

# Redes Neurais Artificiais Aplicadas à Previsão de Demanda de Energia Elétrica no Horizonte de Curtíssimo Prazo para Cidades Inteligentes

Leonel A. Laboissiere

Programa de Pós-Graduação em Engenharia Urbana  
Universidade Federal de São Carlos  
São Carlos, Brasil  
leonel.laboissiere@gmail.com

Ricardo A. S. Fernandes

Programa de Pós-Graduação em Engenharia Urbana  
Universidade Federal de São Carlos  
São Carlos, Brasil  
ricardo.asf@ufscar.br

**Resumo**— Esta pesquisa apresenta uma metodologia baseada em Redes Neurais Artificiais para a previsão de demanda de energia elétrica, considerando o horizonte de curtíssimo prazo. Assim, tal previsão pode ser empregada para aprimorar o planejamento e operação de *Smart Grids* e, conseqüentemente, garantir maior eficiência no uso dos recursos energéticos de cidades inteligentes. A previsão da demanda é de fundamental importância tanto aos produtores de energia elétrica (seja por fontes hídricas, térmicas e/ou renováveis) como também aos comercializadores de energia. Com base na premissa de que a energia elétrica é comercializada como uma *commodity*, este artigo busca empregar a Média Móvel Ponderada (WMA, do inglês *Weighted Moving Average*) para identificar tendências quanto ao uso da energia elétrica. Para avaliar essa proposta, empregou-se uma base de dados proveniente do estado australiano de *New South Wales*. Assim, a WMA foi calculada para as séries temporais de demanda, preço da energia e variáveis climatológicas. Os atributos obtidos do cálculo da WMA foram selecionados por meio do algoritmo *Correlation-based Feature Selection* (CFS), com o intuito de determinar as variáveis de maior relevância à previsão da demanda no horizonte de curtíssimo prazo. Na sequência, foram treinadas e validadas Redes Neurais Artificiais com arquitetura *feedforward*, do tipo *Multilayer Perceptron*. Os resultados obtidos mostraram a eficácia do modelo neural, com Erros Médios Absolutos Percentuais entre 0,2% e 1,2%.

**Palavras-chaves**— *Redes neurais artificiais, previsão de séries temporais, mercado de energia, previsão de demanda.*

## I. 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 [1]. Além disso, projeta-se que, em 2050, 70% da população mundial viverá em regiões urbanas [2].

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

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil Código de Financiamento 001.

das cidades ocuparem menos de 2% 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 [3].

Segundo [1], 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 [2]. A utilização das TIC nas cidades é impulsionada pela busca por uma melhor gestão dos problemas decorrentes da expansão urbana, sendo este novo conceito denominado de Cidade Inteligente (do 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 [4].

No contexto das Cidades Inteligentes, um recurso fundamental é a energia elétrica, a qual deve ser confiável e com preço acessível a seus habitantes [5]. Nota-se ainda que o sétimo objetivo da Agenda 2030 [6] foi criado com o intuito de garantir o acesso à energia elétrica, a sustentabilidade energética e a modernização dos sistemas elétricos. Portanto, a Agenda 2030 prevê o conceito de *Smart Grids* inserido no contexto das Cidades Inteligentes. Assim, deverá haver uma integração de consumidores, geradores e os chamados *prosumers* (que são produtores e consumidores de energia elétrica) [2]. 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 eficiência do sistema [7]. 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 [8], a nível mundial, setores de geração e comercialização de energia elétrica 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 da energia elétrica aos consumidores a preços razoáveis [9]. Acrescenta-se que, aos agentes de mercados de energia modernos, a previsão da demanda é crucial para otimizar o gerenciamento energético de forma sustentável [8].

O artigo é organizado de modo que na Seção II é apresentada uma breve revisão da literatura correlata, com enfoque nas pesquisas que fazem uso de dados do mercado de energia australiano. Na Seção **Erro! Fonte de referência não encontrada.** é mostrado um panorama geral do mercado de energia australiano. A metodologia proposta é apresentada em maiores detalhes na Seção **Erro! Fonte de referência não encontrada.** Por fim, as Seções V e VI são destinadas a apresentar respectivamente os resultados obtidos e as conclusões.

## II. 2,REVISÃO BIBLIOGRÁFICA

A previsão da demanda de energia elétrica é a medida da exatidão da diferença entre os valores atual e previsto de uma futura demanda [10]. Tal medida é provavelmente o tópico mais importante para o planejamento de sistemas elétricos de potência [11], pois auxilia no gerenciamento sustentável do processo de geração, transmissão, distribuição e consumo da energia elétrica [12].

Métodos de previsão robustos são fundamentais para uma eficiente operação de um sistema de potência moderno (*smart grid*), os quais são influenciados pelo clima. Perante as incertezas climatológicas, modelos de previsão baseados em sistemas inteligentes podem desempenhar funções vitais para despacho econômico e um fluxo de potência (planejamento) em *smart grids* e/ou mercados de comercialização de energia.

A inserção 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 [13], um modelo baseado em Redes Neurais Artificiais (RNA) com arquitetura *feedforward* foi empregada à previsão de curto prazo da demanda de *New South Wales*. Em comparação com resultados de métodos clássicos (suavização exponencial e ARIMA), a metodologia proposta foi capaz de obter considerável melhora, com Erros Médios Absolutos Percentuais (MAPE) em torno de 2,14% e 2,15.

Uma combinação de modelos (SARIMA-ARIMA Sazonal, HWT-Holt-Winters, RNA do tipo *Multilayer Perceptron* (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 [12].

Em [14], 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 a um sistema híbrido baseado em GRNN (*Generalized Regression Neural Network*) e SVR (*Support Vector Regression*). O modelo híbrido foi responsável pela previsão da demanda de energia das regiões australianas de *New South Wales* e *Victoria*, obtendo MAPE inferiores a 1,2%.

Por fim, em [15], 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. Foram utilizados os 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%.

## III. MERCADO DE ENERGIA AUSTRALIANO

Mercados de energia são elaborados para fornecer eletricidade com confiabilidade a um baixo custo aos consumidores. Tradicionalmente, concessionárias de energia elétrica são baseadas em sistemas de tarifa fixa [5]. Consequentemente, o consumidor é tarifado com preços de energia elétrica que não refletem as oscilações da demanda [16].

Porém, os mercados de energia estão em um processo de mercado não regulado, pois o sistema de tarifa fixa e regulamentado é considerado uma limitação para a otimização do sistema elétrico de potência [8]. A adoção de novas estruturas de preço acarreta em modificações no mercado de energia, tornando-o competitivo. Em um mercado de energia competitivo, vários produtores competem entre si para vender a energia elétrica diretamente aos consumidores, permitindo que estes negociem contratos com agentes comercializadores, além de ter um mercado *spot*, que reflete a demanda de energia e o custo de sua produção [16].

No contexto de mercados *spot*, os produtores e comercializadores de energia elétrica competem entre si, tal que suas tomadas de decisão podem gerar ganhos ou perdas financeiras. Portanto, ferramentas que auxiliem nas suas operações são de extrema importância. Tais ferramentas podem ser baseadas em técnicas de aprendizado de máquina, tais como as Redes Neurais Artificiais.

O Mercado Nacional de Eletricidade da Austrália (MNEA) é composto por cinco estados que estão interligados e são regiões de preços denominadas por: *New South Wales*, *Queensland*, *South Australia*, *Victoria* e *Tasmania*. Há mais de 300 participantes registrados no MNEA, incluindo produtores de energia, agentes de transmissão e distribuição de energia elétrica, comercializadores e consumidores residenciais e industriais [17].

A operação de MNEA iniciou-se em Dezembro 1988, porém, a *Tasmania* uniu-se ao MNEA em 2005. Desde então, fornece aproximadamente 200 TWh a cada ano. No ano financeiro de 2016/2017, o MNEA comercializou AU\$16,6 bilhões [17]. Ressalta-se que o estado de *New South Wales* é o maior consumidor e representa quase 40% do MNEA.

O MNEA possui dois ambientes de comercialização, a saber: varejista e atacadista. Os produtores competem entre si para vender sua geração aos comercializadores que a revendem aos consumidores finais no mercado varejista [18]. Assim, a demanda e o fornecimento são simultaneamente balanceados por meio de um processo de despacho feito pelo Operador de Mercado de Energia Australiano (AEMO, do inglês *Australian Energy Market Operator*) [17].

No mercado varejista, o preço *spot* é estabelecido a cada meia hora para cada das cinco regiões do MNEA [17]. O AEMO usa o preço *spot* para estabelecer as transações financeiras para liquidar as transações financeiras estabelecidas no MNEA [17]. Ademais, produtores cuja oferta é aceita são pagos pelo valor do preço *spot*, independente do valor que ofereceram.

Produtores e comercializadores ao firmarem seus contratos, determinam a quantidade de energia contratada. Neste sentido, para tais agentes é importante realizar uma melhor tomada de decisões em suas operações de curto prazo.

#### IV. METODOLOGIA PROPOSTA À PREVISÃO DA DEMANDA DE ENERGIA ELÉTRICA AO MERCADO AUSTRALIANO

A metodologia proposta consiste de quatro etapas, sumarizadas na Fig. 1. A primeira etapa representa a coleta dos dados históricos de demanda, preço e clima da região de *New South Wales*. Já a segunda e terceira etapas representam respectivamente o pré-processamento dos dados e a seleção dos atributos considerados mais relevantes à previsão da demanda. Na sequência, a quarta etapa denota o próprio modelo neural de predição.

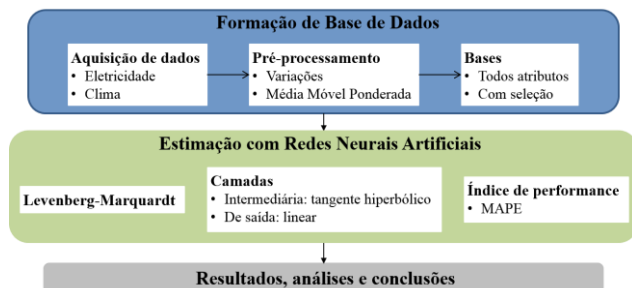


Fig 1. Diagrama de blocos representativo da metodologia proposta.

##### A. Coleta de Dados

Dados sobre demanda (em MW) e preço (AU\$/MWh) são obtidos pelo *website* da AEMO. Já os dados climáticos foram adquiridos do *website* do Departamento Meteorológico Australiano.

O AEMO disponibiliza os dados com frequência de meia hora. Portanto, tem um total de 48 amostras de preço e demanda de energia elétrica para um mesmo dia. Contudo, os dados climatológicos possuem frequência diária, obtidos das estações identificadas por #61055, #61390, #66037 e #66062.

Com base nas fontes de dados e suas respectivas discretizações temporais, formou-se a base de dados. Posteriormente, esta base foi dividida em quatro subconjuntos, de acordo com os seguintes intervalos de tempo: (i) de 00h00 até 05h30; (ii) de 06h00 até 11h30; (iii) de 12h00 até 17h30; e

(iv) de 18h00 até 23h30. Ressalta-se que o histórico de dados considerado é iniciado em 01/01/2013 e encerrado em 31/12/2017.

##### B. Pré-processamento dos Dados

A Tabela I sumariza todos os possíveis dados obtidos com a etapa de pré-processamento, onde  $t$  é a hora atual e  $t+1$  é demanda a ser prevista com 30 minutos a frente. Com base nos dados previamente obtidos, foi possível calcular as variações diária ( $V_{RD}$ ), semanal ( $V_{RS}$ ) e anual ( $V_{RA}$ ) da demanda e do preço. Deve-se compreender de  $V_{RD}$  a diferença entre os valores dos instantes de tempo  $t$  e  $t-48$ ,  $V_{RS}$  a diferença entre os valores dos instantes de tempo  $t$  e  $t-366$  e  $V_{RA}$  é a diferença para os valores entre  $t$  e  $t-17472$ .

Ainda foi calculada a Média Móvel Ponderada (WMA, do inglês *Weighted Moving Average*), que visa indicar tendências para as previsões. A WMA para  $n$  termos é matematicamente expressa por (1):

$$WMA = \frac{\sum_{i=1}^n iV_i}{\sum_{i=1}^n i}, \quad (1)$$

onde  $n = 5$  é o número de dias considerado para o cálculo de WMA. Ademais,  $V_i$  é o valor da demanda, do preço, de qualquer uma das variáveis climáticas (temperaturas máxima e mínima, exposição solar diária e índice pluviométrico) ou das variações previamente diária, semanal e anual ( $V_{RD}$ ,  $V_{RS}$ ,  $V_{RA}$ ).

TABELA I. Lista de todos os possíveis atributos das RNA.

Entradas para tempo $t$	$Preço(t); Demanda(t)$	$T \in \{1, 48, 366, 17472\}$
	$Preço(t-T); Demanda(t-T)$	
Entradas para WMA	$V_{RD}; V_{RS}; V_{RA}$ $Preço e Demanda$	Variações Diária, Semanal e Anual
	Dados Climáticos	Índice Pluviométrico, Temperaturas Máxima e Mínima, Exposição Solar Global – Valores do dia do qual $t$ pertence
Entradas para WMA	$Preço(t); Demanda(t)$	de $t$ para $t-336$
	$Preço(t-T); Demanda(t-T)$	
	$V_{RD}; V_{RS}; V_{RA}$	
	$Preço e Demanda$	
	Dados Climáticos	do dia do qual $t$ pertence até o do dia do qual $t-336$ pertence

Após o pré-processamento, a base de dados resultante conta com 60 distintos atributos que podem ser utilizados como entradas do modelo de predição. Por este motivo, também foi realizada uma etapa de seleção de atributos para reduzir a dimensionalidade dos dados e melhor ajustar o modelo neural que será empregado na predição da série temporal da demanda.

##### C. Seleção de atributos

Devido à grande quantidade de atributos gerados após o pré-processamento dos dados, aplicou-se o algoritmo *Correlation-based Feature Selection* (CFS), responsável por buscar atributos que possuem alta correlação com a demanda a ser prevista e baixa correlação com os demais atributos de entrada. Os atributos selecionados, ou seja, aqueles considerados mais relevantes são apresentados na Tabela 2.

Da Tabela 2, verifica-se para os quatro períodos de tempo considerando que a demanda atual, *Demanda* (*t*), é o principal atributo para a previsão da demanda de energia elétrica da região de *New South Wales*. Além disso, a WMA desse atributo está altamente correlacionada à demanda a ser prevista. O mesmo fato pôde ser observado para *Demanda* (*t-1*) e sua WMA.

De todas as variáveis climáticas investigadas, somente a WMA do *Índice Pluviométrico* possui alta correlação com a demanda a ser prevista. Entretanto, o WMA desse índice tem maior eficácia ao se tratar do subconjunto do período de tempo de 00h00 a 05h30 da estação #66037. Ademais, os atributos relacionados ao preço da energia elétrica não foram selecionados pelo CFS.

Portanto, notou-se que o CFS selecionou, principalmente, as WMA de variáveis relacionadas com a própria demanda em distintos instantes de tempo e para variações diárias.

TABELA II. Atributos selecionados pelo algoritmo CFS, considerando os intervalos de tempo de cada subconjunto de dados.

Conjunto de Dados	Atributos Selecionados
00h00 a 05h30	<i>Demanda</i> ( <i>t</i> )
	WMA da <i>Demanda</i> ( <i>t</i> )
	<i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>Demanda</i> ( <i>t-24</i> )
	WMA do Índice Pluviométrico -66037
06h00 a 11h30	<i>Demanda</i> ( <i>t</i> )
	WMA da <i>Demanda</i> ( <i>t</i> )
	WMA da <i>Demanda</i> ( <i>t-24</i> )
	<i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>Demanda</i> ( <i>t-366</i> )
12h00 a 17h30e	<i>Demanda</i> ( <i>t</i> )
	<i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>Demanda</i> ( <i>t</i> )
	WMA da <i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>V<sub>RD</sub></i> da <i>Demanda</i>
18h00 a 23h30	<i>Demanda</i> ( <i>t</i> )
	WMA da <i>Demanda</i> ( <i>t</i> )
	<i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>Demanda</i> ( <i>t-24</i> )
	WMA da <i>V<sub>RS</sub></i> da <i>Demanda</i> ( <i>t</i> )

D. Modelo Neural de Predição

Redes neurais artificiais são técnicas de aprendizado de máquina que buscam simular o funcionamento do cérebro humano, por meio de neurônios artificiais e do ajuste de pesos sinápticos. Basicamente, uma RNA possui uma camada de entrada de dados, camadas neurais intermediárias (ou ocultas) e uma camada neural de saída. A arquitetura da RNA encontra-se ilustrada na Fig. 2.

Assim, pode-se dispor de *n* sinais de entrada identificados por (*x<sub>1</sub>, x<sub>2</sub>, ..., x<sub>n</sub>*). Cada sinal (*x<sub>i</sub>*) é multiplicado por seu respectivo peso sináptico (*w<sub>i</sub>*). Somam-se os valores (*x<sub>i</sub> \* w<sub>i</sub>*), subtraídos do potencial de ativação (*b*), e o resultado dessa

combinação linear é dado como entrada à função de ativação *g* de cada neurônio, cuja resposta é *y*. Essa saída é matematicamente expressa por (2):

$$y = g \left( \sum_{i=1}^n w_i x_i - b \right) \tag{2}$$

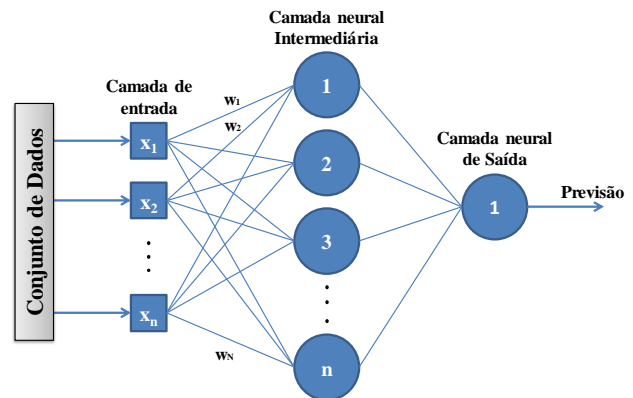


Fig 2. Ilustração da arquitetura da RNA.

A arquitetura da RNA implementada para a previsão de demanda foi *feedforward*, do tipo MLP e treinada com o algoritmo de Levenberg-Marquardt [19]. Optou-se por estabelecer como critério de parada do treinamento um erro quadrático médio de 10<sup>-12</sup> ou um máximo de 250 épocas. Testaram-se topologias com uma e duas camadas neurais intermediária. As topologias com uma camada neural intermediária possuem 4, 8, 12, 16, 20, 24 ou 28 neurônios, enquanto as topologias com duas camadas neurais intermediárias possuem 4, 8, 12, 16, 20, 24 ou 28 neurônios na primeira camada e 8, 12, 16, 20, 24 ou 28 neurônios na segunda. Adotaram-se as funções tangente hiperbólica e linear, respectivamente para os neurônios das camadas intermediárias e de saída.

Vale ainda mencionar que todas as RNAs implementadas foram configuradas utilizando a *toolbox Neural Network* do *Matlab*.

Na sequência, cada configuração de RNA foi treinada com 95% dos dados, considerando a base de dados com e sem a etapa de seleção de atributos. Os 5% restantes dos dados foram utilizados para a validação das RNAs. O desempenho de cada RNA foi averiguado por meio do MAPE, cujo cálculo é expresso por (3):

$$MAPE (\%) = \frac{100}{n} \sum_{i=1}^n \frac{|V_i - \bar{V}_i|}{V_i} \tag{3}$$

V. ANÁLISE E DISCUSSÕES DOS RESULTADOS

Após a validação de todas as topologias de RNA consideradas nessa pesquisa, observou-se que os MAPEs estiveram abaixo de 3,5%. Portanto, esse pode ser considerado o pior cenário possível. Assim, na sequência, são apresentados os resultados em função dos subconjuntos de dados (baseados em distintos intervalos temporais). Para cada subconjunto são

apresentados os resultados das melhores RNAs com 1 e 2 camadas neurais intermediárias e também com e sem a etapa de seleção de atributos.

**A. Resultados obtidos para o subconjunto com intervalo temporal entre 00h00 e 05h30**

A Tabela III apresenta os melhores resultados de previsão obtidos pelo modelo neural para o período de tempo de 00h00 a 05h30. Os resultados em destaque são os melhores atingidos pelas RNAs. Ao analisar referida tabela, percebe-se que o uso de seleção de atributos não foi eficiente, visto que os resultados das RNAs que fazem uso de todos os atributos são muito melhores.

TABELA III. MAPEs obtidos para os dados de 00h00 a 05h30.

Atributos	Com Seleção		Todos os atributos	
Número de neurônios	[4]	[4, 8]	[8]	[4, 24]
MAPE (%)	2,589579	1,881611	<b>0,680101</b>	<b>0,651463</b>

A Fig. 3 exibe graficamente os resultados da previsão feita pelo melhor modelo neural com duas camadas intermediárias para o período de tempo de 00h00 a 05h30.




Fig 3. Melhores resultados obtidos para o subconjunto de dados com intervalo temporal de 00h00 a 05h30.

**B. Resultados obtidos para o subconjunto com intervalo temporal entre 06h00 e 11h30**

Os resultados obtidos para o subconjunto de dados que corresponde ao intervalo temporal de 06h00 a 11h30, diferente do subconjunto previamente apresentado, demonstra que a seleção de atributos realmente pode ser eficiente, conforme destacado na Tabela IV.

TABELA IV. MAPEs obtidos para os dados de 06h00 a 11h30.

Atributos	Com Seleção		Todos os atributos	
Número de neurônios	[8]	[4, 12]	[16]	[4, 16]
MAPE (%)	<b>0,70963</b>	<b>0,828134</b>	3,222931	2,60787

Os melhores resultados, obtidos com seleção de atributos e modelo neural com uma camada neural intermediária, podem ser observados por meio do gráfico da Fig. 4.

**C. Resultados obtidos para o subconjunto com intervalo temporal entre 12h00 e 17h30**

Na Tabela IV são apresentados os melhores resultados de previsão para o período de tempo que compreende 12h00 até 17h30. Assim como ocorreu com as previsões para o período

de tempo de 06h00 até 11h30, a acurácia das previsões obtidas pelos modelos neurais aumentou com o uso da etapa de seleção de atributos.




Fig 4. Melhores resultados obtidos para o subconjunto de dados com intervalo temporal de 06h00 a 11h30.

TABELA V. MAPEs obtidos para os dados de 12h00 a 17h30.

Atributos	Com Seleção		Todos os atributos	
Número de neurônios	[4]	[8, 16]	[8]	[16, 24]
MAPE (%)	<b>0,495711</b>	<b>0,200562</b>	1,483441	1,930087

A diferença entre os MAPEs das melhores RNA (com e sem a seleção de atributos) é menor que 2,5%, o que é uma considerável melhora na previsão ao usar o algoritmo CFS. Graficamente, na Fig. 5 é possível visualizar tal melhora entre os dias 19 e 20.




Fig 5. Melhores resultados obtidos para o subconjunto de dados com intervalo temporal de 12h00 a 17h30.

**D. Resultados para o período de tempo de 18:00 até 23:30**

Por fim, as acurácias das previsões das melhores RNAs (com e sem a seleção de atributos) para o período de tempo de 18h00 até 23h30 são apresentadas na Tabela VI.

TABELA V. MAPEs obtidos para os dados de 18h00 a 23h30.

Atributos	Com Seleção		Todos os atributos	
Número de neurônios	[16]	[8, 28]	[16]	[12, 20]
MAPE (%)	<b>1,174195</b>	<b>1,186582</b>	1,845005	2,98244

Novamente, os melhores resultados foram obtidos por meio da base de dados submetida à etapa de seleção de atributos. Entretanto, apesar da melhora, essa pode ser considerada sutil. A Fig. 6 demonstra, graficamente, a comparação entre os resultados do melhor modelo neural de previsão e os dados reais.




Fig 6. Melhores resultados obtidos para o subconjunto de dados com intervalo temporal de 18h00 a 23h30.

## VI. CONCLUSÕES

A metodologia apresentada para o problema de previsão de demanda de energia elétrica considerou dados obtidos do mercado australiano, mais precisamente da região de *New South Wales*. Após levar em conta uma etapa de pré-processamento de dados, os modelos neurais foram capazes de obter MAPEs inferiores a 3,5%. Entretanto, ao considerar somente os melhores modelos obtidos para cada subconjunto de dados (em função dos intervalos temporais), o MAPE máximo foi de aproximadamente 1,19% e o mínimo foi de 0,2%. Constatou-se então que o uso de WMA como técnica de pré-processamento dos dados é realmente eficiente não somente à análise de dados provenientes de mercados financeiros. Portanto, pode-se considerar tal variável também ao mercado de energia elétrica.

Ainda foi possível notar que, com exceção do subconjunto de dados com valores temporais entre 0h00 e 5h30, os demais subconjuntos de dados foram melhor previstos com o uso da etapa de seleção de atributos. Além disso, o uso do algoritmo CFS, em todos os casos, consegue reduzir drasticamente a dimensionalidade dos dados de entrada.

## REFERÊNCIAS

- [1] UN-Habitat, "Urbanization and Development: Emerging Futures. World. Cities Report 2016," 2016.
- [2] S. P. Mohanty, U. Choppali, and E. Kougianos, "Everything you wanted to know about smart cities: The Internet of things is the backbone," *IEEE Consum. Electron. Mag.*, vol. 5, no. 3, pp. 60–70, Jul. 2016.
- [3] T. Nam and T. A. Pardo, "Smart city as urban innovation: focusing on management, policy, and context," in *Proceedings of the 5th International Conference on Theory and Practice of Electronic Governance - ICEGOV '11*, 2011, p. 185.
- [4] C. Harrison *et al.*, "Foundations for Smarter Cities," *IBM J. Res. Dev.*, vol. 54, no. 4, pp. 1–16, Jul. 2010.
- [5] P. Cramton, "Electricity market design," *Oxford Rev. Econ. Policy*, vol. 33, no. 4, pp. 589–612, Nov. 2017.
- [6] UN, "Transforming our world: the 2030 Agenda for Sustainable Development." 2015.
- [7] J. N. Bharothu, M. Sridhar, and R. S. Rao, "A literature survey report on Smart Grid technologies," in *2014 International Conference on Smart Electric Grid (ISEG)*, 2014, pp. 1–8.
- [8] J. Yang, J. Zhao, F. Luo, F. Wen, and Z. Y. Dong, "Decision-Making for Electricity Retailers: A Brief Survey," *IEEE Trans. Smart Grid*, pp. 1–1, 2017.

- [9] C. W. Gellings and W. L. (Wallace L. . Barron, *Demand forecasting in the electric utility industry*. PennWell Pub, 1996.
- [10] A. Baliyan, K. Gaurav, and S. K. Mishra, "A Review of Short Term Load Forecasting using Artificial Neural Network Models," *Procedia Comput. Sci.*, vol. 48, pp. 121–125, Jan. 2015.
- [11] H. Seifi and M. Sadegh Sepasian, *Electric Power System Planning: Issues, Algorithms and Solutions*, 1st ed. Springer-Verlag Berlin Heidelberg, 2011.
- [12] A. Laouafi, M. Mordjaoui, S. Haddad, T. E. Boukelia, and A. Ganouche, "Online electricity demand forecasting based on an effective forecast combination methodology," *Electr. Power Syst. Res.*, vol. 148, pp. 35–47, Jul. 2017.
- [13] H. Quan, D. Srinivasan, and A. Khosravi, "Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 25, no. 2, pp. 303–315, Feb. 2014.
- [14] W. Li, X. Yang, H. Li, and L. Su, "Hybrid Forecasting Approach Based on GRNN Neural Network and SVR Machine for Electricity Demand Forecasting," *Energies*, vol. 10, no. 1, pp. 1–17, 2017.
- [15] L. Xiao, W. Shao, T. Liang, and C. Wang, "A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting," *Appl. Energy*, vol. 167, pp. 135–153, Apr. 2016.
- [16] C. Beggs, "Competition in energy supply," in *Energy: Management, Supply and Conservation*, Elsevier, 2002, pp. 37–54.
- [17] NEM, "The National Electricity Market NEM fast facts." 2018.
- [18] AEMC, "Electricity system | AEMC," 2018. [Online]. Available: <https://www.aemc.gov.au/energy-system/electricity>. [Accessed: 02-May-2018].
- [19] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Hamilton, Ontario, Canada: Person Education, 2008.