

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Wander Luiz Silva de Miranda

**Modelo Previsional de Produção de Energia
para Sistemas Fotovoltaicos utilizando RNA**



João Pessoa
2021

Wander Luiz Silva de Miranda

Modelo Previsional de Produção de Energia para Sistemas Fotovoltaicos utilizando RNA

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia Elétrica da Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Curso de Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Juan Moises Maurício Villanueva

João Pessoa

2021

Catálogo na publicação
Seção de Catalogação e Classificação

M672m Miranda, Wander Luiz Silva de.

Modelo Previsional de Produção de Energia para Sistemas Fotovoltaicos utilizando RNA / Wander Luiz Silva de Miranda. - João Pessoa, 2021.

55 f. : il.

Orientação: Juan Villanueva.
TCC (Graduação) - UFPB/CEAR.

1. Modelo de Previsão. 2. Sistemas Fotovoltaicos. 3. Redes Neurais Artificiais. 4. Levenberg-Marquardt. 5. Resilient Backpropagation. 6. Energia Solar. I. Villanueva, Juan. II. Título.

UFPB/BS/CT

CDU 620.91(043.2)

Wander Luiz Silva de Miranda

Modelo Previsional de Produção de Energia para Sistemas Fotovoltaicos utilizando RNA

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia Elétrica da Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho aprovado. João Pessoa, 16 de agosto de 2021. Nota: 9,5



**Prof. Dr. Juan Moises Maurício
Villanueva**
Orientador/UFPB



Prof. Dr. Cícero da Rocha Souto
Avaliador Interno/UFPB



**Prof. Dr. Alexandro José Virgínio
dos Santos**
Avaliador Interno/UFPB

João Pessoa
2021

AGRADECIMENTOS

A Deus por me ajudar a superar todos os momentos difíceis e me fazer acreditar que tudo iria dar certo. Por me conceder dons nesta existência que serviram na realização deste projeto, e por zelar sempre por minha vida.

A minha avó **Tereza**, por sempre se preocupar com meu bem-estar durante o meu percurso, à ela minha imensa gratidão e todo o meu amor!

Aos meus pais, **Jeane e Ivanberto** (*in memoriam*), por todos os valores que me passaram, bem como por todo amor e carinho. Em especial, ao meu pai, meu maior incentivador, à ele o meu amor incondicional!

As minhas irmãs, Maria Luiza e Anne Beatriz, por todos momentos de alegria que me proporcionam!

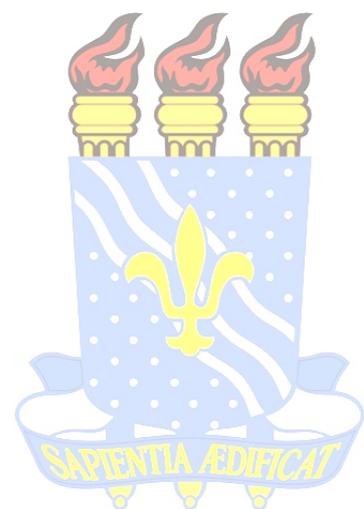
A toda minha família, em especial as minhas tias, tios e aos meus primos, por sempre estarem ao meu lado, me ajudarem nos momentos de dificuldade e de perda, e pelos momentos de lazer.

A minha namorada, **Thalita**, que esteve presente desde o início da minha caminhada acadêmica, me apoiando e cuidando da minha saúde mental, à ela meu amor e carinho.

Aos meus amigos acadêmicos, Leonardo, Duílio, Mateus, Taciana e Mário, pelo companheirismo e pelos bons momentos durante a graduação. À eles, minha admiração.

Ao meu orientador, Juan Moisés M. Villanueva, pela paciência e por estar presente para indicar a direção correta do trabalho, meu muito obrigado!

Aos mestres e doutores, que conheci ao longo da graduação, que foram imprescindíveis em toda essa formação. E todos aqueles que não citei, mas estão marcados em meu coração.



- UFPB

RESUMO

Propõe-se apresentar um modelo de previsão de produção de energia elétrica de sistema fotovoltaicos a partir da utilização de Redes Neurais Artificiais (RNA), aplicando diferentes métodos de treinamento e distintas configurações da topologia da RNA através de dois tipos de algoritmos de treinamento, Levenberg-Marquardt e Resilient Backpropagation. O interesse por essa temática surgiu através da necessidade e os benefícios que podem trazer um modelo de previsão de produção de energia dos sistemas fotovoltaicos, para usuários finais, empresas integradoras e as concessionárias de energia. Em termos metodológicos este presente trabalho é resultado de uma pesquisa bibliográfica, como também a utilização do software MATLAB para os cálculos numéricos e de uma base de dados de produção por meio da SolarWeb (Fronius), uma plataforma de monitoramento. Conclui-se as melhores configurações para uma topologia de uma rede neural *feedforward* de acordo com o período de previsão desejado, como: algoritmos de treinamento e número de neurônios artificiais em cada camada oculta.

Palavras-chave: Modelo de Previsão. Sistemas Fotovoltaicos. Redes Neurais Artificiais. Levenberg-Marquardt. Resilient Backpropagation. Energia Solar.

ABSTRACT

It is proposed to present a prediction model of electric energy production of photovoltaic systems from the use of Artificial Neural Networks (ANN), applying different training methods and different configurations of the ANN topology through two types of training algorithms, Levenberg -Marquardt and Resilient Backpropagation. Interest in this topic arose from the need and the benefits that an energy production forecasting model for photovoltaic systems can bring to end users, integrators and energy concessionaires. In methodological terms, this present work is the result of a bibliographical research, as well as the use of MATLAB software for numerical calculations and a production database through SolarWeb (Fronius), a monitoring platform. The best configurations for a *feedforward* neural network topology are concluded according to the desired forecast period, such as: training algorithms and number of artificial neurons in each hidden layer.

Keywords: Forecast Model. Photovoltaic Systems. Artificial Neural Networks. Levenberg-Marquardt. Resilient Backpropagation. Solar energy.

LISTA DE ILUSTRAÇÕES

Figura 1 – Principais materiais utilizados na fabricação de módulos fotovoltaicos.	17
Figura 2 – Diagrama esquemático de um sistema fotovoltaico autônomo.	19
Figura 3 – Diagrama esquemático de um sistema fotovoltaico conectado à rede.	20
Figura 4 – Total diário de irradiação global horizontal - Média Anual.	21
Figura 5 – Sistema fotovoltaico de microgeração instalado em uma residência.	23
Figura 6 – Sistema fotovoltaico de minigeração instalado em um shopping center.	24
Figura 7 – Usina solar fotovoltaica localizada em Tauá - Ceará.	25
Figura 8 – Semelhança de estrutura entre um neurônio biológico e um neurônio matemático	28
Figura 9 – Diagrama da Rede Neural Artificial Perceptron	29
Figura 10 – Diagrama da Rede Neural Artificial Perceptron Multicamadas	31
Figura 11 – Exemplo de produção energética acumulada diária e mensal de um sistema fotovoltaico no <i>solar.web</i>	34
Figura 12 – Dados de energia acumulada diária para aprendizagem e validação da RNA.	35
Figura 13 – Série com aplicação da média móvel.	36
Figura 14 – Comparação das curvas da série sem e com a utilização da média móvel.	37
Figura 15 – Separação dos dados para treinamento e validação.	38
Figura 16 – Topologia da RNA utilizada.	39
Figura 17 – Matriz Hessiana.	41
Figura 18 – Diferença de entre distribuições com mesma média e desvios padrão diferentes.	43
Figura 19 – Utilização dos dados	44
Figura 20 – Produção energética de 13,27 kWh do sistema fotovoltaico no primeiro dia.	46
Figura 21 – Melhores desempenhos nas previsões do modelo relacionado ao Caso 01	46
Figura 22 – Produção energética de 94,67 kWh do sistema fotovoltaico nos primeiros 07 dias.	48
Figura 23 – Melhores desempenhos nas previsões do modelo relacionado ao Caso 02	48
Figura 24 – Produção energética de 400,94 kWh do sistema fotovoltaico nos primeiros 30 dias.	50
Figura 25 – Melhores desempenhos nas previsões do modelo relacionado ao Caso 03	50

LISTA DE TABELAS

Tabela 1 – Classificação das usinas de acordo com a potência instalada	22
Tabela 2 – Avaliação de desempenho do modelo de previsão em relação ao Caso 01	45
Tabela 3 – Avaliação de desempenho do modelo de previsão em relação ao Caso 02	47
Tabela 4 – Avaliação de desempenho do modelo de previsão em relação ao Caso 03	49
Tabela 5 – Melhores desempenhos do modelo de previsão nos casos de curto, médio e longo Prazo	51
Tabela 6 – Resultados utilizando a série padrão e a série com média móvel	52

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
INPE	Instituto Nacional de Pesquisas Espaciais
LABREN	Laboratório de Modelagem e Estudos de Recursos Renováveis de Energia
CC	Corrente Contínua
CA	Corrente Alternada
DPS	Dispositivo de Proteção de Surto
MPPT	Maximum Power Point Tracking
MLP	Multilayer Perceptron
RNA	Rede Neural Artificial
MAPE	Mean Absolute Percentage Error
DP	Desvio Padrão
MEA	Média do Erro Absoluto

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Pertinência e motivação do trabalho	13
1.2	Objetivos	14
1.2.1	Objetivo Geral	14
1.2.2	Objetivo Específico	14
1.3	Organização do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Energia solar fotovoltaica	16
2.1.1	Tecnologia fotovoltaica	17
2.2	Sistemas Fotovoltaicos	18
2.2.1	Sistemas Fotovoltaicos Autônomos	18
2.2.2	Sistemas Fotovoltaicos Conectados à Rede	20
2.2.2.1	Sistemas Fotovoltaicos Conectados à Rede no Brasil	21
2.2.2.2	Sistemas Fotovoltaicos de Microgeração	22
2.2.2.3	Sistemas Fotovoltaicos de Minigeração	23
2.2.2.4	Usina Fotovoltaica	24
2.3	Séries Temporais	25
2.3.1	Tendência e Sazonalidade	26
2.3.2	Estacionariedade	26
2.3.3	Autocorrelação	27
2.4	Redes Neurais Artificiais	27
2.4.1	Rede Neural Artificial <i>Perceptron</i>	29
2.4.2	Rede Neural Artificial <i>Perceptron Multicamadas</i>	30
3	METODOLOGIA	32
3.1	Ferramentas e Dados	32
3.1.1	<i>Software</i> MATLAB	32
3.1.1.1	Linguagem de Programação Matlab	32
3.1.2	Conjunto de Dados	33
3.2	Modelo de Previsão	35
3.2.1	Modificação dos Dados para Aprendizagem	35
3.2.1.1	Apuração da Produção Energética Diária	35
3.2.1.2	Suavização da Curva de Produção Energética Diária	35
3.2.2	Criação do Banco de Dados	37

3.2.3	Topologia da RNA	38
3.2.3.1	Parâmetros Internos	38
3.2.3.2	Camadas de Entrada e Saída	39
3.2.3.3	Camadas Ocultas	40
3.2.3.4	Algoritmo de Treinamento	40
3.2.3.4.1	Levenberg-Marquard	40
3.2.3.4.2	Resilient Backpropagation	41
3.2.4	Métricas de Avaliação	42
3.2.4.1	Erro Percentual Absoluto Médio - MAPE	42
3.2.4.2	Média do Erro Absoluto	42
3.2.4.3	Desvio Padrão	43
4	RESULTADOS	44
4.1	Descrição dos Dados	44
4.2	Caso 01: Previsão de Curto Prazo	45
4.3	Caso 02: Previsão de Médio Prazo	47
4.4	Caso 03: Previsão de Longo Prazo	49
4.5	Comparativo: Casos de Curto, Médio e Longo Prazo	51
4.6	Comparativo: Série Padrão x Série com Média Móvel	52
5	CONCLUSÃO	53
	REFERÊNCIAS	55

1 INTRODUÇÃO

1.1 PERTINÊNCIA E MOTIVAÇÃO DO TRABALHO

Esta pesquisa tem como objetivo abordar um modelo de previsão de produção de energia elétrica de sistemas fotovoltaicos em geral, baseado na utilização de Redes Neurais Artificiais (RNA) para treinamento e aprendizagem dos dados, como também, ter previsões a partir desses dados disponíveis da produção do sistema para uma janela de previsão pré-determinada.

Assim sendo, no momento atual a tecnologia fotovoltaica, que transforma energia advinda do sol em energia elétrica, vem vivenciando um importante avanço, sendo impulsionado pelos vários pontos positivos que apresenta, nos quais se destacam a grande flexibilidade de utilização, o baixo impacto ambiental e uma facilidade de construção e de operação (VIAN, 2021).

Os sistemas fotovoltaicos podem ser denominados como sistemas autônomos, onde a energia pode ser armazenada em bancos de baterias, ou sistemas conectados à rede que a energia elétrica é fornecida diretamente para rede elétrica disponibilizada pela concessionária de energia. Os sistemas isolados (autônomos) tendem a ser de pequeno porte, o motivo será pelo alto valor das baterias estacionárias, já os sistemas conectados à rede podem obter qualquer quantidade de potência, podendo ser uma usina de micro geração com alguns Watts(W) instalados, até uma usina de grande porte, com centena de MegaWatts(MW) de potência.

Por sua vez, no Brasil, há pouco tempo atrás, a energia solar era utilizada apenas em micro sistemas autônomos em locais onde não havia a distribuição da rede elétrica, locais com difícil acesso ou as obras da rede para chegada de energia não eram viáveis para a concessionária de energia.

Com a publicação da Resolução Normativa nº 482 da ANEEL (Agência Nacional de Energia Elétrica), em 2012, estabeleceu condições gerais para o acesso da geração distribuída aos sistemas de distribuição de energia elétrica e a criação dos sistemas de compensação de energia. A partir disso, ocorreu migração de apenas existirem sistemas autônomos e começaram a instalação de sistemas conectados à rede brasileira(VIAN, 2021).

Dessa forma, um modelo de previsão é importante tanto para as concessionárias distribuidoras de energia elétrica, quanto para as empresas que vendem e instalam sistemas fotovoltaicos (integradoras), e para os consumidores.

Para os consumidores é importante ter uma previsão da produção da energia

fotovoltaica do sistema instalado para o próximo dia, semana ou mês. Essa previsão de curto, médio e longo prazo dá para o consumidor a possibilidade de programar o seu consumo de energia elétrica, com o objetivo de não exceder o valor do consumo energia da sua unidade conectada à rede elétrica ao valor da geração do sistema fotovoltaico, acarretando a liquidação dos valores cobrados nas faturas de energia e conseqüentemente diminuindo a sua taxa de contribuição na iluminação pública, visto que, a contribuição é proporcional ao consumo contabilizado na fatura.

Para as integradoras uma previsão em longo prazo, auxilia na programação das manutenções dos sistemas, como por exemplo, a necessidade de limpeza dos painéis e do inversor fotovoltaico.

E para as concessionárias de energia elétrica a importância de um modelo previsional dos sistemas fotovoltaicos é analisar a necessidade de melhorias na rede de distribuição. Podendo assim adiar gastos com obras de melhorias de rede e indicar a necessidade de melhorias mais urgentes.

1.2 OBJETIVOS

O objetivo deste trabalho consiste em utilizar um modelo computacional chamado de Rede Neural Artificial (RNA) para criação de um modelo de previsão energética de sistemas fotovoltaicos.

1.2.1 OBJETIVO GERAL

Apresentar um estudo relacionado a criação de um modelo de previsão utilizando Redes Neurais Artificiais, a partir de dados de produção de energia fotovoltaica, que obtém características de séries temporais, aplicando diferentes métodos de treinamento e diferente configurações da topologia da RNA.

1.2.2 OBJETIVO ESPECÍFICO

Observação e análise do comportamento de um modelo de previsão de produção fotovoltaica, sugerindo criação de casos que avaliam os resultados de acordo com o período de previsão desejado. A partir da utilização dos algoritmos de treinamento de Levenberg-Marquardt e Resilient Backpropagation, da aplicação de mudanças nas camadas ocultas da topologia da rede neural, alterando os número de neurônios artificiais de cada camada. Por fim, ocorre a apresentação dos resultados e definição de uma melhor configuração para cada período de previsão que pretende realizar.

1.3 ORGANIZAÇÃO DO TRABALHO

Este trabalho foi estruturado em cinco capítulos. No capítulo introdutório, foi abordado a importância e motivação da escolha do tema. Além disso, foram citados os objetivos gerais e específicos.

No segundo capítulo, será realizada uma fundamentação teórica sobre a energia solar fotovoltaica, sua tecnologia e a classificação dos sistemas fotovoltaicos. O avanço e regulamentação do emprego dos sistemas fotovoltaicos no Brasil e a classificação dos sistemas de acordo com a potência instalada. Como também, a teoria que envolve as séries temporais e Redes Neurais Artificiais.

O terceiro capítulo abordará a metodologia utilizada, partindo do software computacional utilizado para emprego da RNA, após isso, a descrição dos dados utilizados para realização deste trabalho e a descrição do modelo de previsão.

No quarto capítulo, os resultados serão apresentados em forma de tabela com o desempenho para cada caso criado de acordo com o período de previsão, as combinações que envolvem os algoritmos de treinamento e o número de neurônios em cada camada oculta, e análise matemática conforme as métricas utilizadas e será feita uma breve explicação dos resultados obtidos.

O quinto capítulo constará da conclusão do trabalho, analisando e comparando os resultados obtidos com os no quarto capítulo. E por fim, será discutido as futuras aplicações e utilidades deste projeto, assim como proposta de melhorias futuras.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ENERGIA SOLAR FOTOVOLTAICA

Devido a grande demanda do mundo no uso da energia elétrica se tornou preocupante o uso de fontes de energias não-renováveis. Tentando a independência dos combustíveis fósseis e a não poluição, há sempre a prioridade do uso de fontes de energias renováveis para a geração de energia elétrica. A energia solar, dentre as todas as energias renováveis disponíveis, é a energia cujo o uso mais cresce em todo mundo por existir vários pontos positivos em sua aplicação: baixo impacto ambiental, flexibilidade de utilização e facilidade de construção e operação.

A energia solar pode ser utilizada para produzir eletricidade a partir do efeito fotovoltaico, que é o processo de conversão direta da energia advinda dos raios solares em energia elétrica. A energia do sol é transmitida para o nosso planeta através do espaço e radiação eletromagnética, no qual essa radiação é constituída de ondas eletromagnéticas.

Todo o espectro de radiação, incluindo ondas visíveis ao olho humano e não visíveis, transporta energia que pode ser captada na forma de calor ou luz. O efeito fotovoltaico, que é a base dos sistemas de energia solar fotovoltaica para a produção de eletricidade, consiste na transformação da radiação eletromagnética do sol em energia elétrica através da criação de uma diferença de potencial, formada por uma célula fotovoltaica.

A análise da radiação solar é realizada com a quantificação da potência da radiação por uma determinada área de superfície. Essa medição é chamada de irradiância, expressa na unidade de W/m^2 . Entretanto, uma outra unidade é muito útil no dimensionamento dos sistemas fotovoltaicos, a insolação, que é a unidade da irradiância multiplicado pelo tempo e a sua unidade é Wh/m^2 . Na prática encontra-se tabelas e mapas de insolação que fornece valores diários expressos em $Wh/m^2/dia$ (VILLALVA, 2015). Banco de dados são criados com informações de insolação do mundo inteiro, obtidos de dados de satélites com análise de um longo período e com parametrização dos modelos, para manter a confiabilidade dos dados disponibilizados ao público.

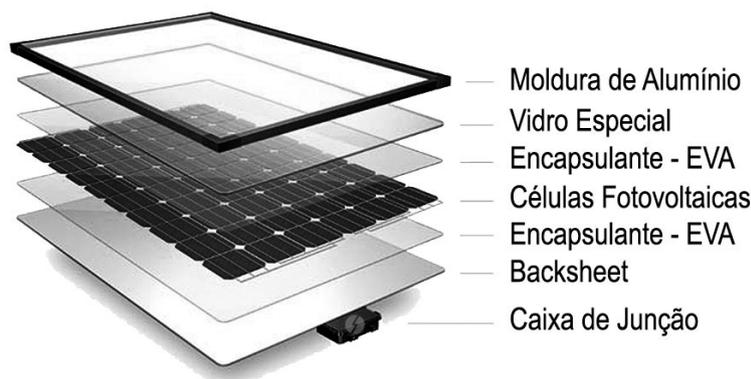
A distribuição de energia do espectro de radiação solar depende da localização geográfica, da hora do dia, das condições climáticas e de outros fatores. O perfil característico médio da radiação solar em uma determinada localidade pode ser obtido experimentalmente, onde existe vários tipos de radiação e cada tipo pode ser medida por um de instrumento específico.

2.1.1 TECNOLOGIA FOTOVOLTAICA

De acordo com Vian (2021), nas células a tecnologia mais utilizada na fabricação é a junção de chapas justapostas de pequena espessura, constituídas de materiais semicondutores. As células funcionam como fontes de correntes contínuas e são conectadas em séries de paralelo/série, formando um módulo fotovoltaico. Os módulos são interligados formando painéis, onde produzem energia em corrente contínua, geralmente a corrente advinda dos painéis é convertida de corrente contínua para uma corrente alternada com a utilização do inversor solar. Na Fig. 1 observar-se a composição de um módulo fotovoltaico.

Dos semicondutores empregados o silício ainda é o mais usual, na sua arquitetura comum é a tecnologia de maior maturidade e detinham 95% da produção fotovoltaica do mundo. Os módulos fotovoltaicos tem tido uma melhoria significativa em seu rendimento e potência nos últimos anos. Há um tempo a eficiência de um módulo era em torno de 13,2% para os multicristalinos e 14,7% para os monocristalinos, e ultimamente a eficiência tem chegado entre 17% e 18%, respectivamente (IRENA, 2019).

Figura 1 – Principais materiais utilizados na fabricação de módulos fotovoltaicos.



Fonte: Portal Solar (2021a)

Observa-se que o surgimento de novas arquiteturas de células tem permitido níveis mais altos de eficiência. As células PERC (*Emissor Passivo na Célula Traseira, em português*) é uma das responsáveis por esse avanço, junto com sua compatibilidade com outras inovações, são células que possuem uma camada adicional de passivação na parte traseira da célula gerando reflexão no fundo da célula permitindo que os raios solares passem mais vezes pelo silício, conseqüentemente havendo mais geração de energia.

Outro avanço significativo da tecnologia no futuro próximo será o uso mais frequente de células e módulos bifaciais, pois são células capazes de gerar energia não apenas pelos raios solares advindos frontalmente, mas também da luz solar que é refletida para parte posterior do módulo. Dessa forma, o seu uso será impulsionado pelo foco na produção dos sistemas fotovoltaicos (VIAN, 2021).

2.2 SISTEMAS FOTOVOLTAICOS

Os sistemas fotovoltaicos tem a capacidade de transformar a energia solar em corrente elétrica, usando a tecnologia dos módulos e dos conversores ou de controladores, pode-se essa energia ser armazenada em bancos de baterias ou ser conectada diretamente à rede elétrica fornecida pela concessionária de energia (VILLALVA, 2015), são denominados como sistemas autônomos e sistemas conectados à rede, respectivamente.

Os sistemas isolados tendem a ser de pequeno porte, o motivo se dá pelo alto valor das baterias estacionárias, onde é o principal instrumento para o armazenamento da energia gerada, refletindo, quanto maior a potência do sistema isolado maior será o número de baterias instaladas.

Já os sistemas conectados à rede podem obter qualquer quantidade de potência, podendo ser uma usina de micro geração com alguns Watts (W) instalados, até uma usina de grande porte, com centena de MegaWatts (MW) de potência.

Os dois tipos de sistemas fotovoltaicos são utilizados em vários projetos de geração, dedicados às aplicações mencionadas abaixo:

- Geração em residências, estabelecimentos comerciais e industriais;
- Bombeamento de água para irrigação, uso doméstico e piscicultura;
- Uso coletivo, por exemplo: escolas, postos de saúde e centros comunitários;
- Sistema de monitoramento e fiscalização de rodovias.

2.2.1 SISTEMAS FOTOVOLTAICOS AUTÔNOMOS

Os sistemas isolados ou autônomos, podem ser individuais ou em mini redes. Os individuais a geração é exclusiva para o consumo de uma única unidade consumidora, na mini rede a geração é compartilhada entre um pequeno grupo de unidades consumidores e estão geograficamente próximas (PINHO; GALDINO, 2014).

Um sistema autônomo é composto geralmente por um conjunto de painéis fotovoltaicos, um controlador de carga, um banco de baterias e dependendo da aplicação, um inversor de corrente contínua para corrente alternada. Pode-se ver um diagrama esquemático do sistema na Fig. 2.

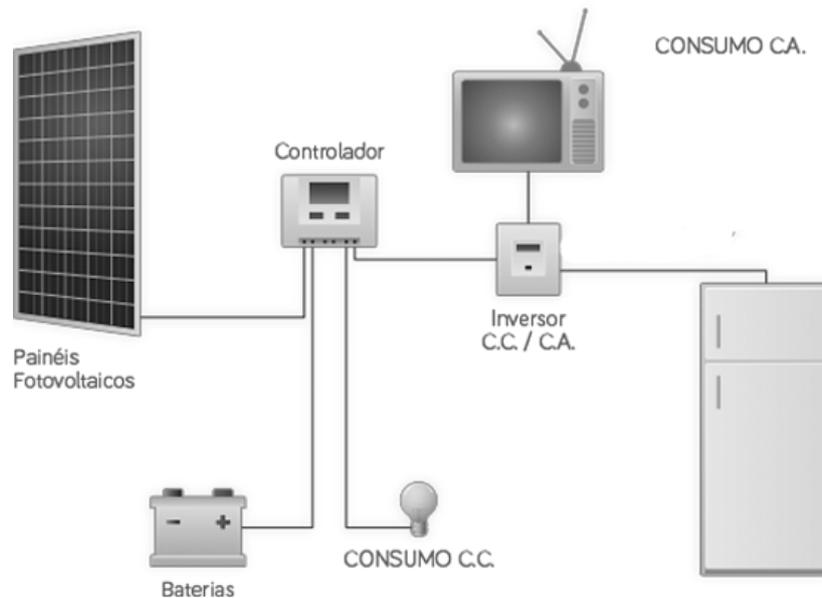
O controlador de carga é o dispositivo eletrônico usado para ajustar o uso das baterias, para não as expor à sobrecargas, nem o descargas excessivas, analisando a demanda em períodos que a produção de energia pelos painéis fotovoltaicos é superior ou inferior à demanda da carga, prorrogando o tempo de vida útil do banco de baterias.

Dependendo do controlador, é acompanhado da tecnologia de rastrear o ponto máximo de potência dos módulos, aumentando o produção de energia do sistema.

O banco de baterias são acumuladores de cargas, são elementos que são projetados para suportar ciclos de *carga/descarga*, repetitivamente. Para o uso em instalações fotovoltaicas não são recomendadas o uso de baterias automobilísticas, pois não suportam um número elevado de ciclos de *carga/descarga*, além da probabilidade de vazamento do fluido interno, eletrólito, por ser altamente corrosivo, pode causar danos. Nas baterias específicas para o contexto de energia solar, o líquido do eletrólito é substituído por um gel.

Como os módulos produzem uma corrente contínua, precisa-se de um inversor *CC-CA* para o uso de cargas que utilizam de corrente alternada, por exemplo para os eletrodomésticos de uma residência.

Figura 2 – Diagrama esquemático de um sistema fotovoltaico autônomo.



Fonte: Sunvia (2021)

Exemplos de aplicações:

- Geração de pequeno porte em residências;
- Controle de tráfego em estradas;
- Monitoramento de condições ambientais;
- Sistema de segurança eletrônica;
- Auxílio em embarcações;

2.2.2 SISTEMAS FOTOVOLTAICOS CONECTADOS À REDE

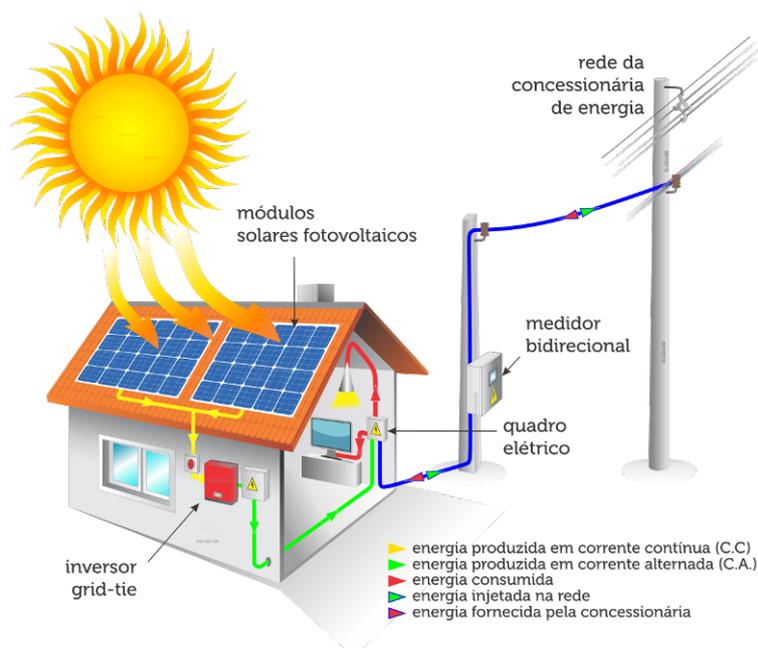
Diferente do sistema autônomo, os sistemas fotovoltaicos conectados à rede refere-se aqueles onde a unidade já está interligada ao sistema de distribuição pública de energia da concessionária do local, operando em paralelo com a rede de eletricidade. O emprego deste sistema tem a finalidade de gerar energia para o consumo próprio, reduzindo ou eliminando todo o consumo, ou até mesmo gerar excedente de energia.

Para a conexão do sistema à rede é necessário converter a energia advinda dos painéis fotovoltaicos, onde a corrente é contínua para corrente alternada utilizando o inversor *CC-CA* que são fabricados para uso em energia solar.

Diferente do sistema isolado, nos sistemas conectados à rede não é necessário o uso do controlador de carga e do banco de baterias (*acumulador de carga*), já que o sistema utiliza a energia da rede elétrica quando há a intermitência na geração solar. Um número menor de dispositivos gerais que são exigidos para o funcionamento deste sistema, comparado ao sistema isolado, influi diretamente no valor inicial de investimento. Como exemplo é apresentado o diagrama na Fig. 3.

Esse tipo de sistema fotovoltaico oferece uma maior variedade de aplicações e de potência instalada, que pode partir de uma potência de Watts (*W*) até vários Megawatts (*MW*), isso contribuiu para que seu uso tivesse um crescimento e também na quantidade de potência instalada mundialmente, e recentemente no Brasil.

Figura 3 – Diagrama esquemático de um sistema fotovoltaico conectado à rede.



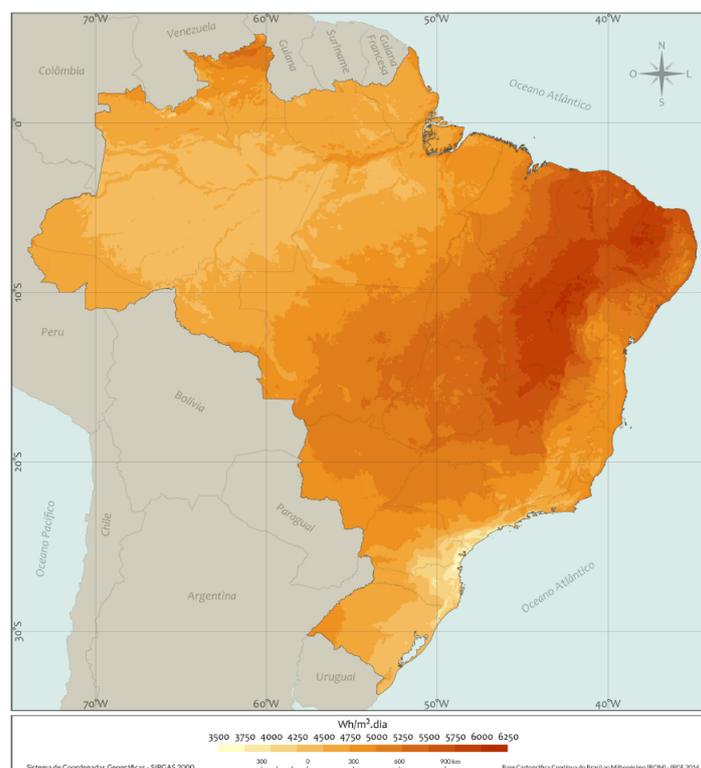
Fonte: Luz Solar (2021)

2.2.2.1 SISTEMAS FOTOVOLTAICOS CONECTADOS À REDE NO BRASIL

No Brasil essa fonte de geração de energia tem mostrado uma capacidade enorme de crescimento. Como os bons índices de irradiação solar e a disponibilidade de espaço no território sem prejudicar atividades econômicas importante, por exemplo, a agropecuária. São essas umas das características que mais contribuem para a expansão, climaticamente e geograficamente, respectivamente.

Pode-se observar na Fig. 4, o mapa da distribuição da incidência da irradiação solar em todo território brasileiro, uma elaboração cooperativa entre o INPE (Instituto Nacional de Pesquisas Espaciais), através do seu Laboratório de Modelagem e Estudos de Recursos Renováveis de Energia (LABREN) e pesquisadores de várias instituições federais do Brasil.

Figura 4 – Total diário de irradiação global horizontal - Média Anual.



Fonte: Pereira et al. (2017)

Há pouco tempo atrás a energia solar no Brasil era utilizada apenas em micro sistemas autônomos em locais que não havia a distribuição da rede elétrica e tinha um difícil acesso, ou as obras da rede para chegada de energia nesses locais não eram economicamente viáveis.

Dessa forma, por meio da Resolução nº 482 da ANEEL, citada anteriormente, ocorreu a mudança de apenas existirem sistemas autônomos para a instalação de sistemas

conectados à rede brasileira. Conforme Vian (2021), a partir disso, se estabeleceu condições gerais para o acesso da geração distribuída aos sistemas de distribuição de energia elétrica, da criação dos sistema de compensação de energia e de todos os protocolos a serem seguidos.

Ainda mais, a resolução contém limitação de potência da geração distribuída que poderia ser conectada à rede, podendo ser no máximo de $1MW$, utilizando qualquer fonte de energia renovável. Vale ressaltar, que em 2015 o limite aumentou para $3MW$ sendo pequena hidrelétricas e $5MW$ para as outras fontes, incluindo as usinas fotovoltaicas.

As usinas fotovoltaicas são classificadas de acordo com a ANEEL pela sua capacidade de geração, como mostra a tabela 1, a seguir:

Tabela 1 – Classificação das usinas de acordo com a potência instalada

Classificação	Capacidade [MW]
Micro	até 0,1
Mini	maior que 0,1 até 1
Pequena	maior que 1 até 30
Grande	maior que 30

Nas próximas seções serão abordadas cada uma das categorias de sistema fotovoltaicos designados pela Agência Nacional de Energia Elétrica, apresentando características usuais das instalações.

2.2.2.2 SISTEMAS FOTOVOLTAICOS DE MICROGERAÇÃO

Os sistemas fotovoltaicos de microgeração são instalações de pequeno porte, com potência instalada de até $100kWp$. Nesta classificação se encaixam sistemas instalados em residências, comércios e pequenas indústrias, que geralmente o sistema supri todo o consumo da unidade consumidora (VILLALVA, 2015).

Com isso, essa categoria de sistema, podem ser conectados as redes monofásicas ou trifásicas das residências, de prédios comerciais e empresarias, ou de qualquer consumidor que contenha acesso a rede de distribuição de energia.

A Fig. 5 mostra um sistema fotovoltaico característico de microgeração em uma residência conectada à rede elétrica, onde, os módulos solares instalados são conectados ao inversor, contando anteriormente com a proteção do circuito de corrente contínua e posteriormente com a proteção do circuito de corrente alternada, só assim havendo a ligação do sistema na rede elétrica da unidade.

A energia gerada pelo sistema fotovoltaico é injetada e distribuída na rede da residência, podendo ser totalmente consumida, ou havendo excedente existente é exportado

para a rede da concessionária, passando pelo medidor bidirecional, gerando créditos para o usuário cadastrado da unidade consumidora (VILLALVA, 2015).

Figura 5 – Sistema fotovoltaico de microgeração instalado em uma residência.



Fonte: Banco de dados da empresa Smartsun - Energia Solar

2.2.2.3 SISTEMAS FOTOVOLTAICOS DE MINIGERAÇÃO

Os sistemas fotovoltaicos de minigeração são aqueles instalados em indústrias, shopping centers e grandes comércios. Geralmente, são construídos para que sua geração supra parcialmente até totalmente a demanda de energia elétrica da unidade que está instalada, isso implica em uma diminuição da dependência dos consumidores da rede elétrica da concessionária.

Além do benefício econômico trazido pela geração solar do sistema, há uma valorização da empresa, por seus produtos e serviços fornecidos serem advindo de uso de fontes de energias renováveis, pois há uma preferência dos consumidores por instituições que decidem investir em uma produção e gestão sustentável (VILLALVA, 2015).

Sistemas dessa categoria, que contém uma potência instalada de até 1 MW, são conectados diretamente à rede de média ou de alta tensão (VIAN, 2021). Na Fig. 6 pode-se ver a instalação de um sistema de minigeração instalado na área disponível no telhado de um shopping center, e como mencionado anteriormente, conectado à rede de alta tensão concedida pela concessionária.

Figura 6 – Sistema fotovoltaico de minigeração instalado em um shopping center.



Fonte: Banco de dados da empresa Smartsun - Energia Solar

2.2.2.4 USINA FOTOVOLTAICA

Usina solar fotovoltaica, também chamada de parque solar ou de central fotovoltaica, é a classificação de sistemas fotovoltaicos que se assemelham às outras usinas de geração de energia de grande porte, onde usam transformadores e linhas de transmissão para se conectar a rede de distribuição elétrica, justamente, desta mesma forma, que são constituídas as usinas termelétricas, hidrelétricas, entre outras (VILLALVA, 2015).

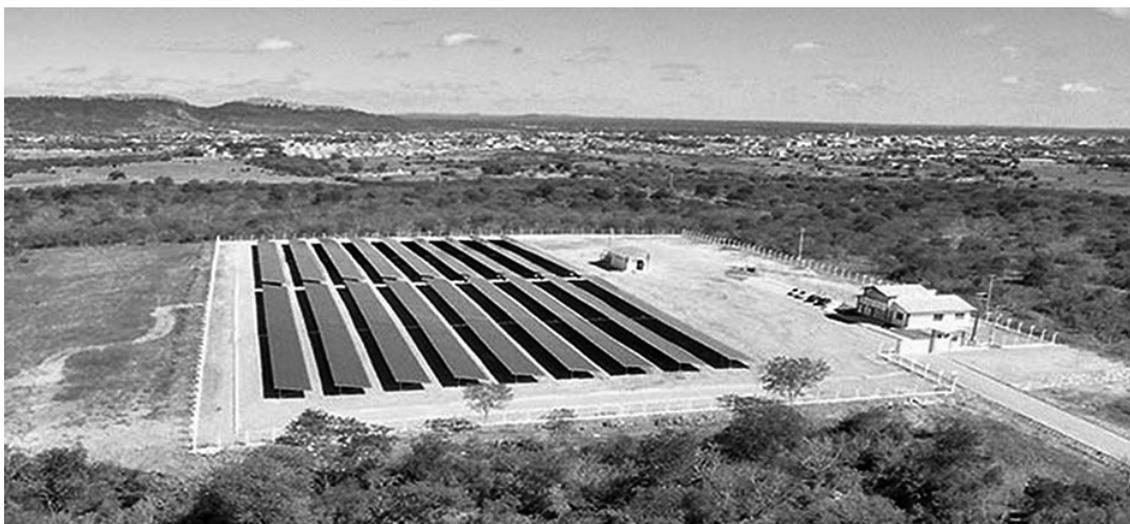
A maioria das usinas são construídas sobre o solo, por apresentar um valor alto de potência instalada, são necessários grandes conjuntos de módulos fotovoltaicos, formando subsistemas conectados a inversores centrais, a junção desse subsistemas constrói um grande sistema de geração, podendo ter potência instalada de muitos MegaWatts.

Em sua maioria os conjuntos de módulos são fixos, mas podem contar com a tecnologia de rastreamento solar, onde há uma variação na inclinação dos painéis seguindo o movimento do sol, embora aumentem o valor da produção de energia, também aumentam os custos de instalação, manutenção e operação da usina (PORTAL SOLAR, 2021b).

Para conexão com a rede os inversores centrais são interligados a cabines de transformação, podendo ser observado a elevação dos valores de tensão advinda dos inversores para que os níveis sejam compatíveis com o valor de tensão das linhas de transmissão do sistema elétrico (VILLALVA, 2015).

Na Fig. 7 te-se a primeira usina solar fotovoltaica construída no Brasil, em 2011, está localizada na cidade de Tauá, no estado do Ceará, que tem a potência inicial instalada de 1 MW.

Figura 7 – Usina solar fotovoltaica localizada em Tauá - Ceará.



Fonte: (PORTAL SOLAR, 2021b)

2.3 SÉRIES TEMPORAIS

As séries temporais são processos estocásticos, no qual possuem uma coleção de observações feitas de forma sequencial ao longo do tempo com leis probabilísticas. Tem como característica crucial a ordem dos dados, como também o tempo que é substituído por outra variável, como por exemplo, espaço e profundidade (EHLERS, 2003).

Deste modo, as séries temporais podem ser caracterizadas de forma contínua e sua observação é realizada continuamente ao decorrer do tempo. E de forma discreta quando a análise é feita de forma repetitiva e em distâncias semelhantes.

Por sua vez, conforme Ehlers (2003), as séries temporais discretas podem ser geradas em diversas formas e as séries contínuas podem ser discretizadas com seus valores registrados em um intervalo de tempo e multivariadas que em cada intervalo de tempo possui um vetor de observação.

Conforme o autor, as ordens temporais possuem determinadas abordagens técnicas descritivas, técnicas de identificação de padrões, modelos probabilísticos como a seleção, comparação e adequação de amostras tendo como ferramenta básica a autocorrelação, a análise espectral, métodos não paramétricos e entre outros (EHLERS, 2003).

Assim sendo, o estudo das séries temporais é de grande importância a partir de alguns dos seus objetivos, como descrever propriedades da série, o padrão de tendência, existência de variação da sazonalidade e detecção dos outliers; a utilização da variação para explicar a variação em outra série e antever os valores futuros com base nos passados. Como também, lidar com a estacionariedade e a autocorrelação, explicadas a seguir.

2.3.1 TENDÊNCIA E SAZONALIDADE

A tendência, se baseando em Hyndman e Athanasopoulos (2018), ocorre quando há um aumento ou diminuição nos dados com vários possíveis padrões, podendo ser linear, exponencial ou amortecido. Com isso, pode-se observar também que diversas séries temporais exibem um comportamento que se repete a cada x período de tempo, ocorrendo um padrão sazonal, em outras palavras, quando uma série temporal é afetada por alguns fatores sazonais, como por exemplo a época do ano.

Desta forma, o autor (EHLERS, 2003), traz três possíveis modelos sazonais, a sazonalidade determinística, ou seja, quando um coeficiente de cada variável representa o fator sazonal de um mês particular; as funções trigonométricas e as sazonalidades estocásticas.

Pode-se também observar alguns tipos de sazonalidade, segundo Ehlers (2003), a aditiva e a multiplicativa. A aditiva apresenta flutuações sazonais geralmente constantes não importando o nível global da série. Já a multiplicativa o tamanho das flutuações sazonais podem variar de acordo com o nível global da série.

Alguns autores afirmam que não existe uma única definição de tendência, e sim, o termo utilizado de formas distintas. O autor citado, define em sua pesquisa a tendência como uma mudança de longo prazo no nível médio da série, tendo como forma mais simples:

$$X_t = \alpha + \beta t + \epsilon t \quad (2.1)$$

Considerando α e β constantes e ϵt evidencia um equívoco aleatório com média 0 (zero). E o termo de tendência define como o nível médio da série no tempo t dado por $m_t = \alpha + \beta t$. Ainda mais, consta que uma forma de lidar com o resultado não sazonais que possua uma tendência consiste em adaptar uma função polinomial (EHLERS, 2003):

$$X_t = \beta_0 + \beta_1 t + \dots + \beta_p t^p + \epsilon t \quad (2.2)$$

2.3.2 ESTACIONARIEDADE

A estacionariedade é uma série temporal a partir que suas propriedades estatísticas não se alteram ao decorrer do tempo, isto é, possuir média e variação constante e a covariância independente do período. Pode-se afirmar que não são todas as séries temporais que são estacionárias, entretanto, é possível transformação de séries não estacionárias para estacionárias.

Ainda mais, na prática, a maioria das séries não são estacionárias, como exemplo,

tendência citada anteriormente. Já as séries temporais podem ser consideradas estacionárias a partir dos períodos curtos ou longos e ao implicar uma mudança de nível e/ou inclinação.

2.3.3 AUTOCORRELAÇÃO

A autocorrelação é uma ferramenta matemática para encontrar padrões de repetições, consiste em uma importante característica de observação para descrever uma série temporal que possui uma ideia semelhante ao coeficiente de correlação usual, no qual para n pares de identificação das variáveis x e y é o coeficiente de correlação amostral representado pela fórmula (EHLERS, 2003):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (2.3)$$

Segundo a definição estatística, o valor da autocorrelação (r) pode variar entre -1 e 1, quando próximo ou igual a 1 (correlação perfeita) x e y são diretamente proporcionais, assim quando r tiver seu valor próximo ou igual a -1 (anti-correlação perfeita) os valores de x e y são inversamente proporcionais. Quando o seu valor é aproximadamente ou igual à zero, há uma ausência total de correlação, x e y estão descorrelacionados. Por sua vez, a função da autocorrelação de um processo estocástico é uma ferramenta necessária para acessar suas propriedades.

2.4 REDES NEURAIS ARTIFICIAIS

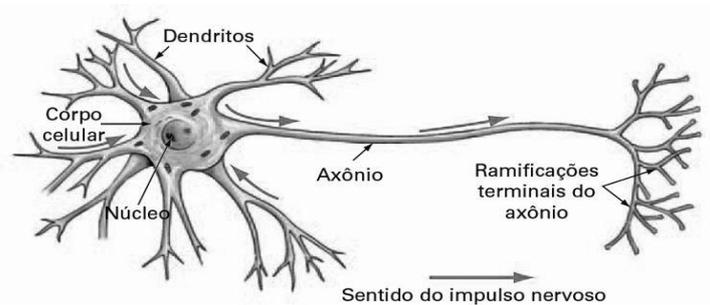
A teoria de Redes Neurais Artificiais (RNA) de modelos matemáticos e de engenharia refere-se aos modelos de neurônios biológicos. Considerando, segundo Kovács (2006), que o neurônio é delimitado por uma afinada membrana celular com funções biológicas normais e determinadas propriedades que são essenciais para o funcionamento elétrico da célula nervosa. Ainda mais, o neurônio possui um axônio ou fibra nervosa, responsável pela transmissão de informações, com ramificações, que tem função de conectar a célula nervosa com um outro sistema nervoso.

Vale ressaltar algumas informações, como por exemplo, esta fibra nervosa pertencente ao neurônio, conforme ao autor, é como um tubo filamentar delimitado através da membrana celular e possui duas regiões, uma interna e outra externa. Assim, sem a presença de um impulso nervoso, esta região interna está em um potencial eletronegativo de dezenas de mV sobre a região externa. Então quando o potencial da membrana está menos eletronegativo do que o de repouso, a chama-se de despolarizada, e quando está mais eletronegativo de hiperpolarizada.

Kovács (2006), traz que esta despolarização pode ser realizada em laboratório pela introdução de microeletrodos nas regiões da fibra nervosa. Quando ocorre o estímulo chega à uma sinapse que terá resultado na membrana pós-sináptica provocado por uma polarização dependente do tipo de neurônio transmissor. E a polarização ocorre logo após a chegada do impulso nervoso na sinapse e a sua propagação através da difusão passiva da membrana até onde o local de interferir no surgimento do potencial de ação.

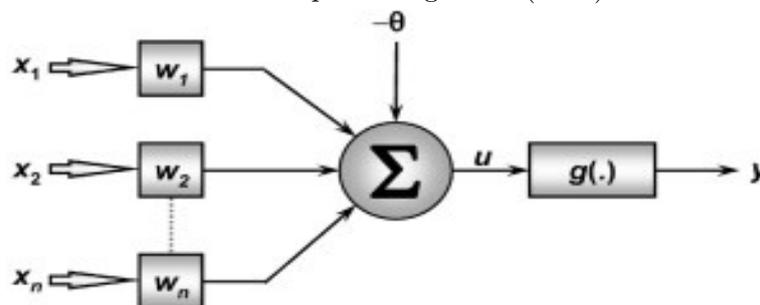
Por sua vez, conforme Trybe (2020), pode-se considerar diversas propriedades do neurônio biológico necessárias para o estudo das RNA, considerando que as Redes Neurais Artificiais surgiram em meados de 1943, através de estudos dos pesquisadores Warren McCulloch e Walter Pitts, que nas suas pesquisas utilizaram cálculos matemáticos para simular o funcionamento dos neurônios biológicos. A partir daí, outros estudiosos utilizaram como base para simular em máquinas o processo das informações realizadas pelo sistema neural.

Desta forma, os neurônios biológicos se relacionam entre si através de impulsos elétricos e assim, executam diversas ações. Assim sendo, as RNA simulam o mecanismo de comunicação entre estes neurônios para realizar o Machine Learning (aprendizado de máquina), isto é, fazer com que o computador reconheça e detecte padrões específicos e tome decisões inteligentes, a partir do algoritmo programado (TRYBE, 2020).



(a) Representação Simplificada do Neurônio Biológico

Fonte: Deep Learning Book (2021)



(b) Representação do Neurônio Matemático

Fonte: Deep Learning Book (2021)

Figura 8 – Semelhança de estrutura entre um neurônio biológico e um neurônio matemático

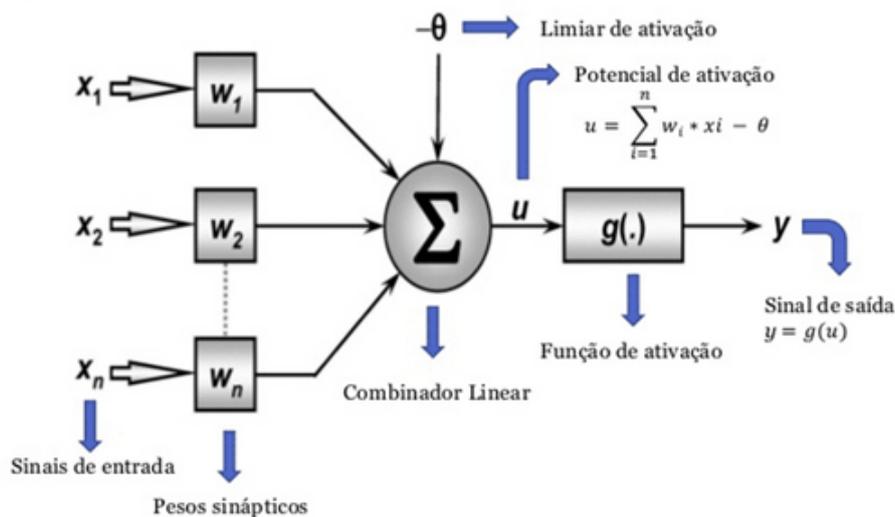
As Redes Neurais Artificiais são utilizadas em diferentes atividades, como por

exemplo a previsão do tempo, a avaliação do cenário econômico e são essenciais para o desenvolvimento de tecnologias modernas. Dessa forma, vale destacar duas classificações das RNA, a Rede Neural Artificial Perceptron e Rede Neural Artificial Perceptron Multicamadas (TRYBE, 2020).

2.4.1 REDE NEURAL ARTIFICIAL PERCEPTRON

A RNA Perceptron, segundo Trybe (2020), é considerado o primeiro modelo de Redes Neurais Artificiais, no qual foi desenvolvido em 1958 pelo psicólogo americano Frank Rosenblatt, que era especialista em inteligência artificial. Este modelo é chamado de linear por apresentar um único neurônio artificial e a forma mais simples de configuração da RNA. Segundo Embarcados (2016), pode-se observar ter N entradas e apenas uma única saída com o valor 0 e 1 ou -1 e 1, conforme visualiza-se na Fig. 9:

Figura 9 – Diagrama da Rede Neural Artificial Perceptron



Fonte: Embarcados (2016)

Assim sendo, o funcionamento deste modelo é bastante simples, os sinais de entrada representado por X representam as informações do processo que será mapeado, sendo cada entrada com um peso sináptico que são os W , que pondera a importância de cada entrada sobre o valor de saída Y . Desta forma, o resultado da soma de todas as entradas será somado ao limiar de ativação θ e assim, repassado como argumento da função de ativação $g(\cdot)$ tendo o resultado de saída esperado. E a função de ativação é do tipo degrau ou degrau linear, que pode-se representar por $y = g(u)$, onde u (EMBARCADOS, 2016):

$$u = \sum_{i=1}^n W_i \times X_i - \theta \quad (2.4)$$

Classificando as entradas X_i como valor real ou binário, os pesos sinápticos W_i com o valor real aleatório, a limiar de ativação θ como valor real aleatório, a saída y como valor binário e a função de ativação $g(\cdot)$ como degrau ou degrau bipolar. Sendo assim, segundo Embarcados (2016), caso o valor final de saída produza o esperado, os pesos sináptico e os limiares proporcionam aos valores dos sinais de entrada.

Já se a saída tiver resultado diferente, os valores são decrementados até alcançar o valor esperado e será utilizado as seguintes equações, no qual η vai representar a taxa de aprendizado ou velocidade do processo e é compreendido entre $0 < \eta < 1$ e K é a k -ésima amostra (EMBARCADOS, 2016):

$$W_i^{atual} = W_i^{anterior} + \eta \times (d^{(k)} - y) \times X^{(k)} \quad (2.5)$$

ou

$$\theta_i^{atual} = \theta_i^{anterior} + \eta \times (d^{(k)} - y) \times X^{(k)} \quad (2.6)$$

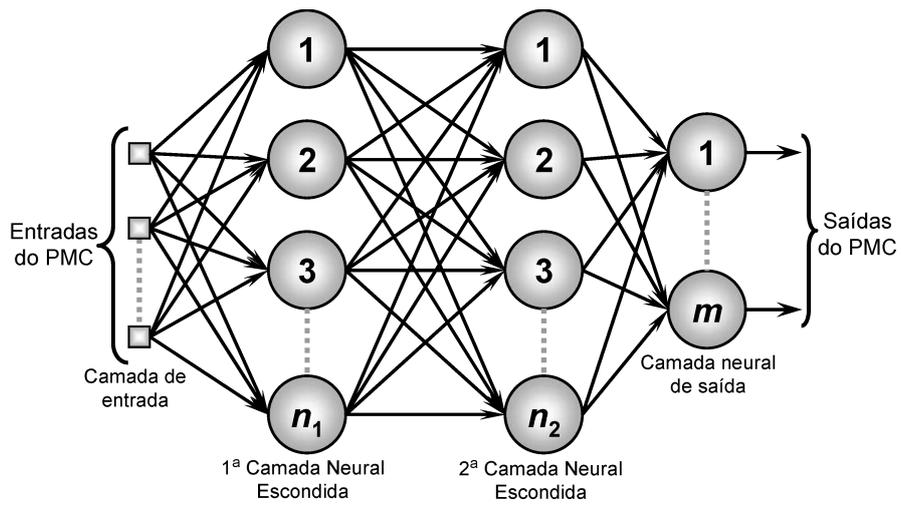
2.4.2 REDE NEURAL ARTIFICIAL *PERCEPTRON MULTICAMADAS*

O modelo de Rede Neural Artificial Perceptron Multicamadas ou Multilayer Perceptron (MLP), são utilizados distintos neurônios artificiais e diversas camadas que se comunicam até que tenha o resultado final, como se ilustra na Fig. 10. Semelhante a rede anterior, a partir da ativação de um neurônio todos são ativadas, entretanto, se relaciona com vários neurônios de saída e não prever o resultado esperado nas camadas intermediárias, no qual pode-se chamar de camada oculta (ENSINA AÍ, 2021).

No treinamento da Rede Neural Artificial MLP é utilizado um algoritmo de retropropagação chamado de Backpropagation e é composto por quatro passos, o primeiro é o de inicialização, onde ocorre a atribuição dos valores distintos para os pesos e limites de w , essa escolha dos valores iniciais influenciará no comportamento da rede neural. O segundo passo é a ativação, no qual calcula os valores neurais tanto da camada oculta, quanto da camada de saída.

O terceiro passo é treinar os pesos, onde calcula os erros dos neurônios das camadas acima – oculta e saída, calcula a correção dos pesos e atualiza os pesos dos neurônios das camadas. E por fim, o quarto passo é a iteração, isto é, repete o processo após o segundo passo até a satisfação do critério de erro.

Figura 10 – Diagrama da Rede Neural Artificial Perceptron Multicamadas



Fonte: Ensina Aí (2021)

3 METODOLOGIA

Neste capítulo será apresentada a metodologia usada para realização do trabalho do documento em questão, no qual realizar-se explicação de todos os programas, dados, recursos e métodos aplicados almejando atingir com mais precisão, o modelo de previsão proposto.

3.1 FERRAMENTAS E DADOS

Foram utilizados um software e uma base de dados. Como ferramenta computacional foi utilizado o software *MATLAB* para os cálculos numéricos e programação da RNA (Redes Neurais Artificiais), com objetivo de construção do modelo de previsão de energia. A base de dados de produção fotovoltaica foi advinda de uma plataforma de monitoramento, *SolarWeb*, onde os dados foram utilizados para aprendizagem da RNA.

3.1.1 SOFTWARE MATLAB

O *MATLAB* (**MA**Trix **LAB**oratory) é uma plataforma de programação desenvolvida especificamente para engenheiros e cientistas para projetar sistemas, analisar e criar produtos (THE MATHWORKS, INC., 2021b).

Um *software* interativo de alta performance direcionado para cálculo numérico. Este *software* integra cálculo de matrizes, processamento de sinais, análise numérica e construção de gráficos, tudo isto em apenas em uma interface, onde soluções matemáticas é a principal aplicação, ao contrário da programação tradicional.

O sistema do *MATLAB* utiliza matrizes como elemento básico de suas operações, assim permite a resolução de variados problemas numéricos em um intervalo muito curto de tempo, conseguindo executar programas e entregar resultados muito mais rápido que utilizando outras linguagens de programação, e com mais uma vantagem, a forma de soluções numéricas é escrita bem semelhante as operações matemáticas usuais.

3.1.1.1 LINGUAGEM DE PROGRAMAÇÃO MATLAB

O *MATLAB* é construído numa linguagem própria, conhecida também por *M-código* ou simplesmente por *M*. A linguagem *M* é uma combinação de muitas linguagens de programação, como C, Java e Basic, e segue de maneira efetiva a forma e aspectos de escrita das linguagens que foram usadas na sua origem, sendo uma vantagem o uso do

MATLAB, pois programadores de outras linguagens usadas para o desenvolvimento da linguagem *M*, não terão dificuldades em se adaptar (THE MATHWORKS, INC., 2021b).

Nesta linguagem as variáveis são definidas dinamicamente, o que significa que as variáveis podem ser atribuídas sem declaração do seu tipo. O *MATLAB* fornece várias maneiras convenientes para a criação de matrizes de qualquer dimensão, como por exemplo matriz com três dimensões ($N \times M \times L$), sendo N , M e L maiores que 1. Em outras linguagens uma matriz pode ser definida como array ou array multidimensional, dependendo da dimensão (THE MATHWORKS, INC., 2021b).

3.1.2 CONJUNTO DE DADOS

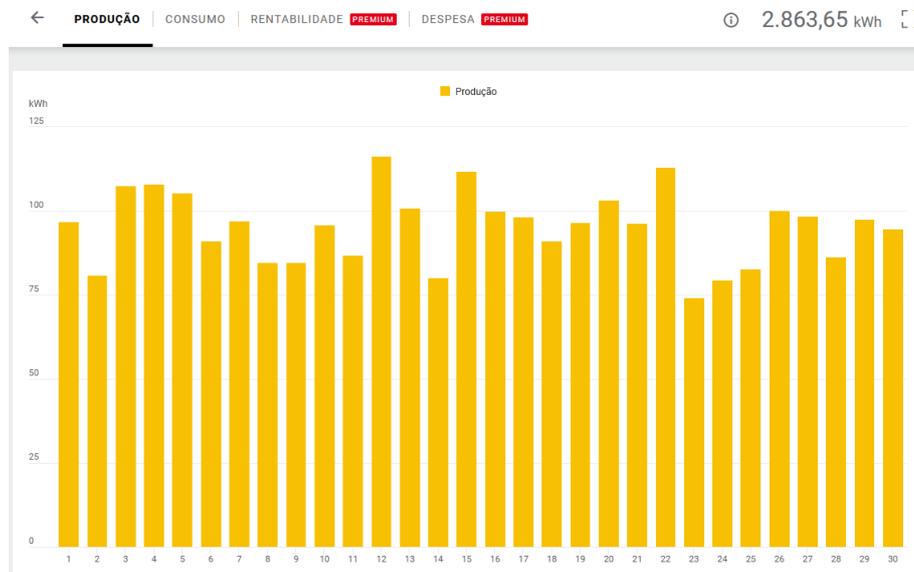
Os dados utilizados para este trabalho foram retirados de uma plataforma de monitoramento de sistemas fotovoltaicos chamada *SolarWeb*, desenvolvida pela *Fronius*, uma empresa austríaca referência na fabricação de inversores para sistemas de geração de energia solar. Esses dados estão disponíveis na plataforma na conta de acesso da empresa Smartsun, integradora no ramo de energia solar, localizada no município de João Pessoa, no estado da Paraíba.

Na Fig. 11 se ilustra a produção energética de um sistema fotovoltaico conectado à rede, no portal da *SolarWeb*, expondo os dados de forma estilizada, mas consegue-se exportar todos os dados envolvendo o sistema fotovoltaico em forma de planilha, e melhor, estruturalmente na forma de uma matriz. O sistema coleta cada medição numa frequência de 1 amostra a cada 05 minutos, informando dados sobre valores decorrentes da geração, dentre eles:

- Corrente alternada (A);
- Corrente contínua (A);
- **Energia (Wh);**
- Potência aparente (VA);

Neste trabalho, especificamente, foi levado em consideração exclusivamente os dados **energia** para a contabilização da produção de energia diária (*energia acumulada diária*), de apenas um sistema fotovoltaico de microgeração conectado à rede, localizado em Serra Negra do Norte, município no interior do Rio Grande do Norte.

Figura 11 – Exemplo de produção energética acumulada diária e mensal de um sistema fotovoltaico no *solar.web*.



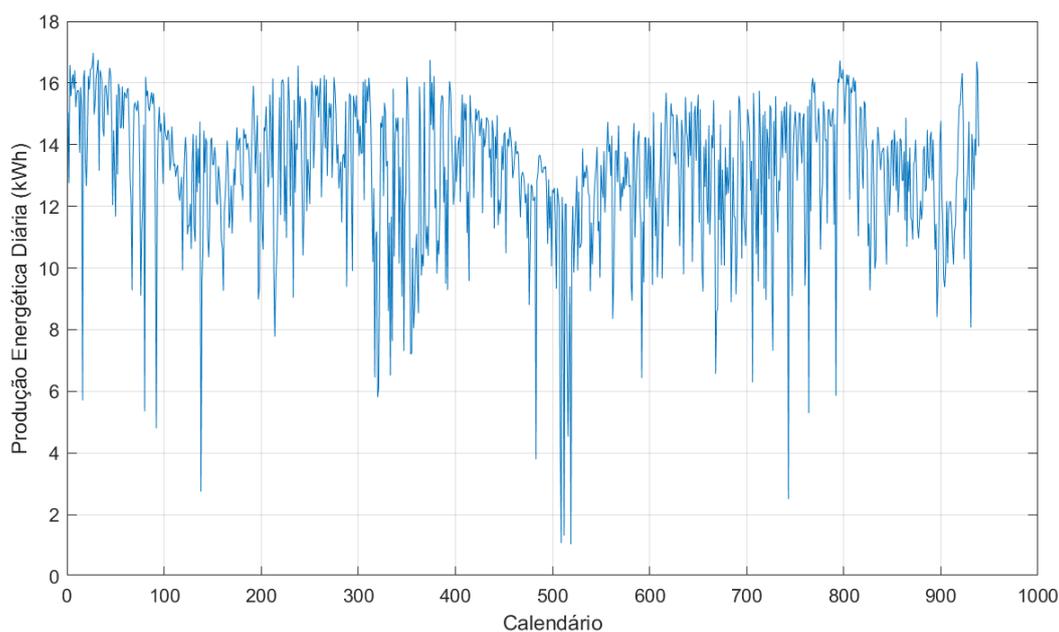
Fonte: Captura de tela do portal da *solar.web*.

Foram coletados os dados de produção de energia elétrica do sistema de microgeração, no período de 01 de agosto de 2018 a 24 de fevereiro de 2021, totalizando 939 dias de medição de produção energética. Estes dados são apresentados na Fig. 12.

Pode-se observar na Fig. 12 que as amostras seguem uma periodicidade (sazonalidade), encontra-se a presença de períodos com um aumento na produção energética (picos positivos) e também períodos que há um decréscimo na produção (picos negativos). Este evento é decorrente das mudanças climáticas na região, de acordo com as estações do ano. Os picos positivos ocorrem no período do verão, os picos negativos se apresentam no inverno e as transições são exatamente no período entre as essas duas estações.

Além das características descritas, há também a existência de outliers, que são ocasionados por motivos como: falta de fornecimento de energia elétrica na unidade consumidora, o não envio de informações ao servidor por falta de conexão com a internet e também a não correta comunicação entre o inversor fotovoltaico e o adaptador de rede responsável por adquirir as variáveis da geração. O resultado dessas faltas geram valores atípicos e extremamente baixos de produção energética, às vezes zerando a produção diária.

Figura 12 – Dados de energia acumulada diária para aprendizagem e validação da RNA.



Fonte: Autoria própria

3.2 MODELO DE PREVISÃO

3.2.1 MODIFICAÇÃO DOS DADOS PARA APRENDIZAGEM

Para aplicar os dados disponíveis à treino e validação, foi-se necessário o tratamento dos dados advindos da plataforma de monitoramento, utilizando as ações que serão explicitadas a seguir.

3.2.1.1 APURAÇÃO DA PRODUÇÃO ENERGÉTICA DIÁRIA

Como foi dito anteriormente, os dados da geração disponíveis são criados e enviados num intervalo de 05 minutos. A variável primária, **energia (Wh)**, conseqüentemente também é enviada neste intervalo e o valor de energia produzida é exposto apenas nesta lacuna de tempo.

Para obter a variável de interesse, **produção de energia diária (kWh)**, teve-se que somar todos os valores de energia produzidos em um único dia, resultando nos valores diários de energia acumulada. Como mostra na Fig. 12.

3.2.1.2 SUAVIZAÇÃO DA CURVA DE PRODUÇÃO ENERGÉTICA DIÁRIA

A geração de um sistema fotovoltaico é de caráter intermitente, onde há muitas incertezas. A disponibilidade da geração durante o dia está sujeita à indeterminação

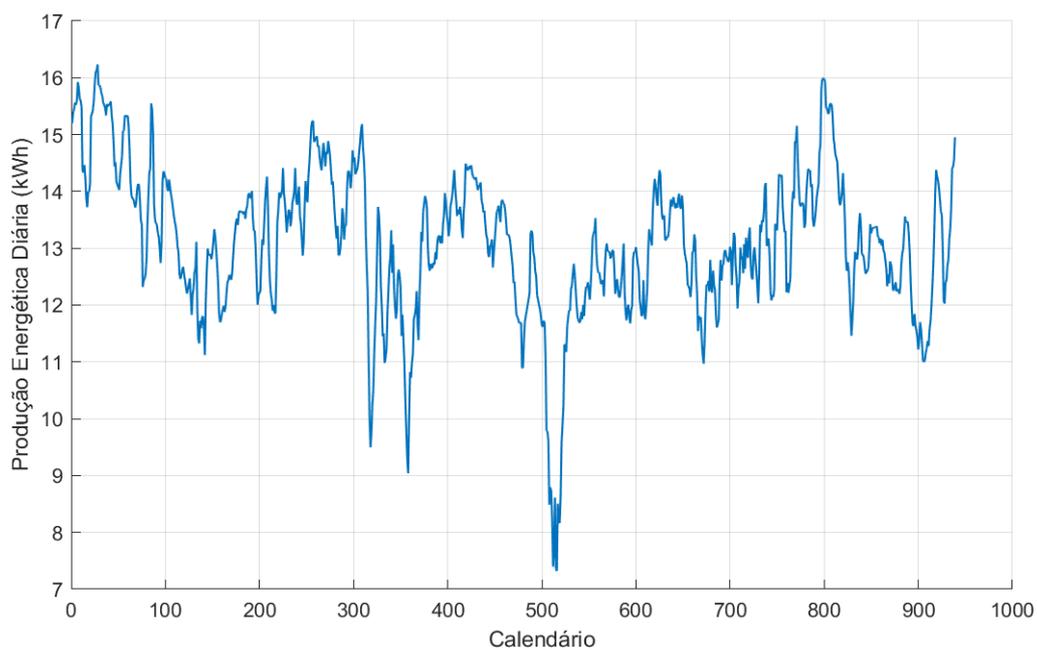
climática, em conjunto ao sombreamento das nuvens, e isso traz um grau elevado de peculiaridade aos dados (VIAN, 2021).

Além dessas peculiaridades advindas de fenômenos da natureza, existem outros motivos que podem diminuir o desempenho do treinamento e aprendizagem dos dados na RNA, como, a falta de fornecimento de energia elétrica no local da unidade, onde todo o sistema é desligado automaticamente para segurança dos operadores da rede, ou a perda de dados no envio das informações geradas pelo inversor fotovoltaico para o servidor na internet.

Para isso utilizou-se um artifício de **média móvel**, onde há a substituição do valor atual pela média dos valores adjacentes, tornando a curva da série de produção energética mais suave e menos aleatória.

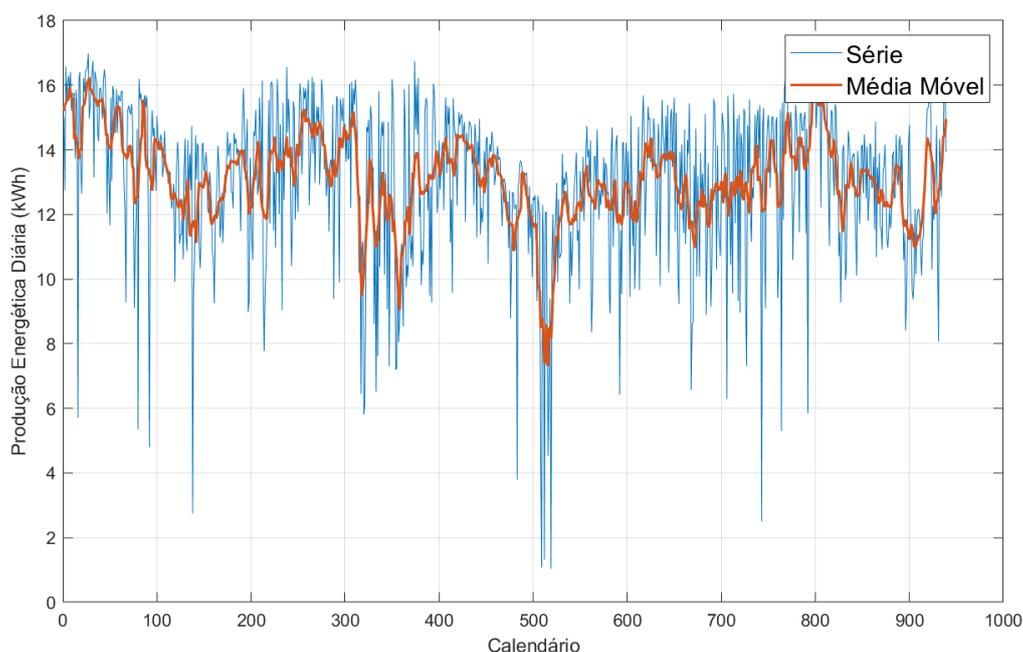
Constata-se como a curva da série ficou sob o efeito da aplicação da média móvel na Fig. 13, e na Fig. 14 apresenta e enfatiza a diferença entre os dois casos das séries de produção de energia diária.

Figura 13 – Série com aplicação da média móvel.



Fonte: Autoria própria

Figura 14 – Comparação das curvas da série sem e com a utilização da média móvel.



Fonte: Autoria própria

Posteriormente será feita a análise e comparação dos resultados da atuação do modelo previsional utilizando os dados da série padrão e a série com a utilização do artifício da média móvel.

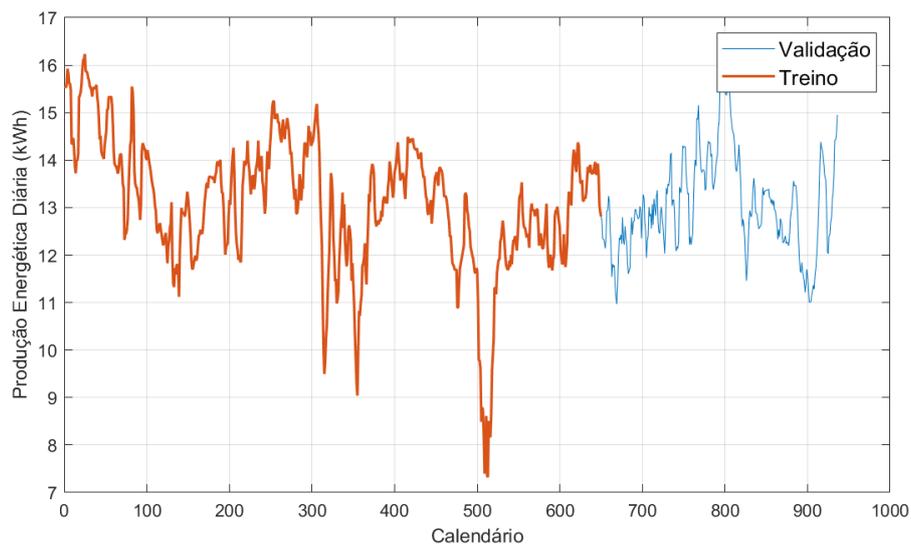
3.2.2 CRIAÇÃO DO BANCO DE DADOS

Para uma melhor utilização da RNA para a aplicação de um modelo previsional, precisa-se de um banco de dados, onde uma parte dos dados são utilizados para treinamento e o complemento são para a validação do funcionamento.

Neste modelo de previsão estudado, pode-se alterar de forma dinâmica a quantidade de amostras anteriores ao evento que pretende-se fazer a previsão, como também quantos eventos futuros devem ser gerados a partir do treinamento da RNA.

O conjunto de dados para este trabalho, como dito anteriormente, tem um número de 939 amostras, e foi decidido o uso de aproximadamente 70% (setenta por cento) das amostras para o uso do treinamento e aproximadamente 30% (trinta por cento) para validação. A Fig. 15 mostra a separação dos dados.

Figura 15 – Separação dos dados para treinamento e validação.



Fonte: Autoria própria

3.2.3 TOPOLOGIA DA RNA

A rede artificial MLP empregada neste trabalho é chamada de *feedforward*. Nesta topologia todos os neurônios de uma mesma camada são conectados com todas as entradas da camada seguinte, além disso, os dados seguem em uma única direção, sem retorno dos cálculos de matrizes para camadas anteriores.

3.2.3.1 PARÂMETROS INTERNOS

A topologia da RNA utilizada se manterá, mas o número de elementos de cada camada que compõe a estrutura da topologia serão variados para o estudos de casos, como também, o algoritmo de treinamento para observação do melhor comportamento da mesma, mas tendo a premissa de seguir sempre o uso de duas camadas de neurônios ocultos. As variações aconteceram nas seguintes camadas:

- Número de entradas;
- Número de saídas;
- Número de neurônios em cada camada oculta;
- Algoritmo de treinamento;

O número de entradas da RNA é relacionado ao número de dias (número de amostras), atual e anteriores, que serão utilizados para obtenção de resultados futuros. Já

o número de saída é o número de dias futuros que se deseja fazer a previsão de produção energética (janela de previsão).

As entradas e saídas se configuram como as equações 3.1 e 3.2, respectivamente:

$$p(k - n), \dots, p(k - 2), p(k - 1), p(k). \quad (3.1)$$

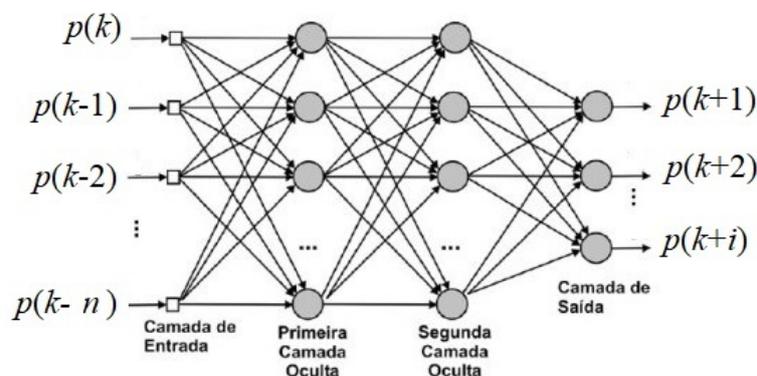
$$p(k + 1), p(k + 2), \dots, p(k + i). \quad (3.2)$$

Onde:

- $p(k)$: amostra atual
- n : quantidade de amostras anteriores
- i : quantidade de amostras futuras.

Como exemplo, tem-se a ilustração de uma topologia semelhante na Fig. 16, onde há disponibilidade de variação do número de amostras e no número neurônios artificiais nas duas camadas ocultas, correlacionando à topologia utilizada.

Figura 16 – Topologia da RNA utilizada.



Fonte: Matheus Facure (2017)

3.2.3.2 CAMADAS DE ENTRADA E SAÍDA

Primeiramente, serão considerados as mudanças nas camadas de entradas e saídas variando o número de amostras para análise dos resultados obtidos da RNA levando em consideração um curto, médio e longo prazo de previsão de produção energética de um sistema fotovoltaico. Serão criadas três combinações dos números de amostras anteriores e futuras como mostra a seguir:

- **Caso 01 (Curto Prazo): 03 (três)** amostras anteriores e **01 (uma)** amostra futura;
- **Caso 02 (Médio Prazo): 30 (trinta)** amostras anteriores e **07 (sete)** amostras futuras;
- **Caso 03 (Longo Prazo): 90 (noventa)** amostras anteriores e **30 (trinta)** amostras futuras;

3.2.3.3 CAMADAS OCULTAS

Posteriormente à análise de cada caso mencionado anteriormente, a mudança interna na topologia da RNA se deverá pela variação nos números de neurônios em cada camada oculta.

- **05 (cinco)** neurônios em cada camada oculta;
- **20 (vinte)** neurônios em cada camada oculta;
- **100 (cem)** neurônios em cada camada oculta.

3.2.3.4 ALGORITMO DE TREINAMENTO

Por último, após os dois passos de variação nas camadas da topologia da rede neural artificial de cada caso, haverá a mudança no algoritmo de treinamento. São eles:

- Levenberg-Marquardt - **trainlm**;
- Resilient Backpropagation - **trainrp**.

3.2.3.4.1 Levenberg-Marquard

O algoritmo *Levenberg-Marquardt* foi projetado para se aproximar da velocidade de treinamento de segunda ordem sem ter que calcular a matriz Hessiana. Quando a função de desempenho tem a forma de uma soma de quadrados, como é típico em redes feedforward de treinamento, então a matriz Hessiana pode ser aproximada como (THE MATHWORKS, INC., 2021a):

$$H = J^T \times J$$

E o gradiente pode ser calculado como:

$$g = J^T \times e$$

Onde \mathbf{J} é a matriz Jacobiana que contém as primeiras derivadas dos erros de rede em relação aos pesos, e \mathbf{e} é um vetor de erros de rede. A matriz Jacobiana pode ser calculada por meio de uma técnica de retropropagação padrão que é muito menos complexa do que calcular a matriz Hessiana (THE MATHWORKS, INC., 2021a).

O algoritmo de Levenberg-Marquardt usa esta aproximação para a matriz Hessiana:

$$x_{k+1} = x_k - [J^T \times J + \mu I]^{-1} \times J^T e$$

De acordo com The MathWorks, Inc. (2021a), quando o escalar μ é zero, a equação equivale ao método de Newton, usando a matriz Hessiana aproximada. Quando μ é um alto valor, torna-se um gradiente descendente com um pequeno tamanho de passo.

O método de Newton é mais rápido e preciso perto de um mínimo de erro, então o objetivo é mudar para o método de Newton o mais rápido possível. Assim, μ é diminuído após cada etapa bem-sucedida (redução na função de desempenho) e é aumentado apenas quando uma etapa provisória aumentaria a função de desempenho.

Desta forma, a função de desempenho é sempre reduzida a cada iteração do algoritmo. Este algoritmo parece ser o método mais rápido para treinar redes neurais feedforward de tamanho moderado, até várias centenas de pesos (THE MATHWORKS, INC., 2021a).

Figura 17 – Matriz Hessiana.

$$H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

Fonte: Matemática II (2012)

3.2.3.4.2 Resilient Backpropagation

O algoritmo *Resilient Backpropagation* pode treinar qualquer rede, desde que suas funções de peso, entrada e transferência tenham funções derivativas. É geralmente muito mais rápido do que outros algoritmos. Também obtém uma boa propriedade de exigir apenas um aumento modesto nos requisitos de memória. O algoritmo precisa armazenar os valores de atualização para cada peso e polarização, o que é equivalente ao armazenamento do gradiente (THE MATHWORKS, INC., 2021a).

A retropropagação é usada para calcular derivados de desempenho em relação às variáveis de peso e polarização. Cada variável é ajustada de acordo com o seguinte:

$$\delta X = \delta X \times \text{sing}(gX);$$

Onde os elementos de δX são todos inicializados para $\delta 0$ e gX é o gradiente. A cada iteração, os elementos do δX são modificados. Um método adaptativo direto para aprendizado de retropropagação mais rápido (THE MATHWORKS, INC., 2021a).

3.2.4 MÉTRICAS DE AVALIAÇÃO

Para facilitar a análise de desempenho do modelo empregado para cada caso que deverá ser estudado e outras comparações, serão usadas as métricas de avaliação de MAPE, Média do Erro Absoluto e o Desvio Padrão.

3.2.4.1 ERRO PERCENTUAL ABSOLUTO MÉDIO - MAPE

O erro percentual absoluto médio (MAPE), é uma medida da precisão de um método de previsão em estatísticas. Geralmente expressa a precisão como uma proporção definida pela Equação (3.3):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - P_t}{A_t} \right| * 100 \quad (3.3)$$

Em que, A_t é o valor atual e P_t é o valor previsto. O valor absoluto neste cálculo é somado para cada ponto previsto no tempo e dividido pelo número de pontos ajustados n . Multiplicar por 100% faz com que seja um erro em porcentagem.

3.2.4.2 MÉDIA DO ERRO ABSOLUTO

A Média do Erro Absoluto utilizada como métrica de avaliação, é uma média aritmética dos erros em seu valor absoluto apresentados entre os dados reais de produção energética diária e os valores de produção diários advindos da previsão do modelo.

A equação para calcular a Média do Erro Absoluto:

$$MEA = \frac{\sum_{t=1}^n |(Pr_i - P_p^i)|}{n} \quad (3.4)$$

Onde:

- Pr_i : produção energética real na posição i ;
- Pp_i : produção energética prevista pelo modelo na posição i ;

- n : número de erros.

3.2.4.3 DESVIO PADRÃO

O Desvio Padrão é um valor que expressa o grau de dispersão de um conjunto de dados, assim ele representa o quanto um conjunto de dados é uniforme. Quanto mais próximo de 0 (zero) for o valor do desvio padrão de um conjunto, mais homogêneos são os dados.

A equação que calcula o desvio padrão é:

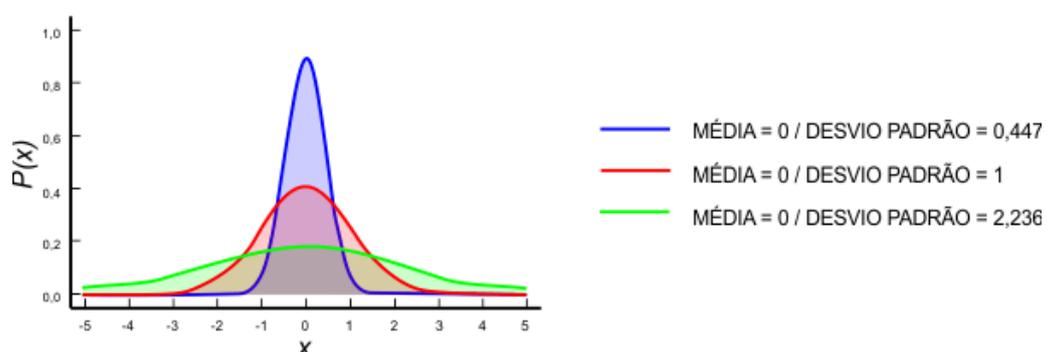
$$DP = \sqrt{\frac{\sum_{i=1}^n (x_i - M_a)^2}{n}}; \quad (3.5)$$

Onde:

- x_i : valor da posição i no conjunto de dados
- M_a : média aritmética dos dados;
- n : quantidade de dados.

A Fig. 18 mostra os diferentes comportamentos da curva do desvio padrão de acordo com o seu valor, observando que quanto mais próximo de zero, a curva tende a ficar mais concentrada na abscissa no valor 0 (zero), relacionando que o conjunto de dados são mais consistentes e homogêneos.

Figura 18 – Diferença de entre distribuições com mesma média e desvios padrão diferentes.



Fonte: Oper (2019)

4 RESULTADOS

Neste capítulo será apresentado os resultados da aplicação do modelo previsional de produção energética de acordo com os dados obtidos de um sistema fotovoltaico conectado à rede, ilustrando, comparando e analisando todas as consequências correlacionadas as mudanças nas camadas da topologia *feedforward* da rede neural artificial.

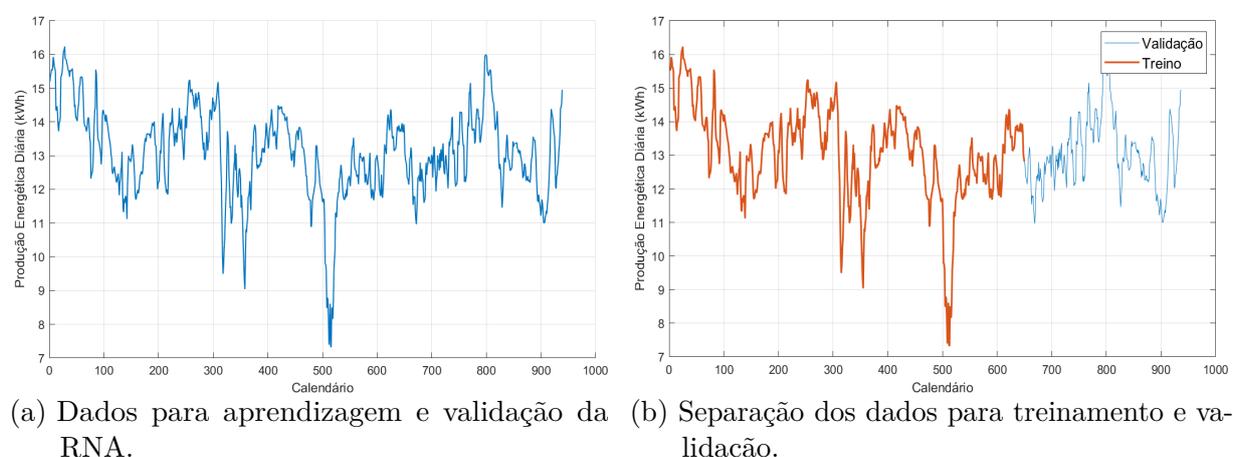
Serão descritos os resultados para os 03 (três) casos construídos: **curto, médio e longo prazo**. Cada caso obtém particularidades, pelo número de dias que o modelo objetiva prever, mas seguem as análises das mudanças nos números de neurônios nas camadas ocultas e no algoritmos de treinamento que foram utilizados, Levenberg-Marquardt e Resilient Backpropagation.

4.1 DESCRIÇÃO DOS DADOS

Para realizar o treinamento, os testes da RNA, e trazer os resultados expostos neste capítulo utilizou-se um conjunto de dados de produção fotovoltaica (produção energética) de um sistema fotovoltaico, localizado no município de Serra Negra, no estado no Rio Grande do Norte. Foram coletados os dados de produção de energia elétrica do sistema, no período de 01 de agosto de 2018 a 24 de fevereiro de 2021, totalizando 939 dias de medições, pode-se observar na figura 19a.

A distribuição dos dados se deu pelo uso de aproximadamente 70% (setenta por cento) das amostras para o treinamento e aproximadamente 30% (trinta por cento) para validação da rede neural. A Fig. 19 ilustra os dados e a separação dos mesmos.

Figura 19 – Utilização dos dados



Fonte: Autoria própria

Fonte: Autoria própria

4.2 CASO 01: PREVISÃO DE CURTO PRAZO

Neste primeiro caso, foi considerado um período de curto prazo, tem-se o objetivo de prever **01 (um) dia** a partir de **03 (três) amostras passadas** de dias de produção energética.

Nesta seção é realizada a análise de como a rede neural se comportou e a comparação dos resultados obtidos para este período de previsão, de acordo com as mudanças na camada de neurônios ocultos e no algoritmos de treinamento. A Tabela 2 apresenta estes resultados utilizando as métricas de avaliação descritas no capítulo anterior e em destaque (células em verde claro e escuro) estão as combinações entre as configurações da topologia da RNA que foram mais eficazes, onde geraram menos discordância entre os dados originais de produção e os dados da previsão realizada pelo modelo de previsão criado.

Tabela 2 – Avaliação de desempenho do modelo de previsão em relação ao **Caso 01**

		Nº Neurônios:		
		05	20	100
Levenberg-Marquardt	MAPE	0.78594%	0.71334%	1.7499%
	MEA	0.12440	0.12804	0.31442
	DESVIO P.	0.13419	0.12262	0.28715
Resilient Backpropagation	MAPE	0.72344%	0.85763%	1.5719%
	MEA	0.11818	0.1268	0.22174
	DESVIO P.	0.12052	0.1407	0.28591

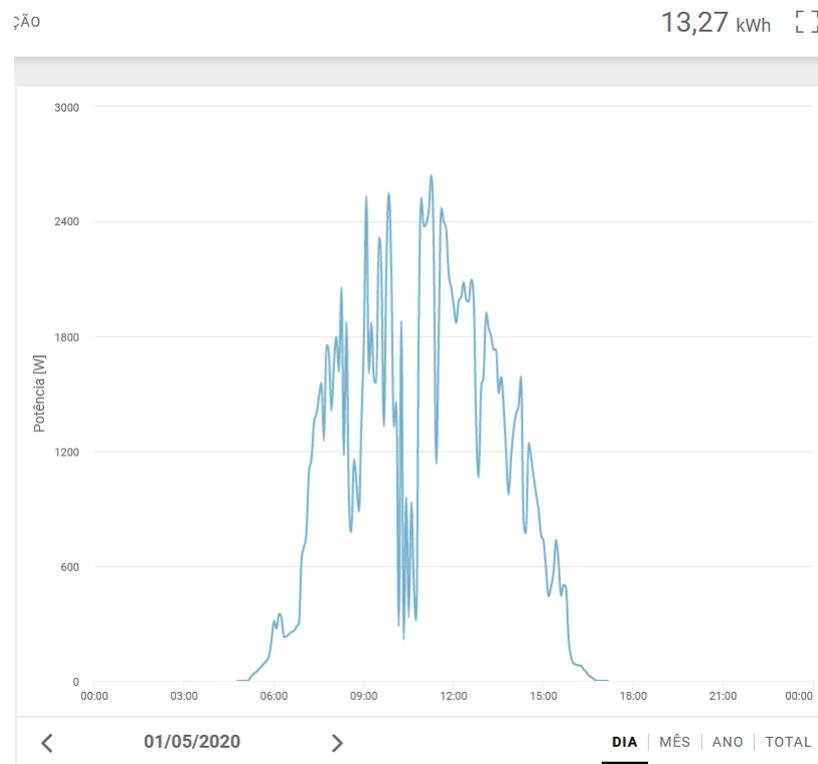
Pode-se verificar dos resultados apresentados na Tabela 2 que dentre os algoritmos de treinamento, o Resilient Backpropagation obteve um melhor desempenho nos critérios de MAPE, MEA do Erro e no Desvio Padrão em duas variações no número de neurônios na camada oculta, entre as três aplicadas. Esses resultados se devem principalmente ao método de cálculo do algoritmo, que utiliza funções derivativas para encontrar os pesos e polarização entre as camadas da topologia.

Observa-se também que a combinação (verde escuro) com **05 (cinco) neurônios em cada camada oculta e utilizando o algoritmo Resilient Backpropagation** obteve maior destaque apesar de apresentar uma perda no MAPE de 0,01010%, mas obteve melhores resultados na MEA e no Desvio Padrão em comparação a configuração que apresenta 20 (vinte) neurônios e utilizando o algoritmo Levenberg-Marquardt, além disto leva-se em consideração a rapidez que o algoritmo Resilient Backpropagation executa o treinamento e previsão, sobrevalendo da pequena porcentagem a mais de erro no MAPE.

Na Fig. 20 pode-se ver a produção energética do sistema fotovoltaico utilizado como fonte deste trabalho no dia 01 de maio de 2020. Este dia equivale a primeira amostra após os dados utilizados para treinamento da RNA e conseqüentemente a primeira amostra dos dados usados para validação. Sabendo-se que o valor de geração deste dia foi de 13,27kWh,

tem-se as comparações entre o dado real na Fig. 20 e as análises estabelecidas anteriormente, de acordo com a Tabela 2. Foram escolhidos os três melhores resultados e apresentados na Fig. 21 e comparando os valores da produção confirma-se que a melhor previsão, exposta na **Fig. 21a**, foi a combinação de configuração da célula verde escura.

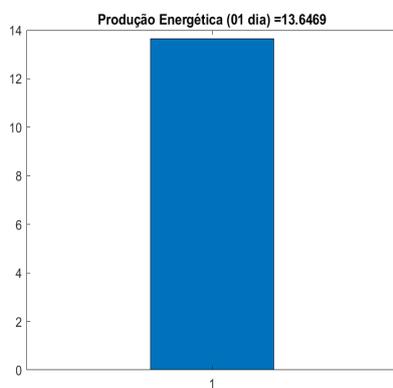
Figura 20 – Produção energética de 13,27 kWh do sistema fotovoltaico no primeiro dia.



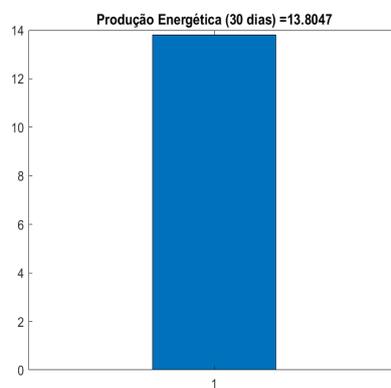
Fonte: Plataforma da Fronius Internacional GmnH (2021)

Figura 21 – Melhores desempenhos nas previsões do modelo relacionado ao **Caso 01**

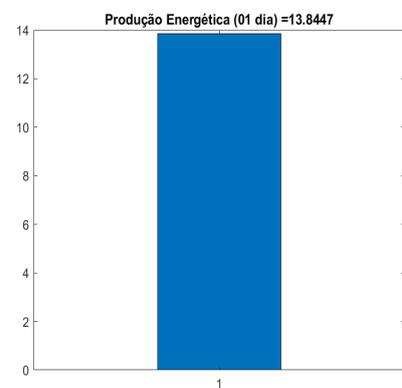
- (a) Previsão: 13.6469kWh;
Nº Neurônios: 05;
Resilient Backpropagation
- (b) Previsão: 13.8047kWh;
Nº Neurônios: 20;
Levenberg-Marquardt
- (c) Previsão: 13.8447kWh;
Nº Neurônios: 100;
Resilient Backpropagation



Fonte: Autoria própria



Fonte: Autoria própria



Fonte: Autoria própria

4.3 CASO 02: PREVISÃO DE MÉDIO PRAZO

No segundo caso, foi considerado um período de médio prazo, com objetivo de prever **07 (sete) dias** a partir de **30 (trinta) amostras passadas** de dias de produção energética.

Seguindo o modo de análise que foi usado na seção anterior, nesta seção também é realizada a análise do comportamento da rede neural e a comparação dos resultados para o período de médio prazo, de acordo com as mudanças nos algoritmos de treinamento e na camada de neurônios ocultos.

Tabela 3 – Avaliação de desempenho do modelo de previsão em relação ao **Caso 02**

		Nº Neurônios:	05	20	100
Levenberg-Marquardt	MAPE		2.8331%	2.1346%	2.4961%
	MEA		0.38841	0.30084	0.29843
	DESVIO P.		0.48079	0.34953	0.43829
Resilient Backpropagation	MAPE		2.2741%	1.8097%	2.1886%
	MEA		0.32664	0.28464	0.29225
	DESVIO P.		0.41227	0.33048	0.36002

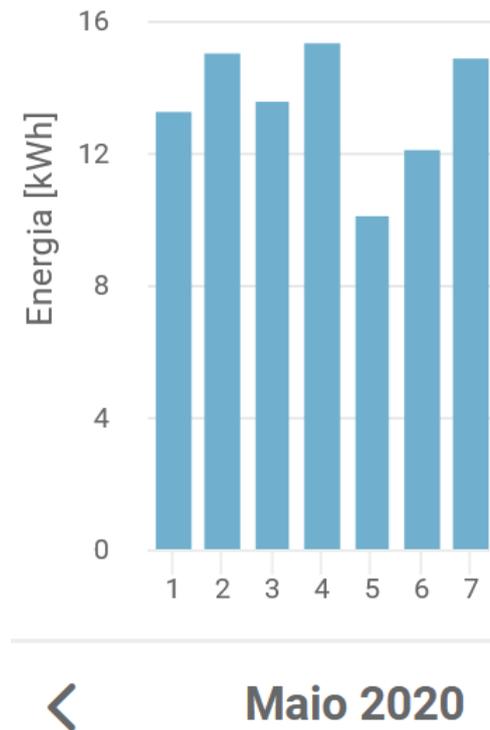
Os resultados apresentados na Tabela 3 conclui-se que dentre os algoritmos de treinamento, o Resilient Backpropagation obteve um melhor desempenho nos critérios de MAPE, MEA e no Desvio Padrão nas três variações no número de neurônios na camada oculta, praticamente repetindo os resultados do Caso 01. Admitindo novamente que esses resultados se devem principalmente ao método de cálculo do algoritmo.

A combinação (verde escuro) com **20 (vinte) neurônios em cada camada oculta e utilizando o algoritmo Resilient Backpropagation** obteve maior destaque por obter melhores resultados no MAPE, MEA e no Desvio Padrão em comparação as outras configurações empregadas.

Para concluir a análise para este caso é apresentada na Fig. 22 a produção energética do sistema fotovoltaico e na Fig. 23 as produções previstas pelo modelo com diferentes configurações nos 07(sete) primeiros dias do mês de Maio de 2020. Estes dias equivalem as sete primeiras amostra após os dados utilizados para treinamento da RNA.

A geração do sistema destes 07 (sete) dias foi de $94,67kWh$, e a combinação da configuração da **Fig. 23b** (célula verde escura) obteve uma produção energética acumulada de $93,9294kWh$, o valor mais próximo do valor real dentre as outras previsões, confirmando as análise estabelecida na Tabela 3.

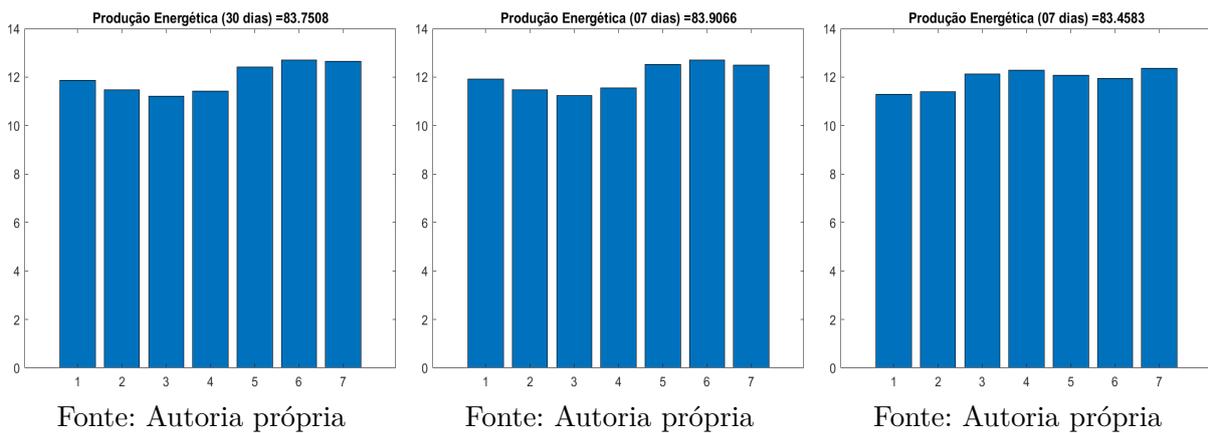
Figura 22 – Produção energética de 94,67 kWh do sistema fotovoltaico nos primeiros 07 dias.



Fonte: Plataforma da Fronius Internacional GmnH (2021)

Figura 23 – Melhores desempenhos nas previsões do modelo relacionado ao **Caso 02**

- (a) Previsão: 83.7508kWh; N^o Neurônios: 05; Resilient Backpropagation
- (b) Previsão: 83.9066kWh; N^o Neurônios: 20; Resilient Backpropagation
- (c) Previsão: 83.4583kWh; N^o Neurônios: 100; Resilient Backpropagation



Fonte: Autoria própria

Fonte: Autoria própria

Fonte: Autoria própria

4.4 CASO 03: PREVISÃO DE LONGO PRAZO

Por último, e terceiro caso, foi considerado um período de longo prazo, tem-se o objetivo de prever **30 (trinta) dias** a partir de **90 (noventa) amostras passadas** de dias de produção energética.

Mantendo o modo de análise e comparações que foram usadas nos casos 1 e 2, neste último caso também é realizada a análise do comportamento da rede neural e apresentação dos resultados para o período de longo prazo, levando sempre em consideração as mudanças nos algoritmos de treinamento e no número de neurônios nas camadas ocultas, como segue a Tabela a seguir.

Tabela 4 – Avaliação de desempenho do modelo de previsão em relação ao **Caso 03**

		Nº Neurônios:	05	20	100
Levenberg-Marquardt	MAPE		4.3185%	4.3275%	2.5878%
	MEA		0.55941	0.54746	0.41684
	DESVIO P.		0.74345	0.68305	0.43106
Resilient Backpropagation	MAPE		6.8041%	2.831%	3.4209%
	MEA		0.59454	0.52248	0.49349
	DESVIO P.		1.105	0.33048	0.42233

Os resultados da Tabela 4 mostra que para o período considerado como "*longo prazo*" o algoritmo de treinamento Levenberg-Marquardt se torna mais eficiente que o algoritmo Resilient Backpropagation, onde consegue obter resultados melhores na maioria dos critérios em duas combinações, trazendo uma perspectiva diferente dos dois primeiro casos.

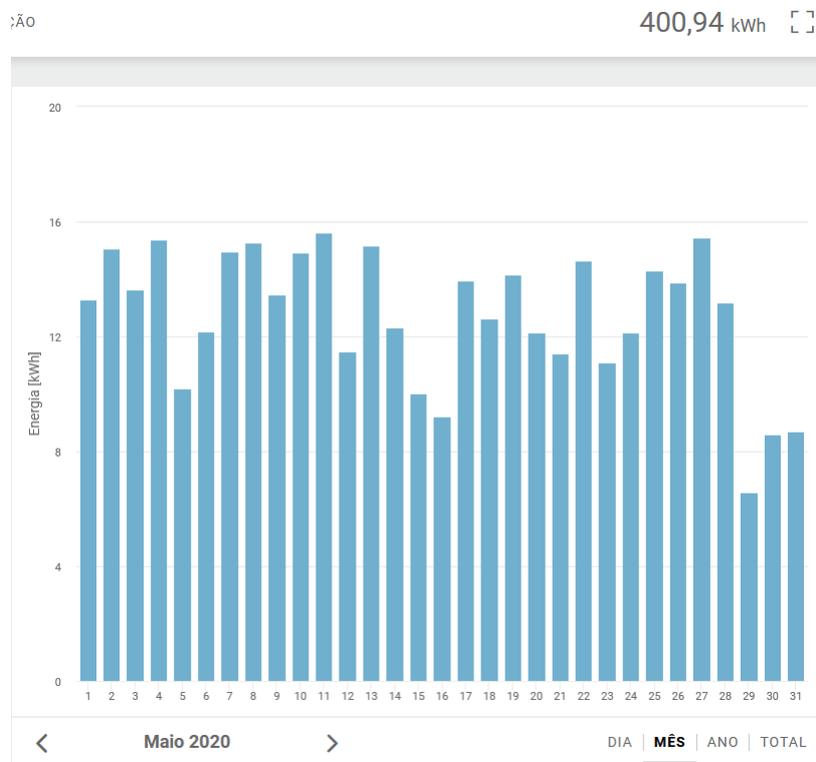
A combinação (verde escuro) com **100 (vinte) neurônios em cada camada oculta e utilizando o algoritmo Levenberg-Marquardt** obteve melhores resultados no MAPE, MEA e no Desvio Padrão em comparação as outras configurações empregadas.

Isso se dá pelo fato de que do método de Levenberg-Marquardt obtém uma forma de cálculo mais densa que o Resilient Backpropagation, sua função de desempenho é considerada mais complexa, mas que a cada iteração a função de desempenho obtém uma redução. Neste caso a recomendação de sua aplicação são para redes que são consideradas de tamanho moderado. Exatamente as configurações que lhe foram empregadas, ao usar um número de amostras maiores de entradas e saídas, como também um maior número de neurônios.

Concluindo as análises para este caso, tem-se na Fig. 24 a produção energética do sistema fotovoltaico e na Fig. 25 as produções previstas pelo modelo nos 30(trinta) dias do mês de Maio de 2020. Explicitando que a geração do sistema no mês foi de 400,94kWh, e de acordo com os resultados da Tabela 4, a combinação da configuração da **Fig. 25c**

(célula verde escura) obteve uma produção energética acumulada de 399,4379kWh, o valor mais próximo do valor real, assim confirmam-se as análises estabelecidas nesta seção.

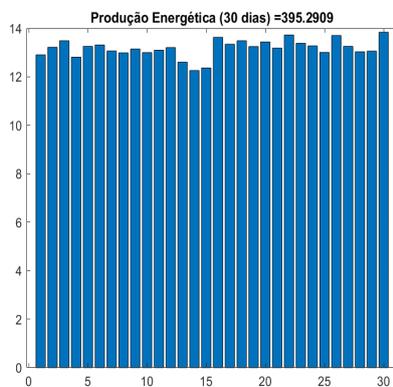
Figura 24 – Produção energética de 400,94 kWh do sistema fotovoltaico nos primeiros 30 dias.



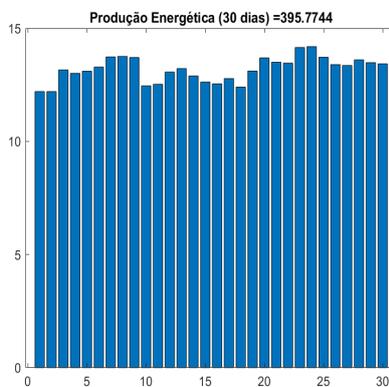
Fonte: Plataforma da Fronius Internacional GmnH (2021)

Figura 25 – Melhores desempenhos nas previsões do modelo relacionado ao **Caso 03**

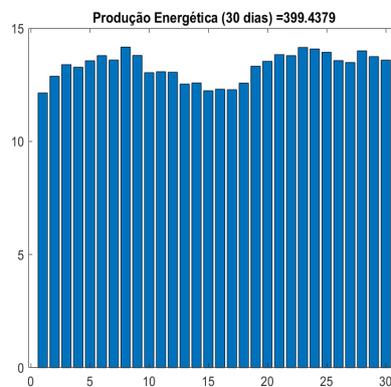
- (a) Previsão: 395.2909kWh;
Nº Neurônios: 05;
Levenberg-Marquardt
- (b) Previsão: 395.7744kWh;
Nº Neurônios: 20;
Resilient Backpropagation
- (c) Previsão: 399.4379kWh;
Nº Neurônios: 100;
Levenberg-Marquardt



Fonte: Autoria própria



Fonte: Autoria própria



Fonte: Autoria própria

4.5 COMPARATIVO: CASOS DE CURTO, MÉDIO E LONGO PRAZO

Neste comparativo, observar-se de maneira geral o comportamento do modelo de previsão estabelecido de acordo com os casos empregados nas análises anteriores, com as análises do modelo para um período de curto, médio e longo prazo, de acordo com os critérios das métricas de avaliação, a Tabela 5 mostra os melhores resultados de cada caso estudado, de acordo com esses critérios.

Tabela 5 – Melhores desempenhos do modelo de previsão nos casos de curto, médio e longo Prazo

		Caso 01	Caso 02	Caso 03
Nº Neurônios:		05	20	100
Levenberg-Marquardt	MAPE	-	-	2.5878%
	MEA	-	-	0.41684
	DESVIO P.	-	-	0.43106
Resilient Backpropagation	MAPE	0.72344%	1.8097%	-
	MEA	0.11818	0.28464	-
	DESVIO P.	0.12052	0.33048	-

De acordo com os dados apresentados na Tabela 5, o modelo de previsão obteve melhor desempenho na configuração (célula verde escura) que tem o objetivo e prever 01 (um) dia (Caso 01) e utilizou o algoritmo de treinamento Resilient Backpropagation com 05 neurônios artificiais em cada camada oculta, resultou em melhores números no MAPE, MEA e no Desvio Padrão em comparação as outros casos de previsão e configurações empregadas.

O método de treinamento Resilient Backpropagation obteve melhor desempenho nos casos de um menor período de previsão, caso 01 e 02, onde contém o objetivo de prever 01 (um) e 07 (sete) dias, respectivamente, e também com número de neurônios artificiais menores, 05 e 20 neurônios. Já o algoritmo de Levenberg-Marquardt obteve mais eficiência no caso 03 (30 dias de previsão) e com a configuração com mais elementos em sua topologia, onde o número de neurônios foi de 100 unidades.

Essa análise nos entrega a conclusão que o algoritmo de treinamento de Levenberg-Marquardt obtém mais sucesso em rede neurais que são consideradas moderadamente grande, as que contém um número maior de elementos em sua topologia, como número de entradas, saídas, número de camadas ocultas e o número de neurônio em cada camada, tudo isso pelo seu método de cálculo de pesos e de polarização, que suas funções e matrizes são mais complexas que o outro método.

O método Resilient Backpropagation se comporta melhor com redes neurais menores,

menos elementos em sua topologia, e sobretudo o suas expressões para cálculos dos pesos são consideradas mais simples e bem mais rápidas que muito outros algoritmos.

4.6 COMPARATIVO: SÉRIE PADRÃO X SÉRIE COM MÉDIA MÓVEL

Nesta seção é feita a comparação dos resultados utilizando as configurações em que houveram melhores desempenhos descritos na seção anterior, utilizando a série com o artifício da média móvel e a série padrão para as mesmas configurações e casos. A Tabela 6 mostra este comparativo.

Tabela 6 – Resultados utilizando a série padrão e a série com média móvel

		Caso 01	Caso 02	Caso 03
Algoritmo de treinamento:		Resilient Backpropagation	Resilient Backpropagation	Levenberg-Marquardt
Nº Neurônios:		05	20	100
Série Média Móvel	MAPE	0.72344%	1.8097%	2.5878%
	MEA	0.11818	0.28464	0.41684
	DESVIO P.	0.12052	0.33048	0.43106
Série Padrão	MAPE	10.0701%	15.7351%	19.5739%
	MEA	1.0726	1.6827	1.6413
	DESVIO P.	1.4159	2.1486	2.9059

A Tabela 6 ajuda na análise que foi-se necessário o uso da série com o artifício de média móvel, onde os resultados e desempenho utilizando a série padrão tem valores maiores envolvendo o erro dos dados de previsão em comparação com os dados reais de produção energética do sistema fotovoltaico.

5 CONCLUSÃO

Neste trabalho monográfico foi apresentado um modelo previsional de produção de energia elétrica de sistemas fotovoltaicos em geral, baseado na utilização de Redes Neurais Artificiais (RNA) para treinamento e aprendizagem dos dados e ter previsões a partir dos dados disponíveis da produção do sistema em um longo período anterior.

Foram construídos três casos relacionados ao período de previsão, considerados como período de curto, médio e longo prazo. Dentro desses casos foram feitas combinações de configurações de mudanças nas camadas da topologia da rede neural, onde tinha-se dois tipos de algoritmos de treinamento, Levenberg-Marquardt e Resilient Backpropagation, como também mudanças no número de neurônios artificiais em cada camada oculta.

Para avaliação e validação dos casos e configurações empregadas, foram as métricas de avaliação de erro, MAPE, MEA e Desvio Padrão. De acordo com a tabela 5, onde apresenta o resultado comparativo dentre os casos construídos e configurações.

O método de treinamento Resilient Backpropagation obteve melhor desempenho nos casos de um menor período de previsão, caso 01 e 02, onde contém o objetivo de prever 01 (um) e 07 (sete) dias, respectivamente, e também com número de neurônios artificiais menores, 05 e 20 neurônios. O algoritmo de Levenberg-Marquardt obteve mais eficiência no caso 03 (30 dias de previsão) e com a configuração com mais elementos em sua topologia, onde o número de neurônios foi de 100 unidades.

Conforme o parágrafo anterior, conclui-se que o algoritmo de treinamento Resilient Backpropagation se comporta melhor com redes neurais menores, menos elementos em sua topologia, e sobretudo o suas expressões para cálculos dos pesos são consideradas mais simples e bem mais rápidas que muito outros algoritmos.

O método de Levenberg-Marquardt obtém um melhor desempenho em rede neurais que são consideradas moderadamente grande, onde contém um número maior de elementos em sua topologia, como número de entradas, saídas, número de camadas ocultas e o número de neurônio em cada camada, tudo isso pelo seu método de cálculo de pesos e de polarização, que suas funções e matrizes são mais complexas que o outro método.

Os resultados da Tabela 5 indica as melhores configurações para cada período de tempo, vale salientar que todas estas configurações obtém resultados satisfatórios de acordo com o objetivo do modelo previsional desenvolvido e estudado neste trabalho, onde os valores de produção energética previstos pelas melhores combinações se aproximam bastante dos valores reais de produção do sistema fotovoltaico conectado à rede usado como base para estudo.

Desta forma, a escolha pela melhor combinação de configuração da rede neural para um melhor desempenho do modelo previsional de produção energética vai depender do período de previsão que o usuário precisará prever.

Este modelo previsional havendo melhorias e implementando uma interface visando o uso para qualquer tipo de usuário, poderá auxiliar o usuário final que podem regular o seu consumo de energia elétrica de acordo com a previsão de produção energética do seu sistema. As empresas que instalam os sistemas fotovoltaicos (integradoras), para análise de desempenho do sistema e abertura de chamados para manutenções preventivas nos equipamentos ou apenas a limpeza dos painéis fotovoltaicos.

Em um emprego mais complexo que seria seu uso pelas concessionárias de energia onde reuniriam a previsão de longo prazo de vários sistemas de uma região para observar a necessidade de melhorias de rede, evitando obras desnecessárias ou a execução das mesma onde haveria necessidade.

Para um trabalho futuro é sugerido:

- Utilização de um modelo de correção de outliers dos dados, para um melhor treinamento da rede neural;
- Utilização de dados meteorológicos em conjunto com as entradas, e também para previsão da produção energética dos sistemas;
- Criação de uma interface voltada para a experiência do usuário;

Por fim, este trabalho monográfico teve grande contribuição na adição de conhecimento adquiridos ao decorrer da graduação de Engenharia Elétrica, enfatizando o aproveitamento na área de automação e sistemas inteligentes. Dessa forma, o conhecimento adquirido na construção desta pesquisa foi de grande valia para a conclusão da graduação, como também, para a prática profissional.

REFERÊNCIAS

- DEEP LEARNING BOOK. *Capítulo 4 – O Neurônio, Biológico e Matemático*. 2021. Disponível em: <<https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>>. Acesso em: 25 de Maio de 2021. Citado na página 28.
- EHLERS, R. S. *Análise de Séries Temporais*. Ricardo Sandes Ehlers, 2003. Disponível em: <<https://sites.icmc.usp.br/ehlers/stemp/stemp.pdf>>. Citado 3 vezes nas páginas 25, 26 e 27.
- EMBARCADOS. *Rede Perceptron de uma única camada - Embarcados*. 2016. Disponível em: <<https://www.embarcados.com.br/rede-perceptron-de-uma-unica-camada/>>. Acesso em: 25 de Maio de 2021. Citado 2 vezes nas páginas 29 e 30.
- ENSINA AÍ. *Rede Neural Perceptron Multicamadas - Ensina Aí*. 2021. Disponível em: <<https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>>. Acesso em: 25 de Maio de 2021. Citado 2 vezes nas páginas 30 e 31.
- FENTIS, A. et al. Simple model for short-term photovoltaic power forecasting using statistical learning approach. In: *2018 Renewable Energies, Power Systems Green Inclusive Economy (REPS-GIE)*. [S.l.: s.n.], 2018. p. 1–6. Nenhuma citação no texto.
- FRONIUS INTERNACIONAL GMNH. *SolarWeb*. 2021. Disponível em: <<https://www.solarweb.com/PvSystems/Widgets>>. Acesso em: 17 de Junho de 2021. Citado 3 vezes nas páginas 46, 48 e 50.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: Otexts, 2018. Citado na página 26.
- IRENA. Future of solar photovoltaic: Deployment, investment, technology, grid integration and socio-economic aspects (a global energy transformation: paper). *International Renewable Energy Agency, Abu Dhabi*, Abu Dhabi, 2019. Disponível em: <https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Nov/IRENA_Future_of_Solar_PV_2019.pdf>. Citado na página 17.
- KASBURG, C.; STEFENON, S. F. Deep learning for photovoltaic generation forecast in active solar trackers. *IEEE Latin America Transactions*, v. 17, n. 12, p. 2013–2019, 2019. Nenhuma citação no texto.
- KHAN, I. et al. Photovoltaic power forecasting based on elman neural network software engineering method. In: *2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. [S.l.: s.n.], 2017. p. 747–750. Nenhuma citação no texto.
- KOVÁCS, Z. L. *Redes Neurais Artificiais: Fundamentos e Aplicações. 4ª Edição*. [S.l.]: Editora Livraria da Física, 2006. Citado 2 vezes nas páginas 27 e 28.
- LUZ SOLAR. *Como funciona o sistema fotovoltaico? - Luz Solar*. 2021. Disponível em: <<https://luzsolar.com.br/como-funciona-o-sistema-fotovoltaico/>>. Acesso em: 13 de Maio de 2021. Citado na página 20.

- MARTINS, R. P.; FERREIRA, V. H.; LOPES, T. T. e. Artificial neural network for probabilistic forecasting of the output power of photovoltaic systems. In: *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*. [S.l.: s.n.], 2018. p. 1–6. Nenhuma citação no texto.
- MATEMÁTICA II. *Matriz Hessiana*. 2012. Disponível em: <<https://sites.google.com/site/m2sanignaciodeloyola/matriz-hessiana>>. Acesso em: 17 de Junho de 2021. Citado na página 41.
- MATHEUS FACURE. *Redes Neurais Feedforward Densas*. 2017. Disponível em: <<https://matheusfacure.github.io/2017/05/15/deep-ff-ann/>>. Acesso em: 15 de Junho de 2021. Citado na página 39.
- NIIMURA, T. et al. Profiling residential pv output based on weekly weather forecast for home energy management system. In: *2012 IEEE Power and Energy Society General Meeting*. [S.l.: s.n.], 2012. p. 1–5. Nenhuma citação no texto.
- OPER. *O que é Desvio Padrão e Erro Padrão?* 2019. Disponível em: <<https://operdata.com.br/blog/desvio-padrao-e-erro-padrao/>>. Acesso em: 22 de Junho de 2021. Citado na página 43.
- OUDJANA, S. H.; HELLAL, A.; MAHAMED, I. H. Short term photovoltaic power generation forecasting using neural network. In: *2012 11th International Conference on Environment and Electrical Engineering*. [S.l.: s.n.], 2012. p. 706–711. Nenhuma citação no texto.
- PEREIRA, E. B. et al. *Atlas Brasileiro de Energia Solar - 2ª ed.* [S.l.]: INPE, 2017. Citado na página 21.
- PINHO, J. T.; GALDINO, M. A. *Manual de Engenharia para Sistemas Fotovoltaicos - Edição Revisada e Atualizada*. [S.l.]: CEPEL - CRESESB, 2014. Citado na página 18.
- PORTAL SOLAR. *Passo a passo da fabricação do Painel Solar - Portal Solar*. 2021. Disponível em: <<https://www.portalsolar.com.br/passa-a-passo-da-fabricacao-do-painel-solar.html>>. Acesso em: 02 de Maio de 2021. Citado na página 17.
- PORTAL SOLAR. *Usina Solar - Portal Solar*. 2021. Disponível em: <<https://www.portalsolar.com.br/usina-solar.html>>. Acesso em: 25 de Maio de 2021. Citado 2 vezes nas páginas 24 e 25.
- SUNVIA. *Sistema solar fotovoltaico - Sunvia*. 2021. Disponível em: <<https://www.sunvienergy.com/servicos/>>. Acesso em: 15 de Maio de 2021. Citado na página 19.
- THE MATHWORKS, INC. *Help Center*. 2021. Disponível em: <<https://www.mathworks.com/help/matlab/>>. Acesso em: 27 de Junho de 2021. Citado 3 vezes nas páginas 40, 41 e 42.
- THE MATHWORKS, INC. *O que é Matlab?* 2021. Disponível em: <<https://www.mathworks.com/discovery/what-is-matlab.html>>. Acesso em: 27 de Maio de 2021. Citado 2 vezes nas páginas 32 e 33.

TRYBE. *Redes Neurais Artificiais: O que são e como funcionam?* - Blog da Trybe. 2020. Disponível em: <<https://blog.betrybe.com/tecnologia/redes-neurais-artificiais/>>. Acesso em: 25 de Maio de 2021. Citado 2 vezes nas páginas 28 e 29.

VIAN, A. *Energia solar: fundamentos, tecnologia e aplicações*. [S.l.]: Edgard Blücher Ltda., 2021. Citado 5 vezes nas páginas 13, 17, 22, 23 e 36.

VILLALVA, M. G. *Energia solar fotovoltaica: conceitos e aplicações - 2^a ed. rev. e atual.* [S.l.]: Érica, 2015. Citado 5 vezes nas páginas 16, 18, 22, 23 e 24.

YADAV, H. K.; PAL, Y.; TRIPATHI, M. Photovoltaic power forecasting methods in smart power grid. In: *2015 Annual IEEE India Conference (INDICON)*. [S.l.: s.n.], 2015. p. 1–6. Nenhuma citação no texto.
