

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**



LUIZ FELIPE BENICHIO DO NASCIMENTO

**ANÁLISE COMPARATIVA ENTRE MODELOS MATEMÁTICOS PARA PAINÉIS
FOTOVOLTAICOS E PREVISÃO DE GERAÇÃO**

VITÓRIA

2022

LUIZ FELIPE BENICHIO DO NASCIMENTO

**ANÁLISE COMPARATIVA ENTRE MODELOS MATEMÁTICOS PARA
PAINÉIS FOTOVOLTAICOS E PREVISÃO DE GERAÇÃO**

Parte manuscrita do Projeto de Graduação do aluno **Luiz Felipe Benichio do Nascimento**, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientador: Prof. Dr. Helder R. O. Rocha

VITÓRIA

2022

LUIZ FELIPE BENICHIO DO NASCIMENTO

**ANÁLISE COMPARATIVA ENTRE MODELOS MATEMÁTICOS PARA
PAINÉIS FOTOVOLTAICOS E PREVISÃO DE GERAÇÃO**

Parte manuscrita do Projeto de Graduação do aluno **Luiz Felipe Benichio do Nascimento**, apresentada ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

COMISSÃO EXAMINADORA

Helder Roberto de O. Rocha

Prof. Dr. Helder R. O. Rocha
Orientador

Jussara Farias Fardin

Profa. Dra. Jussara F. Fardin
Examinador

Rodrigo Fiorotti

Prof. Me. Rodrigo Fiorotti
Examinador

Dedicado aos meus pais, amigos e todos que me acompanharam até aqui. Muito obrigado.

AGRADECIMENTOS

Em primeiro lugar gostaria de agradecer aos meus pais, por sempre estarem ao meu lado nos momentos mais difíceis e por sempre terem me dado todo o suporte necessário para chegar onde estou hoje. Agradeço às minhas irmãs por estarem nessa jornada comigo, também, sempre dando todo o apoio necessário. Amo vocês.

Agradeço à todos os professores que participaram na minha formação, desde os meus primeiros anos de vida. Eles podem ter certeza que cada um teve um papel fundamental na minha educação e formação como pessoa.

Agradeço ao professor Helder, por ter aceitado o desafio e me dado total suporte no desenvolvimento deste trabalho.

Por fim, agradeço aos meus amigos, que estiveram comigo durante todo o caminho da graduação e deixaram essa fase importante da minha vida muito mais alegre e divertida.

RESUMO

No Brasil, a principal fonte de energia ainda são as usinas hidrelétricas e a crise hídrica teve grande impacto no abastecimento de energia. Hoje, a principal solução para essa situação é despachar as usinas termelétricas, fazendo com que o preço da energia para o consumidor aumente, além de causar maiores impactos ambientais. A utilização de fontes de energias renováveis, como a fotovoltaica, faz com que a demanda pelas termelétricas seja reduzida e traz alguns benefícios não só para o cliente final, mas também para o meio ambiente. A utilização de algum tipo de inteligência agregada à geração fotovoltaica já vem sendo utilizada ao redor do mundo, trazendo cada vez mais confiabilidade e previsibilidade às usinas fotovoltaicas, promovendo melhor funcionamento para suas plantas. Neste projeto serão apresentados três modelos matemáticos que representam a potência gerada nos terminais de um módulo fotovoltaico. Para isso, será utilizada uma base de dados com as séries históricas de geração, bem como irradiância e temperatura dos módulos. Com essa base de dados, os modelos matemáticos serão alimentados. A potência gerada através dos modelos matemáticos será comparada com os valores reais através da métrica MAPE, que é uma métrica que avalia percentualmente a média de erros do modelo matemático. Os dados de irradiância e temperatura irão alimentar uma rede neural que fará a previsão desses dados para o dia seguinte. Os dados previsto irão alimentar o modelo matemático que apresentar a menor taxa de erro na métrica MAPE, além de alimentar uma rede neural que aprenderá o comportamento da usina com relação à essas variáveis.

Palavras-chave: Módulos fotovoltaicos. Modelos matemáticos. Redes neurais artificiais. Previsão de geração.

ABSTRACT

In Brazil, the main source of energy is still hydroelectric plants and the water crisis had a great impact on energy production. Today, the main solution to this situation is to turn on the thermoelectric plants, causing the price of energy for the consumer to increase, in addition to increasing the contribution to pollution. The use of renewable energy sources, such as photovoltaics, reduces the demand for thermoelectric plants and brings some benefits not only to the final customer, but also to the environment. The use of some kind of intelligence added to photovoltaic generation has already been used around the world, bringing more and more reliability and predictability to photovoltaic plants, in this way those responsible can guarantee the best operation for their plants. In this project, three mathematical models will be presented that represent the power generated at the terminals of a photovoltaic module. For this, a database will be used that has the generation values, as well as the irradiance and temperature of the modules. With this database, the mathematical models will be fed. The power generated through the mathematical models will be compared with the real values through the MAPE metric, which is a metric that evaluates the average errors of the mathematical model in percentage. The irradiance and temperature data will feed a neural network that will make the prediction of this data for the next day. The predicted data will feed the mathematical model that presents the lowest error rate in the MAPE metric, in addition to feeding a neural network that will learn the plant's behavior in relation to these variables.

Keywords: Photovoltaic modules . Mathematical models . Artificial neural networks. Generation forecast .

LISTA DE ILUSTRAÇÕES

Figura 1 – Participação das fontes na capacidade instalada	10
Figura 2 – Potencia instalada em MW	11
Figura 3 – Evolução da Fonte Solar Fotovoltaica no Brasil	12
Figura 4 – Esquema de uma célula fotovoltaica	15
Figura 5 – Estrutura de uma célula de silício	16
Figura 6 – Curva característica (ou curva I-V) de uma célula fotovoltaica	17
Figura 7 – Circuito equivalente para uma célula fotovoltaica	18
Figura 8 – Associação em série de células fotovoltaicas	20
Figura 9 – Associação em paralelo de células fotovoltaicas	20
Figura 10 – Influência da irradiância solar numa célula de silício cristalino à 25°C	21
Figura 11 – Influência da temperatura da célula fotovoltaica na curva I-V	22
Figura 12 – Inversores fotovoltaicos	23
Figura 13 – Exemplo de uma estação solarimétrica	24
Figura 14 – Estrutura de um neurônio	26
Figura 15 – Organização de uma rede neural artificial	27
Figura 16 – Fluxograma de desenvolvimento do trabalho	31
Figura 17 – Amostra dos dados contidos na base de dados	32
Figura 18 – Irradiância coletada ao longo de um ano na UFV	33
Figura 19 – Irradiância na primeira semana de janeiro no ano de 2021	33
Figura 20 – Temperatura de módulo coletada ao longo de um ano na UFV	34
Figura 21 – Temperatura de módulo na primeira semana de janeiro no ano de 2021	34
Figura 22 – Potência medida ao longo de um ano na UFV	35
Figura 23 – Potência medida na primeira semana de janeiro no ano de 2021	36
Figura 24 – Potência dada pelo <i>Sixth (6th) PV model</i>	37
Figura 25 – Comparação entre <i>6th PV model</i> e potência medida ao longo do ano	38
Figura 26 – Comparação entre <i>6th PV model</i> e potência medida na primeira semana de janeiro	39
Figura 27 – Comparação entre <i>6th PV model</i> e potência medida ao longo do ano após correção do modelo	39
Figura 28 – Comparação entre <i>6th PV model</i> e potência medida na primeira semana de janeiro após correção do modelo	40
Figura 29 – Potência calculada pelo modelo de diodo simples	41
Figura 30 – Comparação entre modelo diodo simples e potência medida ao longo do ano	41

Figura 31 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro	42
Figura 32 – Comparação entre modelo diodo simples e potência medida ao longo do ano após correção do modelo	42
Figura 33 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro após correção do modelo	43
Figura 34 – Potência calculada pelo modelo de diodo simples adaptado	43
Figura 35 – Comparação entre modelo diodo simples adaptado e potência medida ao longo do ano	44
Figura 36 – Comparação entre modelo diodo simples adaptado e potência medida na primeira semana de janeiro	44
Figura 37 – Comparação entre modelo diodo simples e potência medida ao longo do ano após correção do modelo	45
Figura 38 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro após correção do modelo	45
Figura 39 – Comparação entre modelos matemáticos através da métrica MAPE	46
Figura 40 – Previsão de irradiância solar para o dia 01/07/2021	47
Figura 41 – Previsão de temperatura do módulo solar para o dia 01/07/2021	47
Figura 42 – Previsão de potência solar para o dia 01/07/2021 utilizando o modelo matemático	48
Figura 43 – Estrutura da rede neural	48
Figura 44 – Previsão de potência solar para o dia 01/07/2021 utilizando a rede neural	49

LISTA DE ABREVIATURAS E SIGLAS

ABGD	Associação Brasileira de Geração Distribuída
ABSOLAR	Associação Brasileira de Energia Solar Fotovoltaica
ANEEL	Agência Nacional de Energia Elétrica
GD	Geração Distribuída
GW	Gigawatts
MAPE	<i>Mean Absolut Percentage Error</i>
O&M	Operação & Manutenção
UFV	Usina Fotovoltaica

SUMÁRIO


1	INTRODUÇÃO	10
1.1	Trabalhos relacionados	13
1.2	Objetivos	14
1.3	Estrutura do projeto de graduação	14
2	REFERENCIAL TEÓRICO	15
2.1	Células fotovoltaicas e o efeito fotovoltaico	15
2.2	Características elétricas das células fotovoltaicas	16
2.2.1	Curva I-V	16
2.2.2	Parâmetros elétricos	18
2.3	Associações de dispositivos fotovoltaicos	19
2.3.1	Associação em série	19
2.3.2	Associação em paralelo	19
2.4	Parâmetros externos que influenciam nas características elétricas	21
2.4.1	Influência da irradiância solar	21
2.4.2	Influência da temperatura	21
2.4.3	Influência da sujidade	22
2.4.4	Influência do <i>mismatch</i>	22
2.5	Inversores fotovoltaicos	23
2.6	Estação solarimétrica	23
2.7	Modelos matemáticos	24
2.7.1	Métrica MAPE	25
2.8	Redes neurais artificiais	25
3	METODOLOGIA E ETAPAS DE DESENVOLVIMENTO	28
3.1	Modelos matemáticos	29
3.2	Previsão de geração	31
4	BASE DE DADOS	32
4.1	Irradiância [kW/m ²]	32
4.2	Temperatura do módulo fotovoltaico [°C]	33
4.3	Potência medida [W]	35
5	RESULTADOS	37
5.1	Sixth (6 th) PV model	37
5.2	Modelo diodo simples	38

5.3	Modelo diodo simples adaptado	41
5.4	Comparação entre os modelos matemáticos	45
5.5	Previsão dos dados meteorológicos	46
5.6	Previsão da curva de potência	46
5.6.1	Previsão de potência através do modelo matemático	47
5.6.2	Previsão de potência através do treinamento de rede neural	47
6	CONCLUSÃO	50
	REFERÊNCIAS	51

1 INTRODUÇÃO

A matriz elétrica brasileira pode ser considerada predominantemente renovável, isso porque a maior parte da energia elétrica gerada no Brasil é proveniente das usinas hidrelétricas. No ano de 2020 as usinas hidrelétricas representaram mais de 60% da capacidade instalada da matriz elétrica brasileira [1], como mostrado na Figura 1.

Figura 1 – Participação das fontes na capacidade instalada



Fonte: Adaptado de EPE [1].

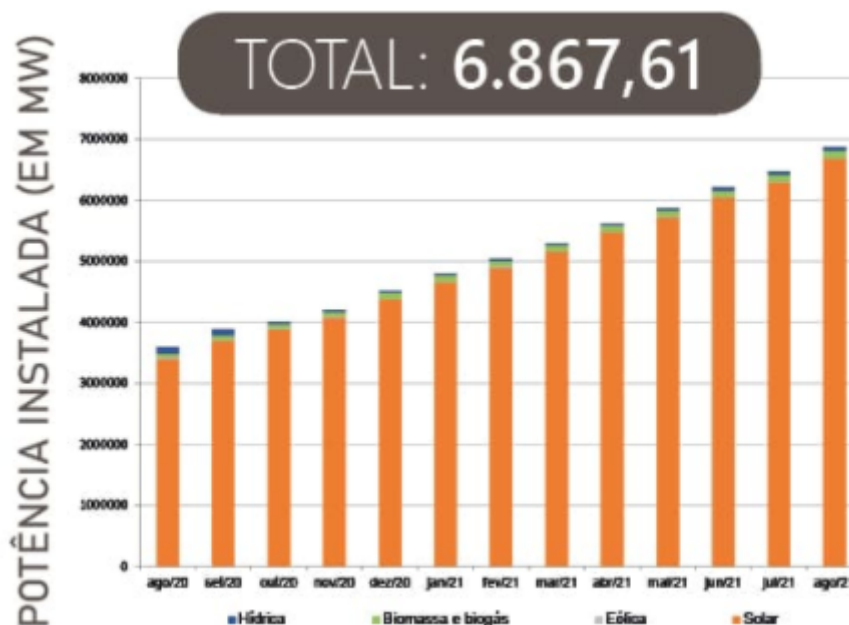
Apesar da grande participação das hidrelétricas em capacidade instalada na matriz elétrica, o Brasil vem sofrendo em 2021 com os baixos níveis dos reservatórios das hidrelétricas, fazendo com que o valor da tarifa de energia repassada para o consumidor seja elevada. Esse aumento é repassado pelo sistema de bandeiras tarifárias que foi adotado no Brasil desde 2015 [2], que prevê um acréscimo no valor da tarifa de energia elétrica de acordo com o nível dos reservatórios das usinas. Quando os níveis das hidrelétricas estão mais baixos, é necessário captar a energia elétrica a partir de outras fontes, como as termelétricas, por exemplo. Esse tipo de usina geralmente utiliza combustíveis fósseis,

como gás natural, tornando o processo de geração de energia elétrica menos eficiente, mais poluente e caro.

Visando reduzir o custo com energia elétrica, muitos consumidores passaram a adotar algum tipo de geração distribuída (GD). No Brasil, a implementação de GD na rede elétrica teve um grande crescimento a partir de 2012, quando a Resolução Normativa nº 482/2012 da Agência Nacional de Energia Elétrica (ANEEL) entrou em vigor. A resolução estabeleceu as regras de ligação de sistemas fotovoltaicos distribuídos e troca de energia gerada com a rede da concessionária de energia [3], além dos critérios para o sistema de compensação de energia elétrica, em que o consumidor reduz do valor da sua fatura de energia à medida que vai gerando energia elétrica nos módulos fotovoltaicos. Se a energia injetada na rede for maior do que a energia consumida, será criado um crédito de energia, que não pode ser revertido em dinheiro, mas pode ser utilizado para reduzir o consumo de outras unidades, com a mesma propriedade, ou na mesma unidade consumidora, nos meses seguintes, desde que todas as unidades estejam todas na mesma área de concessão, com validade de 60 meses [4].

Com a possibilidade de converter em créditos, a energia gerada e com a queda no valor do sistema fotovoltaico, a participação da GD na matriz elétrica brasileira vem crescendo de forma considerável e, no último ano, teve um crescimento de praticamente 3 gigawatts (GW) [5], como pode-se ver na Figura 2.

Figura 2 – Potencia instalada em MW




Fonte: Adaptado de ABGD [5].

A cada ano que passa, a quantidade de sistemas de GD fotovoltaica ligados à rede cresce [5] e, com a redução dos custos pra implantar a geração fotovoltaica, ela acaba se tornando uma opção interessante para o mercado livre de energia do Brasil. Devido à queda nos preços dos equipamentos e à acirrada competição no mercado, os preços das

fontes fotovoltaicas têm se tornado cada vez mais competitivos e inferiores aos de outras fontes renováveis como pequenas centrais hidrelétricas, centrais geradoras hidrelétricas e biomassa [6]. Com isso, UFVs passaram a ser construídas cada vez mais no Brasil, como é observado na Figura 3.

Figura 3 – Evolução da Fonte Solar Fotovoltaica no Brasil



Fonte: ANEEL/ABSOLAR, 2021 [7]

Com o grande crescimento que a GD fotovoltaica teve nos últimos anos, começaram a surgir diversos tipos de serviços e, dentre eles, surgiu o serviço de Operação Manutenção (O&M) de Usinas Fotovoltaicas (UFVs), esses serviços envolvem limpeza dos módulos fotovoltaicos, monitoramento da potência gerada pelos inversores, gestão de manutenção preventiva, manutenção corretiva, dentre outros. Esse tipo de serviço é de grande importância para os proprietários de UFVs, tendo em vista o fato de que se as usinas não operarem corretamente, irão gerar menos e, por consequência, gerar prejuízo ao cliente. Dito isto, é importante ter uma referência de quanto uma usina deveria estar gerando para que a equipe responsável pelo monitoramento possa direcionar suas atuações quando uma usina não está gerando de forma esperada. Para tal, é importante fazer as simulações da

geração dos painéis fotovoltaicos utilizando modelos matemáticos que consigam representar fielmente o funcionamento dos painéis fotovoltaicos.

Com as usinas ficando cada vez maiores, e os proprietários movimentando cada vez mais dinheiro ao vender energia elétrica para o mercado livre de energia, cada perda de geração se reverte em grandes prejuízos financeiros e, por isso, é importante implementar o máximo de inteligência para que se tenha uma referência confiável no momento de simular o quanto uma usina deveria estar gerando. Para isso, a escolha de um bom modelo matemático é essencial.

Com os modelos matemáticos em mãos, um leque de possibilidades se abre para a GD fotovoltaica, como por exemplo o treinamento de redes neurais para análise preditiva de manutenção, reconhecimento de falhas, entre outros.

1.1 Trabalhos relacionados

Em [8], o autor utiliza um modelo matemático para aproximar a geração de um modelo fotovoltaico e, com isso prever a geração com um dia de antecedência. Essa previsão vem a ser interessante no meio dos negócios pois dá uma prévia aos empreendedores do quanto a usina dele deve produzir, mas pode acontecer de o modelo matemático utilizado nas simulações não ser fiel ao sistema real, sendo necessário buscar o modelo matemático que mais se aproxime da usina real.

Em [9], o autor compara diversos modelos matemáticos para painéis fotovoltaicos, cada um tendo sua particularidade, mostrando que quanto mais complexo um modelo é, mais fiel ao caso real ele se torna. Com isso, encontrar o modelo matemático que tenha uma pequena taxa de erro com relação aos valores reais e alimentar uma inteligência artificial com os resultados, resultará num modelo de previsão mais robusto e mais fiel à usina real.

Em [10] é mostrada a importância de alimentar uma inteligência artificial para criar um modelo digital da usina. Na Índia, por exemplo, com o intuito de evitar instabilidades na rede elétrica, os donos das grandes UFVs são obrigados a enviar ao operador do sistema de energia elétrica uma previsão de geração com um dia de antecedência e, caso não o faça ou erre na previsão por mais de 15 %, o proprietário da UFV sofre penas legais.

Em [11], o autor implementa modelos estatísticos com Redes Neurais Artificiais (RNA) para as previsões de velocidade de vento e de geração eólica de curtíssimo prazo para a Usina Eólico-Elétrica de Palmas (PR). Neste trabalho, o autor consegue resultados satisfatórios de previsibilidade, avaliados através da métrica MAPE, de geração com até seis horas de antecedência.

1.2 Objetivos

O objetivo geral deste trabalho é avaliar, através da métrica MAPE, três modelos matemáticos para geração de painéis fotovoltaicos (potência injetada no inversor) e, para aquele que apresentar o melhor desempenho, aplicar redes neurais para fazer previsão de geração.

Para dar cumprimento ao objetivo geral formulado, são definidos os objetivos específicos a seguir:

- Adquirir uma base de dados para alimentar os modelos matemáticos.
- Através da ferramenta Matlab, usar os modelos matemáticos desenvolvidos para simular a geração e comparar os resultados com os dados reais de geração, avaliando o resultado de cada um através da métrica MAPE.
- Alimentar uma rede neural com o modelo matemático de melhor desempenho para realizar uma previsão de geração com um dia de antecedência.

1.3 Estrutura do projeto de graduação

Este projeto está estruturado da seguinte forma: No Capítulo 2 estão descritos os principais referenciais teóricos que embasam o trabalho. No Capítulo 3 é mostrada a metodologia que define o fluxo de trabalho neste projeto. No Capítulo 4 é apresentada a base de dados utilizada para alimentar os modelos matemáticos. No Capítulo 5 os resultados são apresentados e as análises são feitas. E, por fim, no Capítulo 6 têm-se as conclusões deste trabalho e sugestões para trabalhos futuros.


2 REFERENCIAL TEÓRICO

Nesse Capítulo é apresentada a revisão de alguns conceitos necessários para o entendimento deste projeto, por exemplo, as partes que compõem um sistema fotovoltaico, modelos matemáticos e redes neurais.

2.1 Células fotovoltaicas e o efeito fotovoltaico

Células fotovoltaicas são fabricadas com material semicondutor, que é um material com características intermediárias entre um condutor e um isolante [12]. Normalmente, o silício se apresenta como areia, mas através dos meios adequados consegue-se adquirir o silício em sua forma pura. Por não possuir elétrons livres, o silício acaba sendo um mal condutor elétrico e, para alterar isso, são acrescentadas porcentagens de outros elementos ao silício. É dado a esse processo o nome de dopagem. Dopando o silício com o elemento fósforo, que possui elétrons livres, obtém-se um material resultante com portadores de carga negativa, o silício tipo N. Realizando o mesmo processo, mas agora dopando o silício com Boro, é obtido um material com falta de elétrons (ou portador de cargas positivas), o silício tipo P [13]. Cada célula fotovoltaica é composta de uma camada fina do material tipo N e outra mais espessa do material tipo P, como mostra a Figura 4.

Figura 4 – Esquema de uma célula fotovoltaica



Fonte: Adaptado de NASCIMENTO (2004) [12]

Separadas, as “metades” da célula fotovoltaica são eletricamente neutras, porém quando são unidas como na Figura 4, surge uma região P-N onde forma-se um campo elétrico devido aos elétrons livres do silício tipo N ocuparem as lacunas presentes no silício tipo P. Quando uma luz incide sobre a célula fotovoltaica, os fótons colidem com os elétrons


presentes na estrutura do silício e os fornecem energia o suficiente para o material se tornar condutor e, devido ao campo elétrico gerado na região P-N, os elétrons se orientam e passam a fluir da camada P para a camada N [13].

Enquanto houver luz incidente na célula fotovoltaica, se existir um circuito elétrico externo ligando a camada P à camada N, haverá uma corrente elétrica de intensidade proporcional à quantidade de luz que incide sobre a célula [14].

É importante frisar que uma célula fotovoltaica não armazena energia elétrica, mas apenas mantém um fluxo de elétrons estabelecidos num circuito elétrico enquanto houver incidência de luz sobre ela. Este fenômeno é denominado “Efeito fotovoltaico” [12].

Na Figura 5 pode-se ver a estrutura de uma célula fotovoltaica de silício:

Figura 5 – Estrutura de uma célula de silício



Fonte: Adaptado de PINHO E GALDINO (2014) [14]

2.2 Características elétricas das células fotovoltaicas

2.2.1 Curva I-V

A corrente elétrica em uma célula fotovoltaica pode ser descrita como a diferença entre a corrente gerada pelo efeito fotovoltaico e a corrente de uma junção PN no escuro (diodo semiconductor) [14]. Colocando essa corrente em função da tensão na célula fotovoltaica,

obtêm-se a curva I-V, também chamada de curva característica, que pode ser descrita pela equação (2.1):

$$I = I_L - I_0 \left[\exp\left(\frac{qV}{nkT}\right) - 1 \right] \quad (2.1)$$

Onde:

I_L - corrente fotogerada (A);

I_0 - corrente de saturação reversa do diodo (A);

n - fator de idealidade do diodo, adimensional, obtido através de dados experimentais medidos;

q - carga do elétron ($1,6 \times 10^{-19} \text{C}$);

k - constante de Boltzmann ($1,38 \times 10^{-23} \text{J/K}$);

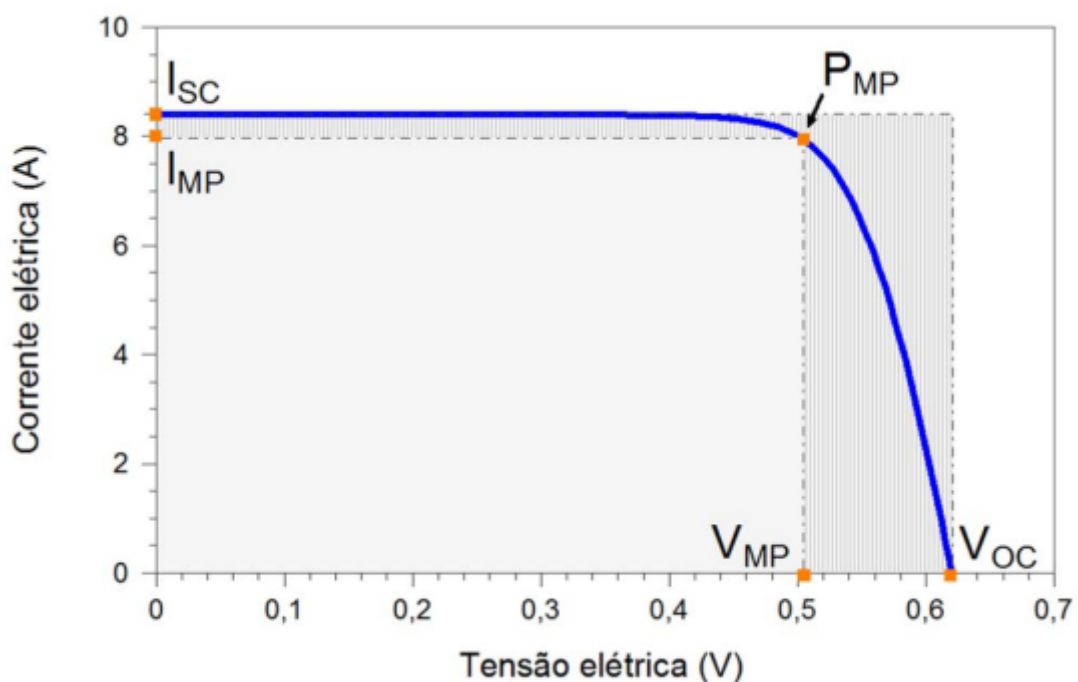
T - temperatura absoluta (K).

Pelo fato de em uma célula fotovoltaica existir resistência em série devido à junção metal-semicondutor, malhas metálicas, regiões dopadas, entre outros e resistência em paralelo devido a pontos de curto-circuitos na junção PN [14], a equação da curva característica ganha novos termos e passa a ser:

$$I = I_L - I_0 \left[\exp\left(\frac{q(V + IR_S)}{nkT}\right) - 1 \right] - \frac{V + IR_S}{R_P} \quad (2.2)$$

Onde R_S e R_P são as resistências série e paralelo, respectivamente.

Figura 6 – Curva característica (ou curva I-V) de uma célula fotovoltaica




Fonte: Adaptado de PINHO E GALDINO (2014) [14]

A Figura 6 mostra a curva I-V de uma célula fotovoltaica e traz também alguns pontos importantes marcados na curva, que serão discutidos mais adiante nesse trabalho.

A célula fotovoltaica possui um modelo de circuito elétrico equivalente que traduz o comportamento da sua curva característica. Esse circuito é formado por uma fonte de corrente I_L , que representa a corrente gerada pelo efeito fotovoltaico, por um diodo D que representa o diodo semicondutor (junção PN no escuro, pela resistência em série R_S e pela resistência em paralelo R_P . A Figura 7 mostra como o circuito equivalente é montado:

Figura 7 – Circuito equivalente para uma célula fotovoltaica



Fonte: Adaptado de PINHO E GALDINO (2014) [14]

2.2.2 Parâmetros elétricos

Como dito anteriormente, na Figura 6 existem alguns pontos marcados que são importantes. Esses pontos indicam a tensão de circuito aberto (V_{OC}), a corrente de curto-circuito (I_{SC}) e com eles pode-se calcular o fator de forma (FF) da célula fotovoltaica.

- Tensão de circuito aberto (V_{OC}): é a tensão entre os terminais da célula fotovoltaica quando a corrente circulando por ela é igual a zero. É a máxima tensão que pode ser adquirida nos terminais de uma célula fotovoltaica [13].
- Corrente de curto-circuito (I_{SC}): é a maior corrente que se pode medir em uma célula fotovoltaica, quando a tensão entre seus terminais é igual a zero. Pode ser medida curto-circuitando os terminais da célula com um amperímetro, por exemplo [13].
- Fator de forma (FF): é determinado pela razão entre a máxima potência da célula e o produto entre a tensão de circuito aberto e a corrente de curto-circuito [13]. Quanto menores forem as perdas resistivas, mais próxima de um retângulo será a curva I-V da célula. O FF é definido pela equação (2.3):

$$FF = \frac{V_{MP} I_{MP}}{V_{OC} I_{SC}} \quad (2.3)$$

Onde:

V_{MP} - tensão de máxima potência;

I_{MP} - corrente de máxima potência.

2.3 Associações de dispositivos fotovoltaicos

Dispositivos fotovoltaicos podem ser associados em série ou paralelo a fim de obter os níveis desejados de tensão e corrente. Segundo a norma NBR10899, o módulo fotovoltaico é um dispositivo formado por um conjunto de células fotovoltaicas associadas eletricamente e encapsuladas, com o objetivo de gerar energia elétrica [14]. Além disso, os módulos fotovoltaicos podem ser associados em série ou paralelo com a finalidade de obter os níveis de tensão e corrente desejados. A associação de módulos fotovoltaicos é chamada de arranjo fotovoltaico ou painel fotovoltaico.

2.3.1 Associação em série

Na associação em série, o terminal positivo de um dispositivo fotovoltaico é conectado ao terminal negativo de outro dispositivo fotovoltaico e assim sucessivamente. Para dispositivos idênticos, ou seja, com as mesmas características construtivas, a associação em série faz com que a tensão dos dispositivos associados seja igual à soma das tensões de todos os dispositivos, equação (2.4), e a corrente seja a mesma, equação (2.5). A Figura 8 ilustra o efeito da associação em série dos dispositivos fotovoltaicos.

$$V = V_1 + V_2 + V_3 + \dots + V_n \quad (2.4)$$

$$I = I_1 = I_2 = I_3 = \dots = I_n \quad (2.5)$$

Onde:

V – tensão total da associação;

I – corrente total da associação.

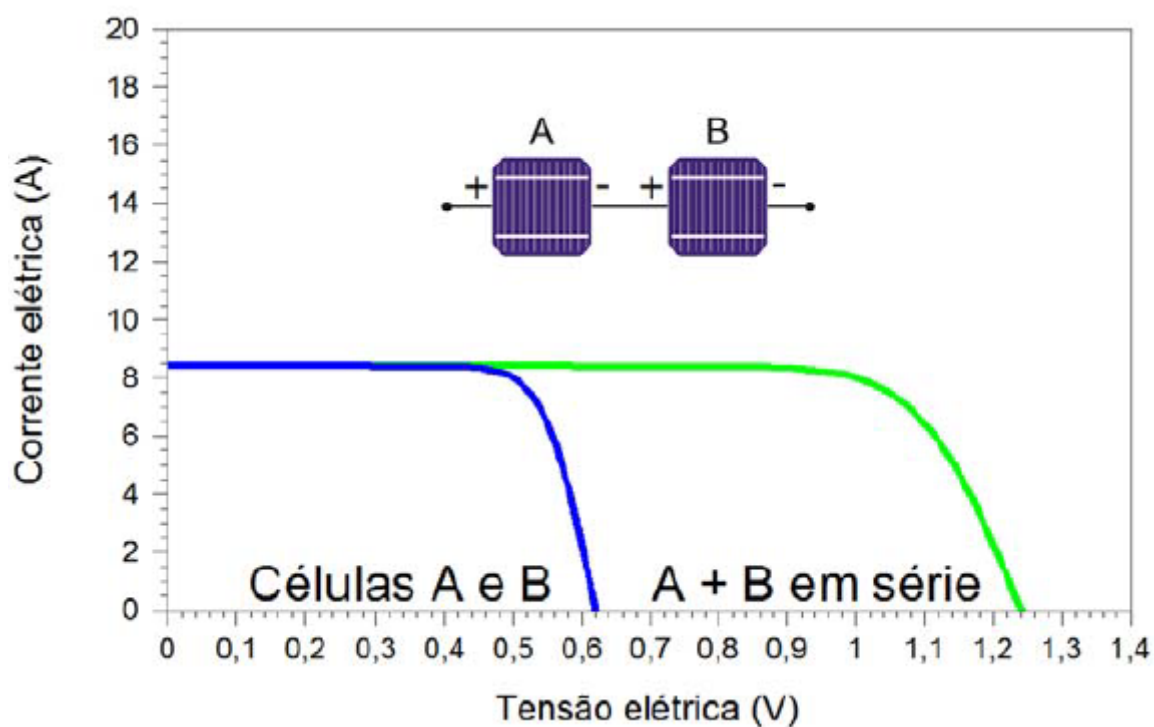
2.3.2 Associação em paralelo

Na associação em paralelo os terminais positivos dos dispositivos são interligados entre si, assim como os terminais negativos. Nesse caso, as correntes são somadas, equação (2.6), enquanto a tensão da associação permanece inalterada, equação (2.7). A Figura 9 ilustra o efeito da associação em paralelo dos dispositivos fotovoltaicos.

$$I = I_1 + I_2 + I_3 + \dots + I_n \quad (2.6)$$


$$V = V_1 = V_2 = V_3 = \dots = V_n \quad (2.7)$$

Figura 8 – Associação em série de células fotovoltaicas



Fonte: Adaptado de PINHO E GALDINO (2014) [14]

Figura 9 – Associação em paralelo de células fotovoltaicas



Fonte: Adaptado de PINHO E GALDINO (2014) [14]


2.4 Parâmetros externos que influenciam nas características elétricas

O desempenho das células fotovoltaicas é diretamente afetado por fatores externos que influenciam tanto em sua tensão quanto em sua corrente. As células fotovoltaicas são afetadas principalmente pela exposição à radiação solar e pela temperatura de operação das células [14].

2.4.1 Influência da irradiância solar

A capacidade de geração de corrente elétrica de uma célula fotovoltaica cai linearmente à medida que a irradiância solar é reduzida. Na Figura 10, é possível observar o comportamento da curva característica I-V de uma célula fotovoltaica de silício cristalino à temperatura de 25°C [14].

Figura 10 – Influência da irradiância solar numa célula de silício cristalino à 25°C




Fonte: Adaptado de CRESESB (2004) [13]

2.4.2 Influência da temperatura

O aumento da irradiância incidente e/ou da temperatura ambiente causa uma elevação de temperatura de operação da célula fotovoltaica e, conseqüentemente, tende a reduzir sua eficiência. Isto se deve ao fato de que a tensão na célula cai significativamente com o aumento da temperatura, enquanto que a corrente permanece praticamente inalterada. Na Figura 11, pode se observar o efeito da temperatura em uma célula de silício cristalino para uma irradiância de $1000W/m^2$ [14].

Figura 11 – Influência da temperatura da célula fotovoltaica na curva I-V



Fonte: Adaptado de CRESESB (2004) [13]

2.4.3 Influência da sujeira

A sujeira na superfície dos módulos fotovoltaicos afeta diretamente a geração de energia. A incrustação pode levar a uma redução da irradiância solar absorvida pelas células que compõem um módulo fotovoltaico e, em casos extremos, pode levar a sombras parciais que se tornam pontos quentes, elevando o estresse térmico nas células, o que pode levar ao desenvolvimento de microfissuras na célula. Diante dos muitos efeitos negativos da sujeira nos módulos, a limpeza deve ser feita com uma frequência razoável para evitar encurtar a vida útil do sistema, além de evitar a perda de potência gerada [15].

2.4.4 Influência do *mismatch*

O *mismatch* é uma incompatibilidade entre os módulos fotovoltaicos de uma mesma string. Em [16], o autor descreve o fenômeno como “o descompasso existente entre módulos conectados em série ou paralelo em virtude de fatores extrínsecos ou intrínsecos ao sistema fotovoltaico”. O *mismatch* pode ser dividido em duas categorias:

- *Mismatch* de fabricação: O *mismatch* de fabricação é a diferença de potência de módulos do mesmo lote devido ao processo de fabricação. Essa diferença pode ser de até 5 %. Quando um módulo de potência menor é colado em uma string fotovoltaica

junto com outros módulos do mesmo lote, a corrente da string ficará limitada à corrente do módulo de menor potência, causando perda por *mismatch* na string.

- *Mismatch* de operação: são quando as incompatibilidades de fabricação são intensificadas pelos fatores ambientais nos quais os sistemas fotovoltaicos operam. Por exemplo: sombras, diferentes inclinações e orientações de módulos fotovoltaicos interligados, sujeira, altas temperaturas, rachaduras ou outros defeitos na superfície dos módulos fotovoltaicos, entre outros.

2.5 Inversores fotovoltaicos

Um inversor é um dispositivo eletrônico que, a partir de uma fonte de energia elétrica em corrente contínua, fornece energia elétrica em corrente alternada. A fonte de energia em corrente contínua pode ser proveniente de baterias, células combustíveis, módulos fotovoltaicos, entre outros [14]. Os inversores fotovoltaicos, Figura 12, são equipamentos que convertem a energia elétrica gerada em corrente contínua pelos módulos fotovoltaicos para corrente alternada, em tensão e frequência compatíveis com a concessionária de distribuição de energia [17].

Figura 12 – Inversores fotovoltaicos



Fonte: Adaptado de AYRÃO (2018) [14]

2.6 Estação solarimétrica

Para projetos de usinas fotovoltaicas de grande porte que se destinam à venda de energia em leilões, é obrigatória a utilização de estações equipadas pelo menos com um piranômetro para medição de irradiância global [18], que é um equipamento que consegue medir a radiação solar que incide sobre uma área horizontal. A estação solarimétrica,

Figura 13 é de extrema importância para uma UFV, pois é dela que consegue-se analisar as condições que fazem com que a usina funcione (radiação solar e temperatura), por exemplo, se em um dia com alta incidência de radiação solar a UFV gerar pouca energia elétrica, haverá certa desconfiança e os responsáveis pela operação e manutenção da usina começarão a investigar se há algo de errado com a usina e, provavelmente, acharão algo que não está funcionando como deveria.

Figura 13 – Exemplo de uma estação solarimétrica



Fonte: Adaptado de HUKSEFLUX BRASIL [19]

2.7 Modelos matemáticos

Os modelos matemáticos podem ser apresentados como uma representação de um sistema real, ou seja, ele deve representar um sistema e a forma como ocorrem as mudanças no mesmo. Os modelos são utilizados em várias áreas da vida humana, como: Física, Química, Engenharia, Economia, etc. Uma vez que o sistema é modelado e o modelo tem sua validade assegurada, é possível utilizar o modelo matemático para estudar o

comportamento de um sistema ou até mesmo fazer previsões, que é um dos objetivos desse trabalho. Dependendo do sistema que se deseja modelar, o modelo pode ser simples, de fácil solução, ou complexo, de solução complexa, tornando necessário o uso de ferramentas computacionais para chegar a uma solução.

2.7.1 Métrica MAPE

Para avaliar o quão bom um modelo matemático é, deve-se compará-lo com os valores do mundo real e analisar o quão próximo da realidade o modelo é.

Neste projeto, será utilizada a métrica MAPE como forma de avaliação do modelo matemático. A métrica MAPE nada mais é que o erro percentual absoluto médio, ou seja, ela mostra percentualmente se um modelo condiz com os valores reais. Ter uma métrica $MAPE = 10\%$ significa que, em média, o modelo matemático faz previsões que erram por 10% do valor real. A métrica MAPE é dada pela equação (2.8):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{m_i - p_i}{m_i} \right| \cdot 100\% \quad (2.8)$$

Onde:

n - número total de amostras;

m - valor real da amostra;

p - valor previsto da amostra.

2.8 Redes neurais artificiais


Os neurônios são as células que compõem o cérebro dos seres-vivos, eles são formados basicamente por três partes: os dendritos, que recebem as informações de outras células, o corpo celular, que é onde os sinais são processados e o axônio, que repassa a informação já processada. A estrutura de um neurônio pode ser vista na Figura 14

Redes neurais artificiais é uma tecnologia de computação que propõe um modelo matemático inspirado na estrutura neural de organismos inteligentes que adquirem conhecimento por meio da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto o cérebro dos mamíferos pode ter bilhões de neurônios [21].

Uma rede neural artificial tem duas bases que são a sua arquitetura e o algoritmo de aprendizagem. Essa divisão surge pelo paradigma de como a rede é treinada, pois a rede é treinada a partir de exemplos [22].

A rede neural é composta por unidades de processamento, onde essas unidades são conectadas entre si por canais de comunicação que estão associados a um peso [22]. Cada unidade de processamento opera apenas sobre seus dados locais, ou seja, as entradas recebidas pelas suas conexões. A inteligência de uma rede neural vem das interações entre

Figura 14 – Estrutura de um neurônio



Fonte: Adaptado de [20].

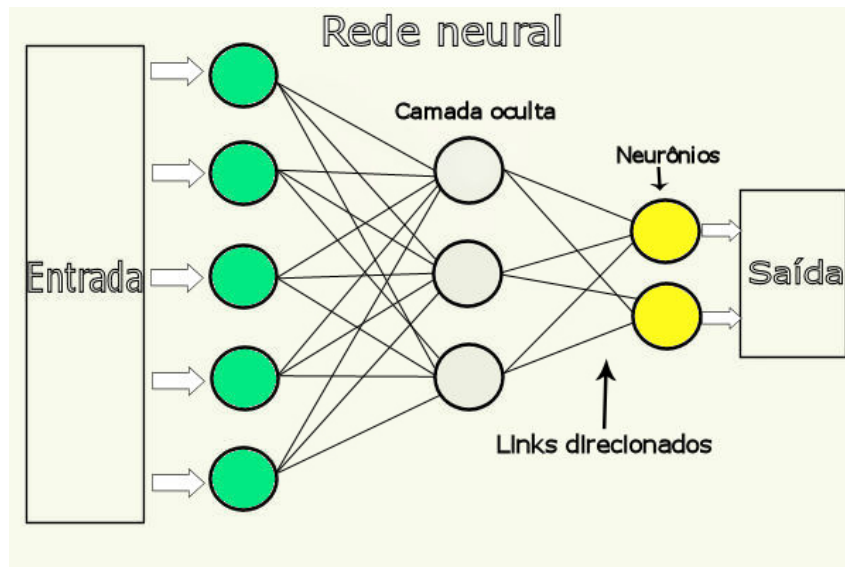
as unidades de processamento da rede [21]. A maior parte das redes neurais possuem alguma regra de treinamento, ou seja, os pesos de suas conexões são ajustados de acordo com os padrões apresentados, em outras palavras, elas aprendem através de exemplos [21].

Arquiteturas neurais são usualmente organizadas em camadas, como mostrado na Figura 15, que possuem unidades que se comunicam com as unidades das próximas camadas. O valor de cada camada de neurônios dependerá da quantidade de dados de entrada e do tipo de problema a ser resolvido. Geralmente essas camadas são divididas em três grupos;

- Entrada: A camada de entrada recebe os dados de entrada e produz os valores finais na camada de saída;
- Saída: A camada de saída é onde a rede neural treinada entrega seu resultado, ou seja, a conclusão que ela chegou ao receber os dados da camada de entrada;
- Oculta: As chamadas camadas ocultas fazem cálculos intermediários que ajudam a rede a encontrar o valor final.

A propriedade mais importante de uma rede neural é a capacidade de aprender com o ambiente, melhorando assim seu desempenho. Isso é feito através de um processo iterativo de aprimoração de pesos. Um conjunto bem definido de regras para resolver um problema de aprendizagem é chamado de algoritmo de aprendizagem. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de rede neural, e esses algoritmos diferem principalmente em como os pesos são modificados. Outro fator importante é a forma como a rede neural se relaciona com o ambiente. Neste caso, existem os seguintes modelos de aprendizagem:

Figura 15 – Organização de uma rede neural artificial



Fonte: Adaptado de [23]

- Aprendizado supervisionado: quando um agente externo indica à rede a resposta desejada;
- Aprendizado não-supervisionado: quando não há um agente externo indicando à rede a resposta desejada;
- Reforço: quando um crítico avalia a resposta gerada pela rede neural.

3 METODOLOGIA E ETAPAS DE DESENVOLVIMENTO

Neste projeto, será realizada uma pesquisa aplicada a fim de validar modelos matemáticos que simulam o comportamento de módulos fotovoltaicos. A pesquisa será de natureza quantitativa, tendo em vista que os modelos serão avaliados perante uma métrica pré estabelecida, a métrica MAPE, que indica o quão próximo da realidade está o modelo matemático.

Dentre as técnicas utilizadas estão a revisão bibliográfica utilizando pesquisa em *websites*, consultoria em artigos científicos e em livros e a investigação experimental utilizando simulações feitas em *softwares* que conseguem implementar os modelos matemáticos. O método da análise dos dados será estatístico, tendo gráficos incorporados e tabelas que mostrem os resultados de forma clara para o leitor.

Como base de dados para alimentar os modelos matemáticos e compará-los com o modelo real, foi utilizada uma UFV localizada na cidade de Goiânia, no estado de Goiás, composta por um inversor da marca ABB, modelo TRIO-50.0-TL-OUTD, no qual estão conectados 200 módulos JAP6-72-320/4BB da marca JA SOLAR, esses módulos possuem uma potência nominal de 320 W, totalizando 64 kWp de potência instalada no inversor. A base de dados é composta pelos dados de irradiância solar, temperatura das células dos módulos e potência CC que está sendo injetada no inversor. Os dados de irradiância solar e temperatura de módulo são considerados iguais para todos os módulos, tendo em vista que todos eles estão orientados de forma idêntica com relação ao sol. Esses dados foram coletados no período entre 01 de julho de 2020 e 30 de junho de 2021 com uma amostragem de 5 minutos, totalizando 105120 amostras. As amostras de temperatura e irradiância foram utilizadas para alimentar 3 modelos matemáticos diferentes.

Para a previsão de geração, foram escolhidos dois métodos a serem seguidos, ambos envolvendo a previsão da curva de irradiância e temperatura dos módulos para o dia desejado, 01 de julho de 2021. Para realizar a previsão dessas curvas, foi utilizado o *PROPHET*, que é uma rede neural disponibilizada gratuitamente pelo *FACEBOOK* que é capaz de realizar previsões a partir de séries históricas a partir de regressão linear [24]. Nesse caso, as informações de entrada foram os dados de irradiância e temperatura dos módulos coletados a cada 5 minutos do dia 01 de julho de 2020 ao dia 30 de junho de 2021. Como os dados são coletados a cada 5 minutos, um dia irá possuir 288 pontos de amostragem de dados e, dessa forma, o *PROPHET* foi programado para prever os próximos 288 pontos a partir dos dados de entrada, em outras palavras, ele prevê como será a irradiância e temperatura no dia seguinte (01 de julho de 2021).

3.1 Modelos matemáticos

O primeiro deles foi o *Sixth (6th) PV model*, que é tido como uma abordagem analítica [9] pelo fato de conseguir calcular a potência de saída de um módulo fotovoltaico com base nos parâmetros do fabricante como tensão de circuito aberto e corrente de curto-circuito, além de irradiância e temperatura, como pode-se ver nas equações (3.1) à (3.3). O fator de forma é calculado a partir dos dados do manual do fabricante também, como visto no Capítulo 2:

$$P_{PV6^{th}}(t) = V_{OC}(t) \times I_{SC}(t) \times FF \times N \quad (3.1)$$

$$V_{OC}(t) = V_{OCSTC}(t) + K_v (T_C(t) - T_{STC}) \quad (3.2)$$

$$I_{SC}(t) = \frac{G(t)}{G_{STC}} (I_{SCSTC} + K_i (T_C(t) - T_{STC})) \quad (3.3)$$

Onde:

$P_{PV6^{th}}$ - potência gerada pelos módulos fotovoltaicos no modelo *Sixth (6th) PV model*;

V_{OC} - tensão de circuito aberto do módulo fotovoltaico nas condições de operação;

V_{OCSTC} - tensão de circuito aberto do módulo fotovoltaico na STC (fabricante);

I_{SC} - corrente de curto-circuito do módulo fotovoltaico nas condições de operação;

I_{SCSTC} - corrente de curto-circuito do módulo fotovoltaico na STC (fabricante);

FF - fator de forma do módulo fotovoltaico;

N - quantidade de módulos fotovoltaicos ligados ao inversor;

k_v - coeficiente de tensão do módulo;

k_i - coeficiente de corrente do módulo;

G - irradiância incidente no módulo;

T - temperatura de operação do módulo.

O segundo modelo utilizado foi o chamado modelo de diodo simples, adaptado do circuito equivalente visto na Figura 7. Nesse modelo, multiplica-se o circuito equivalente de uma célula fotovoltaica pela quantidade total de módulos presentes na usina fotovoltaica, de forma que o modelo calcule a potência total gerada pelos módulos fotovoltaicos. O modelo é dado pela equação (3.4):

$$P_{PVDS} = V \times I \times N \quad (3.4)$$

Onde:

P_{PVDS} - potência gerada pelos módulos fotovoltaicos no modelo diodo simples;

N - número de módulos na UFV;

V - tensão do módulo fotovoltaico em dado ponto da curva I-V;

I - corrente do módulo fotovoltaico em dado ponto da curva I-V (2.2).

Na equação (2.2), o I_L é calculado da através da equação (3.5) [25]:

$$I_L = (I_{SCSTCn} + K_i\Delta T) \frac{G}{G_{STC}} \quad (3.5)$$

$$I_{SCSTCn} = \left(\frac{R_P + R_S}{R_P} \right) I_{SCSTC} \quad (3.6)$$

Onde:

I_{SCSTCn} - corrente de curto-circuito do módulo fotovoltaico na STC corrigida pelos efeitos das resistências série e paralelo intrínsecas da célula fotovoltaica;

K_i - coeficiente de corrente por temperatura da célula;

G - irradiância incidente na célula;

G_{STC} - 1000 W/m².

Ainda na equação (2.2), I_0 é calculado da seguinte forma:

$$I_0 = \frac{I_{SCSTC} + K_i\Delta T}{\exp((V_{OCSTC} + K_v\Delta T)/\alpha V_t) - 1} \quad (3.7)$$

$$V_t = \frac{N_s k T}{q} \quad (3.8)$$

Onde:

K_v - coeficiente de tensão por temperatura do módulo;

K_i - coeficiente de corrente por temperatura do módulo;

T - temperatura absoluta da célula [K];

α - constante do diodo;

N_s - número de células no módulo;

k - constante de Boltzmann;

q - carga do elétron.

No terceiro modelo foram feitas algumas adaptações do segundo modelo apresentado, o de diodo simples. O modelo de diodo simples não prevê a inclinação do módulo fotovoltaico em relação ao plano horizontal de irradiância, bem como também não prevê a degradação anual do módulos fotovoltaicos (dado do fabricante). Para adequar o modelo de diodo simples, foi multiplicada a equação final de potência por duas constantes que foram chamadas de K_{inc} e K_{deg} , que representam a inclinação do módulo em relação ao plano de incidência da irradiância solar e a degradação do módulo, respectivamente. Dessa forma, a potência é calculada como mostra a equação (3.9):

$$P_{PVDSA} = P_{PVDS} \times K_{inc} \times K_{deg} \quad (3.9)$$

Onde:

P_{PVDSA} - potência gerada pelos módulos fotovoltaicos no modelo de diodo simples corrigido;

K_{inc} - fator de correção da inclinação do módulo fotovoltaico;

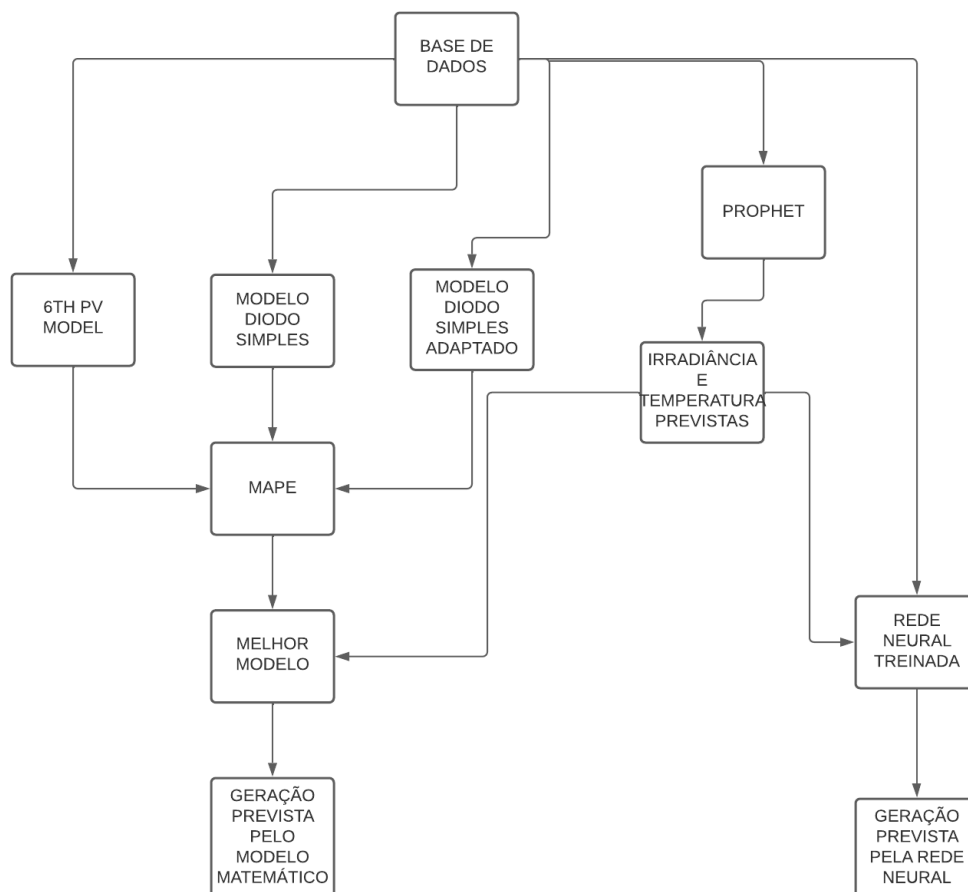
K_{deg} - fator de correção da degradação por tempo do módulo fotovoltaico.

3.2 Previsão de geração

O primeiro caminho adotado para a previsão de geração foi utilizar os dados do dia previsto pelo *PROPHET* como entrada do melhor dos modelos matemáticos apresentados neste trabalho (o melhor será definido através da métrica MAPE), dessa forma é prevista a curva de potência do dia e, por consequência, a geração de energia dos módulos fotovoltaicos.

O segundo caminho adotado para a previsão de geração é um pouco diferente, porém também utiliza da previsão dos dados meteorológicos feita pelo *PROPHET*. Primeiramente, utilizando o *software* matlab, foi treinada uma rede neural que aprende como são os dados de potência medidos na UFV em estudo com relação aos dados de temperatura e irradiância coletados durante um ano. Logo após, a rede neural treinada recebe como entrada os dados de temperatura e irradiância previstos e dá como saída uma previsão da curva de potência que será medida no dia e, por consequência, uma previsão da energia gerada no dia. Na Figura 16 têm-se um esquema de como será o fluxo de atividades desse trabalho.

Figura 16 – Fluxograma de desenvolvimento do trabalho



Fonte: Própria do autor.

4 BASE DE DADOS

Como dito no Capítulo 3, foram utilizados os dados de temperatura do módulo, que foi medida através de um sensor de temperatura fixado na parte traseira dos módulos fotovoltaicos, irradiância horizontal e potência ativa gerada pelos módulos fotovoltaicos coletados durante um ano, a cada 5 minutos, de uma UFV localizada em Goiânia, Goiás. Todos esses dados foram coletados através de sensores localizados na planta e, devido à isso, podem ocorrer falhas de medição. Para contornar esses erros de medição os dados foram tratados da seguinte forma: no período que não há incidência de irradiação solar, o sensor de irradiância pode marcar um valor negativo bem pequeno e, quando isso ocorre, os valores foram substituídos por zero. Abaixo, na Figura 17, pode-se ver uma amostra de como estão estruturados os dados que serão utilizados neste trabalho.

Figura 17 – Amostra dos dados contidos na base de dados

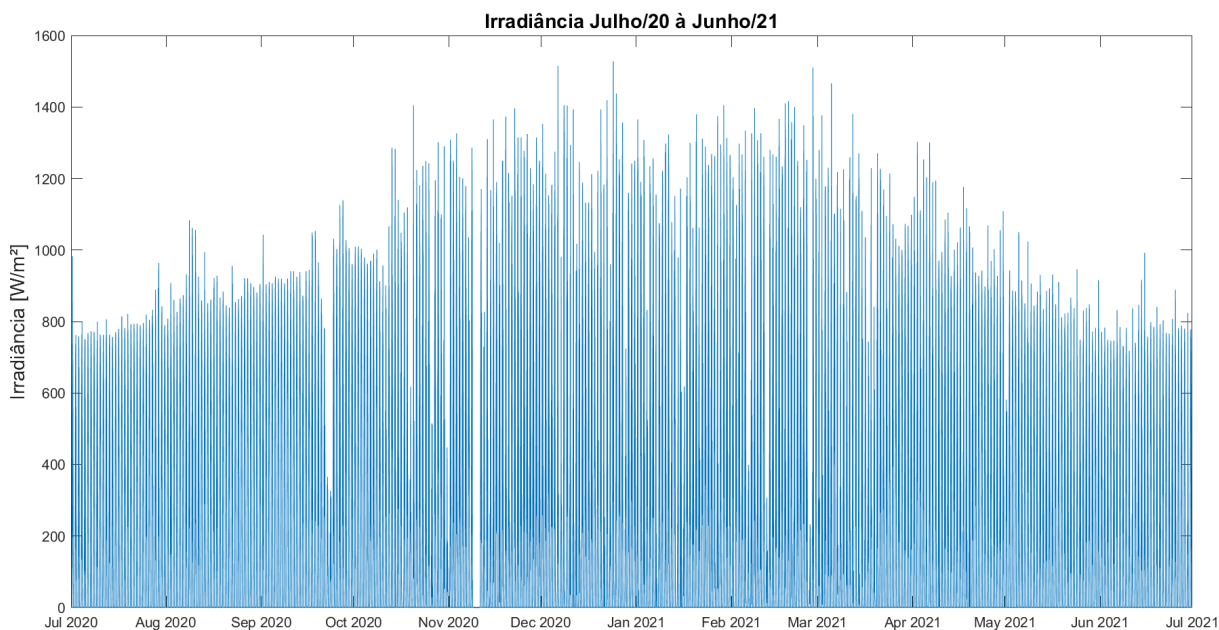
time	pot	irr	modtemp
01/07/2020 09:35	28423,85	554,1	41,58
01/07/2020 09:40	26362,49	518,36	41,5
01/07/2020 09:45	27522,41	540,91	41,63
01/07/2020 09:50	27001,12	551,27	42,7
01/07/2020 09:55	29934,26	583,09	42,63
01/07/2020 10:00	21085,26	413,91	41,69
01/07/2020 10:05	28534,4	555,55	41,58
01/07/2020 10:10	29558,59	577,73	42,36
01/07/2020 10:15	31991,55	628,64	43,21
01/07/2020 10:20	27960,61	552,7	42,9
01/07/2020 10:25	30743,64	595,3	43,06
01/07/2020 10:30	33224,98	650,27	43,37
01/07/2020 10:35	33462,82	660,45	44,74

Fonte: Própria do autor.

4.1 Irradiância [kW/m²]

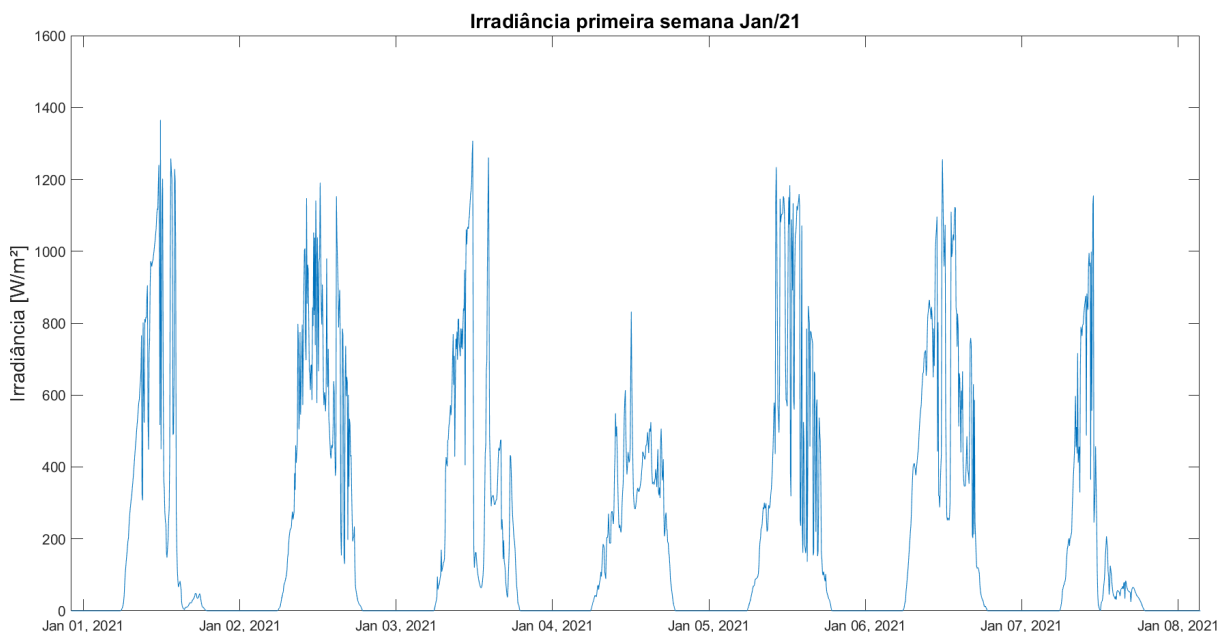
No modelo matemático para geração de módulos fotovoltaicos, a irradiância solar tem um papel importantíssimo, tendo em vista que ela é a principal responsável pela geração de energia elétrica no módulo fotovoltaico. Sendo assim, é de suma importância manter uma base de dados contendo essa informação, a fim de realizar análises profundas e até mesmo identificar falhas na UFV. A Figura 18 mostra os dados coletados de irradiância no período de 01 de julho de 2020 à 30 de junho de 2021 enquanto a Figura 19 mostra uma aproximação dessa mesma curva para que possa ser observado o comportamento da irradiância solar durante a primeira semana de janeiro de 2021.

Figura 18 – Irradiância coletada ao longo de um ano na UFV



Fonte: Própria do autor.

Figura 19 – Irradiância na primeira semana de janeiro no ano de 2021



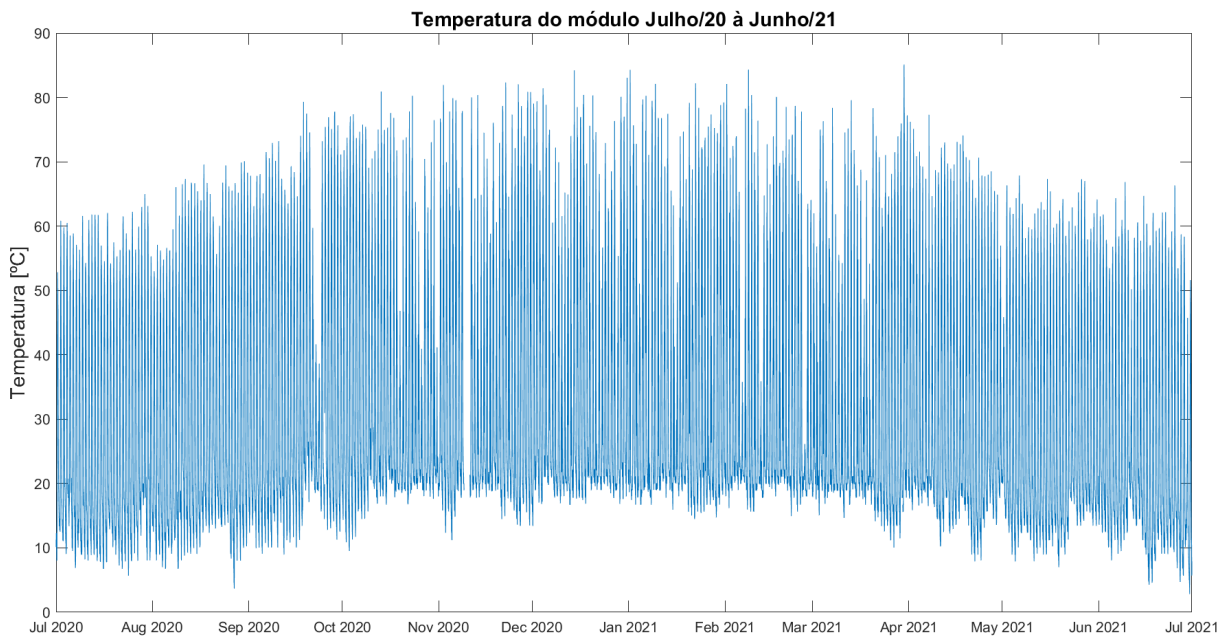
Fonte: Própria do autor.

4.2 Temperatura do módulo fotovoltaico [°C]

A temperatura de operação de um módulo fotovoltaico também é importante para o seu funcionamento, já que quanto maior a temperatura de operação, pior é o seu rendimento. Portanto, é muito importante manter uma base de dados sobre esse parâmetro que impacta diretamente na geração de energia de uma UFV. Na Figura 20 pode-se visualizar os dados coletados referentes à temperatura de módulo no período de 01 de julho de 2020 à 30 de junho de 2021, o mesmo da irradiância, enquanto na Figura 21 observa-se uma aproximação


dessa mesma curva para que possa ser observado o comportamento da temperatura de módulo durante a primeira semana de janeiro de 2021.

Figura 20 – Temperatura de módulo coletada ao longo de um ano na UFV



Fonte: Própria do autor.

Figura 21 – Temperatura de módulo na primeira semana de janeiro no ano de 2021




Fonte: Própria do autor.

Pode-se notar que, nos picos de irradiância, onde os painéis geram mais energia, ocorrem os picos de temperatura de operação devido à irradiação incidente nos módulos, causando também as maiores perdas.

4.3 Potência medida [W]

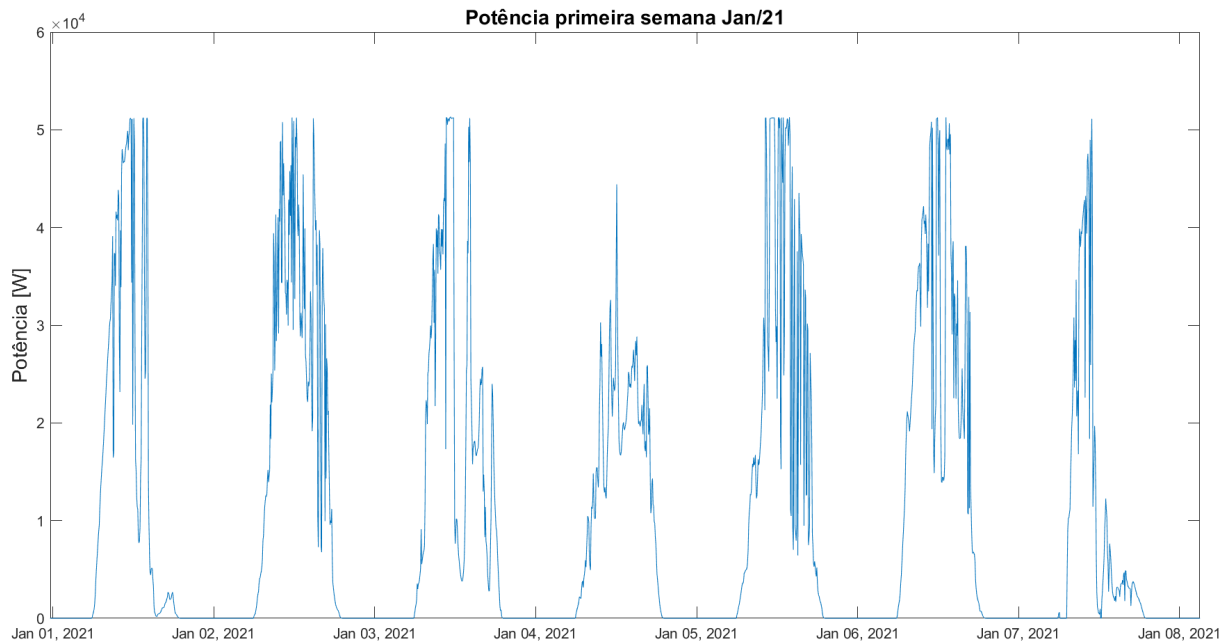
A coleta de dados da potência gerada pelos módulos fotovoltaicos da UFV é de suma importância para esse trabalho, pois esses dados serão utilizados como comparação para os modelos matemáticos bem como para o treinamento da rede neural. Na Figura 22 são observados os dados medidos de potência no período de 01 de julho de 2020 à 30 de junho de 2021, o mesmo da irradiância e da temperatura de módulo, enquanto na Figura 23 observa-se uma aproximação dessa mesma curva para que possa ser observado o comportamento da potência medida durante a primeira semana de janeiro de 2021. Pode-se notar que nos meses mais próximos ao verão, há uma limitação de potência, isso acontece porque o inversor fotovoltaico limita a potência de entrada em 52 kW. Ainda assim é de costume utilizar a prática de sobredimensionar a quantidade de módulos para o inversor de forma que a geração de energia seja a máxima durante uma maior parte do dia.

Figura 22 – Potência medida ao longo de um ano na UFV



Fonte: Própria do autor.

Figura 23 – Potência medida na primeira semana de janeiro no ano de 2021



Fonte: Própria do autor.

5 RESULTADOS

5.1 Sixth (6th) PV model


O primeiro modelo matemático abordado neste trabalho será o *Sixth (6th) PV model*, modelo que utiliza os dados do manual do módulo, fornecidos pelo fabricante, além da irradiância e temperatura, para calcular a potência gerada por um módulo fotovoltaico. O modelo utiliza os dados de V_{OC} , I_{SC} , V_{MPPT} , I_{MPPT} , K_v e K_i para calcular a potência de saída dos módulos fotovoltaicos. Além disso, ele também utiliza o fator de forma do módulo, que é calculado a partir da equação (2.3).

Para o módulo em questão, têm-se [26]:

- $V_{OC} = 46,22$ V;
- $I_{SC} = 9,06$ A;
- $V_{MPPT} = 37,38$ V;
- $I_{V_{MPPT}} = 8,56$ A;
- $K_v = -0,33$ %/°C;
- $K_i = 0.058$ %/°C.

Aplicando esses valores às equações (3.1) a (3.3) e utilizando como entrada os valores de irradiância e temperatura do módulo da base de dados, obtêm-se o valor calculado para potência em todos os pontos no período entre 01 de julho de 2020 e 30 de junho de 2021, como mostra a Figura 24:


Figura 24 – Potência dada pelo *Sixth (6th) PV model*



Fonte: Própria do autor.

É possível observar que, nos meses mais próximos ao verão, o modelo matemático calcula um valor relativamente mais elevado para a potência em comparação à potência medida na UFV, isso pode ser observado na Figura 25, que faz uma comparação entre as curvas anuais medida e calculada, e na Figura 26, que mostra uma aproximação da comparação na primeira semana de janeiro. Essa diferença ocorre por que a medição é feita em sensores localizados no inversor fotovoltaico e, quando a potência gerada pelos módulos ultrapassa uma potência de 52 kW, ele limita a potência gerada pelos módulos através do seu MPPT.

Figura 25 – Comparação entre 6^{th} PV model e potência medida ao longo do ano



Fonte: Própria do autor.


Utilizando a métrica MAPE, definida pela equação (2.8), o erro medido entre as curvas anuais, medida e calculada, foi de 21,77 %.

Para contornar a limitação de potência do inversor, foi adicionado ao modelo matemático uma condição na qual toda vez que a saída do modelo fosse maior que 52 kW, ela seria considerada 52 kW. Dessa forma, a curva calculada se torna mais próxima da medida, como pode-se ver na Figura 27, e é possível observar melhor o efeito da correção no modelo na Figura 28. Após essa correção, o MAPE passou a ser de 10,99 %.

5.2 Modelo diodo simples


O segundo modelo matemático abordado é o modelo de diodo simples para módulos fotovoltaicos, que se baseia no circuito equivalente de uma célula fotovoltaica mostrado na Figura 7. Neste modelo é utilizada a equação (2.2) para traçar a curva I-V do módulo fotovoltaico para cada ponto de irradiância e temperatura de módulo e, de cada uma

Figura 26 – Comparação entre 6th PV model e potência medida na primeira semana de janeiro



Fonte: Própria do autor.

Figura 27 – Comparação entre 6th PV model e potência medida ao longo do ano após correção do modelo

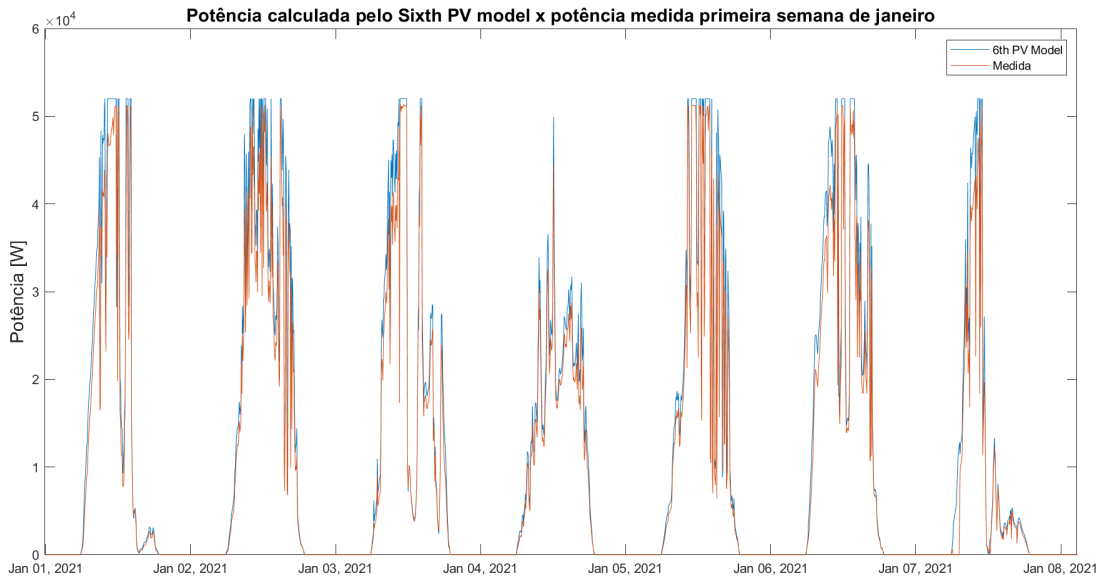


Fonte: Própria do autor.

dessas curvas, é detectado o ponto de máxima potência e esse é o escolhido para plotar a curva de potência ao longo do ano.

A principal diferença entre o modelo de diodo simples e o modelo mencionado na seção anterior é que o modelo de diodo simples simula as características físicas do módulo além de utilizar os dados de placa dele, fazendo com que o modelo seja mais próximo do real. Os parâmetros necessários para o cálculo desse modelo são, além dos dados de placa do

Figura 28 – Comparação entre 6th PV model e potência medida na primeira semana de janeiro após correção do modelo



Fonte: Própria do autor.

módulo já descritos no capítulo anterior, R_S , R_P e α .

Esses parâmetros são calculados de forma iterativa a partir de um método desenvolvido em [25] e seus valores são:


- $R_S = 0,359 \Omega$;
- $R_P = 2244,62 \Omega$;
- $\alpha = 1,06$.

Aplicando esses valores às equações (3.5) a (3.8) e substituindo os resultados na equação (2.2) para calcular (3.4) e utilizando como entrada os valores de irradiância e temperatura de módulo da base de dados e multiplicando pelo número de módulos na planta, obtêm-se o valor calculado para potência em todos os pontos no período entre 01 de julho de 2020 e 30 de junho de 2021, como mostra a Figura 29.

Assim como no modelo do Capítulo 6, é possível observar que, nos meses mais próximos ao verão, o modelo de diodo simples também calcula um valor mais elevado para a potência em comparação à potência medida na UFV, isso pode ser observado na Figura 30, e na Figura 31, que mostra uma aproximação da comparação na primeira semana de janeiro. Nessas condições a medida de erro MAPE foi de 18,45 %.


Como no modelo anterior, foi adicionado ao modelo matemático uma condição na qual toda vez que a saída do modelo fosse maior que 52 kW, ela seria considerada 52 kW. Dessa forma, a curva calculada se torna mais próxima da medida, como pode-se ver na Figura 32, e é possível observar melhor o efeito da correção no modelo na Figura 33. Após essa correção, o MAPE passou a ser de 8,45 %.

Figura 29 – Potência calculada pelo modelo de diodo simples



Fonte: Própria do autor.

Figura 30 – Comparação entre modelo diodo simples e potência medida ao longo do ano




Fonte: Própria do autor.

5.3 Modelo diodo simples adaptado


O terceiro modelo apresentado é uma adaptação do modelo apresentado na seção anterior, pois o modelo de diodo simples não prevê a inclinação do módulo fotovoltaico em relação ao plano horizontal de irradiância, bem como também não prevê a degradação anual do módulos fotovoltaicos (dado do fabricante). Na UFV em questão, os módulos fotovoltaicos estão inclinados com um ângulo de -2° para o sul, enquanto a inclinação ideal para a região de Goiânia seria de 16° para o norte (a inclinação ideal, nos sistemas fixos, de um módulo fotovoltaico localizado no hemisfério sul é igual ao ângulo da coordenada

Figura 31 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro



Fonte: Própria do autor.

Figura 32 – Comparação entre modelo diodo simples e potência medida ao longo do ano após correção do modelo

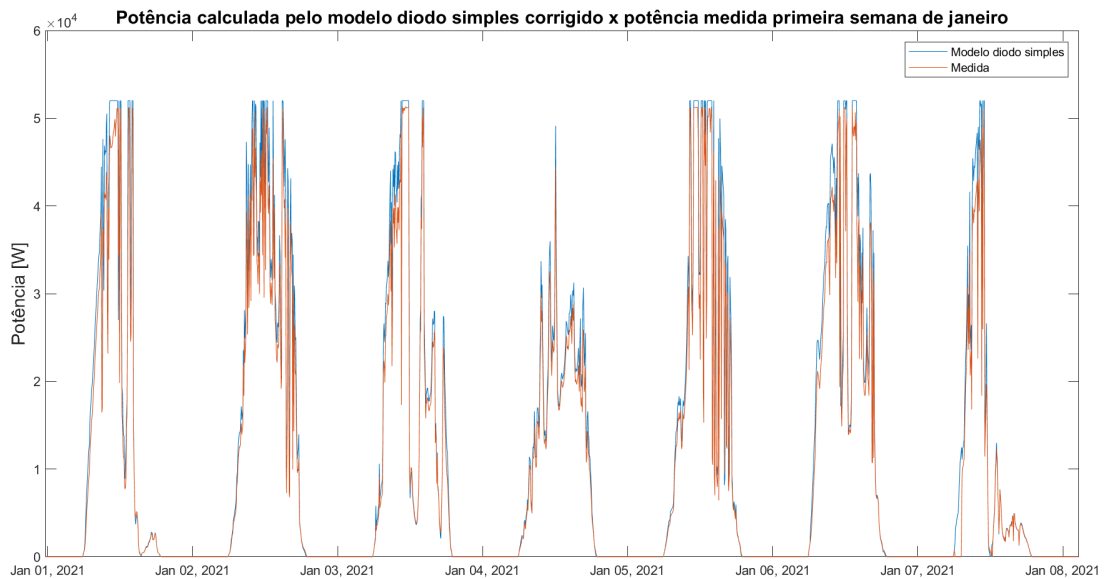


Fonte: Própria do autor.

de latitude da região [27]). Para corrigir a degradação anual nos módulos, foi utilizada a curva de degradação disponibilizada no *datasheet* do módulo, nesse caso é de 0,75 % ao ano. Dessa forma, os coeficientes de correção por inclinação e degradação, K_{inc} e K_{deg} , são calculados da seguinte forma:

$$K_{inc} = \cos(16^\circ) \quad (5.1)$$

Figura 33 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro após correção do modelo



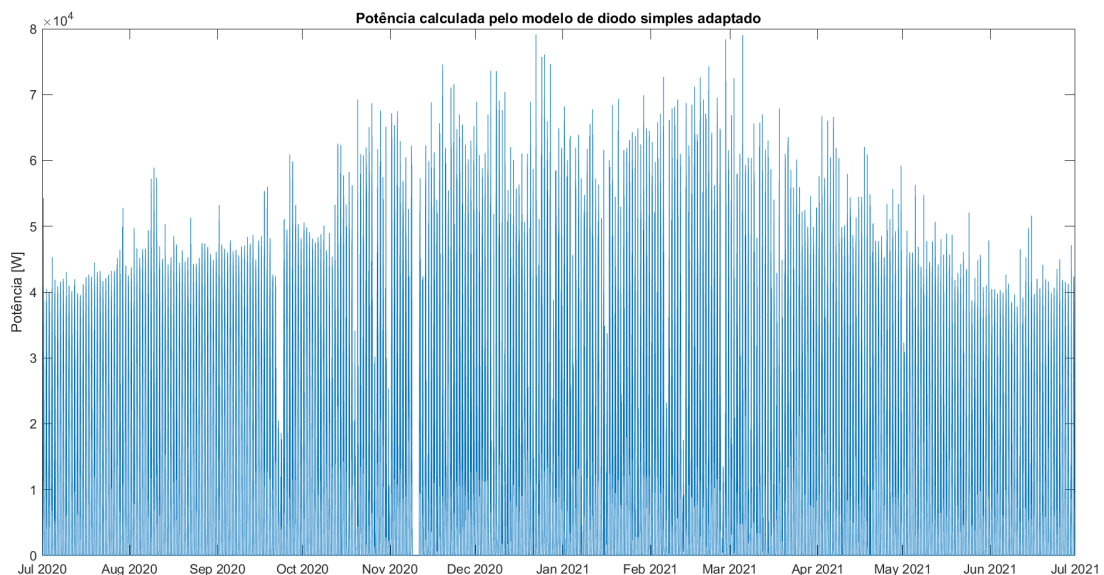
Fonte: Própria do autor.

$$K_{deg} = 1 - 0,0075 \times A \quad (5.2)$$

Onde:

A - quantidade de anos passados após início de operação da UFV (31/10/2017).

Figura 34 – Potência calculada pelo modelo de diodo simples adaptado




Fonte: Própria do autor.

Os valores de entrada pra esse modelo são exatamente os mesmos do modelo de diodo simples, a única diferença é o resultado que é multiplicado por K_{inc} e K_{deg} , como mostra a equação (3.9). A curva de potência calculada pelo modelo ao longo do ano pode ser vista na Figura 34


Seguindo a mesma dinâmica dos dois modelos anteriores, nos meses mais próximos ao verão há uma diferença maior entre a potência calculada e a potência medida, como pode-se ver na Figura 35 e na Figura 36. Nesse caso, o MAPE é de 12,18 %.

Figura 35 – Comparação entre modelo diodo simples adaptado e potência medida ao longo do ano



Fonte: Própria do autor.

Figura 36 – Comparação entre modelo diodo simples adaptado e potência medida na primeira semana de janeiro




Fonte: Própria do autor.

Seguindo os dois modelos anteriores, foi adicionado ao modelo matemático uma condição na qual toda vez que a saída do modelo fosse maior que 52 kW, ela seria considerada igual a 52 kW. Dessa forma, a curva calculada se torna mais próxima da medida, como pode-se

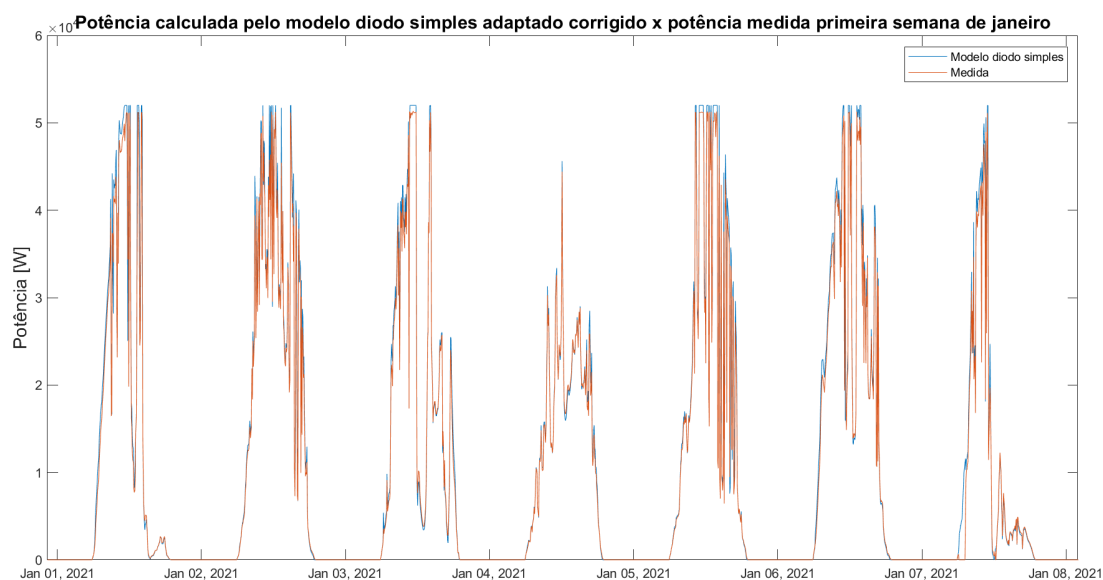
ver na Figura 32e é possível observar melhor o efeito da correção no modelo na Figura 33. Após essa correção, o MAPE passou a ser de 6,45 %.

Figura 37 – Comparação entre modelo diodo simples e potência medida ao longo do ano após correção do modelo



Fonte: Própria do autor.

Figura 38 – Comparação entre modelo diodo simples e potência medida na primeira semana de janeiro após correção do modelo



Fonte: Própria do autor.

5.4 Comparação entre os modelos matemáticos

Após avaliar os três modelos matemáticos presentes neste trabalho, como mostrado na Figura 39, foi identificado que o modelo de diodo simples adaptado e corrigido se saiu melhor entre todos.

Figura 39 – Comparação entre modelos matemáticos através da métrica MAPE

MODELO MATEMÁTICO		MAPE
6th PV MODEL	NÃO CORRIGIDO	21,77%
	CORRIGIDO	10,99%
DIODO SIMPLES	NÃO CORRIGIDO	18,45%
	CORRIGIDO	8,45%
DIODO SIMPLES	NÃO CORRIGIDO	12,18%
ADAPTADO	CORRIGIDO	6,45%

Fonte: Própria do autor.

Sendo assim, pode-se dizer que esse é o modelo que melhor representa a realidade da UFV estudada e, devido à isso, ele será utilizado para calcular a potência prevista da UFV utilizando os dados meteorológicos previstos. A escolha por incluir a adaptação apenas ao modelo de diodo simples se deu pelo fato que essa adaptação é realizada a partir de dois coeficientes lineares, sendo assim, como o o modelo de diodo simples se saiu melhor que o *6th PV MODEL*, a adaptação foi adicionada apenas a ele.

5.5 Previsão dos dados meteorológicos

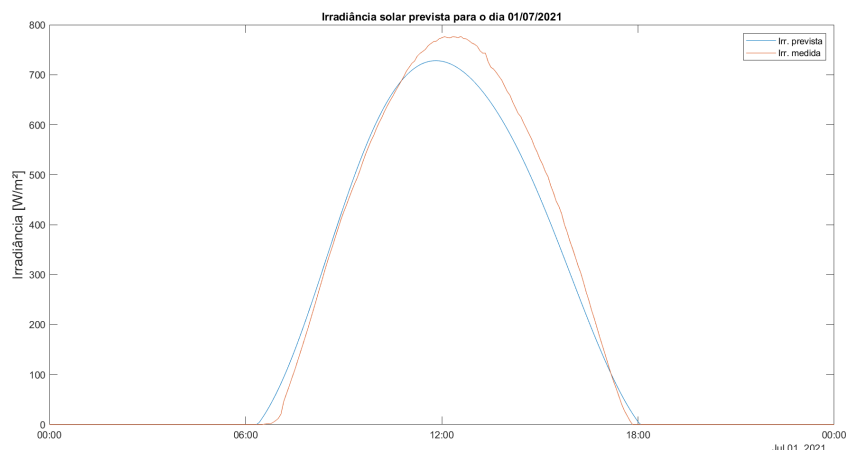
Com o objetivo de prever a curva de potência de um dia utilizando apenas dados dos dias anteriores, foi utilizado o *PROPHET*, que é a rede neural fornecida gratuitamente pelo *FACEBOOK* para fazer previsões de séries temporais [24]. Como dados de entrada foram utilizados os dados de irradiância e temperatura do módulo coletados ao longo de um ano, como mostram as Figuras 18 e 20, respectivamente.

Utilizando o guia rápido do *PROPHET* para *PYTHON*, foi possível prever os dados de irradiância e temperatura para o dia 01 de julho de 2021, ou seja, um dia após a série de dados lida. A diferença entre o prophet e os outros modelos de *machine learning* é que ele roda todo o conjunto de dados ao invés de dividir o conjunto entre treino e teste (70 %/30 %). As Figuras 40 e 41 mostram os resultados das previsões de irradiância e temperatura, respectivamente.

5.6 Previsão da curva de potência

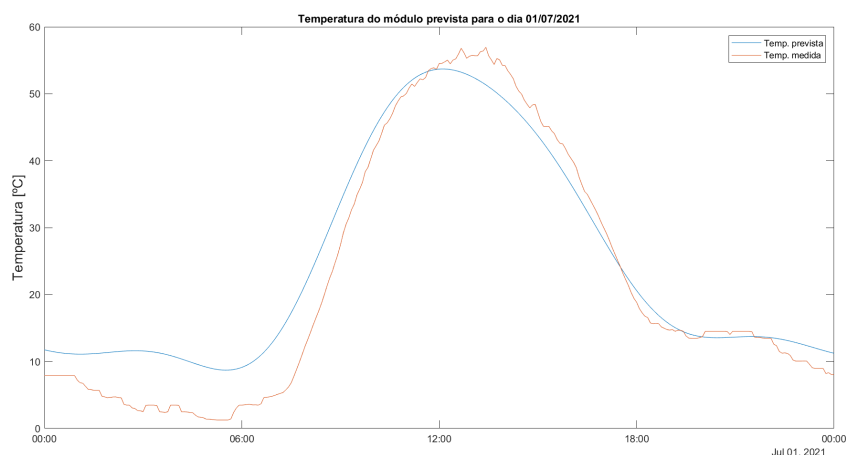
Como dito no Capítulo 3, foram escolhidos dois caminhos a serem seguidos para realizar a previsão de potência, ambos envolvendo a previsão da curva de irradiância e temperatura dos módulos para o dia desejado, 01 de julho de 2021.

Figura 40 – Previsão de irradiância solar para o dia 01/07/2021



Fonte: Própria do autor.

Figura 41 – Previsão de temperatura do módulo solar para o dia 01/07/2021



Fonte: Própria do autor.

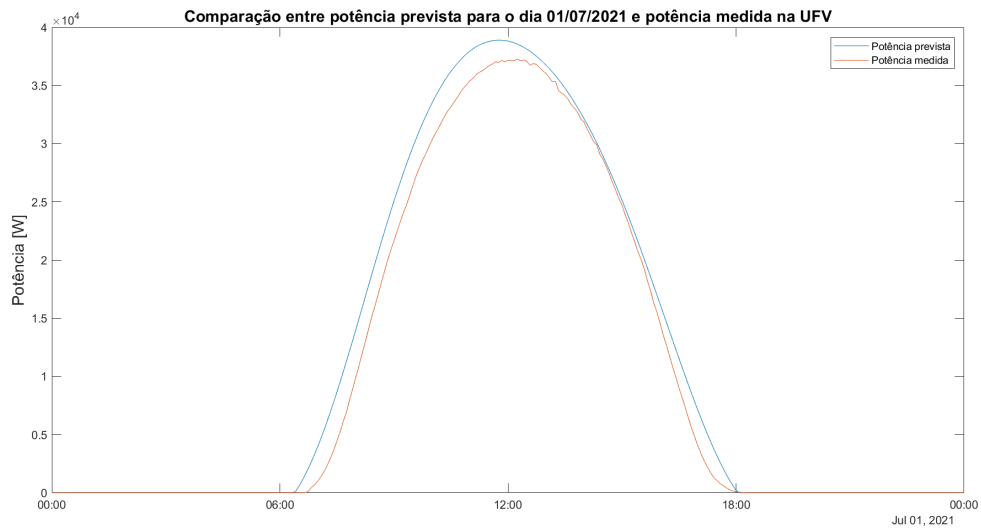
5.6.1 Previsão de potência através do modelo matemático

Utilizando o modelo matemático de diodo simples adaptado e corrigido, que apresentou o melhor desempenho ao calcular a potência da UFV em questão, foi feita uma previsão da potência para o dia 01 de julho de 2021, como mostra a Figura 42. Pode-se observar que, para essa usina em específico, a curva de potência prevista é bem próxima à curva medida, o que comprova que tanto a predição dos dados meteorológicos quanto o modelo matemático funcionam bem para este caso. O MAPE calculado entre essas curvas foi de 9,06 %.

5.6.2 Previsão de potência através do treinamento de rede neural

Utilizando os dados de potência gerada da própria UFV, juntamente com os dados de irradiância e temperatura, foi treinada uma rede neural utilizando a *toolbox* nntool do matlab [28], que é um aplicativo que trabalha aprendizado de máquinas em cima de dados. Nesse caso, o objetivo foi treinar a rede neural para saber como a UFV se comporta de

Figura 42 – Previsão de potência solar para o dia 01/07/2021 utilizando o modelo matemático




Fonte: Própria do autor.

acordo com a temperatura e a irradiância. Utilizando a base de dados como entrada da rede neural, sendo irradiância e temperatura como entradas e potência como saída, a rede neural foi treinada.

A rede neural escolhida foi *Feed-forward backprop* com a função de treinamento Levenberg-Marquardt com 5 camadas, sendo as quatro primeiras com dez neurônios cada e função de transferência (ativação) *Log-sigmoid* e a camada de saída contendo apenas um neurônio e função de ativação *Purelin*. A estrutura da rede ficou como mostra a Figura 43


Figura 43 – Estrutura da rede neural



Fonte: Própria do autor.

A rede foi treinada e logo em seguida testada com os dados meteorológicos previstos pelo *PROPHET*. No *Matlab*, o padrão é utilizar 70 % da base de dados para treino e os 30 % restantes para validação e teste. Pode-se observar pela Figura 44 que a curva de potência prevista é bem próxima à curva medida, o que comprova que tanto a predição dos dados meteorológicos quanto a rede neural treinada pela ferramenta *nntool* funcionam bem para esta usina. O MAPE calculado entre as duas curvas de potência foi de 8,01 %.

Figura 44 – Previsão de potência solar para o dia 01/07/2021 utilizando a rede neural



Fonte: Própria do autor.

6 CONCLUSÃO

A utilização de algum tipo de inteligência agregada à geração fotovoltaica já vem sendo utilizada ao redor do mundo, trazendo cada vez mais confiabilidade e previsibilidade às usinas fotovoltaicas, dessa forma os responsáveis podem garantir o melhor funcionamento para suas plantas.

Os modelos matemáticos têm um grande papel na implementação de inteligência artificial nas plantas fotovoltaicas, tendo em vista que eles são as bases para os cálculos de potência gerada. Neste trabalho ficou claro que o modelo que se saiu melhor foi o que simulava os efeitos físicos do painel fotovoltaico, ou seja, o modelo de diodo simples, porém só isso não foi o suficiente, ou seja, ainda foi necessário adicionar as particularidades da usina ao modelo para que o resultado fosse mais satisfatório.

Ficou claro também neste trabalho que é válido utilizar redes neurais para prever os dados meteorológicos sensíveis à UFV com o objetivo de realizar a previsão de geração, que virá a ser usada como uma referência sólida de geração para a usina, tendo em vista que hoje muitos clientes se baseiam em modelos que se tornam cada vez mesmo precisos ao longo do tempo.

Tanto a previsão utilizando o modelo matemático, quanto utilizando a rede neural treinada, trouxeram resultados satisfatório com taxas de erro menores que 10 %. Esse resultado valida o processo que foi tomado neste trabalho para que uma previsão de geração com um dia de antecedência fosse realizada.

Para trabalhos futuros, seria interessante adicionar ao modelo matemático de geração de módulos fotovoltaicos alguns coeficientes que representem a sujidade dos módulos. Isso seria muito útil no sentido de se saber exatamente quando uma usina deve ser limpa ajudando, dessa forma, a reduzir os gastos devido à perdas de geração e limpeza de painéis.

Outra sugestão para trabalhos futuros seria interessante criar uma ferramenta que adicione mais dados meteorológicos a cada dia que passa, além de buscar dados de várias plataformas diferentes trazendo mais confiabilidade à previsão dos dados meteorológicos. Além disso, outra sugestão seria alimentar o treinamento da rede neural automaticamente a cada dia que passa tornando a previsão cada vez mais acertiva cada dia que passa para que ela consiga aprender cada vez mais e com mais precisão como a usina fotovoltaica realmente se comporta de acordo com a irradiância e temperatura dos módulos.

REFERÊNCIAS

- [1] EMPRESA de Pesquisa Energética. BALANÇO ENERGÉTICO NACIONAL 2021: ANO BASE 2020. 2020. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-601/topico-596/BEN2021.pdf>. Acesso em: 29 nov. 2021.
- [2] MÁXIMO, Wellton; BRANDÃO, Marcelo. Agência Brasil explica: como funciona nova bandeira tarifária de luz: criadas em 2015, tarifas refletem custo variável na produção elétrica. Criadas em 2015, tarifas refletem custo variável na produção elétrica. 2021. Disponível em: <https://agenciabrasil.ebc.com.br/economia/noticia/2021-09/agencia-brasil-explica-como-funciona-nova-bandeira-tarifaria-de-luz>. Acesso em: 29 nov. 2021.
- [3] BRASIL, ANEEL. Resolução ANEEL nº 482 de 17 de abril de 2012. Estabelece as condições gerais para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição de energia elétrica, o sistema de compensação de energia elétrica, e dá outras providências. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2012482.pdf>. Acesso em 29 nov. 2021.
- [4] BRASIL, ANEEL. Geração Distribuída. 2015. Disponível em: <https://www.aneel.gov.br/geracao-distribuida>. Acesso em: 29 nov. 2021.
- [5] ASSOCIAÇÃO BRASILEIRA DE GERAÇÃO DISTRIBUÍDA. Dados Mercado: veja alguns dados atualizados do mercado. 2021. Disponível em: <https://www.abgd.com.br/portal/dados-mercado/>. Acesso em: 29 nov. 2021.
- [6] PORTAL SOLAR. Cresce participação da fonte solar no mercado livre de energia. 2020. Disponível em: <https://www.portalsolar.com.br/blog-solar/energia-renovavel/cresce-participacao-da-fonte-solar-no-mercado-livre-de-energia.html>. Acesso em: 30 nov. 2021.
- [7] ABSOLAR. Panorama da solar fotovoltaica no Brasil e no mundo. 2021. Disponível em: <https://www.absolar.org.br/mercado/infografico/>. Acesso em: 30 nov. 2021.
- [8] ROCHA, H. R. O. et al. Forecast of distributed electrical generation system capacity based on seasonal micro generators using elm and pso. *IEEE Latin America Transactions*, v. 16, n. 4, p. 1136–1141, 2018.
- [9] AL-MASRI, H. M.; MAGABLEH, S. K.; ABUELRUB, A. Output power computation and sizing of a photovoltaic array by advanced modeling. *Sustainable Energy Technologies and Assessments*, v. 47, p. 101519, 2021. ISSN 2213-1388. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2213138821005300>>.

- [10] SOLAR POWER EUROPE (org.). Digitalisation solar in emerging markets: task force report. 2019. Disponível em: https://www.solarpowereurope.org/wp-content/uploads/2019/11/SolarPower-Europe_Digitalisation_solar_in_emerging_markets.pdf?cf;d=4107. Acesso em: 18 jan. 2022.
- [11] HIRUMA, Felipe Shogo. Previsão da geração de energia eólica com redes neurais artificiais. 2016. 168 f. Dissertação (Mestrado) - Curso de Engenharia de Recursos Hídricos e Ambiental, Universidade Federal do Paraná, Curitiba, 2016. Disponível em: <https://acervodigital.ufpr.br/bitstream/handle/1884/43520/R%20-%20D%20-%20FELIPE%20SHOGO%20HIRUMA.pdf?sequence=1&isAllowed=y>. Acesso em: 05 mar. 2022.
- [12] NASCIMENTO, C. A. D. Princípio de funcionamento da célula fotovoltaica. *Diss. Universidade Federal de Lavras*, 2004.
- [13] CENTRO DE REFERÊNCIA PARA ENERGIAS SOLAR E EÓLICA SÉRGIO DE S.BRITO. Manual de Engenharia para Sistemas Fotovoltaicos. 2004. Disponível em: <https://www.infolivros.org/pdfview/400-manual-de-engenharia-para-sistemas-fotovoltaicos-centro-de-referencia-para-energias-solar-e-eolica-sergio-de-sbrito/>. Acesso em: 07 nov. 2021.
- [14] PINHO, J.T.; GALDINO, M. A. (orgs.). Manual de Engenharia Para Sistemas Fotovoltaicos, 2014. E-book (530 p.). Rio de Janeiro: 2014. Disponível em: http://www.cresesb.cepel.br/publicacoes/download/manual_de_engenharia_fv_2014.pdf. Acesso em 01 dez. 2021.
- [15] SAKÔ, Elson Yoiti. Saiba os efeitos da sujeira nos módulos fotovoltaicos: o que a sujeira de um módulo fotovoltaico pode causar e quando é necessário limpá-lo?. O que a sujeira de um módulo fotovoltaico pode causar e quando é necessário limpá-lo?. 2020. Disponível em: <https://canalsolar.com.br/saiba-os-efeitos-da-sujeira-nos-modulos-fotovoltaicos/>. Acesso em: 28 mar. 2022.
- [16] ARAÚJO, Ericka. O problema do mismatch nas instalações fotovoltaicas: entenda e previna-se dos problemas que o mismatch pode causar nas instalações fotovoltaicas. Entenda e previna-se dos problemas que o mismatch pode causar nas instalações fotovoltaicas. 2020. Disponível em: <https://canalsolar.com.br/mismatch-nas-instalacoes-fotovoltaicas/>. Acesso em: 28 mar. 2022.
- [17] AYRÃO, V. Energia solar fotovoltaica no Brasil: conceitos, aplicações e estudos de caso. 2018. E-book (102 p.). Disponível em: <http://abccobre.org.br/wp-content/uploads/2021/04/estudos-fotovoltaicos-vinicius-ayrao.pdf>. Acesso em 02 dez. 2020.

- [18] CANAL SOLAR. O que é uma estação solarimétrica padrão EPE? 2020. Disponível em: <https://canalsolar.com.br/o-que-e-uma-estacao-solarimetrica-padrao-epe/>. Acesso em: 02 dez. 2021.
- [19] HUKSEFLUX BRASIL. Estação Solarimetrica com Telemetria de Dados. Disponível em: <https://huksefluxbrasil.com.br/produtos/estacao-solarimetrica>. Acesso em: 02 dez. 2021.
- [20] BARDINE, Renan. NEURÔNIOS: Características e funções. Disponível em: <https://www.coladaweb.com/biologia/histologia/neuronios>. Acesso em: 05 mar. 2022.
- [21] CARVALHO, André de. Redes Neurais Artificiais. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 02 dez. 2021.
- [22] RAUBER, T. W. Redes neurais artificiais. *Universidade Federal do Espírito Santo*, v. 29, 2005.
- [23] OLIVEIRA, Jeymisson. REDES NEURAIAS ARTIFICIAIS. Disponível em: <http://www.dsc.ufcg.edu.br/pet/jornal/setembro2011/materias/informatica.html>. Acesso em: 05 mar. 2022.
- [24] FACEBOOK. PROPHET: forecasting at scale. Disponível em: <https://facebook.github.io/prophet/>. Acesso em: 05 mar. 2022.
- [25] VILLALVA, M. G.; GAZOLI, J. R.; FILHO, E. R. Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, IEEE, v. 24, n. 5, p. 1198–1208, 2009.
- [26] JA SOLAR. DATASHEET. Disponível em: <https://documents.unboundsolar.com/media/specs-3975302543.1931060-1.pdf>. Acesso em: 09 set. 2021.
- [27] VILLALVA, Marcelo. Como determinar o ângulo de inclinação dos módulos fotovoltaicos?: entenda quais são as melhores inclinações para módulos fotovoltaicos. Entenda quais são as melhores inclinações para módulos fotovoltaicos. 2020. Disponível em: <https://canalsolar.com.br/como-determinar-o-angulo-de-inclinacao-dos-modulos-fotovoltaicos/>. Acesso em: 05 mar. 2022.
- [28] MATHWORKS. NNTOOL. Disponível em: <https://www.mathworks.com/help/deep-learning/ref/nntool.html>. Acesso em: 05 mar. 2022.