

Tarcisio Prest Bernabé

Previsão de Demanda Elétrica, Recurso Eólico e Solar Utilizando Redes Neurais

Vitória – ES

Agosto de 2016

Tarcisio Prest Bernabé

Previsão de Demanda Elétrica, Recurso Eólico e Solar Utilizando Redes Neurais

Parte manuscrita do Projeto de Graduação do aluno Tarcisio Prest Bernabé, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Universidade Federal do Espírito Santo – UFES

Departamento de Engenharia Elétrica

Projeto de Graduação

Orientador: Prof. Msc. Tiago Malavazi de Christo

Coorientador: Prof. Dr. Jussara Farias Fardin

Vitória – ES

Agosto de 2016

Tarcisio Prest Bernabé

Previsão de Demanda Elétrica, Recurso Eólico e Solar Utilizando Redes Neurais

Parte manuscrita do Projeto de Graduação do aluno Tarcisio Prest Bernabé, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Trabalho aprovado. Vitória – ES, 24 de agosto de 2016:

Prof. Msc. Tiago Malavazi de Christo
Orientador

Prof. Dr. Jussara Farias Fardin
Coorientador

Prof. Dr. Klaus Fabian Côco
Examinador

Msc. Lucas de Assis Soares
Examinador

Vitória – ES
Agosto de 2016

*Este trabalho é dedicado ao meu irmão,
que me ensinou a viver, sonhar e conquistar.*

Agradecimentos

Os agradecimentos são direcionados aos meus orientadores, por terem me instruído e acreditado em mim ao longo do projeto, minha família, que me deu suporte durante todos esses anos de vida acadêmica, e aos meus professores de graduação por terem me ajudado a obter o conhecimento necessário para desenvolver este projeto e todos os outros futuros trabalhos em minha carreira profissional.

*Nunca deixe que lhe digam que não vale a pena
acreditar no sonho que se tem
ou que os seus planos nunca vão dar certo
ou que você nunca vai ser alguém...*
(Renato Russo)

Resumo

O presente trabalho avalia aplicações de redes neurais artificiais e decomposição *wavelet* para realizar a previsão da demanda elétrica e capacidade de geração de sistemas eólicos e solar. Uma abordagem utilizando variáveis exógenas também é testada. Para desenvolvimento dos modelos de previsão foi empregado o *software* Matlab, utilizando séries de dados meteorológicos coletados do projeto SONDA, estação Petrolina, e memória de massa da UFES. Para a realização deste trabalho foram avaliados a aplicação de redes neurais, *wavelet*, técnicas de tratamento de dados, conceitos de correlação, séries temporais e os fatores e variáveis que afetam a previsão. Ao final do projeto, são apresentados os resultados para previsão de velocidade do vento, irradiância solar e demanda elétrica. Percebeu-se que, em todos os casos, a aplicação de decomposição *wavelet packet* trouxe os maiores valores de R^2 , em relação aos outros modelos sintetizados neste trabalho, com grau de acerto de até 99,3%, 88,9%, 98,9% e 98,2% para recurso solar, eólico, demanda ativa e reativa, respectivamente.

Palavras-chave: redes neurais. variáveis exógenas. decomposição *wavelet*. RNA. previsão. eólica. solar. demanda.

Abstract

This work analyzes artificial neural networks and wavelet decomposition to achieve the prediction of electric demand and generation capacity of wind and solar systems. Also, an approach using exogenous variables are tested. To develop the prevision models, it was used the software MATLAB, using series of meteorological data collected from project SONDA, Petrolina station, and UFES's electric consumption spreadsheets. To accomplish this project it was evaluated neural network, wavelet, data treatment technics, correlation concepts, temporal series and factors and variables that affect the prevision. At the end of this paper, it is presented the results for the prevision of the wind speed, solar irradiance and electrical demand. It was noticed that, in all the cases, the wavelet packet decomposition application brought the greatest values of R^2 , comparing to all other models synthesized in this project, with an accuracy of up to 99.3%, 88.9%, 98.9% and 98.2% to solar and wind resources and active and reactive demands, respectively.

Keywords: neural network. exogenous variables. wavelet decomposition. RNA. forecasting. wind. solar. electrical demand.

Lista de ilustrações

Figura 1 – Taxa de crescimento anual das energias renováveis.	17
Figura 2 – Capacidade instalada de energia eólica no mundo 2011-2015[MW]	18
Figura 3 – Componentes da radiação solar sobre um dispositivo fotovoltaico. . . .	21
Figura 4 – Curva solar de Petrolina para o ano de 2014 plotada em Matlab considerando $\alpha = 1$	23
Figura 5 – Curva solar de Petrolina para um dia típico de 2014.	23
Figura 6 – Formação dos ventos devido ao deslocamento de massas de ar	24
Figura 7 – Curva de Weibull típica	25
Figura 8 – Curva de demanda típica para consumidor residencial	27
Figura 9 – Curva de demanda típica para consumidor industrial	27
Figura 10 – Curva de demanda típica para consumidor comercial	27
Figura 11 – Decomposição wavelet de 4 níveis	28
Figura 12 – Decomposição wavelet de 3 níveis	29
Figura 13 – Sinais da aproximação e detalhes para uma decomposição de 5 níveis	29
Figura 14 – Decomposição wavelet packet	30
Figura 15 – Exemplos do efeito de borda, em cinco sinais, para diferentes técnicas de preenchimento	31
Figura 16 – Erro médio quadrático na borda dos cinco sinais, para diferentes tipos de preenchimento	31
Figura 17 – Modelo de neurônio artificial	33
Figura 18 – Rede neural multicamadas	34
Figura 19 – Rede MLP	35
Figura 20 – Irradiância solar normalizada em Petrolina com resolução de 1h no ano de 2014	39
Figura 21 – Análise do número de delays a ser usado na RNA para previsão solar	40
Figura 22 – Análise do número de neurônios na camada oculta da RNA para previsão solar	40
Figura 23 – Análise do número de neurônios na camada oculta da RNA para previsão solar	41
Figura 24 – Resultados RNA para previsão solar	41
Figura 25 – Comportamento da previsão da RNA para previsão solar	42
Figura 26 – Correlação cruzada entre a curva solar e irradiância solar medida	43
Figura 27 – Correlação cruzada entre irradiância solar medida e sua derivada de primeira ordem	43
Figura 28 – Derivada de primeira ordem da série temporal de irradiância solar	44
Figura 29 – Análise do número de delays das variáveis exógenas para previsão solar	44

Figura 30 – Topologia da RNA + E para previsão solar	44
Figura 31 – Resultados RNA + E para previsão solar	45
Figura 32 – Comportamento da previsão da RNA + E para previsão solar	46
Figura 33 – Modelo de previsão RNA + W para previsão solar	47
Figura 34 – Resultados RNA + W para previsão solar	47
Figura 35 – Comportamento da previsão da RNA + W para previsão solar	48
Figura 36 – Resultados RNA + WP para previsão solar	49
Figura 37 – Comportamento da previsão da RNA + WP para previsão solar	49
Figura 38 – Desempenho dos modelos desenvolvidos para previsão solar	50
Figura 39 – Velocidade do vento normalizada em petrolina a 25 metros de altura no ano de 2010	51
Figura 40 – Análise do número de <i>delays</i> a ser usado na RNA para previsão eólica .	52
Figura 41 – Análise do número de neurônios na camada oculta da RNA para previsão eólica	52
Figura 42 – Topologia de RNA utilizada para previsão eólica	52
Figura 43 – Resultados RNA para previsão eólica	53
Figura 44 – Comportamento da previsão da RNA para previsão eólica	53
Figura 45 – Correlação cruzada entre a velocidade e direção do vento	54
Figura 46 – Correlação cruzada entre velocidade do vento e temperatura do ar	55
Figura 47 – Correlação cruzada entre velocidade do vento e sua derivada de primeira ordem	55
Figura 48 – Análise do número de delays das variáveis exógenas para previsão eólica	55
Figura 49 – Topologia de RNA para previsão eólica com variáveis exógenas	56
Figura 50 – Resultados RNA + E para previsão eólica	56
Figura 51 – Comportamento da previsão da RNA + E para previsão eólica	57
Figura 52 – Resultados RNA + W para previsão eólica	58
Figura 53 – Comportamento da previsão da RNA + W para previsão eólica	58
Figura 54 – Resultados RNA + WP para previsão eólica	59
Figura 55 – Comportamento da previsão da RNA + WP para previsão eólica	60
Figura 56 – Desempenho dos modelos desenvolvidos para previsão eólica	61
Figura 57 – Demanda ativa e reativa da UFES com resolução de 1h no ano de 2014	62
Figura 58 – Demanda ativa e reativa da UFES no dia 1º de abril de 2014	62
Figura 59 – Análise do número de <i>delays</i> a ser usado na RNA para previsão de demanda ativa	63
Figura 60 – Análise do número de <i>delays</i> a ser usado na RNA para previsão de demanda reativa	64
Figura 61 – Análise do número de neurônios na camada oculta da RNA para previsão de demanda ativa	64

Figura 62 – Análise do número de neurônios na camada oculta da RNA para previsão de demanda reativa	65
Figura 63 – Topologia de RNA utilizada para previsão de demanda ativa e reativa .	65
Figura 64 – Resultados RNA para previsão de demanda ativa	66
Figura 65 – Resultados RNA para previsão de demanda reativa	66
Figura 66 – Comportamento da previsão da RNA para previsão de demanda	66
Figura 67 – Correlação cruzada entre demanda ativa e reativa	67
Figura 68 – Correlação cruzada entre demanda e derivada de primeira ordem	68
Figura 69 – Correlação cruzada entre demanda e dia da semana	68
Figura 70 – Correlação cruzada entre demanda e hora do dia	68
Figura 71 – Análise do número de <i>delays</i> das variáveis exógenas para previsão de demanda ativa	69
Figura 72 – Análise do número de <i>delays</i> das variáveis exógenas para previsão de demanda reativa	69
Figura 73 – Topologia de RNA para previsão de demanda reativa com variáveis exógenas	70
Figura 74 – Resultados RNA+E para previsão de demanda ativa	70
Figura 75 – Resultados RNA+E para previsão de demanda reativa	71
Figura 76 – Comportamento da previsão da RNA+E para previsão de demanda . .	71
Figura 77 – Resultados RNA+W para previsão de demanda ativa	72
Figura 78 – Resultados RNA+W para previsão de demanda reativa	73
Figura 79 – Comportamento da previsão da RNA+W para previsão de demanda .	73
Figura 80 – Resultados RNA+WP para previsão de demanda ativa	74
Figura 81 – Resultados RNA+WP para previsão de demanda reativa	74
Figura 82 – Comportamento da previsão da RNAWP para previsão de demanda . .	75
Figura 83 – Desempenho dos modelos desenvolvidos para previsão de demanda ativa	76
Figura 84 – Desempenho dos modelos desenvolvidos para previsão de demanda reativa	76

Lista de tabelas

Tabela 1 – Resultados da previsão solar para RNA	41
Tabela 2 – Resultados da previsão solar para RNA + E	45
Tabela 3 – Resultados da previsão solar para RNA + W	48
Tabela 4 – Resultados da previsão solar para RNA + WP	49
Tabela 5 – Tabela comparativa dos modelos desenvolvidos para previsão solar . .	50
Tabela 6 – Resultados da previsão eólica para RNA	54
Tabela 7 – Resultados da previsão eólica para RNA + E	57
Tabela 8 – Resultados da previsão eólica para RNA + W	58
Tabela 9 – Resultados da previsão eólica para RNA + WP	59
Tabela 10 – Tabela comparativa dos modelos desenvolvidos para previsão eólica . .	61
Tabela 11 – Resultados da previsão de demanda para RNA	67
Tabela 12 – Resultados da previsão de demanda para RNA+E	72
Tabela 13 – Resultados da previsão de demanda para RNA+W	73
Tabela 14 – Resultados da previsão de demanda para RNA+WP	75
Tabela 15 – Tabela comparativa dos modelos para previsão de demanda	76

Lista de abreviaturas e siglas

RMSE	Raiz Quadrada do Erro Quadrático Médio
ANEEL	Agência Nacional de Energia Elétrica
MLP	Perceptron Multicamadas
MSE	Erro Quadrático Médio
ONU DI	Organização das Nações Unidas para o Desenvolvimento Industrial
RNA	Rede Neural Artificial
SIN	Sistema Interligado Nacional
SONDA	Sistema Nacional de Organização de Dados Ambientais
UFES	Universidade Federal do Espírito Santo
WEC	Conselho Mundial de Energia
WWEA	Associação Mundial de Energia Eólica

Lista de símbolos

GW_p	Gigawatt Pico
G	Irradiância Solar [W/m^2]
G_o	Irradiância que chega à Terra de valor médio de 1.367 [W/m^2]
G_b	Irradiância direta [W/m^2]
G_{diff}	Irradiância difusa [W/m^2]
G_{refl}	Irradiância refletida [W/m^2]
LMT	Tempo Civil, ou <i>Local Mean Time</i>
LAT	Tempo Solar, ou <i>Local Apparente Time</i>
λ	Comprimento da zona geográfica
λ_r	Comprimento da zona geográfica de referencia
GMT	Tempo Civil no meridiano de <i>Greenwich</i> , ou <i>Greenwich Mean Time</i>
ET	Equação de tempo
c	Constante de compensação de horáriod e verão
d	Sequência data de um ano
α	Índice de cobertura de nuvens
γ_s	Altitude solar
ϕ	latitude local
ω	Ângulo horário solar
δ	declinação do sol
GW	Gigawatt
P_{vento}	Potência do incidente [W]
ρ	Densidade do ar [kg/m^3]
A	Área do rotor [m^2]

V	Velocidade do vento [m/s]
$P_{\acute{u}til}$	Potência efetivamente entregue pela turbina [W]
η_a	Rendimento aerodinâmico do gerador
η_m	Rendimento mecânico
η_e	Rendimento elétrico
C_p	Coefficiente de potência do aerogerador
A_n	Aproximação da decomposição wavelet de nível n
D_n	Detalhe da decomposição wavelet de nível n

Sumário

1	INTRODUÇÃO	17
1.1	Justificativa	19
1.2	Objetivo	20
1.2.1	Objetivo geral	20
1.2.2	Objetivos específicos	20
1.3	Estrutura do trabalho	20
2	REFERENCIAL TEÓRICO	21
2.1	Caracterização da energia solar	21
2.2	Caracterização da energia eólica	24
2.3	Demanda elétrica	26
2.4	Decomposição wavelet	28
2.4.1	Efeito de borda	30
2.5	Redes neurais	32
2.5.1	Neurônio artificial	32
2.5.2	Topologia e arquitetura de redes neurais	33
2.5.3	Redes perceptron multicamadas (MLP)	34
3	METODOLOGIA ADOTADA	36
3.1	Coleta e tratamento de dados	36
3.2	Implementação dos modelos	37
3.3	Análise qualitativa entre os modelos obtidos	38
4	RESULTADOS	39
4.1	Previsão solar	39
4.1.1	Modelo RNA	39
4.1.2	Modelo RNA com entradas exógenas	42
4.1.3	Modelo RNA com uso de Wavelet	46
4.1.4	Modelo RNA com uso de Wavelet Packet	48
4.1.5	Conclusão	50
4.2	Previsão Eólica	51
4.2.1	Modelo RNA	51
4.2.2	Modelo RNA com entradas exógenas	54
4.2.3	Modelo RNA com uso de Wavelet	57
4.2.4	Modelo RNA com uso de Wavelet Packet	59
4.2.5	Conclusão	60

4.3	Previsão de Demanda	61
4.3.1	Modelo RNA	63
4.3.2	Modelo RNA com entradas exógenas	67
4.3.3	Modelo RNA com uso de Wavelet	72
4.3.4	Modelo RNA com uso de Wavelet Packet	74
4.3.5	Conclusão	75
5	CONSIDERAÇÕES FINAIS	77
	REFERÊNCIAS	78

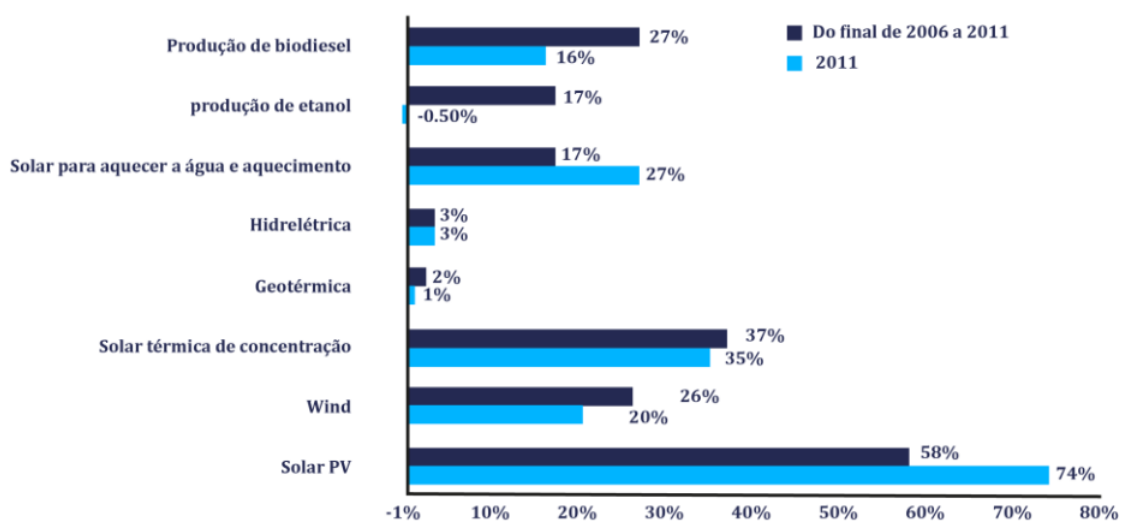
1 Introdução

É de consenso geral que a energia elétrica é indispensável para o desenvolvimento de qualquer cidade ou país. Dessa forma, satisfazer a crescente demanda de energia no mundo, preocupando-se com a diversificação da matriz energética, tornou-se um desafio, visto que a maioria da energia utilizada no planeta ainda é de origem não renovável. Segundo a IEA - Agência Internacional de Energia, em 2013, 78% de toda a energia elétrica gerada no mundo era de origem não renovável.

Com a recente e crescente preocupação em torno das questões ambientais devido aos impactos causados pelas formas tradicionais de geração de energia, inúmeros países vêm investindo na complementação e transformação de sua matriz energética, através da introdução de fontes renováveis de energia em seus parques energéticos. Com isso, nota-se cada vez mais investimentos na área de energias renováveis, o que proporcionou ao longo dos últimos anos a queda dos preços e evolução da tecnologia de células fotovoltaicas e aerogeradores, principalmente.

Segundo a [ONU DI \(2015\)](#), houve um crescimento rápido e sustentado, entre 2006 e 2011, da participação das chamadas energias renováveis no mercado de energia global. Estima-se que no final de 2011, 20,3% do fornecimento de energia elétrica eram provenientes de fontes renováveis. A energia solar fotovoltaica cresceu de forma mais expressiva que suas "concorrentes" durante este período. É o que mostra a [Figura 1](#). Durante este período houve um crescimento médio anual de 58%.


Figura 1 – Taxa de crescimento anual das energias renováveis.



Fonte: [ONU DI \(2015, p. 2\)](#)

Em termos de capacidade total instalada, a fotovoltaica ocupa apenas o terceiro lugar dentre as fontes de energias renováveis, após a hidrelétrica e a energia eólica (ONU, 2015). Em 2015, a capacidade total instalada de energia eólica era de 435GW, segundo a Associação Mundial de Energia Eólica (WWEA, na sigla em inglês). Para se ter uma ideia da magnitude da expansão desse tipo de energia no mundo, em 2011 a capacidade mundial foi de cerca de 236 GW, um aumento de 84% em 4 anos, aproximadamente. Na Figura 2 é possível observar o crescimento da capacidade instalada no mundo entre 2011 e 2015.

Figura 2 – Capacidade instalada de energia eólica no mundo 2011-2015[MW]



Fonte: WWEA (2016)

A quantidade de energia gerada baseia-se na quantidade de energia demandada pelas residências, indústrias e comércios. Sendo assim, surge um problema em se introduzir sistemas renováveis em grandes malhas energéticas, a natureza é intermitente. Isto é, a quantidade de energia gerada por sistemas eólicos e solar, por exemplo, está diretamente associada à intermitência dos eventos da natureza, como a velocidade do vento, existência de nuvens e neblina. Dessa forma, é difícil determinar um montante fixo de energia que será gerada para o sistema elétrico. Com isso, há a necessidade de maior capacidade de reserva de geração, destinada a elevar a segurança no fornecimento de energia.

Considerando a necessidade de lidar com a intermitência dessas fontes, existe a necessidade de se investigar técnicas de previsão de produção de energia renovável que melhorem o gerenciamento e a tomada de decisões no sistema de energia.

Trabalhos anteriores mostram resultados excelentes na aplicação de redes neurais e decomposição *wavelet* para a previsão de geração eólica e solar. Em (REN; SUGANTHAN; SRIKANTH, 2015) um modelo de rede neural associado a decomposição *wavelet* é apresentado para previsão de velocidade do vento, com horizonte de previsão de 5 horas, e irradiância solar, com horizonte de previsão de 24 horas. Os resultados obtidos foram de RMSE = 0.111 para previsão de velocidade de vento e de RMSE = 0.099 para irradiância

solar. Já em (MENG et al., 2016) foi desenvolvido um modelo associando rede neural à decomposição *wavelet packet* para previsão de velocidade do vento com horizonte de previsão de 5 horas e $RMSE = 0.639$. O presente trabalho busca desenvolver um modelo de previsão para demanda ativa e reativa, recurso eólico e solar, que possa ser aplicado para se estimar um montante de energia demandado pelas unidades consumidoras e gerado por fontes renováveis afim de diminuir os problemas causados pela intermitência da natureza. Espera-se garantir a confiabilidade e disponibilidade do sistema, além de reduzir custos operacionais e facilitar a operação de grandes sistemas de energia.

1.1 Justificativa

A demanda por energia está diretamente ligada ao crescimento das cidades e da população mundial. A cada ano, a geração de energia aumenta e com isso cresce o interesse em reduzir-se os custos operacionais e os impactos ambientais causados pela geração de energia não renovável. Por isso, a inserção de energia renovável na matriz energética mundial e métodos que contribuam para gestão de sistemas elétricos são importantes para garantir um sistema confiável, disponível, limpo e barato.

Por isso, existe a necessidade de se estimar o quanto de energia será fornecido por fontes renováveis sujeitas à intermitência da natureza e o quanto será consumido pelos consumidores finais da rede.

A literatura mostra que a utilização de redes neurais artificiais voltadas para a previsão de comportamento de variáveis já é fundamentada, visto que podem ser encontrados na literatura aplicações práticas com desempenho capaz de melhorar a gestão de sistemas elétricos de potência (REN; SUGANTHAN; SRIKANTH, 2015), (MENG et al., 2016).

A base de dados escolhida para previsão de demanda foi obtida da UFES, devido a existência de dados de memória de massa que foram utilizados nos modelos de previsão.

Para previsão eólica e solar, foram coletados dados de Petrolina em Pernambuco, através do projeto SONDA, devido a consistência e validação dos dados meteorológicos.

Além disso, visando obter sistemas sustentáveis, confiáveis e abundantes, além de diminuir custos, há interesse constante por parte dos governantes e indústrias pela implementação de técnicas de previsão que possam melhorar a gestão de sistemas elétricos.

1.2 Objetivo

1.2.1 Objetivo geral

Implementar e avaliar um sistema para previsão de demanda energética, recurso solar e eólico, com horizonte de previsão de 24 horas, através de redes neurais, decomposição *wavelet* e variáveis exógenas utilizando o *software Matlab*.

1.2.2 Objetivos específicos

- Verificar qual tipo de decomposição *wavelet* é mais apropriada para previsão eólica, solar e de demanda;
- Verificar o grau de acerto da rede neural antes e depois de utilizar decomposição *wavelet*;
- Verificar a influência de se inserir variáveis exógenas como entradas da rede neural;
- Realizar estudo comparativo entre os modelos desenvolvidos.

1.3 Estrutura do trabalho

O presente trabalho foi dividido em cinco Capítulos. Este primeiro Capítulo apresentou o tema do trabalho, expondo seus objetivos e a motivação para a escolha do tema tratado.

O segundo Capítulo apresenta o embasamento teórico do projeto. Nas seções 2.1, 2.2 e 2.3 são apresentados conceitos de energia solar, eólica e demanda energética, respectivamente. Em seguida, nas seções 2.4 e 2.5, uma revisão teórica de redes neurais artificiais e decomposição *wavelet* é apresentada.

No terceiro Capítulo é abordada a metodologia utilizada para desenvolvimento dos modelos de previsão. Em seguida, no Capítulo 4 são apresentados os resultados de cada modelo para previsão solar, eólica e de demanda elétrica. No Capítulo 5, são apresentadas as considerações finais obtidas e as sugestões para trabalhos futuros.

Por fim, são apresentadas as referências bibliográficas utilizadas para a elaboração deste trabalho.


2 Referencial teórico

2.1 Caracterização da energia solar

A radiação solar é a energia que chega do sol em forma de ondas eletromagnéticas. Ou seja, é a energia transmitida, através do espaço, pelo sol. A partir dessa definição, surgem dois conceitos: irradiância e irradiação solar. O primeiro deles, representado pela variável G , constitui uma média de potência por unidade de área. Em geral, é medido em watts por metro quadrado (W/m^2). A irradiância que chega ao nosso planeta proveniente do sol tem um valor médio aproximado de $1.367 W/m^2$, G_o . O segundo deles, irradiação solar, é a quantidade de energia solar incidente por unidade de superfície durante um período definido de tempo. Obtém-se integrando a irradiância global neste período de tempo. Em geral, é expresso em quilo watts hora por metro quadrado dia ($kWh/m^2.dia$). (ONUDI, 2015)

Ao atravessar a atmosfera terrestre, a irradiância solar decompõe-se em três frações, são elas: irradiância direta (G_b), irradiância difusa (G_{diff}) e irradiância refletida ou albedo (G_{refl}). A primeira incide diretamente sobre a superfície, sem sofrer qualquer influência. A segunda fração atinge a superfície após sofrer espalhamento pela atmosfera terrestre. E, por último, o albedo é a radiação solar que chega à superfície terrestre e é refletida pelo ambiente entorno (solo, vegetação, obstáculos, etc.). A soma dessas três frações em uma determinada superfície, também é chamada de irradiância global (PINHO; GALDINO, 2014). A Figura 3 mostra a incidência destas três componentes sobre um dispositivo fotovoltaico.

Figura 3 – Componentes da radiação solar sobre um dispositivo fotovoltaico.



Fonte: ONUDI (2015, p. 28)

Um dispositivo fotovoltaico “plano”, funcionando em modo convencional, é capaz de aproveitar as componentes direta, difusa e refletida da irradiância solar, de modo que a intensidade da corrente elétrica que produz é diretamente proporcional ao valor da irradiância global. (ONUUDI, 2015)

Usualmente, a referência temporal com a qual estamos acostumados cotidianamente denomina-se, Tempo Médio Local (*LMT - Local Mean Time*), ou Tempo Civil, que é o tempo corrigido para o meridiano local em relação ao meridiano de *Greenwich*. Porém, ao trabalhar com energia solar é mais simples se adotarmos o Tempo Solar (*LAT - Local Apparent Time*). A diferença entre um e outro depende basicamente do comprimento da zona geográfica considerada, λ .

O comprimento de referência, λ_r , é o meridiano de Greenwich e seu tempo civil é conhecido como GMT (*Greenwich Mean Time*). Devido a pequenos movimentos do eixo Norte-Sul terrestre, há uma leve diferença entre GMT e LAT, referente a chamada equação de tempo (ET). Com isso, a equivalência entre tempo civil e tempo solar, para uma zona geográfica de comprimento λ é dada pela [Equação 2.1](#). A cada hora a mais em relação ao GMT corresponde a 15 graus em comprimento. Caso haja no país horário de verão, a variável c deve ser considerada. (ONUUDI, 2015)

$$LAT = LMT + ET + (\lambda - \lambda_r)/15 - c \quad (2.1)$$

A hora solar é utilizada para conhecer e prever a magnitude de radiação solar em determinado momento específico. Além disso é necessário identificar os ângulos geométricos que definem a posição do sol com relação a um observador terrestre.

Através da posição solar é possível obter a irradiância incidente sobre um plano horizontal e obter o ângulo de incidência da radiação solar sobre os dispositivos fotovoltaicos utilizado para um possível rastreamento solar.

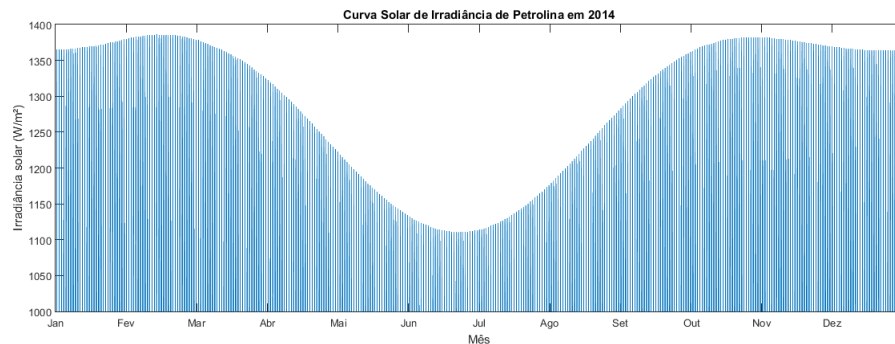
A irradiância sobre um plano horizontal fora da atmosfera é definido pela [Equação 2.2](#). Sendo d a sequência data de um ano, α o índice de cobertura de nuvens, G_o a constante de valor $1367W/m^2$ e γ_s representa a altitude solar, definida pela [Equação 2.3](#).

$$G = \alpha G_o \left(1 + 0.0334 \cos \left(\frac{360d}{365.25} - 2, 8^\circ \right) \right) \text{sen}(\gamma_s) \quad (2.2)$$

$$\gamma_s = \text{sen}^{-1} (\text{sen}\phi \text{sen}\delta + \text{cos}\phi \text{cos}\delta \text{cos}\omega) \quad (2.3)$$

Em que, ϕ é a latitude local, ω é o ângulo horário solar e δ é conhecido como declinação do sol. A [Figura 4](#) mostra a curva obtida em *Matlab* para o ano de 2014 em Petrolina.

Figura 4 – Curva solar de Petrolina para o ano de 2014 plotada em Matlab considerando $\alpha = 1$.




Fonte: Próprio autor.

Percebe-se que, nesta região, nos meses iniciais e finais do ano, correspondentes ao período do verão, ocorrem os maiores valores de irradiância solar. Em contrapartida, nos meses centrais, correspondentes ao período de inverno, são observados os menores valores de irradiância solar.

Na [Figura 5](#) é apresentada a curva solar típica de um dia para a região de Petrolina. Essa curva tem característica periódica pois se repete ao longo dos 365 dias do ano, devido ao movimento de rotação da terra. Porém, devido a presença de nuvens, neblina e ao movimento de translação da terra ao redor do sol, os valores de irradiância tendem a aumentar ou diminuir, como foi observado na [Figura 4](#).

Figura 5 – Curva solar de Petrolina para um dia típico de 2014.




Fonte: Próprio autor.

2.2 Caracterização da energia eólica

A energia eólica provém da radiação solar uma vez que os ventos são gerados pelo aquecimento não uniforme da superfície terrestre. Naturalmente, as regiões tropicais são mais aquecidas do que regiões polares. Por isso, o ar quente que se encontra nas baixas altitudes das regiões tropicais, por ser menos denso, tende a subir, sendo este substituído por massas de ar menos quentes oriundas das regiões polares. De forma geral e simplificada, o deslocamento dessas massas de ar determinam a formação dos ventos, representada pela [Figura 6](#) (CRESESB, 2015).

Figura 6 – Formação dos ventos devido ao deslocamento de massas de ar



Fonte: [CRESESB \(2015\)](#)

Tendo em vista que o eixo da Terra está inclinado de $23,5^\circ$ em relação ao plano de sua órbita em torno do Sol, variações sazonais na distribuição de radiação recebida na superfície da Terra resultam em variações sazonais na intensidade e duração dos ventos, em qualquer local da superfície terrestre. Como resultado surgem os ventos continentais ou periódicos e compreendem as monções e as brisas ([CRESESB, 2015](#)).


Essas circulações também são influenciadas pelos movimentos de rotação da terra, pela topografia e, ainda, por comportamentos característicos em áreas montanhosas e costeiras, dado o maior ou menor aquecimento de cada superfície, que reflete em diferentes sentidos de convecção das massas de ar ([CHRISTO, 2012](#)).

Na avaliação do recurso eólico, uma das curvas mais importantes, a partir da qual a maior parte das análises pode ser realizada, é a curva de frequência das velocidades, que fornece o período de tempo, em termos percentuais, em que uma velocidade foi observada ([REIS, 2003](#)). Essa curva pode ser obtida através da escolha da curva de distribuição de

Weibull que melhor contorne o histograma de frequências das velocidades. Essa técnica possibilita a caracterização do perfil eólico através de apenas duas constantes, os parâmetros “c” (fator de escala que, depende essencialmente da velocidade média do vento) e “k” (fator de forma que, depende do desvio padrão da velocidade média) de Weibull, [Equação 2.4](#) (CHRISTO, 2012). A variação da curva de distribuição para diferentes valores de “k”, mantendo-se “c” fixo, é apresentada na [Figura 7](#).

$$h(v) = \frac{k}{c} \frac{v}{c} e^{-\frac{v}{c} k} \quad (2.4)$$

Figura 7 – Curva de Weibull típica



Fonte: [CHRISTO \(2012\)](#)

Na prática, segundo o teorema de Betz, a máxima parcela da potência do vento que poderá ser realmente extraída será sempre inferior a 59,3% ([CHRISTO, 2012](#)).

Para a análise do potencial eólico disponível em uma dada região, utiliza-se comumente o cálculo da potência do vento por metro quadrado da área interceptada (W/m^2). A potência eólica pode ser expressa de forma simplificada pelas seguintes equações ([CHRISTO, 2012](#)):

$$P_{vento} = \frac{1}{2} \cdot \rho \cdot A \cdot V^3 \quad (2.5)$$

$$P_{útil} = P_{vento} \cdot \eta_a \cdot \eta_m \cdot \eta_e \quad (2.6)$$

$$P_{útil} = \frac{1}{2} \cdot \rho \cdot A \cdot V^3 \cdot C_p \quad (2.7)$$

Em que, “ P_{vento} ” é a potência do vento incidente (W), “ ρ ” representa a densidade do ar (kg/m^3), “ A ” é a área do rotor (m^2), “ V ” representa a velocidade do vento (m/s), “ $P_{útil}$ ” é a potência efetivamente entregue pela turbina (W), “ η_a ” igual ao rendimento

aerodinâmico do gerador, “ η_m ” igual ao rendimento mecânico, “ η_e ” igual ao rendimento elétrico e “ C_p ” representa o coeficiente de potência do aerogerador.

Devido ao fator cúbico da velocidade do vento, tendo em vista que a densidade do ar para uma mesma região tem pouca variabilidade e que o coeficiente de potência da turbina é conhecido, basta saber a velocidade do vento para se estimar a potência útil que um aerogerador pode fornecer a rede.

2.3 Demanda elétrica

Segundo a resolução da ANEEL nº 456 de 29/11/2000, define-se demanda como a média das potências elétricas ativas ou reativas, solicitadas ao sistema elétrico pela parcela da carga instalada em operação na unidade consumidora, durante um intervalo de tempo especificado.

A demanda serve para dimensionar e pagar a implantação e conservação dos ativos, materiais e equipamentos, necessários ao transporte da energia elétrica entre a distribuidora e a unidade consumidora. A cobrança da demanda é determinada pela demanda contratada, porém se houver ultrapassagem, será determinada pela demanda medida, que é a maior demanda de potência ativa, verificada por medição, integralizada no intervalo de 15 minutos durante o período de faturamento, expressa em quilowatts (kW).

Demanda ativa é medida em quilowatts (kW) e a demanda reativa é medida em quilo Volt Ampère reativo ($kvar$), esta última pode ser de natureza capacitiva ou indutiva.


Os consumidores de energia possuem características diferenciadas de consumo, de acordo com a natureza de sua carga: residencial, comercial, industrial, rural, iluminação pública e serviço público. Portanto, suas curvas de demanda apresentam comportamento diferenciado ao decorrer do dia.

A [Figura 8](#) representa uma curva típica do SIN de um consumidor residencial. A característica desse tipo de consumidor é o aumento abrupto de consumo entre 18 e 21 horas, devido ao retorno da população às residências nesse período.

A [Figura 9](#) ilustra o comportamento do consumo das indústrias ao longo de um dia, percebe-se que este tipo de consumidor apresenta um consumo elevado durante todo o dia, com exceção do horário de ponta, cujo consumo diminui consideravelmente.


A curva de carga de um consumidor comercial caracteriza-se por elevar o seu consumo por volta das 8 horas mantendo-se constante durante o dia. No horário de ponta, ocorre outro pico de demanda, [Figura 10](#).

Figura 8 – Curva de demanda típica para consumidor residencial




Fonte: COUTINHO (2010)

Figura 9 – Curva de demanda típica para consumidor industrial



Fonte: COUTINHO (2010)

Figura 10 – Curva de demanda típica para consumidor comercial



Fonte: COUTINHO (2010)

Percebe-se que o horário tem influência direta no consumo de energia. Além disso, os comportamentos apresentados nas curvas de demanda podem sofrer algumas alterações dependendo do dia da semana, estação do ano, ou vigência do horário de

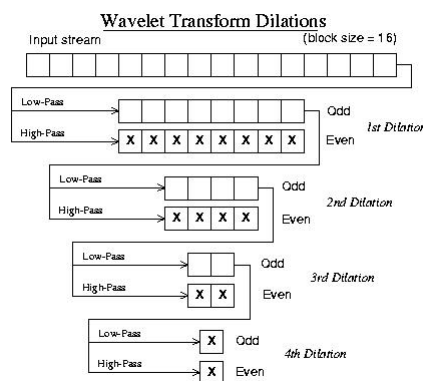
verão, por exemplo. Mas de forma geral, para a mesma unidade consumidora, existe um comportamento periódico diário durante o ano.

2.4 Decomposição wavelet

As *wavelets* são funções matemáticas que são particionadas em diversas subfunções, de acordo com uma escala de interesse. Essa escala varia conforme o nível de descrição que se deseja da subfunção (MALLAT, 1987).

Para a decomposição, é aplicado um algoritmo piramidal que irá fazer uma filtragem passa-baixa nos elementos de posição par e passa-alta nos elementos de posição ímpar do sinal. A Figura 11 mostra a representação das sucessivas filtragens visando a decomposição do sinal (MALLAT, 1987).

Figura 11 – Decomposição wavelet de 4 níveis



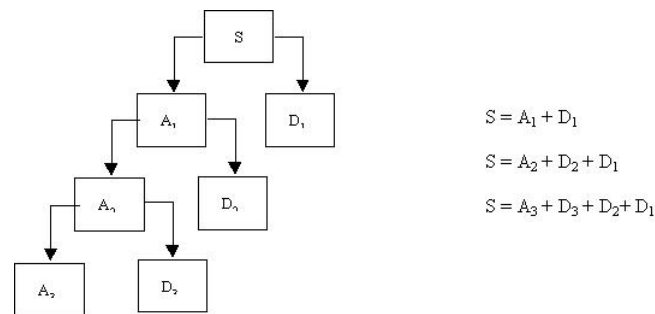
Fonte: EDWARDS (1991).

O sinal é dividido em aproximação (A_n) e detalhe (D_n). Essa aproximação é então dividida em uma outra aproximação de segundo nível e mais um detalhe, e o processo se repete. Para uma decomposição de nível n , há $n + 1$ caminhos possíveis para decompor ou codificar o sinal. De forma que, a soma dos detalhes com a aproximação resulta no sinal original. Como mostra a Figura 12, para uma decomposição de 3 níveis.

Essa propriedade, torna essa ferramenta interessante para o uso associado à redes neurais. Uma vez que é possível dividir o sinal a ser analisado em subsinais com bandas de frequência diferentes de modo que, ao aplicar uma rede neural específica para cada subsinal, o processo de treinamento torne-se mais eficaz e aumente o grau de acerto da rede neural.

A Figura 13 mostra um caso real de uma decomposição de 5 níveis. Percebe-se um sinal senoidal e que sua frequência de oscilação aumenta consideravelmente no instante


Figura 12 – Decomposição wavelet de 3 níveis



Fonte: EYNG e VERGARA (2000).

500. Aplicando a decomposição wavelet, ocorre que os detalhes contêm as componentes de frequências mais altas e a aproximação as componentes mais baixas. Além disso, nota-se que ao aumentar o nível da decomposição, os detalhes possuem componentes de frequência mais baixas. Por exemplo, é possível notar que o detalhe d_2 possui um sinal de frequência mais elevada do que d_5 .

Figura 13 – Sinais da aproximação e detalhes para uma decomposição de 5 níveis




Fonte: Próprio autor.

Um outro tipo de decomposição, chamado *wavelet packet*, também é implementado neste projeto. A diferença principal é a decomposição dos detalhes obtidos na decomposição *wavelet* padrão. Conforme mostra a Figura 14.

Neste caso, para uma decomposição de nível n , são obtidos 2^n subsinais. Dessa forma, é possível caracterizar o sinal em mais bandas de frequência, o que pode trazer melhores resultados em relação ao grau de acerto das redes neurais aplicadas a cada

subsinal.

Figura 14 – Decomposição wavelet packet



Fonte: MathWorks (2016).

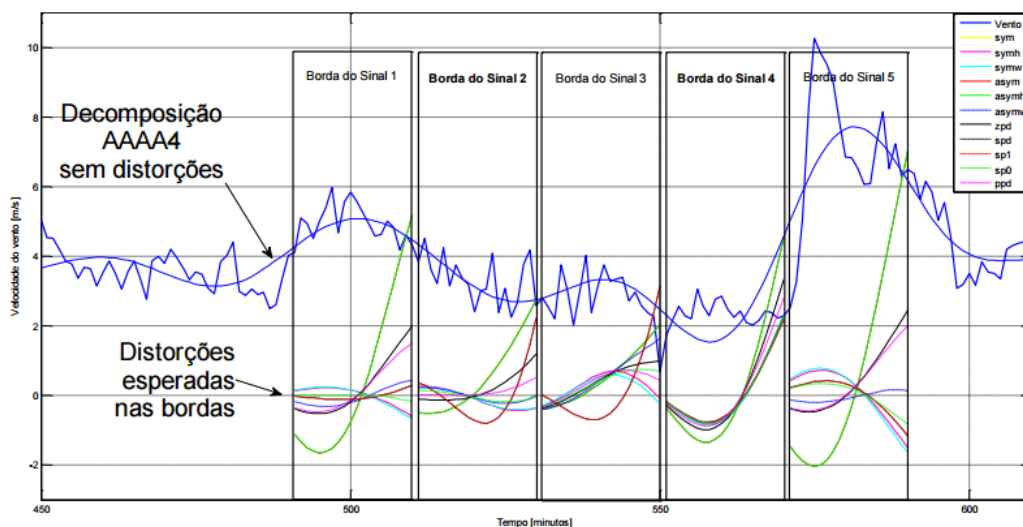
2.4.1 Efeito de borda

Efeitos de borda são comuns no processamento de sinais de comprimento finito. Quando a wavelet chega próximo ao limite do sinal, o cálculo da convolução requer valores inexistentes, que estariam além da fronteira (SU; LIU; LI, 2012). Isso cria uma distorção conhecida como efeito de borda, fruto de informação desconhecida além da fronteira do sinal.

Para lidar com o efeito de borda diversos métodos de extensão de borda tem sido discutidos na literatura (SU; LIU; LI, 2012) (RANA; KOPRINSKA, 2016). No *MatLab* existem 11 métodos tradicionais de extensão de borda, são eles: Preenchimento com zeros ('zpd'); Extensão simétrica ('sym', 'symh' e 'symw'); Extensão Anti-simétrica ('asym', 'asymh' e 'asymw'); Preenchimento com derivada de primeira ordem ('spd' ou 'sp1'); Preenchimento com derivada de ordem zero ('sp0'); Preenchimento periódico ('ppd' e 'per').

Em (CHRISTO; BERNABE, 2016), os métodos de extensão de borda, listados acima, foram aplicados em cinco seguimentos de sinais de velocidade do vento, com espaçamento de 20 passos (horas) entre eles. A Figura 15 apresenta de forma sobreposta parte de uma série de velocidade de vento, a decomposição AAAA4 e as distorções encontradas nas bordas dos cinco sinais de teste, quando comparados a decomposição AAAA4 sem distorções. O sinal em azul de maior frequência, é um sinal típico de velocidade do vento, o sinal em azul com característica senoidal refere-se a componente AAAA4 da decomposição sem distorção de borda deste sinal do vento. Abaixo destes sinais, são apresentados os erros absolutos entre a decomposição sem efeito de borda e a decomposição, dos sinais 1 a 5, com distorção de borda para cada um dos 11 métodos de extensão de borda com a intenção de verificar qual método é mais eficaz para minimizar a distorção de borda.


Figura 15 – Exemplos do efeito de borda, em cinco sinais, para diferentes técnicas de preenchimento



Fonte: CHRISTO e BERNABE (2016).

A Figura 16, apresenta em forma de gráfico de barras o erro quadrático médio obtido para cada um dos 11 métodos, considerando os últimos 20 elementos da borda, em cada um dos cinco sinais testados.

Figura 16 – Erro médio quadrático na borda dos cinco sinais, para diferentes tipos de preenchimento



Fonte: CHRISTO e BERNABE (2016).

O método que na maioria dos casos apresentou a menor distorção de borda foi o preenchimento com derivada de ordem zero ('sp0'). No entanto, os resultados mostram que nenhum dos métodos tradicionais permite eliminar o efeito de borda em sua totalidade,

porém podem minimizá-los. Assim, é necessário recorrer a métodos alternativos, como os abordados por (SU; LIU; LI, 2012), por (RANA; KOPRINSKA, 2016), ou ainda descartar parte da borda da decomposição. Este efeito é um dos principais limitantes para a aplicação da decomposição de *wavelet* para realizar previsão.

2.5 Redes neurais

As Redes Neurais Artificiais são técnicas de inteligência computacional que vêm sendo aplicadas a uma enorme gama de problemas com sucesso. Dentre as principais áreas de aplicação das Redes Neurais Artificiais podemos citar sistemas de controle, reconhecimento de padrões e aproximação de funções. (SILVA, 2005)

Redes neurais apresentam características similares e análogas as observadas no funcionamento do cérebro humano, destacando-se:


- Conhecimento é adquirido ou “aprendido” pela rede neural, como no cérebro humano, através de um processo de aprendizado;
- Pesos existentes nas conexões entre neurônios artificiais, análogos às sinapses em neurônios biológicos, são responsáveis por armazenar o conhecimento aprendido;
- Apresenta como o cérebro humano, a capacidade de generalização baseada no conhecimento aprendido. Isto significa que uma rede neural consegue produzir saídas adequadas para entradas não observadas no seu processo de treinamento.

2.5.1 Neurônio artificial

O elemento processador básico de uma rede neural artificial é o neurônio artificial. Como mostra a [Figura 17](#), o modelo apresenta os seguintes componentes principais:

- Um conjunto de sinapses ou conexões de entrada, sendo cada entrada ponderada por um peso sináptico, que indica a sua influência na saída da unidade;
- Uma junção de soma, responsável pela combinação aditiva das entradas ponderadas pelos pesos sinápticos, que produz um nível de atividade responsável por ativar ou não a função de ativação;
- A função de ativação, geralmente não linear, responsável pela ativação da saída ou resposta do elemento processador é ativada se o nível de atividade exceder um certo limite (*threshold*). Se ativada a unidade produz uma determinada resposta de saída.

Figura 17 – Modelo de neurônio artificial



Fonte: ZAMBIASI (2011)


De forma simplificada:

- Sinais de entrada: $x_1 + x_2 + x_3 + \dots + x_n$;
- Pesos sinápticos: $w_{k1} + w_{k2} + w_{k3} + \dots + w_{kn}$;
- Threshold: b_k ;
- Nível de atividade: $v = x_1w_1 + x_2w_2 + x_3w_3 + \dots + x_nw_n$;
- A saída será: $y = 1$, se $a \geq T$; $y = 0$, se $a < T$.

2.5.2 Topologia e arquitetura de redes neurais

Uma rede neural pode ter uma ou várias camadas. As redes que possuem uma única camada são as redes que possuem um nó entre uma entrada e uma saída da rede. Esse tipo de rede é indicado para a solução de problemas linearmente separáveis. Já as redes multicamadas possuem uma ou mais camadas entre as camadas de entrada e saída. Essas camadas são chamadas de camadas escondidas (*hidden*, intermediárias ou ocultas). Observe a topologia de uma rede neural multicamadas na [Figura 18](#).

Figura 18 – Rede neural multicamadas



Fonte: [CULTURAMIX \(2015\)](#)


2.5.3 Redes perceptron multicamadas (MLP)

Uma das formas mais simples para utilizar uma rede neural em classificação é a rede perceptron, formada por uma camada de entrada conectada a uma única saída, que possui a função de ativação degrau. Sua limitação é conseguir classificar apenas conjuntos linearmente separáveis, utilizando para isso a regra delta em seu treinamento. Existe também o perceptron multicamadas, com uma arquitetura mais complexa envolvendo camadas ocultas, conforme mostra a [Figura 19](#).

O treinamento de uma rede MLP pode ser dividido em dois sentidos, direto e inverso. No sentido direto, o fluxo de informação ocorre dos neurônios de entrada, passando pelos neurônios intermediários, até chegar no neurônio de saída. O sinal de saída é comparado com o sinal desejado, e um sinal de erro é gerado. Este sinal percorre a rede no sentido inverso, da saída para entrada para ajustar os pesos e minimizar o erro quadrático médio da saída. Esse ciclo permanece até que o resultado seja aceitável.

Ainda existem redes recorrentes, que utilizam a saída como entrada. São basicamente redes realimentadas com a intenção de diminuir o erro quadrático médio. Porém, essas redes caracterizam-se pelo alto custo computacional.

Figura 19 – Rede MLP



Fonte: [HAYKIN \(2001\)](#)

3 Metodologia adotada

O projeto proposto foi dividido em 3 etapas de desenvolvimento: coleta e tratamento de dados, implementação dos modelos de previsão e análise qualitativa entre os modelos obtidos.

3.1 Coleta e tratamento de dados

Nesta etapa, foram reunidos os dados do processo. Os dados utilizados para previsão de velocidade do vento e irradiância solar foram coletados da estação meteorológica de Petrolina, através do projeto SONDA. Já os utilizados para previsão de demanda energética foram coletados da memória de massa da Universidade Federal do Espírito Santo.

Inicialmente, foi observado que os dados estavam com alguns erros de medição, *not a number (NaN)*. Dessa forma, as amostras *NaN* foram substituídas pela média aritmética entre sua antecessora e sucessora.

Outro problema encontrado foi em relação a resolução dos dados coletados. Os dados de irradiância solar estavam amostrados com um minuto de resolução, os dados de velocidade de vento com periodicidade de 10 minutos e os de demanda elétrica com periodicidade de quinze minutos. Por isso, esses dados foram integralizados, através da média aritmética entre as amostras, de forma que todos os três estivessem na mesma resolução, 1 hora.

Em seguida, os dados foram normalizados segundo a [Equação 3.1](#). A normalização de dados de entrada em uma rede neural pode trazer algumas vantagens como uma redução dos erros e diminuição no tempo de processamento. Outro fator importante é que os algoritmos de ajuste de peso normalmente priorizam o ajuste de entradas cujo erro é maior, assim uma diferença na magnitude das variáveis de entrada pode causar problemas no aprendizado da rede ([SOLA; SEVILLA, 1997](#)). Portanto todos os dados foram normalizados entre 0.05 e 0.95. Os dados retornam a seus valores originais empregando-se a [Equação 3.2](#).

$$x_n = 0.05 + \frac{x - x_{min}}{x_{max} - x_{min}} \times 0.9 \quad (3.1)$$

$$x = x_{min} + \frac{x_n - 0.05}{0.95} \times (x_{max} - x_{min}) \quad (3.2)$$

3.2 Implementação dos modelos

Depois que os dados foram tratados, 75% dos dados foram utilizados para treinamento das redes neurais e os 25% restantes, para validação dos modelos de previsão encontrados. Desses 75% dos dados o Matlab usa 70% desses dados para treinamento, 15% para teste e 15% para validação.

Para todos os modelos foram utilizados somente uma camada oculta, com função de ativação *sigmoid*, e na camada de saída função de ativação linear, configuração *default* do Matlab. O algoritmo de treinamento utilizado foi a *Bayesian Regularization*.

Quatro modelos de previsão foram implementados para cada variável de interesse (irradiância solar, velocidade do vento e demanda ativa e reativa) utilizando redes neurais para previsão de cada variável, no software MatLab. São eles:

- Rede neural: RNA;
- Rede neural + variáveis exógenas: RNA+E;
- Rede neural + wavelets: RNA+W;
- Rede neural + wavelet packet: RNA+WP.

No primeiro modelo foi utilizado apenas uma rede neural, cuja série de entrada da rede era igual a seu *target*, saída. Por isso, foi empregada a rede tipo NAR (*Nonlinear Autoregressive*, são utilizadas para prever uma série de dados $y(t)$ baseando-se em seus d últimos valores, disponível no *toolbox ntstool* do *Matlab*). Este modelo foi utilizado para definir a configuração de rede neural para cada uma das quatro previsões (irradiância solar, velocidade do vento e demanda ativa e reativa). A princípio, foi fixado o número de neurônios na camada oculta igual a um e então foi variado o número de atrasos de tempo a serem considerados nos dados de entrada. O número de atrasos que proporcionou o maior grau de acerto da rede foi escolhido e fixado. Em seguida, foi realizado o mesmo procedimento anterior para determinar o número de neurônios na camada oculta. Esse procedimento, foi aplicado com a intenção de obter um modelo de previsão com o melhor grau de acerto possível.

No segundo modelo, foi empregada a mesma saída, porém na entrada da RNA, foram utilizadas, além da série temporal do primeiro modelo, variáveis auxiliares com certo grau de correlação com a variável de interesse. Essas variáveis são apresentadas nas seções subsequentes. Por isso, foi aplicada a rede tipo NARX (*Nonlinear Autoregressive with External Input*, são utilizadas para prever uma série de dados $y(t)$ baseando-se em seus d_1 últimos valores e nos d_2 últimos valores de outras séries $x_1(t), x_2(t) \dots x_n(t)$, disponível no *toolbox ntstool* do *Matlab*). Para determinar o número de atrasos das variáveis auxiliares na entrada da rede, foi utilizado o mesmo procedimento descrito no parágrafo acima.

No terceiro e no último modelo, as entradas e saídas da rede foram, justamente, os detalhes e a aproximação da série, obtidos através da decomposição *wavelet*. Novamente, foi empregado a rede tipo *NAR*. Dessa forma, cada rede é responsável por realizar a previsão de uma banda de frequência específica, possibilitando um aprendizado mais eficaz e diminuindo os erros de previsão. Essa escolha será melhor abordada na [subseção 4.1.3](#).

3.3 Análise qualitativa entre os modelos obtidos

Nesta etapa, foram realizados estudos comparativos a fim de se determinar o modelo mais adequado para previsão com horizonte de um dia a frente. Foram observadas as curvas prevista e real com intuito de comparar se a previsão representava os valores de pico e variações abruptas encontradas na série real. Além disso, conclusões foram tomadas baseando-se nos parâmetros R^2 (também chamado de coeficiente de determinação, é uma medida de ajustamento de um modelo estatístico linear generalizado em relação aos valores observados. O R^2 varia entre 0 e 1, indicando, em percentagem, o quanto o modelo consegue explicar os valores observados. Quanto maior o R^2 , mais explicativo é o modelo e melhor ele se ajusta à amostra) e MSE (erro quadrático médio, também chamado de risco quadrático, quanto mais próximo de zero, menor o erro entre os valores estimados e reais).

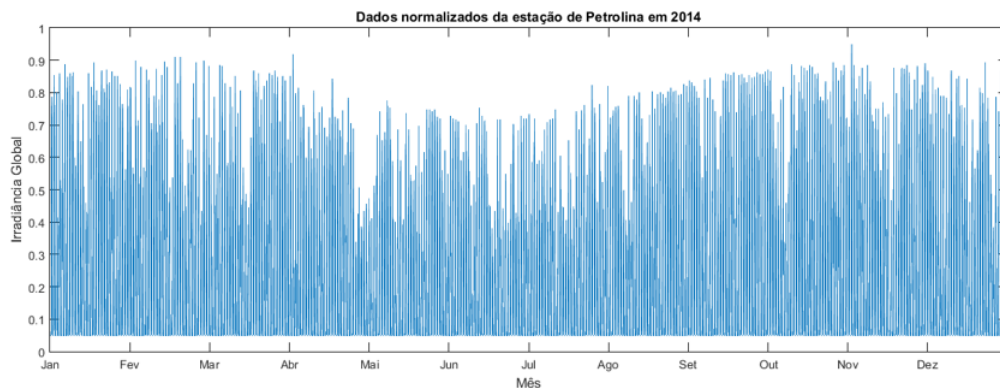
4 Resultados

4.1 Previsão solar

Os dados utilizados referem-se ao período de janeiro à dezembro de 2014, do projeto SONDA, da estação de Petrolina em Pernambuco. No total, são 525.600 mil amostras, com resolução de 1 minuto. Esses dados foram tratados segundo a [seção 3.1](#) e obtidos 8.760 mil dados com resolução de 60 minutos.

Na [Figura 20](#) é apresentada a série temporal obtida durante o ano de 2014. A série apresentada já está normalizada e com resolução de 1h. Percebe-se que ela possui comportamento similar a curva solar ideal apresentada na [Figura 4](#).

Figura 20 – Irradiância solar normalizada em Petrolina com resolução de 1h no ano de 2014



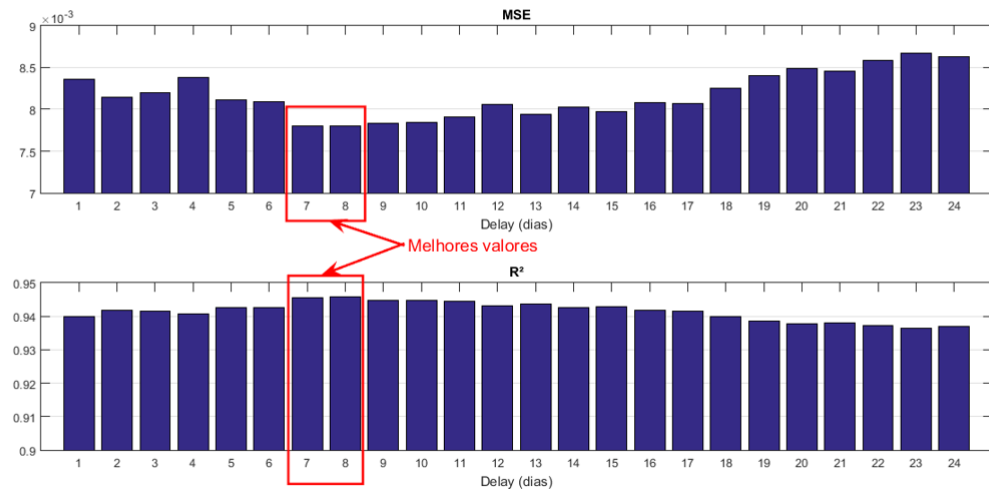
Fonte: Próprio autor.

4.1.1 Modelo RNA

Inicialmente, foi desenvolvido um sistema de previsão utilizando apenas a série temporal de irradiância global como entrada e target de uma RNA. Neste caso, o principal fator a se levar em consideração é justamente a escolha do número de neurônios da camada oculta e quantos atrasos de tempo (*delay*) serão utilizados para realizar a previsão.

Para determinar o número de neurônios e atrasos de tempo foram testadas em torno de 40 configurações de redes, seguindo a metodologia adotada na [seção 3.2](#). A [Figura 21](#) mostra que neste caso, o melhor R^2 e menor MSE ocorreram para atrasos de tempo de sete e oito dias (168 e 192 horas).

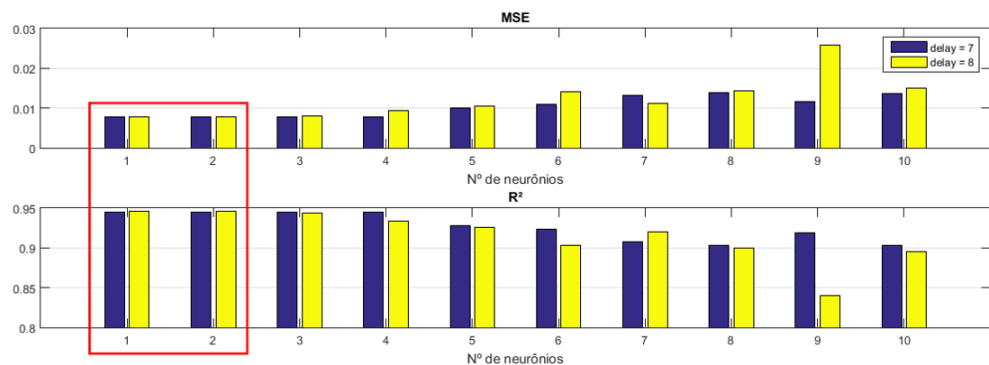
Figura 21 – Análise do número de delays a ser usado na RNA para previsão solar



Fonte: Próprio autor.

Visto isso, seguindo a metodologia da [seção 3.2](#), variou-se o número de neurônios de 1 a 10, com a intenção de verificar se o aumento do número de neurônios na camada oculta implicaria na melhora do grau de acerto da rede neural. Neste caso, a [Figura 22](#) mostra que, para um e dois neurônios foram obtidos os maiores valores de R^2 e menores MSE.


Figura 22 – Análise do número de neurônios na camada oculta da RNA para previsão solar



Fonte: Próprio autor.

De acordo com a [Figura 21](#) e [Figura 22](#) e do ponto de vista do custo computacional, foi escolhido o modelo considerando 8 dias, ou 192 horas, de atraso de tempo com um neurônio na camada oculta, como mostra a [Figura 23](#).

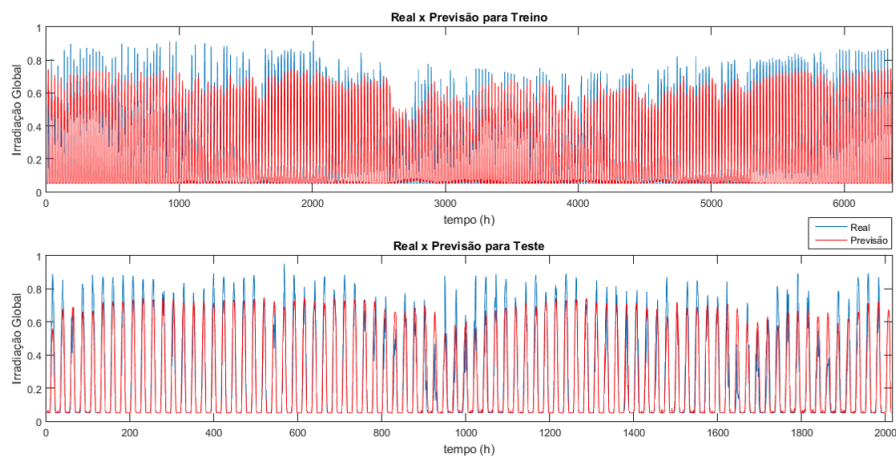
Figura 23 – Análise do número de neurônios na camada oculta da RNA para previsão solar



Fonte: Próprio autor.

Determinada a configuração da rede neural, a [Figura 24](#) mostra as séries temporais prevista e medida. Percebe-se que a previsão não acompanha os picos da série real. Na [Figura 25](#) é mostrada as primeiras 192 amostras da série de dados de teste. Na [Tabela 1](#) são apresentados os índices de desempenhos R^2 e MSE. Observa-se que a RNA não reproduz os comportamentos abruptos do nível de irradiância, porém representa bem valores médios.

Figura 24 – Resultados RNA para previsão solar




Fonte: Próprio autor.

Tabela 1 – Resultados da previsão solar para RNA

	MSE	R
Treino	0.0061032	0.94677
Teste	0.0078279	0.94574

Fonte: Próprio autor.

Figura 25 – Comportamento da previsão da RNA para previsão solar



Fonte: Próprio autor.

4.1.2 Modelo RNA com entradas exógenas


A escolha de variáveis auxiliares se baseou no critério de correlação cruzada entre a variável de interesse e a possível variável exógena. A Figura 26 mostra que a curva solar, Figura 4, tem elevada correlação com a variável de interesse a cada 12 horas, alcançando valores de até 80%. Assim como a derivada de primeira ordem do sinal, Figura 27, com correlação em torno de 50% com a irradiância solar a cada 12 horas, aproximadamente. A derivada de primeira ordem da série pode ser observada na Figura 28.

A Figura 26, Figura 27 e as seguintes são interpretadas da seguinte forma: para cada valor de atraso d tem-se a correlação entre $y(t)$ e $x(t - d)$, sendo y (irradiância solar) a saída e x a entrada em questão, neste caso, curva solar ideal e derivada de primeira ordem, respectivamente. A linha azul presente nas figuras supracitadas representa a mínima correlação para que esta seja estatisticamente significativa. Em todos os casos aqui abordados considerou-se um intervalo de confiança de 95%, ou seja, dado que a correlação é maior em módulo que a linha azul tem-se pelo menos 95% de chance de haver uma correlação real entre as duas variáveis.

Observa-se que a curva solar e derivada de primeira ordem possuem uma correlação significativa com a irradiância solar. Dessa forma fica fundamentada a utilização dessas variáveis como entradas exógenas da rede estudada.

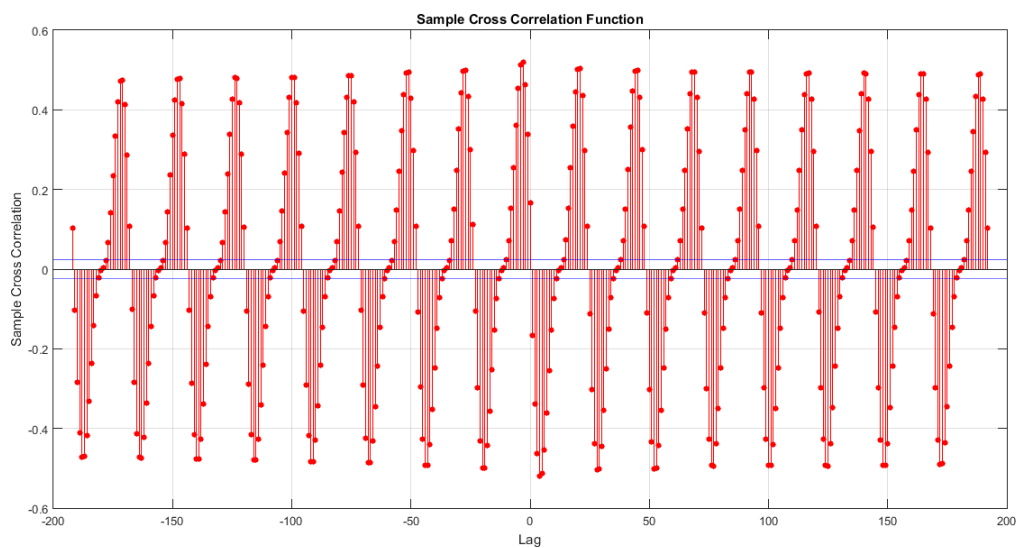
Para determinar o atraso de tempo das variáveis exógenas foi utilizado o mesmo método explicitado na seção 3.2. De acordo com a Figura 29 percebe-se que o menor valor de MSE e maior valor de R^2 ocorreram para *delay* igual a oito dias. Portanto, para esta topologia de rede foi considerado um atraso de tempo de 192 horas. A Figura 30 mostra a topologia de RNA utilizada.

Figura 26 – Correlação cruzada entre a curva solar e irradiância solar medida



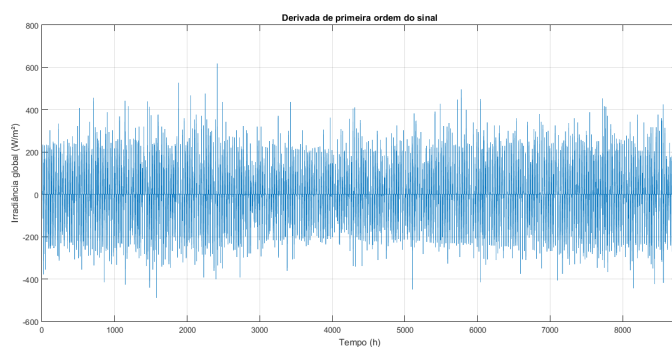
Fonte: Próprio autor.

Figura 27 – Correlação cruzada entre irradiância solar medida e sua derivada de primeira ordem




Fonte: Próprio autor.

Figura 28 – Derivada de primeira ordem da série temporal de irradiância solar




Fonte: Próprio autor.

Figura 29 – Análise do número de delays das variáveis exógenas para previsão solar



Fonte: Próprio autor.

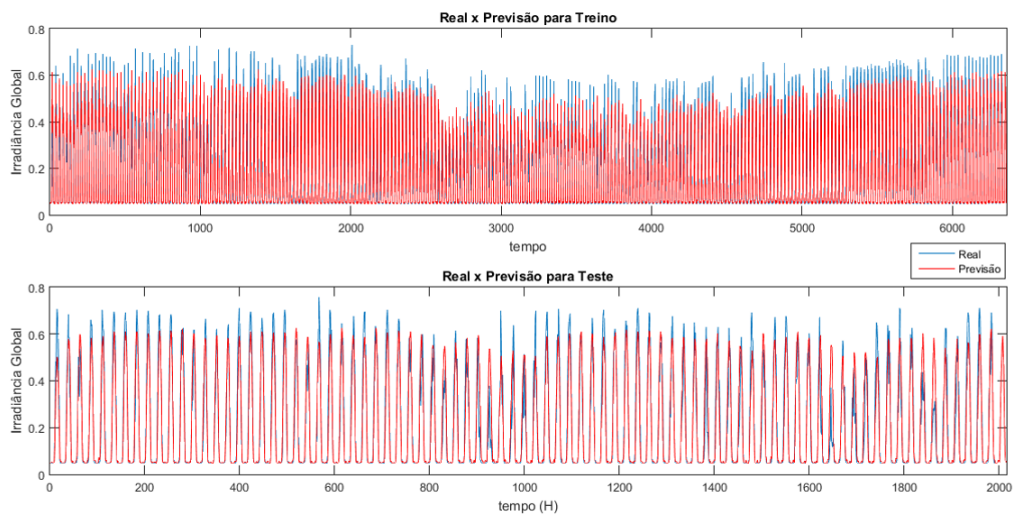
Figura 30 – Topologia da RNA + E para previsão solar



Fonte: Próprio autor.

Determinada a configuração da rede neural RNAE, a [Figura 31](#) mostra as séries temporais prevista e medida. Percebe-se que a previsão não acompanha os picos da curva real, assim como aconteceu para o modelo RNA do item anterior. Na [Figura 32](#) é apresentada a mesma série para dados de teste, agora com as 192 primeiras amostras. Pode-se notar que, como no item anterior, a previsão não acompanha variações abruptas da irradiância solar. Na [Tabela 2](#) são mostrados os índices de desempenhos R^2 e MSE. Observa-se que os resultados obtidos foram ligeiramente superiores em relação ao grau de acerto do modelo RNA, cerca de 0,2% de ganho em R^2 para dados de teste.

Figura 31 – Resultados RNA + E para previsão solar



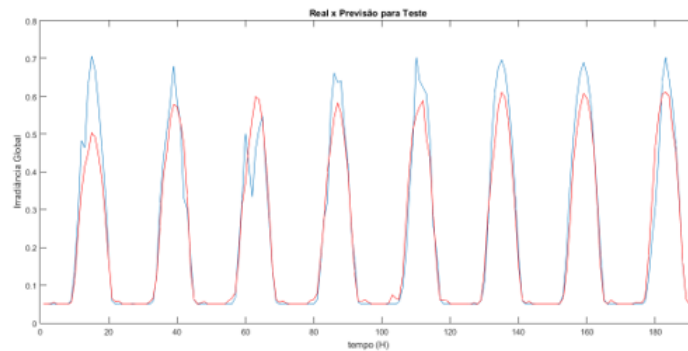
Fonte: Próprio autor.

Tabela 2 – Resultados da previsão solar para RNA + E

	MSE	R
Treino	0.0035028	0.95017
Teste	0.0045263	0.94779

Fonte: Próprio autor.

Figura 32 – Comportamento da previsão da RNA + E para previsão solar



Fonte: Próprio autor.


Esta configuração de RNA mostrou que a inserção de variáveis exógenas para previsão é um caminho alternativo a ser pesquisado e desenvolvido. Variáveis como nebulosidade, temperatura do ar e outras podem vir a ser interessantes para serem utilizadas num modelo similar a este implementado. Porém, até o momento do desenvolvimento deste modelo, o autor não conseguiu reunir dados confiáveis de um ano inteiro e por isso essas outras variáveis supracitadas não foram investigadas.

4.1.3 Modelo RNA com uso de Wavelet

O modelo de previsão proposto neste item baseia-se na [Figura 33](#). Inicialmente os dados foram coletados e tratados, de acordo com a [seção 3.1](#). Em seguida, foi aplicada decomposição *wavelet* de 4 níveis. Cada subsinal foi submetido a uma RNA e o resultado de cada RNA foi somado. Para esse nível de decomposição foram necessárias 5 RNA, uma para a aproximação e quatro para os detalhes. A previsão de cada RNA foi somada e o resultado comparado com o *target*. Foi considerada a mesma topologia de rede utilizada no modelo RNA para cada uma das 5 redes neurais utilizadas neste modelo, [Figura 23](#).


Determinada a configuração da rede neural, a [Figura 34](#) mostra as séries temporais prevista e medida. Percebe-se que, neste modelo, a previsão alcança os picos da curva real, ao contrário dos modelos anteriores. Na [Figura 35](#) é mostrada a mesma série para dados de teste, agora para as primeiras 192 horas. Pode-se notar que, como nos itens anteriores, a previsão não acompanha variações abruptas da irradiância solar. Na [Tabela 3](#) são mostrados os índices de desempenhos R^2 e MSE. Observa-se que os resultados obtidos foram melhores que os modelos até agora apresentados, aproximadamente 2% maior para R^2 para os dados de teste em relação ao modelo RNAE.

Figura 33 – Modelo de previsão RNA + W para previsão solar



Fonte: Próprio autor.

Figura 34 – Resultados RNA + W para previsão solar




Fonte: Próprio autor.

Tabela 3 – Resultados da previsão solar para RNA + W

	MSE	R
Treino	0.0031883	0.97328
Teste	0.0042536	0.97076

Fonte: Próprio autor.

Figura 35 – Comportamento da previsão da RNA + W para previsão solar



Fonte: Próprio autor.


4.1.4 Modelo RNA com uso de Wavelet Packet

O modelo de previsão proposto neste item baseia-se na [Figura 33](#), porém utilizando a decomposição *wavelet packet*. Inicialmente, os dados foram coletados e tratados, de acordo com [seção 3.1](#). Em seguida, foi aplicada decomposição wavelet packet de 4 níveis. Cada subsinal foi submetido a uma RNA e o resultado de cada RNA foi somado. Para esse nível de decomposição foram necessárias 16 RNA. A previsão de cada RNA foi somada e o resultado comparado com o *target*. Foi considerada a mesma topologia de rede utilizada no primeiro modelo RNA para cada uma das 16 redes neurais utilizadas neste modelo, [Figura 23](#).

Determinada a configuração das redes neurais, a [Figura 36](#) mostra as séries temporais prevista e medida. Percebe-se que, neste modelo, a previsão acompanha os picos da curva real. Na [Figura 37](#) é apresentada a mesma série para dados de teste, agora para as primeiras 192 amostras. Pode-se notar que, ao contrário dos itens anteriores, esta rede conseguiu acompanhar variações abruptas da irradiância solar e reproduzir os valores reais de irradiância solar global com R^2 de até 99,5%. Na [Tabela 4](#) são mostrados os índices de desempenhos R^2 e MSE. Observa-se que os resultados obtidos foram ainda melhores que os


obtidos no modelo anterior, RNA+W. Houve um ganho de 2% em R^2 , aproximadamente, para dados de teste em relação ao modelo RNA+W.

Figura 36 – Resultados RNA + WP para previsão solar



Fonte: Próprio autor.

Figura 37 – Comportamento da previsão da RNA + WP para previsão solar



Fonte: Próprio autor.

Tabela 4 – Resultados da previsão solar para RNA + WP

	MSE	R
Treino	0.00070578	0.99449
Teste	0.0011312	0.99251

Fonte: Próprio autor.


4.1.5 Conclusão

Analisando a [Figura 38](#) e a [Tabela 5](#), que resumem os resultados obtidos neste capítulo, percebe-se que o ultimo modelo (RNA+WP) foi o que obteve melhor resultado. O projeto mostrou que é possível estimar níveis de irradiância global com até 24 horas a frente com precisão de 99,25%, aproximadamente. Dessa forma, seria possível estimar quanto de energia solar, em determinada região, será gerada no próximo dia. Com isso, é possível tomar decisões em relação ao sistema de energia de modo que diminua custos e aumente sua confiabilidade.

Vale ressaltar que o modelo (RNA+E) mostrou-se promissor, porém é necessário obter dados confiáveis que possibilitem o estudo e aplicação do modelo.

A aplicação desta metodologia para outras série temporais de outros locais é extremamente viável. Porém, não é garantido desempenho semelhante.

Figura 38 – Desempenho dos modelos desenvolvidos para previsão solar



Fonte: Próprio autor.

Fonte: Próprio autor.

Tabela 5 – Tabela comparativa dos modelos desenvolvidos para previsão solar

		TREINO			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0061032	0,0035028	0,0031883	0,0007058
R ²		0,94677	0,95017	0,97328	0,99449
		TESTE			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0078279	0,0045263	0,0042536	0,0011312
R ²		0,94574	0,94779	0,97076	0,99251


Fonte: Próprio autor.

4.2 Previsão Eólica

Os dados utilizados referem-se ao período de janeiro à dezembro de 2010, do projeto SONDA, da estação de Petrolina em Pernambuco. No total, são 52.560 mil amostras de velocidade do vento a 25 metros de altura, com resolução de 10 minutos. Esses dados foram tratados segundo a [seção 3.1](#), obtendo-se uma nova série temporal de 8.760 mil dados, mesma resolução utilizada na previsão solar.

Na [Figura 39](#) é apresentada a série temporal obtida durante o ano de 2010. A série já está normalizada e com resolução de 1h. Percebe-se que os dados de vento possuem comportamento mais imprevisível que os dados de irradiância solar, por exemplo, que possuem certa periodicidade diária. Esse fato implica diretamente no grau de acerto da rede neural.

Figura 39 – Velocidade do vento normalizada em petrolina a 25 metros de altura no ano de 2010




Fonte: Próprio autor.

4.2.1 Modelo RNA

Assim como realizado para previsão solar, para se determinar o número de neurônios e atrasos foram testadas, em torno de, 55 configurações de redes seguindo a metodologia adotada na [seção 3.2](#). A [Figura 40](#) mostra que neste caso, o maior R^2 e menor MSE ocorreram para atrasos de tempo entre dois e quatro dias.


Visto isso, foi fixado o número de atrasos e o número de neurônios na camada oculta foi variado, conforme é orientado na [seção 3.2](#). Neste caso, a [Figura 41](#) mostra que, para um neurônio e 3 dias de *delay* foi obtido o maior R^2 e menor MSE. A [Figura 42](#) mostra a topologia de RNA utilizada.

Figura 40 – Análise do número de *delays* a ser usado na RNA para previsão eólica




Fonte: Próprio autor.

Figura 41 – Análise do número de neurônios na camada oculta da RNA para previsão eólica



Fonte: Próprio autor.


Figura 42 – Topologia de RNA utilizada para previsão eólica



Fonte: Próprio autor.


Determinada a configuração da rede neural, a [Figura 43](#) mostra as séries temporais prevista e medida. Percebe-se que a previsão, apesar de acompanhar a tendência da série temporal, não representa os picos e variações do sinal medido. Na [Figura 44](#) é mostrada a mesma série para dados de teste, agora para as 192 primeiras amostras. Pode-se notar que a previsão não acompanha variações abruptas da velocidade do vento. Na [Tabela 6](#) são mostrados os índices de desempenhos R^2 e MSE.

Figura 43 – Resultados RNA para previsão eólica



Fonte: Próprio autor.

Figura 44 – Comportamento da previsão da RNA para previsão eólica



Fonte: Próprio autor.

Tabela 6 – Resultados da previsão eólica para RNA

	MSE	R
Treino	0.011874	0.65005
Teste	0.01325	0.5627


Fonte: Próprio autor.

4.2.2 Modelo RNA com entradas exógenas

A escolha de variáveis auxiliares se baseou no critério de correlação cruzada entre a variável de interesse e as possíveis variáveis exógenas, já explicitado na [subseção 4.1.2](#). Foram analisadas a direção do vento, temperatura do ar e derivada de primeira ordem da velocidade do vento. A [Figura 45](#), [Figura 46](#) e [Figura 47](#) comprovam que as variáveis exógenas testadas possuem uma correlação significativa com a velocidade do vento.


Para determinar o delay das variáveis exógenas foi utilizado o mesmo método explicitado na [seção 3.2](#). De acordo com a [Figura 48](#) percebe-se que, para MSE, os menores valores ocorreram para *delay* igual a nove e dez dias, entretanto, o maior R^2 ocorreu para sete dias. Neste trabalho, o R^2 é a principal variável para comparar desempenho, além disso, a diferença de MSE para 7, 9 e 10 dias de *delay* está na quarta casa decimal, enquanto que, para R^2 está logo na segunda casa. Portanto para esta topologia de rede foi considerado um atraso de tempo de sete dias. A [Figura 49](#) mostra a topologia de RNA utilizada.

Figura 45 – Correlação cruzada entre a velocidade e direção do vento




Fonte: Próprio autor.

Figura 46 – Correlação cruzada entre velocidade do vento e temperatura do ar




Fonte: Próprio autor.

Figura 47 – Correlação cruzada entre velocidade do vento e sua derivada de primeira ordem




Fonte: Próprio autor.

Figura 48 – Análise do número de delays das variáveis exógenas para previsão eólica



Fonte: Próprio autor.

Figura 49 – Topologia de RNA para previsão eólica com variáveis exógenas

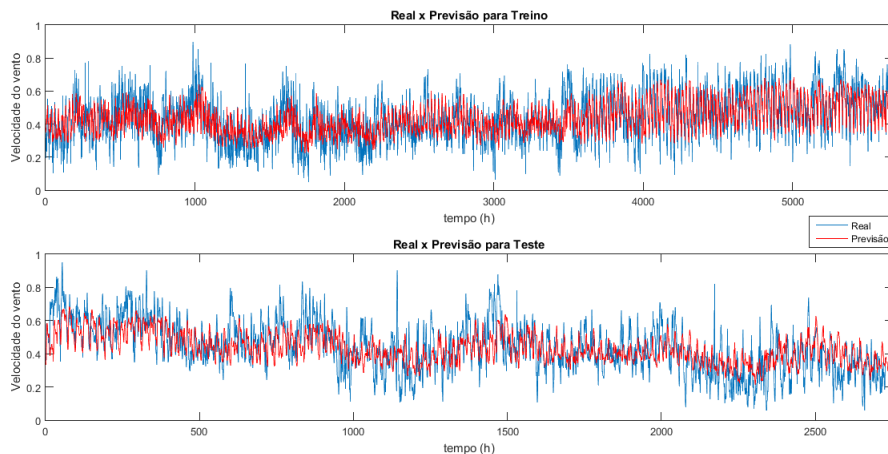


Fonte: Próprio autor.

Determinada a configuração da rede neural, a [Figura 50](#) mostra as séries temporais prevista e medida. Percebe-se que a previsão não representa os valores reais de forma correta. Na [Figura 51](#) é mostrada a mesma série para dados de teste, agora para as 192 primeiras amostras. Fica claro que, como na [subseção 4.2.1](#), a previsão não conseguiu acompanhar variações abruptas da velocidade do vento. Na [Tabela 7](#) são apresentados os índices de desempenhos R^2 e MSE. Observa-se que os resultados obtidos foram superiores aos do modelo RNA. Na etapa de teste, cerca de 6% em R^2 .


Assim como observado na previsão solar, a inserção de variáveis exógenas para previsão é um caminho alternativo a ser pesquisado e desenvolvido. Outras variáveis como velocidade do vento e temperatura do ar em regiões próximas, cuja corrente de ar que passa em Petrolina seja a mesma dessa dada região poderiam ser testadas para serem utilizadas num modelo similar a este implementado.

Figura 50 – Resultados RNA + E para previsão eólica



Fonte: Próprio autor.

Figura 51 – Comportamento da previsão da RNA + E para previsão eólica



Fonte: Próprio autor.

Tabela 7 – Resultados da previsão eólica para RNA + E

	MSE	R
Treino	0.010665	0.67649
Teste	0.013601	0.62203

Fonte: Próprio autor.

4.2.3 Modelo RNA com uso de Wavelet

O modelo de previsão proposto neste item baseia-se na [Figura 33](#) com decomposição *wavelet* de 4 níveis. Inicialmente, foi considerada a mesma topologia aplicada no modelo RNA, [Figura 42](#), para cada rede neural com intuito de demonstrar o ganho em se utilizar o modelo proposto.


Determinada a configuração da rede neural, a [Figura 52](#) mostra as séries temporais prevista e medida. Visivelmente, a previsão parece ter sido superior aos modelos anteriores, em relação ao grau de acerto. Analisando a [Tabela 8](#), percebe-se que realmente houve um ganho de 15%, aproximadamente, em R^2 para os dados de teste em relação ao modelo RNAE. Na [Figura 53](#) é apresentada a mesma série para dados de teste, agora para as primeiras 192 horas. Percebe-se que a previsão não consegue representar de forma precisa os valores de pico e as variações abruptas da velocidade do vento.

Tabela 8 – Resultados da previsão eólica para RNA + W

	MSE	R
Treino	0.0066161	0.82359
Teste	0.0076295	0.77662


Fonte: Próprio autor.

Figura 52 – Resultados RNA + W para previsão eólica



Fonte: Próprio autor.

Figura 53 – Comportamento da previsão da RNA + W para previsão eólica




Fonte: Próprio autor.

4.2.4 Modelo RNA com uso de Wavelet Packet

O modelo de previsão proposto neste item baseia-se na Figura 33, porém utilizando a decomposição *wavelet packet* de 4 níveis. Foi considerada a mesma topologia utilizada no modelo RNA, Figura 42, para cada uma das 16 redes neurais.

Analisando a Figura 54 e Tabela 9 percebe-se que, neste modelo, a previsão foi a melhor dentre os modelos anteriores para previsão de velocidade do vento. Na Figura 55 é mostrada a mesma série para dados de teste, porém para as 192 primeiras amostras. Pode-se notar que, ao contrário dos itens anteriores, esta rede conseguiu acompanhar as variações dos valores da série e reproduzir valores reais de velocidade do vento com precisão de até 91,5%. Houve um ganho de mais de 11% em R^2 para dados de teste, em relação ao modelo RNA+W.

Figura 54 – Resultados RNA + WP para previsão eólica




Fonte: Próprio autor.

Tabela 9 – Resultados da previsão eólica para RNA + WP

	MSE	R
Treino	0.003332	0.91544
Teste	0.0040395	0.88901

Fonte: Próprio autor.

Figura 55 – Comportamento da previsão da RNA + WP para previsão eólica



Fonte: Próprio autor.

4.2.5 Conclusão

Assim como observado para previsão solar e analisando a [Figura 56](#) e a [Tabela 10](#), que resumem os resultados deste capítulo, o ultimo modelo (RNA+WP) foi o que obteve melhor resultado. O projeto mostrou que é possível estimar velocidade do vento com horizonte de previsão de 24 horas com grau de acerto superior a 88%. Dessa forma, pode-se estimar quanto de energia eólica deve ser gerada em determinada região no dia seguinte, por exemplo, por sistemas eólicos. Com isso, é possível tomar decisões em relação ao sistema de energia de modo que diminua custos e aumente sua confiabilidade.

O modelo (RNA+E), demonstrou-se promissor, porém é necessário realizar um estudo mais amplo sobre o modelo.

A aplicação desta metodologia para outras série temporais de outros locais é viável. Porém, não é garantido desempenho semelhante.

A topologia de rede utilizada nos modelos RNA+W e RNAW+P, poderia ter sido ajustada para melhorar o grau de acerto dos modelos. Porém, por opção do autor, foi mantida a mesma topologia utilizada no modelo RNA, justamente para comparar a utilização da decomposição *wavelet* associadas à redes neurais. Testes realizados ao longo do projeto, mostraram que ao utilizar-se uma topologia com 8 dias de atraso de tempo e um neurônio na camada oculta, foram obtidas previsões com grau de acerto superior a 95%.

Figura 56 – Desempenho dos modelos desenvolvidos para previsão eólica



Fonte: Próprio autor.

Fonte: Próprio autor.

Tabela 10 – Tabela comparativa dos modelos desenvolvidos para previsão eólica

		TREINO			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0118740	0,0106650	0,0066161	0,0033320
R^2		0,65005	0,67649	0,82359	0,91544
		TESTE			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0132500	0,0136010	0,0076295	0,0040395
R^2		0,56270	0,62203	0,77662	0,88901

Fonte: Próprio autor.

4.3 Previsão de Demanda

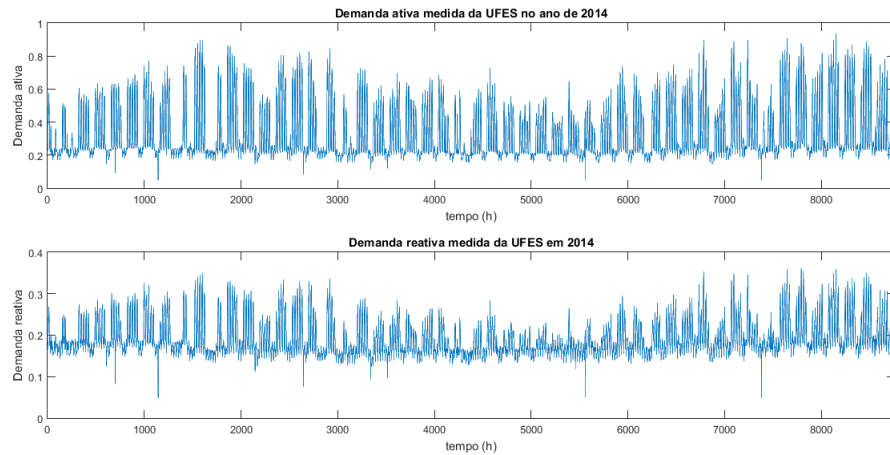
Os dados utilizados referem-se ao período de janeiro à dezembro de 2014, da memória de massa da UFES, obtidos através da concessionária de energia EDP Escelsa. No total, são 35.040 mil amostras, com resolução de 15 minutos, referente a demanda ativa e reativa. Esses dados foram tratados segundo a [seção 3.1](#), obtendo-se duas séries temporais com 8.760 mil dados, uma para demanda ativa e outra para reativa.

Na [Figura 57](#) são apresentadas as séries de demanda ativa e reativa referentes ao ano de 2014. A série já está normalizada e com resolução de 1h. Percebe-se que o comportamento das duas séries temporais são similares, com exceção da amplitude. Outro fato importante é o comportamento característico dessa unidade consumidora.

Do ponto de vista anual, percebe-se o aumento da demanda no período de início do primeiro semestre letivo (final do verão) e final do segundo semestre letivo (início do

verão). Nota-se também a diminuição gradual da demanda no inverno, principalmente no mês de julho, período de férias.

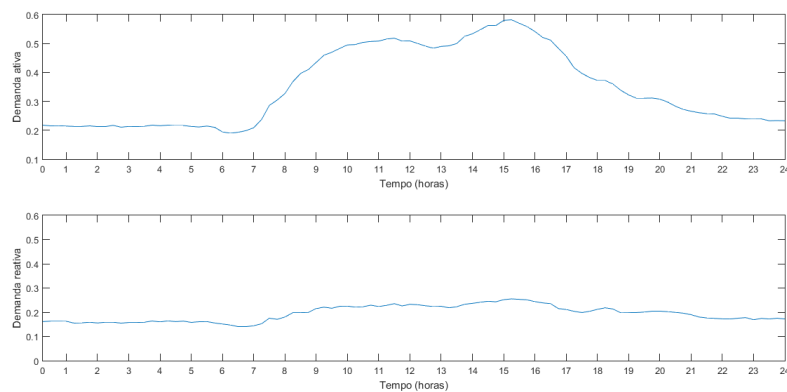
Figura 57 – Demanda ativa e reativa da UFES com resolução de 1h no ano de 2014



Fonte: Próprio autor.

Do ponto de vista diário, segundo a [Figura 58](#), percebe-se que no início da manhã, sete horas (início das aulas), existe um aumento gradual da demanda até dez horas da manhã, aproximadamente. Esse valor se mantém praticamente constante até as quinze horas, quando há um pico de demanda. A partir desse horário a demanda cai gradativamente até chegar ao valor residual. O perfil de demanda desta unidade consumidora se assemelha com o perfil de curva comercial apresentada na [seção 2.3](#), porém com pico de demanda as 15 horas da tarde.

Figura 58 – Demanda ativa e reativa da UFES no dia 1º de abril de 2014



Fonte: Próprio autor.

4.3.1 Modelo RNA


Assim como realizado nos modelos de previsão eólica e solar, inicialmente, foi desenvolvido um sistema de previsão utilizando apenas a série temporal de demanda ativa ou reativa como entrada e target de uma RNA.

Foi aplicada a mesma metodologia utilizada anteriormente para determinar a topologia de rede, seção 3.2. Neste caso, como temos demanda ativa e reativa, são estudadas duas RNA, uma para cada tipo de demanda.

Primeiramente, foi estudado o modelo para demanda ativa. Percebeu-se que o aumento do atraso de tempo na série de entrada implicou no aumento do R^2 e diminuição do MSE . Analisando a Figura 59, pode-se notar que os resultados melhoram quando é considerado pelo menos uma semana de atraso de tempo para as variáveis de entrada. Outro fator importante é que para até 37 atrasos, aproximadamente, houve ganho ao aumentar o número de atrasos, em relação ao grau de acerto da rede neural. A partir daí, observou-se uma espécie de saturação, em que o aumento do atraso não aumentava de forma significativa o grau de acerto da RNA. Por esse motivo, optou-se por escolher como *delay* 37 ou 38 dias.


Para demanda reativa, repetiu-se o processo e foram observados resultados semelhantes ao anterior, como mostra a Figura 60.

Figura 59 – Análise do número de *delays* a ser usado na RNA para previsão de demanda ativa



Fonte: Próprio autor.


Figura 60 – Análise do número de *delays* a ser usado na RNA para previsão de demanda reativa



Fonte: Próprio autor.


Analisando a [Figura 61](#) e [Figura 62](#), percebe-se que o aumento de neurônios na camada oculta não trouxe melhora no grau de acerto da rede. Além disso, para um neurônio, não percebeu-se diferença significativa entre 37 e 38 dias de *delay*.

Figura 61 – Análise do número de neurônios na camada oculta da RNA para previsão de demanda ativa



Fonte: Próprio autor.


Figura 62 – Análise do número de neurônios na camada oculta da RNA para previsão de demanda reativa



Fonte: Próprio autor.

Portanto, foi empregada uma RNA com um neurônio na camada oculta e com 37 dias (888 horas) de atraso de tempo, como mostra a Figura 63, tanto para previsão de demanda ativa como reativa.

Figura 63 – Topologia de RNA utilizada para previsão de demanda ativa e reativa

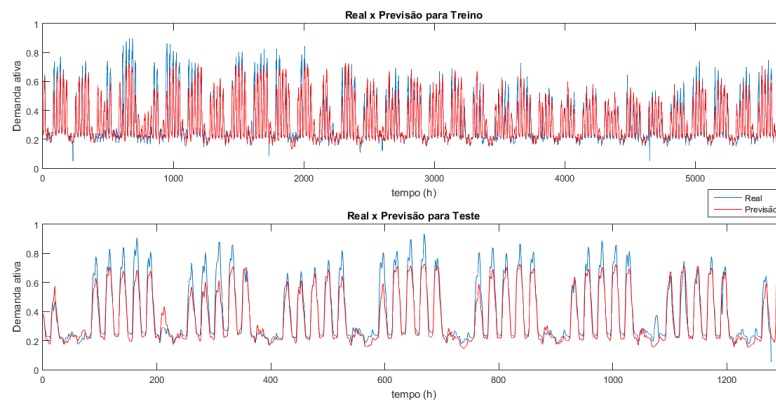


Fonte: Próprio autor.

Determinada a configuração da rede neural, a Figura 64 e Figura 65 mostram as séries temporais prevista e medida, a primeira para demanda ativa e a segunda para demanda reativa.

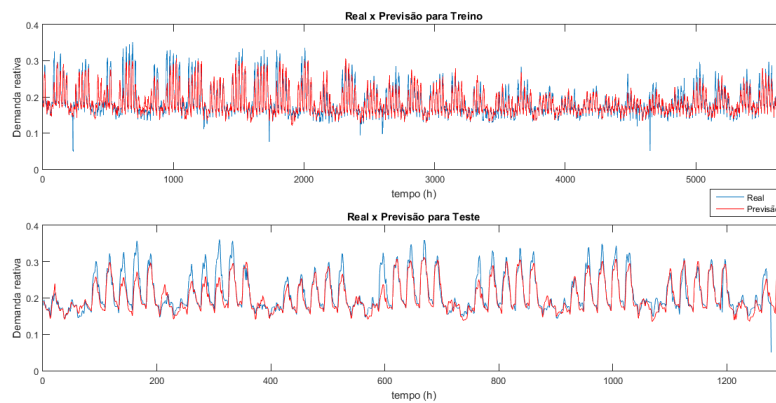
Na Figura 66 são apresentados as mesmas séries para dados de teste, agora para as 192 primeiras amostras. Similar ao que foi encontrado para previsão solar, percebe-se que a previsão de demanda, apesar de acompanhar a tendência da série temporal, não representa os picos e variações do sinal medido.

Figura 64 – Resultados RNA para previsão de demanda ativa



Fonte: Próprio autor.

Figura 65 – Resultados RNA para previsão de demanda reativa




Fonte: Próprio autor.


Figura 66 – Comportamento da previsão da RNA para previsão de demanda

(a) Demanda ativa

(b) Demanda reativa



Fonte: Próprio autor.



Fonte: Próprio autor.

Na [Tabela 11a](#) e [Tabela 11b](#) são mostrados os índices de desempenho R^2 e MSE. Percebe-se que, para este modelo, os resultados obtidos para R^2 , foram maiores para os dados de teste do que para os dados de treino. Fato que não havia sido observado até então.

Tabela 11 – Resultados da previsão de demanda para RNA

(a) Demanda ativa

	MSE	R
Treino	0.005202	0.88817
Teste	0.0044158	0.96197

Fonte: Próprio autor.

(b) Demanda reativa

	MSE	R
Treino	0.00042356	0.85879
Teste	0.00048104	0.91768


Fonte: Próprio autor.

4.3.2 Modelo RNA com entradas exógenas

A escolha de variáveis auxiliares se baseou no critério de correlação cruzada entre a variável de interesse e as possíveis variáveis exógenas, já explicitado nas seções anteriores de previsão solar e eólica. Foram analisadas a correlação entre demanda ativa e reativa, hora do dia (de 00:00 à 23:45 horas), dia da semana (de 1 a 7, sendo 1 para domingo, 2 para segunda-feira e assim por diante) e derivada de primeira ordem da demanda ativa e reativa.


A [Figura 67](#), [Figura 68](#), [Figura 69](#) e [Figura 70](#) comprovam que as variáveis exógenas testadas possuem correlação significativa com a variável de interesse. Dessa forma, para previsão de demanda ativa foram utilizadas como entradas exógenas, demanda reativa, hora do dia, dia da semana e derivada de primeira ordem da demanda ativa. Já para previsão de demanda reativa foram utilizadas como variáveis exógenas, demanda ativa, hora do dia, dia da semana e derivada de primeira ordem da demanda reativa.

Figura 67 – Correlação cruzada entre demanda ativa e reativa




Fonte: Próprio autor.

Figura 68 – Correlação cruzada entre demanda e derivada de primeira ordem



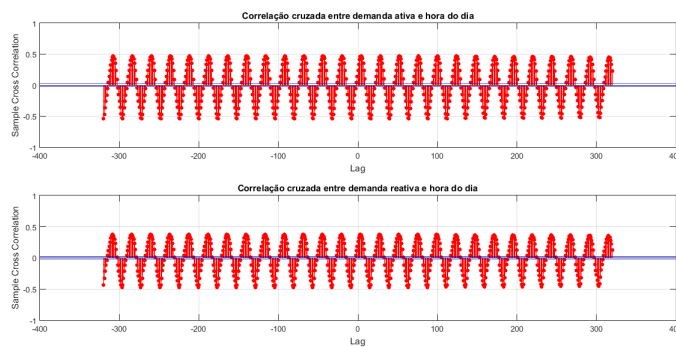
Fonte: Próprio autor.

Figura 69 – Correlação cruzada entre demanda e dia da semana



Fonte: Próprio autor.

Figura 70 – Correlação cruzada entre demanda e hora do dia




Fonte: Próprio autor.

Para determinar o atraso de tempo das variáveis exógenas foi utilizado o mesmo método aplicado nos capítulos anteriores. De acordo com a [Figura 71](#), percebe-se que, para previsão de demanda ativa a RNA com maior grau de acerto ocorreu para atraso de tempo de dez dias para variáveis exógenas.


Já para previsão de demanda reativa, a RNA com melhor grau de acerto ocorreu para *delay* igual a nove dias, como mostra a [Figura 72](#). A [Figura 73](#) mostra a topologia de RNA utilizada para previsão de demanda reativa, que é a mesma utilizada para demanda ativa, com exceção do atraso de tempo aplicado de 240 horas ou dez dias.

Figura 71 – Análise do número de *delays* das variáveis exógenas para previsão de demanda ativa




Fonte: Próprio autor.

Figura 72 – Análise do número de *delays* das variáveis exógenas para previsão de demanda reativa



Fonte: Próprio autor.

Figura 73 – Topologia de RNA para previsão de demanda reativa com variáveis exógenas




Fonte: Próprio autor.

Determinada a configuração da rede neural, a [Figura 74](#) e [Figura 75](#) mostram as séries temporais previstas e medidas, a primeira para demanda ativa e a segunda para demanda reativa. Percebe-se que os resultados obtidos são similares ao primeiro modelo, RNA.


Na [Figura 76](#) são apresentados as mesmas séries para dados de teste, porém para as primeiras 192 amostras. Novamente, percebe-se que a previsão, apesar de acompanhar a tendência da série temporal, não representa bem os picos e variações do sinal medido.

Figura 74 – Resultados RNA+E para previsão de demanda ativa



Fonte: Próprio autor.


Figura 75 – Resultados RNA+E para previsão de demanda reativa



Fonte: Próprio autor.


Figura 76 – Comportamento da previsão da RNA+E para previsão de demanda

(a) Demanda ativa



Fonte: Próprio autor.

(b) Demanda reativa



Fonte: Próprio autor.

Na [Tabela 12a](#) e [Tabela 12b](#) são apresentados os índices de desempenho R^2 e MSE. O modelo RNA+E melhorou o grau de acerto para os dados de treino em relação ao primeiro modelo, RNA. Para dados de teste, na previsão de demanda ativa foram obtidos resultados similares e para demanda reativa, mais uma vez, os resultados obtidos foram superiores ao primeiro modelo em cerca de 1% para R^2 . Em contrapartida, em relação aos dados de treino, houve ganho de 3% em R^2 , aproximadamente, tanto para demanda ativa quanto para demanda reativa.

A inserção de variáveis exógenas parece contribuir para aumentar o grau de acerto da RNA. Outras variáveis como temporada do ano, temperatura local e dias letivos podem ser utilizadas como variáveis exógenas nesse tipo de previsão. Vale ressaltar que, o uso de variáveis exógenas aumenta consideravelmente o custo computacional do programa, fato este que levou o menor número de testes na análise do *delay* para variáveis exógenas.

Tabela 12 – Resultados da previsão de demanda para RNA+E

	(a) Demanda ativa		(b) Demanda reativa	
	MSE	R	MSE	R
Treino	0.0039402	0.91653	0.0003471	0.88569
Teste	0.0051224	0.96117	0.00045235	0.92558

Fonte: Próprio autor.

Fonte: Próprio autor.


4.3.3 Modelo RNA com uso de Wavelet

O modelo de previsão proposto neste item baseia-se na [Figura 33](#) com decomposição wavelet de 4 níveis. Foi considerada a mesma topologia aplicada no modelo RNA, [Figura 63](#), para cada rede neural com intuito de demonstrar o ganho em se utilizar o modelo proposto.

Determinada a configuração da rede neural, a [Figura 77](#) e [Figura 78](#) mostram as séries temporais previstas e medidas, a primeira para demanda ativa e a segunda para demanda reativa. Visivelmente, parece que os resultados obtidos são melhores que os anteriores em relação ao grau de acerto e as séries previstas, tanto para demanda ativa quanto reativa, alcançam a maioria dos picos da série medida.


Analisando a [Tabela 13a](#) e [Tabela 13b](#), comprova-se que houve um ganho de, aproximadamente, 2,5% e 5% em R^2 para demanda ativa e reativa, respectivamente, em relação ao modelo RNA+E.

Figura 77 – Resultados RNA+W para previsão de demanda ativa



Fonte: Próprio autor.

Figura 78 – Resultados RNA+W para previsão de demanda reativa



Fonte: Próprio autor.

Na Figura 79 são apresentadas as mesmas séries para dados de teste, agora para as primeiras 192 horas da série. Percebe-se que as séries previstas representam os picos e variações abruptas das séries medidas.

Tabela 13 – Resultados da previsão de demanda para RNA+W

(a) Demanda ativa

(b) Demanda reativa

	<u>MSE</u>	<u>R</u>		<u>MSE</u>	<u>R</u>
Treino	0.00097654	0.97998	Treino	9.4086e-05	0.9704
Teste	0.0011075	0.98702	Teste	0.00012792	0.97488



Fonte: Próprio autor.

Fonte: Próprio autor.

Figura 79 – Comportamento da previsão da RNA+W para previsão de demanda

(a) Demanda ativa

(b) Demanda reativa



Fonte: Próprio autor.


Fonte: Próprio autor.

4.3.4 Modelo RNA com uso de Wavelet Packet

O modelo de previsão proposto neste item baseia-se na Figura 33, porém utilizando a decomposição *wavelet packet* de 4 níveis. Foi considerada a mesma topologia aplicada no modelo RNA, Figura 63, para cada rede neural.


Determinada a configuração da rede neural, a Figura 80 e Figura 81 mostram as séries temporais previstas e medidas. Visivelmente, a previsão parece ter sido tão boa quanto a do modelo anterior, RNA+W.

Figura 80 – Resultados RNA+WP para previsão de demanda ativa



Fonte: Próprio autor.

Figura 81 – Resultados RNA+WP para previsão de demanda reativa



Fonte: Próprio autor.

Analisando, a [Tabela 14a](#) e a [Tabela 14b](#), conclui-se que o modelo RNA+WP superou todos os outros modelos desenvolvidos em relação ao grau de acerto, tanto para demanda ativa quanto para demanda reativa. Aproximadamente, houve um acréscimo de 0,2% e 0,8% em R^2 para dados de teste, para demanda ativa e reativa, respectivamente, em relação ao modelo RNA+W.

Tabela 14 – Resultados da previsão de demanda para RNA+WP

(a) Demanda ativa

	MSE	R
Treino	0.00074686	0.98529
Teste	0.00097159	0.98914

Fonte: Próprio autor.

(b) Demanda reativa


	MSE	R
Treino	5.3233e-05	0.98339
Teste	9.2809e-05	0.98203

Fonte: Próprio autor.

Na [Figura 82](#) são apresentadas as mesmas séries para dados de teste, agora para as 192 primeiras amostras da série. Assim como para o modelo anterior, percebe-se que as séries previstas representam os picos e variações abruptas das séries medidas.


Figura 82 – Comportamento da previsão da RNAWP para previsão de demanda

(a) Demanda ativa



Fonte: Próprio autor.

(b) Demanda reativa



Fonte: Próprio autor.


4.3.5 Conclusão

Assim como observado para previsão solar e eólica e analisando a [Figura 83](#), [Figura 84](#) e [Tabela 15](#), que resumem os resultados encontrados neste capítulo, o ultimo modelo (RNA+WP) foi o que obteve melhor resultado. O projeto mostrou que é possível estimar demanda ativa e reativa com horizonte de previsão de 24 horas com grau de acerto superior a 98%. Dessa forma, é possível estimar quanto de energia elétrica será demandada em certa unidade consumidora no dia seguinte, por exemplo. Com isso, é possível tomar decisões em relação ao sistema de energia de modo que diminua custos e aumente sua confiabilidade.

Novamente, o modelo (RNA+E), demonstrou-se promissor, porém é necessário realizar um estudo mais detalhado sobre o modelo.

A aplicação desta metodologia para outras série temporais de outros locais é extremamente viável. Porém, não é garantido desempenho semelhante.

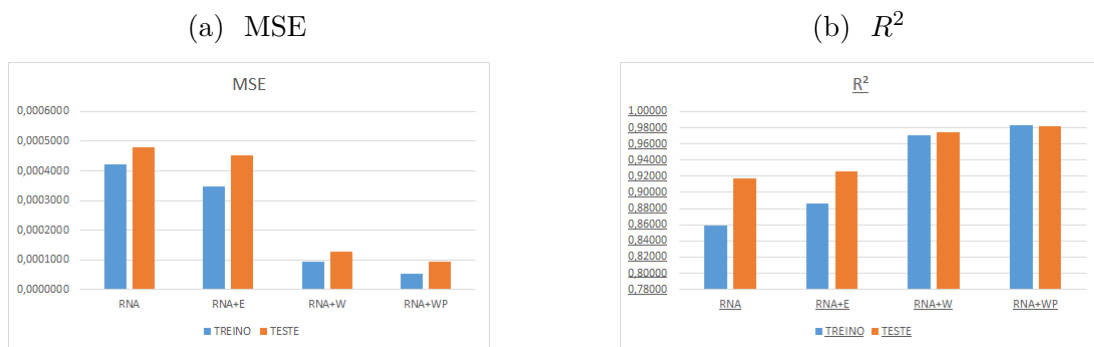
Figura 83 – Desempenho dos modelos desenvolvidos para previsão de demanda ativa



Fonte: Próprio autor.

Fonte: Próprio autor.

Figura 84 – Desempenho dos modelos desenvolvidos para previsão de demanda reativa



Fonte: Próprio autor.

Fonte: Próprio autor.

Tabela 15 – Tabela comparativa dos modelos para previsão de demanda

(a) Demanda ativa

		TREINO			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0052020	0,0039402	0,0009765	0,0007469
R ²		0,88817	0,91653	0,97998	0,98529
		TESTE			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0044158	0,0051224	0,0011075	0,0009716
R ²		0,96197	0,96117	0,98702	0,98914

Fonte: Próprio autor.

(b) Demanda reativa

		TREINO			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0004236	0,0003471	0,0000941	0,0000532
R ²		0,85879	0,88569	0,97040	0,98339
		TESTE			
		RNA	RNA+E	RNA+W	RNA+WP
MSE		0,0004810	0,0004524	0,0001279	0,0000928
R ²		0,91768	0,92558	0,97488	0,98203

Fonte: Próprio autor.

5 Considerações Finais

Os modelos RNA apresentaram os menores valores de R^2 para os três tipos de previsão (recurso solar, eólico e demanda elétrica). O modelo RNA+E mostrou que uso de variáveis exógenas trouxe melhora no grau de acerto da rede neural. Entretanto, os modelos de previsão desenvolvidos neste projeto que demonstraram maior grau de acerto foram os dois últimos, RNA+W e RNA+WP. A aplicação de *wavelets*, principalmente o uso de *wavelet packet*, permitiu que o aprendizado das redes neurais fosse maximizado, uma vez que, foi aplicado uma rede neural específica para cada banda de frequência do sinal.

Os modelos propostos mostraram que, foi possível prever 24 horas a frente, com R^2 entre 94,6% e 99,3% para recurso solar, 56,3% e 88,9% para recurso eólico, 96,2% e 98,9% para demanda ativa e 91,8% e 98,2% para demanda reativa. Porém, a distorção de borda torna necessário que este problema seja tratado antes do treino da rede e minimizado durante a previsão.

Os resultados obtidos neste trabalho, contribuem para elevação da segurança e eficiência do sistema elétrico moderno, uma vez que pode contribuir para tomada de decisão com 24 horas de antecedência.

Como sugestão para trabalhos futuros pode-se investigar de forma mais ampla o uso de variáveis exógenas para previsão do recurso eólico, solar e de demanda elétrica, uma vez que foi observada uma melhora em R^2 de até 6% nos modelos de previsão sintetizados neste trabalho. Além disso, o desenvolvimento de uma metodologia para diminuir a influência do efeito de borda, consolidaria a aplicação de *wavelet* para previsão.

Referências

- CHRISTO, T. M. *Uma Proposta de matriz energética para estação antártica comandante ferraz: uma experiência aplicável à novas edificações*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, 2012. Citado 2 vezes nas páginas 24 e 25.
- CHRISTO, T. M.; BERNABE, T. P. Wavelets e redes neurais aplicadas a previsão de recurso eólico. *CBA*, 2016. Citado 2 vezes nas páginas 30 e 31.
- COUTINHO, P. C. *O ONS e a operação do sistema nacional - SIN*. [S.l.], 2010. Citado na página 27.
- CRESESB. *Energia Eólica - Princípios e Tecnologia*. 2015. Disponível em: <http://www.cresesb.cepel.br/index.php?section=com_content&cid=tutorial_eolica>. Citado na página 24.
- CULTURAMIX. *Perceptron multicamadas*. 2015. Disponível em: <<http://www.culturamix.com/tecnologia/inteligencia-artificial/perceptron-multicamadas>>. Citado na página 34.
- EDWARDS, T. Discrete wavelets transforms: Theory and implementation. *Stanford University*, set 1991. Disponível em: <https://www.researchgate.net/publication/2291606_Discrete_Wavelet_Transforms_Theory_and_Implementation>. Citado na página 28.
- EYNG, J.; VERGARA, A. Wavelets e wavelet packets. 2000. Disponível em: <<http://www.inf.ufsc.br/~visao/2000/Wavelets/>>. Citado na página 29.
- HAYKIN, S. *Redes Neurais*. [S.l.]: Bookman, 2001. Citado na página 35.
- MALLAT, S. G. A theory for multiresolution signal decomposition: The wavelet representation. *University of Pennsylvania Scholarly Commons*, 1987. Citado na página 28.
- MATHWORKS. *Matlab 2016a - Wavelet Packets*. [S.l.], 2016. Disponível em: <<http://www.mathworks.com/help/wavelet/ug/wavelet-packets.html>>. Citado na página 30.
- MENG, A. et al. Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm. *Energy Conversion and Management*, v. 114, p. 75–88, 2016. Citado na página 19.
- ONUDI. *Programa de capacitação em energias renováveis: Energia solar fotovoltaica*. [S.l.], 2015. Citado 4 vezes nas páginas 17, 18, 21 e 22.
- PINHO, J. T.; GALDINO, M. A. *Manual de engenharia para sistemas fotovoltaicos*. Rio de Janeiro, 2014. Citado na página 21.
- RANA, M.; KOPRINSKA, I. Forecasting electricity load with advanced wavelet neural networks. *Neurocomputing*, v. 182, p. 118–132, 2016. Citado 2 vezes nas páginas 30 e 32.
- REIS, L. B. *Geração de Energia Elétrica: Tecnologia, Inserção Ambiental, Planejamento, Operação e Análise de Viabilidade*. Barueri, SP: Manole Ltda, 2003. Citado na página 24.

REN, Y.; SUGANTHAN, P.; SRIKANTH, N. Ensemble methods for wind and solar power forecasting – a state-of-the-art review. *Renewable and Sustainable Energy Reviews*, p. 82–91, mai 2015. Citado 2 vezes nas páginas 18 e 19.

SILVA, R. *Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP*. Dissertação (mathesis) — PUC-Rio, 2005. Citado na página 32.

SOLA, J.; SEVILLA, J. Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear*, v. 44, p. 1464 – 1468, 1997. Citado na página 36.

SU, H.; LIU, Q.; LI, J. Boundary effects reduction in wavelet transform for time-frequency analysis. *WSEAS TRANSACTIONS on SIGNAL PROCESSING*, p. 169–179, 2012. Citado 2 vezes nas páginas 30 e 32.

WWEA. *The world sets new wind installations record: 63,7GW new capacity in 2015*. 2016. Disponível em: <<http://www.wwindea.org/the-world-sets-new-wind-installations-record-637-gw-new-capacity-in-2015/>>. Citado na página 18.

ZAMBIASI, S. P. *Redes neurais: O neurônio artificial*. 2011. Disponível em: <http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html>. Citado na página 33.