercado de energia competitivo e justo, o que se espera dos mercados no contexto de cidades inteligentes. Deste modo, reforça-se a justificativa de estudar o mercado australiano em uma ambientação de *Smart Grids/Cidades Inteligentes*.

### **3.2 MERCADO DE ENERGIA DO BRASIL**

O mercado de energia brasileiro pode ser dividido em quatro submercados segundo suas regiões geográficas: sudeste/centro-oeste, sul, nordeste e norte. Na Figura 7, observa-se o

consumo anual de 2009 a 2017 destes submercados. Cabe comentar que o consumo da região centro-oeste tem a mesma grandeza da região/submercado nordeste. Adicionalmente, o consumo do submercado sudeste/centro-oeste representa, em média, 60% do total de eletricidade consumida no Brasil (EMPRESA DE PESQUISA ENERGÉTICA, 2018). Neste sentido, este submercado brasileiro assemelha-se com a região de NSW do NEM em termos de representatividade no mercado de energia nacional.

**Figura 7** - Consumo anual de eletricidade dos submercados do Mercado Nacional de Eletricidade do Brasil – Período de início de 2009 ao fim de 2017.



**Fonte:** Adaptado de EPE, 2018.

A Câmara de Comercialização de Energia Elétrica (CCEE) promove a comercialização de energia no Brasil, desde 2004, em dois ambientes: o Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL). No ACR atuam os produtores e distribuidores de energia elétrica, enquanto no ACL podem participar todos os agentes registrados na CCCE: geradores, distribuidores, comercializadores, importadores e exportadores, além dos consumidores livres e especiais (CCEE, 2018a).

Segundo Abraceel (2018), no presente momento, há três categorias de consumidores:

- Consumidor cativo – é aquele que não pode comprar energia elétrica diretamente, senão por meio da empresa distribuidora de sua localidade. Nesta categoria, estão todos os clientes de baixa tensão e a maioria dos consumidores de média tensão;

- Consumidor livre – é aquele consumidor que pode optar por comprar energia diretamente no chamado mercado livre. Esse consumidor deve ter demanda mínima de 3 MW, em qualquer nível de tensão;
- Consumidor especial – é o consumidor que também pode negociar energia no mercado livre, desde que a adquira de fontes incentivadas, como biomassa, pequenas centrais hidrelétricas (PCH) e solar. Para que o consumidor possa ser enquadrado como especial, sua demanda deve ser igual ou superior a 500 kW.

No ACR, o consumidor é denominado cativo e consiste de consumidores residenciais e industriais de baixo porte (carga inferior a 3 MW). Tais consumidores, conforme a argumentação relatada em Beggs (2002a), ficam à mercê da concessionária de distribuição da região onde estão. No ACL o consumidor livre deve ter uma carga superior a 3 MW. Pela ótica do consumidor final, o ACR pode ser compreendido como um mercado varejista e o ACL como um mercado atacadista.

Por questões de legislação, a totalidade de energia elétrica consumida deve ser 100% contratada. Deste modo, todos os consumidores devem ter contratos bilaterais de fornecimento de eletricidade para os prazos curto, médio e longo (ABRADEE, 2018). Os contratos celebrados no mercado, seja no ACR ou no ACL, são registrados na CCEE. Conseqüentemente, a CCEE afere a quantidade fornecida/consumida por cada agente. A contabilização das diferenças, positivas ou negativas, são liquidadas no Mercado de Curto Prazo (MCP) e valoradas ao Preço de Liquidação de Diferenças (PLD) (CCEE, [s.d.]).

Conforme a ABRADEE (2018), o ACR promove um ambiente de competição entre os produtores de eletricidade para venderem sua produção, enquanto o ACL é um ambiente de compra e venda de energia elétrica entre seus participantes. Ademais, em ambos os ambientes os contratos firmados são bilaterais, porém no ACR a negociação se dá por meio de leilões e no ACL é uma negociação direta entre os participantes.

Pode-se entender que o MCP é o mercado *spot* brasileiro e o PLD é o preço *spot*. No MCP, os agentes podem realizar operações de compra, no caso de *déficit* de energia contratada, e operações de venda, no caso de sobra de energia contratada. Para tanto, os agentes necessitam efetivar o custeio de garantias financeiras (CCEE, 2018b).

Logo, para tais agentes de mercado de energia elétrica, é crucial preverem a demanda e o preço da energia elétrica a fim de dispor de uma melhor tomada de decisão de suas operações de curto prazo.



## 4 TÉCNICAS DE ANÁLISE DE SÉRIES TEMPORAIS

Neste capítulo serão apresentados fundamentos de previsão de séries temporais e as técnicas de análise de séries temporais utilizadas no presente trabalho.

Uma série temporal é uma coleção de observações feitas sequencialmente no tempo (WOODWARD; GRAY; ELLIOTT, 2017). As observações podem ser coletadas em diversos intervalos de tempo, mensal e semanalmente, por exemplo. Séries temporais abrangem vários campos do conhecimento, como: economia, medicina, engenharia e ciências naturais (BOX; JENKINS; REINSEL, 2008). Nessas áreas do conhecimento, há o interesse em compreender os mecanismos subjacentes de dados afim de produzir previsões e conclusões sobre comportamentos de dados (WOODWARD; GRAY; ELLIOTT, 2017).

É definida previsão como uma expressão relativa a resultados desconhecidos em um futuro determinado. A previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma consequente tomada de decisão, a qual visa atingir determinados objetivos. Desta forma, é afirmado que a análise de séries temporais foca na obtenção de relações de dependência entre as observações adjacentes (dados históricos) da série temporal (BOX; JENKINS; REINSEL, 2008).

A previsão de demanda de energia elétrica é provavelmente o tópico mais importante para o planejamento de sistemas de potência (SEIFI; SADEGH SEPASIAN, 2011), cuja operação eficiente e confiável é somente possível por meio de uma adequada previsão de demanda de curto prazo, que desempenha uma função crucial sobre vários aspectos dos sistemas de potência, tais como: manutenção, planejamento, análises de fluxo de carga e de emergência (BALIYAN; GAURAV; MISHRA, 2015).

Deve-se entender por estimação de demanda a medida de exatidão da diferença entre os valores real e previsto da demanda futura (BALIYAN; GAURAV; MISHRA, 2015). Tal medida é realizada por modelos de previsão de séries temporais, os quais podem ser divididos em dois grupos: modelos paramétricos e não paramétricos.

Dentre os primeiros modelos estão aqueles baseados em métodos Autoregressivos e de Médias Móveis (AR, MA e ARMA), bem como o modelo Autoregressivo Integrado de Médias Móveis (ARIMA). Os modelos paramétricos são modelos de séries temporais lineares cujo uso são baseadas nas seguintes premissas: o processo analisado é estocástico; linearidade; o processo analisado é estacionário; o modelo possui coeficientes fixos (GELLINGS; BARRON,

1996). Técnicas de análises de séries temporais paramétricas não se adaptam bem à presença de mudanças abruptas. Essa desvantagem é superada por modelos de inteligência artificial, pois apresentam potencial de adaptação global (BALIYAN; GAURAV; MISHRA, 2015). Entre estes modelos, destacam-se os baseados em redes neurais artificiais, pois possuem a habilidade de resolver relações complexas, tomar decisões perante incertezas e prever padrões, tornando-os ferramentas poderosas em posse de vários pesquisadores (HAYKIN, 2008).

#### **4.1 FUNDAMENTOS DE MINERAÇÃO DE DADOS**

Os autores como Han e Kamber (2006) definem o termo mineração de dados como o processo de descoberta de padrões em bases de dados. Por outro lado, Fayyad, Piatetsky-Shapiro e Smyth (1996) definem o termo como uma das etapas do processo de descoberta de conhecimento em bases de dados. O presente estudo adota a definição de Fayyad, Piatetsky-Shapiro e Smyth (1996).

A mineração de dados pode ser percebida como um resultado natural do progresso das TICs (HAN; KAMBER, 2006). Conseqüentemente, também é natural o seu emprego em um contexto de cidades inteligentes, onde haverá uma massiva quantidade de dados. Reforça-se que as TICs visam fornecer uma informação, por exemplo a previsão de uma variável, tal que otimize os processos e os recursos da cidade inteligente

Ao se tratar de previsão, comumente, é requerida uma quantidade massiva de dados. Estes dados devem conter informações referentes aos consumidores, que podem gerar dados ou fontes externas aos consumidores. Esses dados não são de uso exclusivo para previsão realizada por agentes de mercados de energia. Legisladores, instituições e defensores públicos também podem utilizar essa informação. Ademais, os próprios clientes também podem requerer esses dados (GELLINGS; BARRON, 1996) e, para cada fim, a mineração de dados pode proporcionar um auxílio adequado.

Pelo que foi exposto à mineração de dados, é primordial para uma efetiva otimização dos diversos processos, como os de gerenciamento de tráfego, água e energia, atuantes em ambientes com inteligência (*Smart Grids* e Cidades Inteligentes). Com este viés, o presente estudo emprega um algoritmo de seleção de atributos em um dos passos da metodologia proposta com o intuito de descobrir o conjunto de variáveis de maior influência a previsão de curtíssimo prazo das séries temporais de demanda e de preço da região de NSW do NEM.

Conforme Papaioannou *et al.* (2016) e Gellings; Barron (1996), diversos fatores influenciam a demanda de eletricidade, tais como, a época do ano, dia da semana, hora do dia e condições climatológicas. Pode-se afirmar que tais variáveis também afetam o preço da eletricidade, visto que o preço possui dependência da demanda. Assim, para elaboração desta pesquisa foram obtidos dados históricos de preço, de demanda e de variáveis climatológicas.

Deve-se esclarecer que a etapa da metodologia proposta que visa a determinação das variáveis mais relevantes é realizada para assegurar uma melhor estimativa/previsão da demanda e do preço das regiões australianas. Deste modo, o processo de mineração de dados é composto por algoritmos destinados à seleção de atributos (subseção 4.1.1). Os resultados provenientes da seleção de atributos auxiliam na execução da etapa de previsão, a qual é realizada por meio de Redes Neurais Artificiais que será apresentada na (seção 4.2).

#### **4.1.1 Seleção de atributos**

Em uma base de dados é considerado atributo uma coluna que representa as diferentes características das diversas instâncias contidas nesta base. Conforme este entendimento de “atributo”, em Liu e Motoda (1998) os autores definem o procedimento de seleção de atributos como a ação de encontrar um subconjunto de atributos ótimo cuja responsabilidade é generalizar a informação presente na base de dados, em concordância com a resposta desejada, ou seja, em função de uma variável de saída.

Perante um imenso número de atributos, métodos de classificação e previsão não são capazes de generalizar de forma satisfatória determinados padrões. Para obter um melhor desempenho dessas técnicas são empregados algoritmos de seleção de atributos para tratamento dos dados de entrada.

Neste trabalho foi empregado um método baseado em correlação, *Correlation-Based Feature Selection* (CFS), proposto por Hall (1999), que permite remover características redundantes e irrelevantes. Conforme mostrado por Hall (2000), este método pode ser aplicado tanto em conjuntos de dados contínuos quanto discretos. O CFS emprega correlação para avaliar o custo de atributos individuais e subconjuntos de atributos.

CFS é um algoritmo no qual *thresholds* não precisam ser especificados, assim como, a quantidade de atributos. Além disso, não apresenta o alto custo computacional comumente associado a algoritmos de aprendizado de máquina (HALL, 1999). O objetivo do CFS é determinar um subconjunto de atributos que contenha características altamente correlatas com

a saída, que no caso deste trabalho será a demanda e o preço da eletricidade. Ademais, busca-se que os atributos do subconjunto não sejam correlatos entre si, de forma a eliminar atributos redundantes.

Basicamente, o mecanismo de funcionamento do CFS é formar subconjuntos iterativamente. O critério de parada se dá quando as últimas cinco iterações retornam o mesmo subconjunto de atributos. Deste modo, é determinado o melhor subconjunto de atributos. Esta pesquisa utilizou o programa computacional *Weka* versão 3.8 para a execução do CFS.

## **4.2 REDES NEURAIS ARTIFICIAIS**

Nesta seção, a estrutura geral das RNAs é apresentada. Segundo Haykin (2008), a RNA é uma técnica de Inteligência Artificial que objetiva simular por meio de modelos matemático-computacionais o funcionamento do cérebro humano de uma maneira simplificada.

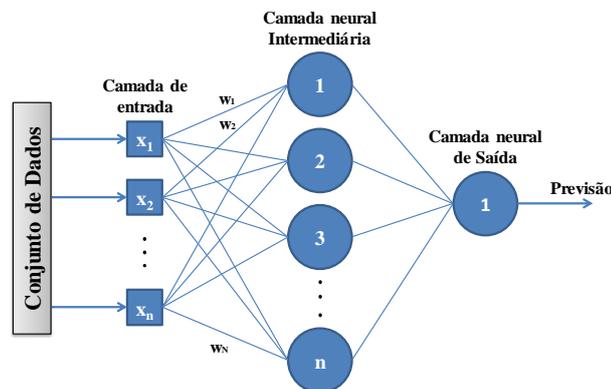
São diversas as possibilidades de aplicação de RNAs, por exemplo, avaliação de imagens médicas ou captadas por satélites, classificação de padrões de escrita e de fala, reconhecimento facial, controle de frota e previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2010). Essa significativa potencialidade das RNAs se deve às suas seguintes propriedades e capacidades: adaptabilidade, aprendizado, generalização, tolerância a falhas organização e armazenamento de dados e (HAYKIN, 2008). Tais características são descritas a seguir:

1. Adaptabilidade – ajustes de parâmetros das RNAs conforme a apresentação sucessiva de exemplos (padrões, amostras, medidas), permitindo o ganho de conhecimento por experiência;
2. Aprendizado – por um processo de treinamento, a RNA determina (aprende) relações entre as distintas variáveis dos exemplos que lhe são apresentados;
3. Generalização – capacidade de estipular soluções desconhecidas, após a fase de treinamento;
4. Organização e armazenamento de dados – agrupamento interno de padrões das informações referentes do conjunto de exemplos apresentado no processo de aprendizado. A formação desse arranjo de dados é distribuída, o que permite um incremento da robustez da RNA;

5. Tolerância a falhas – mesmo que uma parte da estrutura interna neural esteja corrompida, a RNA funcionará devido ao nível de interconexão entre os dados presentes na própria RNA.

Redes neurais, sejam biológicas ou artificiais, são compostas por estruturas denominadas neurônios. Entretanto, os neurônios biológicos são interconectados de maneira extremamente complexa e não linear para formar uma rede de processamento paralelo. Por outro lado, as RNAs apresentam camadas que são compostas por neurônios e interconectadas de modo sequencial, conforme a arquitetura de RNA com uma camada de entrada de dados e duas camadas neurais (intermediária e de saída) mostrada na Figura 8.

**Figura 8** - Arquitetura com  $n$  entradas.



**Fonte:** Autor.

As RNAs são modelos simplificados da arquitetura cerebral, haja vista que estas possuem algumas centenas de neurônios, enquanto o cérebro apresenta em torno de 100 bilhões de neurônios. Outra diferença está no fato de o cérebro utilizar os 5 sentidos como entrada e as RNAs necessitarem, obrigatoriamente, de dados numéricos.

Apesar de significativas distinções em termos de quantidade de neurônios e interconexão, pode-se dizer que as RNAs são semelhantes ao cérebro em duas características:

- conhecimento é adquirido por um processo de aprendizado;
- conexões entre seus neurônios são utilizadas para armazenar o conhecimento adquirido.

Para que fique mais claro o funcionamento de uma RNA, nas subseções que seguem, é apresentada a modelagem de um neurônio artificial e as funções de ativação empregadas no âmbito dessa dissertação.

#### 4.2.1 Neurônio Artificial - *Perceptron*

RNAs são sistemas paralelos distribuídos constituídos de simples unidades de processamento (neurônios) que calculam específicas funções matemáticas (BRAGA; CARVALHO; LUDERMIR, 2007). O funcionamento das RNAs baseia-se no cérebro humano, isto é, armazenam o conhecimento adquirido e possibilitam o uso de tal informação (HAYKIN, 2008).

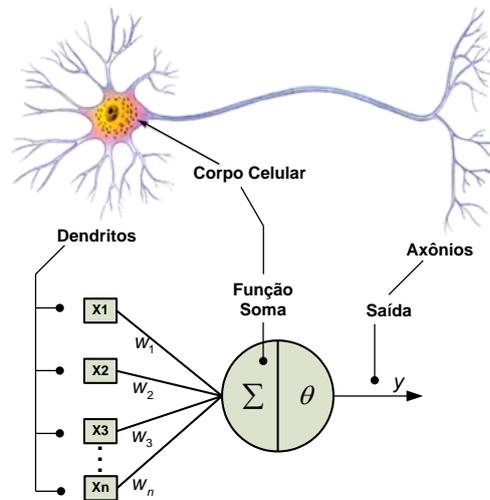
Por meio da Figura 9, uma comparação entre o neurônio biológico e o neurônio artificial pode ser visualizada. Nota-se por meio desta figura que o neurônio artificial pode ser dividido nos seguintes elementos básicos: entradas, combinador linear (soma) e função de ativação  $g(\cdot)$ . Estes elementos são explanados em maiores detalhes:

1. Sinais de entrada  $\{x_1, x_2, x_3, \dots, x_n\}$  – cada um ponderado pelo seu peso sináptico  $\{w_1, w_2, w_3, \dots, w_n\}$ , os quais são provenientes do meio externo e representam os valores assumidos pelas variáveis de uma aplicação específica. O conjunto de entradas é usualmente normalizado visando incrementar a eficiência computacional da RNA (SILVA; SPATTI; FLAUZINO, 2010);
2. Combinador linear (representado pelo somatório da Figura 3.1) – realiza a soma da multiplicação dos sinais de entrada pelos seus respectivos pesos sinápticos a fim de gerar um valor de potencial de ativação (SILVA; SPATTI; FLAUZINO, 2010);
3. Função de ativação  $g(\cdot)$  – objetiva gerar uma saída que esteja dentro de um intervalo de valores válidos. As funções de ativação serão apresentadas na subseção 4.2.2.

Por meio dos três elementos básicos supracitados, a saída de um neurônio artificial pode ser expressa conforme a Equação 4.1.

$$y = g\left(\sum_{i=1}^n w_i x_i - \theta\right). \quad (4.1)$$

**Figura 9** - Comparação entre neurônios biológico e artificial.



**Fonte:** FERNANDES (2009).

Diga-se de passagem, que há na literatura correlata dois modelos matemáticos para neurônio, a saber: *Adaline* e *Perceptron*. O primeiro somente apresenta funções de ativação parcialmente diferenciáveis, característica favorável ao emprego de classificação de padrões e deficiente para a previsão de séries temporais (HAYKIN, 2008). Por este motivo, para esta dissertação considerou-se o uso de *Perceptron*.

#### 4.2.2 Funções de Ativação

Conforme previamente citado, a função de ativação fornece um valor de saída limitado. Segundo Silva, Spatti e Flauzino (2010) as funções de ativação são divididas em dois grupos: parcialmente diferenciáveis e as totalmente diferenciáveis.

Dentre as funções de ativação parcialmente diferenciáveis, destacam-se: degrau, degrau bipolar e rampa simétrica. Já as funções de ativação totalmente diferenciáveis que se destacam em redes neurais artificiais são: logística, tangente hiperbólica, gaussiana e linear.

Nesta dissertação, foram utilizadas funções de ativação sigmoide e linear, respectivamente nos neurônios das camadas intermediárias e de saída. Essas funções podem ser representadas pelas Equações 4.2 e 4.3:

$$g_1(u) = \frac{2}{1 - e^{-2u}} - 1, \quad (4.2)$$

$$g_2(u) = u. \quad (4.3)$$

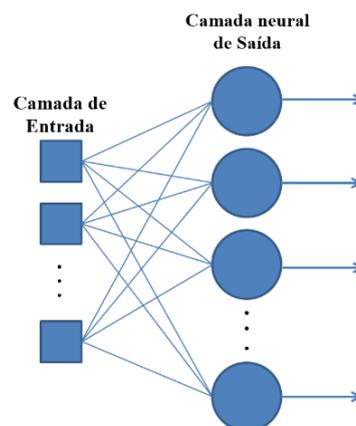
### 4.2.3 Arquiteturas

A arquitetura de uma RNA é o que define o arranjo dos neurônios (SILVA; SPATTI; FLAUZINO, 2010) e, conseqüentemente, o processo de aprendizado (HAYKIN, 2008). Pode-se identificar fundamentalmente três tipos de arquiteturas: redes *feedforward* de única camada única, redes *feedforward* de múltiplas camadas e redes recorrentes (ou realimentada).

Na Figura 10 é ilustrada a arquitetura *feedforward* com única camada neural. Em termos de camadas, é a arquitetura neural mais simples. Somente na camada de saída que há processamento computacional (HAYKIN, 2008).

De uma maneira simples, uma arquitetura de múltiplas camadas é uma *feedforward* de única camada neural com outras camadas neurais denominadas intermediárias ou ocultas. Sua ilustração pode ser visualizada na Figura 8. Apesar desta figura mostrar que a quantidade de neurônios da 1ª camada intermediária é igual ao número  $n$  de sinais de entrada, isto não é mandatório. Os números de camadas ocultas e seus respectivos neurônios depende da complexidade do problema tratado e da qualidade dos dados disponíveis sobre o problema. Contudo, a quantidade de neurônios na arquitetura *feedforward* de única camada sempre será o número de sinais de entrada (SILVA; SPATTI; FLAUZINO, 2010).

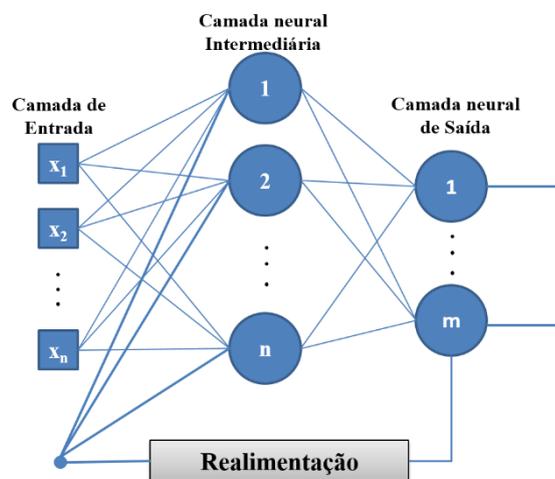
**Figura 10** - Arquitetura *feedforward* de camada única neural.



**Fonte:** Adaptado de (HAYKIN, 2008).

Uma rede de arquitetura recorrente apresenta um laço de realimentação que conecta as respostas da camada neural de saída com os sinais de entrada. A presença de laço de realimentação possui um significativo impacto no aprendizado e no desempenho da RNA (HAYKIN, 2008), podendo ser usadas em sistemas dinâmicos, como previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2010). Na Figura 11 é ilustrada a arquitetura recorrente (ou realimentação, termo que provém do termo em inglês *feedback*).

**Figura 11** - Arquitetura neural recorrente.



**Fonte:** Adaptado de Silva; Spatti; Flauzino (2010).

Outros parâmetros como número de camadas, quantidade de neurônios por camada, tipo de conexão entre os neurônios e a topologia da rede são consideradas para especificar a arquitetura de uma RNA (FERNANDES, 2009).

Segundo Haykin (2008), redes de arquitetura MLP possuem três principais características:

- As funções de ativação dos neurônios são não lineares e totalmente diferenciáveis;
- Contém pelo menos uma camada intermediária;
- Alto grau de conectividade dado pelos pesos sinápticos dos neurônios.

Dentre os algoritmos de treinamento da MLP, o mais conhecido é o *backpropagation*, cuja principal característica é o uso do gradiente descendente para minimizar o erro do treinamento. Conforme Haykin (2008), esse processo de treinamento consiste de duas etapas:

1. Etapa *forward* – os pesos sinápticos são determinados e os sinais de entrada são transmitidos para frente, camada a camada, até a sinal de saída. Ademais, as mudanças são restritas aos potenciais de ativação e saídas de cada neurônio da rede;
2. Etapa *backward* – é produzido um sinal de erro pela comparação da saída da rede com a saída desejada. O sinal do erro é transmitido para trás, camada a camada, isto é, no sentido contrário ao da etapa 1. Deste modo, os pesos sinápticos são sucessivamente ajustados.

Porém, conforme Hagan; Menhaj (1994), no algoritmo de treinamento de Levenberg-Marquardt, um processo de interação do ajuste dos pesos sinápticos é otimizado e permite uma rápida convergência em relação ao *backpropagation*. Deste modo, esse foi o algoritmo adotado nessa dissertação para o treinamento das RNAs do tipo MLP.

Cabe comentar que a quantidade de neurônios que há nas RNAs influencia nos resultados gerados. Redes neurais com poucos neurônios apresentam uma baixa capacidade de aprendizado, ao passo que o uso de muitos neurônios apresenta baixa capacidade de generalização (QUAN; SRINIVASAN; KHOSRAVI, 2014).

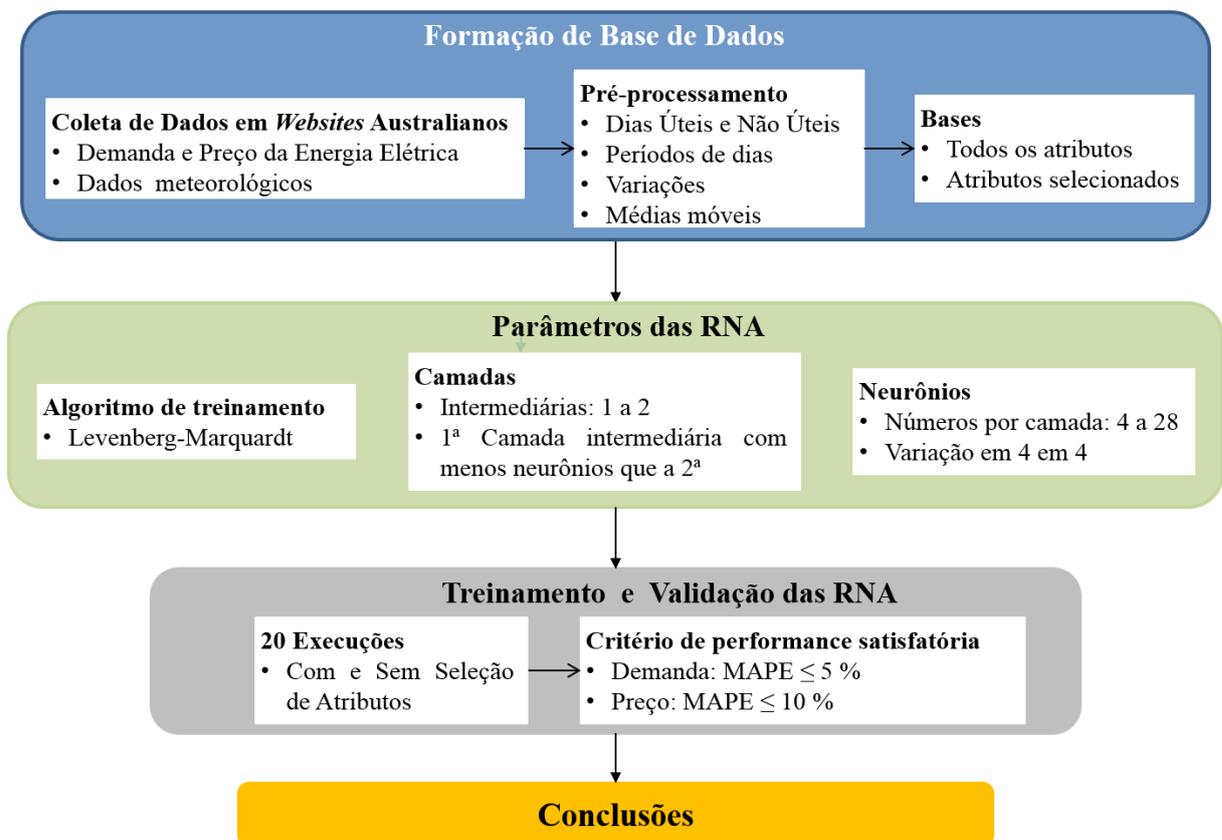
Acrescenta-se que as RNAs podem apresentar problemas denominados de *underfitting* e *overfitting*. Ambos os problemas estão relacionados ao treinamento. *Underfitting* é caracterizado quando as RNAs que não foram treinadas o suficiente com o conjunto de amostras (HAYKIN, 2008). Dito de outra forma, não convergência no processo de treinamento (BRAGA; CARVALHO; LUDERMIR, 2007). Enquanto o *overfitting* representa RNAs que foram treinadas em excesso com o conjunto de amostras (HAYKIN, 2008). Em consequência, há uma piora na taxa de acertos para padrões distintos dos usados para ajustar os pesos sinápticos e se entende que a RNA decorou os padrões de treinamento, inclusive peculiaridades e ruídos das amostras (BRAGA; CARVALHO; LUDERMIR, 2007).

Por fim, é importante mencionar que esta dissertação fez uso de RNAs com arquitetura MLP e topologia *feedforward*, com neurônios parcialmente conectados. Esta pesquisa utilizou a *toolbox Neural Networks* pertencente ao programa computacional *MatLab* versão 2014b para a implementação das RNA.

## 5 METODOLOGIA

A metodologia para o desenvolvimento deste projeto consiste em 4 etapas, esquematizadas de maneira sintetizada na Figura 12, pela qual é possível observar os passos que se iniciam na coleta de dados e finaliza com os resultados da previsão da demanda e do preço da energia elétrica por meio das RNAs. As etapas são devidamente descritas na sequência.

**Figura 12** - Esquema das etapas da metodologia utilizada.



Fonte: Autor.

### 5.1 FORMAÇÃO DA BASE DE DADOS

Nesta seção são trazidos detalhes sobre a coleta de dados e como ocorre a formação da base de dados.

Os dados que representam os valores históricos da demanda e do preço da energia elétrica da região australiana NSW foram obtidos no *website* do OMEA. Todos os dados são

fornecidos por meio de planilhas eletrônicas no formato .csv. Conforme previamente comentado, o OMEA disponibiliza tais informações com discretização de meia hora.

Já os dados climatológicos, tais como índice pluviométrico e temperatura, foram obtidos por meio do *website* do Departamento de Meteorologia do governo australiano. Dentre as variáveis que se pode obter estão: temperatura (mínima e máxima), índice pluviométrico e exposição solar diária. Deve-se entender de exposição solar diária como a energia solar total incidente numa superfície horizontal. É medida de meia noite de um dia à meia noite do próximo dia. As temperaturas máxima e mínima, respectivamente, são o maior e menor valor de temperatura registrados em um dia. O índice pluviométrico é a quantidade de precipitação que alcançou o solo, como chuva, chuvisco, granizo e neve.

Todas as variáveis climáticas são fornecidas por estações meteorológicas. A Tabela 1 informa as estações das quais foram coletados os dados.

**Tabela 1** - Estações meteorológicas usadas para a formação da base de dados.

Região	Cidade	Código da Estação
New South Wales (NSW)	Newcastle	61055
		61390
	Sydney	66037
		66062

**Fonte:** Autor.

Com a união dos dados coletados, formou-se um conjunto de dados, o qual foi dividido em 2 grupos, a saber: um grupo formado somente por dias úteis e outro por finais de semana e feriados. Por fim, a partir de cada uma destas bases foram formados mais 4 subgrupos: Madrugada, Manhã, Tarde e Noite. Deve-se entender Madrugada como o período de 00:00 à 05:30, Manhã o período de 06:00 à 11:30, Tarde é o período de 12:00 à 17:30 e Noite o período de 18:00 à 23:30. É essencial ressaltar que as bases iniciais de dados foram formadas por uma janela de tempo que iniciada em 01/01/2012 e encerrada em 31/08/2018, deste modo são utilizados 2.434 dias.

Um detalhe a ser informado é que as regiões que consta na Tabela 1 também são estados geográficos. A população do estado NSW é de aproximadamente de 7,5 milhões de pessoas das quais 63% residem na cidade de Sydney, a cidade australiana mais populosa. Apesar da capital

federal Canberra localiza-se em NSW, a cidade de Newcastle é a segunda maior em população de NSW. Logo, Newcastle e Sydney foram escolhidas para coletar os dados meteorológicos, provenientes de duas estações meteorológicas de cada cidade. Nos destaques da Figura 13 é possível ter uma percepção da localização geográfica das estações.

**Figura 13** - Destaque das estações meteorológicas de NSW



**Fonte:** Adaptado de <http://www.bom.gov.au/nsw/observations/sydneymap.shtml>.

## 5.2 PRÉ-PROCESSAMENTO DE DADOS

Deve ser entendido que as RNAs fornecerão para um instante futuro de tempo  $t+1$ , uma saída de  $y(t+1)$ , em que  $y$  representa o preço ( $Pr$ ) ou a demanda ( $Dem$ ). A RNA recebe um conjunto de entradas  $\{x_1, x_2, \dots, x_n\}$ , composto pelas variáveis mais relevantes.

No conjunto de entradas  $\{x_1, x_2, \dots, x_n\}$  está contido um subconjunto de entradas passadas  $\{y(t), y(t-1), \dots, y(t-T)\}$ , em que  $T$  é um número natural. Dito de outra forma, um conjunto de entradas atrasadas no tempo da variável  $y$ , cujo valor se deseja estimar no instante  $t+1$ . Na Tabela 2 são apresentados os tempos de atraso  $T$  adotados para a formação da base de dados nesta pesquisa.

**Tabela 2** - Significado do tempo de atraso para as variáveis.

Tempo de atraso	Preço ou Demanda
T=1	atraso de 30 min
T=T <sub>D</sub> = 48	atraso de 1 dia
T=48*7= T <sub>S</sub> = 366	atraso de 1 semana
T=48*364= T <sub>A</sub> = 17472	atraso de 1 ano

**Fonte:** Autor.

Para cada base (dias úteis e finais de semana e feriados) e seus subgrupos (Madrugada, Manhã, Tarde e Noite) descrita anteriormente, foram calculadas as variações de meia hora, diária, semanal e anual. Os cálculos das variações foram realizados somente com os dados de preço e demanda de energia elétrica. Segue a descrição do cálculo das variações:

- Variação de meia hora ( $V_{RH^{1/2}}$ ) – é a diferença entre os valores dos dados do instante  $t$  e do instante  $t - 1$  de determinado dia  $D$ ;
- Variação diária ( $V_{RD}$ ) – é a diferença entre os valores do instante  $t$  e do instante  $t - T_D$ , ou seja, a diferença entre valores de dados de determinado dia  $D$  e do dia anterior  $D-1$ ;
- Variação semanal ( $V_{RS}$ ) – é a diferença entre os valores do instante  $t$  e do instante  $t - T_S$ . Dito de outra forma, é diferença entre os valores de determinado dia  $D$  e do dia 7 dias atrás  $D-7$  (desta maneira a diferença entre os mesmos dias da semana, isto é, segunda dia  $D$  com segunda dia  $D-7$ , por exemplo).
- Variação anual ( $V_{RA}$ ) – é a diferença entre os valores do instante  $t$  e do instante  $t - T_A$ . Para as variáveis climatológicas,  $V_{RA}$  é a diferença entre os valores de determinado dia  $D$  e do dia 364 atrás  $D-364$ .

Após o cálculo das variações, foram também calculadas as médias móveis de 5 dias. O propósito desse cálculo é filtrar possíveis flutuações e evidenciar tendência das variáveis que podem influenciar a previsão da demanda e do preço da energia elétrica. A média móvel ( $M_M(n)$ ) é expressa pela Equação 5.1:

$$M_M(n) = \frac{\sum_{n=1}^M nV_n}{\sum_{n=1}^M n}, \quad (5.1)$$

onde  $V_n$  é valor da variável (preço, demanda, temperatura, índice pluviométrico, incidência solar e variações);  $M$  indica a quantidade de valores  $V_n$  usados no cálculo, no caso dessa dissertação  $M=5$ ; e  $n$  é o índice da variável  $V_n$  e varia entre os valores 1 a  $M$ , o qual também pode ser interpretado como peso da variável  $V_n$ .

Percebe-se, a partir da Equação 5.1, que quando  $n=M$ , tem-se a situação de maior peso no cálculo de  $M_M$ . Justamente por este fato, para que haja indicação de tendência à RNA, o valor mais recente deve ter índice  $n=M$  e o valor menos recente deve ter índice  $n=1$ . Dito de outra forma,  $V_M$  é o valor mais significativo e  $V_1$  é menos significativo na formação de tendência de uma série temporal através do emprego de cálculo de média móvel.

Após a inserção dos valores de variações e de médias móveis nas bases de dias úteis e de finais de semana e feriados e subgrupos (Madrugada, Manhã, Tarde e Noite) é obtida a configuração final das bases para a previsão. A configuração final de atributos de entrada e saída é apresentada na Tabela 3.

A Tabela 3 indica a configuração de um conjunto de entradas com a saída desejada (preço ou demanda), para um instante de tempo  $t$  pertencente a um determinado dia  $D$ . Ao considerar os subgrupos (Madrugada, Manhã, Tarde e Noite), um determinado dia  $D$  possui seis horas. Conseqüentemente, tem-se seis valores distintos para preço, demanda, variações e médias móveis de preço e demanda. Ressalta-se que  $Pr$ ,  $Dem$ ,  $M_M$ , são respectivamente, preço, demanda e média móvel.

**Tabela 3** - Atributos com as saídas desejadas para as regiões de NSW.

	<b>Atributos</b>	<b>Detalhamento</b>
<b>Entradas de instante de tempo <math>t</math></b>	$Pr(t); Dem(t)$ $Pr(t-T); Dem(t-T)$	<i>Tempo de atraso (T)</i> $T \in \{T_{H/2}, T_D, T_S, T_A\}$
	$V_{RH/2}; V_{RD}; V_{RS}; V_{RA}$ para $Pr$ e $Dem$	Variações de meia hora, diária, semanal, anual
	Dados Meteorológicos	Índice pluviométrico, Temperaturas máxima e mínima, Exposição Solar Global Diária – Valores do dia D em que $t$ pertence
<b>Entradas de Média Móvel – <math>M_M</math></b>	$Pr(t); Dem(t)$ $Pr(t-T); Dem(t-T)$ $V_{RH/2}; V_{RD}; V_{RS}; V_{RA}$ para $Pr$ e $Dem$	de $t$ a $t-4*T_D$
	Dados Meteorológicos	de $D$ a $D-4$
<b>Saída desejada para o instante de tempo <math>t+1</math></b>	Preço ( $Pr(t+1)$ ) Demanda ( $Dem(t+1)$ )	Uma topologia de rede para cada saída

**Fonte:** Autor.

Por outro lado, pelo *website* do departamento australiano de clima é fornecido somente um único valor diário para cada atributo de clima (índice pluviométrico, temperaturas máximas e mínimas e incidência solar). Deste modo, os valores dos atributos climáticos e suas médias móveis são exatamente os mesmos para os seis horários de um dia.

É importante salientar que a partir desses dados, formaram-se bases distintas com a aplicação da seleção de dados. Também, cabe ainda destacar que a quantidade de atributos foi reduzida drasticamente, visto que a base de dados possui um total de 66 atributos e as taxas de redução estão em torno de 80% a 94%.

### 5.3 PARAMETRIZAÇÃO DAS REDES NEURAIS ARTIFICIAIS

Nesta etapa são definidas as topologias de RNA implementadas na previsão de demanda e preço. Assim, tais RNAs serão parametrizadas da seguinte forma:

- Arquitetura = *Perceptron* Multicamadas (MLP);
- Algoritmo de treinamento = Levenberg-Marquardt;
- Erro quadrático médio =  $10^{-12}$ ;
- Número máximo de épocas = 250;
- Número de camadas = topologias com 1 e 2 camadas neurais intermediárias;
- Neurônios das camadas intermediárias = funções de ativação do tipo sigmóide;
- Neurônios da camada de saída = funções de ativação do tipo linear;
- Número de neurônios por camada intermediária = de acordo com a Tabela 5.

**Tabela 4** - Quantidade de neurônios nas camadas intermediárias.

Número de neurônios	1ª camada neural intermediária	2ª camada neural intermediária
[N <sub>1</sub> , -]	N <sub>1</sub> de 4 a 28	-
[N <sub>1</sub> , N <sub>2</sub> ]	N <sub>1</sub> igual a 4	N <sub>2</sub> de 8 a 28
[N <sub>1</sub> , N <sub>2</sub> ]	N <sub>1</sub> igual a 8	N <sub>2</sub> de 12 a 28
[N <sub>1</sub> , N <sub>2</sub> ]	N <sub>1</sub> igual a 16	N <sub>2</sub> de 20 a 28
[N <sub>1</sub> , N <sub>2</sub> ]	N <sub>1</sub> igual a 20	N <sub>2</sub> de 24 a 28

Na Tabela 4 são apresentadas as quantidades de neurônios por camada intermediária das RNAs empregadas nesta pesquisa. O valor  $N_1$  é o número de neurônios na primeira camada neural intermediária e o valor  $N_2$  representa o número de neurônios da segunda camada neural intermediária. Deste modo,  $[N_1, -]$  denota as topologias com somente uma camada neural intermediária, enquanto  $[N_1, N_2]$  são as topologias com duas camadas neurais intermediárias. Essa notação será adotada para expressar a configuração da RNA. Por exemplo,  $[12, 16]$  é uma RNA com 12 neurônios na 1ª camada neural intermediária e 16 neurônios na 2ª camada neural intermediária.

Ao observar a Tabela 4, o arranjo dos neurônios é tal que a segunda camada neural intermediária tenha mais neurônios que a primeira, quando se tem a topologia  $[N_1, N_2]$ . Assim, foi testado um total de 27 topologias. É ressaltado que as RNAs são de arquitetura MLP e treinadas com o algoritmo de Levenberg-Marquardt. Ressalta-se que cada topologia de RNA deve fornecer uma saída (demanda ou preço) e, portanto, a camada neural de saída será composta por apenas um neurônio e com função de ativação linear.

## 5.4 TREINAMENTO/VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAS

Cada topologia de RNA considerada nessa dissertação foi treinada e validada quinze vezes. Para tanto, utilizam-se as 24 bases de dados supracitadas. Reforça-se que são oito bases de dados na configuração “com seleção de atributos” para demanda, oito bases de dados na configuração “com seleção de atributos” para preço e outras oito na configuração “sem seleção de atributos”. Os resultados das estimações são apresentados nas Seções 6.2 e 6.3.

A execução do treinamento é realizada com 95% dos dados de cada base, enquanto o processo de validação é executado com os 5% restantes. Isto é, são utilizados 128 dias para validação dos 2.434, ou seja, cada para subgrupo (Madrugada, Manhã, Tarde e Noite) são estimados 1.460 valores de demanda e de preço de energia elétrica.

As Equações 5.1 a 5.3 são os índices de desempenho com os quais as RNAs serão avaliadas. Portanto, as análises serão realizadas em função do Erro Absoluto Médio (MAE, do inglês *Mean Absolute Error*), do Erro Absoluto Percentual Médio (MAPE, do inglês *Mean Absolute Percentual Error*) e do Erro Médio Quadrático (RMSE, do inglês *Root Mean Square Error*):

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_i - \bar{V}_i|, \quad (5.1)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|V_i - \bar{V}_i|}{V_i}, \quad (5.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_i - \bar{V}_i)^2}, \quad (5.3)$$

onde,  $V_i$  representa o valor desejado para demanda ou preço;  $\bar{V}_i$  representa o valor estimado pela RNA para demanda ou preço; e  $n$  é o número de amostras usadas para validação da RNA.

## 6 RESULTADOS

Neste capítulo são discutidos os resultados obtidos para a região australiana de NSW tanto no contexto da demanda de energia como também do preço, considerando dados de dias úteis e de finais de semana e feriados para os quatro subgrupos horários previamente definidos.

Por uma questão de simplicidade, a notação adotada para topologias candidatas é  $[N_1, N_2]$ , sendo  $N_1$  o número de neurônios da primeira camada neural intermediária e  $N_2$  o número de neurônios da segunda camada neural intermediária.

### 6.1 SELEÇÃO DE ATRIBUTOS

Reforça-se que o algoritmo CFS fornece um subconjunto de atributos altamente correlatos com a atributo de saída (preço ou demanda). Nas Tabelas 5 e 6 são apresentados estes subconjuntos, cujos atributos são os mais relevantes para a previsão tanto da demanda (Tabela 6) quanto do preço (Tabela 5) da região australiana NSW.

Cabe comentar que, por uma questão de simplicidade, as variáveis climáticas – exposição solar diária, temperaturas máxima e mínima e índice pluviométrico – são representadas, respectivamente, por  $S_{ol}$ ,  $T_{max}$ ,  $T_{min}$  e  $I_{plu}$ . Quando uma variável climática é

indicada, sempre será acompanhada pela numeração da estação correspondente. As identificações das estações meteorológicas podem ser observadas na Tabela 1.

**Tabela 5** - Atributos selecionados da mineração de dados para previsão do Preço.

Período	Madrugada	Manhã	Tarde	Noite
<b>Dias</b>	$Pr(t)$ $Pr(t-T_D)$	$Pr(t)$ $Pr(t-T_D)$	$Pr(t)$ $Pr(t-T_D)$	$Pr(t)$
<b>Úteis</b>	$V_{RA} Dem$ $M_M Pr(t)$ $M_M Pr(t-T_D)$ $M_M I_{plu} - \#61055$	$Pr(t-T_S)$ $V_{RH/2} Dem$ $M_M S_{ol} - \#66037$	$Sol - \#61390$ $M_M V_{RH/2} Pr$	$T_{min} - \#61055$ $M_M Pr(t-T_D)$
<b>Finais de Semana e Feriados</b>	$Pr(t)$ $Pr(t-T_D)$ $Pr(t-T_S)$ $M_M Pr(t)$	$Pr(t)$ $Pr(t-T_D)$ $V_{RA} Dem$ $M_M Pr(t)$	$Pr(t)$ $Dem(t-T_D)$ $Pr(t-T_D)$ $Pr(t-T_S)$ $Pr(t-T_A)$ $V_{RH/2} Dem$ $M_M Pr(t-T_D)$	$Pr(t)$ $Pr(t-T_S)$ $M_M Pr(t-T_D)$ $M_M T_{min} - \#61055$

**Tabela 6** - Atributos selecionados da mineração de dados para previsão da Demanda.

Período	Madrugada	Manhã	Tarde	Noite
<b>Dias</b>	$Dem(t)$ $Pr(t)$ $Dem(t-T_D)$ $Dem(t-T_S)$ $Dem(t-T_A)$ $Pr(t-T_A)$ $V_{RS} Pr$ $I_{plu} - \#61055$ $I_{plu} - \#61390$ $M_M Dem(t-T_D)$	$Dem(t)$ $Pr(t-T_D)$ $V_{RS} Dem$ $M_M Dem(t-T_S)$ $M_M I_{plu} - \#66037$ $M_M S_{ol} - \#66037$ $M_M I_{plu} - \#66062$ $M_M S_{ol} - \#66062$ $M_M S_{ol} - \#61055$ $M_M S_{ol} - \#61390$	$Dem(t)$ $Dem(t-T_D)$ $Dem(t-T_S)$ $Dem(t-T_A)$ $V_{RH/2} Dem$ $I_{plu} - \#61390$ $M_M V_{RA} Pr$	$Dem(t)$ $Dem(t-T_D)$ $Dem(t-T_S)$ $Dem(t-T_A)$ $V_{RH/2} Dem$ $I_{plu} - \#61055$ $I_{plu} - \#61390$ $M_M Pr(t-T_S)$
<b>Finais de Semana e Feriados</b>	$Dem(t)$ $Dem(t-T_D)$ $Dem(t-T_S)$ $Dem(t-T_A)$ $V_{RS} Dem$ $M_M Pr(t-T_S)$ $M_M Pr(t-T_A)$	$Dem(t)$ $Dem(t-T_D)$ $Pr(t-T_A)$ $V_{RH/2} Pr$ $V_{RS} Dem$ $M_M S_{ol} - \#66037$ $M_M S_{ol} - \#66062$	$Dem(t)$ $Pr(t)$ $Dem(t-T_S)$ $Dem(t-T_D)$ $V_{RH/2} Dem$ $V_{RD} Dem$	$Dem(t)$ $Dem(t-T_D)$ $Dem(t-T_S)$ $Dem(t-T_A)$ $V_{RH/2} Dem$ $T_{min} - \#61055$ $M_M V_{RD} Pr$ $M_M T_{min} - \#66037$ $M_M S_{ol} - \#66062$

Em específico, para a previsão do preço, somente para o conjunto de dados contendo as tardes de finais de semana e feriados foi escolhida uma demanda atrasada –  $Dem(t-T_D)$ . Em

contrapartida, as variações da demanda horária ou anual são atributos significativos em alguns conjuntos de dados. Acredita-se que devido a alguns contratos serem firmados em um horizonte temporal de anos, a  $V_{RA}$  influencie na precificação da eletricidade. Além disso, ao considerar que tanto produtores quanto comercializadores devem tomar decisões de curto prazo, a  $V_{RH/2}$  é outro parâmetro influenciador da precificação da eletricidade.

Pela aplicação do CFS, notou-se que as variações e suas respectivas médias móveis são atributos de influência na previsão da demanda da energia elétrica.

Cabe ainda destacar que a quantidade de atributos foi reduzida drasticamente, visto que a base de dados possui um total de 66 atributos e as taxas de redução estão em torno de 80% a 94%.

## **6.2 RESULTADOS DA PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA**

Nesta seção são apresentados os resultados das previsões da demanda de eletricidade para a região australiana de NSW considerando o uso ou não da seleção de atributos. Reforça-se que estes resultados foram obtidos para oito bases de dados na configuração “sem seleção de dados” e para oito bases de dados na configuração “com seleção de dados”, porém são feitos 20 testes para o desempenho das RNAs com e sem os atributos mais relevantes selecionados.

As topologias das RNAs que apresentaram os melhores desempenhos para as oito bases de dados com e sem a seleção de atributos têm seus resultados destacados e também apresentados em formatos gráficos.

### **6.2.1 Base de Dados de Finais de Semana e Feriados – Período da Madrugada**

Após o treinamento e validação das RNAs, foi possível obter as três topologias que apresentaram os melhores resultados para as previsões de demanda em finais de semana e feriados, considerando apenas a faixa de horários que compreendem a madrugada. Tais resultados são apresentados na Tabela 7, onde nota-se que houve uma redução de 38,0% do MAPE ao contrastar as melhores topologias de RNA para dados sem e com a seleção de atributos, mostrando assim que a metodologia proposta é eficaz e corrobora com a hipótese

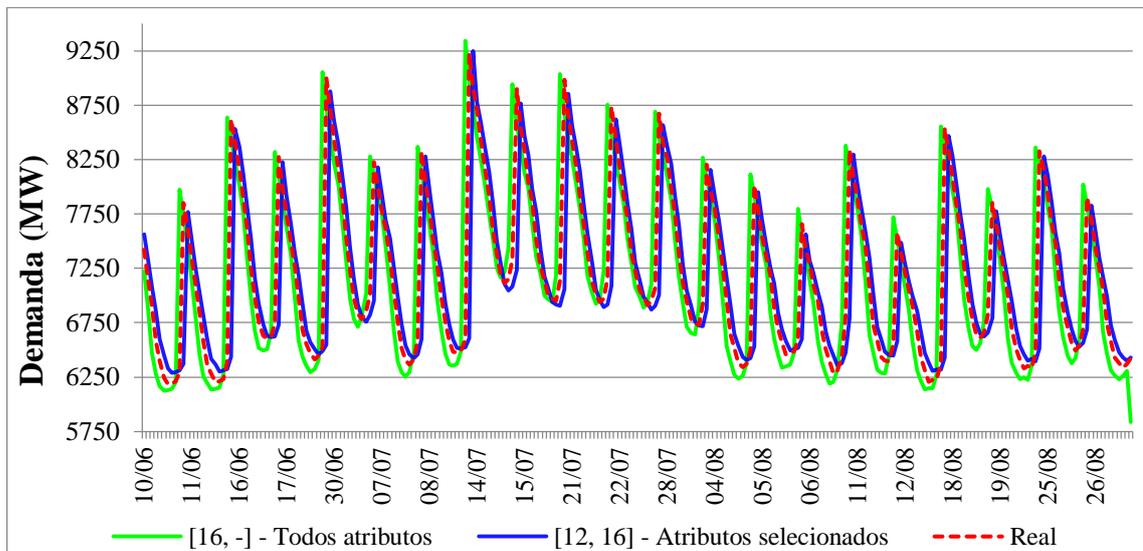
dessa dissertação. Além disso, é importante observar que todos os MAPEs obtidos são menores que os 5% estabelecidos como meta dessa dissertação.

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figuras 13.

**Tabela 7** - Melhores resultados para o período da madrugada de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[16, -]	[12, 28]	[16, 20]	[12, 16]	[16, 20]	[20, 24]
MAE (MW)	297,4	328,5	313,7	225,3	282,8	242,6
MAPE (%)	4,28	4,62	4,54	2,96	3,71	3,09
RMSE (MW)	539,9	518,6	600,2	385,5	415,5	516,1

**Figura 14** - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da madrugada.



### 6.2.2 Base de Dados de Dias Úteis – Período da Madrugada

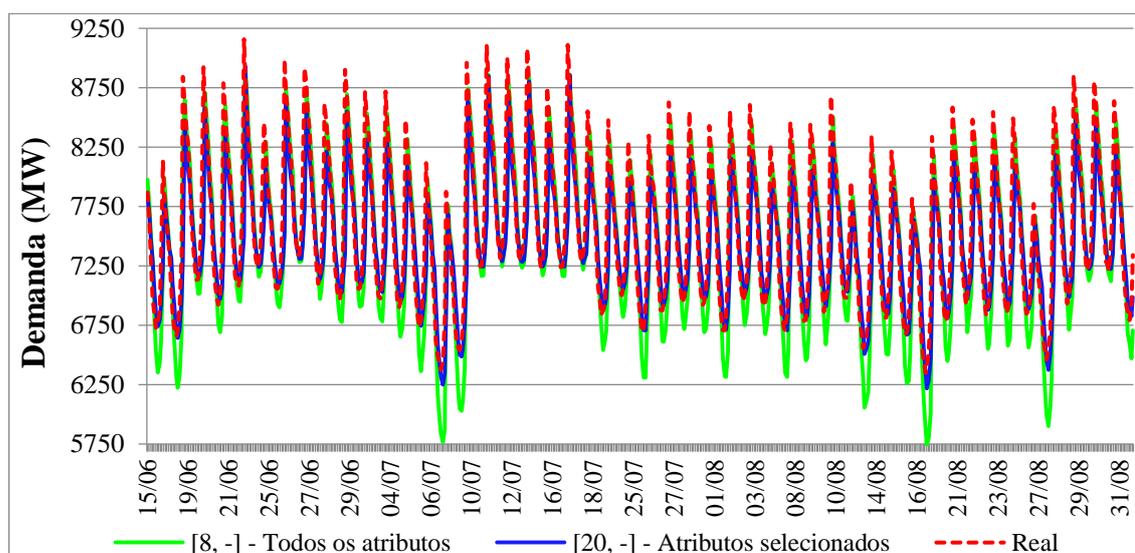
Por meio da Tabela 8 observa-se que as topologias cujas entradas são selecionadas (destacadas em vermelho) apresentam mais neurônios do que as configurações de RNA cujas entradas são todos os atributos.

**Tabela 8** - Melhores resultados para o período da madrugada de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[8, -]	[16, 20]	[20, 24]	[20, -]	[4, 8]	[12, 16]
MAE (MW)	273,0	300,0	345,6	230,8	243,1	285,1
MAPE (%)	3,57	3,89	4,48	2,92	3,06	3,32
RMSE (MW)	429,3	455,9	427,8	385,8	443,8	368,3

Os gráficos dos melhores resultados de previsão são apresentados por meio da Figura 14. Neste caso, quando comparado o MAPE das duas melhores RNAs, nota-se uma redução de 18,2% ao selecionar atributos, chegando a 2,92% de MAPE. Novamente, é possível observar que o MAPE das previsões encontra-se abaixo da meta de 5% previamente estabelecida.

**Figura 15** - Resultados de previsões de demanda com a base de dados de dias úteis para o período da madrugada.



### 6.2.3 Base de Dados de Finais de Semana e Feriados – Período da Manhã

Na Tabela 9, são destacadas as topologias que apresentaram o melhor desempenho. Observa-se que os índices de desempenhos se mantêm abaixo de 5% de MAPE para as melhores topologias, destacadas em vermelho.

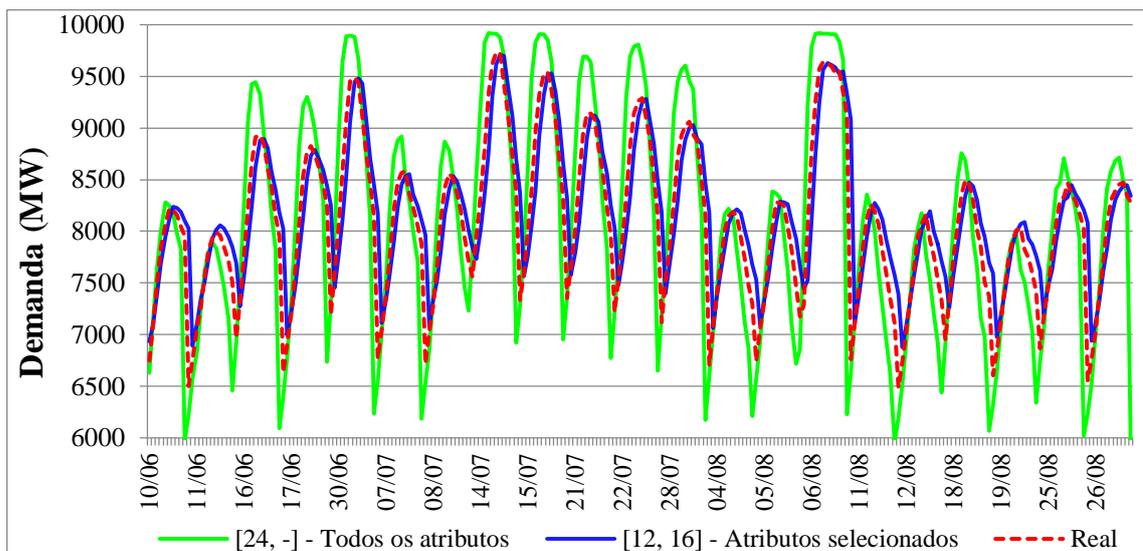
Ao analisar o gráfico da Figura 16, que correspondente à resposta da RNA com topologia [24, -], nota-se que a mesma apresenta certa dificuldade para estimar os picos de demanda máximos e mínimos. Entretanto, ao realizar a seleção dos atributos (Figura 19), nota-

se que a RNA com topologia [12, 16] consegue reduzir o MAPE em cerca de 30,8% ao considerar como referência o MAPE de 4,84% obtido pela topologia [24, -]. Além disso, é importante observar que a seleção de atributos ainda contribuiu para minimizar o erro em termos de demanda absoluta, em que é notável uma redução do MAE em 154,7 MW.

**Tabela 9** - Melhores resultados para o período da manhã de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[24, -]	[4, 16]	[12, 20]	[4, -]	[4, 12]	[12, 16]
MAE (MW)	398,5	412,7	351,3	268,0	263,1	258,0
MAPE (%)	4,84	5,14	4,38	3,46	3,40	3,35
RMSE (MW)	494,8	519,1	578,9	394,6	394,9	396,7

**Figura 16** - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da manhã.



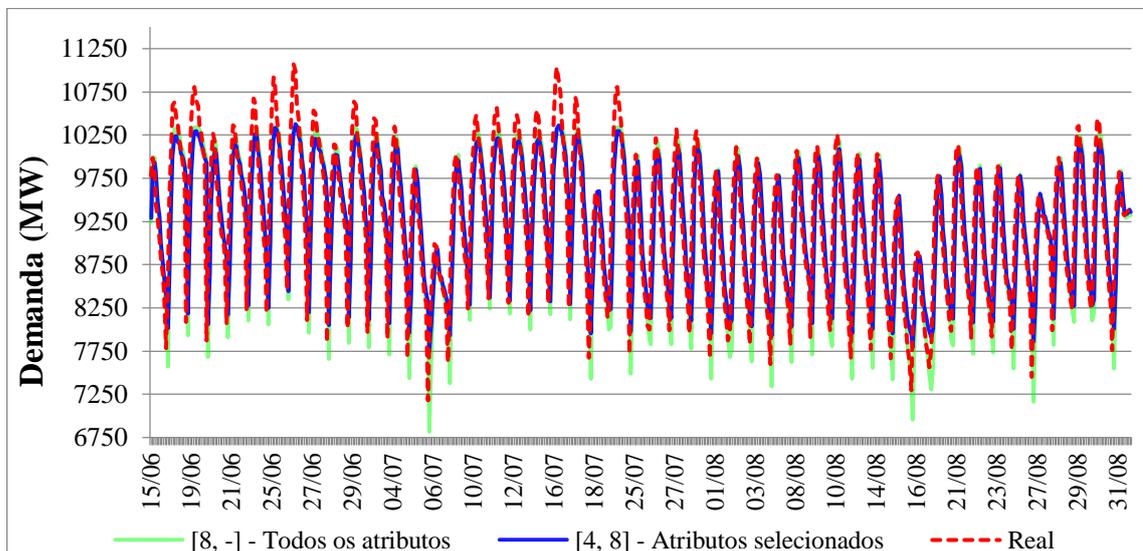
#### 6.2.4 Base de Dados de Dias Úteis – Período da Manhã

Destaca-se que a configuração neural [8, -] apresenta subestimações em picos de demanda mínima. Conforme pode ser observado na Tabela 12, apesar de a topologia [8, -] apresentar um MAPE de 4,14%, ainda assim, o uso da seleção de atributos contribuiu para a melhoria nos resultados, mesmo que sutilmente. Deste modo, foi possível obter uma topologia [4, 8] com MAPE de 4,01%. Os resultados destas topologias são apresentados Figura 16.

**Tabela 10** - Melhores resultados para o período da manhã de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[8, -]	[4, 20]	[12, 20]	[4, -]	[4, 8]	[8, 12]
MAE (MW)	377,8	418,5	464,4	380,3	365,4	367,7
MAPE (%)	4,14	4,59	5,07	4,21	4,01	4,00
RMSE (MW)	498,0	519,4	592,2	452,6	453,3	515,1

**Figura 17** - Resultados de previsões de demanda com a base de dados de dias úteis para o período da manhã.



### 6.2.5 Base de Dados de Finais de Semana e Feriados – Período da Tarde

Para essa base de dados, conforme observado por meio da Tabela 13, os MAPE sofrem uma redução sutil ao se comparar as RNAs com melhores resultados com e sem seleção de atributos. Entretanto, ao analisar os gráficos da Figuras 17, nota-se que a RNA com topologia [12, 16] que fez uso de atributos selecionados apresenta uma melhor estimativa dos picos de máxima demanda do que a RNA com topologia [12, 20].

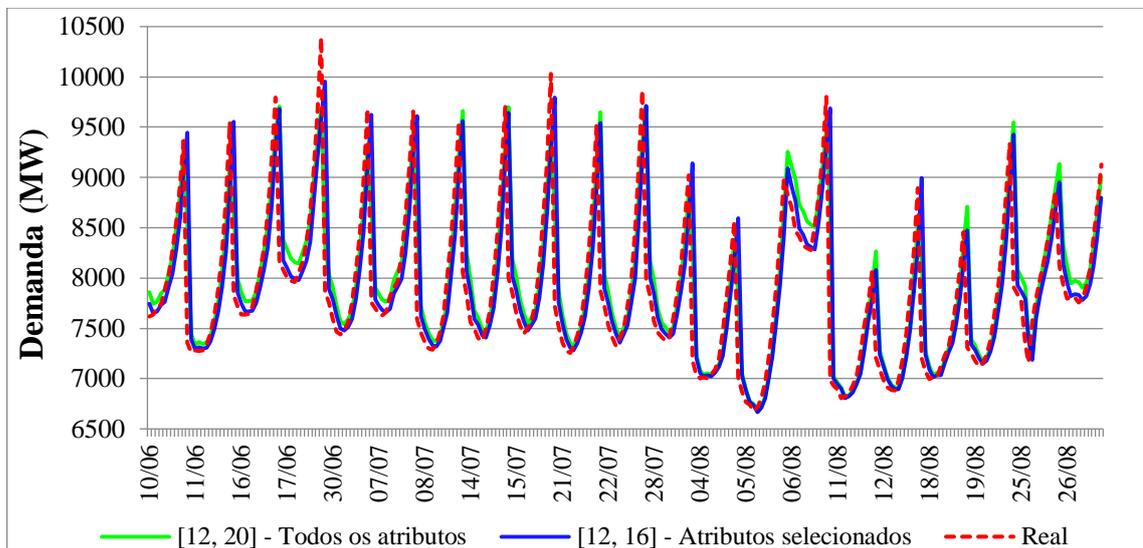
Cabe mencionar que uma série temporal, principalmente, se for relacionada com demanda de eletricidade, apresenta boa parte de seus valores dentro de uma determinada faixa. Deste modo, modelos de previsão que fornecerem estimativas em tal faixa, poderão apresentar um MAPE relativamente baixo, como é o caso das duas melhores topologias sem e com seleção de atributos. Contudo, verifica-se que é necessária uma análise gráfica ao comparar modelos de

previsão cujos índices de desempenho estejam próximos, com o intuito de identificar o modelo mais eficaz.

**Tabela 11** - Melhores resultados para o período da tarde de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[4, 12]	[8, 28]	[12, 20]	[8, 16]	[12, 16]	[16, 24]
MAE (MW)	300,6	322,8	253,1	282,7	295,3	294,4
MAPE (%)	3,83	4,13	3,20	3,61	3,79	3,66
RMSE (MW)	553,0	570,0	412,0	480,8	424,1	426,3

**Figura 18** - Resultados de previsões de demanda com a base de dados de finais de semana e feriados para o período da tarde.



### 6.2.6 Base de Dados de Dias Úteis – Período da Tarde

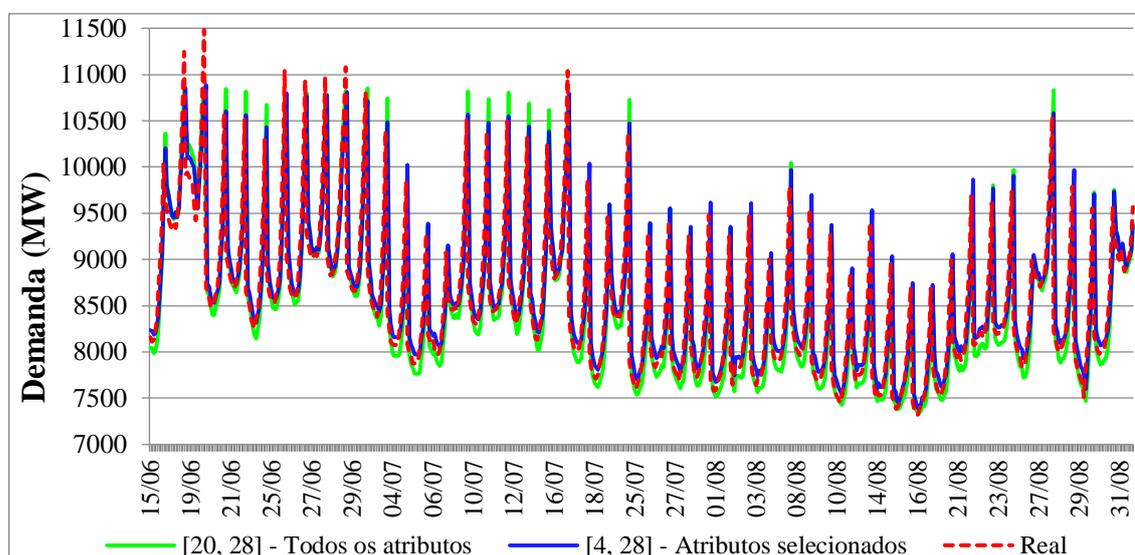
A Tabela 14, demonstra a necessidade de uma grande quantidade de neurônios e duas camadas neurais intermediárias para se obter uma boa previsão sem a seleção de atributos, conforme topologia [20, 28]. Nesse caso, a seleção de atributos não trouxe eficácia significativa ao desempenho das RNAs, como pode ser observado ao comparar os resultados da topologia [20, 28] com os da topologia [4, 28]. Porém, a redução no número de neurônios da primeira camada intermediária é evidente.

Além disso, graficamente (Figura 18), também é possível notar que a topologia que faz uso de seleção de atributos é pouco melhor do que a topologia que faz uso de todos os atributos como entradas.

**Tabela 12 - Melhores resultados para o período da tarde de dias úteis.**

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[24, -]	[8, 24]	[20, 28]	[24, -]	[4, 28]	[8, 28]
MAE (MW)	322,8	317,2	320,8	356,5	293,7	301,0
MAPE (%)	3,74	3,63	3,54	3,88	3,39	3,50
RMSE (MW)	545,7	537,4	505,7	550,0	514,4	559,9

**Figura 19 - Resultados de previsões de demanda com a base de dados de dias úteis para o período da tarde.**



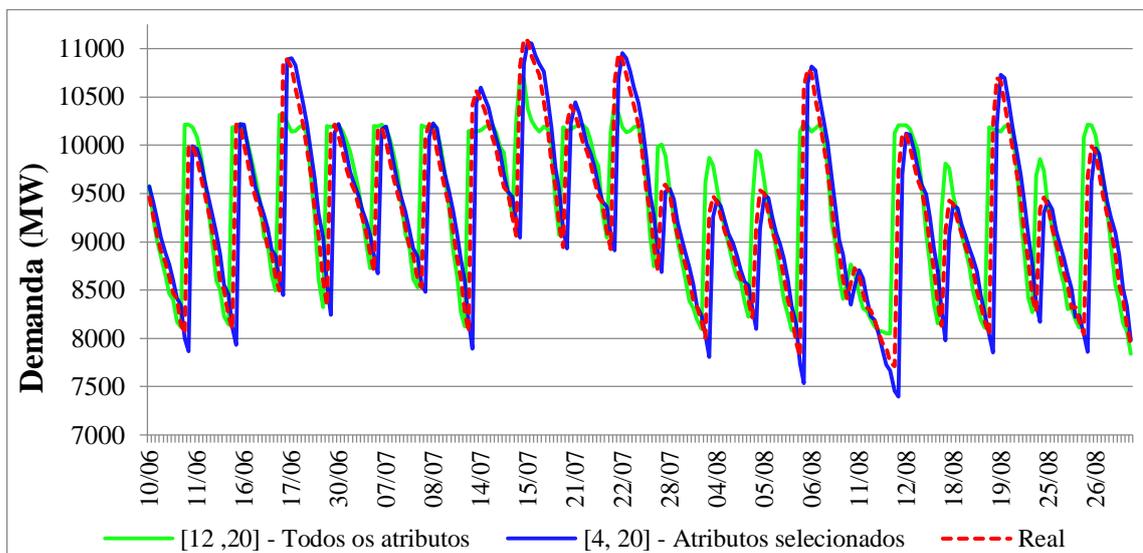
### 6.2.7 Base de Dados de Finais de Semana e Feriados – Período da Noite

Pela Tabela 13 nota-se que as topologias neurais [12, 20] e [4, 20], respectivamente sem e com a seleção de atributos, mostraram-se mais adequadas em termos de MAPE. Neste caso, houve ganho em se empregar a seleção de atributos que possibilitou uma redução de 17,2% em termos de MAE.

Graficamente nota-se o ganho de performance na Figura 20 são apresentados os gráficos dos melhores resultados de previsão de um total de 20 execuções de treinamento e validação. Em situações de demandas máximas e mínimas, quando as tomadas decisão de curtíssimo prazo possuem maior impacto financeiro, evidencia-se o ganho de performance.

**Tabela 13** - Melhores resultados para o período da noite de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[8, 12]	[12, 20]	[16, 24]	[28, -]	[4, 20]	[16, 20]
MAE (MW)	346,9	314,2	389,5	265,2	260,3	267
MAPE (%)	4,02	3,52	4,36	2,77	2,68	2,73
RMSE (MW)	614,3	558,0	561,1	503,5	505,0	516,1

**Figura 20** - Melhores resultados das previsões com a base de dados de dias não úteis - Período da Noite.

### 6.2.8 Base de Dados de Dias Úteis – Período da Noite

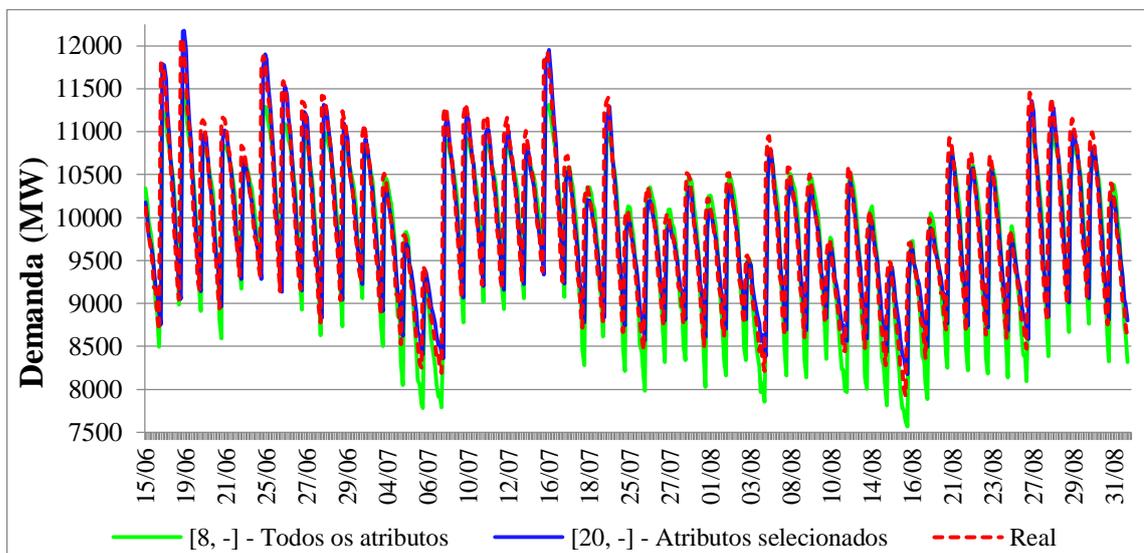
Os melhores resultados obtidos são expostos na Tabela 14. Novamente, o MAPE pôde ser reduzido ao se empregar a seleção de atributos. A diferença de desempenho pode ser nitidamente observada nos gráficos da Figura 21, em que os picos de demanda máxima são subestimados pela topologia [8, -] (sem seleção de atributos), enquanto a topologia [20, -] apresenta estimacões com maior precisão.

Ao se comparar os MAPes das topologias [20, -] e [8,16], verifica-se que o desta é inferior ao daquela. Entretanto, não ser verifica o mesmo em termos de MAE e RMSE. Por isso, escolheu-se a topologia [20, -] como a de melhor performance, assim se justifica seu destaque na Tabela 14.

**Tabela 14** - Melhores resultados para o período da noite de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
Número de neurônios	[8, -]	[4, 8]	[8, 12]	[20, -]	[4, 12]	[8, 16]
MAE (MW)	367,5	468	442,8	283,2	283,5	274,7
MAPE (%)	3,60	4,66	4,40	2,79	2,72	2,65
RMSE (MW)	678,2	821,4	789,7	551,8	593,4	608,8

**Figura 21** - Resultados de previsões de demanda com a base de dados de dias úteis para o período da noite.



No Anexo I, as Tabelas 25 a 32 apresentam os índices médios de desempenho (MAE, RMSE, MAPE) de 20 execuções de validação das RNA. De uma maneira geral, constatou-se que o acréscimo de número de neurônios fornece uma expectativa de acurácia de previsão ineficiente.

### 6.3 RESULTADOS DA PREVISÃO DO PREÇO DA ENERGIA ELÉTRICA

Nesta seção são apresentados os resultados das previsões do preço de eletricidade para a região australiana de NSW considerando o uso ou não da seleção de atributos. Reforça-se que estes resultados foram obtidos para oito bases de dados na configuração “sem seleção de

atributos” e oito bases de dados na configuração “comm seleção de atributos”, porém são feitos 20 testes para o desempenho das RNAs com e sem os atributos mais relevantes selecionados.

As topologias das RNAs que apresentaram os melhores desempenhos para as oito bases de dados com e sem a seleção de atributos têm seus resultados destacados e também apresentados em formatos gráficos.

### 6.3.1 Base de Dados de Finais de Semana e Feriados – Período da Madrugada

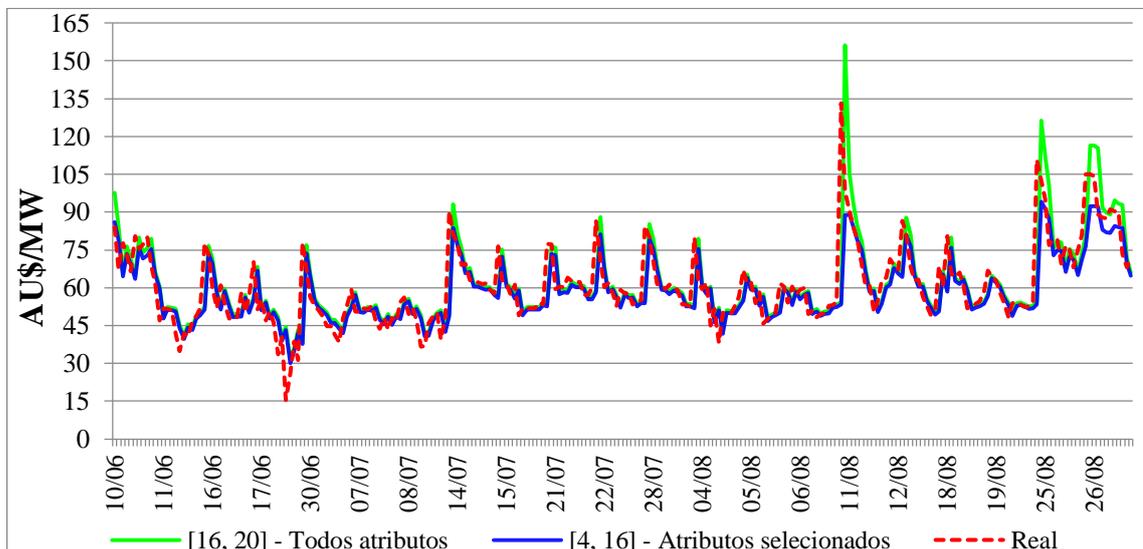
Pela Tabela 15 nota-se que as topologias neurais [12, 20] e [4, 20], respectivamente sem e com a seleção de atributos, mostraram-se mais adequadas em termos de MAPE. A seleção de dados não forneceu expressivos ganhos na acurácia da previsão do preço, porém possibilitou desempenho computacional, pois há menos variáveis para processar.

Na Figura 22 são apresentados os gráficos dos melhores resultados de previsão de um total de 20 execuções de treinamento e validação.

**Tabela 15** - Melhores resultados para o período da madrugada de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
	[8, -]	[4, 24]	[16, 20]	[20, -]	[4, 16]	[8, 20]
Número de neurônios	[8, -]	[4, 24]	[16, 20]	[20, -]	[4, 16]	[8, 20]
MAE (AU\$/MW)	8,00	8,60	6,90	6,20	6,20	6,30
MAPE (%)	13,82	14,05	11,10	10,17	10,12	10,27
RMSE (AU\$/MW)	12,00	13,00	11,70	10,60	10,60	10,80

**Figura 22** - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da madrugada.



### 6.3.2 Base de Dados de Dias Úteis – Período da Madrugada

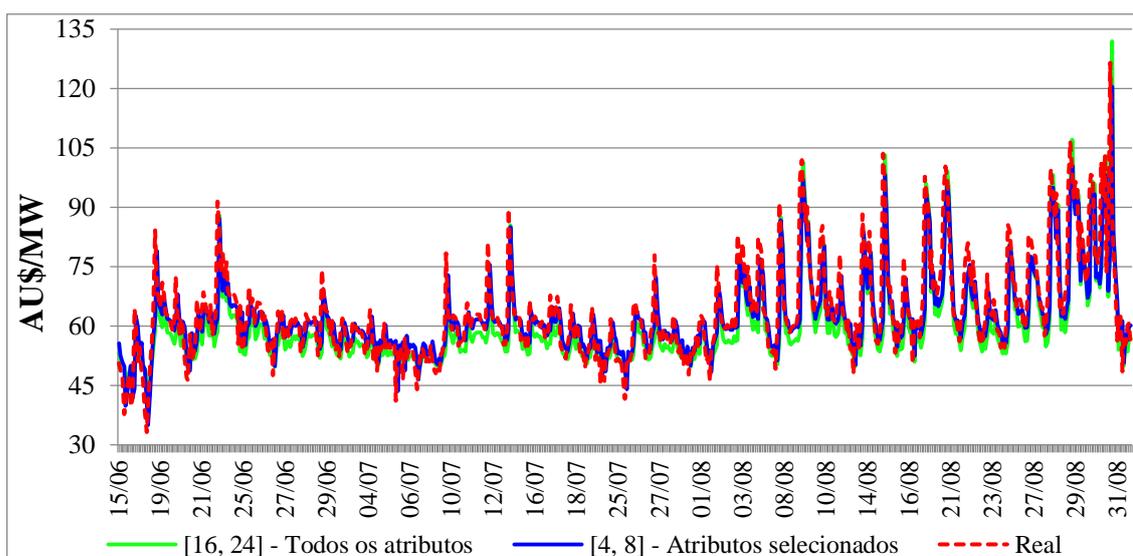
Observa-se na Tabela 16 que houve uma redução de 30,8% do MAPE ao comparar as melhores topologias de RNA para dados sem e com a seleção de atributos, mostrando assim que a metodologia proposta é eficaz e corrobora com a hipótese dessa dissertação. Também, houve sensível redução dos números de neurônios das RNAs de melhor desempenho.

**Tabela 16** - Melhores resultados para o período da madrugada de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
	[24, -]	[4, 16]	[16, 24]	[4, 8]	[8, 16]	[12, 24]
<b>Número de neurônios</b>	[24, -]	[4, 16]	[16, 24]	[4, 8]	[8, 16]	[12, 24]
<b>MAE (AU\$/MW)</b>	5,70	6,30	5,50	4,70	4,80	4,80
<b>MAPE (%)</b>	8,30	9,53	8,17	7,06	7,28	7,19
<b>RMSE (AU\$/MW)</b>	9,30	8,80	8,50	7,60	7,40	7,60

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 23.

**Figura 23** - Resultados de previsões de preço com a base de dados de dias úteis para o período da madrugada.



### 6.3.3 Base de Dados de Finais de Semana e Feriados – Período da Manhã

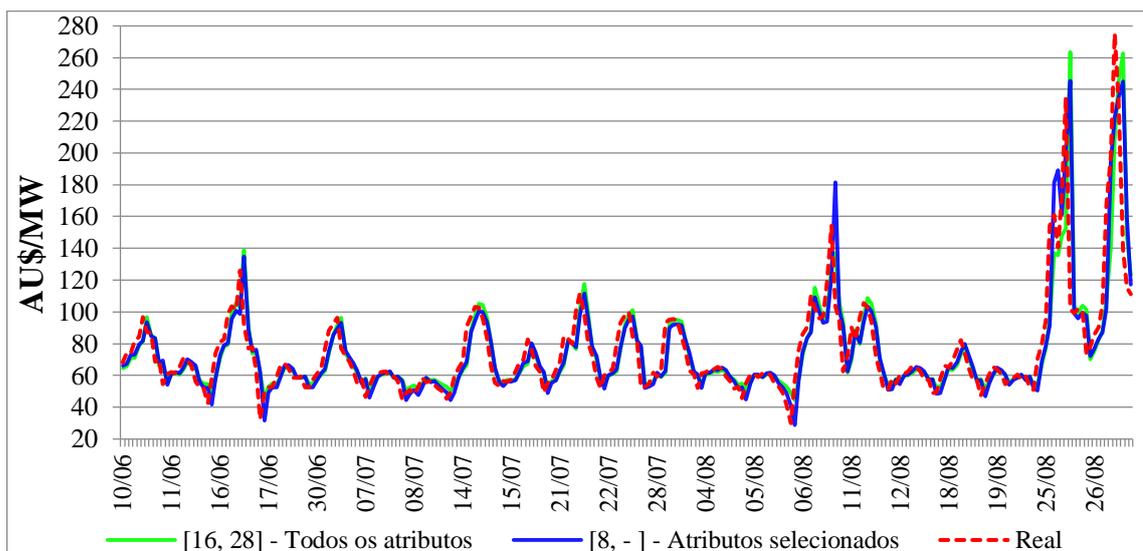
Na Tabela 17 destacam-se os melhores resultados com e sem seleção de dados. Percebe-se que não satisfazem o critério  $MAPE \leq 10\%$ . Neste sentido, não foi obtido nenhum resultado satisfatório com a base de dados dos conjuntos de dias finais de semana e feriados do período da manhã.

Na Figura 24 estão graficamente as estimações das topologias destacadas na Tabela 17. Apesar de que, aparentemente, as previsões sejam adequadas, os índices de performance expressam o contrário.

**Tabela 17** - Melhores resultados para o período da manhã de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
	<b>Número de neurônios</b>	[4, 28]	[12, 20]	[16, 28]	[8, -]	[4, 20]
<b>MAE (AU\$/MW)</b>	9,90	10,40	9,50	9,70	9,80	10,20
<b>MAPE (%)</b>	11,70	11,37	11,31	11,88	11,98	12,02
<b>RMSE (AU\$/MW)</b>	17,50	22,40	19,20	16,30	16,70	18,30

**Figura 24** - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da manhã.

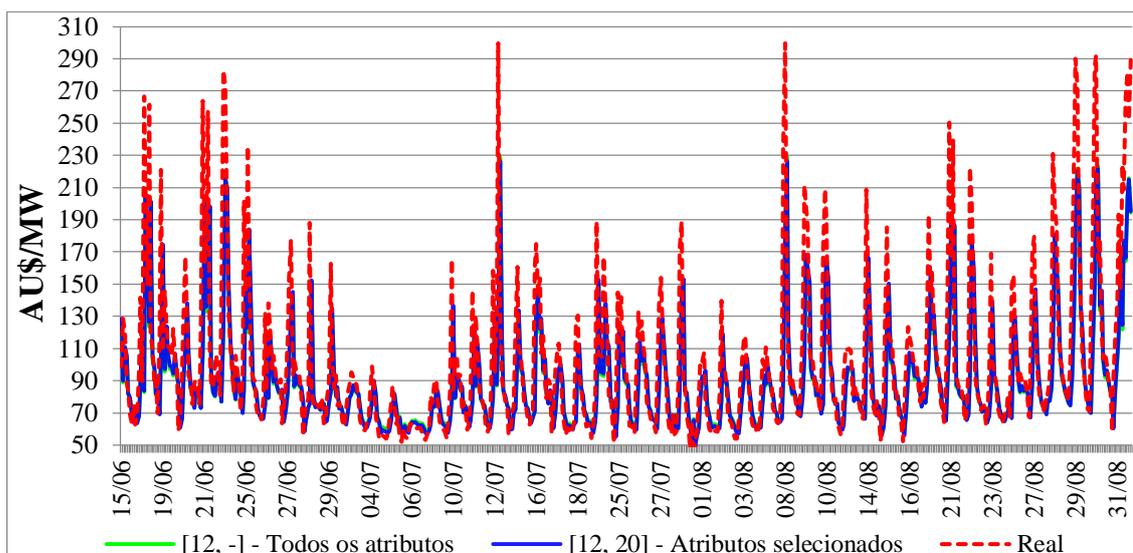


### 6.3.4 Base de Dados de Dias Úteis – Período da Manhã

Na Tabela 19 expõem-se os melhores resultados com e sem seleção de dados. Percebe-se que não satisfazem o critério  $MAPE \leq 10\%$ , inclusive os considerados melhores, que estão destacados na tabela citada. Neste sentido, conforme ocorreu com o grupo de dias de feriados e finais de semana, não foi obtido nenhum resultado satisfatório com a base de dados dos conjuntos de dias úteis do período da manhã.

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 25. Nota-se que aparentemente não há as estimações de [12, -], pois são bem semelhantes as das [12, 20], assim os gráficos se sobrepõem.

**Figura 25** - Resultados de previsões de preço com a base de dados de dias úteis para o período da manhã.



**Tabela 18** - Melhores resultados para o período da manhã de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
<b>Número de neurônios</b>	[12, -]	[8, 24]	[16, 28]	[16, -]	[4, 12]	[12, 20]
<b>MAE (AU\$/MW)</b>	21,09	23,20	23,7	21,39	23,10	20,98
<b>MAPE (%)</b>	16,72	17,94	18,37	16,67	17,80	16,68
<b>RMSE (AU\$/MW)</b>	36,63	39,6	41,0	37,24	39,94	36,32

### 6.3.5 Base de Dados de Finais de Semana e Feriados – Período da Tarde

A principal consequência da aplicação da seleção de atributos foi a redução dos números de neurônios da RNA mais eficaz nas previsões. No caso, de [16, 20] para [8, 20] conforme Tabela 19.

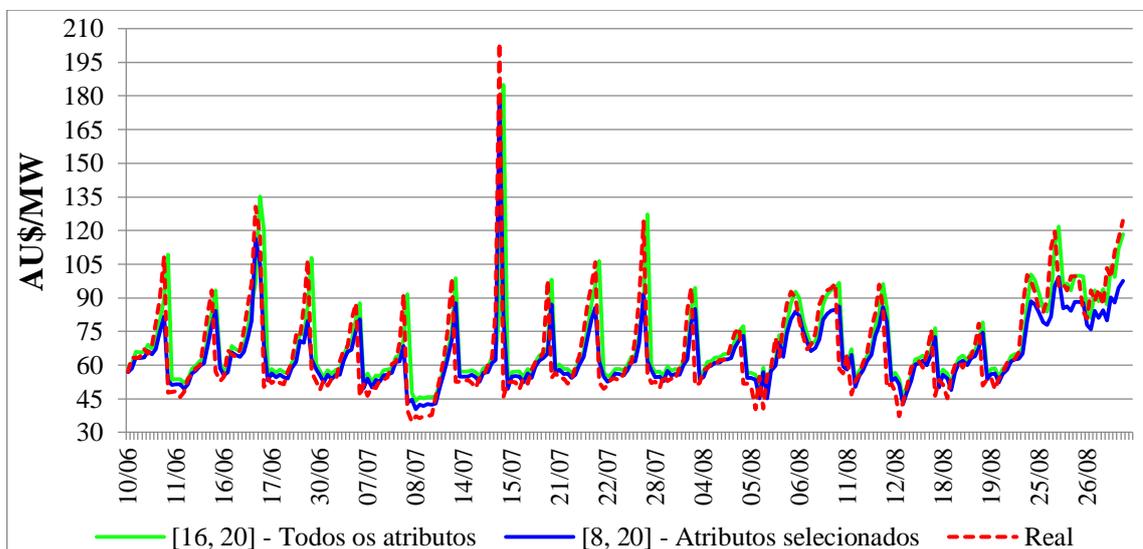
Assim como também ocorreu com a base de dados de finais de semana e feriados do período da manhã, a topologia neural [16, 20], cujas entradas são todos os atributos, foi a melhor. Além dessa similaridade, os índices de desempenho são praticamente idênticos. Neste sentido, há um indicativo do limite das MLPs pelo uso de todas as variáveis das bases de dados de finais de semana e feriados.

**Tabela 19** - Melhores resultados para o período da tarde de finais de semana e feriados.

Atributos	Todos os atributos			Com seleção de atributos		
	[12, 20]	[16, 20]	[20, 28]	[8, 20]	[16, 24]	[20, 24]
<b>Número de neurônios</b>	[12, 20]	[16, 20]	[20, 28]	[8, 20]	[16, 24]	[20, 24]
<b>MAE (AU\$/MW)</b>	8,69	6,90	8,89	6,31	6,83	6,96
<b>MAPE (%)</b>	14,02	11,10	13,97	10,27	11,58	11,22
<b>RMSE (AU\$/MW)</b>	13,35	11,71	14,18	10,77	10,97	11,42

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 25. Nota-se que após picos de demandas máximas a RNA [16, 20] tende a realizar sobrestimações.

**Figura 26** - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da tarde.



### 6.3.6 Base de Dados de Dias Úteis – Período da Tarde

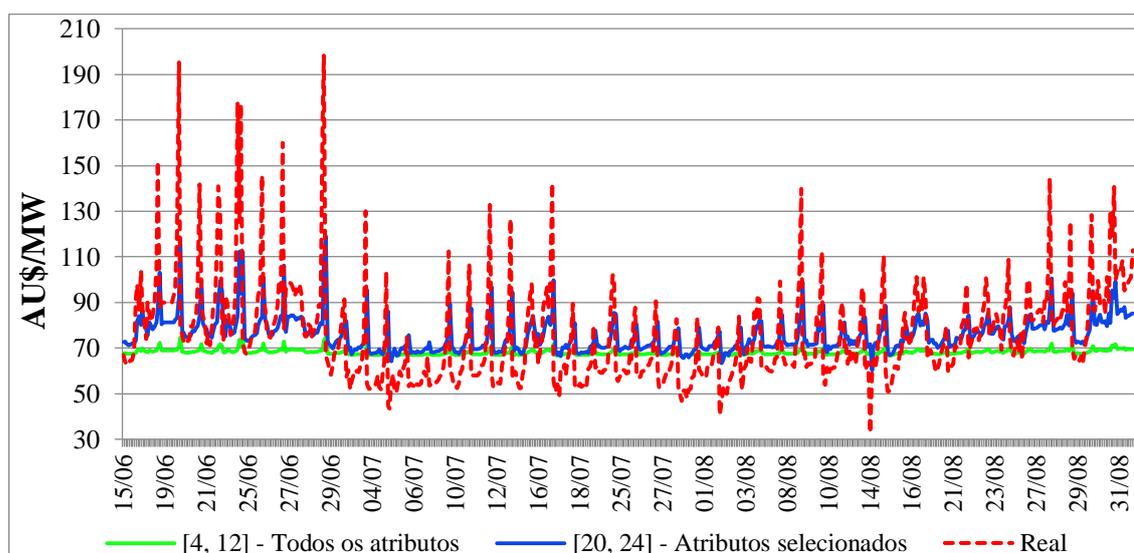
Por meio dos destaques em vermelho da Tabela 20, observa-se que as topologias cujas entradas são selecionadas apresentam mais neurônios do que as configurações de RNA cujas entradas são todos os atributos. Ademais, os resultados são semelhantes aos da Tabela 18, referentes aos resultados da base de dados de dias úteis do período da manhã.

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 27, percebe-se que ocorreu *overfitting* das RNAs.

**Tabela 20** - Melhores resultados para o período da tarde de dias úteis.

Atributos	Todos os atributos			Com seleção de atributos		
	[20, -]	[4, 12]	[8, 16]	[4, -]	[16, 20]	[20, 24]
Número de neurônios	[20, -]	[4, 12]	[8, 16]	[4, -]	[16, 20]	[20, 24]
MAE (AU\$/MW)	16,75	14,95	15,74	15,39	14,33	12,49
MAPE (%)	18,30	17,98	18,97	17,61	20,77	16,64
RMSE (AU\$/MW)	24,25	21,87	22,84	23,24	18,94	17,82

**Figura 27** - Resultados de previsões de preço com a base de dados de dias úteis para o período da tarde.



### 6.3.7 Base de Dados de Finais de Semana e Feriados – Período da Noite

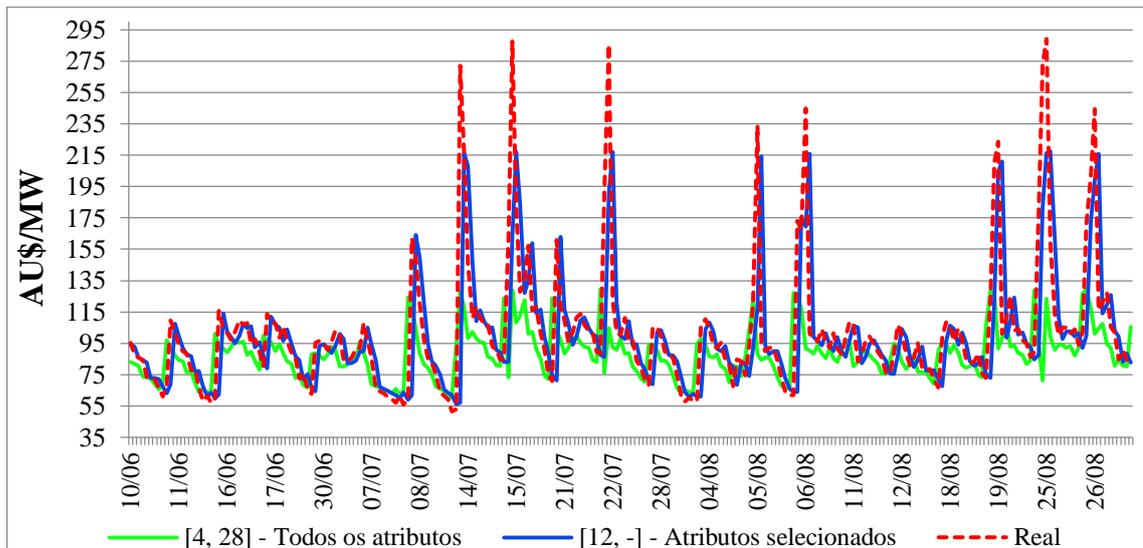
Por meio da Tabela 21 nota-se que a aplicação do algoritmo CFS permitiu ganhos de performance. Em termos de MAPE, é uma redução de 20,4% entre os melhores resultados (destaques em vermelho). Deste modo, mostrando que a metodologia proposta é eficaz e corrobora com a hipótese dessa dissertação.

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 28. Nota-se dificuldade das RNAs para estimar os picos de demanda máximos, também, não apresentaram resultados satisfatórios,  $MAPE \leq 10\%$ .

**Tabela 21** - Melhores resultados para o período da noite de finais de semana e feriados.

Atributos	Todos os atributos		Com seleção de atributos			
Número de neurônios	[12, -]	[4, 28]	[12, 16]	[12, -]	[4, 20]	[20, 28]
MAE (AU\$/MW)	21,87	20,45	17,61	17,13	18,69	18,92
MAPE (%)	18,84	16,48	16,57	13,12	13,88	15,48
RMSE (AU\$/MW)	38,56	38,19	33,77	34,23	38,11	34,13

**Figura 28** - Resultados de previsões de preço com a base de dados de finais de semana e feriados para o período da tarde.



### 6.3.8 Base de Dados de Dias Úteis – Período da Noite

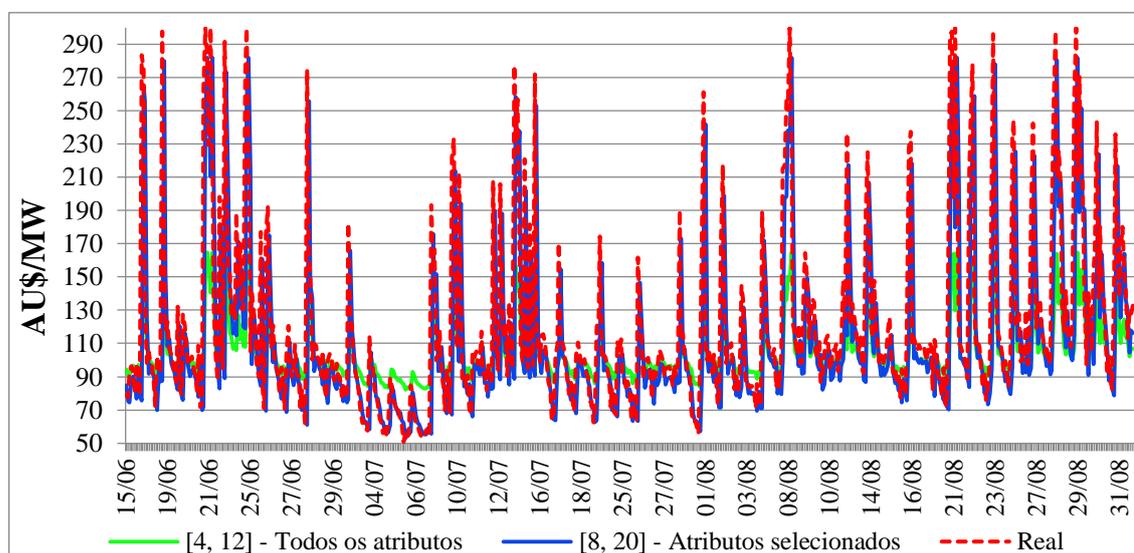
Na Tabela 22 exibem-se os melhores índices de desempenho. Conforme ocorreu com os resultados referentes à base de dados de finais de semana e feriado do período da noite, a aplicação da seleção de atributos favoreceu os resultados das RNAs.

As melhores estimações, sem e com a seleção de atributos, são apresentadas graficamente por meio da Figura 29, percebe-se que ocorreu *overfitting* das RNAs

**Tabela 22** - Melhores resultados para o período da noite de dias úteis.

Atributos	Todos os atributos		Com seleção de atributos			
Número de neurônios	[4, -]	[4, 12]	[8, 12]	[20, -]	[4, 8]	[8, 20]
MAE (AU\$/MW)	31,98	27,44	30,71	24,89	29,78	26,32
MAPE (%)	21,67	19,01	21,52	17,36	20,33	17,96
RMSE (AU\$/MW)	54,10	47,23	51,81	43,13	48,24	45,47

**Figura 29** - Resultados de previsões de preço com a base de dados de dias úteis para o período da noite.



No Anexo I, as Tabelas 33 a 39 apresentam os índices médios de desempenho (MAE, RMSE, MAPE) de 20 execuções de validação das RNA. De uma maneira geral, constatou-se que o acréscimo de número de neurônios fornece uma expectativa de acurácia de previsão ineficiente.

## 7 CONCLUSÕES

Apresentou-se uma metodologia para previsão de demanda e de preço de energia elétrica para a região australiana de *New South Wales* pertencente ao Mercado de Energia da Austrália. Para tanto, foram criadas bases de dados com séries históricas de variáveis climáticas, de preço e de demanda de eletricidade, além da aplicação de algoritmo *Correlation-based Feature Selection*. Essas bases de dados serviram como entradas das RNAs, que previram a demanda e o preço.

No total, foram formadas 24 bases de dados. Destas, 8 com todos os atributos considerados para previsão de demanda e de preço, 8 provenientes da seleção de atributos para previsão de demanda e 8 provenientes da seleção de atributos para previsão de preço. Para cada topologia de RNA de um total de 27 consideradas, foram realizadas 20 execuções de treinamento e validação. De maneira geral, constatou-se que à medida que se aumenta os números de neurônios nas camadas intermediárias, a expectativa dos resultados de previsão torna-se ineficaz. Em contrapartida, foram obtidos resultados condizentes com as metas estabelecidas nessa dissertação (MAPEs menores ou iguais a 5% para a demanda e menores ou iguais a 10% para o preço) ao se empregar topologias com um número reduzido de neurônios.

Em relação à seleção de atributos percebeu-se, em geral, uma melhoria na acurácia das previsões. Tal processo reduziu o número de variáveis de entrada (entre 84 a 90%) e, conseqüentemente, o decréscimo de esforço computacional. Dentre as variáveis selecionadas estão variáveis climáticas, médias móveis e variações de demanda e de preço. Neste sentido, foi positivo inserir tais atributos na formação inicial das bases de dados.

Ao considerar as estimações da demanda, os resultados mostraram-se sempre abaixo de 5% em termos de MAPE. Entretanto, não se pode afirmar o mesmo para os resultados do preço, cujo patamar de resultado previamente estabelecido era de 10% de MAPE. Assim, constatou-se que somente o uso de RNAs não é adequado para tomadas de decisão em torno da precificação da energia para janelas temporais de curtíssimo prazo. Assim, métricas como MAE e RMSE, bem como análise gráfica podem ser mais adequadas para se obter resultados com maior eficácia.



## REFERÊNCIAS BIBLIOGRÁFICAS

ABRACEEL. **ABRACEEL**. Disponível em: <[http://www.abraceel.com.br/zpublisher/secoes/consumidor\\_livre.asp](http://www.abraceel.com.br/zpublisher/secoes/consumidor_livre.asp)>. Acesso em: 18 maio. 2018.

ABRADEE. **Entenda a Indústria de Energia Elétrica**, 2018.

AEMC. **Electricity system | AEMC**. Disponível em: <<https://www.aemc.gov.au/energy-system/electricity>>. Acesso em: 2 maio. 2018.

AER. **State of the Energy Market**. Melbourne: [s.n.]. Disponível em: <<https://www.aer.gov.au/node/29372>>.

BALIYAN, A.; GAURAV, K.; MISHRA, S. K. A Review of Short Term Load Forecasting using Artificial Neural Network Models. **Procedia Computer Science**, v. 48, p. 121–125, 1 jan. 2015.

BEGGS, C. Competition in energy supply. In: **Energy: Management, Supply and Conservation**. [s.l.] Elsevier, 2002a. p. 37–54.

BEGGS, C. Energy and the environment. In: **Energy: Management, Supply and Conservation**. [s.l.] Elsevier, 2002b. p. 1–21.

BENTO, P. M. R. et al. A bat optimized neural network and wavelet transform approach for short-term price forecasting. **Applied Energy**, v. 210, p. 88–97, 15 jan. 2018.

BHAROTHU, J. N.; SRIDHAR, M.; RAO, R. S. **A literature survey report on Smart Grid technologies**. 2014 International Conference on Smart Electric Grid (ISEG). **Anais...IEEE**, set. 2014 Disponível em: <<http://ieeexplore.ieee.org/document/7005601/>>. Acesso em: 2 maio. 2018

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: forecasting and control**. 4. ed. Hoboken, NJ: John Wiley & Sons, Inc., 2008.

BRAGA, A. DE P.; CARVALHO, A. C. P. DE L. F.; LUDERMIR, T. B. **Redes neurais artificiais : teoria e aplicações**. [s.l.] LTC Editora, 2007.

CCEE. **CCEE - Comercialização - Setor elétrico brasileiro**. Disponível em: <[https://www.ccee.org.br/portal/faces/pages\\_publico/onde-atuamos/comercializacao?\\_adf.ctrl-state=zmlc0ba81\\_18&\\_afLoop=106131572467696#!%40%40%3F\\_afLoop%3D106131572467696%26\\_adf.ctrl-state%3Dzmlc0ba81\\_22](https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/comercializacao?_adf.ctrl-state=zmlc0ba81_18&_afLoop=106131572467696#!%40%40%3F_afLoop%3D106131572467696%26_adf.ctrl-state%3Dzmlc0ba81_22)>. Acesso em: 10 out. 2018.

CCEE. **CCEE - Setor elétrico - Conheça o ambiente em que a CCEE está inserida**. Disponível em: <[https://www.ccee.org.br/portal/faces/pages\\_publico/onde-atuamos/setor\\_eletrico?\\_adf.ctrl-state=17yce23yqg\\_5&\\_afLoop=168111436856953#!](https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/setor_eletrico?_adf.ctrl-state=17yce23yqg_5&_afLoop=168111436856953#!)>. Acesso em: 18 maio. 2018a.

CCEE. **CCEE - Quem são os agentes - Agentes que atuam no setor de energia elétrica**. Disponível em: <[https://www.ccee.org.br/portal/faces/pages\\_publico/quem-participa/quem\\_sao\\_os\\_agentes?\\_adf.ctrl-state=17yce23yqg\\_68&tv%3DCCEE\\_015224%26=&\\_afLoop=167303386446546#!](https://www.ccee.org.br/portal/faces/pages_publico/quem-participa/quem_sao_os_agentes?_adf.ctrl-state=17yce23yqg_68&tv%3DCCEE_015224%26=&_afLoop=167303386446546#!)>. Acesso em: 18 maio. 2018b.

CHANG, G. W. et al. An improved neural network-based approach for short-term wind

speed and power forecast. **Renewable Energy**, v. 105, p. 301–311, 1 maio 2017.

CHEN, Y. et al. Mixed kernel based extreme learning machine for electric load forecasting. **Neurocomputing**, v. 312, p. 90–106, out. 2018.

CRAMTON, P. Electricity market design. **Oxford Review of Economic Policy**, v. 33, n. 4, p. 589–612, 2 nov. 2017.

DOLARA, A. et al. A Physical Hybrid Artificial Neural Network for Short Term Forecasting of PV Plant Power Output. **Energies**, v. 8, p. 1138–1153, 2015.

DUDEK, G. Multilayer perceptron for GEFCom2014 probabilistic electricity price forecasting. **International Journal of Forecasting**, v. 32, p. 1057–1060, 2016.

EMPRESA DE PESQUISA ENERGÉTICA. **Mercado de energia elétrica, 2006-2015**. [s.l.] EPE, Ministério de Minas e Energia, Governo Federal, 2005.

EMPRESA DE PESQUISA ENERGÉTICA. **Anuário Estatístico de Energia Elétrica 2018**. Brasília, Brasil: [s.n.]. Disponível em: <<http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/Anuario2018vf.pdf>>. Acesso em: 5 fev. 2019.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. Knowledge Discovery and Data Mining: Towards a Unifying Framework. **Proceedings of the Second International Conference on Knowledge Discovery and Data Mining**, p. 82–88, 1996.

FERNANDES, R. A. S. **Identificação de fontes de correntes harmônicas por redes neurais artificiais**. São Carlos: Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo, 5 fev. 2009.

GANDELLI, A. et al. **Hybrid model analysis and validation for PV energy production forecasting**. 2014 International Joint Conference on Neural Networks (IJCNN). **Anais...IEEE**, jul. 2014 Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6889786>>. Acesso em: 2 maio. 2018

GELLINGS, C. W.; BARRON, W. L. (WALLACE L. . **Demand forecasting in the electric utility industry**. [s.l.] PennWell Pub, 1996.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. [s.l.] The University of Waikato, 1999.

HALL, M. A. **Feature Selection for Discrete and Numeric Class Machine Learning**. Conference: Proceedings of the Seventeenth International Conference on Machine Learning (ICML 2000). **Anais...Stanford, CA, USA: 2000** Disponível em: <<https://www.cs.waikato.ac.nz/ml/publications/1999/99MH-Feature-Select.pdf>>. Acesso em: 2 maio. 2018

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. 2. ed. [s.l.] Diane Cerra, 2006.

HARRISON, C. et al. Foundations for Smarter Cities. **IBM Journal of Research and Development**, v. 54, n. 4, p. 1–16, jul. 2010.

HASSAN, S. et al. Electricity load and price forecasting with influential factors in a deregulated power industry. **2014 9th International Conference on System of Systems**

**Engineering (SOSE)**, p. 79–84, 2014.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Hamilton, Ontario, Canada: Person Education, 2008.

HERNÁNDEZ, L. et al. Artificial neural networks for short-term load forecasting in microgrids environment. **Energy**, v. 75, p. 252–264, 1 out. 2014.

HONG, T.; FAN, S. Probabilistic electric load forecasting: A tutorial review. **International Journal of Forecasting**, v. 32, n. 3, p. 914–938, 2016.

HOSSAIN, M. R.; OO, A. M. T.; ALI, A. B. M. S. Smart Grid. In: [s.l.] Springer, London, 2013. p. 23–44.

HU, R. et al. A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm. **Neurocomputing**, v. 221, p. 24–31, jan. 2017.

KELES, D. et al. Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks. **Applied Energy**, v. 162, p. 218–230, 15 jan. 2016.

LAOUAFI, A. et al. Online electricity demand forecasting based on an effective forecast combination methodology. **Electric Power Systems Research**, v. 148, p. 35–47, 1 jul. 2017.

LEVA, S. et al. Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. **Mathematics and Computers in Simulation**, v. 131, n. C, p. 88–100, jan. 2017.

LI, W. et al. Hybrid Forecasting Approach Based on GRNN Neural Network and SVR Machine for Electricity Demand Forecasting. **Energies**, v. 10, n. 1, p. 1–17, 2017.

LIU, H.; MOTODA, H. **Feature selection for knowledge discovery and data mining**. [s.l.] Kluwer Academic Publishers, 1998.

MOHANTY, S. P.; CHOPPALI, U.; KOUGIANOS, E. Everything you wanted to know about smart cities: The Internet of things is the backbone. **IEEE Consumer Electronics Magazine**, v. 5, n. 3, p. 60–70, jul. 2016.

NAM, T.; PARDO, T. A. **Smart city as urban innovation: focusing on management, policy, and context**. Proceedings of the 5th International Conference on Theory and Practice of Electronic Governance - ICEGOV '11. **Anais...**New York, New York, USA: ACM Press, 2011Disponível em: <<http://dl.acm.org/citation.cfm?doid=2072069.2072100>>. Acesso em: 2 maio. 2018

NEM. **The National Electricity Market NEM fast facts**, 2018. Disponível em: <<https://www.aemo.com.au/-/media/Files/Electricity/NEM/National-Electricity-Market-Fact-Sheet.pdf>>. Acesso em: 2 maio. 2018

NEUPANE, B.; WOON, W.; AUNG, Z. Ensemble Prediction Model with Expert Selection for Electricity Price Forecasting. **Energies**, v. 10, n. 1, p. 77, 10 jan. 2017.

OGLIARI, E. et al. PV Plant Planning and Operations by Neural Network Analysis and Validation. **29th European Photovoltaic Solar Energy Conference and Exhibition**, p. 2620–2624, 7 nov. 2014.

PANAPAKIDIS, I. P.; DAGOUMAS, A. S. Day-ahead electricity price forecasting via the application of artificial neural network based models. **Applied Energy**, v. 172, p. 132–151, 15 jun. 2016.

PANAPAKIDIS, I. P.; DAGOUMAS, A. S. Day-ahead natural gas demand forecasting

based on the combination of wavelet transform and ANFIS/genetic algorithm/neural network model. **Energy**, v. 118, p. 231–245, 1 jan. 2017.

PAPAIOANNOU, G. et al. Analysis and Modeling for Short- to Medium-Term Load Forecasting Using a Hybrid Manifold Learning Principal Component Model and Comparison with Classical Statistical Models (SARIMAX, Exponential Smoothing) and Artificial Intelligence Models (ANN, SVM): Th. **Energies**, v. 9, n. 8, p. 635, 2016.

QUAN, H.; SRINIVASAN, D.; KHOSRAVI, A. Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals. **IEEE Transactions on Neural Networks and Learning Systems**, v. 25, n. 2, p. 303–315, fev. 2014.

SEIFI, H.; SADEGH SEPASIAN, M. **Electric Power System Planning: Issues, Algorithms and Solutions**. 1. ed. [s.l.] Springer-Verlag Berlin Heidelberg, 2011.

SEPASI, S. et al. Very short term load forecasting of a distribution system with high PV penetration. **Renewable Energy**, v. 106, p. 142–148, 1 jun. 2017.

SETIAWAN, A.; KOPRINSKA, I.; AGELIDIS, V. G. Very short-term electricity load demand forecasting using support vector regression. **2009 International Joint Conference on Neural Networks**, p. 2888–2894, 2009.

SHAO, Z. et al. **A review of the decomposition methodology for extracting and identifying the fluctuation characteristics in electricity demand forecasting** *Renewable and Sustainable Energy Reviews*, 2017.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. P. P.-S. P. **Redes neurais artificiais para engenharia e ciências aplicadas**. [s.l.] Artliber Editora, 2010.

UN-HABITAT. **Urbanization and Development: Emerging Futures. World. Cities Report 2016**. [s.l.: s.n.]. Disponível em: <[www.unhabitat.org](http://www.unhabitat.org)>. Acesso em: 2 maio. 2018.

UN. **Transforming our world: the 2030 Agenda for Sustainable Development**, 2015. Disponível em: <[http://www.un.org/en/development/desa/population/migration/generalassembly/docs/globalcompact/A\\_RES\\_70\\_1\\_E.pdf](http://www.un.org/en/development/desa/population/migration/generalassembly/docs/globalcompact/A_RES_70_1_E.pdf)>. Acesso em: 2 maio. 2018

WAN, C. et al. Pareto Optimal Prediction Intervals of Electricity Price. **IEEE Transactions on Power Systems**, v. 32, n. 1, p. 817–819, jan. 2017.

WANG, D. et al. Multi-step ahead electricity price forecasting using a hybrid model based on two-layer decomposition technique and BP neural network optimized by firefly algorithm. **Applied Energy**, v. 190, p. 390–407, mar. 2017.

WERON, R. Electricity price forecasting : A review of the state-of-the-art with a look into the future. **International Journal of Forecasting**, v. 30, n. 4, p. 1030–1081, 2014.

WOODWARD, W. A.; GRAY, H. L.; ELLIOTT, A. C. **Applied time series analysis with R**. Second ed. New York: CRC Press, 2017.

XIAO, L. et al. A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. **Applied Energy**, v. 167, p. 135–153, 1 abr. 2016.

YANG, J. et al. Decision-Making for Electricity Retailers: A Brief Survey. **IEEE Transactions on Smart Grid**, p. 1–1, 2017.

YONG, B. et al. **Neural network model with Monte Carlo algorithm for electricity demand forecasting in Queensland**. Proceedings of the Australasian Computer Science Week

Multiconference on - ACSW '17. **Anais...**New York, New York, USA: ACM Press, 2017Disponível em: <<http://dl.acm.org/citation.cfm?doid=3014812.3014861>>. Acesso em: 2 maio. 2018

ZAMEER, A. et al. Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks. **Energy Conversion and Management**, v. 134, p. 361–372, 15 fev. 2017.



## ANEXO I

No Anexo I dessa dissertação são trazidas as Tabelas de 25 a 40, que apresentam a média dos índices de desempenho das 20 execuções do processo de treinamento e validação das RNAs. Na coluna “**Número de neurônios**”, deve-se entender que são os números de neurônios nas camadas neurais intermediárias.

**Tabela 23** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Madrugada.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	812,6	11,40	917,7	296,8	4,30	349,5
[8, -]	1678,4	23,58	1909,0	640,8	9,19	752,5
[12, -]	2727,5	38,13	3144,1	978,6	13,98	1156,7
[16, -]	3777,1	52,52	4410,4	1364,9	19,41	1626,2
[20, -]	4824,8	67,06	5625,1	1754,8	24,83	2131,5
[24, -]	6058,3	84,04	7082,6	2253,3	31,73	2767,9
[28, -]	7284,1	100,99	8536,6	2797,0	39,21	3476,0
[4, 8]	850,3	11,83	1010,9	336,7	4,77	387,7
[4, 12]	1857,4	25,52	2297,8	632,6	8,91	764,6
[4, 16]	2883,5	39,62	3565,5	980,8	13,74	1227,0
[4, 20]	3912,8	53,52	4944,2	1415,1	19,56	1842,5
[4, 24]	5553,4	75,38	7197,3	1834,7	25,31	2425,5
[4, 28]	7261,4	98,74	9507,4	2197,2	30,29	2928,0
[8, 12]	8221,3	112,00	10654,8	2503,1	34,61	3290,7
[8, 16]	9225,8	125,80	11897,6	2809,6	38,88	3693,5
[8, 20]	10462,3	142,34	13570,4	3217,5	44,49	4219,2
[8, 24]	11649,6	158,30	15125,9	3677,1	50,75	4850,2
[8, 28]	13034,9	177,31	16911,8	4097,6	56,49	5427,0
[12, 16]	14063,9	191,19	18252,7	4475,4	61,84	5887,2
[12, 20]	15137,0	205,92	19592,3	4864,2	67,27	6378,4
[12, 24]	16340,2	222,28	21135,8	5273,6	72,99	6897,3
[12, 28]	17599,9	239,42	22761,9	5704,7	78,89	7475,6
[16, 20]	18512,8	251,89	23892,8	6093,3	84,22	8000,2
[16, 24]	19570,9	266,25	25256,2	6472,5	89,51	8477,0
[16, 28]	20598,0	280,23	26538,1	6896,7	95,29	9060,8
[20, 24]	21557,7	293,23	27792,3	7358,2	101,65	9640,8
[20, 28]	22719,2	309,00	29261,2	7829,1	108,05	10271,2

**Tabela 24** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Madrugada.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAPE	MAE	MAPE
[4, -]	750,7	10,01	842,8	296,9	3,92	342,6
[8, -]	1750,2	23,31	1979,1	301,2	9,18	860,4
[12, -]	2786,5	37,12	3161,7	1132,6	14,56	1403,9
[16, -]	4112,1	54,74	4637,6	1748,9	22,39	2201,1
[20, -]	5430,8	72,21	6122,8	2606,3	33,44	3198,2
[24, -]	6974,2	92,50	7917,3	3548,9	45,55	4349,9
[28, -]	8338,4	110,44	9492,9	4439,5	57,00	5468,7
[4, 8]	1028,9	13,56	1201,4	657,7	8,46	792,6
[4, 12]	2418,1	31,66	2839,5	1360,1	17,37	1711,3
[4, 16]	3757,0	48,90	4505,2	1940,2	24,76	2471,1
[4, 20]	5170,2	67,29	6228,2	2566,6	32,76	3272,6
[4, 24]	6695,8	87,08	8144,4	3194,5	40,80	4083,4
[4, 28]	8328,8	107,93	10231,5	4059,9	51,80	5230,9
[8, 12]	9467,9	122,77	11577,6	4727,9	60,38	6034,5
[8, 16]	10787,0	139,88	13168,6	5351,0	68,33	6824,5
[8, 20]	12420,4	160,90	15218,6	6105,4	78,00	7753,2
[8, 24]	14097,4	182,61	17241,7	6885,8	88,01	8718,5
[8, 28]	15386,2	199,53	18745,8	7768,9	99,28	9835,3
[12, 16]	16690,9	216,58	20290,8	8433,5	107,78	10666,2
[12, 20]	17957,4	233,03	21878,6	9265,2	118,47	11684,5
[12, 24]	19454,8	252,49	23667,4	9945,3	127,23	12533,3
[12, 28]	21093,2	273,66	25689,2	10944,5	140,07	13758,4
[16, 20]	22533,7	292,38	27416,7	11732,9	150,08	14780,7
[16, 24]	23816,4	308,98	28975,1	12425,1	159,03	15603,2
[16, 28]	25242,5	327,42	30716,6	13422,1	171,74	16846,1
[20, 24]	26526,5	344,02	32306,9	14188,6	181,57	17775,7
[20, 28]	27667,4	358,88	33688,7	15125,5	193,52	18948,3

**Tabela 25** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Manhã.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1210,0	15,38	1304,0	338,5	4,30	383,8
[8, -]	2837,7	36,00	3068,9	689,8	8,67	788,0
[12, -]	4478,7	56,66	4870,0	1140,9	14,25	1313,7
[16, -]	6176,7	78,10	6696,1	1535,1	19,23	1791,0
[20, -]	7973,9	100,74	8667,3	2154,5	27,00	2539,2
[24, -]	10224,2	128,85	11148,6	2679,1	33,65	3152,6
[28, -]	12234,3	154,16	13333,5	3259,6	40,88	3851,5
[4, 8]	1361,7	17,07	1519,9	406,3	5,11	481,1
[4, 12]	2828,4	35,64	3143,6	907,2	11,29	1089,3
[4, 16]	4418,9	55,44	4960,2	1369,2	17,03	1664,6
[4, 20]	6629,7	82,59	7746,0	1805,2	22,49	2174,8
[4, 24]	8969,4	111,27	10572,0	2460,2	30,55	2983,7
[4, 28]	11025,9	136,39	13239,4	2953,9	36,78	3622,0
[8, 12]	12437,6	154,01	14817,6	3470,8	43,20	4249,5
[8, 16]	14349,6	177,72	17038,4	3975,4	49,45	4855,0
[8, 20]	16172,2	200,25	19151,3	4494,5	55,91	5474,4
[8, 24]	18484,8	228,84	21820,4	4932,5	61,36	6002,6
[8, 28]	20653,0	255,67	24254,8	5530,1	68,77	6783,2
[12, 16]	22257,3	275,67	26066,9	6041,2	75,15	7387,1
[12, 20]	23981,0	297,37	27935,1	6602,3	82,23	8093,3
[12, 24]	26251,1	325,28	30637,5	7209,2	89,68	8830,1
[12, 28]	28207,2	349,68	32798,2	7830,4	97,45	9577,4
[16, 20]	29811,2	369,77	34563,3	8403,9	104,57	10272,2
[16, 24]	31601,1	391,90	36607,5	8989,2	111,83	10969,1
[16, 28]	33417,3	414,76	38631,0	9659,8	120,12	11787,9
[20, 24]	34854,3	432,89	40195,8	10463,6	129,99	12804,9
[20, 28]	36533,9	453,78	42103,9	11234,3	139,6	13724,2

**Tabela 26** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Manhã.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1569,7	17,19	1707,8	609,6	6,59	647,0
[8, -]	3379,1	36,65	3710,7	1242,8	13,30	1352,0
[12, -]	5587,1	60,45	6142,5	2204,9	23,60	2394,4
[16, -]	7892,8	85,30	8664,6	453,3	31,80	3246,3
[20, -]	10743,8	116,08	11778,9	3622,3	38,78	3979,7
[24, -]	13430,0	144,97	14741,3	4751,2	50,82	5240,1
[28, -]	16109,8	173,77	17726,0	5893,7	63,00	6487,8
[4, 8]	3080,7	32,27	3821,4	786,1	8,44	891,1
[4, 12]	5051,4	53,51	6115,3	1782,9	19,05	1986,2
[4, 16]	6700,5	71,15	8085,3	2868,4	30,53	3257,5
[4, 20]	9413,9	99,89	11332,6	3839,9	40,89	4388,0
[4, 24]	12386,3	131,28	14964,5	4786,2	51,20	5437,0
[4, 28]	15064,2	159,87	18104,2	5841,5	62,51	6684,1
[8, 12]	16824,4	178,81	20097,0	6762,0	72,27	7737,9
[8, 16]	18605,2	197,97	22107,2	7745,4	82,78	8802,5
[8, 20]	21144,0	224,92	25062,4	8812,3	94,16	10014,2
[8, 24]	23522,9	250,19	27776,9	9814,8	104,80	11148,6
[8, 28]	26132,4	278,19	30693,7	10912,1	116,48	12422,8
[12, 16]	28465,0	303,27	33322,8	11568,9	123,55	13157,3
[12, 20]	30801,0	328,44	35910,7	12317,2	131,50	14046,0
[12, 24]	33012,4	352,17	38453,6	13411,5	143,21	15299,4
[12, 28]	35259,7	376,44	41028,3	14553,2	155,18	16654,1
[16, 20]	37745,0	403,20	43784,7	15575,0	165,95	17866,3
[16, 24]	39876,7	425,88	46263,3	16600,0	176,94	18979,0
[16, 28]	42183,8	450,41	48880,6	17398,5	185,52	19929,9
[20, 24]	44031,3	470,22	50975,3	18345,8	195,60	21036,2
[20, 28]	46269,1	494,01	53589,3	19442,1	207,26	22281,3

**Tabela 27** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Tarde.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1714,8	21,62	1785,8	333,4	4,25	392,2
[8, -]	3465,6	43,76	3607,7	727,8	9,28	839,8
[12, -]	5650,9	71,56	5904,5	1235,1	15,87	1399,1
[16, -]	8439,0	107,21	8766,8	1750,8	22,46	1989,3
[20, -]	11353,9	144,56	11774,8	2612,6	33,49	2944,5
[24, -]	14472,5	184,28	15029,4	3384,9	43,44	3802,2
[28, -]	18281,2	233,28	18975,9	4451,5	57,11	4986,2
[4, 8]	1377,4	17,09	1600,6	427,8	5,42	497,8
[4, 12]	3239,9	40,85	3644,9	981,4	12,46	1144,5
[4, 16]	4893,8	61,65	5549,9	1517,4	19,15	1788,0
[4, 20]	7267,7	91,83	8401,4	2143,0	27,02	2537,2
[4, 24]	9696,2	122,57	11052,8	3016,4	38,30	3587,1
[4, 28]	12067,4	152,61	13647,5	3758,6	47,84	4440,7
[8, 12]	13934,4	176,27	15623,9	4172,9	53,10	4927,3
[8, 16]	15616,0	197,41	17490,0	4930,0	62,77	5788,9
[8, 20]	17704,2	223,70	19758,5	5800,4	73,93	6744,3
[8, 24]	19919,1	251,75	22134,4	6893,8	88,06	7978,6
[8, 28]	22232,4	281,17	24581,7	7604,0	97,14	8844,1
[12, 16]	24366,0	308,23	26828,0	8268,0	105,67	9602,1
[12, 20]	26347,8	333,22	28969,2	8803,7	112,47	10221,8
[12, 24]	28404,2	359,31	31208,1	9464,3	120,96	10975,4
[12, 28]	30760,2	389,31	33716,7	10288,1	131,59	11901,7
[16, 20]	32569,9	412,19	35641,5	10971,5	140,36	12656,5
[16, 24]	34748,0	439,82	37950,8	11763,8	150,54	13564,4
[16, 28]	37011,9	468,56	40349,9	12400,6	158,68	14306,5
[20, 24]	39051,1	494,61	42489,8	13116,8	167,96	15138,6
[20, 28]	41596,9	527,25	45144,6	14131,8	181,08	16287,1

**Tabela 28** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Tarde.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1337,6	15,56	1461,7	535,1	6,33	582,1
[8, -]	3126,1	36,33	3374,3	1018,8	12,04	1122,5
[12, -]	5325,2	62,17	5650,0	1634,8	19,42	1818,8
[16, -]	7709,7	90,11	8106,4	2265,4	26,94	2518,8
[20, -]	10490,4	122,73	10955,5	2830,0	33,65	3172,8
[24, -]	13270,8	155,37	13848,2	3715,2	44,27	4179,7
[28, -]	15828,3	185,42	16504,9	4657,4	55,62	5280,2
[4, 8]	1175,6	13,48	1327,4	505,6	5,91	572,6
[4, 12]	2953,6	34,02	3326,8	996,6	11,62	1122,9
[4, 16]	5174,5	59,99	5755,6	1725,4	20,24	1947,8
[4, 20]	7762,1	90,11	8638,4	2404,3	28,27	2735,6
[4, 24]	9846,0	114,25	11036,2	3152,5	37,14	3593,2
[4, 28]	11887,0	137,89	13408,6	3868,1	45,64	4440,5
[8, 12]	13338,6	154,63	14969,7	4394,4	51,82	5034,8
[8, 16]	14947,0	173,35	16766,7	5017,8	59,18	5733,1
[8, 20]	16838,2	195,35	18835,7	5673,6	66,99	6461,2
[8, 24]	18893,9	219,13	21222,1	6370,0	75,32	7258,4
[8, 28]	20855,3	241,82	23460,4	7072,4	83,68	8096,6
[12, 16]	22393,4	259,78	25107,4	7800,3	92,30	8896,9
[12, 20]	23944,4	277,65	26881,8	8586,6	101,73	9785,2
[12, 24]	25897,2	300,09	29072,7	9470,2	112,32	10787,6
[12, 28]	28263,2	327,71	31625,1	10393,1	123,37	11852,1
[16, 20]	29741,3	344,87	33256,0	11195,3	132,99	12763,0
[16, 24]	31582,6	366,38	35237,0	11818,5	140,43	13502,7
[16, 28]	33658,1	390,68	37483,3	12610,4	149,85	14437,9
[20, 24]	35474,8	411,81	39486,7	13554,6	161,13	15523,7
[20, 28]	37427,5	434,61	41614,4	14635,9	174,09	16737,0

**Tabela 29** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Noite.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1439,8	15,81	1530,1	1008,1	11,23	1055,9
[8, -]	3331,6	36,62	3531,7	2005,4	22,16	2112,9
[12, -]	5264,2	57,69	5667,6	3299,4	36,54	3470,5
[16, -]	7758,6	85,02	8328,0	4416,9	48,97	4667,8
[20, -]	10483,6	115,03	11230,9	5244,0	58,18	5588,1
[24, -]	13400,3	147,06	14293,3	7048,7	78,48	7527,6
[28, -]	16518,5	180,84	17713,7	8654,1	96,47	9280,4
[4, 8]	1486,4	16,37	1604,5	1047,9	11,68	1122,4
[4, 12]	3450,7	37,58	3869,1	2027,2	22,67	2226,5
[4, 16]	5560,8	60,36	6271,6	3380,6	37,69	3677,4
[4, 20]	8065,8	87,86	9082,6	4368,4	48,67	4798,3
[4, 24]	10952,6	118,44	12536,5	5719,6	63,80	6300,3
[4, 28]	13113,4	142,32	14985,3	7196,9	80,10	8088,4
[8, 12]	14865,6	161,39	16925,7	8251,2	91,84	9225,3
[8, 16]	16776,3	182,12	19042,5	9322,4	103,70	10422,4
[8, 20]	19162,4	207,93	21687,1	10386,8	115,45	11595,9
[8, 24]	21432,7	232,54	24209,7	11728,7	130,36	13059,5
[8, 28]	24441,1	265,22	27609,7	13604,6	151,31	15149,6
[12, 16]	26405,2	286,57	29779,3	14738,7	163,88	16382,5
[12, 20]	28585,2	310,18	32208,1	15805,4	175,71	17555,8
[12, 24]	31054,7	336,66	34983,6	17279,7	192,18	19170,4
[12, 28]	33368,3	361,83	37562,8	18630,9	207,07	20669,5
[16, 20]	35243,4	382,18	39610,6	19810,2	219,84	21964,0
[16, 24]	37793,4	409,71	42383,4	21487,7	238,46	23770,4
[16, 28]	40008,2	433,67	44826,9	22955,6	254,74	25382,3
[20, 24]	42075,4	456,20	47078,1	24165,5	268,09	26699,5
[20, 28]	44074,9	477,94	49305,1	25483,2	282,72	28161,3

**Tabela 30** - Média dos índices de desempenho de 20 execuções de previsão de demanda de eletricidade da região de NSW com dados de dias úteis - Período da Noite.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	1529,5	15,60	1617,5	614,7	6,16	673,9
[8, -]	3399,6	34,42	3671,1	1236,2	12,36	1382,4
[12, -]	5412,0	54,77	5829,3	2083,9	20,67	2382,4
[16, -]	7736,4	78,32	8391,9	2924,6	28,87	3394,1
[20, -]	10845,9	109,66	11744,4	3449,0	34,05	4011,8
[24, -]	14524,8	146,64	15706,6	4350,8	42,91	5111,3
[28, -]	17587,1	177,63	18966,5	5278,7	52,03	6222,1
[4, 8]	2084,2	20,89	2352,7	764,1	7,58	832,9
[4, 12]	4001,2	40,03	4505,9	1471,0	14,63	1672,4
[4, 16]	7483,6	74,53	8432,1	2279,8	22,68	2580,6
[4, 20]	9796,5	97,76	11148,7	3211,1	31,89	3672,7
[4, 24]	13584,2	134,90	15717,7	4396,3	43,50	5065,2
[4, 28]	16956,0	168,40	19653,1	5452,5	53,88	6390,7
[8, 12]	18719,9	186,11	21655,7	6098,3	60,30	7133,7
[8, 16]	20789,7	206,81	24003,6	6749,6	66,84	7892,0
[8, 20]	23212,1	230,95	26815,0	7846,9	77,79	9138,4
[8, 24]	25754,8	256,52	29611,9	8613,2	85,38	10035,9
[8, 28]	28334,3	281,85	32663,9	9623,8	95,38	11257,1
[12, 16]	30527,9	303,70	35078,2	10300,7	102,10	12052,5
[12, 20]	33794,5	335,95	38777,0	11283,3	111,68	13236,9
[12, 24]	35606,4	354,08	40871,9	11920,7	117,95	14030,1
[12, 28]	37666,4	374,78	43229,7	13046,9	129,15	15292,0
[16, 20]	39844,4	396,62	45632,8	13590,8	134,51	15942,8
[16, 24]	42310,6	421,13	48413,2	14245,4	141,00	16721,7
[16, 28]	44622,1	444,33	51058,8	15103,3	149,40	17770,4
[20, 24]	46964,0	467,64	53727,8	15752,5	155,77	18579,0
[20, 28]	49991,5	497,76	57125,4	16828,0	166,32	19860,1

**Tabela 31** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Madrugada.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	26,0	44,12	27,0	8,6	14,08	10,4
[8, -]	50,3	84,60	53,2	17,8	28,97	21,1
[12, -]	72,7	121,70	77,8	28,8	46,36	34,9
[16, -]	98,5	165,46	106,1	45,9	72,72	56,7
[20, -]	124,4	208,67	135,2	60,5	94,99	76,9
[24, -]	148,4	248,61	162,1	75,8	118,29	97,6
[28, -]	179,6	300,67	196,8	91,8	142,94	119,6
[4, 8]	24,7	3614,6	39,1	8,6	13,30	11,3
[4, 12]	47,8	4495,7	75,9	15,9	24,22	22,9
[4, 16]	74,9	5745,2	119,0	24,9	37,70	36,2
[4, 20]	103,9	7924,0	165,8	35,8	53,96	51,9
[4, 24]	130,7	9952,8	208,5	48,4	73,00	69,2
[4, 28]	155,1	11440,6	245,5	58,3	87,87	83,6
[8, 12]	184,8	12763,3	295,7	66,3	100,49	94,7
[8, 16]	209,0	13769,5	335,9	74,5	113,45	106,2
[8, 20]	235,6	14990,7	379,0	85,6	130,47	122,1
[8, 24]	260,2	16148,3	419,5	94,8	144,78	136,6
[8, 28]	282,9	17286,5	455,1	107,4	163,69	154,5
[12, 16]	309,0	18212,4	497,1	117,5	178,94	168,3
[12, 20]	334,7	19206,9	539,9	129,2	196,71	185,6
[12, 24]	360,7	20359,5	581,6	142,0	216,26	203,0
[12, 28]	386,5	21520,6	623,9	157,6	240,12	223,1
[16, 20]	407,0	22185,7	657,6	170,0	259,39	239,8
[16, 24]	430,0	22954,3	695,2	184,7	281,98	259,0
[16, 28]	455,2	23855,4	737,2	198,6	303,32	277,6
[20, 24]	480,4	24668,0	1603,0	210,1	321,59	293,0
[20, 28]	508,7	26162,0	1650,3	225,4	345,04	313,3

**Tabela 32** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Madrugada.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	39,9	65,35	40,5	13,0	20,68	13,5
[8, -]	71,5	117,94	72,8	21,5	34,12	22,7
[12, -]	112,0	184,99	114,0	32,4	51,11	35,0
[16, -]	157,4	260,64	160,3	43,8	69,17	47,9
[20, -]	194,6	322,92	199,0	59,0	93,57	65,2
[24, -]	234,3	388,61	240,3	75,8	120,10	84,4
[28, -]	271,0	449,60	278,4	93,3	147,41	104,5
[4, 8]	37,9	2992,90	61,8	10,7	16,72	12,1
[4, 12]	77,6	6108,51	126,6	22,9	35,92	25,8
[4, 16]	116,6	10014,39	189,9	35,3	55,68	39,6
[4, 20]	156,0	16369,13	253,3	50,5	79,40	56,6
[4, 24]	200,0	21644,16	324,3	67,6	106,62	75,5
[4, 28]	231,6	23799,76	375,0	81,1	128,09	90,5
[8, 12]	263,6	25046,76	427,1	92,3	146,01	103,0
[8, 16]	304,2	27499,52	494,1	105,0	166,26	116,8
[8, 20]	346,9	30339,15	564,3	122,3	193,85	135,6
[8, 24]	381,3	32112,38	620,5	137,2	217,39	152,3
[8, 28]	423,8	35281,34	690,2	154,0	244,37	170,8
[12, 16]	465,1	38735,23	758,6	164,7	261,11	183,3
[12, 20]	504,4	41406,00	822,8	173,2	274,48	193,7
[12, 24]	535,1	42692,67	873,1	187,4	297,33	209,6
[12, 28]	571,9	44587,53	933,1	199,3	315,95	223,4
[16, 20]	605,9	46256,96	989,1	211,4	335,25	237,4
[16, 24]	642,4	48384,49	1049,1	226,4	358,95	254,6
[16, 28]	678,8	50309,57	1109,8	246,9	392,28	276,9
[20, 24]	720,3	51060,29	2109,3	258,8	411,52	290,7
[20, 28]	759,1	53457,26	2173,9	273,4	434,85	307,2

**Tabela 33** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Manhã.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	40,1	54,65	43,4	18,3	23,3	22,9
[8, -]	94,9	132,30	101,6	36,7	47,0	45,8
[12, -]	157,4	219,41	169,4	62,7	80,2	77,5
[16, -]	210,4	294,17	228,3	86,8	110,7	110,5
[20, -]	264,5	368,89	290,3	126,2	160,1	163,1
[24, -]	328,9	459,90	363,0	163,2	206,1	215,7
[28, -]	390,5	547,81	431,2	227,5	289,5	293,7
[4, 8]	52,6	6047,17	73,1	24,4	30,97	31,6
[4, 12]	99,6	10147,16	136,5	50,5	63,74	64,5
[4, 16]	152,0	15552,23	205,8	79,3	100,58	102,0
[4, 20]	208,0	21825,41	281,6	106,1	133,46	141,9
[4, 24]	279,6	34533,61	380,5	137,5	173,73	181,8
[4, 28]	340,8	42135,67	462,2	175,9	223,69	229,5
[8, 12]	392,9	50533,45	530,4	198,7	251,63	261,7
[8, 16]	445,6	55939,85	601,1	230,6	291,06	304,7
[8, 20]	494,4	59946,33	665,5	262,4	329,28	351,1
[8, 24]	539,1	63715,56	724,7	293,4	368,37	395,5
[8, 28]	592,5	70274,63	794,6	327,6	412,35	441,7
[12, 16]	644,6	74987,11	866,7	356,8	448,67	482,1
[12, 20]	704,0	80978,17	950,2	388,1	488,55	523,6
[12, 24]	752,5	84917,70	1015,5	416,5	524,04	562,2
[12, 28]	828,9	94879,19	1121,5	445,0	558,76	605,5
[16, 20]	879,6	99365,18	1190,4	477,0	597,32	649,6
[16, 24]	936,8	105247,9	1270,3	511,3	637,03	700,5
[16, 28]	996,0	111413,	1352,0	546,2	681,57	746,8
[20, 24]	1054,8	112623,3	2979,7	585,2	732,35	793,8
[20, 28]	1124,5	121343,7	3078,1	620,1	778,00	839,9

**Tabela 34** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Manhã.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	81,9	83,9	95,9	81,9	83,9	95,9
[8, -]	180,8	192,8	205,6	180,8	192,8	205,6
[12, -]	354,3	383,1	389,3	354,3	383,1	389,3
[16, -]	527,9	575,3	572,5	527,9	575,3	572,5
[20, -]	788,5	873,5	838,6	788,5	873,5	838,6
[24, -]	1121,0	1252,4	1176,1	1121,0	1252,4	1176,1
[28, -]	1438,5	1616,3	1497,9	1438,5	1616,3	1497,9
[4, 8]	167,7	121209	188,5	51,14	52,72	64,65
[4, 12]	230,5	128908	249,6	108,25	110,32	135,27
[4, 16]	346,8	164257	350,6	176,03	180,63	216,06
[4, 20]	463,0	223044	497,9	248,78	252,48	304,52
[4, 24]	597,6	287661	644,0	356,40	367,46	424,46
[4, 28]	743,5	364053	804,2	439,73	455,32	519,90
[8, 12]	819,4	376947	882,8	505,30	520,93	594,28
[8, 16]	950,5	419405	1026,2	571,77	594,99	671,94
[8, 20]	1116,0	487941	1209,7	660,40	692,04	770,92
[8, 24]	1292,1	558574	1403,6	745,41	782,50	869,66
[8, 28]	1595,8	974407	1745,9	828,78	874,09	961,86
[12, 16]	1793,3	1049115	1973,8	910,61	958,47	1056,72
[12, 20]	2040,7	1466221	2250,6	1009,25	1070,40	1162,38
[12, 24]	2284,9	1622859	2529,6	1093,59	1165,37	1254,80
[12, 28]	2548,4	1814846	2829,9	1219,52	1308,81	1389,12
[16, 20]	2789,4	1964922	3105,4	1314,74	1415,44	1491,57
[16, 24]	3015,4	2108239	3363,6	1411,61	1522,88	1596,19
[16, 28]	3289,1	2307449	3675,8	1513,29	1637,23	1705,24
[20, 24]	3532,0	2309019	5485,1	1616,55	1753,10	1815,71
[20, 28]	3796,0	2540079	5787,9	1738,71	1893,11	1944,93

**Tabela 35** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Tarde.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	81,9	83,9	95,9	81,9	83,9	95,9
[8, -]	180,8	192,8	205,6	180,8	192,8	205,6
[12, -]	354,3	383,1	389,3	354,3	383,1	389,3
[16, -]	527,9	575,3	572,5	527,9	575,3	572,5
[20, -]	788,5	873,5	838,6	788,5	873,5	838,6
[24, -]	1121,0	1252,4	1176,1	1121,0	1252,4	1176,1
[28, -]	1438,5	1616,3	1497,9	1438,5	1616,3	1497,9
[4, 8]	167,7	121209	188,5	111,55	175,35	114,98
[4, 12]	230,5	128908	249,6	210,78	332,05	217,91
[4, 16]	346,8	164257	350,6	340,94	538,89	353,45
[4, 20]	463,0	223044	497,9	466,60	735,89	483,47
[4, 24]	597,6	287661	644,0	612,47	961,26	635,51
[4, 28]	743,5	364053	804,2	757,51	1187,82	787,44
[8, 12]	819,4	376947	882,8	858,70	1345,83	891,62
[8, 16]	950,5	419405	1026,2	984,41	1547,61	1021,19
[8, 20]	1116,0	487941	1209,7	1123,60	1766,58	1163,50
[8, 24]	1292,1	558574	1403,6	1279,17	2012,26	1323,14
[8, 28]	1595,8	974407	1745,9	1450,32	2279,52	1498,00
[12, 16]	1793,3	1049115	1973,8	1567,44	2464,97	1617,60
[12, 20]	2040,7	1466221	2250,6	1696,76	2663,49	1751,18
[12, 24]	2284,9	1622859	2529,6	1823,20	2865,67	1881,37
[12, 28]	2548,4	1814846	2829,9	1987,92	3127,29	2052,79
[16, 20]	2789,4	1964922	3105,4	2119,92	3334,09	2189,48
[16, 24]	3015,4	2108239	3363,6	2257,68	3549,97	2331,17
[16, 28]	3289,1	2307449	3675,8	2392,71	3762,00	2470,24
[20, 24]	3532,0	2309019	5485,1	2509,87	3947,61	2591,68
[20, 28]	3796,0	2540079	5787,9	2684,72	4220,44	2771,59

**Tabela 36** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Tarde.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	237,96	329,33	241,81	128,2	178,90	131,7
[8, -]	748,43	1044,02	753,99	345,2	481,36	351,9
[12, -]	1378,11	1927,02	1384,83	835,9	1171,71	844,3
[16, -]	2109,78	2952,46	2117,75	1476,5	2071,83	1485,7
[20, -]	3525,94	4938,79	3534,55	2197,2	3086,31	2207,5
[24, -]	4931,75	6912,85	4941,15	3303,2	4641,34	3314,1
[28, -]	7337,17	10289,85	7347,27	4362,2	6128,93	4374,8
[4, 8]	261,22	377387	362,68	173,9	244,44	176,3
[4, 12]	1046,12	4347717	1462,28	609,3	855,46	613,3
[4, 16]	2300,27	11782452	3220,27	840,8	1178,88	847,3
[4, 20]	3296,24	17184414	4616,48	1450,7	2037,16	1458,9
[4, 24]	3628,94	17950173	5079,64	2000,9	2811,66	2010,6
[4, 28]	4601,18	23256579	6442,30	2494,1	3504,85	2505,8
[8, 12]	5224,64	24232185	7316,87	2837,6	3987,00	2851,5
[8, 16]	5736,09	25228468	8033,99	3247,1	4562,77	3262,9
[8, 20]	6757,58	29568130	9466,14	3709,3	5212,33	3727,4
[8, 24]	8222,90	36805988	11521,20	4167,3	5857,25	4188,1
[8, 28]	9266,42	39823271	12985,07	4707,7	6618,89	4729,93
[12, 16]	10094,32	41645711	14145,54	5077,2	7136,74	5101,1
[12, 20]	11137,64	45494166	15611,40	5547,3	7796,93	5573,9
[12, 24]	12663,95	53476396	17752,38	6170,8	8671,79	6198,8
[12, 28]	14117,41	58979961	19791,37	6915,9	9721,23	6945,1
[16, 20]	14792,90	60564071	20739,26	7531,7	10585,61	7562,5
[16, 24]	15374,12	61277736	21555,49	8203,8	11531,18	8235,9
[16, 28]	17244,54	74452527	24180,17	9016,2	12673,35	9049,2
[20, 24]	18215,28	74453865	25968,66	9857,5	13861,31	9891,7
[20, 28]	20409,86	89641701	29050,23	10715,2	15067,54	10750,5

**Tabela 37** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de finais de semana e feriados - Período da Noite.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	69,70	74,28	72,15	33,16	31,66	40,08
[8, -]	143,68	153,77	151,39	72,62	70,05	87,32
[12, -]	224,51	241,33	237,13	105,51	100,89	133,62
[16, -]	328,63	354,51	349,68	148,22	141,77	190,72
[20, -]	435,21	468,18	465,30	209,21	201,15	265,21
[24, -]	539,39	578,54	578,09	263,73	252,11	341,22
[28, -]	664,32	711,64	715,20	339,31	326,73	429,95
[4, 8]	58,13	5656	60,96	37,32	36,32	46,26
[4, 12]	120,68	12565	124,51	83,30	81,02	104,12
[4, 16]	185,28	20568	190,46	120,48	116,45	153,10
[4, 20]	277,75	39668	283,85	160,44	153,39	210,36
[4, 24]	367,31	84741	372,66	221,98	210,94	292,42
[4, 28]	468,55	115765	478,13	297,88	284,56	389,05
[8, 12]	536,75	123664	550,24	344,10	330,15	443,27
[8, 16]	617,35	135750	635,21	389,89	374,86	500,25
[8, 20]	714,22	153174	740,50	446,64	430,42	571,29
[8, 24]	789,64	162294	819,45	510,12	491,92	650,29
[8, 28]	876,87	175224	910,92	586,91	565,47	745,02
[12, 16]	962,73	186690	1002,99	631,91	609,31	805,67
[12, 20]	1028,29	194375	1071,34	693,06	668,99	880,10
[12, 24]	1105,92	206962	1152,77	759,73	732,97	962,30
[12, 28]	1200,71	222362	1253,64	817,30	789,21	1033,48
[16, 20]	1283,78	235870	1341,98	876,61	847,32	1107,34
[16, 24]	1371,05	250964	1434,17	917,37	884,41	1170,68
[16, 28]	1450,80	261937	1519,23	976,72	941,59	1246,11
[20, 24]	1537,48	263377	3411,04	1037,67	1002,35	1318,15
[20, 28]	1610,79	271740	3488,37	1086,77	1049,77	1381,76

**Tabela 38** - Média dos índices de desempenho de 20 execuções de previsão de preço de eletricidade da região de NSW com dados de dias úteis - Período da Noite.

Número de neurônios	Sem seleção de atributos			Com seleção de atributos		
	MAE	MAPE	RMSE	MAE	MAPE	RMSE
[4, -]	233,32	221,37	243,92	112,95	108,75	124,96
[8, -]	775,17	752,08	792,41	375,65	361,35	397,16
[12, -]	1959,05	1909,94	1979,96	639,14	619,21	671,20
[16, -]	3519,96	3434,07	3543,21	917,52	889,24	962,98
[20, -]	6552,18	6401,69	6577,43	1268,60	1229,83	1321,58
[24, -]	8811,78	8614,61	8839,75	1687,34	1641,65	1752,64
[28, -]	11953,01	11692,64	11983,69	2285,07	2228,45	2359,95
[4, 8]	733,03	2932717	711,26	180,65	173,3	192,61
[4, 12]	1350,25	4746541	1309,30	377,20	365,4	402,18
[4, 16]	1761,80	5957649	1704,67	502,89	482,6	541,52
[4, 20]	2545,78	8434214	2467,99	750,42	722,6	798,68
[4, 24]	3466,76	11699627	3368,29	995,93	957,7	1055,92
[4, 28]	5301,27	27542034	5155,55	1212,74	1167,1	1284,96
[8, 12]	6438,98	30792411	6271,18	1509,85	1449,6	1592,88
[8, 16]	7179,37	32194157	6995,82	1693,60	1624,5	1790,98
[8, 20]	8220,33	36798841	8012,12	1994,20	1914,4	2103,62
[8, 24]	9790,84	46333258	9550,44	2282,43	2194,4	2402,87
[8, 28]	11234,63	53468720	10962,28	2678,49	2577,9	2808,77
[12, 16]	12823,30	59380348	12520,83	2973,95	2868,5	3111,35
[12, 20]	13901,26	63050260	13573,19	3294,44	3184,9	3441,05
[12, 24]	15749,51	72148535	15381,58	3679,06	3560,9	3830,32
[12, 28]	17547,02	78890468	17144,86	4060,37	3930,4	4221,92
[16, 20]	18976,16	85018364	18542,20	4355,71	4216,7	4525,37
[16, 24]	20469,04	89861305	20007,11	4742,29	4598,8	4918,01
[16, 28]	22567,49	10030886	22064,09	5333,33	5181,1	5517,27
[20, 24]	24494,80	10031039	23934,25	5794,84	5629,1	5983,61
[20, 28]	25728,97	10496719	25144,10	6251,92	6079,8	6448,24