



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA

AMANDA SUIANNY FERNANDES ROCHA

**PREVISÃO DO DESEMPENHO DE UM SISTEMA SOLAR
FOTOVOLTAICO CONFORME DADOS METEOROLÓGICOS DA
REGIÃO**

MOSSORÓ-RN
2019

AMANDA SUIANNY FERNANDES ROCHA

**PREVISÃO DO DESEMPENHO DE UM SISTEMA SOLAR
FOTOVOLTAICO CONFORME DADOS METEOROLÓGICOS DA
REGIÃO**

Dissertação apresentada ao Programa de Pós-
Graduação em Engenharia Elétrica

Linha de Pesquisa: Sistemas Elétricos

Orientador (a): Prof (a). Dr (a). Fabiana Karla
de Oliveira Martins Varella Guerra – UFERSA

Co-orientador (a): Prof (a). Dr (a). Marcelo
Roberto Bastos Guerra Vale – UFERSA

MOSSORÓ-RN
2019

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

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

R672p Rocha, Amanda Suianny Fernandes.
PREVISÃO DO DESEMPENHO DE UM SISTEMA SOLAR
FOTOVOLTAICO CONFORME DADOS METEOROLÓGICOS DA
REGIÃO / Amanda Suianny Fernandes Rocha. - 2019.
118 f. : il.

Orientadora: Fabiana Karla de Oliveira Martins
Varella Guerra.

Coorientador: Marcelo Roberto Bastos Guerra
Vale .

Dissertação (Mestrado) - Universidade Federal
Rural do Semi-árido, Programa de Pós-graduação em
Engenharia Elétrica, 2019.

1. Sistema solar fotovoltaico. 2. Rede neural
artificial. 3. Previsão de potência. 4.
Eficiência energética. I. Guerra, Fabiana Karla
de Oliveira Martins Varella , orient. II. Vale ,
Marcelo Roberto Bastos Guerra, co-orient. III.
Título.

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

AMANDA SUIANNY FERNANDES ROCHA

PREVISÃO DO DESEMPENHO DE UM SISTEMA SOLAR FOTOVOLTAICO
CONFORME DADOS METEOROLÓGICOS DA REGIÃO

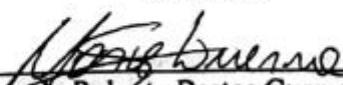
Dissertação apresentada ao Mestrado em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Mestre em Engenharia Elétrica.

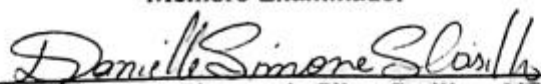
Linha de Pesquisa: Sistemas Elétricos

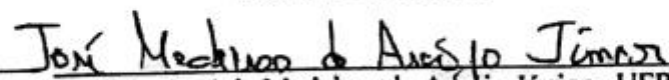
Defendida em: 22/02/2019.

BANCA EXAMINADORA


Prof.^a. Dr.^a. Fabiana Karla de Oliveira Martins Varella Guerra – UFERSA
Presidente


Prof. Dr. Marcelo Roberto Bastos Guerra Vale – UFERSA
Membro Examinador


Prof.^a. Dr.^a. Danielle Simone da Silva Casillo – UFERSA
Membro Examinador


Prof. Dr. José de Medeiros de Araújo Júnior - UFPI
Membro Examinador

AGRADECIMENTOS

Primeiramente a Deus que me proporcionou tamanha conquista e foi quem me ajudou em muitos momentos difíceis.

Aos meus pais, em especial a minha mãe, Rita de Cássia, um exemplo de pessoa e de mãe, que sempre esteve comigo em todos os momentos, me apoiando incondicionalmente, fazendo o possível e algumas vezes o impossível para que eu pudesse realizar meus objetivos. E a minha irmã, Andrezza Fernandes, que me apoiou desde o início, fazendo das minhas conquistas as dela.

A todos os meus familiares, aos mais próximos que estiveram sempre presentes, me ajudando sempre que puderam e aos mais ausentes, por terem seus motivos, mas que de alguma forma sei que torcem por mim.

Ao meu noivo, Caio Borges, pela ajuda, paciência, compreensão nos momentos de ausência e por todo o apoio nas horas difíceis.

Aos meus amigos, em especial a Luann Georgy, companheiro de estudos e que sempre se dispôs a me ajudar. E aos amigos de longa data, por estarem sempre à disposição com apoio e palavras de incentivo.

Ao professor Michael Hrcir da estação meteorológica Espaço ASA/UFERSA, pela atenção em fornecer os dados para a realização da pesquisa.

A minha orientadora, Prof.^a Fabiana Varella, por todo o seu auxílio, sempre prestativa e contribuindo de forma significativa na elaboração deste trabalho, transmitindo importantes conhecimentos.

Ao meu co-orientador, Prof. Marcelo Guerra, pelas importantes contribuições e por toda a disponibilidade a que se dispôs para me ajudar.

Enfim, agradeço a todos que contribuíram de alguma forma, para a realização deste trabalho.

RESUMO

A energia solar fotovoltaica tem sido disseminada em todo o mundo, e no Brasil essa fonte de energia vem ganhando um espaço considerável nos últimos anos, sendo impulsionada, sobretudo, pelas crises energéticas que o país enfrenta. O uso dos sistemas fotovoltaicos proporciona diversas vantagens, tanto ao consumidor final quanto ao país, contribuindo para diversificação da matriz energética e redução da dependência por fontes fósseis. Porém, atrelado aos benefícios, como em todo sistema real, quando instalados em regiões com baixa incidência de irradiação solar essa tecnologia apresenta perda na eficiência de geração de energia. Logo, se faz necessário realizar um estudo prévio das condições climáticas do local onde o sistema fotovoltaico será instalado. Como alternativa à essa consideração, poder-se-ia realizar um estudo da previsão da produção de potência antes da sua instalação, a partir das informações climáticas locais que influenciam diretamente na geração de potência, verificando a viabilidade da implantação do sistema, e evitando um investimento sem retorno. Sendo assim, o presente trabalho tem como objetivo, realizar a previsão da viabilidade de instalação de sistemas fotovoltaicos em outras localidades, por meio de uma Rede Neural Artificial (RNA). Para isso, foi utilizado como modelo um sistema fotovoltaico de 3kW_p localizado no Campus Leste da Universidade Federal Rural do Semi-Árido (UFERSA), com o intuito de prever o seu comportamento quando instalado nos estados do Rio Grande do Sul e Pernambuco. A RNA foi treinada e validada com o auxílio do Matlab[®], e os treinamentos foram implementados inserindo como variáveis de entrada os dados de temperatura e irradiação solar da cidade de Mossoró-RN, fornecidos pela estação meteorológica da UFERSA, e a potência elétrica gerada do sistema fotovoltaico foi inserida como variável de saída. Visando ampliar a pesquisa e obter o melhor resultado, utilizou-se no treinamento dois tipos de rede com propostas de funcionamento diferentes, uma *feedforward* e uma *feedback*. Após a implementação foram realizadas algumas validações com diferentes situações para verificar a capacidade de generalização de cada rede em prever a saída desejada, posteriormente realizou-se a previsão da geração de potência nos estados do Rio Grande do Sul e Pernambuco, onde nota-se, através dos métodos de análise de desempenho, que os resultados se mostram favoráveis para essa aplicação utilizando a rede *feedforward*, visto que a rede *feedback* não obteve bom desempenho para uma quantidade reduzida de amostras inseridas.

Palavras-chave: Sistema solar fotovoltaico. Rede neural artificial. Previsão de potência. Eficiência energética.

ABSTRACT

Photovoltaic solar energy has been disseminated all over the world, and in Brazil this energy source has been getting considerable space in recent years, being stimulated mainly by the energy crises that the country faces. The use of photovoltaic systems offers several advantages, both to the final consumer and the country, contributing to the diversification of the energy matrix and reduction of dependence on fossil sources. However, associated with the benefits, as in any real system, when installed in regions with low incidence of solar irradiation this technology presents a loss in the efficiency of energy generation. Therefore, it is necessary to implement a preliminary study of the climatic conditions from the place where the photovoltaic system will be installed. As an alternative to this consideration, a study of the prediction of power production before its installation could be carried out, based on the local climatic information that directly influences the power generation, verifying the feasibility of the system implantation, and avoiding a investment. Therefore, this work aims to predict the viability of installing photovoltaic systems in other places, through an Artificial Neural Network (ANN). For this, the 3kWp photovoltaic system located in the Federal University of the Semi-Arid (UFERSA) Federal Campus was used as a model, in order to predict its behavior when installed in the states of Rio Grande do Sul and Pernambuco. The RNA was trained and validated with the support of Matlab®, and the training was implemented by inserting the input variables the data of temperature and solar irradiation of the city of Mossoró-RN, provided by the UFERSA weather station, and the generated electricity of the photovoltaic system was inserted as output variable. In order to enlarge the research and obtain the best result, two types of network with different operational proposals, feedforward and feedback were used in the training. After the implementation, some validations were carried out with different situations to verify the generalization capacity of each network in predicting the wanted output. Later, it was realized the power generation forecast in the states of Rio Grande do Sul and Pernambuco, through the methods of performance analysis, that the results are favorable for this application using feedforward network, since the feedback network did not perform well for a reduced amount of inserted samples.

Keywords: Solar photovoltaic system. Artificial neural network. Power Forecast. Energy efficiency.

LISTA DE FIGURAS

Figura 1 – Sistema fotovoltaico conectado à rede elétrica.....	17
Figura 2 – Capacidade instalada da Geração distribuída no Brasil	20
Figura 3 – Influência da radiação solar e da temperatura no desempenho dos módulos	22
Figura 4 – Índices de irradiação solar nas regiões do Brasil	24
Figura 5 – Divisão das camadas da RNA.....	27
Figura 6 – <i>Feedforward</i> de única camada	28
Figura 7 – <i>Feedforward</i> de múltiplas camadas	29
Figura 8 – Esquema de uma rede recorrente	30
Figura 9 – Módulos fotovoltaicos do SFCR do CITED.....	36
Figura 10 – Inversor fotovoltaico	37
Figura 11 – Metodologia da pesquisa	38
Figura 12 – Técnicas de filtragem das amostras.....	41
Figura 13 – Normalização das amostras	42
Figura 14 – Divisão da implementação proposta na pesquisa.....	43
Figura 15 – Esquema das validações propostas na pesquisa.....	44
Figura 16 – Esquema da rede sem realimentação (<i>feedforward</i>)	45
Figura 17 – Esquema da rede com realimentação (NARX).....	45
Figura 18 – Diagrama gráfico da rede neural NEWFF.....	49
Figura 19 – Diagrama gráfico da rede neural NARX em malha fechada	51
Figura 20 – Diagrama de Regressão linear	55
Figura 21 – Janela de treinamento do Caso A.....	57
Figura 22 – Regressões do Caso A	58
Figura 23 – Diagrama de Performance do Caso A	59
Figura 24 – Janela de treinamento do Caso B	60
Figura 25 – Regressões do Caso B	61
Figura 26 – Diagrama de Performance do Caso B	61
Figura 27 – Janela de treinamento do Caso C	62
Figura 28 – Regressões do Caso C	63
Figura 29 – Diagrama de Performance do Caso C	64
Figura 30 – Comparação Real x Previsto da Validação A.....	66
Figura 31 – Comparação Real x Previsto da Validação B	66
Figura 32 – Comparação Real x Previsto da Validação C	67

Figura 33 – Regressões das Validações A, B e C.....	68
Figura 34 – Esquema do conjunto de Validação ABC1	69
Figura 35 – Comparação Real x Previsto do conjunto de Validação ABC1.....	70
Figura 36 – Regressões do conjunto de Validação ABC1	71
Figura 37 – Esquema do conjunto de Validação ABC2	75
Figura 38 – Comparação Real x Previsto do conjunto de Validação ABC2.....	76
Figura 39 – Regressões do conjunto de Validação ABC2	77
Figura 40 – Esquema do conjunto de Validação ABC3	80
Figura 41 – Comparação Real x Previsto do conjunto de Validação ABC3.....	80
Figura 42 – Regressões do conjunto de Validação ABC3	81
Figura 43 – Esquema do conjunto de Validação ABC4	84
Figura 44 – Comparações Prevista x Real do conjunto de Validação ABC4	85
Figura 45 – Regressões do conjunto de Validação ABC4	86
Figura 46 – Curvas resultantes do subconjunto de Validação A9.....	89
Figura 47 – Curvas resultantes do subconjunto de Validação B9	90
Figura 48 – Curvas resultantes do subconjunto de Validação C9	91
Figura 49 – Janela de treinamento do Caso D.....	96
Figura 50 – Regressões do Caso D	96
Figura 51 – Diagrama de performance do Caso D	97
Figura 52 – Comparação Real x Previsto da Validação D.....	98
Figura 53 – Regressão da Validação D.....	99
Figura 54 – Esquema do conjunto de Validação D1	100
Figura 55 – Comparação Previsto x Real do conjunto de Validação D1.....	100
Figura 56 – Regressões do conjunto de Validação D1	101
Figura 57 – Esquema do conjunto de Validação D4	103
Figura 58 – Comparação Real x Previsto do conjunto de Validação D4.....	104
Figura 59 – Regressão do conjunto de Validação D4.....	105
Figura 60 – Curvas resultantes do conjunto de Validação D9	107

LISTA DE GRÁFICOS

Gráfico 1 – Comparação entre as potências médias do conjunto de Validação ABC1	74
Gráfico 2 – Comparação entre as potências médias do conjunto de Validação ABC2	79
Gráfico 3 – Comparação entre as potências médias do conjunto de Validação ABC3	83
Gráfico 4 – Comparação entre as potências médias do conjunto de Validação ABC4	88
Gráfico 5 – Potência prevista média com RMSE% para as validações dos estados (ABC9) ..	94
Gráfico 6 – Comparação entre as potências médias do conjunto de Validação D1	103
Gráfico 7 – Comparação entre as potências médias do conjunto de Validação D4	106
Gráfico 8 – Potência prevista média com RMSE% para as validações dos estados (D9)	109

LISTA DE TABELAS

Tabela 1 – Unidades Consumidoras com GD em 2018.....	21
Tabela 2 – Configuração das redes.....	46
Tabela 3 – Informações dos treinamentos da RNA.....	46
Tabela 4 – Critérios para a seleção das amostras para validações.....	48
Tabela 5 – Resumo das validações com a rede neural <i>feedforward</i>	50
Tabela 6 – Resumo das validações com a rede neural NARX.....	52
Tabela 7 – Resumos dos resultados dos treinamentos.....	64
Tabela 8 – Erros das Validações A, B e C.....	68
Tabela 9 – Erros do conjunto de Validação ABC1.....	72
Tabela 10 – Potências do conjunto de Validação ABC1.....	73
Tabela 11 – Erros do conjunto de Validação ABC2.....	78
Tabela 12 – Potências do conjunto de Validação ABC2.....	78
Tabela 13 – Erros do conjunto de Validação ABC3.....	82
Tabela 14 – Potências do conjunto de Validação ABC3.....	83
Tabela 15 – Erros do conjunto de Validação ABC4.....	87
Tabela 16 – Potências do conjunto de Validação ABC4.....	87
Tabela 17 – Potências previstas dos estados por treinamento.....	92
Tabela 18 – Informações climáticas médias de Mossoró, RS e PE.....	93
Tabela 19 – Erros do conjunto de Validação D.....	99
Tabela 20 – Erros do conjunto de Validação D1.....	102
Tabela 21 – Potências do conjunto de Validação D1.....	102
Tabela 22 – Erros do conjunto de Validação D4.....	105
Tabela 23 – Potências do conjunto de Validação D4.....	106
Tabela 24 – Potências previstas dos estados por treinamento.....	108

LISTA DE ABREVIATURAS E SIGLAS

RNA – Rede Neural Artificial

ME% – Erro Médio Percentual

RMSE% – Percentual da Raiz do Erro Médio Quadrático

SFCR – Sistema Fotovoltaico Conectado à Rede

SIN – Sistema Interligado Nacional

SFV – Sistemas Fotovoltaicos

GD – Geração Distribuída

UC – Unidade Consumidora

IA – Inteligência Artificial

MLP – *Multilayer Perceptron*

NARX – Auto-associativa não linear com entrada externa

ARX – *Autoregressive with exogenous inputs*

UFERSA – Universidade Federal Rural do Semi-Árido

CITED – Centro Integrado de Inovação Tecnológica do Semiárido

CSV – *Comma-separated values*

ME – Erro Médio

MAE – Erro Absoluto Médio

MSE – Erro Quadrático Médio

RMSE – Raiz do Erro Médio Quadrático

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Objetivo Geral.....	16
1.2 Objetivos Específicos	16
2 REVISÃO DE LITERATURA.....	17
2.1 Sistema Solar Fotovoltaico Conectado à Rede	17
2.1.1 Geração Distribuída (GD).....	18
2.1.2 Influência das variações climáticas no desempenho dos sistemas fotovoltaicos	21
2.1.3 Avaliação do potencial para instalação de sistemas fotovoltaicos no Brasil	23
2.1.4 Previsão da geração de potência do SFCR	25
2.2 Redes Neurais Artificiais.....	26
2.2.1 Arquitetura da rede quanto à divisão de camadas	27
2.2.2 Arquitetura da rede quanto a forma de interligação	28
2.2.2.1 <i>Feedforward</i> de única camada.....	28
2.2.2.2 <i>Feedforward</i> de múltiplas camadas	29
2.2.2.3 Redes recorrentes (<i>feedback</i>).....	30
2.2.3 Algoritmo de aprendizagem da rede.....	31
2.3 Identificação das séries temporais usando RNA.....	33
2.4 Trabalhos na área	33
3 MATERIAIS E MÉTODOS.....	36
3.1 Local da pesquisa	36
3.2 Procedimentos da pesquisa	37
3.2.1 Coleta dos dados.....	38
3.2.2 Filtragem dos dados.....	39
3.2.3 Normalização dos dados	41
3.2.4 Implementação da RNA.....	42
3.2.4.1 Validações com a rede <i>feedforward</i> (sem realimentação)	49
3.2.4.2 Validações com a rede NARX (com realimentação).....	50

3.2.5 Métodos para análise do desempenho das previsões com RNA	52
4 RESULTADOS E DISCUSSÕES	56
4.1 Implementação com a rede <i>feedforward</i> (Sem realimentação).....	56
4.1.1 Caso A: Treinamento com dados no período limpo em intervalos de 5 minutos. ..	57
4.1.2 Caso B: Treinamento com dados no período limpo em intervalos de 10 minutos..	59
4.1.3 Caso C: Treinamento com dados no período limpo em intervalos de 1 hora.	62
4.1.4 Validações realizadas para os três casos propostos com a rede <i>feedforward</i>	65
4.1.4.1 Validação ABC - 20% das amostras de treinamento	65
4.1.4.2 Conjunto de Validação ABC1 - Dia 01 de outubro de 2017.....	69
4.1.4.3 Conjunto de Validação ABC2 - Dia 12 de novembro de 2017	74
4.1.4.4 Conjunto de Validação ABC3 - Dia 08 de dezembro de 2017	79
4.1.4.5 Conjunto de Validação ABC4 - Semana de 01 a 07 de outubro de 2017	84
4.1.4.6 Conjunto de Validação ABC9 - Para outras regiões.....	88
4.2 Implementação com a rede NARX (Com realimentação).....	95
4.2.1 Caso D: Treinamento com dados no período limpo em intervalos de 5 minutos. ..	95
4.2.2 Validações realizadas para o caso proposto da rede NARX	97
4.2.2.1 Validação D - 20% das amostras de treinamento	98
4.2.2.2 Conjunto de Validação D1 - Dia 01 de outubro de 2017.....	100
4.2.2.3 Conjunto de Validação D4 - Semana de 01 a 07 de outubro de 2017	103
4.2.2.4 Conjunto de Validação D9 - Para outras regiões.....	107
5 CONCLUSÃO	110
REFERÊNCIAS	112
ANEXO A – LEGENDAS DAS NOMENCLATURAS UTILIZADAS NA PESQUISA ...	116

1 INTRODUÇÃO

As fontes alternativas de energia, principalmente a energia solar fotovoltaica, vêm ganhando um importante espaço no Brasil. Acredita-se que esse crescimento esteja relacionado, sobretudo, a segurança energética do país, que enfrenta longos períodos de estiagem, e afeta o desempenho das usinas hidrelétricas, que compõem primordialmente a matriz energética brasileira (EPE, 2015). Tal fato, prejudica o suprimento de energia oriunda dessas usinas, sendo necessário o acionamento emergencial das termoelétricas, elevando assim o valor cobrado nas faturas de energia.

A temperatura e a irradiação solar são as variáveis climáticas que possuem maior influência na geração de energia elétrica em sistemas fotovoltaicos e, por possuir grande intermitência, tornam-se um dos maiores problemas enfrentados com esse tipo de fonte de energia, podendo reduzir significativamente sua eficiência. Assim, essas variáveis podem ser classificadas como variáveis temporais por depender fortemente das condições meteorológicas, não podendo ser facilmente prevista.

Dentre as variáveis já mencionadas, a irradiação solar destaca-se por apresentar maior impacto nos sistemas fotovoltaicos, e mesmo funcionando com baixos índices de irradiação, sua geração de energia elétrica é reduzida. Apesar da instalação dos sistemas fotovoltaicos ser considerada tecnicamente simples e rápida, requer bastante atenção, ficando o mesmo predisposto a falhas no seu desempenho, devido às perdas em sua eficiência com o não cumprimento dos requisitos necessários para o bom funcionamento desses sistemas. Com isso, para evitar que esses sistemas sejam utilizados de forma inadequada e que antes de serem instalados seja possível obter resultados prévios de geração de energia, se faz necessário utilizar métodos que possibilitem prever a viabilidade desses tipos de sistemas em determinadas localidades.

Para isso serão utilizadas as Redes Neurais Artificiais (RNAs), pois esse tipo de inteligência artificial apresenta bom desempenho ao trabalhar com variáveis temporais, sendo esta uma das principais vantagens com a sua utilização nesta pesquisa. Dentro desses aspectos, as RNAs serão aplicadas no problema de intermitência do sistema solar fotovoltaico, realizando a previsão da potência elétrica gerada a partir das condições climáticas da região, para indicar, preliminarmente, a viabilidade da instalação dos sistemas, ou seja, informar se em determinada localidade será viável ou não a implantação, de acordo com a sua produção.

Diante do que foi exposto, o presente trabalho tem como objetivo realizar a previsão da potência elétrica gerada, em outras regiões do país, utilizando como base o sistema fotovoltaico

de 3kWp instalado em Mossoró/RN, ou seja, verificar a viabilidade da sua instalação em outras localidades. A análise do desempenho da proposta será realizada através dos Erro Médio Percentual (ME%), Percentual da Raiz do Erro Médio Quadrático (RMSE%) e do método de regressão, visando uma maior confiabilidade dos resultados obtidos.

1.1 Objetivo Geral

Prever a potência elétrica gerada por um Sistema Solar Fotovoltaico de 3kWp quando instalado em outras localidades do Brasil utilizando Redes Neurais Artificiais, sendo elas implementadas através do *software* Matlab[®]. Para a realização do treinamento foram inseridas como variáveis de entrada a irradiação solar e a temperatura da cidade de Mossoró-RN no período de seis meses.

1.2 Objetivos Específicos

Com a finalidade de se obter o objetivo geral, os seguintes objetivos específicos foram propostos:

- Identificar e obter as variáveis relevantes para o treinamento da Rede Neural Artificial;
- Determinar as localidades que se deseja prever a potência e assim obter as variáveis climáticas necessárias;
- Realizar treinamentos e validações com diferentes intervalos de amostras;
- Comparar os resultados obtidos entre as redes utilizadas, definindo qual obteve o melhor desempenho;
- Verificar a confiabilidade do método aplicado para a previsão.


2 REVISÃO DE LITERATURA

O presente capítulo visa esclarecer conceitos importantes acerca do assunto abordado. Com destaque para a energia solar fotovoltaica, sistemas fotovoltaicos e a importância da previsão de geração desses sistemas para o seu bom desempenho. Além disso, através da análise de alguns trabalhos existentes, verifica-se a relevância do tema abordado. Discute-se também os conceitos da RNA, e suas ferramentas, visto que o assunto é fundamental para o desenvolvimento do trabalho.

2.1 Sistema Solar Fotovoltaico Conectado à Rede

O Sistema Fotovoltaico Conectado à Rede (SFCR) ou *on-grid*, se caracteriza por se tratar de uma conexão direta com a rede convencional de energia elétrica, onde toda a potência gerada pelo arranjo fotovoltaico é injetada na rede elétrica, sendo consumida instantaneamente, e com isso, dispensa o uso de equipamentos armazenadores de energia. Para tanto é indispensável que seja utilizado um inversor, de modo a satisfazer as exigências de qualidade e segurança para que não comprometa a qualidade do sistema elétrico no qual se interliga o arranjo fotovoltaico (CRESESB, 2004). A Figura 1 mostra a composição principal do SFCR.

Figura 1 – Sistema fotovoltaico conectado à rede elétrica



Fonte: Autoria Própria.

Como pode ser observado na Figura 1, neste tipo de sistema utiliza-se um medidor bidirecional, que contabiliza a energia gerada pelo Sistema Fotovoltaico (SFV) e a energia fornecida pela concessionária local.

No Brasil, a geração de energia elétrica, por meio da tecnologia fotovoltaica, possui um grande potencial, e de acordo com o INPE (2017), no local menos ensolarado do país, é possível gerar mais eletricidade do que no local mais ensolarado da Alemanha, por exemplo. Com esse potencial, o Brasil ganha destaque na implantação desta fonte de energia, podendo contribuir para a redução dos picos de demanda dos sistemas de transmissão do Sistema Interligado Nacional (SIN) (INPE, 2017).

Para esses sistemas existem duas configurações, os sistemas fotovoltaicos distribuídos e os centralizados, sendo elas determinadas de acordo com o porte do sistema e do local de instalação quanto a sua proximidade com o ponto de consumo. A Geração distribuída será melhor explorada na seção 2.1.1, abordando definições e Resoluções Normativas que regem tal configuração.

2.1.1 Geração Distribuída (GD)

Esse método de geração utiliza fontes de energia elétrica de pequeno porte, de forma integrada ou isolada, pelas concessionárias, consumidores e terceiros, gerando eletricidade e consequentes benefícios para o sistema elétrico e para as unidades consumidoras específicas. Essa energia elétrica é produzida no local de consumo ou próximo a ele. Vale ressaltar que a geração distribuída não possui limites de geração, com níveis de potência máxima ou mínima determinados, desta forma ela pode ser formada por unidades de baixa e alta potência. (TORRES, 2015).

Ainda de acordo com Torres (2015), diferente da geração distribuída existe a geração centralizada ou tradicional, que se caracteriza pelas usinas de grande porte, onde grandes centrais de geração fornecem, por meio de uma extensa rede de linhas de transmissão e de distribuição, energia capaz de alimentar diversos consumidores em diversas regiões.

Acredita-se que podem surgir diversas mudanças tanto nas tecnologias envolvidas quanto na forma como são elaborados os negócios com a compra, venda e produção de energia elétrica, caso o crescimento da geração de energia elétrica em suas próprias unidades consumidoras seja algo promissor. De fato, reduzir a demanda das concessionárias ou dos sistemas centralizados, ao produzir sua própria energia, acarreta uma série de mudanças no setor elétrico, demandando cuidados e tecnologias para se adequar ao novo cenário (TORRES, 2015).

O direito do brasileiro gerar sua própria energia elétrica está em vigor desde 17 de abril de 2012, através da Resolução Normativa ANEEL nº 482/2012, nela é citada que o consumidor pode gerar sua própria energia elétrica a partir de fontes renováveis ou cogeração qualificada, e o excedente pode ser fornecido para a rede de distribuição de sua localidade. Nesse contexto, implantam-se a microgeração e a minigeração distribuídas de energia elétrica, aliando e promovendo a economia financeira, consciência socioambiental e autossustentabilidade (ANEEL, 2015a).

Com a atualização da Resolução Normativa 482/2012, novos parâmetros foram criados, passando a ser válido a partir da Resolução Normativa 687/2015, onde tem-se as seguintes definições e informações a respeito dos tipos de geração, em que:

I - microgeração distribuída: central geradora de energia elétrica, com potência instalada menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras;

II - minigeração distribuída: central geradora de energia elétrica, com potência instalada superior a 75 kW e menor ou igual a 3 MW para fontes hídricas ou menor ou igual a 5 MW para cogeração qualificada, conforme regulamentação da ANEEL, ou para as demais fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras;

III - sistema de compensação de energia elétrica: sistema no qual a energia ativa injetada por unidade consumidora com microgeração ou minigeração distribuída é cedida, por meio de empréstimo gratuito, à distribuidora local e posteriormente compensada com o consumo de energia elétrica ativa (ANEEL, 2015b).

Basicamente, esse sistema de compensação funciona quando a energia injetada na rede elétrica é superior à consumida, gerando créditos que podem ser utilizados em até 60 meses. O consumidor tem a opção de utilizar esses créditos em outras unidades previamente cadastradas dentro da mesma área de concessão, desde que seja caracterizada como autoconsumo remoto, geração compartilhada ou integrante de empreendimentos de múltiplas unidades consumidoras, os condomínios, sendo eles, locais diferentes do ponto de consumo. Sobretudo, essa medida pode servir de incentivo para a implantação desses sistemas, em virtude dos diversos benefícios financeiros gerados.

A Resolução Normativa 687/2015 especifica que é possível instalar uma micro ou minigeração em local diferente da unidade consumidora na qual a energia excedente será compensada, com isso foram criadas as modalidades da GD, tais como:

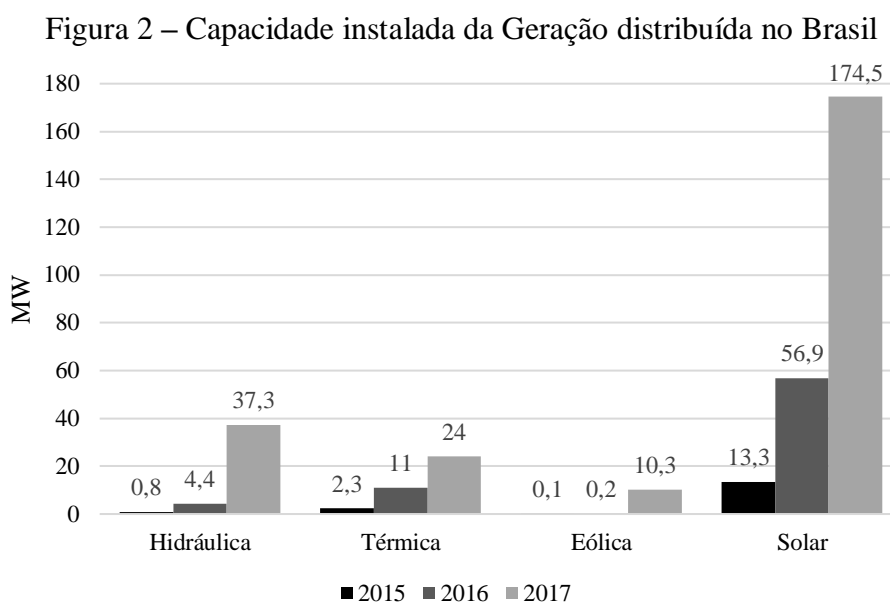
Empreendimento com múltiplas unidades consumidoras: caracterizado pela utilização da energia elétrica de forma independente, no qual cada fração com uso individualizado constitua uma unidade consumidora e as instalações para atendimento das áreas de uso comum constituam uma unidade consumidora distinta, de

responsabilidade do condomínio, da administração ou do proprietário do empreendimento, com microgeração ou minigeração distribuída, e desde que as unidades consumidoras estejam localizadas em uma mesma propriedade ou em propriedades contíguas, sendo vedada a utilização de vias públicas, de passagem aérea ou subterrânea e de propriedades de terceiros não integrantes do empreendimento;

Geração compartilhada: caracterizada pela reunião de consumidores, dentro da mesma área de concessão ou permissão, por meio de consórcio ou cooperativa, composta por pessoa física ou jurídica, que possua unidade consumidora com microgeração ou minigeração distribuída em local diferente das unidades consumidoras nas quais a energia excedente será compensada;

Autoconsumo remoto: caracterizado por unidades consumidoras de titularidade de uma mesma Pessoa Jurídica, incluídas matriz e filial, ou Pessoa Física que possua unidade consumidora com microgeração ou minigeração distribuída em local diferente das unidades consumidoras, dentro da mesma área de concessão ou permissão, nas quais a energia excedente será compensada (ANEEL, 2015b).

No Brasil, a implantação da GD está em crescente avanço, sendo composta principalmente pelas fontes hídricas, térmicas, eólicas e solares. A Figura 2 mostra dados da capacidade instalada da GD para os anos de 2015, 2016 e 2017.



Fonte: Com base em dados de EPE, 2018.

Em 2015 a capacidade total instalada da GD era de 16,5MW, com um aumento significativo em 2016, subindo para 72,5MW, caracterizando um aumento superior a 300%. No ano de 2017, esse aumento foi ainda mais significativo atingindo 246,1MW. Esse expressivo crescimento teve uma maior contribuição por parte da energia solar, que vem se destacando no decorrer dos anos. Em 2018 é mostrado na Tabela 1 as Unidades Consumidoras (UC) com GD divididas por modalidade.

Tabela 1 – Unidades Consumidoras com GD em 2018

Modalidade	Quantidade	Quantidade de UC que recebem os créditos	Potência Instalada (kW)
Autoconsumo remoto	4.455	20.001	135.937,64
Geração compartilhada	172	820	16.118,44
Geração da própria UC	35.476	35.476	343.676,59
Múltiplas UC	26	144	557,97

Fonte: Adaptado de ANEEL, 2018.

Através da Tabela 1 é possível notar que a potência instalada em 2018 ultrapassou 496 MW, distribuídos em 40.129 Unidades Consumidoras por todo o país. Desta forma, percebe-se que estimular a geração distribuída pode gerar diversos benefícios não só ao consumidor, que produz sua própria energia, sendo capaz de fornecê-la às concessionárias, mas também para o sistema elétrico, podendo adiar os investimentos em expansão dos sistemas de transmissão e distribuição, diminuir os impactos ambientais, reduzir o carregamento das redes, minimizar as perdas e contribuir diretamente para a diversificação da matriz energética (ANEEL, 2015a).

O foco principal deste trabalho está na previsão da geração de potência dos SFCR para os estados de Pernambuco e Rio Grande do Sul, evitando dimensionamentos errôneos, sobretudo, devido à redução na geração causada pela baixa incidência de irradiação solar que podem existir nessas localidades. Desta forma, assuntos relacionados ao tema serão abordados com maiores detalhes nas seções 2.1.2, 2.1.3 e 2.1.4, com foco na influência das variáveis climáticas no desempenho dos sistemas fotovoltaicos, bem como o potencial do mesmo no Brasil e a aplicação de previsões para esses sistemas.

2.1.2 Influência das variações climáticas no desempenho dos sistemas fotovoltaicos


As variações climáticas possuem influência significativa na geração de energia a partir de fontes renováveis, sendo os sistemas fotovoltaicos influenciados, principalmente, pelos efeitos da temperatura e intensidade da radiação solar, visto que ao longo do tempo elas variam continuamente, provocadas pelas condições meteorológicas.

Na Figura 3(a) pode-se observar a influência da irradiação solar no desempenho do sistema fotovoltaico, onde a corrente gerada pelo módulo aumenta linearmente com o aumento da intensidade da irradiação solar incidente, e a tensão sofre pouca alteração. Observa-se assim, que é imprescindível a determinação do local adequado para sua instalação, pois o sistema não

irá funcionar de maneira correta, mesmo gerando energia em dias com muita nebulosidade, a geração será de maneira reduzida devido à baixa irradiação solar no local.

O efeito da temperatura pode ser visto na Figura 3(b), onde a eficiência do módulo é afetada quando a tensão diminui significativamente com o aumento da temperatura, enquanto a corrente sofre uma pequena elevação considerada quase desprezível. O nível de insolação e a variação da temperatura ambiente provocam uma variação de temperatura nas células fotovoltaicas, causando um aumento que tende a reduzir a eficiência do sistema (CRESESB, 2004).

Figura 3 – Influência da radiação solar e da temperatura no desempenho dos módulos



Fonte: Adaptado de CRESESB, 2004.

Existem alguns fatores que se caracterizam como sombreamentos em um SFV, tais como, sombreamento causados pela localização da instalação, sombreamento causado por edificações próximas, sombreamentos devido aos painéis fotovoltaicos instalados nas proximidades (COSTA, 2015). Esses são considerados sombreamentos permanentes e ocasionados muitas vezes por falha de projeto, podendo ser evitado antes da instalação.

No entanto, existe o típico sombreamento temporário, resultante da presença de neve, de folhas e de dejetos dos pássaros, pequenas partículas, animais ou entre outros tipos de sujeira (COSTA, 2015). Esses tipos de sombreamentos devem ser solucionados por meio de inspeções e manutenções regulares, garantindo o funcionamento adequado e evitando falhas mais graves. Além disso, alguns tipos de manutenção a serem realizadas, dependendo da magnitude do sistema, podem ser relativamente rápidas e simples. O próprio usuário é capaz de realizar alguns procedimentos para uma boa manutenção preventiva. Entretanto, a manutenção corretiva deve ser realizada por profissionais capacitados, tendo em vista a necessidade de conhecimentos específicos acerca dos componentes que compõem o sistema fotovoltaico (CRESESB, 2004).

Diante do que foi exposto, a temperatura e irradiação solar serão as variáveis utilizadas nessa pesquisa, pois, conforme supracitado, as mesmas apresentam forte influência na geração de potência elétrica dos sistemas fotovoltaicos, e espera-se assim, gerar os melhores resultados no processo de previsão.

2.1.3 Avaliação do potencial para instalação de sistemas fotovoltaicos no Brasil

O Brasil possui grande potencial de crescimento para a instalação de sistemas fotovoltaicos, devido, sobretudo, à sua localização geográfica, que favorece a incidência de variáveis climáticas que possuem ligação direta com o desempenho de tais sistemas.

Essa localização é considerada favorável, pois a extensão territorial do Brasil abrange áreas de baixas e médias latitudes, apresentando diferentes padrões de precipitação, além disso, devido à sua grande extensão territorial, é possível identificar características bastante distintas entre as regiões do país. A exemplo disso, tem-se a Amazônia e o semiárido nordestino que apresentam índices de precipitações opostos, onde na Amazônia a precipitação média é bastante elevada, de duas a sete vezes maior, do que ocorre no semiárido nordestino, com precipitações muito reduzidas (INPE, 2017).

Desta forma, o nível de geração de potência a partir da energia solar fotovoltaica, é influenciado por essas questões climáticas, sobretudo, pela irradiação solar, dependendo fortemente dessa variável meteorológica para operar de forma eficiente. Assim, qualquer situação que impeça a incidência dessa irradiação solar na superfície dos painéis fotovoltaicos, provoca perdas de eficiência, e isso deve ser evitado, para tanto, se faz necessário um estudo prévio no local da sua instalação, para verificar a viabilidade desses sistemas, ou até mesmo métodos de previsão da potência gerada, como por exemplo, técnicas estatísticas e métodos de inteligência artificial.

No Brasil, os níveis de irradiação são considerados elevados, e a Figura 4 mostra os índices médios por região do país.

Figura 4 – Índices de irradiação solar nas regiões do Brasil



Fonte: Adaptado de INPE, 2017.

De acordo com o manual do CRESESB (2014), indica-se que os sistemas fotovoltaicos sejam instalados em regiões com níveis de irradiação superiores a 3 kWh/m².dia, tornando viável esse tipo de adesão e obtendo um melhor aproveitamento desse tipo de energia renovável. Índices acima desse valor são registrados com frequência no Brasil, conforme mostrado na Figura 4, onde apresentam índices médios de irradiação global acima de 4 kWh/m².dia em todas as regiões.

Um estudo realizado pelo INPE (2017) mostra a variabilidade interanual da irradiação solar em cada região do Brasil entre os anos de 2005 e 2015, sendo o Nordeste a região que apresentou a menor variabilidade, com 50% das médias anuais contidas no intervalo entre 5,43 e 5,50 kWh/m², o que indica índices de irradiação a níveis constantes, favorecendo aplicações que façam uso da mesma. Em contrapartida, a região Sudeste registrou a maior variabilidade interanual, com 50% das médias entre 4,97 e 5,11 kWh/m², isso se deve pela forte variação climática característica dessa região. Na região do Sul do país, 50% das médias anuais apresentam valores entre 4,53 e 4,61 kWh/m², enquanto na região Norte os valores médios anuais oscilam entre 4,61 e 4,69 kWh/m².

Com base nesses dados, foram selecionados os estados de Pernambuco e Rio Grande do Sul, localizados nas regiões Nordeste e Sul do país, respectivamente, onde tal escolha se deve às variações climáticas distintas entre eles, e podendo assim, verificar o desempenho do sistema

fotovoltaico de 3kWp abordado nesta pesquisa, quando validados com a RNA em diferentes níveis de temperatura e irradiação solar.

2.1.4 Previsão da geração de potência do SFCR

O ato de prever a produção de energia de sistemas intermitentes, como no caso dos sistemas fotovoltaicos, independentemente do método de previsão escolhido, possui papel fundamental, seja no armazenamento de energia ou no controle da rede elétrica convencional, permitindo uma adaptação da carga de forma a otimizar o transporte de energia ou planejar atividades de manutenção (FERNANDES, 2014).

Apesar do Brasil apresentar índices favoráveis para a instalação de sistemas fotovoltaicos, essa fonte de energia renovável possui grande intermitência, devido às frequentes variações de clima das regiões brasileiras que não seguem fielmente os padrões climáticos de suas estações do ano, influenciado assim na irradiação solar. Essa por sua vez, possui influência direta na geração fotovoltaica, pois quanto maior forem esses níveis de irradiação, melhor será o desempenho do sistema, e conseqüentemente uma maior geração de potência elétrica.

Com isso, o ideal é que se tenha uma previsão do que poderá ser gerado antes de realizar a instalação dos sistemas. Essa previsão é importante, pois possibilita uma melhor gestão da energia, bem como um melhor aproveitamento da mesma, evitando a instalação em locais que não atendam aos requisitos mínimos recomendados para geração dos níveis desejados de energia elétrica.

Além disso, conforme abordam Li et al. (2014), aplicações de previsão da produção de energia através de sistemas fotovoltaicos possuem efeitos significativos na estabilidade de sistemas de potência. O método proposto por eles fez uso de RNA para prever a geração de energia solar fotovoltaica, e atingiu uma elevada exatidão nos resultados. No entanto foi detectada uma redução na precisão do resultado final com o aumento da distância dos pontos previstos, com isso considerou-se intervalos de tempo de uma hora, visando diminuir os erros.

Já Dragoon e Papaefthymiou (2015) abordam que, os modelos de previsão mais eficientes se destacam por melhorar as condições de operação de um sistema fotovoltaico. No entanto, enfatizam também que a qualidade da previsão da geração fotovoltaica pode ser prejudicada pela intermitência e variação da disponibilidade do sol.

Desta forma, Rahman e Hazim (1993) enfatizam algumas técnicas utilizadas em previsões, tais como, séries de modelo temporais de Box-Jenkins, o Modelo Auto Regressivo Integrado de Médias Móveis (ARIMA), regressão linear e modelos adaptativos, que são

classificadas como técnicas estatísticas. Existem também técnicas da inteligência artificial que realizam essas previsões, com destaque para a Lógica Fuzzy e as Redes Neurais Artificiais, sendo utilizados também os modelos híbridos que empregam as duas técnicas.

Entre as técnicas citadas, a RNA foi selecionada para ser implementada nessa pesquisa. Diante disto, no item 2.2 serão abordadas algumas definições a respeito desse método, bem como, parâmetros importantes que devem ser configurados para obter seu melhor desempenho.

2.2 Redes Neurais Artificiais

A Rede Neural Artificial é considerada uma ferramenta da Inteligência Artificial (IA) que funciona de forma semelhante ao cérebro humano por tentar reconhecer regularidades e padrões dos dados. Segundo Haykin (2001), uma rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. O bom desempenho de uma RNA pode ser alcançado por meio de uma interligação maciça de células computacionais denominadas neurônios. Elas aprendem por experiência, e acumulam conhecimentos que serão posteriormente generalizados para tomadas de decisões.

A não linearidade de algumas variáveis pode ser vista com um empecilho para alguns métodos de computação convencional, no entanto, para as RNAs essa é considerada uma de suas principais vantagens, sendo também uma das razões para a adoção desse método. Dentro desses aspectos tem-se as séries temporais, que são qualquer conjunto de observações ordenadas no tempo, e tem como objetivo investigar o mecanismo gerador da série, fazer previsões de valores futuros, descrever apenas o comportamento e procurar periodicidades relevantes nos dados (MORETTIN & TOLOI, 2006).

Desta forma, a relação entre as RNAs e as séries temporais é usualmente aplicada na previsão destas séries, pois permite a aproximação da maioria das funções não-lineares. As séries temporais apresentam comportamentos em que as propriedades de convergência, generalização e aprendizado das redes neurais podem gerar resultados satisfatórios quando comparados com outros modelos (MARTINS; METTE; MACEDO, 2008).

Para isso, a RNA é composta por um neurônio artificial, sendo ele o componente básico de uma RNA e de fundamental importância para o funcionamento da mesma, ele é também denominado unidade de processamento de informação (HAYKIN, 2001). O neurônio artificial é capaz de receber estímulos em sua entrada, de diversos outros neurônios e propagar uma saída, em função dos estímulos recebidos e do estado interno, a vários outros neurônios. A interconexão de diversos neurônios gera a estrutura da rede neural. (CASILLO e VALE, 2017).

Para a implementação de uma RNA, é necessário ainda a inserção de uma função de ativação, que tem como objetivo principal, limitar a saída do neurônio e introduzir não linearidade no modelo (CASILLO e VALE, 2017). Existem 4 modelos principais de funções de ativação, a saber, a função linear, sigmoide, hiperbólica e degrau.

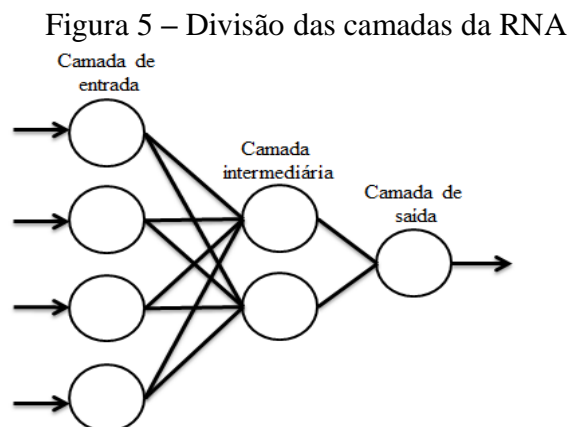
A escolha da função de ativação depende da aplicação, sendo necessário um conhecimento prévio das características do problema, para que seja determinada essa escolha. Caso o valor de um determinado problema seja positivo, por exemplo, é indicado aplicar a função sigmoide, visto que a mesma tem como característica fornecer sempre valores positivos.

Outro parâmetro importante na implementação da RNA é método de inicialização dos pesos, sendo a inicialização aleatória o método mais comum, por ser simples e possuir habilidade de múltiplas soluções. Dependendo da inicialização, a quantidade de ciclos de treinamento pode ter uma redução significativa, sem alterar o desempenho da rede (CASILLO e VALE, 2017).

2.2.1 Arquitetura da rede quanto à divisão de camadas

A arquitetura de uma RNA define como seus neurônios estão arranados, ou dispostos, uns em relação aos outros. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios (SILVA et. al., 2010).

Uma rede neural artificial pode ser dividida em três partes, denominadas de camadas, conforme a Figura 5.



Fonte: Autoria própria

As camadas que constituem a RNA podem ser definidas como (SILVA et. al., 2010):

- Camada de entrada: é a camada responsável pelo recebimento de dados externos.

- Camada intermediária: Também conhecida como camada escondida ou oculta. Nelas ficam localizados os neurônios que possuem a responsabilidade de extrair as características associadas ao processo. Vale salientar que algumas redes não possuem essa camada.
- Camada de saída: Esta camada é constituída pelos neurônios responsáveis pela produção e apresentação dos resultados finais da rede, esses resultados são decorrentes dos processamentos efetuados pelos neurônios das camadas anteriores.


2.2.2 Arquitetura da rede quanto a forma de interligação

A arquitetura da RNA quanto à disposição dos seus neurônios, a forma de interligação entre eles, a constituição de suas camadas e a característica de realimentação, podem ser subdivididas em três classes de arquiteturas, a *Feedforward* de única camada, *Feedforward* de múltiplas camadas e Redes recorrentes (*feedback*) (SILVA et. al., 2010). Sendo as duas últimas abordadas nas subseções 2.2.2.2 e 2.2.2.3 com maiores detalhes, visto que as mesmas foram aplicadas na pesquisa.

2.2.2.1 *Feedforward* de única camada

É constituída, basicamente, por uma camada de entrada e uma camada de saída, onde fica a única camada de neurônios, conforme Figura 6. Observa-se que para esse tipo de rede, o número de saídas sempre irá coincidir com o número de neurônios. Ela é geralmente recomendada para problemas envolvendo classificação de padrões e filtragem linear. O *Perceptron* e o *Adaline* são exemplos de rede que possuem essa característica simples (SILVA et. al., 2010).

Figura 6 – *Feedforward* de única camada

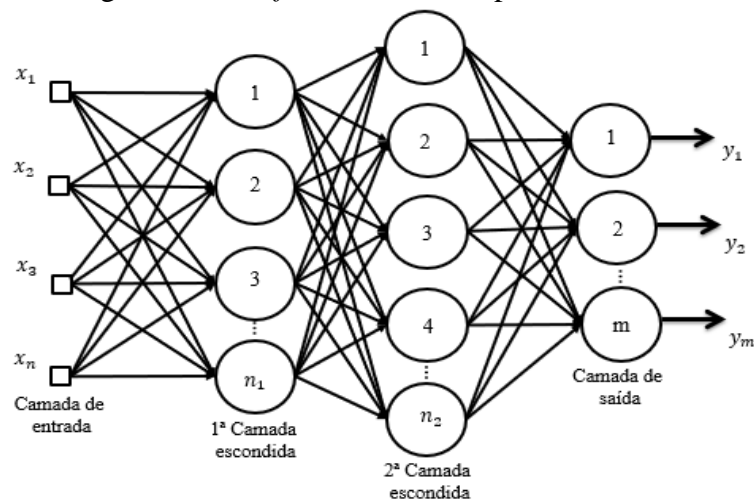


Fonte: Adaptado de SILVA et. al., 2010.

2.2.2.2 *Feedforward* de múltiplas camadas

A rede de múltiplas camadas, também são conhecidas como *Multilayer Perceptron* (MLP). Elas são constituídas por uma ou mais camadas escondidas de neurônios. Geralmente são aplicadas em aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processo, etc. (SILVA et. al., 2010). Como mostra a Figura 7, essa rede é formada por uma camada de entrada com n sinais, duas camadas escondidas, composta por n_1 e n_2 neurônios, e uma camada de saída com m neurônios, que será também o número de saídas.

Figura 7 – *Feedforward* de múltiplas camadas



Fonte: Adaptado de SILVA et. al., 2010.

Com visto na Figura 7 as redes *feedforward* são caracterizadas por possuir uma propagação de sinal, seguindo da camada de entrada, passando pelas camadas ocultas, até atingir a camada de saída, sem apresentar uma realimentação da informação, desta forma, as interligações das camadas são conectadas de forma que a saída de uma camada é conectada imediatamente na entrada da camada posterior.

De acordo com Principe & Kuo (1995) as redes feedforward por apresentar características estáticas, esse tipo de rede pode não ser capaz de capturar a dinâmica de um sistema. Para tanto, se faz necessário o uso das redes recorrentes, que por possuir a capacidade de agregar memória à rede neural se torna mais apropriada e mais eficaz na captura da dinâmica de um sistema.

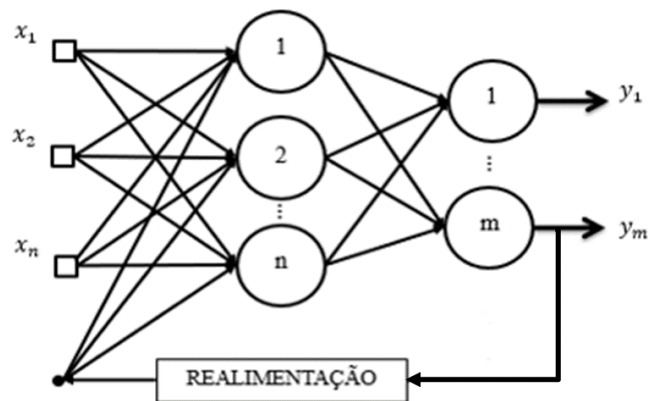
No entanto, Tsoi (1998) *apud* Souza (2007) afirma que uma das maiores razões que torna estas redes populares, é o fato de sua arquitetura ser um aproximador universal, para

mapeamentos estáticos não lineares gerais, para isso o número de neurônios na camada intermediária deve ser suficiente.

2.2.2.3 Redes recorrentes (*feedback*)

São redes que se comportam como uma MLP, no entanto possui uma realimentação, que fornece informações da saída para a entrada, ou seja, as saídas dos neurônios da última camada funcionam como sinais de entrada para os neurônios das camadas iniciais. Essa característica possibilita a implantação de tais redes em processamento dinâmico de informações, podendo ser utilizadas em sistemas variantes no tempo (SILVA et. al., 2010). A Figura 8 mostra o esquema de uma rede recorrente.

Figura 8 – Esquema de uma rede recorrente



Fonte: Adaptado de SILVA et. al., 2010.

Outro modelo de rede que será abordado nesse trabalho é a rede neural *Nonlinear Autoregressive Model With Exogenous Inputs* (NARX), um tipo de rede recorrente e não linear, que se comporta como uma MLP, no entanto possui uma realimentação da saída com atrasos de tempo.

A rede NARX, trata-se de uma rede dinâmica com realimentação, formada por uma conexão que interliga as informações da saída com a entrada, de forma que essas informações chegam com atrasos de tempo. A rede NARX é baseada no modelo ARX linear, que é muito utilizado em previsões de séries temporais, e utilizados na identificação de sistemas lineares tipo caixa preta (ÁLVAREZ, 2015).

A Equação (1) define o modelo NARX, onde observa-se os regressores existentes, de forma que o próximo valor do sinal de saída dependente $y(t)$ é regredido em valores anteriores

do sinal de saída e valores anteriores de um sinal de entrada independente (exógeno) (ÁLVAREZ, 2015).

$$y(t) = f(y(t-1), (t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (1)$$

O laço de realimentação existente na rede NARX permite criar uma memória interna onde são guardados os valores passados da saída e os reintroduzem após um número determinado de retardos na rede como uma variável de entrada adicional (ÁLVAREZ, 2015). A partir dessas características, a rede NARX pode ser aplicada em diversas situações, como por exemplo, para prever o próximo valor do sinal de entrada, em filtragem não linear e na modelagem de sistemas dinâmicos não lineares (MATLAB, 2019a).

2.2.3 Algoritmo de aprendizagem da rede

A RNA se destaca por aprender a partir de amostras que expressam o comportamento do sistema. Onde logo após a rede aprender a relação existente entre a entrada e a saída ela será capaz de generalizar as soluções, estando apta a apresentar valores próximos do esperado, para quaisquer valores inseridos na entrada da rede (SILVA et. al., 2010).

Para treinar uma rede neural aplicam-se alguns passos ordenados necessários para sintonização dos pesos sinápticos e limiares de seus neurônios, obtendo ao final as generalizações das soluções produzidas pelas suas saídas. Esse conjunto de passos é denominado algoritmo de aprendizagem, e ao longo da aplicação extrai características discriminantes do sistema através de amostras retiradas do seu contexto (SILVA et. al., 2010).

O conjunto de amostras selecionado, que abrange as características do sistema, é dividido em dois subconjuntos, o de treinamento, que compreende cerca de 60% a 90% das amostras do conjunto real, utilizado no processo de aprendizado da rede, e o subconjunto de teste, onde utiliza-se entre 10% e 40% do conjunto das amostras, que serve para verificar os aspectos de generalização de soluções da rede, se os mesmos se encontram em faixas aceitáveis, validando assim a topologia escolhida (SILVA et. al., 2010).

Recebe o nome de época o processo iterativo que ocorre durante o treinamento da RNA, é um ciclo de aprendizagem composto das fases de treinamento e teste. O número de épocas necessário para determinar um bom ajuste varia devido alguns fatores, tais como, a

complexidade do problema, os pesos atribuídos inicialmente e a taxa de aprendizagem¹ (SILVA, 2002). Geralmente, o número de épocas é determinante para o critério de parada do treinamento da rede.

No processo de implementação das RNA deve-se atribuir um critério de parada, onde o treinamento é interrompido quando atinge o mínimo erro quadrático médio para os dados de validação ou quando o número pré-determinado de épocas de treinamento for alcançado, no entanto pode-se utilizar uma combinação desses dois fatores (BATISTA, 2009).

Os algoritmos de treinamento podem ser classificados em Supervisionado e Não supervisionado. O que determina essa diferença entre eles é que, no treinamento supervisionado existe a influência de um “professor” com o intuito de verificar possíveis desvios da rede. A partir dos valores de entrada deve-se verificar se a saída obtida possui valores próximos da desejada, caso contrário os pesos devem ser ajustados pelo algoritmo de aprendizagem, que analisa essa defasagem existente entre a saída obtida e a desejada, realizando o procedimento de ajuste. A rede será considerada treinada, quando essa defasagem apresentar valores aceitáveis. No processo de treinamento não supervisionado, não existe a supervisão de um “professor” durante aprendizagem da rede, não necessitando de uma saída desejada. Com isso, através dos dados fornecidos na entrada da rede, a mesma será capaz de generalizar as informações e extrair padrões (SILVA, 2002).

Destaca-se como algoritmo supervisionado o *Backpropagation*, um dos algoritmos mais conhecidos e utilizados. O mesmo trabalha com amostras de entradas e saídas e seu treinamento é dividido em duas etapas, na primeira os sinais das entradas são inseridos e propagados camada por camada até que se obtenha um valor de saída, o mesmo será comparado com o valor de saída desejado, havendo alguma divergência entre eles, ou seja, o surgimento de um erro, este será então retro propagado para a entrada da rede, onde serão feitos ajustes dos pesos, esse processo deverá ser repetido até que se obtenha o menor erro possível.

Outro tipo de algoritmo de treinamento bastante conhecido e também utilizado na implementação da rede neural dessa pesquisa foi o *Levenberg-Marquardt*, que trata-se de uma técnica iterativa que localiza o valor mínimo de uma função que é expressa como a soma dos quadrados de valores reais de funções não lineares (LOURAKIS, 2005). A principal vantagem com a utilização desse algoritmo é a sua capacidade de acelerar o processo de convergência. Essa aceleração do treinamento baseia-se na determinação das derivadas de segunda ordem do

¹ Essa taxa funciona como fator multiplicativo na correção dos pesos das conexões entre os neurônios, ela indica a rapidez com que os pesos sinápticos são ajustados, ou seja, a velocidade de aprendizagem da rede (SILVA, 2002).

erro quadrático em relação aos pesos, diferindo do algoritmo *backpropagation* tradicional que considera as derivadas de primeira ordem (BARBOSA et al., 2005).

2.3 Identificação das séries temporais usando RNA

As RNAs são bastante utilizadas no reconhecimento de padrões temporais e previsões. Segundo Haykin (1994) *apud* Medeiros (2016), se o problema envolver séries temporais, se faz necessário à inserção de um mecanismo de memória, que tem como principal objetivo transformar uma rede neural estática em uma rede dinâmica, ou seja, transformar as características puramente estáticas em dinâmicas (HAYKIN, 2001).

Essa memória pode ser dividida em memória de curto prazo e de longo prazo, dependendo do tempo de retenção. A inserção da memória de longo prazo na RNA é feita por meio da aprendizagem supervisionada, onde o conteúdo de informação do conjunto de amostras de treinamento fica armazenado, parcialmente ou totalmente, nos pesos sinápticos. Já a inserção da memória de curto prazo, se faz pelo atraso de tempo, sendo esta uma das maneiras mais simples, podendo ser implementada a nível sináptico na própria rede ou na camada de entrada (HAYKIN, 2001). De acordo com Haykin (1994) *apud* Medeiros (2016) a aplicação de uma memória de curto prazo em conjunto com uma memória de linha de atraso derivada na entrada da RNA, é considerada uma das redes mais simples e mais utilizadas na previsão de séries temporais.

Quando um sinal de entrada de valores no presente e de valores no passado é armazenado em uma memória de linha de atraso no tempo, os parâmetros livres da rede neural são ajustados visando obter o mínimo erro quadrático médio entre a saída da rede e a resposta desejada (VILLAMAGNA, 2013).

A partir disso, serão abordadas na seção 2.4, algumas aplicações das RNAs na previsão de variáveis dos SFV que influenciarão na potência gerada pelos sistemas fotovoltaicos, mostrando dados de diferentes locais e expondo a relevância da proposta deste estudo.

2.4 Trabalhos na área

A pesquisa de Mellit e Pavan (2010), trata de uma planta fotovoltaica de 20 kWp instalada no telhado do município de Trieste, na Itália. O processo foi implementado no Matlab[®] utilizando *perceptron* multicamadas (MLP) e o algoritmo de treinamento *backpropagation*, onde dois modelos de RNAs foram desenvolvidos e implementados. O primeiro modelo utiliza

como variáveis de entrada a irradiação solar e a temperatura do ar, enquanto o segundo modelo usa apenas a irradiação solar como parâmetro de entrada, vale salientar que ambos os modelos possuem a potência gerada como variável de saída. Dentre as análises de desempenho de previsão adotados, destaca-se o coeficiente de correlação, onde os resultados mostram uma boa eficiência entre a potência medida e a prevista, com resultados do coeficiente de correlação na faixa de 98-99%. Ambos os modelos apresentaram um bom desempenho, no entanto, o primeiro modelo apresenta um desempenho mais preciso se comparado ao segundo, visto que, para o treinamento do mesmo, utilizou-se mais variáveis de entrada, contudo, os autores destacam que mesmo sendo implemento com apenas uma variável de entrada, o segundo modelo apresenta um desempenho significativo e útil para casos em que apenas a irradiação solar esteja disponível.

Mellit et. al. (2013) abordam a previsão da potência gerada de um SFV de 50Wp utilizando RNA, a pesquisa foi realizada em Istambul na Turquia com amostras no período de 01/01/2011 a 24/02/2012. A rede foi implementada utilizando a irradiação solar, temperatura do ar, tensão do módulo fotovoltaico e corrente do módulo fotovoltaico como variáveis de entrada. A partir disso realizou-se duas previsões distintas, sendo uma para um dia nublado (22 de janeiro de 2012) e outra para um dia ensolarados (15 de agosto de 2011). Os resultados obtidos mostram que a previsão para o dia ensolarado apresentou resultados melhores do que para o dia nublado, sendo comprovada tal consideração através dos coeficientes de correlação, que para o dia nublado foi de 0,9640 e o dia ensolarado obteve um coeficiente de 0,9722, apesar da diferença dos coeficientes, ambos são próximos de 1, e caracterizando uma boa previsão.

Já o trabalho de Jumaat et. al. (2016) teve como objetivo prever a radiação solar incidente no sistema fotovoltaico usando RNA localizado em Batu Pahat na Malásia. Para isso foram utilizadas cinco variáveis de entrada, sendo elas, a temperatura do ar, temperatura mínima, temperatura máxima, umidade relativa e velocidade do vento, obtidas no *Software RETScreen*. Para o treinamento da rede utilizou-se a topologia *perceptron* de multicamada com propagação reversa, o algoritmo de treinamento foi o *Levenberg-Marquardt*. A rede possui 2 camadas ocultas, compostas por 20 e 10 neurônios respectivamente, sendo as funções de ativação para as camadas ocultas a *tansig* e a de saída a *purelin*. Ao realizar análises do desempenho de treinamento, tem-se um coeficiente de correlação de 65,4%, com erro médio quadrático para a etapa de treinamento de 0,0670, para o conjunto de testes foi de 0,1169 e o conjunto de validação é 0,1117. Através do coeficiente de correlação obtido, nota-se que a rede não obteve um bom desempenho.

Outra pesquisa que faz uso da RNA para previsão da potência gerada pelo SFV foi desenvolvida por Kayri e Gencoglu (2017). A RNA foi utilizada para prever a produção de energia de um sistema solar fotovoltaico, essa pesquisa tem como diferencial o fato do SFV possuir um único eixo com rotação na direção leste-oeste. Foram utilizadas duas RNAs, treinadas com dados coletados em dias ensolarados (RNA1) e em dias nublados (RNA2), sendo utilizados como variáveis de entrada, a velocidade do vento, direção do vento, ângulo de elevação solar, temperatura do ar, umidade relativa, radiação global. A rede teve como configuração a arquitetura *feedforward* com duas camadas ocultas, 15 neurônios em cada, e as funções de ativação adotadas foram a sigmoide e a tangente hiperbólica, utilizando o algoritmo de treinamento *backpropagation*. A precisão dos resultados obtidos foi analisada através do Erro Quadrado Médio (MSE), Raiz do Erro Quadrático Médio (RSME), Erro Absoluto Médio (MAE) e o coeficiente de correlação, esses índices foram calculados por meio de comparações feitas entre os dados previstos com a rede e os dados medidos *in loco*. Comparando os resultados das validações, nota-se que as redes não apresentaram dados com muitas diferenças, onde para a RNA1 obteve-se MSE=0,00548, RMSE=0,0234, MAE=0,0155, já para a RNA2 os índices obtidos foram, MSE=0,001065, RMSE=0,03264, MAE=0,02241. O coeficiente de correlação é a principal variável que determina os desvios dos dados previstos e reais, e ele também apresentou dados semelhantes para as RNA1 e RNA2, com 0,991 e 0,980 respectivamente, é possível notar a partir disso, que as redes apresentam um bom desempenho para as previsões propostas.

Através das literaturas pesquisadas percebe-se que as RNAs são comumente aplicadas na previsão de variáveis de sistemas FV, evidenciando que a diferença entre as pesquisas é basicamente as variáveis utilizadas, a arquitetura da rede e o algoritmo de aprendizado aplicado.

Diante dos aspectos analisados, percebe-se que a potência gerada de um sistema fotovoltaico requer atenção, visto que o desempenho do mesmo pode ser comprometido com a instalação inadequada. Desta forma, o foco principal deste trabalho será a utilização da RNA, que se mostrou bastante eficiente em trabalhos apresentados ao longo deste capítulo, para prever a potência gerada de um sistema fotovoltaico quando instalado em outras localidades, com o intuito de evitar que o mesmo seja instalado em locais que não apresentam climas favoráveis à instalação desses sistemas. No Capítulo 3, serão abordados o local de estudo e as etapas a serem seguidas, detalhando a obtenção dos dados iniciais e a utilização de ferramentas essenciais para o alcance dos resultados finais da pesquisa.

3 MATERIAIS E MÉTODOS

O presente capítulo descreve o local da pesquisa, os procedimentos realizados para a obtenção das variáveis utilizadas na implementação da RNA, bem como o detalhamento das etapas dessa implementação.

3.1 Local da pesquisa

A pesquisa foi desenvolvida na Universidade Federal Rural do Semi-Árido (UFERSA), Campus Leste, localizada na cidade de Mossoró-RN, em um sistema solar fotovoltaico presente no Centro Integrado de Inovação Tecnológica do Semiárido (CITED). Vale ressaltar, que a cidade de Mossoró possui altos índices de incidência solar durante todo o ano, o que favorece o desempenho dos sistemas fotovoltaicos na região e incentiva estudos e investimentos no setor.

O sistema em estudo trata-se de uma planta fotovoltaica conectada à rede com conexão monofásica, possuindo 3kW de potência nominal. O sistema é composto por quatorze (14) módulos fotovoltaicos, um inversor fotovoltaico, quadro de comando e proteção e um medidor bidirecional, no entanto, a pesquisa teve o suporte principal dos módulos e do inversor fotovoltaico, devido às análises e dados retirados dos mesmos.

Os módulos instalados no sistema fotovoltaico são da marca *Yingli Solar*, modelo YL245P -29b, de 245W cada, com conexão em série, a Figura 9 mostra a disposição dos módulos.

Figura 9 – Módulos fotovoltaicos do SFCR do CITED



Fonte: Autoria própria.

Para converter a corrente contínua gerada pelos módulos fotovoltaicos, utiliza-se o inversor *Sunny Boy 3000HFUS*, da SMA, que transforma essa corrente contínua em corrente alternada, possibilitando a sincronização com a rede convencional e a alimentação da grande maioria dos equipamentos eletroeletrônicos, a Figura 10 mostra o inversor utilizado.

Figura 10 – Inversor fotovoltaico



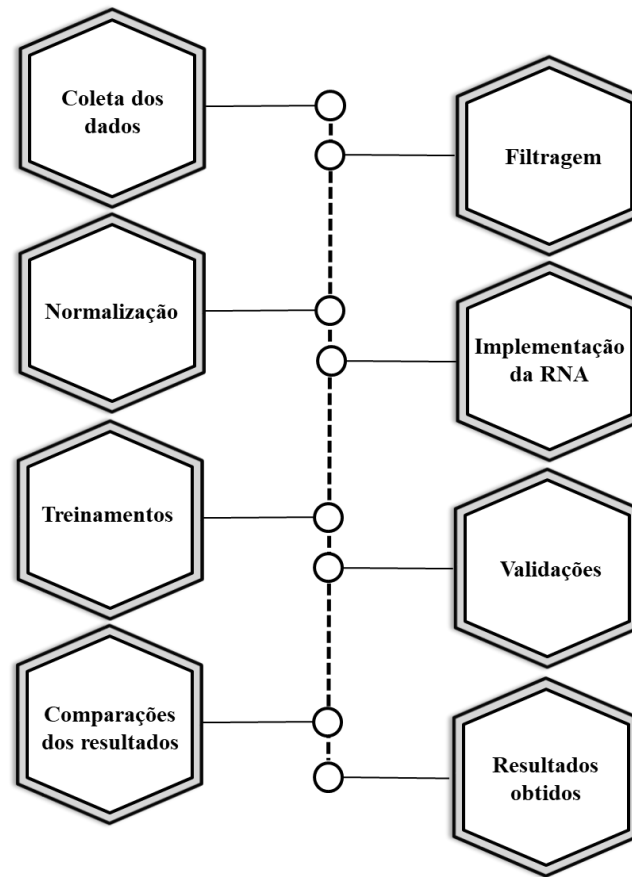
Fonte: Autoria própria.

O inversor fotovoltaico mostrado na Figura 10, além de realizar sua função principal de converter a corrente elétrica, possui tecnologia capaz de fornecer dados importantes, em tempo real, do desempenho do sistema, na própria interface do equipamento e através do programa computacional.

3.2 Procedimentos da pesquisa

Para o desenvolver do tema proposto se fez necessário, visando uma melhor organização e otimização, dividir o trabalho em etapas, desta forma, a pesquisa foi dividida em 8 (oito) etapas, que serão descritas no decorrer desse capítulo. De forma simplificada, a Figura 11 mostra a estrutura metodológica do trabalho.

Figura 11 – Metodologia da pesquisa



Fonte: Autoria própria.

Como pode ser visto na Figura 11, a divisão do processo se inicia com a coleta dos dados, e a partir disso, houve a necessidade de se aplicar métodos de filtragem e normalização, para que em seguida fosse iniciada a implementação da RNA no Matlab[®], seguindo as etapas de treinamento e validação. Após a implementação da RNA foram realizadas uma série de validações, variando os dias e os intervalos das amostras, logo depois, compararam-se os resultados reais com os previstos pela rede. Por fim, com os resultados obtidos pôde-se informar a potência gerada em outras regiões, auxiliando quando houver incertezas a respeito da viabilidade da instalação do sistema fotovoltaico. Vale salientar que cada uma das etapas foi elaborada conforme a busca em atingir os melhores resultados da pesquisa, e consequentemente alcançar melhores previsões de potência.

3.2.1 Coleta dos dados

Para realizar o treinamento da RNA se faz necessário a utilização de variáveis de entrada que estejam diretamente relacionadas com a variável de saída. Para isso, optou-se pela

utilização da irradiação solar e da temperatura (variáveis de entrada), que possui influência direta na potência gerada (variável de saída) pelo sistema solar fotovoltaico.

As variáveis de entrada foram adquiridas junto à estação meteorológica da UFERSA Espaço ASA/UFERSA, localizada no campus oeste. Já a variável de saída, foi obtida por meio do inversor fotovoltaico, visto que o mesmo possui a função de armazenar, por um determinado período, informações da planta fotovoltaica. O inversor utilizado na pesquisa dispõe de um *software* computacional (*Sunny Explore*) para monitoramento via *bluetooth*, onde realizou-se o *backup* dos valores, em formato CSV (*Comma-separated values*), da potência gerada no período escolhido.

Inicialmente a coleta das variáveis de entrada e saída utilizadas para treinar a RNA foi realizada em condições ideais, onde os módulos fotovoltaicos foram limpos semanalmente durante todo o período de aquisição, de 01 de outubro de 2017 a 31 de março de 2018, totalizando 6 (seis) meses.

Como a proposta do trabalho é prever a potência elétrica gerada da instalação de uma planta fotovoltaica de 3kWp em outras regiões, se fez necessário obter irradiação e temperatura de outras localidades, para inserir como variáveis de entrada nas validações da RNA e desta maneira obter as previsões pretendidas. Para isso, utilizou-se os dados do *site Wunder Ground*, onde no mesmo possui dados meteorológicos de todo o mundo de forma *online* e gratuita.

Desta forma, a fim de verificar a coerência das previsões para locais com diferentes incidências de irradiação solar, foram coletados dados, através do *Wunder Ground*, para o Rio Grande do Sul, que possui uma grande disparidade de clima com relação a cidade de Mossoró/RN, e dados de Pernambuco, que dentre as estações meteorológicas da região nordeste disponíveis no site, foi a que teve maior proximidade geográfica com Mossoró. Os dados foram coletados nos dias 01 de outubro de 2017, 12 de novembro de 2017 e 08 de dezembro de 2017, bem como da semana compreendida entre os dias 01 e 07 de outubro de 2017. A escolha de todos esses períodos mencionados coincide com o período em que houve a maior geração de potência elétrica de cada mês da planta fotovoltaica em estudo.

3.2.2 Filtragem dos dados

As grandezas utilizadas como variáveis de entrada e saída possuem elevada intermitência, variando muito ao longo do dia, desta forma, os dados coletados refletem essas variações, apresentando diversos ruídos que podem influenciar negativamente o treinamento da RNA. Desse modo, pretendendo evitar imprecisões dos resultados, realizou-se dois processos de

filtragem desses dados, o primeiro, consistiu na retirada dos valores de 0 (zero) (período em que não há irradiação solar suficiente para a geração de potência elétrica), da planilha de dados, com o uso do Excel[®]. O segundo filtro foi aplicado com o auxílio do Matlab[®], onde o mesmo possui um comando (*filter*) que é baseado no método estatístico da média móvel. Esse método trata-se de uma técnica de suavização dos dados, descrito pela Equação (2), que calcula a média dos dados dependentes do tempo em relação à hora atual e às horas anteriores de dados.

$$a(1)y(n) = b(1)x(n) + b(2)x(n - 1) + \dots + b(N_b)x(n - N_b + 1) - a(2)y(n - 1) - \dots - a(N_a)y(n - N_a + 1) \quad (2)$$

Onde,

a e b são vetores de coeficientes do filtro;

N_a é a ordem do polinômio descrito pelo vetor a ;

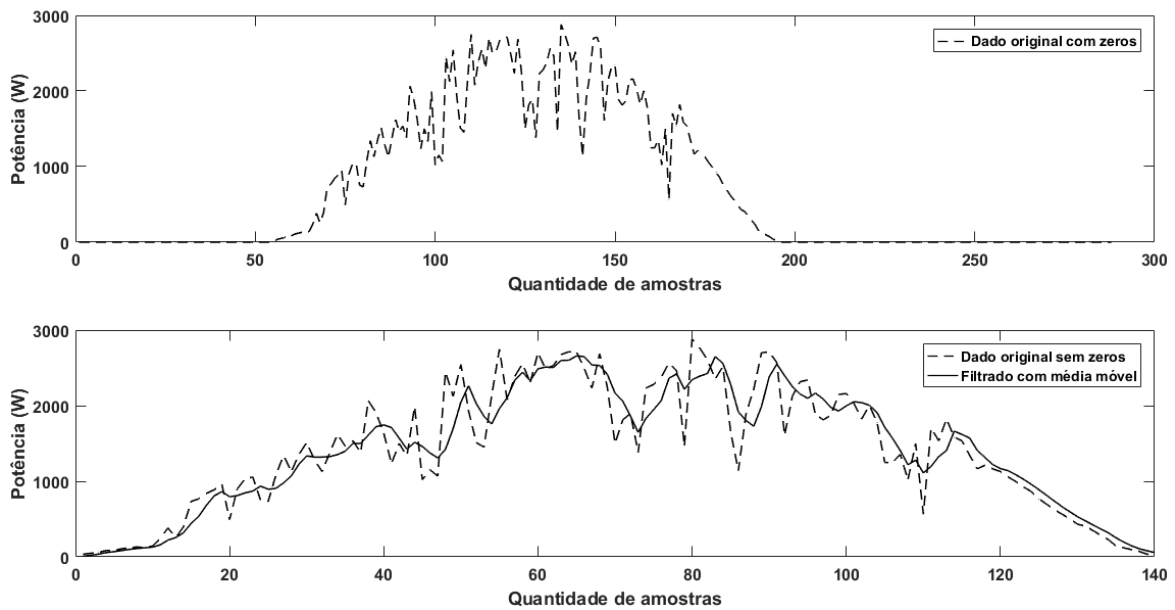
N_b é a ordem do polinômio descrito pelo vetor b ;

n é o índice da amostra atual de x ;

$y(n)$ é uma combinação linear dos elementos atual e anterior de x e y .

Apesar disso, a implementação com o comando *filter* requer a inserção apenas dos coeficientes de filtro, que para essa aplicação foram adotados os valores de a igual a 1 e b igual a $\frac{1}{4}$. Esses valores foram os que apresentaram os melhores resultados no processo de filtragem, suavizando as curvas e reduzindo os picos existentes. Com a aplicação das duas técnicas de filtragem o objetivo foi alcançado, visto que, observou-se uma menor incidência de ruídos nas amostras. Para ilustrar essa informação, tem-se a Figura 12, que mostra uma pequena parcela filtrada dessas variáveis. Vale destacar que esse processo de filtragem foi aplicado em todas as amostras do trabalho.

Figura 12 – Técnicas de filtragem das amostras



Fonte: Autoria Própria.

Como visto na Figura 12, tem-se a geração de potência para um dia, com a aplicação das duas técnicas de filtragem, onde se obteve uma redução das amostras, com a retirada dos zeros, e uma suavização dos dados com a aplicação da média móvel, reduzindo significativamente os picos registrados.

3.2.3 Normalização dos dados

O propósito de utilizar a técnica de normalização é reduzir problemas quando se trabalha com variáveis que possuem unidades e dispersões distintas. Desta forma, é comum que essas amostras não possuam uma variação com a mesma ordem de grandeza, afetando o treinamento de forma que haja uma atribuição de maior importância para certas variáveis e outras não.

O processo de normalização consiste em ajustar os valores de todas as variáveis, que contêm escalas diferentes, convertendo-os em um tamanho comum a todos. Para isso, utilizou o comando *mapminmax* do Matlab[®], que realiza esse ajuste, e baseia-se na Equação (3).

$$y = \frac{(y_{max} - y_{min}) * (x - x_{min})}{x_{max} - x_{min}} + y_{min} \quad (3)$$

Onde,

x é o elemento do vetor a ser normalizado;

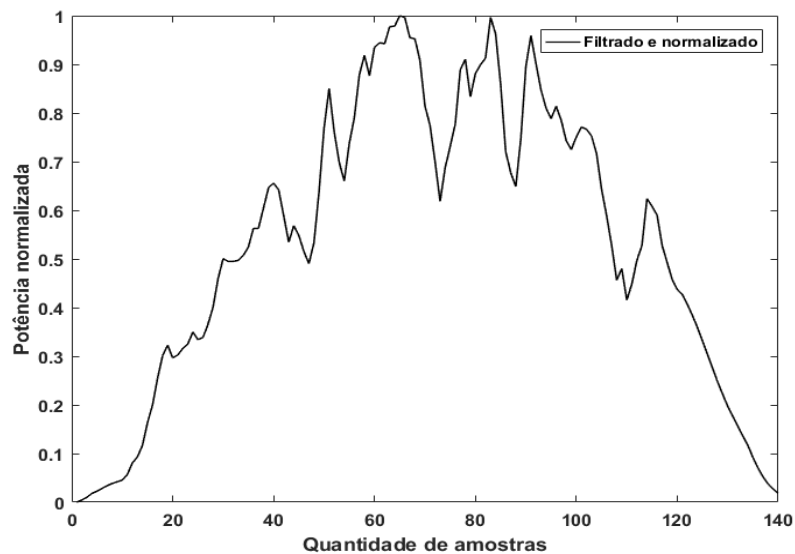
x_{max} e x_{min} são os valores máximo e mínimo do vetor a ser normalizado;

y é o valor normalizado de x ;

y_{max} e y_{min} são os valores máximo e mínimo do intervalo em que se deseja normalizar os elementos.

Para ilustrar o resultado obtido com a normalização e verificar a eficácia desse método, tem-se a Figura 13, onde os dados, de apenas um dia, foram normalizados para o intervalo de (0-1), e esse mesmo intervalo foi aplicado para todas as amostras utilizadas nesse trabalho.

Figura 13 – Normalização das amostras



Fonte: Autoria Própria.

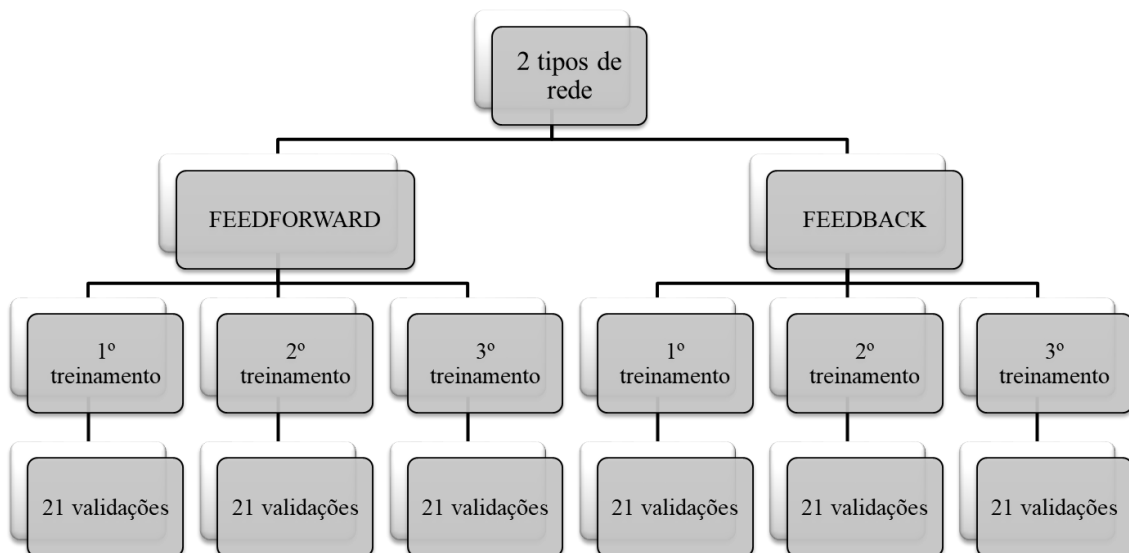
A efeito de comparação, os dados da Figura 13 são do mesmo dia do ilustrado na Figura 12, tendo a normalização como diferença, em que uma possui a potência no seu intervalo real (0-3000), já a outra possui a potência normalizada (0-1). No caso, essa técnica apenas determinou um intervalo em comum entre as variáveis, não invalidando os cálculos realizados com elas. Esse processo pode ser revertido ao final das implementações, também com o uso do comando *mapminmax*.

3.2.4 Implementação da RNA

A implementação da rede foi realizada utilizando o *software* Matlab[®], uma ferramenta computacional capaz de auxiliar na programação de diversos projetos em diferentes áreas de estudo. Será analisado, sobretudo, o desempenho das RNAs quando inseridas amostras em quaisquer intervalos, para isso, as implementações serão realizadas com intervalos em 5

minutos, 10 minutos e 1 hora, essa análise serve para verificar se a RNA apresenta um bom desempenho em prever a potência de saída de um SFCR com qualquer intervalo de amostra disponível. A partir disso, a pesquisa tem como proposta a implementação de 2 tipos de rede (*feedforward* e *feedback*), onde para cada uma serão realizados 3 treinamentos diferentes, com intervalos de 5 minutos, 10 minutos e 1 hora. Para cada um desses treinamentos serão implementadas 21 validações para amostras em diferentes períodos e intervalos distintos. Essas validações consistem em utilizar a rede treinada e inserir variáveis de entrada, que não foram utilizadas no treinamento, e verificar a capacidade da rede em gerar saídas coerentes. Em resumo, a Figura 14 mostra a divisão da implementação proposta na pesquisa, totalizando 6 treinamentos e 126 validações.

Figura 14 – Divisão da implementação proposta na pesquisa

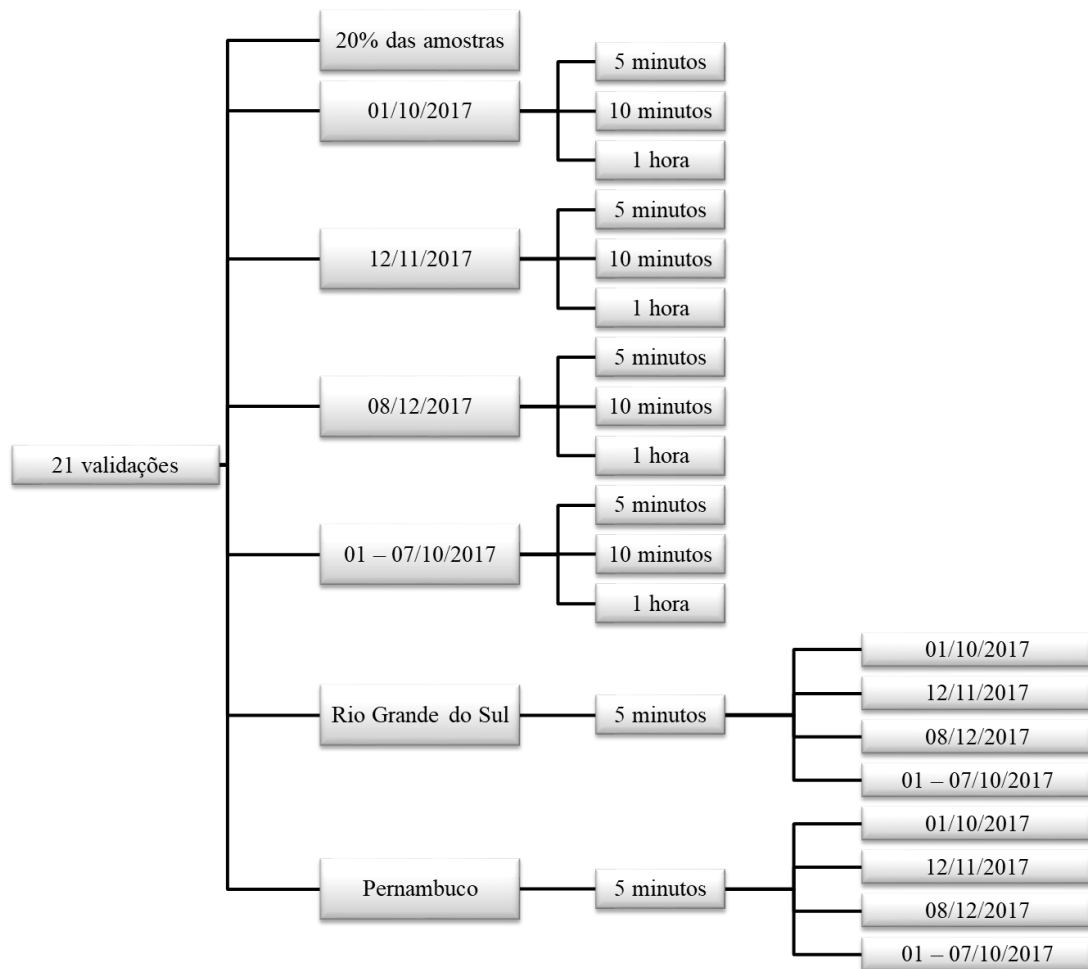


Fonte: Autoria Própria.

Cada um dos treinamentos será composto por 21 validações realizadas de acordo com a Figura 15, nela é possível observar o período e os intervalos das amostras que serão inseridas no processo de validação. Com exceção das validações para os estados do Rio Grande do Sul e Pernambuco, as demais serão realizadas em 3 intervalos distintos.

Vale destacar, que o processo da Figura 15 foi realizado para o 1º, 2º e 3º treinamento de cada tipo de rede. Desta forma, tem-se que, apesar de serem treinadas com um intervalo, as validações não serão feitas apenas com o intervalo de treinamento.

Figura 15 – Esquema das validações propostas na pesquisa




Fonte: Autoria Própria.

Como visto na Figura 14 utilizou-se uma rede *feedforward*, que não possui realimentação, e uma *feedback*, caracterizada por possuir realimentação da saída. O treinamento realizado no Matlab®, fez uso do comando NEWFF para criar a rede *feedforward* e para a rede *feedback* o comando inserido foi NARXNET, criando uma rede de séries temporais Auto-associativa Não Lineares com Entrada Externa (NARX).


Um exemplo do esquema básico dessas redes pode ser visto na Figura 16 e Figura 17, já com suas respectivas variáveis de entrada e saída que serão aplicadas nessa pesquisa. Essas redes foram selecionadas por possuir configurações de trabalho diferentes, o que pode fornecer resultados distintos e assim realizar comparações entre elas, determinando qual a rede melhor se adequa ao problema proposto.

Figura 16 – Esquema da rede sem realimentação (*feedforward*)



Fonte: Autoria Própria.

Figura 17 – Esquema da rede com realimentação (NARX)



Fonte: Autoria Própria.

Antes de iniciar o treinamento, a rede exige a configuração de alguns parâmetros importantes, tais como, arquitetura da rede, número de camadas, número de neurônios, algoritmo de treinamento, função de ativação, divisão das amostras (treinamento, validação e teste), tipo de divisão das amostras e número de atrasos para o caso da rede NARX. As configurações adotadas para cada uma das redes podem ser vistas na Tabela 2. Os pesos iniciais se deram de forma aleatória, gerados ao iniciar os treinamentos pelo próprio Matlab®.

Tabela 2 – Configuração das redes

Configuração da RNA		Tipo de rede	
		<i>Feedforward</i>	NARX
Número de variáveis de entrada		2	2
Número de variáveis de saída		1	1
Número de camadas ocultas		3	3
Número de neurônios nas camadas ocultas		(20,10,1)	(5,10,1)
Algoritmo de treinamento		trainlm	trainlm
Função de ativação		(tansig,logsig,purelin)	(tansig,tansig,purelin)
Divisão das amostras	Treinamento	70%	70%
	Validação	15%	15%
	Teste	15%	15%
Tipo de divisão das amostras		dividerand	divideblock
Número de atrasos		-	(2,2)

Fonte: Autoria Própria.

As configurações foram sendo adotadas pretendendo obter os melhores resultados de treinamentos, assim, após algumas mudanças desses parâmetros ao longo da implementação, os dados da Tabela 2 apresentaram o melhor desempenho para o problema proposto. A configuração do número de atrasos indica um atraso igual a 2 nas amostras das entradas e na saída da RNA. Todos os parâmetros foram configurados em linhas de comando do Matlab®.

A partir dessas configurações é possível iniciar os treinamentos da RNA, e a Tabela 3 mostra a divisão dos treinamentos por tipo de rede, que foram realizados na pesquisa, bem como, informações relevantes que ajudam a esclarecer a forma como esses treinamentos foram elaborados e implementados.

Tabela 3 – Informações dos treinamentos da RNA

	Treinamentos	Período das amostras ²		Intervalo das amostras	Total de amostras	Quantidade de validações
<i>Feedforward</i>	1° - Caso A	Limpo*	01/10/2017	5min	24068	21
	2° - Caso B		-	10min	12041	21
	3° - Caso C		31/03/2018	1hora	2036	21
<i>Feedback</i>	1° - Caso D	Limpo*	01/10/2017	5min	24068	21
	2° - Caso E		-	10min	12041	21
	3° - Caso F		31/03/2018	1hora	2036	21

Fonte: Autoria Própria. *Período em que foram realizadas as manutenções semanais no SFV.

²Período das amostras utilizadas no treinamento, com exceção dos dias 01/10/2017, 12/11/2017, 08/12/2017 e para a semana de 01/10/2017 a 07/10/2017 que foram selecionados para realizar as validações, e desta forma, foram excluídos do conjunto de amostras de treinamento.

Dentre as informações contidas na Tabela 3, pode-se destacar a divisão dos treinamentos da RNA, sendo propostos um total de 6 treinamentos, divididos igualmente entre os tipos de rede, onde para a *feedforward* tem-se 3 treinamentos denominados de Caso A, B e C em que cada um deles foram implementados com intervalos das amostras em 5 minutos, 10 minutos e 1 hora, respectivamente. Para a rede NARX os 3 treinamentos foram denominados de Caso D, E e F, também com intervalos das amostras em 5 minutos, 10 minutos e 1 hora, respectivamente. Contudo, vale ressaltar que os treinamentos da rede NARX em destaque na Tabela 3 não foram abordados na pesquisa, pois não apresentaram resultados satisfatórios que contribuíssem para o objetivo do trabalho.

Nela destaca-se ainda o total de amostras utilizadas para cada variável de entrada e saída inseridas nos treinamentos, que é determinante para a convergência dos mesmos. Outro item abordado na Tabela 3 são a quantidade de validações propostas, em que, para cada treinamento realizou-se 21 validações, correspondendo a 63 para cada uma das redes, resultando em um total de 126 validações na pesquisa, mais detalhes a respeito dessas validações serão abordados nas seções 3.2.4.1 e 3.2.4.2.

Após configurar a rede e treiná-la, pôde-se iniciar as validações, que servem para testar o desempenho da generalização da rede, inserindo novos dados e comparando com os resultados reais, podendo também prever as potências em outras regiões, desde que se tenha amostras suficientes para realizar essa validação, sendo essa a proposta desse estudo.

Dentre as validações realizadas, a primeira de cada treinamento utilizou 20% das amostras de treinamento, tanto para a rede *feedforward*, como para a rede NARX. Com isso, os treinamentos foram realizados com o restante das amostras, ou seja, com os 80% do conjunto de dados, e isso foi repetido para os demais casos propostos nessa pesquisa.

Vale destacar que para a primeira validação realizada com a rede NARX, a mesma foi feita em *openloop* (malha aberta), na qual exige que sejam inseridas também variáveis de saída ao comando de validação, não cumprindo o esperado, que seria retornar as previsões apenas com a inserção das variáveis de entrada. Desta forma, para esse caso, inseriu-se também os dados de saídas equivalentes ao período das variáveis de entrada na rede, a fim de analisar os resultados que seriam obtidos e comparar com os demais. No entanto, as demais validações da rede NARX fez uso do comando *closeloop* (malha fechada), onde o mesmo, exige apenas a inserção das variáveis de entrada para fornecer resultados.

As amostras utilizadas para realizar as validações foram selecionadas de acordo com alguns critérios, onde para as validações utilizando 20% das amostras de treinamento (equivalente aos 36 primeiros dias dos seis meses de amostras utilizadas nos treinamentos), o critério foi

analisar os resultados da rede NARX para a validação em *openloo*, e o restante das amostras (80%) foram utilizadas para realizar os treinamentos da RNA. No período limpo, as amostras foram escolhidas com base na maior geração de potência do SFV, sendo selecionados três dias e uma semana que apresentaram a maior média de potência gerada pelo sistema fotovoltaico entre os meses de outubro e dezembro. Já os estados de Pernambuco e Rio Grande do Sul foram selecionados de acordo com suas condições climáticas características. Na Tabela 4 são mostrados alguns critérios citados e informações a respeito dessas amostras que contribuíram para as validações.

Tabela 4 – Critérios para a seleção das amostras para validações

Período das amostras		Geração média de potência (W)	Intervalo das amostras	Total de amostras
-	20% das amostra do treinamento (36 dias)	-	5min/10min/1hora	4814/2408/408
Limpo	01/10/2017	1668	5min/10min/1hora	140/70/12
	12/11/2017	1448	5min/10min/1hora	143/71/12
	08/12/2017	1344	5min/10min/1hora	145/72/12
	01/10/2017 - 07/10/2017	1491	5min/10min/1hora	979/489/84
RS	01/10/2017	-	5min	130
	12/11/2017	-		154
	08/12/2017	-		120
	01/10/2017 - 07/10/2017	-		929
PE	01/10/2017	-	5min	135
	12/11/2017	-		139
	08/12/2017	-		117
	01/10/2017 - 07/10/2017	-		926

Fonte: Autoria Própria.

Outro item observado na Tabela 4 são as amostras divididas em três intervalos, em 5 minutos, pois espera-se que com um menor intervalo seja obtido uma melhor generalização da RNA e conseqüentemente uma melhor previsão. Utilizou também o intervalo de 10 minutos, visando reduzir ainda mais os ruídos, e o intervalo de 1 hora, visto que a maioria dos dados meteorológicos encontrados para outras regiões eram com esse intervalo, no entanto, nota-se que para esse intervalo existe uma redução significativa na quantidade de amostras, o que pode dificultar a generalização da RNA.

Desta forma, conforme abordado no item 3.2.1, para validar os resultados e prever a potência gerada pelo SFV em outras regiões, utilizou-se amostras com intervalos de 5 minutos,

buscando evitar possíveis falhas na generalização da rede neural, e obter uma melhor aproximação dos valores reais com os previstos, tendo em vista que uma maior quantidade amostras pode favorecer a implementação da RNA. A Tabela 4 mostra ainda, a quantidade de amostras que cada intervalo detém, sendo possível, a partir dessas informações, analisar o desempenho da rede em prever resultados mesmo com variações na quantidade das amostras.


Nas subseções 3.2.4.1 e 3.2.4.2 serão descritas a forma como cada rede foi validada, detalhando as particularidades que cada uma possui.

3.2.4.1 Validações com a rede *feedforward* (sem realimentação)

Para realizar as validações desse tipo de rede utilizou-se o comando *sim* do Matlab®. Todas as validações foram realizadas com esse comando, mudando apenas as variáveis de entrada, para que fosse retornado o valor previsto e equivalente às entradas inseridas. Genericamente o comando para validação $y = \text{sim}(\text{net}, x, xi, ai)$, requer para retornar previsões (y), a rede treinada (net), variáveis de entrada (x), condições iniciais de atraso de entrada (xi) e as condições de atraso da camada inicial (ai), no entanto os argumentos xi e ai são opcionais, sendo obrigatórios somente para redes com atrasos na entrada ou atrasos de camada, como é o caso da rede NARX.

Conforme as configurações da Tabela 2 o diagrama gráfico para o tipo de rede neural *feedforward* é ilustrado na Figura 18.

Figura 18 – Diagrama gráfico da rede neural NEWFF



Fonte: Autoria Própria.

As diversas validações aplicadas nessa pesquisa, para esse tipo de rede, podem ser vistas na Tabela 5, onde realizou-se seis conjuntos de validações ao total. A primeira (Val) foi realizada utilizando como variáveis de entrada 20% dos dados de treinamento, e o intervalo dessas amostras foram determinados de acordo com os intervalos dos treinamentos propostos. Da segunda à quinta (Val 1, Val 2, Val 3 e Val 4), elas são compostas por três subitens referentes às variações de intervalos das amostras, onde para cada período selecionado realizou-se

validações com intervalos de 5 minutos, 10 minutos e 1 hora. Do mesmo modo, para a última validação (Val 9), foi implementada uma sequência de oito validações para os estados selecionados, sendo 4 validações (9.1, 9.2, 9.3 e 9.4) para o Rio Grande do Sul e 4 validações (9.5, 9.6, 9.7 e 9.8) para Pernambuco, todas as validações referentes aos estados foram realizadas em intervalos de 5 minutos.

Tabela 5 – Resumo das validações com a rede neural *feedforward*

Validações		Período	Intervalo das amostras	Validações		Período	Intervalo das amostras	
Val	-	20% das amostras	De acordo com o do treinamento	Val 4	4.1	01/10/2017 - 07/10/2017	5 min	
					4.2		10 min	
					4.3		1 hora	
Val 1	1.1	01/10/2017	5 min	Val 9	9.1	RS	01/10/2017	5 min
	1.2		10 min		9.2	RS	12/11/2017	
	1.3		1 hora		9.3	RS	08/12/2017	
Val 2	2.1	12/11/2017	5 min		9.4	RS	01/10/2017 - 07/10/2017	
	2.2		10 min		9.5	PE	01/10/2017	
	2.3		1 hora		9.6	PE	12/11/2017	
Val 3	3.1	08/12/2017	5 min		9.7	PE	08/12/2017	
	3.2		10 min		9.8	PE	01/10/2017 - 07/10/2017	
	3.3		1 hora					

Fonte: Autoria Própria.

Esse conjunto de validações, mostrado na Tabela 5, foi realizado para os três treinamentos (Caso A, B e C) propostos da rede *feedforward*, com o intuito de avaliar seu desempenho, quando treinada com dados de diferentes intervalos de amostras.


3.2.4.2 Validações com a rede NARX (com realimentação)

A rede NARX é criada e treinada em malha aberta, sendo validada apenas uma vez nessa configuração, com os 20% das amostras de treinamento, para verificar o comportamento da RNA quando no processo de validação é exigido a inserção, também, da variável de saída. Entretanto, para as demais validações realizadas, usa-se o comando *closeloop*, essa ferramenta é utilizada nas linhas de comando do próprio Matlab®, para converter a malha aberta da rede em uma malha fechada, fazendo com que as saídas geradas realimentem a própria rede, dispensando assim a necessidade de inserir variáveis de saída no processo de validação.

A partir da utilização do comando *closeloop*, a rede treinada em malha aberta (*net*), transforma-se em uma rede de malha fechada (*netc*), e posteriormente aplica-se o comando para validação $yc = netc(x, xi, ai)$, onde *netc* é a rede em malha fechada já treinada, *x* são as variáveis de entrada, *xi* são as condições iniciais de atraso de entrada, *ai* as condições de atraso da camada inicial e *yc* são os valores previstos em malha fechada.

Exemplo do diagrama gráfico da rede NARX pode ser visto na Figura 19, para o processo em malha fechada.

Figura 19 – Diagrama gráfico da rede neural NARX em malha fechada



Fonte: Autoria Própria.

Esse processo de fechamento da malha foi repetido em todas as validações, ou seja, cada conjunto de amostras dos períodos propostos utilizados como variáveis de entrada na rede NARX, recebeu comandos de malha fechada e de validações, individualmente.

As validações efetuadas com a rede neural NARX, foram as mesmas aplicadas para a rede neural *feedforward*, reforçando ainda mais a proposta de análises de comparações dos resultados entre as redes, ainda assim, a título de informação e organização, tem-se a Tabela 6 que mostra a forma como foram divididas as validações para o tipo de rede neural NARX. Essas validações foram repetidas para cada treinamento proposto da rede NARX, sendo possível avaliar o desempenho da rede com as mesmas validações, variando apenas os intervalos das amostras de treinamento da rede neural.

De maneira análoga ao que foi citado nas validações da rede *feedforward*, para a rede NARX foram realizadas 21 validações ao total, para cada treinamento. Conforme apresentado na Tabela 6, a primeira validação (Val) foi realizada com 20% das amostras de treinamento, o intervalo dessas amostras será determinado de acordo com o treinamento em questão, e os 80% restantes das amostras serão utilizados para treinar a RNA.

Os conjuntos de validações, Val 1, Val 2, Val 3 e Val 4, foram realizados em períodos distintos, e cada conjunto possui 3 subitens referentes aos intervalos das amostras (5 minutos,

10 minutos e 1 hora) submetidas na validação. A Tabela 6 mostra ainda, o conjunto de validações Val 9, que compreende às validações utilizadas para prever a potência gerada nos estados do RS e PE. Esse conjunto de validações é formado por 8 subitens referentes aos períodos selecionados para realizar tais previsões, em que 4 dessas validações foram para o RS (9.1, 9.2, 9.3, 9.4) e 4 para PE (9.5, 9.6, 9.7, 9.8), sendo todas elas realizadas com amostras em intervalos de 5 minutos.

Tabela 6 – Resumo das validações com a rede neural NARX

Validações		Período	Intervalo das amostras	Validações		Período	Intervalo das amostras	
Val	-	20% das amostras	De acordo com o treinamento	Val 4	4.1	01/10/2017 - 07/10/2017	5 min	
					4.2		10 min	
					4.3		1 hora	
Val 1	1.1	01/10/2017	5 min	Val 9	9.1	RS	01/10/2017	5 min
	1.2		10 min		9.2	RS	12/11/2017	5 min
	1.3		1 hora		9.3	RS	08/12/2017	5 min
Val 2	2.1	12/11/2017	5 min		9.4	RS	01/10/2017 - 07/10/2017	5 min
	2.2		10 min		9.5	PE	01/10/2017	5 min
	2.3		1 hora		9.6	PE	12/11/2017	5 min
Val 3	3.1	08/12/2017	5 min		9.7	PE	08/12/2017	5 min
	3.2		10 min		9.8	PE	01/10/2017 - 07/10/2017	5 min
	3.3		1 hora					

Fonte: Autoria Própria.

Os resultados referentes às validações destacadas na Tabela 6, não serão apresentados no Capítulo 4, visto que os resultados obtidos com essas validações não se mostraram favoráveis para o objetivo principal dessa pesquisa, em prever a potência de saída de um SFCR utilizando RNA, de forma que a RNA seja capaz de realizar essa previsão ao inserir amostras em quaisquer intervalos disponíveis.

3.2.5 Métodos para análise do desempenho das previsões com RNA

Haja vista a numerosa quantidade de validações que foram propostas, se faz necessário aplicar métodos que demonstre o desempenho das mesmas, que além de realizar comparações entre o real e o previsto, possa também averiguar essas comparações por meio de métodos confiáveis, desta forma foram aplicados cálculos de erros que realizam esse tipo de análise e análises por meio do método de regressão.

As equações abordadas mostram os erros utilizados para analisar o desempenho da RNA, os mesmos serão abordados com mais detalhes nessa subseção. Esses erros foram calculados no Matlab®, e alguns já possuem equações prontas.

- **Erro Absoluto**

É a diferença entre o valor real e o previsto.

$$E_{Absoluto} = x_{Real} - x_{Previsto} \quad (4)$$

- **Erro médio (ME)**

Trata-se do somatório da diferença entre o valor real e o previsto dividido pelo número de elementos. O resultado pode variar de infinito negativo a infinito positivo, o melhor resultado que pode ser obtido é o zero, sendo considerada uma previsão, no entanto pode atingir esse valor mesmo para uma previsão ruim, caso existam erros compensatórios. Possui a mesma unidade das variáveis calculadas (GUARNIERI, 2006).

$$ME = \frac{\sum_{t=1}^n E_{Absoluto}}{n} \quad (5)$$

- **Erro Absoluto Médio (MAE)**

É o somatório da diferença, em módulo, entre o valor real e o previsto dividido pelo número de elementos. Os resultados obtidos são sempre positivos, variando de 0 a infinito, e possui a mesma unidade das variáveis calculadas.

$$MAE = \frac{\sum_{t=1}^n |E_{Absoluto}|}{n} \quad (6)$$

- **Erro Quadrático Médio (MSE)**

O erro quadrático médio é a média dos quadrados dos erros absoluto, ele é muito usado na estatística, uma de suas desvantagens está no fato de que a unidade do resultado obtido é a unidade original elevada ao quadrado, dificultando a interpretação imediata dos dados. Sua interpretação pode ser analisada de acordo com o erro absoluto, uma vez que, eles são diretamente proporcionais, ou seja, quanto maiores forem os erros, maior será o MSE, e se os erros forem pequenos, ele também será pequeno.

$$MSE = \frac{\sum_{t=1}^n (E_{Absoluto})^2}{n} \quad (7)$$

- **Raiz do Erro Médio Quadrático (RMSE)**

A vantagem da RMSE é que ela fornece resultados nas mesmas unidades que a série temporal estimada. Pode gerar valores elevados devido o quadrado existente na equação, que proporciona erros maiores, ajudando na comparação do método.


$$RMSE = \sqrt{\frac{\sum_{t=1}^n (E_{Absoluto})^2}{n}} \quad (8)$$

As análises percentuais dos dados na pesquisa serão realizadas com base no cálculo das frações percentuais dos erros ME e RMSE, conforme calcula Guarnieri (2006), onde ME% e RMSE% representam as razões entre os valores de erro e a média dos valores previstos, multiplicadas por 100. Segundo Guarnieri (2006), essas medidas de erro são comumente expressas como frações percentuais em relação à média das previsões, isto é, como erros relativos.

- **Regressão linear**

Esse método estatístico mostra a relação entre os valores reais e os valores previstos pela rede. Para se obter um ajuste perfeito, os dados devem coincidir com a linha de 45 graus apresentada no diagrama de regressão (*vide* Figura 20), desta forma onde as saídas de rede são iguais para os alvos (MATLAB, 2019b).

Figura 20 – Diagrama de Regressão linear



Fonte: Matlab, 2019c.

O valor obtido com a regressão no Matlab[®] é o coeficiente de correlação, que varia de -1 a 1, onde o valor 1 indica uma previsão perfeita. De acordo com Guarnieri (2006), por ser independente da escala e por não levar em conta o viés da previsão, é possível encontrar uma correlação elevada para uma previsão com erros grandes (viés), esse coeficiente possui unidade adimensional.

Para interpretar os resultados de regressão, deve-se analisar o conjunto de resultados obtidos, tanto da dispersão dos dados, como do coeficiente, pois concluir resultados analisando apenas uma delas pode gerar conclusões equivocadas.

Com o uso da RNA espera-se generalizar os resultados, de forma que ao inserir variáveis de entrada de outras regiões a rede continue gerando saídas coerentes com o esperado, e desta forma garantir a previsão da potência gerada pelo SFCR em diferentes localidades. Essa é uma das principais características da RNA, com isso, será possível verificar sua eficiência para esse tipo de aplicação, através dos métodos de análises descritos.

No capítulo 4 serão abordados os resultados obtidos a partir dos treinamentos e das validações que foram propostas, aplicando diferentes análises de desempenho para verificar a performance da RNA.

4 RESULTADOS E DISCUSSÕES

Nesse capítulo serão abordados os resultados obtidos para cada um dos treinamentos e das validações propostas. Com o intuito de facilitar a interpretação do estudo, utilizou-se a nomenclatura com as letras A, B e C para identificar os treinamentos e validações da rede *feedforward* e a nomenclatura com as letras D, E e F para identificar os treinamentos e validações da rede NARX. Para esclarecer as nomenclaturas utilizadas na pesquisa, tem-se o ANEXO A, com legendas que abordam os significados dessas siglas.

O período das amostras coletadas para os treinamentos foram de 6 meses (01/10/2017 - 31/03/2018) e engloba também o período das amostras utilizadas para as validações (01/10/2017, 12/11/2017, 08/12/2017 e a semana de 01/10/2017 a 07/10/2017), no entanto, todas as amostras dos períodos utilizados para as validações foram excluídas do conjunto de treinamento, ou seja, nenhum dos dados utilizados para as validações, foram repetidos no conjunto de dados dos treinamentos, desta forma, os treinamentos tornam-se totalmente imparciais.

A avaliação do desempenho das validações será com base em métodos como, regressão, e os erros, ME, MAE, MSE, RMSE, EM% e RMSE%, que foram descritos no Capítulo 3. Os resultados dos erros ME, MAE, MSE, RMSE são comumente encontrados na literatura na forma normalizada, no entanto, para essa pesquisa se fez necessário desnormalizar os erros EM% e RMSE% para coincidir com os dados previstos nas unidades reais.

4.1 Implementação com a rede *feedforward* (Sem realimentação)

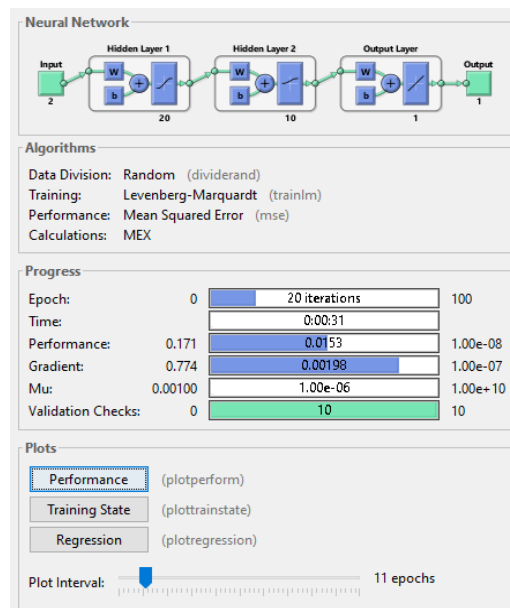
Nessa seção serão abordados os três treinamentos realizados com a rede *feedforward* e suas análises de desempenho, bem como as validações que foram realizadas a partir desses treinamentos, nos quais cada um possui 21 validações ao total. Esses testes serão mostrados nas subseções a seguir, e seus resultados serão abordados detalhadamente.

As seções 4.1.1, 4.1.2 e 4.1.3 apresentam os três treinamentos realizados com a rede *feedforward* para intervalos de 5 minutos (Caso A), 10 minutos (Caso B) e 1 hora (Caso C). Após os treinamentos, cada rede já treinada foi validada em diferentes períodos e intervalos, que serão apresentados nas seções 4.1.4.1, 4.1.4.2, 4.1.4.3, 4.1.4.4, 4.1.4.5 e 4.1.4.6.

4.1.1 Caso A: Treinamento com dados no período limpo em intervalos de 5 minutos.

Foi denominado de Caso A, o treinamento realizado com os dados no período, entre outubro de 2017 e março de 2018, em intervalos de 5 minutos, sendo um total de 24068 amostras. Na Figura 21 tem-se a janela de treinamento, onde mostra as configurações da rede após o treino, visto que, as configurações determinadas inicialmente na RNA, dificilmente serão todas alcançadas ao final do treinamento, pois vai depender muito da convergência da rede. Ela mostra ainda, a quantidade épocas que foram necessárias (20 iterações) para a convergência da rede, bem como, o tempo de duração desse treinamento, que foi de 31 segundos. A partir dessa janela obtém-se também o gráfico de regressão e performance, mostrados na Figura 22 e Figura 23, respectivamente.

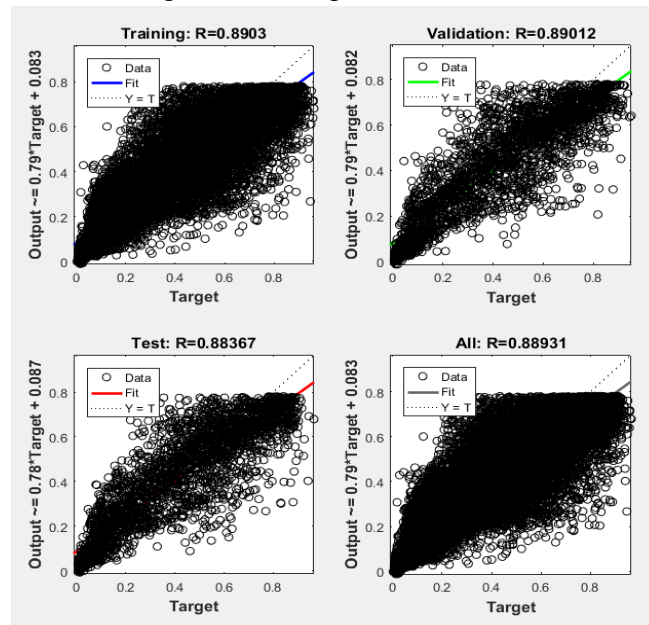
Figura 21 – Janela de treinamento do Caso A



Fonte: Autoria Própria.

As regressões apresentadas na Figura 22 são de treinamento, validação, teste e uma regressão mostrando o desempenho geral da rede.

Figura 22 – Regressões do Caso A




Fonte: Autoria Própria.

Essas regressões mostram a relação entre as saídas da RNA e o alvo, para que o treinamento fosse perfeito as saídas da RNA e o alvos teriam que ser exatamente iguais e o valor obtido na regressão seria igual a 1, no entanto, na prática isso raramente acontece. Diante disso, percebe-se que todas as regressões apontam um bom desempenho para a implementação da rede *feedforward*, na faixa de 0,88 a 0,89. No entanto, nota-se uma grande dispersão dos dados, visto que, as variáveis de entrada inseridas possuem uma grande quantidade de amostras, gerando muitos valores de saída.

Nessa configuração, o treinamento termina após o erro não obter um aumento por dez iterações consecutivas e o melhor desempenho é obtido na época 10 com o menor erro de validação alcançado, como pode ser visto na Figura 23, em que as curvas de treinamento, validação e teste estão sobrepostas.

Figura 23 – Diagrama de Performance do Caso A



Fonte: Autoria Própria.

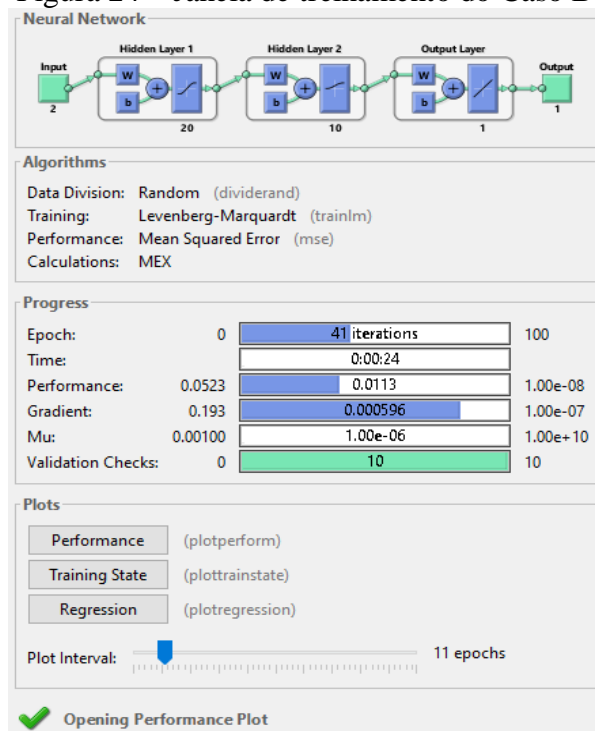
O MSE é utilizado para mostrar a performance da rede, e para essa implementação o MSE obtido foi 0,015002, quanto menor esse valor, melhor será o treinamento. Esse valor será comparado e discutido com os valores de MSE calculados nos demais treinamentos, para se ter uma melhor avaliação do desempenho de cada tipo de rede, através desse critério de desempenho, e verificar qual delas melhor se adaptou à proposta da pesquisa.

4.1.2 Caso B: Treinamento com dados no período limpo em intervalos de 10 minutos.

O treinamento da rede *feedforward* denominado de Caso B, foi realizado utilizando amostras no período compreendido entre os dias 01 de outubro de 2017 a 31 de março de 2018, em intervalos de 10 minutos, totalizando 12041 amostras para o treinamento.

A janela de treinamento da rede na Figura 24 mostra a configuração da rede utilizada, assim como as configurações que foram alcançadas até atingir o critério de parada, dentre elas, o número de épocas, que foram atribuídas 100. No entanto, a rede convergiu e parou o treinamento com 41 iterações, após atingir 10 checagens de validação. Essa checagem de validação indica que, para o caso de não existir um aumento na taxa de erro até um número pré-estabelecido de iterações consecutivas, o treinamento será interrompido, para este treinamento, foi atribuído o número de 10 iterações consecutivas, após atingir esse valor, o treinamento estará terminado.

Figura 24 – Janela de treinamento do Caso B

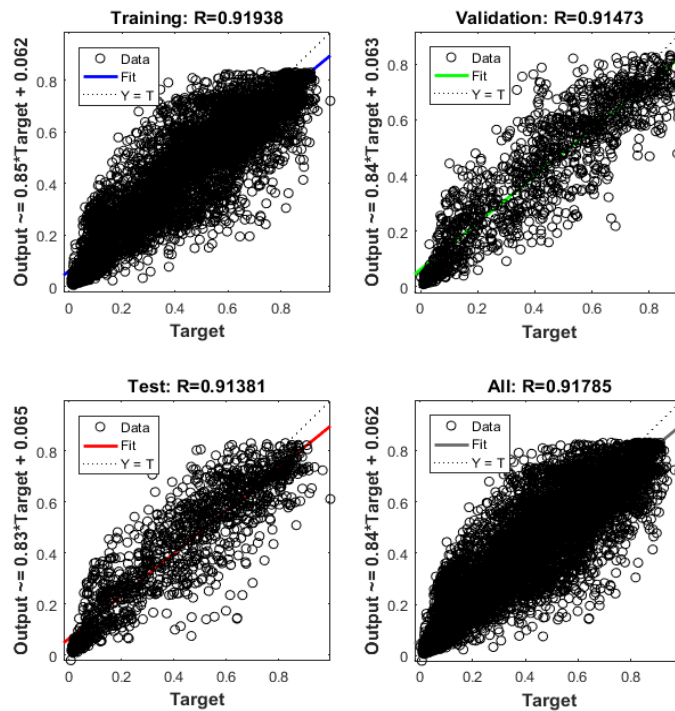


Fonte: Autoria Própria.

Ao atingir o critério de parada, é possível obter alguns diagramas para interpretar o desempenho do treinamento da rede, como o gráfico de performance e a regressão, abordados na Figura 25 e Figura 26, respectivamente.

Além de apresentar um coeficiente de correlação próximo a 1 em todas as situações, nota-se que grande parte das amostras tendem a se aproximar da reta alvo, com base nessas informações, pode-se afirmar que a rede desempenhou um bom treinamento, com dados previstos que se aproximam muito bem do real.


Figura 25 – Regressões do Caso B



Fonte: Autoria Própria.

A Figura 26 mostra a evolução do erro na etapa de validação, em que o melhor erro de validação obtido foi de 0,011698 na época 31. Observa-se que esse erro se mostra levemente menor do que o erro de validação obtido para o Caso A, que foi de 0,015002, no entanto o número de época do Caso B foi superior, possuindo uma convergência mais demorada, em comparação com o Caso B.

Figura 26 – Diagrama de Performance do Caso B



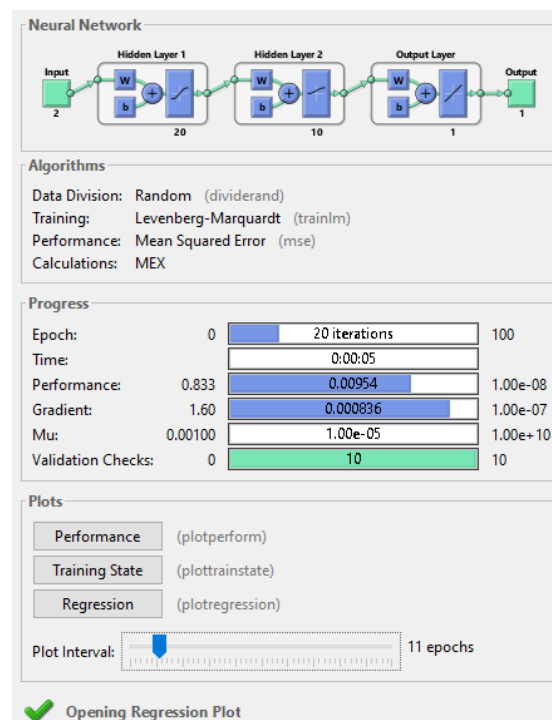
Fonte: Autoria Própria.

4.1.3 Caso C: Treinamento com dados no período limpo em intervalos de 1 hora.

O treinamento denominado de Caso C, se deu a partir da utilização de 6 meses de amostras no período de outubro de 2017 a março de 2018, com intervalos de 1 hora, totalizando 2036 dados utilizados no treinamento da rede neural.

Os resultados iniciais obtidos com esse treinamento podem ser observados na Figura 27, com a janela de treinamento, nela contém informações a respeito das configurações que foram inseridas inicialmente e as que foram atingidas após o treinamento. Nota-se que mesmo inserindo um total de 100 interações como critério de parada, a rede convergiu em apenas 20 épocas, após atingir outro critério de parada, referente ao aumento da taxa de erro. Como não houve aumento dessa taxa por 10 iterações consecutivas, o treinamento foi terminado.

Figura 27 – Janela de treinamento do Caso C

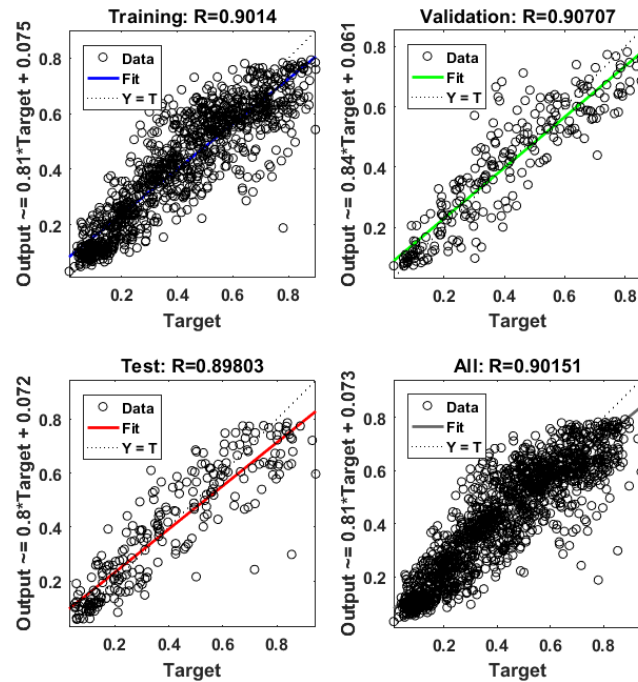


Fonte: Autoria Própria.

Ao analisar as regressões plotadas na Figura 28, nota-se que os dados acompanharam a reta alvo de forma expressiva, mesmo com menos amostras do que os casos anteriores, essa regressão enfatiza o bom desempenho do treinamento, em que todas as etapas possuem coeficiente de correlação considerados bons, próximos ao valor 1, com uma pequena baixa para

a regressão da etapa de teste. No entanto, na regressão com todos os dados, seu coeficiente continua na faixa desejada com $R=0,90151$ e uma distribuição de dados com menos dispersões do que os encontrados nos casos anteriores, por possuir menos amostras.


Figura 28 – Regressões do Caso C



Fonte: Autoria Própria.

Na Figura 29 mostra que as curvas de treinamento, validação e teste apresentam grande semelhança, estando sobrepostas em algumas situações. Nela observa-se também, que a melhor performance obtida na etapa de validação foi de 0,008472, alcançada na época 10. Esse foi o menor erro obtido entre os 3 casos implementados, sendo também a rede que convergiu mais rapidamente, com 10 épocas, esse baixo número de épocas pode ser justificado pelo número reduzido de amostras que foram utilizadas para realizar o treinamento.

Figura 29 – Diagrama de Performance do Caso C



Fonte: Autoria Própria.

A Tabela 7 mostra um resumo dos treinamentos para os três casos (Caso A, B e C) abordados. A partir dela é possível realizar uma comparação entre os resultados e analisar qual obteve o melhor desempenho. Ao analisar o desempenho pelo erro de validação, o Caso C obteve o menor erro, indicando uma melhor performance desse treinamento em relação aos demais, sendo obtido na época 10 e demandando assim um menor esforço computacional

Tabela 7 – Resumos dos resultados dos treinamentos

Caso	Número de épocas	Erro de validação	Melhor época	Tempo de treinamento (s)	Regressão R			
					Treinamento	Validação	Teste	Todos os dados
A	20	0,015002	10	31	0.8903	0,89012	0,88367	0,88931
B	41	0,011698	31	24	0,91938	0,91473	0,91381	0,91785
C	20	0,008472	10	5	0,9014	0,90707	0,89803	0,90151

Fonte: Autoria Própria.

De acordo com os resultados da regressão, o treinamento que melhor se destacou foi o do Caso B, com o maior coeficiente de correlação encontrado em todas as etapas, além disso, a distribuição de dados não possui dispersões expressivas. Com isso, pode-se afirmar que o Caso B obteve os resultados mais satisfatórios, com um erro de validação que não possui discrepância significativa em relação ao do Caso C. No entanto, mesmo apresentando um maior número de épocas, se comparado aos demais treinamentos, essa diferença não se mostra significativa, logo, em nenhum dos casos o esforço computacional foi um fator preocupante. Além disso, vale

destacar que o Caso B possui uma quantidade mediana de amostras, em comparação com os demais, e isso pode ser o motivo pelo qual ele apresentou uma melhor distribuição dos dados com a regressão.

Apesar do Caso B se destacar entre os demais casos, ainda foram realizadas validações com essas redes para se ter uma melhor análise do seu desempenho quanto a generalização dos dados e a capacidade em prever saídas coerentes com a desejada.

4.1.4 Validações realizadas para os três casos propostos com a rede *feedforward*

Nessa subseção serão detalhadas as validações propostas para todos os treinamentos, onde para cada um deles foram realizadas 21 validações divididas em períodos específicos, abordadas nos subitens 4.1.4.1 (Validação ABC), 4.1.4.2 (Validação ABC1), 4.1.4.3 (Validação ABC2), 4.1.4.4 (Validação ABC3), 4.1.4.5 (Validação ABC4) e 4.1.4.6 (Validação ABC9).

Cada subitem abordará a validação para um determinado período, e o mesmo será validado para três intervalos diferentes de amostras, isso foi repetido para os três casos de treinamentos realizados, e ao final foram analisadas e comparadas para se determinar qual treinamento teve um melhor desempenho para essa aplicação.

Vale destacar que entre as 21 validações propostas, 8 serão para a previsão da capacidade de geração de potência do sistema fotovoltaico de 3kWp nos estados do Rio Grande do Sul e Pernambuco, com a inserção de diferentes intervalos de amostras, e as demais validações serão realizadas a fim de testar o desempenho dos treinamentos.

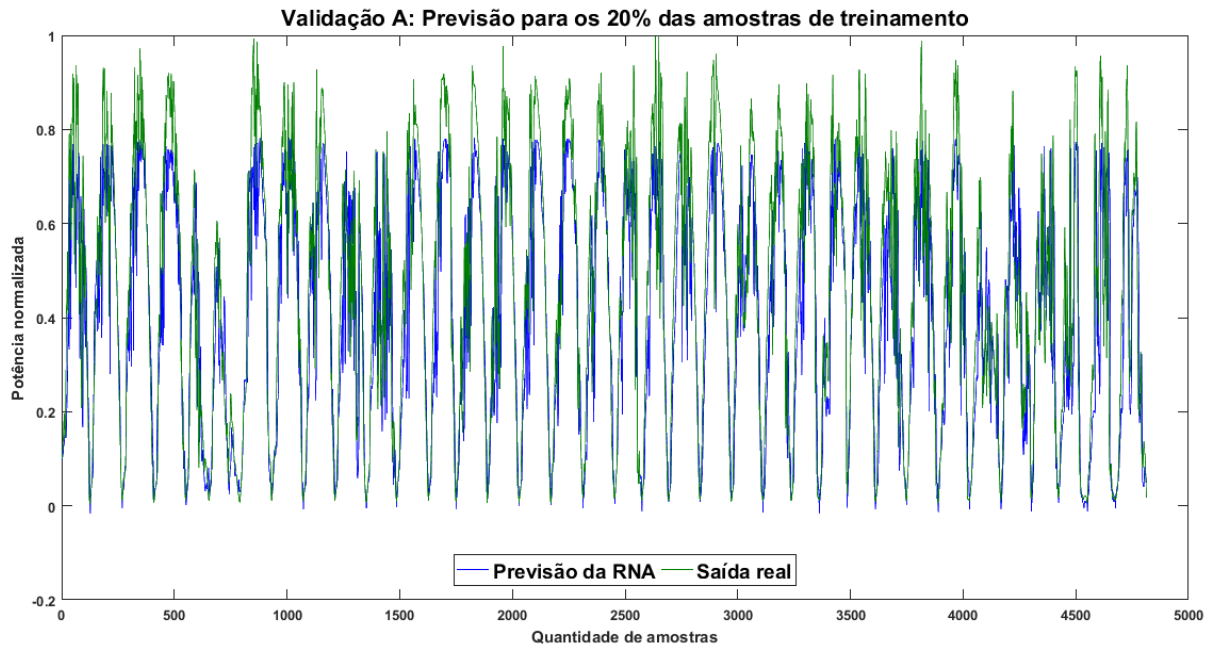
4.1.4.1 Validação ABC - 20% das amostras de treinamento

Conforme já mencionado, a primeira validação de cada caso proposto foi realizada utilizando 20% dos dados de treinamento, ou seja, utilizou uma quantidade de amostras de 4814, 2408 e 408 para os Casos A, B e C, respectivamente. Esse período utilizado para as validações equivale aos primeiros 36 dias dos seis meses de amostras que foram selecionados para realizar os treinamentos. A partir disso, nota-se na Figura 30, Figura 31 e Figura 32, as comparações dos resultados obtidos nas validações A, B e C entre a previsão da RNA e a saída real de cada um deles.

As curvas apresentadas é resultado de treinamentos e validações que variam de acordo com os intervalos das amostras. Na Figura 30 tem-se o resultado de uma RNA treinada e validada (Validação A) com intervalos de 5 minutos, a Figura 31 apresenta resultados de

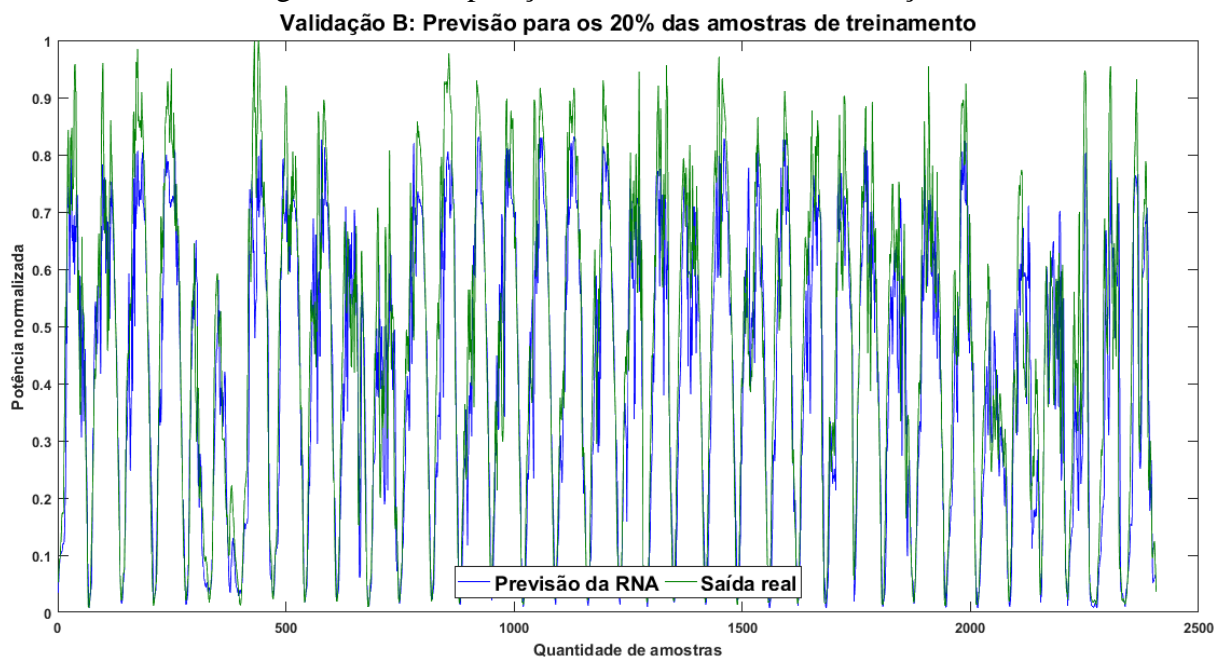
treinamento e validação (Validação B) ambos com intervalos de 10 minutos, já a Figura 32 mostra os resultados referentes ao treinamento e validação (Validação C) realizados com amostras em intervalos de 1 hora.

Figura 30 – Comparação Real x Previsto da Validação A




Fonte: Autoria Própria.

Figura 31 – Comparação Real x Previsto da Validação B



Fonte: Autoria Própria.

Figura 32 – Comparação Real x Previsto da Validação C

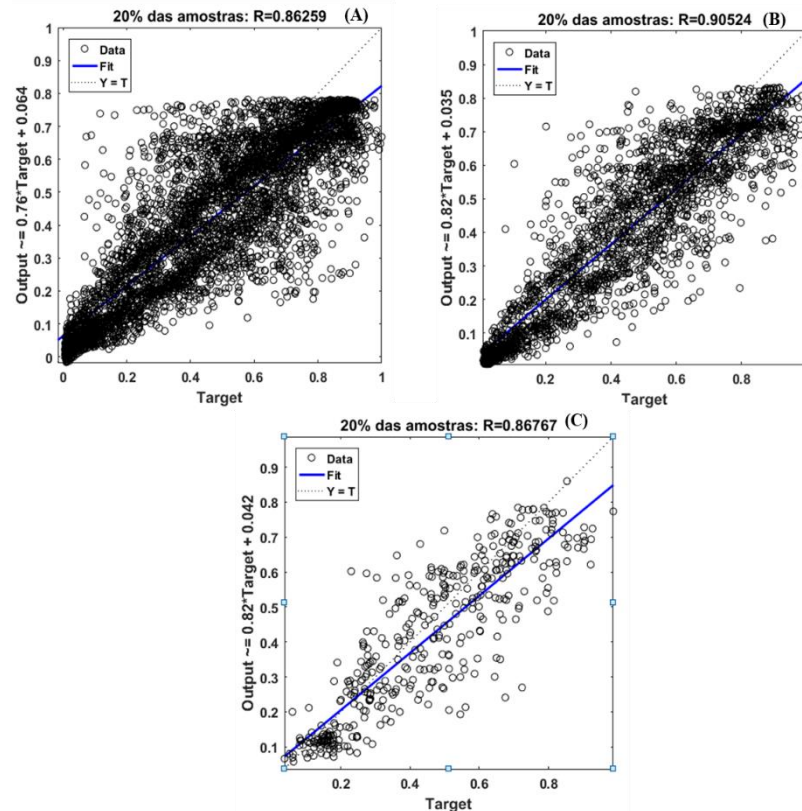


Fonte: Autoria Própria.

Com base nas figuras, observa-se que as curvas possuem um bom acompanhamento, no entanto, a amplitude das curvas de previsão se apresentou abaixo da curva de saída real em todos os casos. Outro detalhe observado foi para a Validação C, onde teve maior diferença nas curvas entre as demais validações, justificada pela redução das amostras, visto que as validações A e B possuem diferenças de amostras bem próximas.

Para analisar o desempenho dessas validações utilizou-se o método de regressão abordado na Figura 33. Na regressão nota-se um coeficiente de correlação regular para as validações A e C, com destaque para a Validação B, que teve o maior coeficiente com $R=0,90524$. Existe ainda, uma tendência dos dados em acompanhar a reta alvo, no entanto atrelado a ela, há também uma dispersão expressiva dos dados. De maneira geral, a regressão obtida para as três validações, mesmo apresentando amostras dispersas, pode ser considerado um valor aceitável e evidencia uma boa previsão para essas validações.

Figura 33 – Regressões das Validações A, B e C



Fonte: Autoria Própria.

Como visto, as maiores ocorrências de erros estão distribuídas dentro de intervalos em torno do zero para todos os histogramas apresentados, indicando uma boa previsão para as validações propostas. Ainda para analisar o desempenho dessas validações, tem-se os erros da Tabela 8.

Tabela 8 – Erros das Validações A, B e C

Validação	Período das amostras	ME	MAE	MSE	RMSE	EM (%)	RMSE (%)
A	20% das amostras	0,0454	0,1074	0,0216	0,1468	10,0105	32,4015
B	20% das amostras	0,0466	0,0926	0,0156	0,1250	10,1266	27,1618
C	20% das amostras	0,0407	0,0928	0,0149	0,1219	9,0029	26,9709

Fonte: Autoria Própria.

Dentre os resultados obtidos, tem-se o maior RMSE% com aproximadamente 32% para a Validação A, a Validação B apresente um RMSE% de aproximadamente 27%, e a Validação C possui o menor RMSE%, em torno de 26%, esses valores indicam o erro de previsão da rede neural em porcentagem. Para essas validações, acredita-se que o valor se mostrou elevado, pois

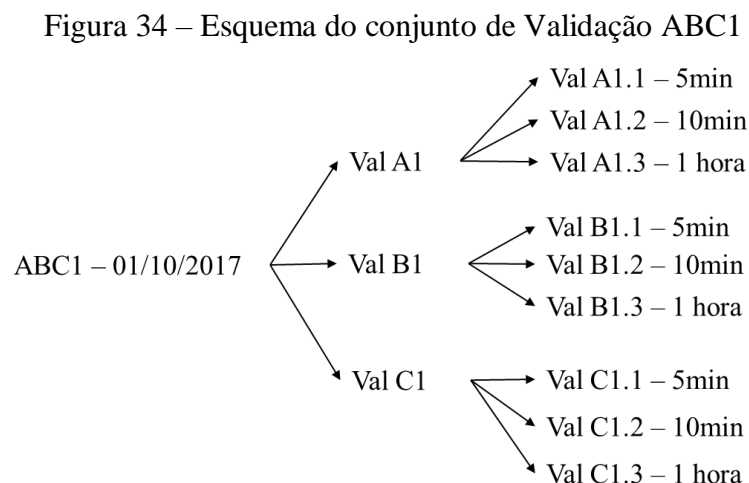
foram utilizadas variáveis com muita intermitência, onde qualquer diferença entre as curvas (prevista e real) geram valores elevados.

Essas validações com 20% das amostras são importantes para testar o desempenho das redes, prevendo uma grande quantidade de amostras, porém, a partir da subseção 4.1.4.2 até a 4.1.4.6 serão abordadas validações para dias pontuais, selecionados com base em critérios já citados no Capítulo 3.

4.1.4.2 Conjunto de Validação ABC1 - Dia 01 de outubro de 2017

Nessa seção será abordado o conjunto de Validação ABC1, composto pelas validações A1, B1 e C1, que foi implementada a partir dos treinamentos A, B e C, elas foram realizadas para o dia 01 de outubro de 2017. As análises desses resultados serão feitas mediante a comparação das validações com intervalos iguais e com treinamentos diferentes.

Para a Validação ABC1 serão realizadas análises para a capacidade de previsão das redes, bem como o desempenho de previsão delas para os diferentes intervalos de amostras inseridos. Dentro da Validação A1 foram realizadas outras 3 validações, A1.1, A1.2 e A1.3, com intervalos de 5 minutos, 10 minutos e 1 hora, respectivamente, sendo treinada de acordo com as configurações do Caso A. A Validação B1 contém as validações B1.1 (intervalos de 5 minutos), B1.2 (intervalos de 10 minutos), e B1.3 (intervalos de 1 hora), sendo treinada de acordo com as configurações de treinamento do Caso B. A Validação C1 é composta pelas validações C1.1, C1.2 e C1.3, com intervalos de 5 minutos, 10 minutos e 1 hora, respectivamente, e elas foram treinadas de acordo com as configurações de treinamento do Caso C. De forma resumida, tem-se o esquema da Figura 34 que ilustra as validações realizadas.

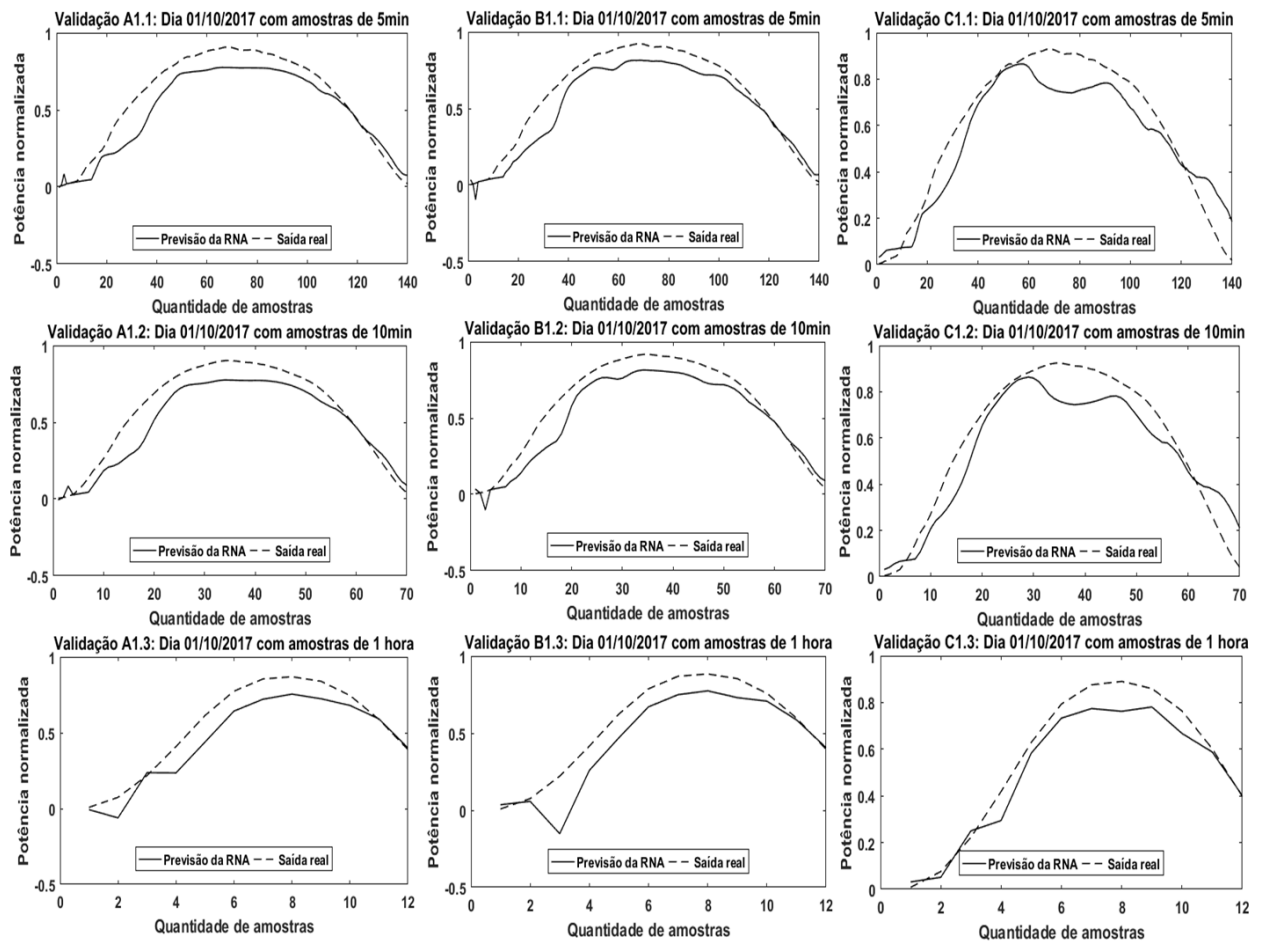


Fonte: Autoria Própria.

O dia selecionado, além de estar dentro do período de manutenção, também foi escolhido por ser considerado o melhor dia do mês de outubro, ou seja, foi o dia em que houve maior geração de potência do SFCR estudado, e isso fica evidente ao observar a curva de geração, denominada na Figura 35 de saída real, onde nota-se pouca variação ao longo do dia, podendo ser visto também os resultados obtidos com as validações ABC1, em que observa-se a comparação entre as curvas previstas pela RNA e a saída real.

Na Figura 35 as comparações dos resultados entre os treinamentos e as validações podem ser realizadas de duas formas, horizontalmente, em que cada curva apresenta validações com o mesmo intervalo de amostras (5 minutos), porém com treinamentos diferentes (Casos A, B e C), e verticalmente, onde nas comparações observa-se que as validações são em intervalos distintos (5 minutos, 10 minutos e 1 hora), porém comparam-se o mesmo treinamento, essas análises podem ser repetidas para todas as figuras que apresentam as comparações entre o real e o previsto de sua respectiva validação.

Figura 35 – Comparação Real x Previsto do conjunto de Validação ABC1

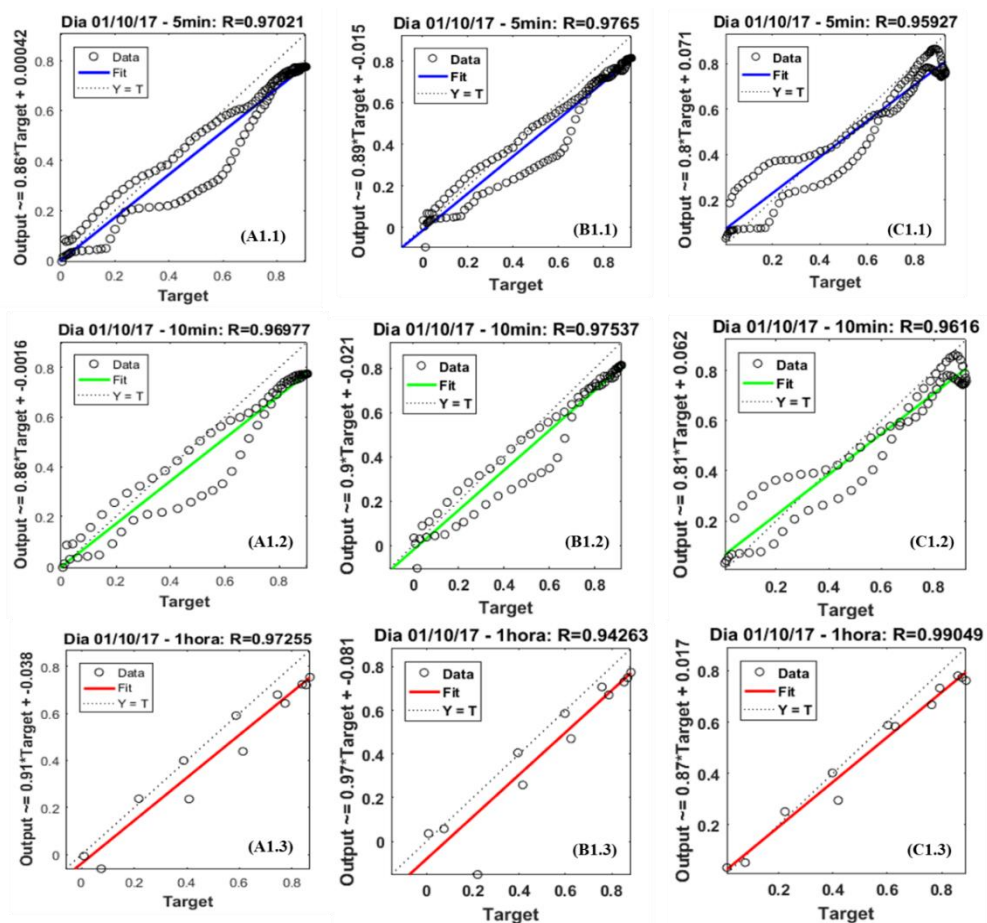


Fonte: Autoria Própria.

Esses resultados demonstram, visualmente, uma boa previsão da RNA, que mesmo possuindo treinamentos distintos, apresentou uma boa aproximação entre as curvas para todos os casos. Por outro lado, algo em comum que pode ser notado entre elas é a amplitude da curva prevista, que se apresenta abaixo da curva de saída real em todas as situações, sendo essa considerada a falha mais evidente. Com isso, acredita-se que alterações em alguns parâmetros do treinamento pode reduzir tal amplitude. Visando obter uma melhor análise do desempenho dessas validações, tem-se as regressões desses resultados.

Todas as regressões obtidas apresentam coeficientes de correlação próximos a 1 (*vide* Figura 36), no entanto, a distribuição dos dados sobre a reta alvo deve ser coerente para que se possa concluir algo sobre a eficiência dos resultados, e analisando a Figura 36 nota-se que os dados de fato possuem uma tendência em acompanhar a reta alvo, porém algumas validações apresentam gráficos com dispersões de dados mais significativas, como é o caso das Validações A1.2, C1.2, A1.3, B1.3 e C1.3, sendo as três últimas validações, com uma quantidade reduzida de amostras, por isso, não afeta diretamente o coeficiente de correlação.

Figura 36 – Regressões do conjunto de Validação ABC1



Fonte: Autoria Própria.

Ao analisar essa figura pelo coeficiente de regressão, percebe-se que a Validação C1.3 obteve maior destaque com $R=0,99049$, em que tanto o treinamento como a validação, foram realizados com amostras em intervalos de 1 hora, sendo ela a situação que se utilizou um menor número de amostras, possibilitando uma redução significativa de ruídos, logo um pequeno número de amostras sobre a reta alvo indicará um elevado coeficiente, o mesmo acontece para as demais validações com intervalos de 1 hora.

Os erros mostrados na Tabela 9 demonstram numericamente os desempenhos das validações do dia 01/10/2017 para cada treinamento. Os EM, MAE, MSE e RMSE apresentam valores próximos para todas as validações, com exceção para a Validação C1.3 que obteve os menores erros MAE, MSE e RMSE, caracterizando um bom desempenho entre os dados previstos e reais dessa validação, e isso pôde ser notado nas curvas de comparações e na regressão, onde a mesma validação se destacou.

Tabela 9 – Erros do conjunto de Validação ABC1

Validação	Período das amostras	ME	MAE	MSE	RMSE	EM (%)	RMSE (%)
A1.1	01/10/2017 - 5min	0,0804	0,0930	0,0124	0,1113	14,04	19,46
A1.2	01/10/2017 - 10min	0,0814	0,0940	0,0126	0,1121	14,21	19,56
A1.3	01/10/2017 - 1 hora	0,0856	0,0912	0,0122	0,1102	16,09	20,73
B1.1	01/10/2017 - 5min	0,0772	0,0863	0,0106	0,1032	13,27	17,73
B1.2	01/10/2017 - 10min	0,0792	0,0885	0,0110	0,1050	13,59	18,03
B1.3	01/10/2017 - 1 hora	0,0996	0,1061	0,0206	0,1434	18,43	26,52
C1.1	01/10/2017 - 5min	0,0489	0,0901	0,0115	0,1073	8,35	18,31
C1.2	01/10/2017 - 10min	0,0508	0,0888	0,0110	0,1051	8,67	17,91
C1.3	01/10/2017 - 1 hora	0,0516	0,0608	0,0055	0,0739	9,48	13,57

Fonte: Autoria Própria.

Outro dado importante nessa tabela é o RMSE%, que mostra o erro de previsão percentual de cada validação, onde C1.3 também apresentou o menor erro, com 13,57%, essa validação é referente ao Caso C, onde o treinamento e a validação foram realizados com amostras em intervalos de 1 hora. Apesar desses erros não apresentarem grande discrepância entre as validações, observa-se que os maiores erros de previsão obtidos foram com as validações A1.3 e B1.3, ambas com intervalos de 1 hora.

Diante do que foi exposto, observa-se que as curvas previstas acompanharam bem as curvas reais para esse dia, apresentando apenas uma queda na amplitude em relação a curva real. No entanto, essa proximidade entre as curvas não diz, com alto grau de precisão, se o

desempenho foi adequado, para isso foram realizadas as somas e as médias das potências previstas para o dia 01/10/17, com o intuito de comparar com a saída real e analisar a diferença existente entre ela, conforme é abordado na Tabela 10. Para realizar essa etapa os dados foram desnormalizados, sendo convertidos para sua unidade real, o Watt.

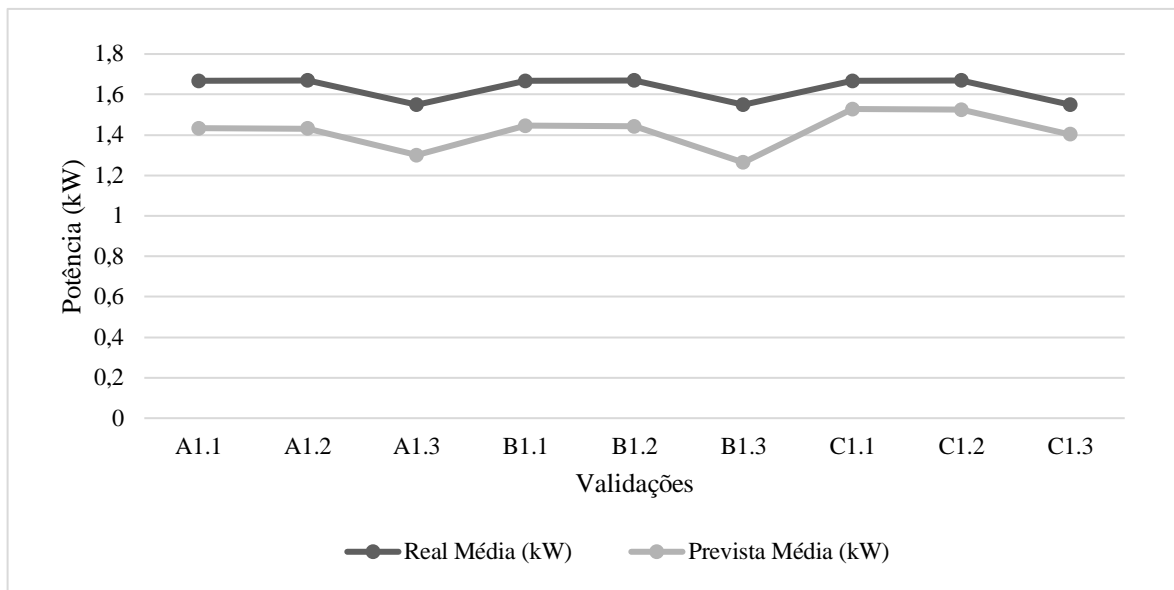
Tabela 10 – Potências do conjunto de Validação ABC1

Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
A1.1	01/10/2017 - 5min	233,418	200,64	32,78	1,667	1,433
A1.2	01/10/2017 - 10min	116,829	100,23	16,60	1,669	1,432
A1.3	01/10/2017 - 1 hora	18,591	15,60	2,99	1,549	1,300
B1.1	01/10/2017 - 5min	233,418	202,45	30,97	1,667	1,446
B1.2	01/10/2017 - 10min	116,829	100,95	15,88	1,669	1,442
B1.3	01/10/2017 - 1 hora	18,591	15,17	3,43	1,549	1,264
C1.1	01/10/2017 - 5min	233,418	213,94	19,48	1,667	1,528
C1.2	01/10/2017 - 10min	116,829	106,71	10,12	1,669	1,524
C1.3	01/10/2017 - 1 hora	18,591	16,83	1,76	1,549	1,402

Fonte: Autoria Própria.

A partir das informações contidas na Tabela 10 nota-se que a previsão das potências apresentou diferenças que chegam a até 32kW destacado em vermelho, como é o caso da Validação A1.1 e o menor valor obtido foi para a Validação C1.3, com uma diferença de 1,76kW destacado em azul na Tabela 10. Vale destacar que essas comparações de resultados só devem ser realizadas entre as validações de mesmo intervalos, ou seja, entre A1.1, B1.1, C1.1 com intervalos de 5 minutos, A1.2, B1.2, C1.2 com intervalos de 10 minutos e A1.3, B1.3, C1.3 em intervalos de 1 hora, visto que cada validação em que se utilizou um tipo de intervalo, a mesma apresentou quantidade de amostras distintas, podendo influenciar no somatório das potências. Ao observar o cálculo das potências médias, tem-se valores aproximados entre as potências médias previstas e as potências médias reais, para melhor ilustrar essa informação, o Gráfico 1 foi elaborado.

Gráfico 1 – Comparação entre as potências médias do conjunto de Validação ABC1



Fonte: Autoria Própria.

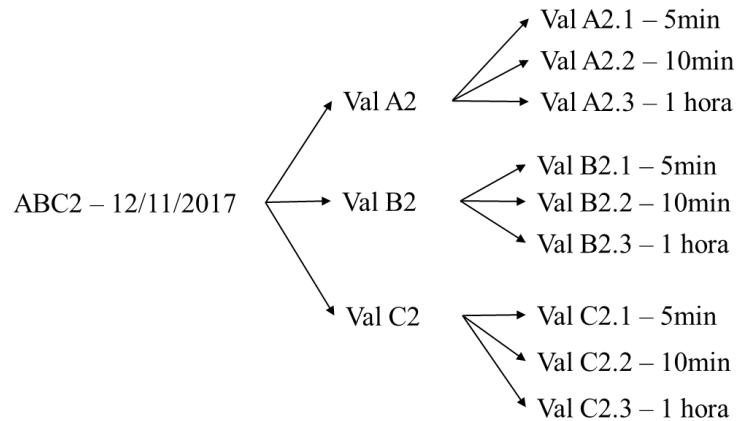
Nele percebe-se uma certa aproximação entre as linhas, principalmente entre as validações C1, que foram treinadas conforme o treinamento do Caso C.

4.1.4.3 Conjunto de Validação ABC2 - Dia 12 de novembro de 2017

Nesse conjunto de validação foram inseridas como variáveis de entrada, amostras do dia 12 de novembro de 2017, esse dia foi considerado o melhor do mês de novembro, com maior geração de potência do SFCR, além disso, esse dia pertence ao período de manutenção. O conjunto de validações ABC2 engloba 3 subconjuntos de validações (Val A2, Val B2 e Val C2), que por sua vez possui 3 validações cada um, sendo implementadas variando-se os intervalos em 5 minutos (Val A2.1, Val B2.1 e Val C2.1), 10 minutos (Val A2.2, Val B2.2 e Val C2.2) e 1 hora (Val A2.3, Val B2.3 e Val C2.3). Vale destacar, que os subconjuntos de validações Val A2, Val B2 e Val C2 foram treinados de acordo com o treinamento do Caso A, B e C, respectivamente.

Na Figura 37 pode-se observar detalhadamente o esquema de validações proposto, nele tem-se que serão realizadas para cada um dos treinamentos, três validações com intervalos diferentes de amostras para o dia 12 de novembro de 2017.

Figura 37 – Esquema do conjunto de Validação ABC2

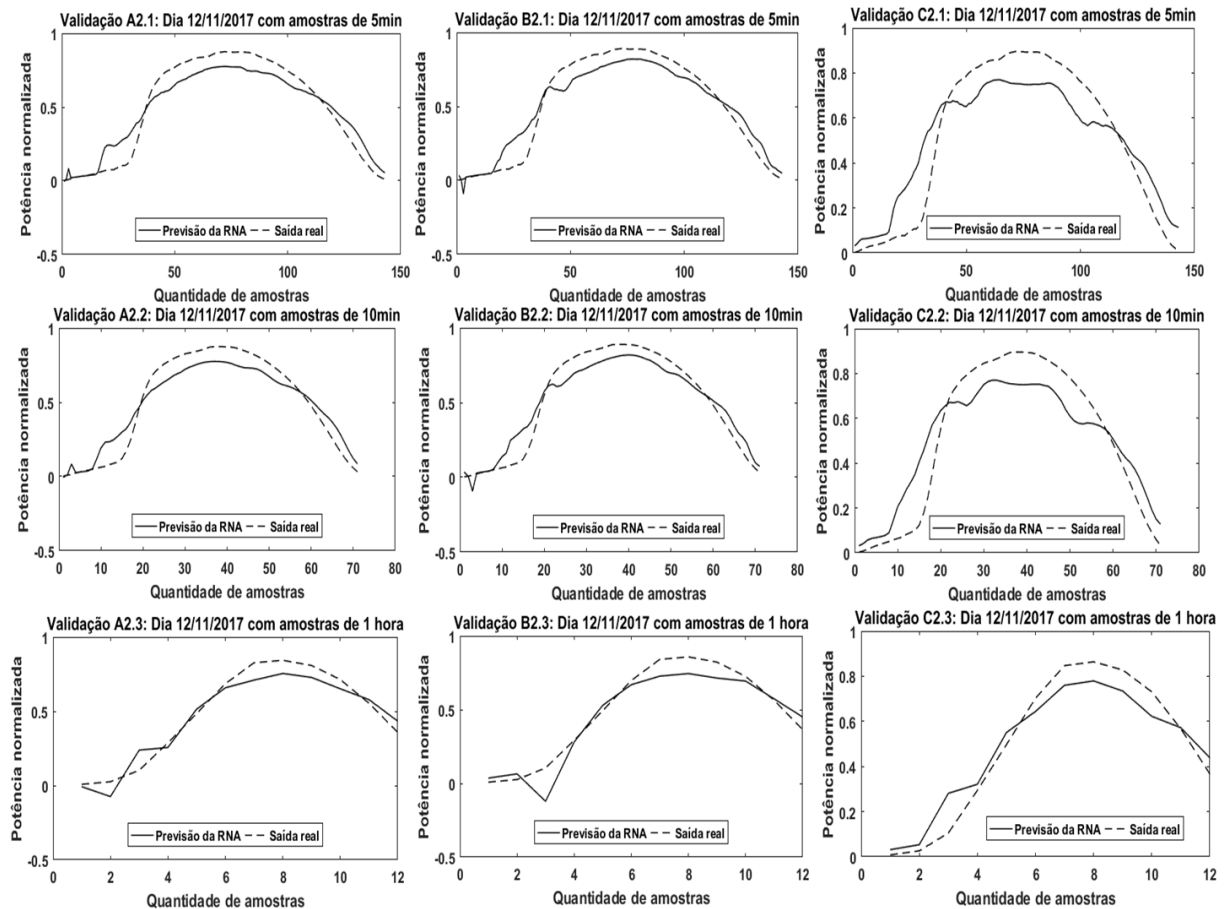


Fonte: Autoria Própria.

Como resultado dessas validações, tem-se na Figura 38 as comparações entre as potências previstas pela RNA e as saídas reais para cada uma das validações implementadas. Visualmente, a rede neural mostrou uma boa previsão dos dados, onde as curvas possuem proximidade entre elas, entretanto, assim como no conjunto de validações ABC1, as curvas previstas apresentam uma baixa amplitude em relação as curvas reais.

Analisando a figura por linha, tem-se a comparação das curvas com validações de mesmo intervalo e treinamentos distintos, onde nota-se que não houve diferenças expressivas nos resultados entre as validações realizadas nos Casos A2 e B2, com ressalva para as validações do Caso C2 (C2.1, C2.2, C2.3) que apresentou pequenas diferenças em relação as validações de mesmos intervalos, porém com pouca expressividade.

Figura 38 – Comparação Real x Previsto do conjunto de Validação ABC2



Fonte: Autoria Própria.

Nota-se que para dias com pouca variação climática, quando a curva de geração de potência exibe variações leves e caracteriza um dia bom, os resultados dessas previsões tem se mostrado favoráveis mesmo com a falha da amplitude. Analisando melhor esses resultados, tem-se as regressões referentes a cada uma dessas curvas, mostrados na Figura 39.


Todas as regressões obtidas apresentam coeficientes de correlação acima de $R=0,95$, caracterizando assim uma boa previsão, e embora esses dados apresentem algumas dispersões, sua distribuição condiz com os coeficientes de correlação, visto que os dados apresentam uma forte tendência em acompanhar a reta alvo, e com uma certa quantidade de amostras sobre a mesma.

Analisando por treinamento, as validações A2.1 e A2.2 obtiveram os melhores resultados de acordo com o coeficiente de correlação, sendo, portanto, o melhor aproveitamento conferido ao treinamento do Caso A, em que foi treinado com amostras em intervalos de 5 minutos. A Validação A2.3 não obteve o menor coeficiente de correlação para esse treinamento, no entanto,

observa-se que esse coeficiente não apresentou grande discrepância em relação as demais validações (B2.3 e C2.3).

Observa-se que para todas as validações com intervalos de 1 hora, os valores dos coeficientes são elevados, mesmo com uma distribuição de amostras dispersas, porém isso condiz com a quantidade reduzida de dados que foram utilizados.

Figura 39 – Regressões do conjunto de Validação ABC2



Fonte: Autoria Própria.

Na Tabela 11 mostra-se os diferentes erros obtidos para analisar a confiabilidade das validações, nela pode ser observado que existe uma aproximação entre os erros obtidos, com destaque para as validações C2, que apresenta algumas ocorrências de erros baixos, se comparado com as demais validações, no entanto, ao analisar o RMSE% dessa validação, a mesma apresenta os maiores erros entre as validações, atingindo valores de até 25%, indicando uma falha na previsão do dados, com maiores desvios entre os dados previstos e os reais.

Tabela 11 – Erros do conjunto de Validação ABC2

Validação	Período das amostras	ME	MAE	MSE	RMSE	EM (%)	RMSE (%)
A2.1	12/11/2017 - 5min	0,0143	0,0849	0,0094	0,0970	2,88	19,53
A2.2	12/11/2017 - 10min	0,0142	0,0837	0,0090	0,0947	2,85	18,95
A2.3	12/11/2017 - 1 hora	0,0216	0,0656	0,0058	0,0760	4,54	16,00
B2.1	12/11/2017 - 5min	0,0081	0,0759	0,0081	0,0902	1,60	17,86
B2.2	12/11/2017 - 10min	0,0094	0,0753	0,0077	0,0879	1,85	17,29
B2.3	12/11/2017 - 1 hora	0,0364	0,0692	0,0085	0,0919	7,54	19,04
C2.1	12/11/2017 - 5min	0,0066	0,1134	0,0171	0,1308	1,31	25,71
C2.2	12/11/2017 - 10min	0,0072	0,1110	0,0163	0,1277	1,42	24,93
C2.3	12/11/2017 - 1 hora	0,0041	0,0679	0,0066	0,0815	0,85	16,74

Fonte: Autoria Própria.

Visando uma análise mais próxima da realidade, realizou-se comparações com os resultados em sua unidade real, no caso o Watt. Os resultados dessa etapa são abordados na Tabela 12, com a potências acumuladas reais e prevista, bem como a média aritmética delas.

Tabela 12 – Potências do conjunto de Validação ABC2

Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
A2.1	12/11/2017 - 5min	206,98	201,02	5,95	1,4474	1,4058
A2.2	12/11/2017 - 10min	103,40	100,46	2,94	1,4563	1,4149
A2.3	12/11/2017 - 1 hora	16,61	15,85	0,75	1,3838	1,3209
B2.1	12/11/2017 - 5min	206,98	203,66	3,31	1,4474	1,4242
B2.2	12/11/2017 - 10min	103,40	101,49	1,91	1,4563	1,4295
B2.3	12/11/2017 - 1 hora	16,61	15,35	1,25	1,3838	1,2795
C2.1	12/11/2017 - 5min	206,98	204,27	2,70	1,4474	1,4285
C2.2	12/11/2017 - 10min	103,40	101,93	1,46	1,4563	1,4357
C2.3	12/11/2017 - 1 hora	16,61	16,46	0,14	1,3838	1,3720


Fonte: Autoria Própria.

Para essas validações, a maior diferença (destacada em vermelho) obtida entre as potências previstas acumulada e potências reais acumulada foi de 5,95kW, fato ocorrido na Validação A2.1, e a menor diferença encontrada, destacada em azul na tabela, foi de 141W, com a Validação C2.3. Para uma melhor demonstração dos valores das potências médias previstas e reais, foi elaborado

Gráfico 2. Nele observa-se que os valores possuem uma certa proximidade, sendo a validação B2.3 a que teve a maior diferença entre as potências médias, mesmo com a ideia prévia de que

outras figuras apresentam um maior erro (Figura 38) , pôde ser comprovado a partir dessa análise que isso não ocorre.

Gráfico 2 – Comparação entre as potências médias do conjunto de Validação ABC2



Fonte: Autoria Própria.

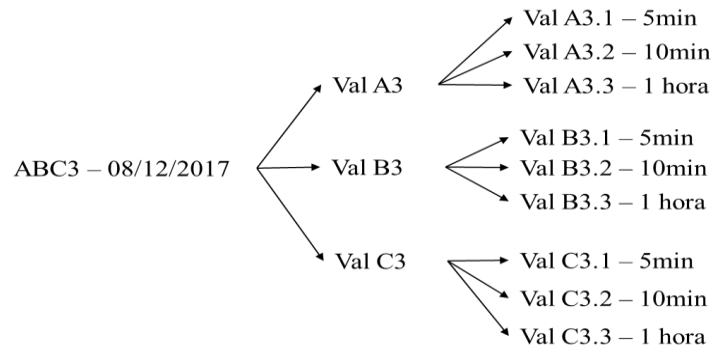
Essa análise é importante para verificar que mesmo existindo diferenças entre as curvas de comparação (Figura 38), com o

Gráfico 2 é possível indicar a geração de potência média prevista e real, mostrando nesse caso que o treinamento C foi o que deteve melhor desempenho, apresentando uma maior proximidade entre as potências médias.

4.1.4.4 Conjunto de Validação ABC3 - Dia 08 de dezembro de 2017

O conjunto de validações ABC3 foi realizado utilizando amostras do dia 08 de dezembro de 2017, dentro do período de manutenção. Os subconjuntos (Val A3, Val B3 e Val C3), que formam o conjunto principal ABC3, foram treinados de acordo com os treinamentos do Caso A, B e C, respectivamente, e suas validações foram implementadas em intervalos de 5 minutos, 10 minutos e 1 hora, conforme o esquema da Figura 40, que mostra resumidamente a divisão dessas validações.

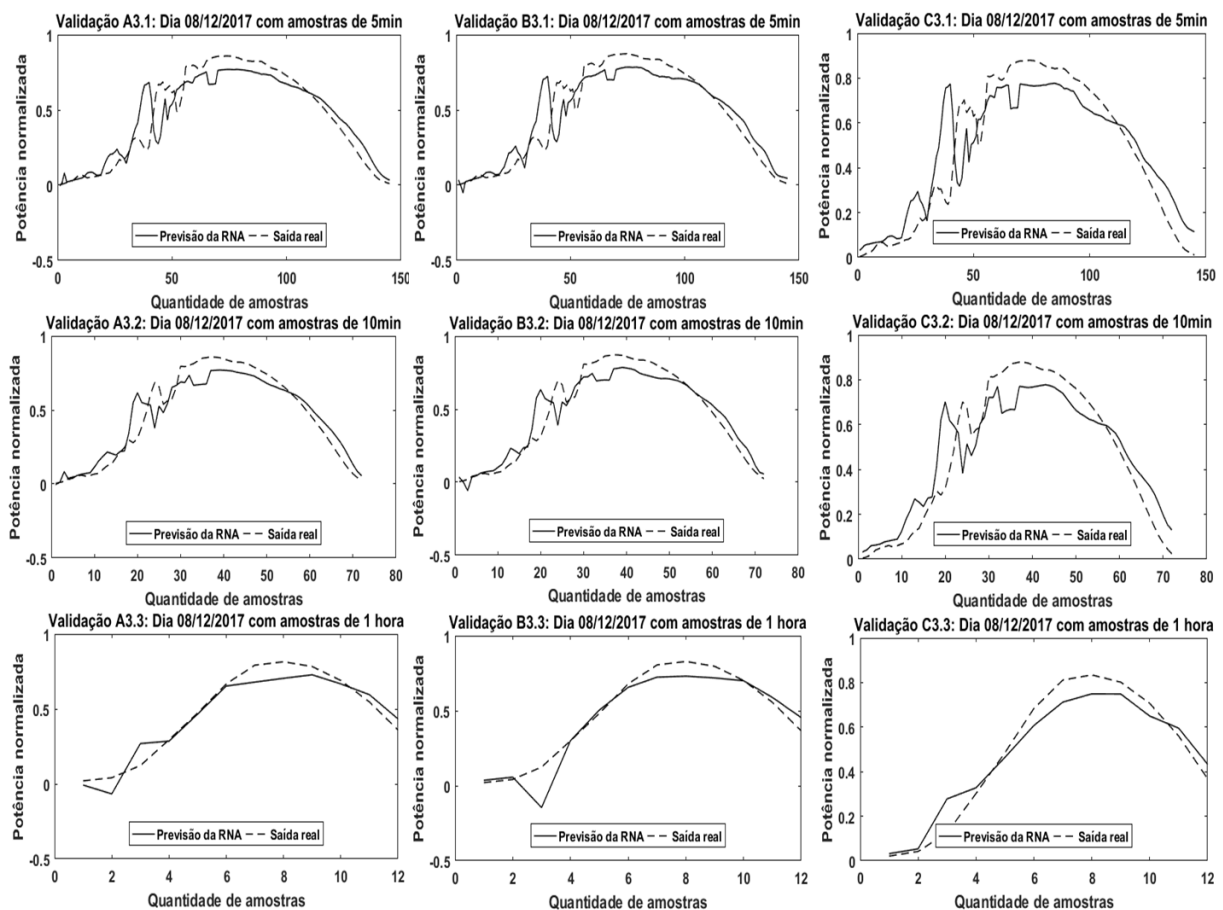
Figura 40 – Esquema do conjunto de Validação ABC3



Fonte: Autoria Própria.

A Figura 41 mostra os resultados do conjunto de validações ABC3, onde são apresentadas todas as comparações realizadas entre as validações. Nota-se que, mesmo estando dentro do período limpo, e sendo o dia com maior geração de potência do mês de dezembro de 2017, a curva de saída real apresenta algumas variações ao longo do dia, dificultando a previsão da rede neural.

Figura 41 – Comparação Real x Previsto do conjunto de Validação ABC3

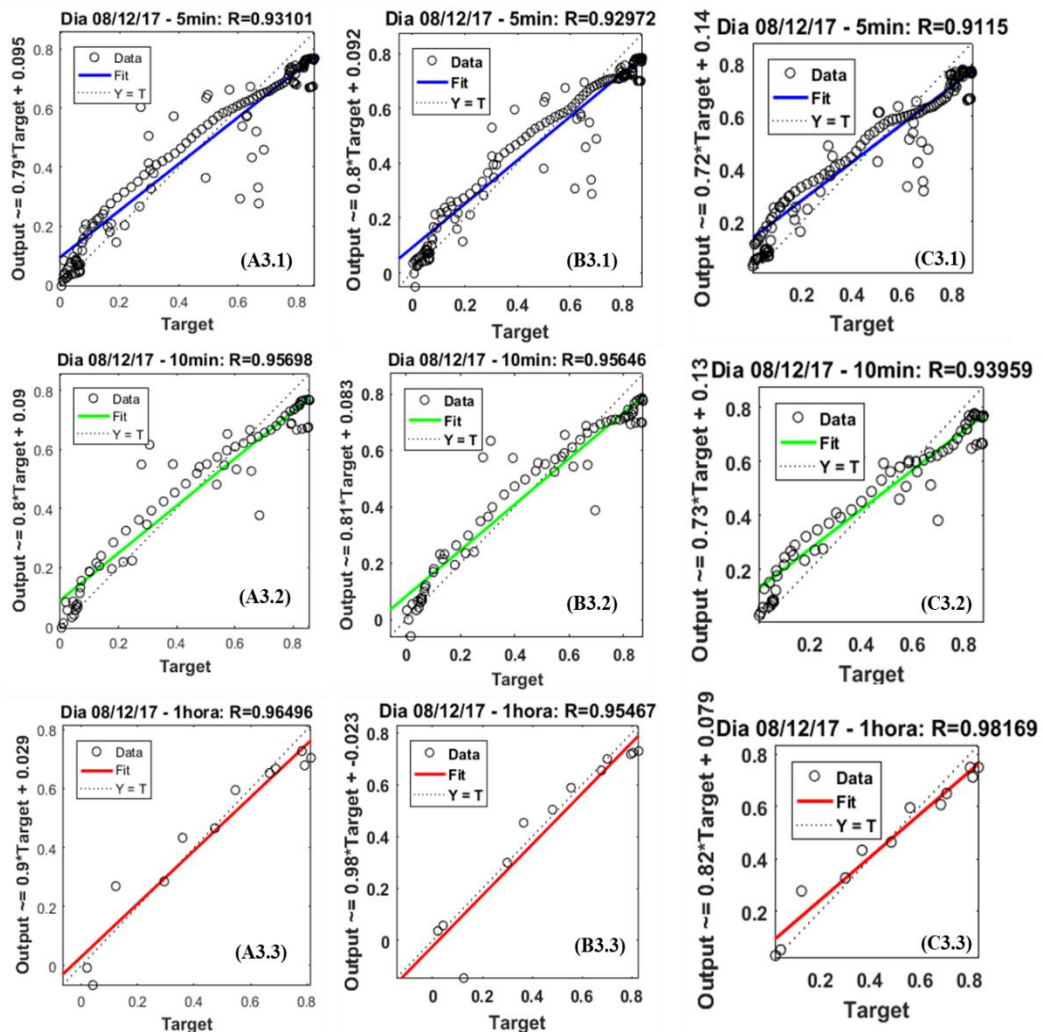


Fonte: Autoria Própria.

Diante disto, observa-se que a rede não acompanhou de forma eficiente tais variações, além disso, as curvas de previsão da RNA continuam apresentando amplitudes abaixo da curva de saída real. Mesmo apresentando essas falhas nas análises visuais, as regressões dessas validações se mostram eficientes, com coeficientes de correlação próximo a 1, e com a distribuição dos dados coerentes com esses coeficientes, apresentado uma tendência em seguir a reta alvo e com poucos desvios entre os valores reais e previstos, a Figura 42 mostra essas informações.

A melhor previsão, de acordo com o coeficiente de correlação, é da Validação C3.3, com $R=0,98169$, ela, por possuir uma quantidade de amostras reduzidas, propiciou uma redução nas variações das curvas, suavizando os picos existente, o que favoreceu a previsão para essa validação.

Figura 42 – Regressões do conjunto de Validação ABC3



Fonte: Autoria Própria.

Na

Tabela 13 são abordados os erros obtidos para cada uma dessas validações, onde o menor erro de previsão obtido foi para a Validação C3.3, com RMSE% de aproximadamente 14%. Dentre as validações, as que apresentaram o menor RMSE% de cada treinamento foram as validadas com intervalos de 1 hora. A Validação C3.1 apresenta o maior RMSE% entre as validações, com aproximadamente 28% de erro, com isso, observa-se que as validações do treinamento C deteve os extremos desses erros, englobando o mínimo e o máximo de erro em suas validações. Nota-se, portanto, que mesmo sendo validada com um maior número de amostras e intervalos menores, a Validação C1.3 não obteve sucesso no treinamento C, sendo a pior previsão obtida.

Tabela 13 – Erros do conjunto de Validação ABC3

Tabela de erros ABC3							
Validação	Período das amostras	ME	MAE	MSE	RMSE	EM (%)	RMSE (%)
A3.1	08/112/2017 - 5min	0,0629	0,1028	0,0175	0,1323	0,47	25,01
A3.2	08/112/2017 - 10min	0,0705	0,1006	0,0163	0,1278	0,71	20,70
A3.3	08/112/2017 - 1 hora	0,0503	0,0926	0,0127	0,1128	3,56	16,41
B3.1	08/112/2017 - 5min	0,0029	0,0809	0,0138	0,1176	0,63	25,08
B3.2	08/112/2017 - 10min	0,0043	0,0709	0,0092	0,0959	0,92	20,40
B3.3	08/112/2017 - 1 hora	0,0315	0,0605	0,0088	0,0938	6,63	19,76
C3.1	08/112/2017 – 5min	-0,0062	0,1007	0,0183	0,1354	-1,31	28,64
C3.2	08/112/2017 - 10min	-0,0017	0,0933	0,0138	0,1177	-0,36	24,86
C3.3	08/112/2017 - 1 hora	0,0075	0,0577	0,0049	0,0701	1,57	14,66

Fonte: Autoria Própria.

Para uma melhor interpretação desses resultados tem-se a Tabela 14 com as potências previstas e reais em Watt, nela observa-se que a potência acumulada real e prevista para o dia 08/12/17 obtido para cada umas das validações, a menor diferença observada foi para a Validação C3.3, com 255W, observa-se ainda que as validações C3.1 e C3.2 apresentaram uma diferença negativa, o que significa que a potência prevista foi superior à potência real nesses dois testes. A validação B3.1 apresentou a maior diferença com 1,22kW, sendo este valor destacado na Tabela 14 na cor vermelha.


Tabela 14 – Potências do conjunto de Validação ABC3

Tabela de Potências ABC3						
Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
A3.1	08/112/2017 - 5min	194,91	194,00	0,91	1,344	1,338
A3.2	08/112/2017 - 10min	96,94	96,26	0,69	1,346	1,337
A3.3	08/112/2017 - 1 hora	16,33	15,75	0,58	1,361	1,312
B3.1	08/112/2017 - 5min	194,91	193,69	1,22	1,344	1,336
B3.2	08/112/2017 - 10min	96,94	96,06	0,88	1,346	1,334
B3.3	08/112/2017 - 1 hora	16,33	15,25	1,08	1,361	1,271
C3.1	08/112/2017 - 5min	194,91	197,46	-2,55	1,344	1,362
C3.2	08/112/2017 - 10min	96,94	97,29	-0,35	1,346	1,351
C3.3	08/112/2017 - 1 hora	16,33	16,07	0,26	1,361	1,339

Fonte: Autoria Própria.

Os resultados médios das potências também são importantes para a análise, uma vez que demonstra para onde se concentra a distribuição dos dados, e ao realizar a comparação dos resultados médios das potências reais e previstas, nota-se uma boa aproximação entre elas na Tabela 14, no entanto, para uma melhor interpretação desses resultados, o Gráfico 3 foi elaborado.

Gráfico 3 – Comparação entre as potências médias do conjunto de Validação ABC3



Fonte: Autoria Própria.

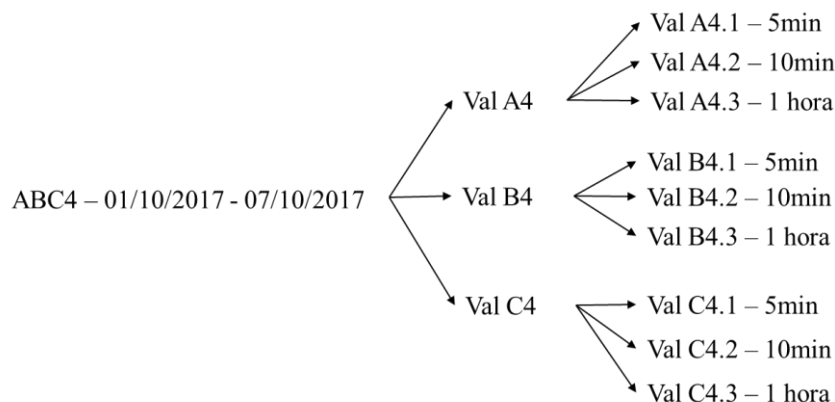
No Gráfico 3 é possível observar a aproximação dos resultados para as validações A3.1, A3.2, B3.1, B3.2, C3.1 e C3.2, sendo as duas últimas compostas por diferenças negativas,

conforme pode ser visto no Gráfico 3. Nota-se ainda que as validações com intervalos de 1 hora foram os que registraram as maiores diferenças de potências médias. A partir desses resultados, tem-se que os treinamentos com melhor generalização foram dos Casos A e B, apresentando as menores diferenças de potências médias.

4.1.4.5 Conjunto de Validação ABC4 - Semana de 01 a 07 de outubro de 2017

O conjunto de validação ABC4 contou com amostras da semana de 01 a 07 de outubro de 2017, em que para os itens dos subconjuntos (Val A4, Val B4 e Val C4) realizou-se validações variando os intervalos das amostras de cada um, em 5 minutos, 10 minutos e 1 hora, essa semana foi selecionada por ser a semana de maior geração de potência entre os meses de outubro e dezembro. Um resumo da divisão das validações realizadas é mostrado na Figura 43.

Figura 43 – Esquema do conjunto de Validação ABC4

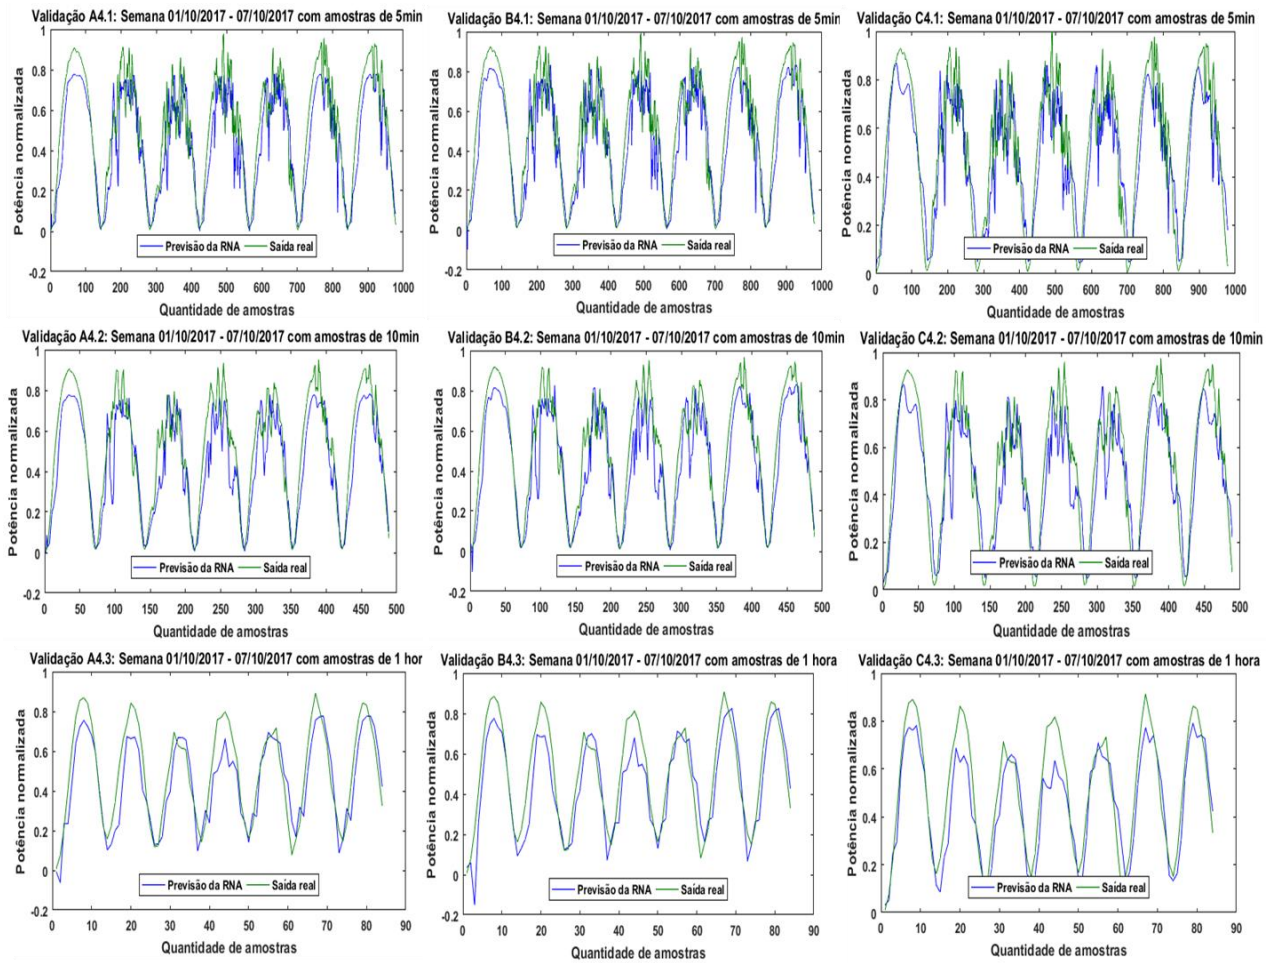


Fonte: Autoria Própria.

Essas validações resultaram nas curvas da Figura 44 onde observa-se falhas na previsão dessas validações na amplitude e nas variações das curvas. A curva de previsão da RNA fica sempre abaixo da curva da saída real, e com relação as variações, a rede não consegue acompanhar tão bem esses picos e quedas nas curvas ao longo da geração de potência, essas falhas foram observadas nas três validações.

Nota-se então que para dias com muita intermitência a rede neural não apresenta resultados satisfatórios, visto que a curva de previsão da RNA não acompanha a curva real com eficiência, apresentando diferenças significativas entre elas.

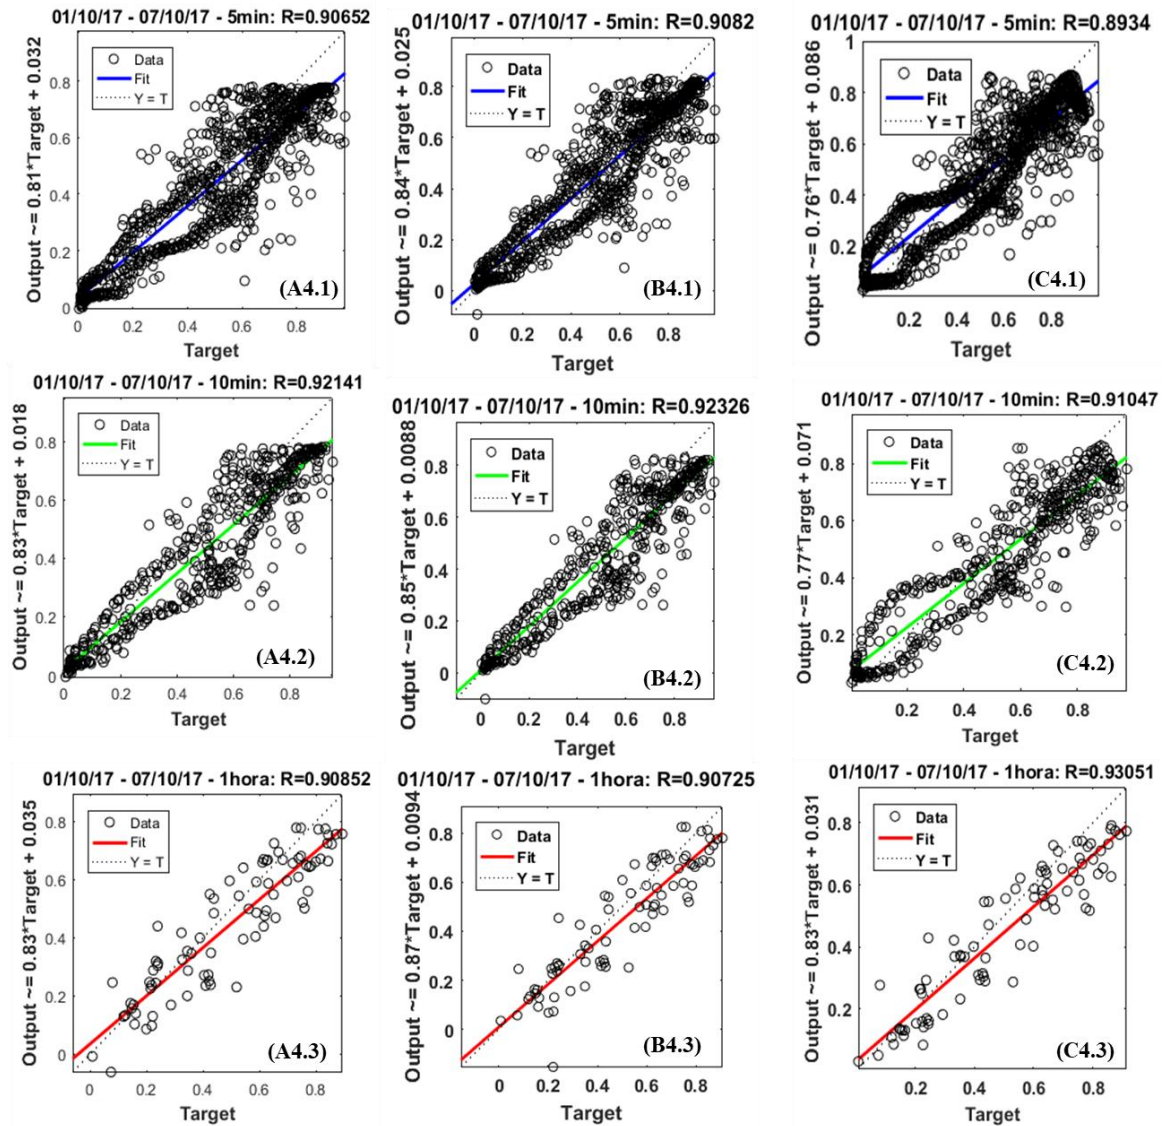
Figura 44 – Comparações Prevista x Real do conjunto de Validação ABC4



Fonte: Autoria Própria.

Os métodos de regressão utilizado para analisar o desempenho dessas validações é mostrado na Figura 45. As regressões apresentam coeficientes de correlação considerados bons para determinar uma boa previsão, onde o menor coeficiente obtido foi de $R=0,8934$ para a Validação C4.1. Diferentemente das validações anteriores, essa apresenta uma previsão para vários dias o que implica em uma maior quantidade de amostras para as validações e consequentemente mais ruídos serão inseridos, ocasionando uma maior dispersão de dados, conforme visto na Figura 45, que mesmo apresentando tendência em seguir a reta alvo, ainda assim possui desvio entre os dois dados previsto e reais.

Figura 45 – Regressões do conjunto de Validação ABC4



Fonte: Autoria Própria.

Os dados apresentados na Tabela 15 mostram os erros nas mesmas faixas de valores, não apresentando discrepância significativa entre as validações. O RMSE% apresenta variações, porém com valores bem próximos, onde a variação entre o maior e o menor erro chegam a aproximadamente 5% apenas. O menor erro ocorreu na Validação C4.3 com 20% aproximadamente, e o maior ocorreu na Validação A4.1 com 25,85%.

Tabela 15 – Erros do conjunto de Validação ABC4

Validação	Período das amostras	ME	MAE	MSE	RMSE	EM (%)	RMSE (%)
A4.1	01/10/2017-07/10/17 - 5min	0,0055	0,1381	0,0282	0,1678	12,30	25,85
A4.2	01/10/2017-07/10/17 - 10min	0,0161	0,1414	0,0297	0,1724	13,68	24,80
A4.3	01/10/2017-07/10/17 - 1 hora	0,0930	0,0989	0,0175	0,1323	10,13	22,74
B4.1	01/10/2017-07/10/17 - 5min	0,0599	0,1009	0,0174	0,1318	11,52	25,32
B4.2	01/10/2017-07/10/17 - 10min	0,0689	0,0989	0,0162	0,1272	13,14	24,28
B4.3	01/10/2017-07/10/17 - 1 hora	0,0544	0,0938	0,0138	0,1176	10,79	23,31
C4.1	01/10/2017-07/10/17 - 5min	0,0404	0,1067	0,0179	0,1337	7,71	25,51
C4.2	01/10/2017-07/10/17 - 10min	0,0489	0,1047	0,0162	0,1271	9,27	24,08
C4.3	01/10/2017-07/10/17 - 1 hora	0,0547	0,0855	0,0113	0,1063	10,77	20,92

Fonte: Autoria Própria.

Com os dados da Tabela 16 pode-se ter uma melhor análise dos resultados obtidos a partir das validações, visto que nela os dados são manipulados em sua unidade real, dando uma melhor interpretação dos resultados. Diante disso, tem-se a diferença entre as potências acumuladas reais e previstas de cada validação para a semana em estudo, sendo a Validação A4.1, destacada em vermelho, a que obteve a maior diferença com 179,5kW, nota-se que as validações com intervalos de 5 minutos (A4.1, B4.1 e C4.1) foram as que obtiveram as maiores diferenças de potência entre seus respectivos treinamentos. Em azul está destacada a validação que apresentou a menor diferença entre as potências acumuladas, com 9,65kW.

Tabela 16 – Potências do conjunto de Validação ABC4


Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
A4.1	01/10/2017-07/10/17 - 5min	1459,97	1280,48	179,48	1,491	1,308
A4.2	01/10/2017-07/10/17 - 10min	734,21	633,79	100,42	1,501	1,296
A4.3	01/10/2017-07/10/17 - 1 hora	121,41	109,11	12,30	1,445	1,299
B4.1	01/10/2017-07/10/17 - 5min	1459,97	1291,85	168,11	1,491	1,320
B4.2	01/10/2017-07/10/17 - 10min	734,21	637,74	9,65	1,501	1,304
B4.3	01/10/2017-07/10/17 - 1 hora	121,41	108,32	13,09	1,445	1,289
C4.1	01/10/2017-07/10/17 - 5min	1459,97	1347,40	112,56	1,491	1,376
C4.2	01/10/2017-07/10/17 - 10min	734,21	666,16	68,05	1,501	1,362
C4.3	01/10/2017-07/10/17 - 1 hora	121,41	108,34	13,07	1,445	1,290

Fonte: Autoria Própria.

Nota-se que os resultados entre as potências médias reais e previstas apresentam diferenças significativas, onde a validação que mais se aproximou do valor médio real foi a

C4.1, em que o valor médio real foi de 1,491kW e o valor previsto foi de 1,376kW, o Gráfico 4 mostra a linhas das potências médias do conjunto de validações ABC4.

Gráfico 4 – Comparação entre as potências médias do conjunto de Validação ABC4



Fonte: Autoria Própria.

Conforme visto nas curvas do Gráfico 4, devido à maior quantidade de amostras utilizadas no conjunto de validações ABC4, que foi compreendido no período de validações de 7 dias, os resultados demonstram uma maior diferença encontrada entre as potências médias reais e previstas, essa maior quantidade de amostras influenciará na média desses valores, de forma a elevar os erros.

4.1.4.6 Conjunto de Validação ABC9 - Para outras regiões

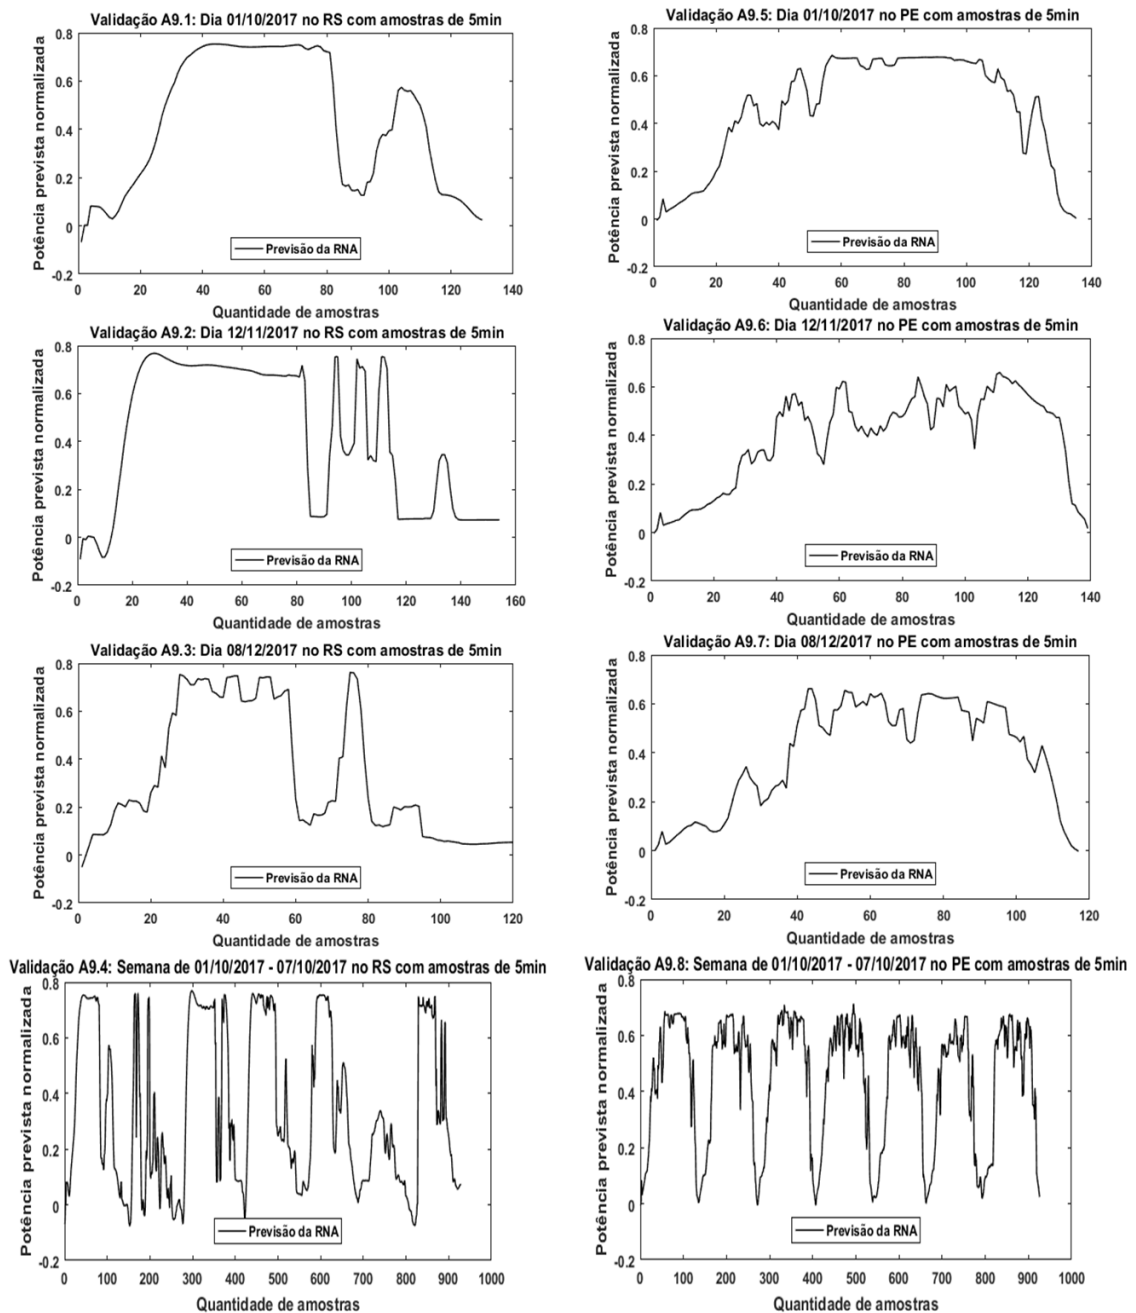
As validações para outras regiões foram realizadas com o intuito de prever a potência gerada pelo SFCR se instalado em diferentes regiões, para isso, realizou-se o conjunto de validações ABC9 constituído dos subconjuntos A9 (de A9.1 a A9.8), B9 (de B9.1 a B9.8) e C9 (de C9.1 a C9.8), treinados de acordo com as configurações de treinamento, do Caso A, B e C, respectivamente, e foram validados com informações meteorológicas dos estados do Rio Grande do Sul e Pernambuco, para possibilitar a previsão da potência gerada com a instalação do sistema nesses estados. Os dias utilizados para essa validação foram, 01 de outubro, 12 de novembro, 08 de dezembro, e para a semana de 01 a 07 de outubro, todos do ano de 2017, utilizando amostras com intervalos de 5 minutos.

Essas validações foram realizadas após aplicar os três treinamentos propostos, visando testar a eficiência da rede neural com a inserção de amostras com diferentes intervalos, o que

permite ao usuário mais opções de dados de entrada, uma vez que a rede estando apta a isso, ela irá receber qualquer intervalo de amostra e generalizá-las com eficiência.

Com as validações do treinamento do Caso A tem-se as curvas da Figura 46. Na primeira coluna tem-se as curvas de potência prevista para o Rio Grande do Sul, correspondendo às validações do subconjunto A9, que são A9.1 a A9.4, já para Pernambuco as validações são de A9.5 a A9.8, conforme a segunda coluna de curvas da Figura 46.

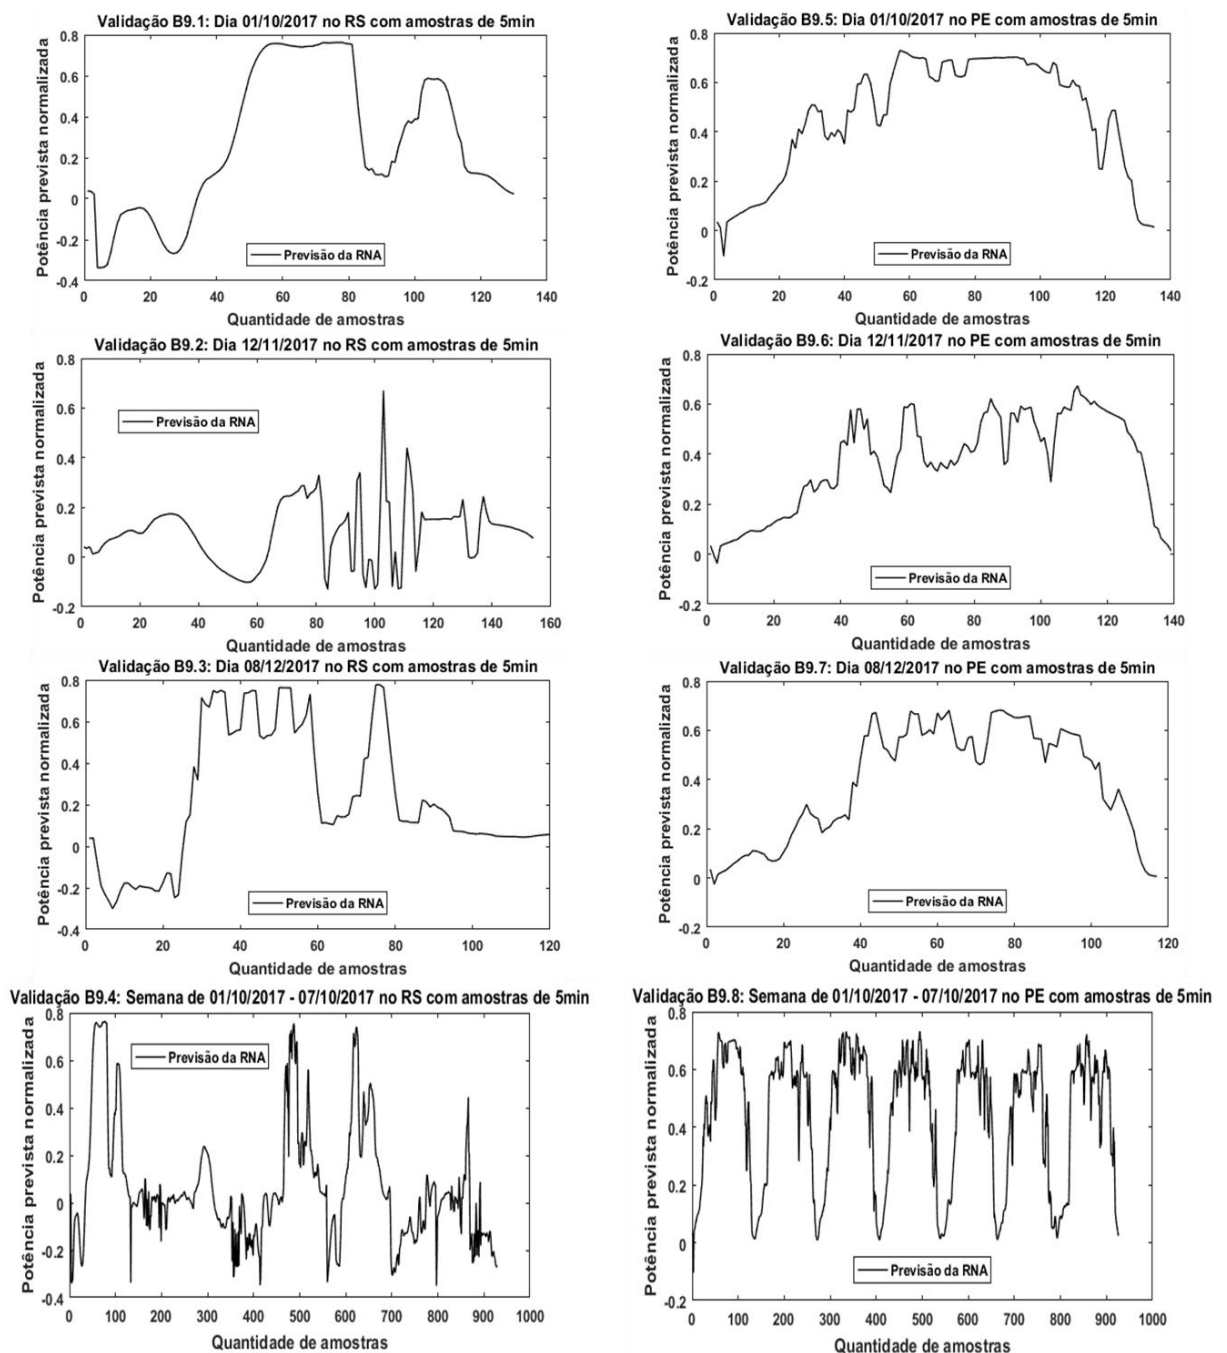
Figura 46 – Curvas resultantes do subconjunto de Validação A9



Fonte: Autoria Própria.

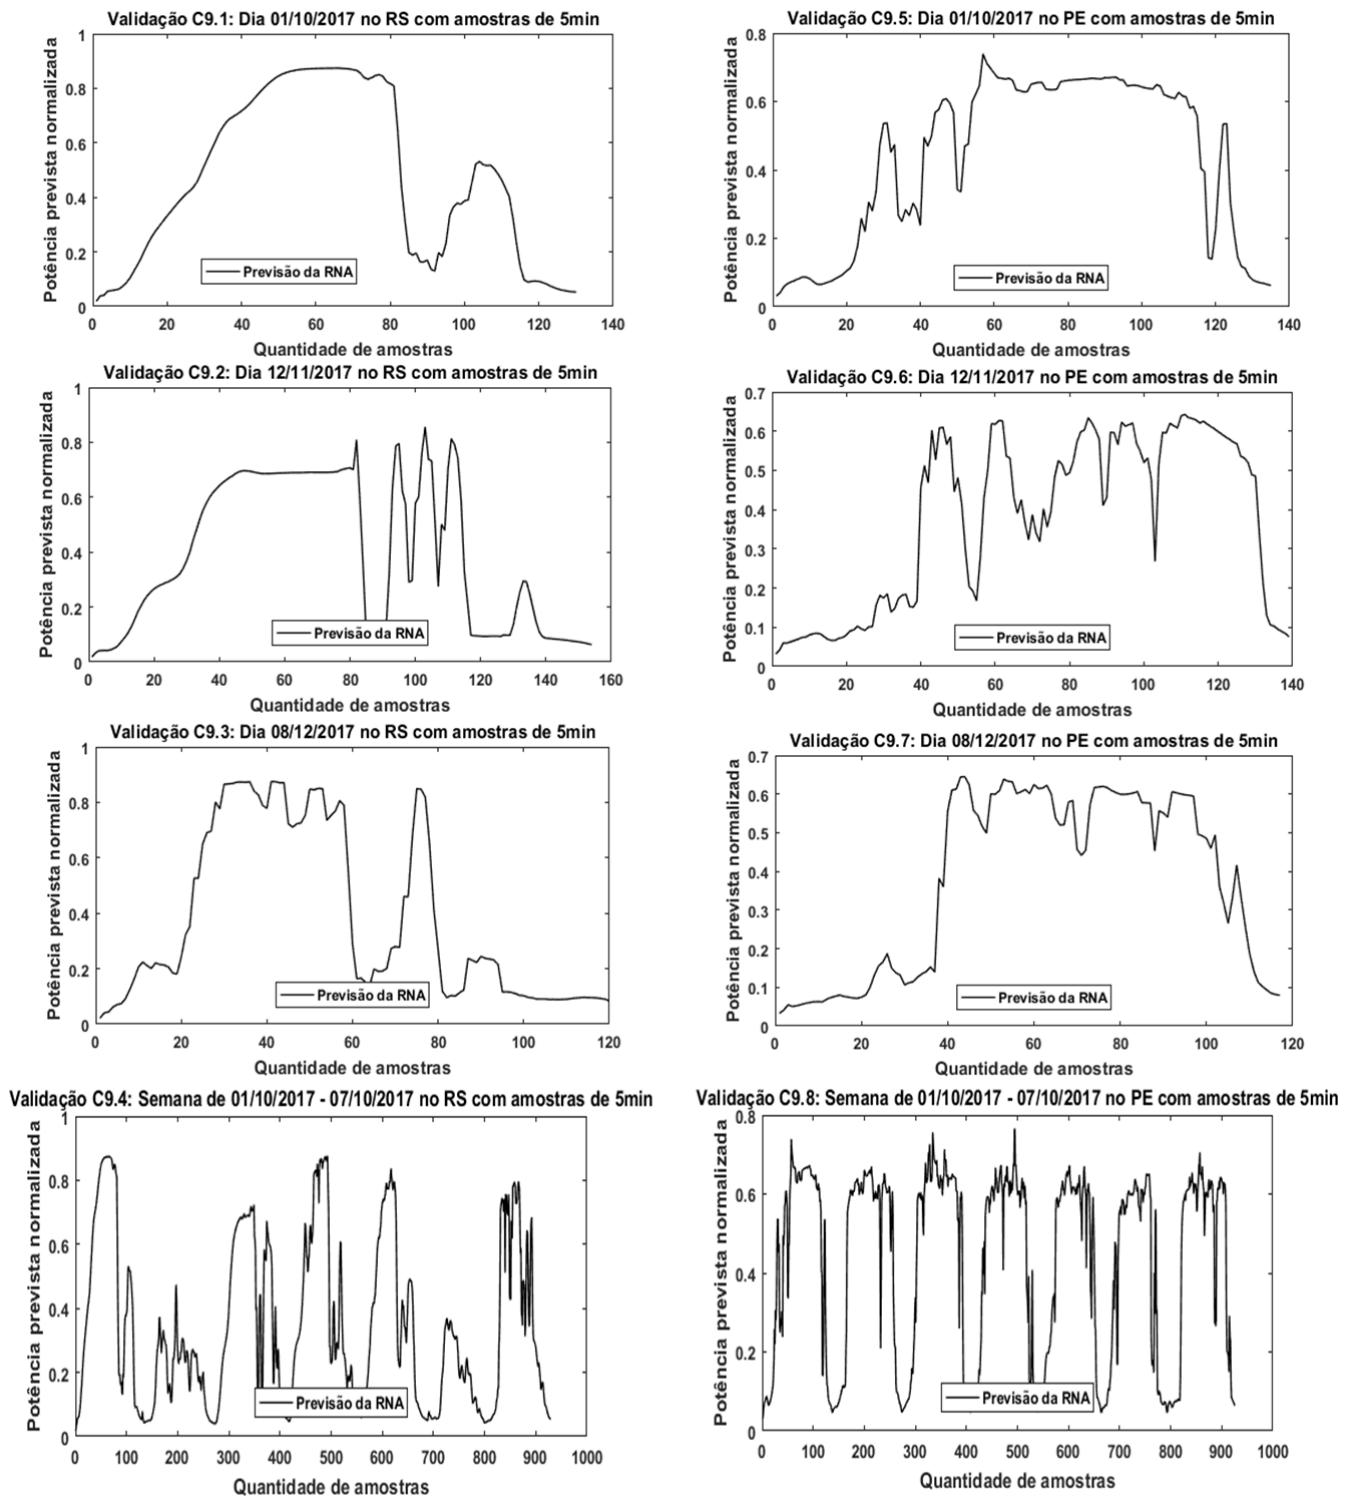
Nota-se que as validações realizadas para PE são melhores do que para o RS, não podendo afirmar que é um problema somente da rede neural, visto que as condições climáticas do RS não favorecem a geração fotovoltaica, apresentando grandes variações ao longo do dia, comparações entre os estados serão mostradas no decorrer dessa seção a partir da potência elétrica obtida. Essas fortes variações que ocorrem nas curvas do estado do RS se repetem para as demais validações das Figura 47 (subconjunto B9) e Figura 48 (subconjunto C9), em que cada uma delas são mostradas as validações referentes aos treinamentos.

Figura 47 – Curvas resultantes do subconjunto de Validação B9



Fonte: Autoria Própria.

Figura 48 – Curvas resultantes do subconjunto de Validação C9



Fonte: Autoria Própria.

De maneira geral, as previsões não apresentaram diferenças expressivas entre as validações, mesmo implementadas com treinamentos diferentes, elas resultam em curvas bastantes semelhantes de um treinamento para o outro, ao comparar as curvas entre as Figura 46, Figura 47 e Figura 48.

No entanto, elas apresentam elevadas variações ao longo do período de previsão, principalmente para o RS, com isso, realizou-se o somatório das gerações de potência previstas, para se ter uma análise quantificada dessa geração e poder realizar comparações entre os estados, bem como, dos treinamentos, determinando qual deles se destacou com a melhor generalização das amostras e conseqüentemente a melhor previsão. Para tanto, tem-se a Tabela 17, que mostra as potências previstas com as validações em cada treinamento.

Tabela 17 – Potências previstas dos estados por treinamento

Período das amostras	Caso A		Caso B		Caso C	
	Acumulada (kW)	Média (kW)	Acumulada (kW)	Média (kW)	Acumulada (kW)	Média (kW)
RS 01/10/17	163,18	1,255	100,60	0,774	173,47	1,334
PE 01/10/17	180,63	1,338	177,11	1,312	166,65	1,234
RS 12/11/17	187,54	1,218	43,43	0,282	171,80	1,116
PE 12/11/17	158,24	1,138	146,09	1,051	149,07	1,072
RS 08/12/17	113,60	0,947	76,56	0,638	129,61	1,080
PE 08/12/17	133,83	1,144	130,12	1,112	124,20	1,062
RS semana	935,79	1,007	180,91	0,195	920,34	0,991
PE semana	1190,74	1,286	1160,82	1,254	1132,66	1,223

Fonte: Autoria Própria.

Para uma melhor visualização dos dados, a Tabela 17 foi destacada em azul e vermelho, onde indica, respectivamente, os maiores e os menores valores de potência prevista encontrados por treinamento. Nota-se a partir disto, que as validações que foram treinadas de acordo com as configurações do Caso A, ou seja, o treinamento realizado com amostras de 5 minutos, deteve o maior número de validações com valores mais elevados de potência prevista.

Ainda de acordo com a Tabela 17, observa-se que as validações que foram treinadas com amostras em intervalos de 10 minutos (Caso B) apresentou uma maior quantidade de valores reduzidos de potência prevista, se comparado com os resultados de validações dos demais treinamentos (Caso A e C).

Essas diferenças de potência prevista obtidas nas validações de cada treinamento, pode ser justificada pelas configurações de treinamento em que cada uma foi submetida, visto que, os intervalos das amostras de treinamento podem alterar esses resultados. Principalmente, quando os treinamentos são realizados com amostras em intervalos diferentes ao que se insere nas validações, como foi o caso dos testes realizados nessa pesquisa.

Conforme pode ser visto na Tabela 17, na maioria das validações, o estado de Pernambuco apresentou maiores índices de potência elétrica prevista, se comparado ao obtido

para o estado do Rio Grande do Sul, isso pode ser justificado pelas condições climáticas de cada região, que foram inseridas no processo de validação, e dessa forma, poderá influenciar diretamente nos resultados.

As potências médias geradas pelo SFCR em Mossoró variam, para os dias selecionados, em torno de 1,3kW a 1,6kW, esses valores são superiores aos obtidos nas validações do estados do RS e PE, com isso, acredita-se que os baixos valores podem ser justificados por alguma falha de treinamento da rede, bem como pelas condições climáticas que são diferentes, e conseqüentemente a geração de potência também será influenciada, principalmente pela temperatura e irradiação que foram as variáveis utilizadas para validar tais resultados.

Na Tabela 18 são mostradas as informações climáticas, das localidades estudadas nessa pesquisa, apresentando os valores médios de irradiação e temperatura para cada um dos dias estudados.

Tabela 18 – Informações climáticas médias de Mossoró, RS e PE

Período	Mossoró-RN		Recife-PE		Porto Alegre-RS	
	Temperatura (°C)	Irradiação (W/m ²)	Temperatura (°C)	Irradiação (W/m ²)	Temperatura (°C)	Irradiação (W/m ²)
01/10/2017	28,46	624,41	21,91	480,05	28,52	469,66
12/11/2017	29,08	623,69	17,26	478,99	29,09	373,56
08/12/2017	29,57	535,36	22,39	408,79	30,3	429,14
Semana	28,79	569,64	18,43	374,4	28,38	439,4

Fonte: Com base nos dados da estação meteorológica e do *site Wunder ground*.

As informações contidas na Tabela 18 abordam os valores médios de temperatura e irradiação nos períodos estudados de cada uma das localidades, com isso, observa-se que, conforme esperado, as informações climáticas do Nordeste possuem índices mais elevados, e no geral as temperaturas de Mossoró e de Pernambuco se mostram bastante próximas, entretanto a irradiação da cidade de Mossoró se sobressai com índices mais elevados em todo o período utilizado nas validações.

Além de serem abordadas nas curvas das Figura 46, Figura 47 e Figura 48, essas análises abordando a quantização da potência prevista é importante, pois não importa se as potências foram geradas nos mesmos instantes de tempo, o que será relevante para determinar a viabilidade da instalação em determinada localidade é a potência gerada no final, visto que, cada localidade possui suas particularidades climáticas.


Levando em consideração que o melhor treinamento observado, considerando os máximos de potência encontrados, foi o do Caso A, serão realizadas comparações com os erros de RMSE% encontrados no decorrer da pesquisa, para projetar o quanto de erros essas potências

previstas possuem. Como não existem valores de potência reais para realizar comparações e obter uma melhor precisão dos resultados, os erros de RMSE% deverão indicar uma margem de erro para mais e para menos da potência média prevista, sendo considerado, nesse caso, apenas os erros de previsão das validações do Caso A, para intervalos de 5 minutos, coincidindo com os intervalos das validações feitas para o RS e PE.

Os erros inseridos no Gráfico 5 são referentes às validações A1.1, A2.1, A3.1 e A4.1, onde os RMSE% aplicados nessa análise foram retirados das Tabela 9, Tabela 11,

Tabela 13, e Tabela 15. Vale lembrar, que essa análise leva em consideração apenas os erros de previsão, ou seja, os erros da própria RNA em prever os resultados. Sendo essa, a única influência de erro sobre os valores previstos com as validações, que será levada em consideração para gerar esse gráfico.

Gráfico 5 – Potência prevista média com RMSE% para as validações dos estados (ABC9)



Fonte: Autoria Própria.

De acordo com o Gráfico 5, as potências médias prevista variam em torno de 19% para os dias 01/10/17 e 12/11/17 de ambos os estados, já para o dia 08/12/17 e para a semana de 01 a 07 de outubro de 2017, as potências médias possuem uma variação de 25% nos dois estados. Levando esses valores para Watt, a maior variação de potência média encontrada foi de aproximadamente 320W para mais ou para menos, referente a semana em PE (barra com linhas horizontais do Gráfico 5), sendo esse um valor considerado baixo, frente a geração total que o sistema pode produzir.

Desta forma, com a previsão de geração de potência dos SFCRs, pode-se ter um maior planejamento para a instalação desses sistemas, sem prejudicar seu desempenho e assim, obter sua produção máxima em cada região.

Visando enriquecer a pesquisa e tentar melhorar os resultados obtidos, foram realizados treinamentos utilizando a rede NARX com as mesmas validações realizadas na rede *feedforward*, essas informações serão abordadas na seção 4.2.

4.2 Implementação com a rede NARX (Com realimentação)

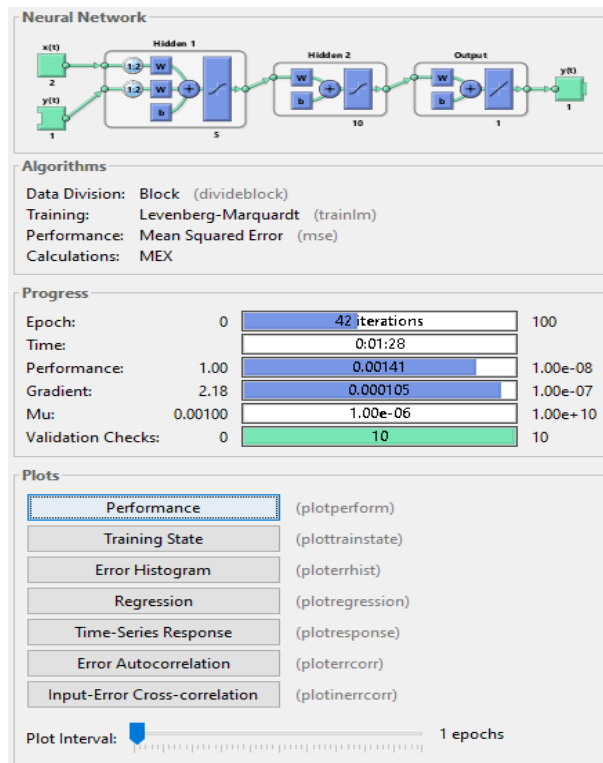
A ideia inicial dessa seção era abordar três treinamentos, cada um realizado com um intervalo de amostras diferentes, conforme feito para rede *feedforward*, no entanto, a rede NARX apresentou um baixo desempenho em generalizar resultados com uma quantidade reduzida de amostras, sendo então reduzidos o número de testes, visto que, os resultados omitidos não iriam agregar valor à pesquisa, tornando-se repetitivos. Desta forma, as validações em destaque na Tabela 3 e Tabela 6 do Capítulo 3 não serão apresentadas no Capítulo 4, logo, será apresentado um treinamento (Caso D) e 11 validações, abordadas no conjunto de validações D, D1, D4 e D9, os resultados das validações D2 e D3 não serão abordados.

4.2.1 Caso D: Treinamento com dados no período limpo em intervalos de 5 minutos.

O treinamento do Caso D foi realizado com amostras em intervalos de 5 minutos do período limpo, sendo o total de dados utilizados de 24068 amostras. Os parâmetros determinados para esse treinamento podem ser visto na Figura 49 com a janela de treinamento. Nota-se na janela de treinamento a configuração final da rede, com atrasos na entrada e na realimentação, sendo essa a principal diferença com a rede *feedforward*.

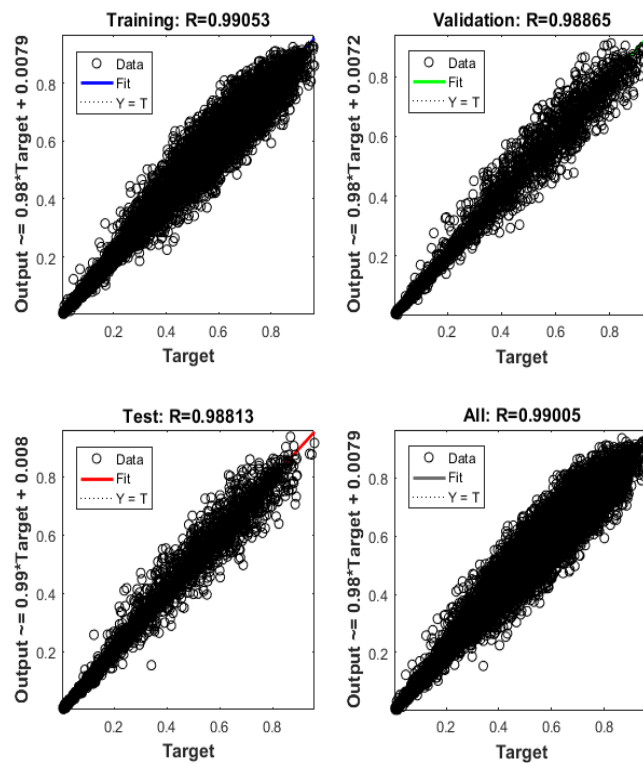
Dentre as configurações que podem ser vistas ao final do treinamento, tem-se o número de iterações, que foram 42, sendo determinada inicialmente um número de 100 épocas como critério de parada, no entanto, a rede convergiu antes de atingir tal valor, pois o número de checagens de validação, também utilizado como critério de parada, se sobressaiu, sendo atingido mais rapidamente, e o tempo necessário para essa convergência foi de 1 minuto e 28 segundos. Para analisar o desempenho desse treinamento tem-se na Figura 50 e Figura 51 as regressões e o diagrama de performance.

Figura 49 – Janela de treinamento do Caso D



Fonte: Autoria Própria.


Figura 50 – Regressões do Caso D



Fonte: Autoria Própria.

Conforme visto na Figura 50, os coeficientes de correlação apresentam valores muito próximos de 1, em que o menor valor encontrado foi para a etapa de teste com $R=0,98813$. Em conjunto com os coeficientes, tem-se a distribuição dos dados, onde nota-se que mesmo inserindo uma elevada quantidade de amostras no treinamento, não houve, grandes desvios desses resultados, ou seja, os valores previstos se aproximam muito bem do real, indicando assim um bom desempenho do treinamento realizado com a rede NARX,

Conforme apresentado na Figura 51, as curvas de convergência de treinamento, validação e teste estão sobrepostas, e o treinamento termina após o erro não obter um aumento por dez iterações consecutivas e o melhor desempenho é obtido na época 32 com o menor erro de validação alcançado, de 0,0015958.




Fonte: Autoria Própria.

4.2.2 Validações realizadas para o caso proposto da rede NARX

Nessa seção serão abordadas as validações realizadas com o treinamento descrito anteriormente (Caso D), em que se utilizou amostras em intervalos de 5 minutos para treiná-lo. Serão realizadas sete validações, uma para as amostras de 20% do treinamento com intervalos de 5 minutos, três para o dia 01/10/2017 variando o intervalo das amostras em 5 minutos, 10 minutos e 1 hora, e as demais para a semana de 01 a 07 de outubro de 2017, que foram validadas também em intervalos de 5 minutos, 10 minutos e 1 hora.

4.2.2.1 Validação D - 20% das amostras de treinamento


Nessa implementação utilizou-se como variáveis de entrada, 20% dos dados que foram inseridos no treinamento, totalizando 4814 amostras. Para esse teste, a Validação D foi realizada com a rede em *openloop*, desta forma, a variável de saída (potência do SFCR) também foi inserida durante o processo de validação, ou seja, os dados que se desejava obter foram inseridos na validação da rede, não atingindo o objetivo principal, que seria a rede prever os dados de saída apenas com a inserção de variáveis de entrada. Com essa situação, foi possível perceber que a os resultados se mostram favoráveis, como poder visto na Figura 52, em que a curva prevista pela rede acompanha muito bem a curva de saída real.



Fonte: Autoria Própria.

Analisando melhor esse desempenho tem-se os gráficos de regressão apresentados na Figura 53, nela é possível identificar a precisão da previsão realizada com a situação descrita anteriormente. Com um coeficiente de correlação de 0,96951 e uma boa distribuição dos dados sobre a reta alvo, comprova o que se era esperado, visto que a saída dessa validação foi dada pelo usuário.

Figura 53 – Regressão da Validação D



Fonte: Autoria Própria.

A Tabela 19 comprova ainda mais essa precisão da Validação D, com erros baixos, inclusive o RMSE%, que indica um erro de previsão de aproximadamente 14% entre as curvas dispostas na Figura 52.

Tabela 19 – Erros do conjunto de Validação D

Período das amostras	EM	MAE	MSE	RMSE	EM (%)	RMSE (%)
20% das amostras	-0,0003	0,0488	0,0046	0,0677	-0,0666	14,94

Fonte: Autoria Própria.

Os parâmetros de desempenho que foram abordados para a Validação D, todos apresentaram um bom desempenho, no entanto, a rede neural não realizou as previsões de forma independente ao utilizar o comando *openloop*, pois a rede necessitou que fossem inseridos também dados de saída, que ela deveria prever sozinha.

Essa validação serviu para mostrar a necessidade de se utilizar o comando *closeloop* quando for realizada implementações com a rede NARX. Esse comando possibilita que a rede gere a própria saída, a partir dos dados de entrada, e realmente a entrada com esses dados, trabalhando em malha fechada. Com isso, a rede neural não faz uso de saídas externas, pois a mesma, gera a própria saída. Diante disso, as próximas validações serão realizadas em malha fechada, fazendo uso do comando *closeloop*.

4.2.2.2 Conjunto de Validação D1 - Dia 01 de outubro de 2017

Para o conjunto de validações D1 utilizou-se amostras do dia 01/10/2017, com três intervalos diferentes, conforme mostra o esquema da Figura 54. Todas as validações foram implementadas no treinamento do Caso D e validadas em malha fechada, através do comando *closeloop*.


Figura 54 – Esquema do conjunto de Validação D1



Fonte: Autoria Própria.

Os resultados gráficos dessas validações podem ser vistos na Figura 55. A primeira validação, realizada com intervalos de 5 minutos, mostra uma boa aproximação entre as curvas previstas pela RNA e a saída real. No entanto, a partir da segunda validação, a curva prevista pela RNA começa a mostrar certa discrepância da curva de saída real, e na terceira validação, as curvas apresentam uma diferença extrema de resultados.


Figura 55 – Comparação Previsto x Real do conjunto de Validação D1



Fonte: Autoria Própria.

Nota-se, portanto, que as validações que foram realizadas com um menor número de amostras, não obtiveram um bom desempenho, ou seja, a medida que as amostras utilizadas para as validações vão sendo reduzidas, a rede NARX vai perdendo a capacidade de prever resultados coerentes com a saída esperada.

Esse fato pode ser notado nos gráficos de regressão apresentados na Figura 56, onde os coeficientes de correlação vão se distanciando do valor 1, de acordo com as validações que apresentam intervalos mais espaçados, isso também ocorre com a dispersão dos dados, que apresentam um maior desvio entre os dados previstos e os reais.



Fonte: Autoria Própria.

Uma análise quantitativa a respeito dessas validações pode ser vista na Tabela 20, com resultados que reafirmam os resultados gráficos anteriores, apresentando erros proporcionais aos intervalos das validações. Com destaque para o RMSE% da Validação D1.3, que apresentou um erro de previsão de 44%, sendo esse o maior erro encontrado dentre todas as validações realizadas nessa pesquisa. Os demais RMSE% encontrados foram de 21% e 26% para as validações D1.1 e D1.2 respectivamente.

Tabela 20 – Erros do conjunto de Validação D1

Validação	Período das amostras	EM	MAE	MSE	RMSE	EM (%)	RMSE (%)
D1.1	01/10/2017 - 5min	-0,0089	0,0819	0,0149	0,1222	-1,5446	21,36
D1.2	01/10/2017 - 10min	-0,0228	0,1322	0,0238	0,1542	-3,9803	26,92
D1.3	01/10/2017 - 1 hora	0,1162	0,2023	0,0564	0,2375	21,8434	44,65

Fonte: Autoria Própria.

As potências acumuladas e médias dessas validações são apresentadas na Tabela 21, onde nota-se que para as validações D1.1 e D1.2 a diferença entre a potência real e a prevista apresentou valores negativos, o que implica em uma potência prevista superior ao valor real, isso pode ser justificado pelos picos ocasionados na potência prevista, conforme visto nas curvas dessas validações na Figura 55, em que esses picos superaram as curvas reais. A maior diferença encontrada entre as potências acumuladas foi para a Validação D1.3, destacada em vermelho na Tabela 21, com uma diferença de aproximadamente 4kW.


Tabela 21 – Potências do conjunto de Validação D1

Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
D1.1	01/10/2017 - 5min	233,42	237,03	-3,61	1,667	1,693
D1.2	01/10/2017 - 10min	116,83	121,48	-4,65	1,669	1,735
D1.3	01/10/2017 - 1 hora	18,59	14,53	4,06	1,549	1,211

Fonte: Autoria Própria.

As potências previstas médias encontradas para as validações D1.1 e D1.2 foram todas acima das potências médias reais, no entanto, a Validação D1.3 apresentou a maior diferença entre as potências médias reais e potências médias previstas de todas as validações que foram realizadas nessa pesquisa, sendo esse o valor que mais se distanciou do valor real. Essas diferenças podem ser melhor exemplificadas no Gráfico 6.

Gráfico 6 – Comparação entre as potências médias do conjunto de Validação D1




Fonte: Autoria Própria.

4.2.2.3 Conjunto de Validação D4 - Semana de 01 a 07 de outubro de 2017

A Validação D4 contou com amostras da semana de 01 a 07 de outubro de 2017, onde realizou-se validações variando as amostras em três intervalos distintos, conforme é apresentado no esquema da Figura 57. Essas validações foram realizadas no treinamento do Caso D, onde o mesmo foi treinado com amostras em intervalos de 5 min.

Figura 57 – Esquema do conjunto de Validação D4




Fonte: Autoria Própria.

Os resultados obtidos a partir dessas validações podem ser vistos na Figura 58, onde nota-se que para a Validação D4, ocorre o mesmo observado na Validação D1, em que quanto menor a quantidade de amostras são utilizadas nas validações, pior será a generalização da rede NARX. Na Validação D4.3 fica evidente essa observação, visto que, a curva de previsão da RNA apresenta uma grande discrepância em relação a curva de saída real. As demais curvas apresentam apenas falhas da rede em prever as variações existentes ao longo dos dias, fato que

também ocorreu com as previsões da rede *feedforward*, além disso a Validação D4.2 apresenta uma leve defasagem entre as curvas.

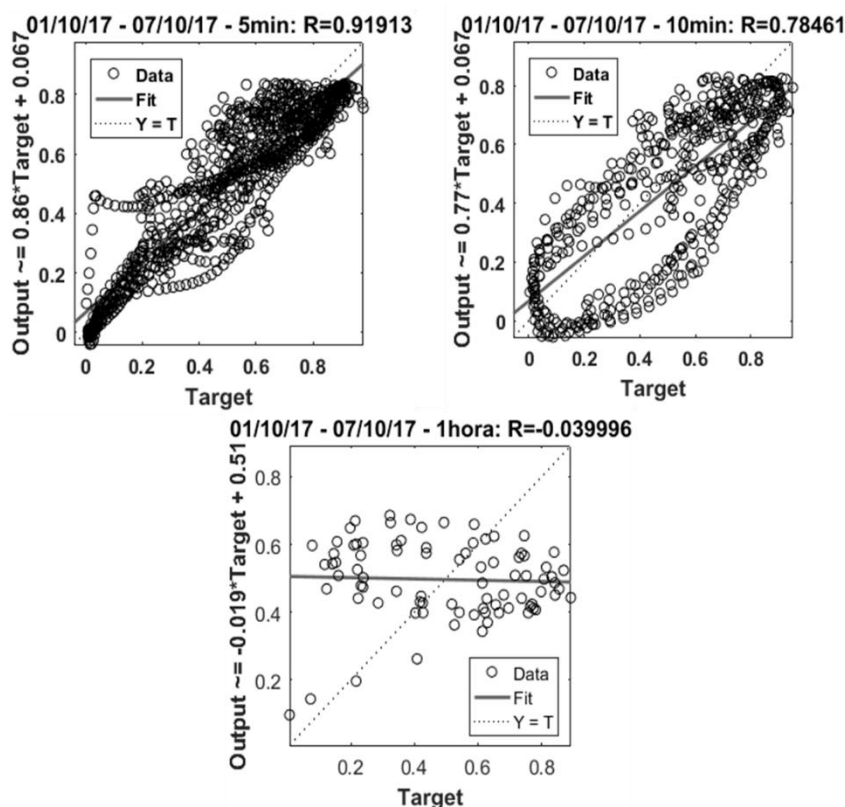
Figura 58 – Comparação Real x Previsto do conjunto de Validação D4



Fonte: Autoria Própria.

Os gráficos de regressão também comprovam tais resultados, apresentando coeficientes de correlação que demonstram nitidamente os desvios existentes entre os dados reais e previstos, principalmente para a Validação D4.3, em que o coeficiente de correlação é um valor muito baixo, caracterizando uma correlação muito fraca entre os dados. A defasagem observada na Validação D4.2 reflete nos resultados do coeficiente de correlação, que apresentou uma redução, se comparado à Validação D4.1. As dispersões dos dados se mostram em concordância com os coeficientes de correlação, com elevados desvios entre os dados previstos e reais, a medida que o coeficiente diminui, na Figura 59 é possível observar tais resultados.

Figura 59 – Regressão do conjunto de Validação D4



Fonte: Autoria Própria.

Os erros calculados para essa validação demonstram coerência com os métodos de análise anteriores, em que apresentam valores maiores à medida que os espaçamentos dos intervalos aumentam, com exceção dos EM e EM% que além de resultar em valores negativos ainda são bem inferiores ao obtidos nas demais validações. Nota-se ainda que o RMSE% máximo obtido foi de 54%, para a Validação D4.3, e o mínimo com 21% para a Validação D4.1, essas informações podem ser vistas na Tabela 22.

Tabela 22 – Erros do conjunto de Validação D4

Validação	Período das amostras	EM	MAE	MSE	RMSE	EM (%)	RMSE (%)
D4.1	Semana - 5min	0,0069	0,0835	0,0119	0,1089	1,3495	21,27
D4.2	Semana - 10min	0,0538	0,1547	0,0345	0,1856	10,4448	36,02
D4.3	Semana - 1 hora	-0,0006	0,2363	0,0735	0,2712	-0,1231	54,66

Fonte: Autoria Própria.

De acordo com as potências obtidas e mostradas na Tabela 23 é possível observar que a potência acumulada obtida para o período em questão, apresenta uma significativa diferença entre a potência prevista acumulada e potência real acumulada, com 76kW na Validação D4.2 destacada em vermelho. Na Validação D4.1 tem-se a menor potência acumulada positiva, visto

que a Validação D4.3 apresenta um valor negativo, implicando em uma potência acumulada prevista superior a potência acumulada real.

Tabela 23 – Potências do conjunto de Validação D4


Validação	Período das amostras	Real (kW)	Prevista (kW)	Real x Prevista (kW)	Real Média (kW)	Prevista Média (kW)
D4.1	01/10/2017 - 5min	1459,97	1440,30	19,67	1,491	1,471
D4.2	01/10/2017 - 10min	734,21	657,55	76,67	1,501	1,345
D4.3	01/10/2017 - 1 hora	121,41	121,56	-0,15	1,445	1,447

Fonte: Autoria Própria.

Apesar dos resultados previstos estarem muito próximos dos reais, é importante destacar que graficamente esses resultados não se mostram satisfatórios, uma vez que, conforme as curvas da Figura 58, as curvas previstas se mantiveram na mesma faixa de valores, sem acompanhar as variações reais da potência gerada, sendo, portanto, o somatório e a média influenciados, de forma a gerar valores elevados e distante de como realmente se comporta a geração de potência.

Os comportamentos das potência médias podem ser melhor observados no Gráfico 7, apresentando dados tendenciosos, que aproximam a potência média prevista da real (Validação D4.1 e D4.3) sem conformidade com as curvas geradas, e isso se deve, sobretudo, ao fato de que os valores médios indicam para onde se concentram os dados de uma distribuição, e desta forma, influenciou diretamente os resultados finais dessas validações.

Gráfico 7 – Comparação entre as potências médias do conjunto de Validação D4



Fonte: Autoria Própria.

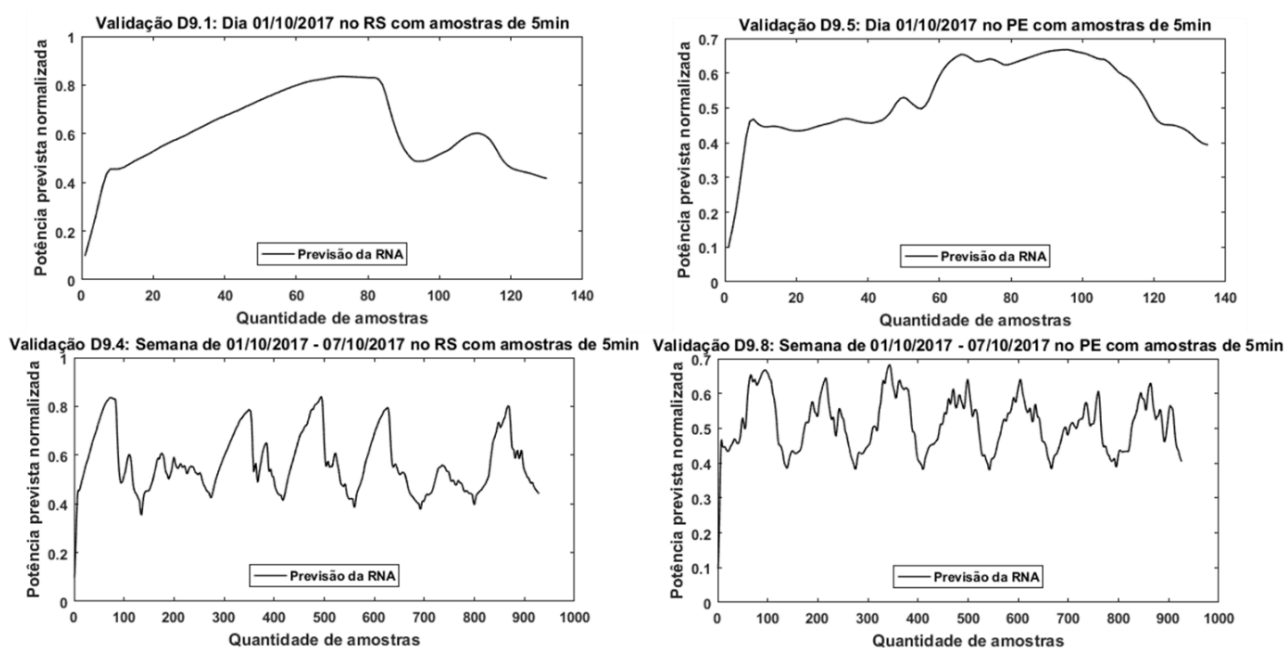
4.2.2.4 Conjunto de Validação D9 - Para outras regiões

Mesmo a rede NARX não apresentando resultados satisfatórios para as validações em intervalos de 1 horas, foram realizadas validações para prever a potência gerada do SFCR de 3kWp nos estados do Rio Grande do Sul e Pernambuco. As validações foram realizadas com intervalos de 5 minutos, sendo este, o intervalo utilizado nas validações anteriores que resultaram nos melhores desempenhos dessa rede.

As validações foram realizadas para o dia 01/10/2017 e para a semana compreendida de 01 a 07 de outubro de 2017, e os resultados obtidos podem ser vistos na Figura 60. A primeira coluna mostra os resultados das Validações D9.1 e D9.4 para o RS, as curvas apresentam uma certa tendência em seguir a curva genérica de geração de potência, no entanto, nota-se que para a Validação D9.4 as curvas permaneceram em uma faixa de valores que não condiz com o comportamento real, além disso, elas possuem uma amplitude baixa entre 0,4 e 0,8. O mesmo é observado para as validações de PE, entretanto, as curvas da Validação D9.8 possuem amplitudes mais reduzidas, na faixa de 0,4 a 0,6.

Analisando apenas graficamente não se pode concluir se as previsões apresentadas possuem concordância com a realidade, para isso, se faz necessário mostrar dados quantitativos que enfatize o desempenho alcançado, sendo elaborada a Tabela 24 para tal objetivo.

Figura 60 – Curvas resultantes do conjunto de Validação D9



Fonte: Autoria Própria.

Na Tabela 24 tem-se as potências acumuladas e as médias das validações apresentadas, sendo possível observar que mais uma vez as curvas são tendenciosas, de forma que, os resultados obtidos não condiz com o esperado, sendo nítida a influência que essas curvas provocam por se manterem em uma faixa de valores elevadas, sem apresentar as variações reais que a geração de potência possui. Com isso, são obtidos valores elevados, mesmo com curvas que não possuem um bom desempenho.

Tabela 24 – Potências previstas dos estados por treinamento

Período das amostras	Caso D	
	Acumulada (kW)	Prevista Média (kW)
RS 01/10/17	230,33	1,772
PE 01/10/17	207,08	1,534
RS semana	1537,17	1,655
PE semana	1382,25	1,493


Fonte: Autoria Própria.

Vale lembrar que além das falhas da rede neural, existem também as influências climáticas, conforme foi abordado em detalhes na seção 4.1.1.6.

De maneira análoga ao que foi abordado com as Validações ABC9 da seção 4.1.1.6, serão feitas comparações entre os resultados obtidos com as Validações D9 e os RMSE% obtidos com as Validações D1 e D4, criando um cenário em que esses seriam os erros de previsão do conjunto de Validações D9, levando em consideração apenas os erros ocasionados pela própria rede neural.

Diante disso, o Gráfico 8 indica a potência média gerada nos estados de acordo com cada períodos estipulado, onde as quatro validações propostas resultou em uma margem de erro de previsão, que varia em torno de 21% para mais ou para menos. A maior variação encontrada foi para o estado do RS no dia 01/10/2017 com 372W, essa observação é referente a barra na cor cinza escuro do Gráfico 8.

Gráfico 8 – Potência prevista média com RMSE% para as validações dos estados (D9)



Fonte: Autoria Própria.

Essa máxima variação encontrada é superior ao que foi detectado na comparação com a rede *feedforward*, no entanto, as porcentagens do erro para as validações semanais se mostram inferiores.

De maneira geral, a rede NARX apresentou bons resultados apenas quando validadas com amostras em intervalos pequenos, ao inserir amostras com intervalos mais espaçados a rede não generaliza os dados de maneira coerente. Vele salientar, que mesmo apresentando resultados quantitativos próximos dos reais, graficamente os resultados apresentam curvas com distribuição tendenciosa, gerando sempre valores elevados, não sendo interessante para a pesquisa, pois os dados são imprecisos.

O baixo desempenho da rede NARX nessa aplicação pode ser justificado pela forma de trabalho da mesma, em que ela é realimentada por uma estimativa, ou seja, por um erro, e isso faz com que a rede não resulte em resultados satisfatórios, conforme foi apresentado na pesquisa.

5 CONCLUSÃO

Prever a produção de energia de fontes com elevada intermitência é uma tarefa difícil, pois requer métodos que se adequem às diversas variações climáticas que possam surgir. Essas variações não seguem padrões predefinidos e isso reduz ainda mais as opções de métodos disponíveis. Diante disso, a RNA se mostrou como um método eficiente e viável para realizar tais previsões.

Para isso, foram realizados diversos treinamentos e validações em intervalos diferentes, com o intuito de reduzir a dispersão dos dados, visto que esta ação diminui a quantidade de amostras, testando assim, sua eficiência para qualquer intervalo de amostras que se tenha disponível. Essas validações serviram para analisar o desempenho das redes, comparando os resultados previstos com os reais, dando uma maior confiabilidade ao método, para posteriormente ser aplicado na previsão da potência elétrica gerada pelo SFCR de 3kWp instalado em outras regiões.

Com as validações realizadas para a rede *feedforward*, os resultados não apresentaram grandes variações entre os diferentes treinamentos implementados, contendo RMSE% na mesma faixa de valores, entre 13% e 28% e coeficientes de correlação de 0,86-0,99. O mesmo aconteceu comparando-se as validações com intervalos distintos, onde a rede não apresentou respostas discrepantes entre elas, mesmo para validações com intervalos mais espaçados, onde o menor RMSE% encontrado foi de 13,57% e o maior coeficiente de correlação com $R = 0,99$ para a Validação C1.3, sendo ela treinada e validada com amostras em intervalos de 1 hora.

Em contrapartida, para a rede NARX com validações em malha fechada, quanto mais espaçadas as amostras, maior foi o erro de previsão obtido, alcançando um RMSE% de até 54%, sendo também o menor coeficiente de correlação encontrado com -0,039, fatos ocorridos para a Validação D4.3, que foi treinada com amostras de 5 minutos e validada com intervalos de 1 hora. No entanto, para as validações em intervalos de 5 minutos, a rede NARX apresentou resultados parecidos com a *feedforward*, gerando um RMSE% na mesma faixa de valores, em torno de 21%, porém com R mais reduzidos, entre 0,78 e 0,93.

Quando submetidas às previsões de potência, as duas redes apresentaram resultados quantitativos semelhantes de potência acumulada e média, no entanto, as curvas de previsão possuem diferenças nítidas, onde as curvas originadas da rede NARX possuem a distribuição dos dados em uma faixa de valores elevados, influenciando nos resultados finais de potência. Já para a rede *feedforward*, as curvas são mais próximas da realidade, principalmente para a previsão do estado de Pernambuco.

Portanto, de maneira geral, a rede *feedforward* apresentou um comportamento melhor do que a rede NARX para essa aplicação. Mesmo a rede *feedforward* não acompanhando as curvas com grande eficiência para os dias que apresentam variações na geração de potência, como pôde ser visto em algumas curvas, isso não foi refletido com expressividade nos resultados quantitativos, apresentando RMSE% e R que demonstram um melhor desempenho dessa rede, além disso elas são capazes de generalizar resultados para amostras em diferentes intervalos, oferecendo mais opções na inserção de variáveis de entradas e aumentando assim as possibilidades de se utilizar RNAs para previsão da produção de potência dos SFCR.

Ao analisar os resultados obtidos, nota-se que a proposta em prever a potência elétrica em outras regiões com a utilização de RNAs é algo viável, uma vez que, para os estados do Rio Grande do Sul e Pernambuco essas análises apresentaram bons resultados, com erros de previsão de no máximo 25% utilizando a rede *feedforward*. Desta forma, seria viável a instalação do SFCR de 3kWp em ambos os estados, de acordo com a RNA e as variáveis climáticas que foram utilizadas.

Diante das análises realizadas, sugere-se como trabalhos futuros para o aperfeiçoamento da aplicação proposta nessa pesquisa, a inserção de variáveis de entrada adicionais na RNA que influenciem na geração de potência dos SFVs, bem como configurações diferentes dos parâmetros da RNA, de modo a obter uma maior precisão nas previsões. Essas previsões podem ainda se estender para outras localidades, dando uma maior confiabilidade ao método

Outra sugestão, seria a aplicação do método para a previsão de geração de potência de outras fontes em diferentes localidades, como dos sistemas eólicos, visto que o mesmo, apresenta forte influência das variações climáticas, sobretudo, da incidência do vento.

REFERÊNCIAS

ÁLVAREZ, Ângela P. P. **Previsão do preço spot do Mercado Majoritário Boliviano Utilizando Redes Neurais Artificiais**. 2015. 88 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Unesp, Ilha Solteira, 2015. Disponível em: <<https://repositorio.unesp.br/handle/11449/145480>>. Acesso em: 25 jan. 2019.

ANEEL, Agência Nacional de Energia Elétrica. **Geração Distribuída - Micro e Minigeração Distribuídas**. 2015a. Disponível em: <http://www.aneel.gov.br/informacoes-tecnicas/-/asset_publisher/CegkWaVJWF5E/content/geracao-distribuida-introducao/1/656827?inheritRedirect=false>. Acesso em: 08 nov. 2017.

_____. **Resolução Normativa nº 687**. Brasília: ANEEL, 2015b. 26p. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2015687.pdf>> 09 nov. 2017.

_____. **BIG - Banco de Informações de Geração**. 2018.

BALLINI, Rosangela. **Análise e previsão de vazão utilizando modelos de séries temporais, redes neurais e redes neurais nebulosas**. 2000. 183 f. Tese (Doutorado) - Curso de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2000. Disponível em: <<http://repositorio.unicamp.br/handle/REPOSIP/260553>>. Acesso em: 10 nov. 2017.

BARBOSA, Anderson Henrique; FREITAS, Marcílio Sousa da Rocha; NEVES, Francisco de Assis das. **Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais**. Rem: Revista Escola de Minas, [s.l.], v. 58, n. 3, p.247-255, set. 2005. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0370-44672005000300011>. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0370-44672005000300011>. Acesso em: 12 nov. 2017.

BATISTA, André Luiz França. **Modelo de séries temporais e redes neurais artificiais na previsão de vazão**. 2009. 89 f. Dissertação (Mestrado) - Curso de Pós-graduação em Engenharia de Sistemas, Universidade Federal de Lavras, Minas Gerais, 2009. Disponível em: <<http://www.prpg.ufla.br/esistemas/wp-content/uploads/2012/08/7-Andre-Luis-Franca-Batista-Dissertacao.pdf>>. Acesso em: 12 nov. 2017.

CASILLO, Leonardo Augusto; VALE, Marcelo Roberto Bastos Guerra. **Aprendizado de máquina: RNA**. Mossoró. 2017. 84 slides, color, 25x20.

COSTA, Sara Domingues. **Deteção de Defeitos em Células e Módulos Fotovoltaicos por Medidas de Termografia**. 2015. 91 f. Dissertação (Mestrado) - Curso de Engenharia da Energia e do Ambiente, Universidade de Lisboa, Lisboa, 2015. Disponível em: <<http://repositorio.ul.pt/handle/10451/22426>>. Acesso em: 06 dez. 2017.

CRESESB, Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Brito. **Manual de engenharia para sistemas fotovoltaicos**. Rio de Janeiro, 2004.

_____. **Manual de engenharia para sistemas fotovoltaicos**. Rio de Janeiro, 2014.

Dragoon, k., e Papaefthymiou, G., *Power System Flexibility Strategy Roadmap: Preparing power systems to supply reliable power from variable energy resources*, 2015. Disponível em: <https://www.researchgate.net/publication/282012266_Power_System_Flexibility_Strategic_Roadmap>. Acesso em 24 de jan. 2019.

_____. **Balanco Energético Nacional 2018, Relatório Síntese ano base 2017**. Rio de Janeiro, 2018. Disponível em: <<http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-303/topico-397/Relat%C3%B3rio%20S%C3%ADntese%202018-ab%202017vff.pdf>> Acesso em: 31 jan. 2019.

FERNANDES, José Dário Pereira. **Previsão de produção de energia elétrica a partir do vento**. 2014. 118 f. Dissertação (Mestrado) - Curso de Engenharia Informática, Universidade da Madeira, Portugal, 2014. Disponível em: <https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&cad=rja&uact=8&ved=0ahUKEwjC1f305cXWAhXIVJAKHTJpDzAQFggnMAA&url=http://digituma.uma.pt/bitstream/10400.13/548/1/MestradoD%C3%A1rioFernandes.pdf&usq=AFQjCNGo-yJ7Ojo6s3dt9YhVxI_Sb2_PoA>. Acesso em: 27 set. 2017.

GUARNIERI, Ricardo André. **Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no refinamento das previsões de radiação solar do modelo ETA**. 2006. 171 f. Dissertação (Mestrado) - Curso de Pós-graduação em Meteorologia, Inpe, São José dos Campos, 2006. Disponível em: <http://ftp.cptec.inpe.br/labren/publ/teses/DISSERTACAO_RICARDO-GUARNIERI.pdf>. Acesso em: 22 jan. 2019.

HAYKIN, Simon. **Redes Neurais: Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

INPE, Instituto Nacional de Pesquisas Espaciais. **Atlas Brasileiro de Energia Solar**. 2. ed. São José dos Campos, 2017. 80 p.

Jumaat, S. A. B; Crocker, F; Abd Wahab, M. H; Mohammad Radzi, N. H. B. *Investigate the photovoltaic (PV) module performance using Artificial Neural Network (ANN)*, 2016 IEEE Conference on Open Systems (ICOS), Langkawi, 2016, pp. 59-64.

KAYRI, Ismail; GENCOGLU, Muhsin Tunay. *Prediction of power production from a single axis photovoltaic system by Artificial Neural Networks*. In: International Conference on Engineering of Modern Electric Systems (EMES), 14., 2017, Romênia. **Conferência. Romênia**: IEEE, 2017. p. 212 - 215. Disponível em: <<http://ieeexplore.ieee.org/document/7980417/>>. Acesso em: 01 dez. 2017.

LEE, Y., OH, S e KIM, M. (1991). *The effect of initial weights on premature saturation in back-propagation learning*. International Joint Conference on Neural Networks, Vol. 1, p. 765-770. Disponível em: <<http://ieeexplore.ieee.org/document/155275/>> Acesso em: 12 nov. 2017.

LI, Z. Y., et al. *Short Term Photovoltaic Power Generation Forecasting Using RBF Neural Network*. The 26th Chinese Control and Decision Conference. 2014. Disponível em: <<https://ieeexplore.ieee.org/document/6852641>>. Acesso em: 25 jan. 2019

LOURAKIS, M. A *Brief Description of the Levenberg-Marquardt Algorithm*. Institute of Computer Science. Crete, Greece, 2005. Disponível em: <http://users.ics.forth.gr/~lourakis/publ/2005_levmar.pdf>. Acesso em: 25 jan. 2019.

MATLAB. *Design Time Series NARX Feedback Neural Networks*. 2019a. Disponível em: <<https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>>. Acesso em: 25 jan. 2019

_____. *Fit Data with a Shallow Neural Network*. 2019b. Disponível em: <<https://www.mathworks.com/help/deeplearning/guide/fit-data-with-a-neural-network.html>>. Acesso em: 25 jan. 2019

_____. *Regression*. 2019c. Disponível em: <<https://www.mathworks.com/help/deeplearning/ref/regression.html>>. Acesso em 14 mar. 2019

MARTINS, M. A. S.; METTE, F.; MACEDO, G. R. **A utilização de Redes Neurais Artificiais para a estimação dos preços da Petrobrás PN na Bovespa**. 2008. 16 f. ConTexto - Revista do Programa de Pós-Graduação em Controladoria e Contabilidade da UFRGS. Porto Alegre, 2017. Disponível em: <https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&cad=rja&uact=8&ved=0ahUKEwjny7bl9ovXAhXBG5AKHXVWBOEQFggMAE&url=http%3A%2F%2Fseer.ufrgs.br%2FConTexto%2Farticle%2Fdownload%2F11090%2Fpdf_5&usq=AOvVaw0yrE35fxuplW30y83P8K7O>. Acesso em: 25 out. 2017.

MEDEIROS, Romero Álamo Oliveira de. **Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica**. 2016. 86 f. Dissertação (Mestrado) - Curso de Pós-graduação em Engenharia Elétrica, Universidade Federal da Paraíba, João Pessoa, 2016. Disponível em: <<http://tede.biblioteca.ufpb.br/handle/tede/8795>>. Acesso em: 01 nov. 2017.

MEDEIROS, Heitor. **Introdução às Redes Neurais Artificiais**. Natal. 2017. 41 slides, color, 25x20. Disponível em: <https://www.dca.ufrn.br/~heitorm/aulasDCA/dca0121/DCA0121-02-RedesNeurais-Conceitos_v1.0.pdf>. Acesso em: 12 nov. 2017.

MELLIT, Adel; PAVAN, Alessandro Massi. **Performance prediction of 20 kWp grid-connected photovoltaic plant at Trieste (Italy) using artificial neural network**. *Energy Conversion And Management*. v. 51, n. 12, p.2431-2441, maio 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890410001822>>. Acesso em: 01 dez. 2017.

MELLIT, A; SAĞLAM, S; KALOGIROU, S. A. *Artificial neural network-based model for estimating the produced power of a photovoltaic module*. *Renew Energy*, vol. 60, pp. 71–78, 2013.

MORETTIN, P. A; TOLOI, C. M. C. **Análise de Séries Temporais**. 2ª edição - São Paulo: Edgard Blücher, 2006. 564p.

PRINCIPE, J.C.; KUO. J. *Dynamic Modelling of Chaotic Time Series with Neural Networks*.

Advances in Neural Information Processing Systems 7, p. 311-318, 1995. Disponível em <<https://papers.nips.cc/paper/934-dynamic-modelling-of-chaotic-time-series-with-neural-networks.pdf>>. Acesso em: 25 jan. 2019.

RAHMAN, S. e HAZIM, O. (1993). *A Generalized Knowledge-Based Short-Term Load-Forecasting Technique*, IEEE Transactions On Power Systems, Vol. 8, no. 2.

SILVA, Anderson Francisco da. **Previsão da evapotranspiração de referência utilizando redes neurais**. 2002. 68 f. Tese (Doutorado) - Curso de Pós-graduação em Engenharia Agrícola, Universidade Federal de Viçosa, Minas Gerais, 2002. Disponível em: <<http://www.locus.ufv.br/handle/123456789/9459>>. Acesso em: 12 nov. 2017.

SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático**. São Paulo: Artliber, 2010.

SOUZA, Luciane de Fátima Rodrigues de. **Redes Neurais Artificiais na Predição de respostas e Estimação de Derivadas Aerodinâmicas de Aeronaves**. 2007. 167 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Escola de Engenharia de São Carlos, São Carlos, 2007. Disponível em: <http://www.teses.usp.br/teses/disponiveis/18/18135/tde-19012011-113815/publico/tese_Luciane.pdf>. Acesso em: 25 jan. 2019.

TORRES, Rafael Gerzson. **Desenvolvimento de metodologia para avaliação do potencial de utilização de sistemas de energia solar fotovoltaica em meios urbanos**. 2015. 163 f. Dissertação (Mestrado) - Pós-graduação em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/140530>>. Acesso em: 09 nov. 2017.

VILLAMAGNA, Maíra Rodrigues. **Seleção de modelos se séries temporais e redes neurais artificiais na previsão de consumo e demanda de energia elétrica**. 2013. 118 f. Dissertação (Mestrado) - Curso de Pós-graduação em Estatística e Experimentação Agropecuária, Universidade Federal de Lavras, Minas Gerais, 2013. Disponível em: <[http://repositorio.ufla.br/bitstream/1/1117/1/DISSERTAÇÃO_Seleção de modelos de séries temporais e redes neurais artificiais na previsão de consumo e demanda de energia elétrica.pdf](http://repositorio.ufla.br/bitstream/1/1117/1/DISSERTAÇÃO_Seleção%20de%20modelos%20de%20séries%20temporais%20e%20redes%20neurais%20artificiais%20na%20previsão%20de%20consumo%20e%20demanda%20de%20energia%20elétrica.pdf)>. Acesso em: 12 nov. 2017.

ANEXO A – LEGENDAS DAS NOMENCLATURAS UTILIZADAS NA PESQUISA

NOMENCLATURA	LEGENDA
Caso A	Treinamento realizado com amostras em intervalos de 5 minutos para a rede <i>feedforward</i>
Caso B	Treinamento realizado com amostras em intervalos de 10 minutos para a rede <i>feedforward</i>
Caso C	Treinamento realizado com amostras em intervalos de 1 hora para a rede <i>feedforward</i>
Caso D	Treinamento realizado com amostras em intervalos de 5 minutos para a rede NARX
ABC1	Conjunto de validações realizadas para o dia 01/10/2017 para os Casos A, B e C (Equivale às validações A1, B1 e C1)
ABC2	Conjunto de validações realizadas para o dia 12/11/2017 para os Casos A, B e C (Equivale às validações A2, B2 e C2)
ABC3	Conjunto de validações realizadas para o dia 08/12/2017 para os Casos A, B e C (Equivale às validações A3, B3 e C3)
ABC4	Conjunto de validações realizadas para a semana de 01-07/10/2017 para os Casos A, B e C (Equivale às validações A4, B4 e C4)
ABC9	Conjunto de validações realizadas para a semana de 01-07/10/2017 para os Casos A, B e C (Equivale às validações A9, B9 e C9)
A	Validação com 20% das amostras de treinamento do Caso A
B	Validação com 20% das amostras de treinamento do Caso B
C	Validação com 20% das amostras de treinamento do Caso C
D	Validação com 20% das amostras de treinamento do Caso D
A1	Conjunto de validações para o dia 01/10/2017 em intervalos de 5min (A1.1), 10min(A1.2) e 1hora (A1.3) do treinamento do Caso A
B1	Conjunto de validações para o dia 01/10/2017 em intervalos de 5min (B1.1), 10min (B1.2) e 1hora (B1.3) do treinamento do Caso B
C1	Conjunto de validações para o dia 01/10/2017 em intervalos de 5min (C1.1), 10min (C1.2) e 1hora (C1.3) do treinamento do Caso C
D1	Conjunto de validações para o dia 01/10/2017 em intervalos de 5min (D1.1), 10min(D1.2) e 1hora (D1.3) do treinamento do Caso D
A2	Conjunto de validações para o dia 12/11/2017 em intervalos de 5min (A2.1), 10min (A2.2) e 1hora (A2.1) do treinamento do Caso A
B2	Conjunto de validações para o dia 12/11/2017 em intervalos de 5min (B2.1), 10min (B2.2) e 1hora (B2.1) do treinamento do Caso B
C2	Conjunto de validações para o dia 12/11/2017 em intervalos de 5min (C2.1), 10min (C2.2) e 1hora (C2.1) do treinamento do Caso C
D2	Conjunto de validações para o dia 12/11/2017 em intervalos de 5min (D2.1), 10min(D2.2) e 1hora (D2.3) do treinamento do Caso D
A3	Conjunto de validações para o dia 08/12/2017 em intervalos de 5min (A3.1), 10min (A3.2) e 1hora (A3.1) do treinamento do Caso A
B3	Conjunto de validações para o dia 08/12/2017 em intervalos de 5min (B3.1), 10min (B3.2) e 1hora (B3.1) do treinamento do Caso B
C3	Conjunto de validações para o dia 08/12/2017 em intervalos de 5min (C3.1), 10min (C3.2) e 1hora (C3.1) do treinamento do Caso C
D3	Conjunto de validações para o dia 08/12/2017 em intervalos de 5min (D3.1), 10min(D3.2) e 1hora (D3.3) do treinamento do Caso D

NOMENCLATURA	LEGENDA
A4	Conjunto de validações para a semana 01-07/10/2017 em intervalos de 5min (A4.1), 10min (A4.2) e 1hora (A4.1) do treinamento do Caso A
B4	Conjunto de validações para a semana 01-07/10/2017 em intervalos de 5min (B4.1), 10min (B4.2) e 1hora (B4.1) do treinamento do Caso B
C4	Conjunto de validações para a semana 01-07/10/2017 em intervalos de 5min (C4.1), 10min (C4.2) e 1hora (C4.1) do treinamento do Caso C
D4	Conjunto de validações para a semana 01-07/10/2017 em intervalos de 5min (D4.1), 10min (D4.2) e 1hora (D4.1) do treinamento do Caso D
A9	Conjunto de validações para os estados do RS (A9.1, A9.2, A9.3 e A9.4)e PE (A9.5, A9.6, A9.7 e A9.8)
A9.1	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso A para o RS
A9.2	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso A para o RS
A9.3	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do Caso A para o RS
A9.4	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso A para o RS
A9.5	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso A para PE
A9.6	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso A para PE
A9.7	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do Caso A para PE
A9.8	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso A para PE
B9	Conjunto de validações para os estados do RS (B9.1, B9.2, B9.3 e B9.4)e PE (B9.5, B9.6, B9.7 e B9.8)
B9.1	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso B para o RS
B9.2	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso B para o RS
B9.3	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do Caso B para o RS
B9.4	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso B para o RS
B9.5	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso B para PE
B9.6	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso B para PE
B9.7	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do Caso B para PE
B9.8	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso B para PE
C9	Conjunto de validações para os estados do RS (C9.1, C9.2, C9.3 e C9.4)e PE (C9.5, C9.6, C9.7 e C9.8)
C9.1	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso C para o RS
C9.2	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso C para o RS

NOMENCLATURA	LEGENDA
C9.3	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do CasO C para o RS
C9.4	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso C para o RS
C9.5	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso C para PE
C9.6	Validação para o dia 12/11/2017 em intervalos de 5 min do treinamento do Caso C para PE
C9.7	Validação para o dia 08/12/2017 em intervalos de 5 min do treinamento do Caso C para PE
C9.8	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso C para PE
D9	Conjunto de validações para os estados do RS (D9.1 e D9.4) e PE (D9.5 e D9.8)
D9.1	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso D para o RS
D9.4	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso D para o RS
D9.5	Validação para o dia 01/10/2017 em intervalos de 5 min do treinamento do Caso D para o PE
D9.8	Validação para a semana 01-07/10/2017 em intervalos de 5 min do treinamento do Caso D para o PE