

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Vagner Henrique de Souza

**Sistema de Análise Multivariada para Identificação de Falhas em
Geração de Energia Fotovoltaica**

Fortaleza – CE

6 de fevereiro de 2026

Vagner Henrique de Souza

Sistema de Análise Multivariada para Identificação de Falhas em Geração de Energia Fotovoltaica

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Visão Computacional

Orientador: Prof. Dr. ANTONIO WENDELL DE OLIVEIRA
RODRIGUES

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

6 de fevereiro de 2026

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

SOUZA, VAGNER HENRIQUE DE.

SISTEMA DE ANÁLISE MULTIVARIADA PARA IDENTIFICAÇÃO DE FALHAS EM GERAÇÃO DE ENERGIA FOTOVOLTAICA : DISSERTAÇÃO / VAGNER HENRIQUE DE SOUZA. - 2026.

75 f. : il. color.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2026.

Orientação: Profa. Dra. Dr. ANTONIO WENDELL DE OLIVEIRA RODRIGUES.

1. ENERGIA SOLAR. . 2. DETECÇÃO DE FALHAS. . 3. PROCESSAMENTO DE DADOS.. 4. INTELIGENCIA ARTIFICIAL.. 5. SISTEMAS EMBARCADOS. I. Título.

CDD 004



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Vagner Henrique de Souza

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

**Orientador: Prof. Dr. ANTONIO WENDELL
DE OLIVEIRA RODRIGUES**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

**Prof. Dr. ANDRÉ LUIZ CARNEIRO DE
ARAÚJO**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Prof. Dr. Claudio de Castro Monteiro
Instituto Federal do Tocantins (IFTO)

Fortaleza – CE
6 de fevereiro de 2026

*Este trabalho é dedicado às crianças adultas que,
quando pequenas, sonharam em se tornar cientistas.*

Agradecimentos

Agradeço, em primeiro lugar, a Deus, pelo conforto nas horas difíceis e por permitir o dom da vida. Aos meus pais, Francisca Ferreira de Souza e Pedro Bernardino de Souza, pelo amor, pelo apoio durante toda a minha vida e pela confiança nas horas importantes, deixo um agradecimento especial.

Ao Instituto Federal do Ceará (IFCE), que, por meio do Programa de Pós-Graduação em Ciência da Computação (PPGCC), do Laboratório de Aplicações Maciçamente Paralelas (LAMP) e do Laboratório de Inovação Tecnológica (LIT), tornou possível a realização deste projeto de mestrado. À Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP), pelo aporte financeiro recebido durante o desenvolvimento deste projeto.

Ao meu orientador e amigo, Prof. Antônio Wendell de Oliveira Rodrigues, pela disponibilidade e paciência em me guiar no desenvolvimento deste trabalho, mesmo quando as condições eram difíceis, cansativas e o tempo era escasso, deixo o meu muito obrigado.

Agradeço também à minha coorientadora, Professora Rejane Cavalcante de Sá Rodrigues, pela motivação e pelas sugestões, que foram de grande importância para o alcance de cada etapa necessária à conclusão deste trabalho. Obrigado a ambos, pois, sem o apoio de vocês, não vejo como este mestrado teria sido concluído. Obrigado por acreditarem em mim.

Aos professores Cláudio de Castro Monteiro e André Luiz Carneiro de Araújo, agradeço pela disponibilidade em participar da banca examinadora e pelas valiosas contribuições.

Por fim, não poderia deixar de agradecer aos meus amigos do LIT, em especial ao meu amigo Tiago Façanha, que sempre esteve disponível para ajudar e compartilhar experiências.

“Não tentes ser bem-sucedido, tenta antes ser um homem de valor”
(Albert Einstein)

Resumo

O rápido avanço na implantação de sistemas de energia solar vem abrindo inúmeras necessidades no processo de geração eficiente de energia. Alguns problemas são crônicos em plantas com módulos solares, além do sombreamento, há outros fatores que contribuem muito no processo de degradação dos equipamentos, causando, em muitos casos, a inutilização de todo o módulo solar. Este trabalho busca o levantamento de mensurações da planta, classificação dos potenciais problemas bem como mecanismos de detecção das falhas durante o funcionamento e a geração de energia. Desta forma, o principal objetivo é produzir um conjunto de dados de tempo real que sirva de subsídio para um sistema de avaliação de módulos solares usando técnicas modernas da computação para auxiliar na predição de problemas. Com isso, durante a produção de energia, será possível detectar as falhas atribuídas aos módulos, quantificar e alertar a operação para possíveis estratégias de manutenção corretiva e/ou preventiva. Para validar os parâmetros de indicadores verificados no sistema, é proposto um ambiente de predição de potência gerada comparando ferramentas de regressão usando *machine learning*.

Este trabalho apresenta uma abordagem para análise de geração de energia em sistemas fotovoltaicos. O objetivo é identificar o impacto qualitativo na energia produzida de acordo com a detecção e previsão de falhas com base no conjunto de dados de medição elétrica e meteorológica.

Atualmente, aprendizado de máquina e profundo têm sido usados efetivamente para reconhecer padrões em medições de painéis solares. Sujeira, quebra e sombreamento podem reduzir muito a eficiência projetada de usinas de energia solar. Assim, aumentar a quantidade e a qualidade do conjunto de dados de medição de falhas pode melhorar significativamente a confiabilidade e seu desempenho.

Palavras-chave: Energia Solar. Detecção de falhas. Processamento de dados.

Abstract

The fast advance in the implantation of solar energy systems produces countless needs in the efficient energy generation process. Some problems are chronic in plants with solar modules, in addition to shading, there are other factors that contribute to contribute greatly to the process of equipment degradation, causing, in many cases, the disablement of the entire solar module. This work seeks to survey measurements of the plant, classification of potential problems as well as detection mechanisms of failures during operation and power generation. In this way, the main objective is produce a set of real-time data that serves as a subsidy for a system of evaluation of solar modules using modern computer techniques to assist in the problem prediction. Thus, during energy production, it will be possible to detect the failures attributed to modules, quantify and alert the operation to possible strategies corrective and/or preventive maintenance. To validate the indicator parameters check data in the system, a prediction environment of generated power is proposed comparing regression tools using machine learning.

This paper presents an approach for power generation analysis in photovoltaic systems. The objective is to identify the qualitative impact on the energy produced according to fault detection and prediction based on the electrical and weather measurement dataset.

Currently, machine and deep learning have been used effectively to recognize patterns in solar panel measurements. Dirt, breakage and shading can greatly reduce the designed efficiency of solar power plants. Thus, increasing the quantity and quality of the failure measurement dataset can significantly improve reliability and its performance.

Keywords: Solar energy. Fault detection. Data processing

Lista de ilustrações

Figura 1 – Geração Distribuída	28
Figura 2 – Circuito equivalente de uma célula FV	30
Figura 3 – Tipos de Células	31
Figura 4 – Montagem do Módulo Fotovoltaico	32
Figura 5 – Componentes de um sistema fotovoltaico	33
Figura 6 – Exemplo de painéis solares parcialmente sombreados	34
Figura 7 – Ponto de Máxima Potência (MPP)	35
Figura 8 – Diodos de bypass nos sistemas de energia solar fotovoltaica	37
Figura 9 – Hotspot causado pelo sombreamento de uma célula solar	38
Figura 10 – Corrente elétrica em função da Irradiância	41
Figura 11 – Sensor de luminosidade, piranômetro.	42
Figura 12 – Montagem do Módulo Fotovoltaico	43
Figura 13 – Sistema de Captura de dados Experimental	45
Figura 14 – Sistema off-Grid usando MPPT	46
Figura 15 – Telhado IFCE, Campus Fortaleza	48
Figura 16 – Teste de Campo com inversor não-linear	49
Figura 17 – Sistema com Medidor Bidirecional	50
Figura 18 – Case do ESP32 e sensores conectados	51
Figura 19 – Calibração Piranômetro	54
Figura 20 – Piranômetro Digital	54
Figura 21 – Parte do Dashboard do inversor	55
Figura 22 – Arquitetura proposta para o cluster MPI em usinas fotovoltaicas.	61
Figura 23 – Comparação entre curva I–V em condições normais e com falha	61
Figura 24 – Imagem térmica de painel fotovoltaico indicando célula com ponto quente	62
Figura 25 – Gráfico de erro de previsão.	66
Figura 26 – Curva de aprendizado para lightGBM.	66
Figura 27 – Importância das variáveis	67

Lista de tabelas

Tabela 1 – Comparação entre métodos de detecção de falhas	62
Tabela 2 – Medidas cruzadas de dados de inversores e estação meteorológica. . . .	64
Tabela 3 – Métodos regressão.	65

Lista de abreviaturas e siglas

ADC	Analog Digital Converter (Conversor analógico digital)
ANEEL	Agência Nacional de Energia Elétrica
API	Application Programming Interface
CA	Corrente Alternada
CC	Corrente Contínua
DAQ	Data Acquisition
EL	Eletroluminescência
EVA	Etil, Vinil e Acetato
FV	Fotovoltaica
GD	Geração Distribuída
GPIO	General Purpose Input/Output
IFCE	Instituto Federal de Educação, Ciência e Tecnologia do Ceará
IoT	Internet of Things
KW	kilowatts
MAGE	Incerteza associada a cada única medida
MFV	Módulo Fotovoltaico
MPPT	Maximum Power Point Tracking
MQTT	Message Queuing Telemetry Transport
MW	Megawatt
NTC	Negative Temperature Coefficient
PMC	Perceptron Multicamadas
PWM	Pulse Width Modulation
QPS	Quadros de Proteção e Seccionamento

RPi	Raspberry pi
SFV	Sistema Fotovoltaico
SMGFV	Sistema de Microgeração Fotovoltaica
SoC	System on a Chip
VNC	Virtual Network Computing
WLAN	Wireless Local Area Network

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	24
1.2	Descrição do problema	25
1.3	Objetivos Geral e Específicos	25
1.4	Produção	26
1.5	Estrutura da Dissertação	26
2	FUNDAMENTOS TEÓRICOS	27
2.1	Sistemas Fotovoltaicos	27
2.2	Geração distribuída de energia elétrica	28
2.3	Módulos Fotovoltaicos e Grandes Usinas	29
2.3.1	Funcionamento dos Módulos Fotovoltaicos	29
2.3.2	Montagem Módulo Fotovoltaico	31
2.3.3	Componentes de um Sistema fotovoltaico	32
2.4	Falhas em painéis solares	33
2.4.1	Rastreamento do Ponto de Maior Potência (MPPT)	34
2.5	Detecção de falhas	36
2.5.1	Detecção de Pontos quentes	37
2.5.2	Usinas Fotovoltaicas	38
2.6	Detecção de Padrões	38
2.6.1	Árvore de decisão	39
2.6.2	RandomForest	39
2.6.3	Redes Neurais Convolucionais	40
2.7	Significado dos fator de relevância em Painéis fotovoltaicos	40
2.7.1	Irradiância Solar e seu sensoriamento	40
2.7.2	Influencia da Temperatura no MFV	42
2.8	Trabalhos Correlatos	43
2.8.1	Fatores para geração de Energia PV	44
3	METODOLOGIA	45
3.1	Métodos de Detecção e Predição de Falhas	45
3.2	Sistema de geração distribuída de energia	47
3.3	Inversores Fotovoltaicos	48
3.4	Coleta de dados	50
3.4.1	Hardware de aquisição de dados	51
3.4.2	Protocolo MQTT	52

3.4.3	Controlador ESP 32	53
3.4.4	Calibração do sensor Piranômetro	53
3.4.5	Aquisição de dados temporais	55
3.5	Predição com Aprendizado de Máquina	56
3.5.1	Aprendizado supervisionado	56
3.5.2	Treinando com lightGBM	57
3.6	Integração do Sistema Distribuído MPI para Predição e Mapeamento de Sombreamento	58
3.6.1	Introdução	58
3.6.2	Motivação e Contexto	58
3.6.3	Arquitetura Distribuída com MPI	59
3.6.4	Integração com a Metodologia da Dissertação	59
3.6.5	Implementação Experimental	59
3.6.6	Geração de Mapa Virtual de Sombreamento	60
3.7	Comparação entre Abordagens de Detecção de Falhas	60
3.7.1	Medições Elétricas	61
3.7.2	Imagens e Dados Ambientais	61
3.7.3	Considerações Comparativas	62
4	RESULTADOS	63
4.1	Conjunto de dados de medição de PV	63
4.2	Comparando métodos	64
4.3	Treinamento do Regressor	65
4.4	Cluster MPI	68
4.4.1	Conclusões e Trabalhos Futuros	68
5	CONCLUSÃO	71
5.1	Agradecimentos	72
	REFERÊNCIAS	73

1 Introdução

Smart grid (SUN et al., 2011) (PAUL; SEN; DEY, 2019) é um sistema que consiste em, usando soluções digitais, monitorar, controlar e analisar o fluxo de energia bidirecional entre todos os tipos de unidades geradoras, como usina termelétrica, geração hidrelétrica, usina solar, usina nuclear, etc. e consumidores finais. É usado para monitorar e controlar o fluxo de energia automaticamente, através de uma estação mestre com o auxílio da tecnologia. A tecnologia Smart Grid permite o controle de componentes do sistema de energia em geração, transmissão, sistema de distribuição. Permite monitorar e controlar o consumo de energia nas instalações dos consumidores pelo sistema de automação e fornece controle adequado no sistema de distribuição. Também analisa o consumo de energia para que haja um controle adequado no sistema de geração e transmissão automática. A rede inteligente pode ser aplicada em todas as camadas de manuseio de energia. Em relação à produção de energia, os sistemas de painéis solares fornecem uma fonte de energia interessante.

A energia produzida por sistemas de painéis solares está proliferando rapidamente nos últimos anos. Isso se deve, principalmente, ao custo reduzido e aos benefícios atribuídos ao meio ambiente. No entanto, o desempenho desses sistemas é afetado por muitos problemas. Ancuta e Cepisca em (ANCUTA; CEPISCA, 2011) apresentam análises de falhas para painéis fotovoltaicos (PV) que diminuem seu resultado de acordo com o projeto da planta.

Assim, este trabalho aborda os fatores externos que impactam diretamente na perda de potência. Para isso, analisamos algumas indústrias que utilizam usinas solares e enumeramos os principais problemas em relação a falhas. A maioria deles está relacionada a vandalismo e poeira, até mesmo poeira de pássaros. Como o conjunto de dados para este problema é quase inexistente, coletamos experimentalmente dados de medição de uma planta de painéis solares de pequena escala de nossa instituição e aplicamos alguns métodos de reconhecimento de padrões para fornecer uma solução em tempo real para melhorar o desempenho do sistema.

Os módulos fotovoltaicos são projetados para receber todos os intempéries do tempo, sol, chuva, ventos e outros. Porém, existe uma condição específica que pode gerar degradação dos módulos, essa condição é o sombreamento, onde parte ou todo o módulo solar é impedido de receber luz solar e, por consequência, gerar energia. O sombreamento natural causado pelas questões de incidência solar ao longo do dia e disposição de nuvens sobre a planta de geração. Entretanto, outros tipos de problemas, tais como vandalismo, sujeiras de animais, poeiras, podem gerar interferência da incidência solar sobre o painel.

Outro ponto muito importante é a instalação, que pode gerar em uma microfissura por mau manuseio ou por sombreamento em algum período, pelo fato do ângulo do sol mudar durante o ano ou mesmo o crescimento de vegetação ao redor da instalação.

As sombras causadas nas células fotovoltaicas geram efeitos negativos. Como sua geração elétrica é diretamente proporcional à incidência de luz solar, qualquer diminuição na área de absorção reduz drasticamente a eficiência. Um bom funcionamento do painel precisa de um bom planejamento, desde o nascer até o pôr do sol (BALZATEGUI; ECIOLAZA; MAESTRO-WATSON, 2021).

Outro ponto mais delicado é a danificação das placas. Quando apenas uma parte do painel fotovoltaico está recebendo luz solar, o pedaço sombreado acaba realizando um efeito contrário: os raios de sol, absorvidos na parte funcionante, são dissipados como calor no local sombreado. Em bem pouco tempo, isso pode danificar o (EVA) - Etil, Vinil e Acetato, a película de isolamento das células solares.

Visto o quão prejudicial o sombreamento nos painéis pode ser, é essencial saber como evitá-lo. Tudo deve começar pelo projeto. É necessária uma análise detalhada sobre o ambiente antes da instalação: não apenas ver se a luz do sol incide no local, mas entender como ela se comporta. Esta análise é chamada de cálculo do sombreamento do projeto (KIM; KREIN, 2015).

Outra medida para evitar esse problema é cuidar das manutenções após a instalação. Fatores externos podem acontecer, como novas construções ao redor, e uma boa forma de prolongar a vida útil e a eficiência do seu sistema é fazer uma checagem periódica da incidência solar.

Entretanto, existem casos onde não é possível evitar os sombreamentos. Nesta situação, o fator sombreamento é levado em consideração durante o cálculo do projeto. Dessa forma, a produção de energia não é prejudicada e, conseqüentemente, o retorno financeiro também não.

A economia é garantida ao decorrer do tempo em um sistema bem dimensionado e bem instalado com suas manutenções em dia. Em média, em 6 anos todo o sistema se paga, se for financiado, e o fabricante ainda garante um rendimento de até 70% em 25 anos, então, de acordo com o (portalsolar, 2022), são 20 anos de energia grátis para uma instalação doméstica.

1.1 Motivação

Este trabalho é motivado pela necessidade de elencar formas de detecção de falhas em painéis solares. Este é um equipamento considerado caro e que tem durabilidade elevada em funcionamento adequado. Entretanto, uma falha pode danificar um módulo solar em

poucos dias. Com uso de um equipamento computadorizado embarcado e um conjunto de algoritmos, é possível construir uma solução capaz de detectar uma falha no momento que ela ocorre, bem como analisando os dados do painel, pode-se evitar a falha antes de ela ocorra (LIM et al., 2016). Com isto, é feita uma previsão de falha com o intuito de manter a durabilidade do equipamento.

1.2 Descrição do problema

O sombreamento parcial gera bastante aquecimento nas células do módulo solar, o uso de diodos de *by-pass* ajuda até certo ponto para proteger as células, quando mais de uma célula sofre sombreamento o diodo não consegue mais ajudar, o diodo de proteção acaba aquecendo e modificando as características de funcionamento ideal e apresentando mudança nos valores de corrente e tensão. Com esta mudança nos diodos de proteção, pode-se estimar a gravidade da falha e alertar ao operador do sistema antes que a falha seja permanente, garantindo a segurança do sistema, sua energia gerada e sua durabilidade. Além da questão técnica aqui defendida, há um fator limitante da ausência de *datasets* públicos que auxiliem o processo de identificação das falhas. Isso se torna uma contribuição necessária para que trabalhos similares a este possam avançar para o modelo ideal de detecção (ANCUTA; CEPISCA, 2011).

1.3 Objetivos Geral e Específicos

No sentido amplo, o objetivo geral deste trabalho é avaliar a identificação de padrões de anomalias nas medições de grandezas elétricas, bem como a caracterização da irradiância solar sobre painéis fotovoltaicos no contexto de sistemas embarcados *offline* com processadores e memória limitados.

Em seu sentido mais particular, os objetivos específicos são:

- Elencar sensores para monitoramento de parâmetros de geração de energia por painéis fotovoltaicos.
- Armazenar dados históricos advindos do sistema de sensoriamento, gerando assim um *dataset* qualificado.
- Associar a irradiância solar com o desempenho de geração dos painéis fotovoltaicos.
- Extrair características pré-processadas na construção de um dataset classificável.
- Aplicar técnicas de *machine learning* sobre o dataset e caracterização de classes de normalidade e anomalia.
- Analisar o processo de embarcar o modelo treinado em sistema embarcado não conectado à Internet.

1.4 Produção

Durante o desenvolvimento desta pesquisa, o seguinte trabalho científico foi publicado:

Souza, Vagner Henrique de, Wendell Rodrigues, and Matheus Lima "**SmartGrid Improvements on Photovoltaic Systems by Analyzing Energy and Weather Measures**," *advance2023 : International Workshop on ADVANCEs in ICT Infrastructures and Services*, 2023, pp. 1-5.

1.5 Estrutura da Dissertação

A estrutura desta dissertação é dividida em 4 capítulos. No Capítulo 2 são descritos trabalhos correlatos sobre o assunto, o funcionamento dos módulos fotovoltaicos, os problemas relacionados aos módulos e as técnicas para identificar padrões em painéis solares. No Capítulo 3 é apresentada a metodologia, como os algoritmos que foram desenvolvidos e testados para predição de falhas e detecção. No Capítulo 4 são discutido os resultados do trabalho e por fim, a conclusão e perspectivas futuras e cronograma final de atividades são vistos no Capítulo 5.

2 Fundamentos Teóricos

Neste capítulo serão apresentados os principais conceitos de Geração Fotovoltaica (FV), os principais equipamentos e os problemas que podem gerar defeitos, bem como os modos de medição de energia. Por seguinte, são apresentados o carácter dos dados de medição e os principais modos de classificação do mesmo, demonstrando as principais técnicas.

2.1 Sistemas Fotovoltaicos

Krauter (KRAUTER, 2006) define a energia fotovoltaica (PV) como uma energia elétrica solar gerada através da conversão direta da radiação solar em eletricidade. Atualmente, essa conversão pode atingir cerca de 26% dos 33% teóricos da irradiância solar recebida.

Segundo Sumathi (SUMATHI; KUMAR; SUREKHA, 2015), em 2010, entre a energia total mundial, a contribuição da energia solar fotovoltaica era uma fração muito pequena. No entanto, um rápido crescimento é observado na instalação de energia solar fotovoltaica e continuaria a aumentar nos próximos anos. No Cenário Novas Políticas, a energia gerada a partir da energia solar fotovoltaica em 2035 é mais de 26 vezes a de 2010, passando de 32 Twh para 846 Twh. A energia da energia solar fotovoltaica instalada aumentaria de 67 GW em 2011 para 600 GW em 2035, por conta da redução de gastos e ajudas governamentais.

Assim, a indústria e outros setores produtivos da sociedade têm altos ganhos competitivos ao adotar esta tecnologia.

Resumidamente, um único dispositivo fotovoltaico é conhecido como célula. Uma célula fotovoltaica individual geralmente é pequena, geralmente produzindo cerca de 1 ou 2 watts de potência. Essas células são feitas de diferentes materiais semicondutores e geralmente têm menos do que a espessura de quatro fios de cabelo humanos. A fim de resistir ao ar livre por muitos anos, as células são colocadas entre materiais de proteção em uma combinação de vidro e/ou plástico.

Os módulos fotovoltaicos e as matrizes são apenas uma parte de um sistema fotovoltaico. Os sistemas também incluem estruturas de suporte, juntamente com os componentes, como inversores, que pegam a eletricidade de corrente contínua (CC) produzida pelos módulos e a convertem em eletricidade de corrente alternada (CA) usada para alimentar dispositivos elétricos.

2.2 Geração distribuída de energia elétrica


A energia elétrica faz parte do dia a dia do mundo e é a que precisa de mais suporte para manter sua distribuição e fornecimento aos consumidores.

Várias são fontes de energia que são facilmente convertidas em energia elétrica, energia potencial das hidroelétricas, energias químicas das usinas nucleares, as energias dos ventos entre outras.

Em Hidayat e Li (2013) explica que a geração distribuída de energia precisa de componentes geradores e consumidores interligados proximamente na rede elétrica. Há dois pontos que é preciso entender, como funciona a geração centralizada de energia e a geração descentralizada, na geração concentrada os elementos geradores de energia e os elementos consumidores de energia são distintos, por exemplo, uma parque eólico, uma usina nuclear, uma hidroelétrica e um parque solar, são elementos geradores de um sistema centralizado, na outra, o ponto de um sistema centralizado há os consumidores residências, grandes indústrias, o comércio de bens de consumo, e outros empreendimentos em geral como shoppings etc.

A principal característica desse sistema é que a geração de energia e o consumidor são elementos distintos do sistema. Como o produtor e o consumidor de energia em geral estão fisicamente separados, há a necessidade de haver vários elementos de conversão de energia e por conseguinte há muita perda de energia nesse processo (HIDAYAT; LI, 2013).

Figura 1 – Geração Distribuída



Fonte: canalsolar.com.br/o-que-e-geracao-distribuida-de-energia-eletrica/

Na Figura 1, é visto um exemplo de um modelo de geração de energia distribuída de várias fontes possíveis, as setas azuis representam a geração de energia centralizada, em verdade a geração de energia descentralizada e em vermelha as setas dos consumidores, podemos observar duas coisas importantes na Figura 1, primeiramente a geração de energia fica fisicamente mais próximo dos consumidores (HIDAYAT; LI, 2013), outro ponto importante é que o consumidor pode ser também produtor de energia, em muitos casos a energia gerada excede o consumo do domicílio ou empreendimento, no caso muitas concessionárias de energia permite a geração de créditos para uso futuro, ou ser descontados em outros domicílios.

2.3 Módulos Fotovoltaicos e Grandes Usinas

No Brasil, o maior produtor de energia elétrica é a hidroelétrica, que é um problema quando há escassez de água. Além dela, tem a energia eólica, queima de minerais como carvão e a captação direta da luz solar, entre outras, há algumas que não são de fontes solares, são elas a degradação de elementos químicos como o urânio e a exploração de fontes geotérmicas para a movimentação de turbinas geradoras de energia, visto em outros países.

Na geração de energia com a captação de luz solar, o processo de geração de energia FV é bastante diverso, vai de uma micro geração com um módulo FV e um conversor DC/AC para atender um pequeno equipamento instalado em local ermo até grande usinas que podem atender diversas cidades com capacidade de geração na casa de vários Mega Wh. A seguir é explanado em detalhes a geração de energia FV e seus principais problemas e desafios.


2.3.1 Funcionamento dos Módulos Fotovoltaicos

Os módulos solares geram energia elétrica a partir da irradiância solar, sensibilizando um conjunto de diodos especiais que são ligados em série para somar a tensão e são postos em paralelo para somar a corrente elétrica, quando o sol atinge a célula os elétrons dos diodos são sensibilizados criando uma tensão que movimentam os elétrons, gerando uma corrente elétrica (LIM et al., 2016).

Cada célula contribui com 100% da corrente elétrica quando ligados em série, sendo série a ligação mais comum, mas cada célula contribui somente com 0,55 volt, então para construir um painel solar de 42 volts nominal, são necessários 72 células solares fotovoltaicas. Como proteção, os diodos são divididos em três conjuntos protegidos por diodos de by-pass. Na Figura 2, pode-se observar a componente I_{ph} que representa a fonte geradora de corrente por incidência solar, I_{ph} depende do nível de radiação solar, I_d , a corrente do diodo só é ativa quando a célula está gerando energia e não está senso

consumida por R , logo $I_{ph} = I$, com o circuito fechado e $I_{ph} = I_d$ quando o circuito está aberto. (PLATONOVA; TOROPOV; TULIKOV, 2019)

Figura 2 – Circuito equivalente de uma célula FV




Fonte: www.ecorienergiasolar.com.br/

São três os tipos de células segundo sua construção:

- Monocristalinos – São mais eficientes e feitos de células monocristalinas de silício, de onde vem seu nome. O silício possui elevada pureza, o que envolve um processo de fabricar mais elaborado;
- Células Policristalinos – São um pouco menos eficientes que os monocristalinos. Nestes painéis as células são formadas por diversos e não somente um cristal, dando uma aparência de vidro quebrado à célula;
- Painéis de Filme Fino – O material fotovoltaico é depositado diretamente sobre uma superfície, como metal ou vidro para formar o painel. São mais baratos e também menos eficientes. A área disponível pode ser uma restrição, pois a baixa eficiência deve ser compensada por uma área maior.

Na Figura 3 podemos ver exemplos de células policristalinas e monocristalinas, que são os dois tipos de células mais utilizadas no momento, uma outra diferença entre as células mono e policristalinas é que estas não precisam que suas bordas sejam cortadas, e costumam ser aplicadas aos módulos em sua forma quadrada.

Figura 3 – Tipos de Células

**POLICRISTALINO****MONOCRISTALINO**

Fonte: Editadas pelo Autor

Por causa do seu processo de fabricação mais simples, as células de silício policristalino possuem custos mais baixos e, até pouco tempo atrás, eram o tipo mais comercializado em painéis fotovoltaicos no mundo (portalsolar, 2022).


No entanto, o aperfeiçoamento dos processos de fabricação de células monocristalinas trouxe uma queda de seus custos, e desde 2019 elas vêm ganhando espaço por apresentarem maior eficiência.

A eficiência de células de silício policristalino é de 13% a 15%.

2.3.2 Montagem Módulo Fotovoltaico

A estrutura de um Módulo Fotovoltaico (MFV) representado na Figura 4, é de uma pilha de equipamentos selada com fusão em alta temperatura com propósito de vedar o equipamento contra chuva, umidade e corrosividade (eco-greenenergy.com, 2022). As partes do módulo solar são:

Figura 4 – Montagem do Módulo Fotovoltaico



Fonte: <https://www.eco-greenenergy.com/pt-pt/o-que-e-o-eva/>

- Frame - ou moldura é a parte do módulo que agrega todos os outros equipamentos dos módulos e fornece resistência mecânica;
- Glass - ou vidro, é uma lâmina especial de material transparente, geralmente vidro, que oferece resistência mecânica e proteção às células FV, ajuda na dissipação de calor e oferece estrutura para o módulo em geral;
- EVA - é uma parte essencial para a adesão das células solares ao vidro e ao back sheet, facilita na dissipação de calor e durante sua fusão, preenche as lacunas entre as células e superfícies, com objetivo de minimizar os impactos mecânicos sobre as células;
- Back Sheet - ou folha de fundo, é uma tela geralmente em metal para fornecer suporte mecânico e dissipação de calor;
- Junction Box - ou caixa de junção é onde são feitas as interconexões dos polos positivos e negativos do módulo.

2.3.3 Componentes de um Sistema fotovoltaico

Em Ma et al. (2019) verificamos os principais componentes de um sistema fotovoltaico para geração de energia elétrica utilizando painéis solares são variados, podendo ter diversas configurações, painéis em série ou em paralelo, com inversor ou carregador de bateria, as possibilidades são diversas, mas podemos dividir em três tipos básicos, on-grid, off-grid e híbrido. O sistema on-grid é conectado à rede elétrica de distribuição de energia. Toda a energia é injetada diretamente na rede da concessionária, se o domicílio ou empresa consumir totalmente a energia produzida, a rede elétrica fornece somente o que faltar para

o consumidor, se o sistema exceder o consumo há necessidade de um medidor de energia especial, que contabilize a energia fornecida para a rede elétrica, assim gerando créditos para o usuário. A Figura 5 apresenta um esquema dos componentes de um sistema.

Figura 5 – Componentes de um sistema fotovoltaico



Fonte: nucleoats.ind.br/sistema-fotovoltaico/

O sistema off-grid não é conectado à rede elétrica de distribuição e o armazenando da energia solar é alocado em baterias. A energia armazenada nas baterias é distribuída de forma direta para os equipamentos domésticos e eletrônicos. Este modo é muito utilizado em locais que não são atendidos concessionária (MA et al., 2019). O sistema híbrido tem sua operação de modo simultâneo, entre on-grid e off-grid, fazendo com que ocorra o trabalho conectado à rede enquanto o banco de baterias está carregando, e vice-versa.

2.4 Falhas em painéis solares

Cada painel solar é um conjunto de várias células solares trabalhando em conjunto, a eficiência do módulo solar, ou painel, depende do funcionamento individual de cada célula, uma ou mais células com problema na geração de energia afeta todo conjunto, a célula que não gerar energia acabar por consumi-la, gerando calor, danificando as células vizinhas e a película EVA que protege as células na moldura do módulo solar. Para ajudar a proteger as células que estão com sobreaquecimento, os módulos são construídos dividindo os conjuntos de células em três e aplicando um diodo de By-pass em cada conjunto, desta forma o diodo passa a aquecer no lugar da célula com sobreaquecimento (LIM et al., 2016).

O principal problemas que incide sobre o módulo solar é o sombreamento, que pode ser total ou parcial:

Figura 6 – Exemplo de painéis solares parcialmente sombreados



Fonte: www.ecorienergiasolar.com.br/

- Parcial - No sombreamento parcial exemplificado na Figura 6, o sombreamento pode afetar algumas células do módulo gerando calor e degradação do módulo solar, além de afetando a produção energética;
- Total - Já no sombreamento total não há degradação do módulo solar, porém a produção energética é bastante afetada, alguns exemplos de sombreamento total é o aparecimento de nuvens, grandes estruturas cobrindo todo o módulo solar e o acúmulo de sujeira.

2.4.1 Rastreamento do Ponto de Maior Potência (MPPT)

A energia solar, sendo a fonte de energia mais prontamente disponível na Terra, pode se tornar um excelente substituto e ajudar a resolver a crise energética enfrentada pelo mundo.

As células fotovoltaicas são usadas para gerar energia elétrica a partir da energia solar, mas, por serem não lineares em suas características, são altamente ineficientes. Portanto, é difícil extrair a potência máxima das células fotovoltaicas solares em diferentes condições climáticas. O processo de geração de potência máxima possível a partir das células fotovoltaicas é conhecido como rastreamento de ponto de potência máxima (MPPT).


Uma variedade de algoritmos MPPT como o método de condutância incremental, o método de tensão fracionária, perturbar e observar, controle de lógica difusa, etc., foram desenvolvidos e estão sendo usados na indústria ao longo dos anos (FATEMI; SHADLU; TALEBKHAH, 2020).

Existe a necessidade de um mecanismo eficaz para estimar rapidamente o ponto de máxima potência devido à mudança contínua da intensidade da radiação solar (NEACA, 2021). Um sistema de conversão de energia solar geralmente é composto por um módulo fotovoltaico solar, controladores de carregador e uma estrutura de interconexão para fornecer a energia gerada para posterior distribuição.

Quando a radiação solar incide sobre o painel fotovoltaico, as células são excitadas levando à geração de fotocorrentes que são direcionadas para impedâncias de carga para consumo de energia. As características de fotocorrente e potência versus tensão de uma célula solar para diferentes intensidades de irradiação.

Na Figura 7, temos duas importantes curvas para exemplificar melhor como é encontrado P_{mp} (Ponto de Máxima Potência), e também alguns outros pontos importantes. Em vermelho temos a curva PV (potência-tensão), o ponto máximo da curva é também o P_{mp} o problema que esse ponto muda conforme a variação da irradiância solar e também de outros fatores como sombreamento.

Figura 7 – Ponto de Máxima Potência (MPP)



(canalsolar, 2023)

Ainda na figura 7, a curva em azul IV (corrente-tensão) mostra o comportamento da corrente em função da tensão, o ponto de máxima potência ocorre quando o produto $I \times V$ é o maior possível, o que devemos levar em consideração, é que há propriedade do módulo solar, a medida que drenamos corrente elétrica do módulo, a tensão tem uma queda, observe que o ponto V_{mp} (tensão de máxima potência), justamente com o I_{mp} (Corrente de máxima potência) indicam o P_{mp} , sendo sempre I_{mp} menor que o I_{sc} (Corrente de curto-circuito) e o V_{mp} menor que o V_{oc} (tensão de circuito aberto)(BOUTASSETA et al., 2021).

Em outras palavras, o controlador de carga ou inversor, datado de MPPT, constantemente drenando corrente e verificando se $V \times I$ é o máximo, utilizando o algoritmo de perturba e observa em muitos casos(GABOR et al., 2020).

Existe uma relação complexa entre radiação solar, temperatura e potência de saída nas células fotovoltaicas, o que cria uma relação não linear conhecida como características P-V e I-V. O objetivo do sistema MPPT é gerar os sinais de comutação para o conversor DC-DC de modo que a potência máxima possa ser obtida do painel PV em quaisquer condições ambientais (BOUTASSETA et al., 2021).


Nos últimos anos, vários esquemas de MPPT foram introduzidos que diferem em custo e complexidade, sensores necessários, velocidade de convergência, rastreabilidade e implementação de hardware.

A técnicas Hill Climbing (HC) e Perturb and Observe (P & O), que são muito populares por bastante simples. A base do método de subida é criar perturbações no ciclo de operação do conversor, o que causa uma perturbação na tensão e na corrente. No método P & O, aplicar uma perturbação na tensão PV aumenta ou diminui a potência de saída que se aproxima do MPP, continuando ou revertendo a próxima perturbação (FATEMI; SHADLU; TALEBKHAH, 2019).

2.5 Detecção de falhas

Analisando a Figura 8, temos um módulo solar composto de 72 células divididas em 3 conjuntos de 24 células, cada conjunto está protegido por um diodo de ByPass, as células em preto está exemplificando células sombreadas, quando sombreadas as células são polarizadas reversamente dificultando a passagem de corrente elétrica. Com o uso do diodo, a corrente elétrica encontra um novo caminho, impedindo que as células sombreadas aqueçam (LIM et al., 2016).

Figura 8 – Diodos de bypass nos sistemas de energia solar fotovoltaica




Fonte: canalsolar.com.br

Para problemas como este, são apresentados alguns métodos de detecção destas falhas, como detecção de pontos quentes, detecção de padrões, verificação de irradiância, entre outros.

2.5.1 Detecção de Pontos quentes

O objetivo da termografia aérea é a inspeção dos painéis solares da usina fotovoltaica. A inspeção de cabos e conexões elétricas deve ser realizada por termografia terrestre, com câmeras manuais. Penetração de umidade causada geralmente por defeitos na folha plástica traseira (backsheet) do módulo. A presença de anomalias térmicas percebidas na forma de pontos quentes (hotspots) pode indicar a existência de alguns defeitos. Identificação de módulos defeituosos é importante para evitar problemas no desempenho e na segurança das usinas. Mesmo nas situações que não evoluem para casos de incêndio, os defeitos ocasionam a redução do desempenho e limitam a vida útil do sistema (GABOR et al., 2020). Algumas anomalias são vistas na Figura 9, na esquerda e imagem RGB e na direita a imagem termográfica.

Figura 9 – Hotspot causado pelo sombreamento de uma célula solar



Fonte: canalsolar.com.br

2.5.2 Usinas Fotovoltaicas

Diferenciando-se do setor de geração distribuída, no qual os próprios consumidores produzem sua energia por meio de sistemas de micro e minigeração, a usina solar é capaz de gerar energia em grande escala, de forma centralizada.

As usinas solares consistem, portanto, em sistemas fotovoltaicos de grandes dimensões, desenvolvidos para a produção e comercialização de energia elétrica. Para isso, milhares de MFV's são utilizados.

Apesar de atuar em uma escala maior, a usina solar fotovoltaica funciona de maneira semelhante ao sistema de energia solar fotovoltaica residencial. As usinas solares utilizam placas fotovoltaicas, que contam com células fotovoltaicas em sua composição. Essas são responsáveis por absorver a energia do sol, criando um potencial elétrico e, dessa forma, produzindo energia. A energia gerada, que se encontra em corrente contínua, é direcionada aos inversores, que a transformam em corrente alternada, possibilitando o seu consumo.

2.6 Detecção de Padrões

Em Lari et al. (2021) confirma-se que produção de energia fotovoltaica depende muito de situações ambientais logo um estudo dos efeitos ambientais são muito importantes para a previsão de geração de energia. Isto inclui aprovar o desempenho ideal dos conversores de energia solar, atendendo à maior demanda em várias circunstâncias ambientais.

Os principais dados estudados são temperatura do ar, umidade relativa, temperatura da superfície fotovoltaica, irradiância, poeira, velocidade do vento e potência de saída. Um

modelo foi sugerido no trabalho de Lari et al. (2021), para ajusta e treina três algoritmos de previsão, incluindo Rede Neural Artificial, Multi-Variate e Support Vector Machine (SVM). O modelo explora três algoritmos de previsão bem conhecidos e algoritmo de votação para determinar a probabilidade ideal de geração de energia fotovoltaica. Com isso foi possível prever a geração de energia FV com precisão a cima de 90%.

2.6.1 Árvore de decisão

Uma árvore de decisão é um algoritmo de aprendizado de máquina supervisionado que é utilizado para classificação e para regressão. Isto é, pode ser usado para prever categorias discretas (sim ou não, por exemplo) e para prever valores numéricos (o valor do lucro em reais) (GAVANKAR; SAWARKAR, 2015).

Assim como um fluxograma, a árvore de decisão estabelece nós (*decision nodes*) que se relacionam entre si por uma hierarquia. Existe o nó-raiz (*root node*), que é o mais importante, e os nós-folha (*leaf nodes*), que são os resultados finais. No contexto de machine learning, o raiz é um dos atributos da base de dados e o nó-folha é a classe ou o valor que será gerado como resposta.

Em (MEDDAGE et al., 2021) foi desenvolvido um modelo baseado em aprendizado de máquina rápido e computacionalmente econômico para prever os coeficientes de pressão externa média da superfície de um edifício com uma configuração não convencional usando três regressores baseados em árvore: Adaboost, Extra Tree e RandomForest.

O algoritmo de machine learning ExtraTrees (*Extremely Randomized Trees*) cria muitas árvores de decisão de maneira aleatória, para então através da combinação dos resultados de cada árvore encontrar a resposta final. Seu principal diferencial está no fato deste processo ser extremamente aleatório, contribuindo assim para modelos mais generalizáveis.

2.6.2 RandomForest

No algoritmo Random Forest algumas amostras dos dados de treino são selecionadas de maneira aleatória, sendo que as árvores criadas pelo algoritmo não conterão a totalidade dos dados utilizados na construção do modelo.

Para definir a estrutura de cada árvore é feita uma seleção aleatória de variáveis, para que – dentre as selecionadas – aconteça a escolha daquela que estará no primeiro nó. Assim, tem-se duas etapas importantes do processo acontecendo de maneira aleatória, tanto a seleção de variáveis quanto a seleção de amostras.

2.6.3 Redes Neurais Convolucionais

Uma Rede Neural Convolucional (ConvNet) é um algoritmo de aprendizado profundo que pode captar uma imagem de entrada e atribuir importâncias como pesos e vieses a vários aspectos e objetos da imagem e ser capaz de diferenciar umas das outras. A arquitetura de uma ConvNet é análoga àquela do padrão de conectividade de neurônios no cérebro humano e foi inspirada na organização do córtex visual. (CHEN et al., 2018)


2.7 Significado dos fator de relevância em Painéis fotovoltaicos

São diversos os fatores que influenciam um módulo solar a atingir o seu ponto de maior eficiência, fatores como ângulo de instalação, irradiância e temperatura de trabalho são alguns fatores que influenciam bastante a produção e o rendimento final de energia por módulo. A seguir descreveremos os fatores mais importantes investigados nesse trabalho.

2.7.1 Irradiância Solar e seu sensoramento

A radiação solar é o fluxo de energia emitida pelo Sol e transmitida sob a forma de radiação eletromagnética. Durante muitos anos foi considerada uma constante em torno de $1.365 W m^2$. As medidas de radiação são denominadas como Irradiância Solar Total (*TSI* - *Total Solar Irradiance*) e Irradiância Solar Espectral (*SSI* - *Solar Spectral Irradiance*). A Irradiância Solar Total é definida como a potência total da energia proveniente do Sol por unidade de área a $1UA$ (distância entre o Sol e a Terra conhecida como Unidade Astronômica). As medidas podem ser realizadas em função do comprimento de onda [$W m^2 nm^1$] e integradas para determinar a TSI.

Figura 10 – Corrente elétrica em função da Irradiância



Fonte: (portalsolar, 2022)

Na Figura 10 vemos o gráfico da onda de corrente de um típico módulo solar para diferentes exposições à irradiância solar, 1000 W/m^2 , 750 W/m^2 , 500 W/m^2 e por fim 150 W/m^2 , a medida que a irradiância diminui a corrente elétrica e por conseguinte a energia gerada também diminui.

Irradiância é uma medida da quantidade de luz solar que incide sobre uma determinada superfície. O símbolo I é usado para denotar irradiação e sua unidade é W/m^2 . Com a mudança da hora do dia, a energia recebida do Sol pelo painel fotovoltaico muda, o ângulo de instalação, nuvens e outros fatores podem ser considerados para calcular a irradiância. A tensão e a corrente sendo ambas uma função da luz que incide sobre a célula, existe uma relação complexa entre irradiância e energia de saída (BURTA; SZABO, 2020).

Com o aumento da radiação solar, tanto a tensão de circuito aberto quanto a corrente de curto-circuito aumentam e, portanto, o ponto de potência máximo varia. O ângulo do sol, nuvens passageiras, neblina e poluição do ar podem afetar os níveis de irradiância. No entanto, a energia total recebida pelo sistema do sol permanece relativamente constante de ano para ano. É fato que o clima muda todos os dias e a posição da Terra em relação ao sol muda ao longo do ano. Isso significa que um painel solar em um local fixo pode produzir 55 W ao meio-dia de dezembro e 110 W ao meio-dia de junho. Da mesma forma, o mesmo painel pode produzir 130 kWh por ano em uma localização geográfica e apenas 105 kWh em outra. Em ambas as situações, a diferença de produção é em grande parte devido a diferentes quantidades de luz solar.

Alguns equipamentos especiais são utilizados para sensorear a luminosidade eficaz instantânea em W/m^2 , um dos mais utilizados é piranômetro, Figura 11, é capaz de medir com bastante sensibilidade a irradiância solar do ambiente.

Figura 11 – Sensor de luminosidade, piranômetro.



Fonte: o autor.

O piranômetro da figura 11, é composto de um corpo metálico, um cabo longo que será ligado no equipamento de medição e uma janela vidro, por onde passará a luminosidade do dia inteiro. Sua sensibilidade pode ser dada em $\mu V W/m^2$, micro Voltes por metro quadrado, ou utilizando-se de um sensor de corrente de 4mA a 20 mA. Nesse caso o máximo de medição é dado por uma proporção em relação ao máximo da medição do sensor (CAMPANELLI; OSTERWALD, 2016).

2.7.2 Influencia da Temperatura no MFV


Muito similar a outros dispositivos semicondutores, as células solares também são sensíveis aos níveis de temperatura. Aumentos na temperatura do material afetam os parâmetros do material. À medida que a temperatura do módulo solar aumenta, sua corrente de saída aumenta discretamente, enquanto a saída de tensão é reduzida linearmente. Como resultado, o calor pode reduzir severamente a geração do módulo solar.

O aumento de I_{sc} , deve-se ao fato de que quando a temperatura do silício aumenta, ocorre uma redução do valor do gap de energia do material, tornando mais fácil a geração de pares elétron-buraco por fótons. O valor de I_{sc} aumenta cerca de 0,07% por grau Kelvin (LARI et al., 2021).

O valor de V_{oc} diminui cerca de 0,4% para cada aumento de um grau Celsius, pois o valor da tensão de circuito aberto também está relacionado ao valor do gap do semicondutor. Como o valor de corrente e tensão dependem da temperatura, o valor da potência de saída também depende, e reduz cerca de 0,4% a 0,5% por grau Celsius.

Nas células de silício esta diminuição de potência é de 0,35 a 0,45% por grau Celsius de aumento de temperatura. A diminuição da potência útil é principalmente devida a uma diminuição da tensão de circuito aberto, em consequência da difusão dos portadores minoritários.

Figura 12 – Montagem do Módulo Fotovoltaico



Fonte: (portalsolar, 2022)

2.8 Trabalhos Correlatos

A literatura técnico-científica da área tem apresentado alguns trabalhos correlatos ao tema abordado nesta dissertação.

Em Parikh et al. (2020) é listado as diversas formas de detecção de falhas em Módulos fotovoltaicos (MFV), como por exemplo, a detecção por imagens RGB ou imagens térmicas ou também o rastreamento de máxima potência dos MFV, com uma ampla gama de defeitos, falhas e degradação que pode se desenvolver em diferentes estágios da vida útil dos MFV. Para avaliar com precisão seu efeito no desempenho do módulo, essas falhas precisam ser detectadas e quantificadas.

A imagem de eletroluminescência (EL) é um poderoso método de diagnóstico, fornecendo imagens de alta resolução espacial de células e módulos solares. Na EL há a necessidade de criar uma sala escura onde é aplicado uma potência nos módulos, assim os módulos liberam luminosidade que são detectadas por câmeras especiais.

Utilizando extratores das imagens adquiridas com esse método, é possível adquirir bons resultados na detecção de falhas estruturais nos MFV, no trabalho de Parikh et

al. (2020) a máquina preditiva foi treinada usando descritores para classificar os defeitos detectados em três categorias: rachaduras, microtrincas, falhas por sujeira e nenhuma falha.

Ao comparar os métodos desenvolvidos com os comumente utilizados, este estudo demonstra que o pré-processamento de imagens em um vetor de características de parâmetros estatísticos, fornece uma precisão de classificação maior do que seria obtida apenas por imagens brutas. O método proposto pode detectar de forma autônoma rachaduras e falhas por sujeira, permitindo a inspeção EL externa usando um sistema montado em drone para avaliações rápidas de campos fotovoltaicos.

No trabalho de Silva et al. (2022) foi proposto uma metodologia para a previsão horária da potência fotovoltaica FV de duas usinas instaladas na região metropolitana de Fortaleza - CE. A metodologia utiliza duas Redes Neurais Artificiais (RNA) para prever séries temporais: tipo Perceptron com Múltiplas Camadas (MLP) e funções de base radial (RBF), treinadas com dados históricos de potência fotovoltaica horária coletada durante o ano de 2020 nas localidades em estudo. Com esse modelo foi possível prever o comportamento da planta com precisão de 80%, sendo a acurácia da MLP melhor que em RBF, neste modelo uma tratamento dos dados inicialmente poderia gerar um resultado melhor, também uma forma de melhorar os resultados, seria o uso de novas variáveis.

2.8.1 Fatores para geração de Energia PV

A entrega anual de energia de um sistema fotovoltaico depende de muitos fatores, tipos de células dos módulos, irradiância, temperatura, localização geográfica, clima, ângulos de montagem, albedo local, sombreamento de módulos ou objetos vizinhos, sujeira, tipo de inversores, se o sistema é rastreamento ou estático, se o armazenamento está integrado e se o sistema está limitado a uma determinada potência máxima do sistema.

A receita do sistema está fortemente ligada à entrega de energia, mas com alta penetração de PV na rede, o valor da energia produzida durante os horários de baixa irradiância do dia pode ser maior do que durante os períodos de alta irradiância.

Superestimar o desempenho em baixas irradiâncias focando em dados de alta irradiância pode resultar em perdas significativas de receita (GARG; CHOCHAN; DOBHALL, 2021).

3 Metodologia

Neste capítulo são apresentados os materiais e métodos utilizados no desenvolvimento do sistema proposto para o detecção de falhas em painéis solares utilizando *machine learning* (**aprendizado de máquinas**). Como produto busca-se uma solução de hardware para aquisição de dados, um *dataset* e um rede treinada para detecção de padrões capaz de determinar se um conjunto de dados faz parte de um sistema PV com defeitos.

3.1 Métodos de Detecção e Predição de Falhas

Uma maneira eficaz de detectar mudanças de padrão é comparar um grande número de medidas em diferentes dias em diferentes condições climáticas. Normalmente, a tensão e a corrente sofrem pequenas alterações se tivermos a mesma irradiância solar (SOLANKI et al., 2018).

Figura 13 – Sistema de Captura de dados Experimental



Fonte: o autor.


Assim, um levantamento experimental foi implementado a fim de adquirir medidas elétricas de PV em diversas condições de tempo e clima. A Figura 13 mostra os elementos deste banco de teste adicional para análise em pequena escala adicionando interferência externa, como sujeira ou sombras. Durante a produção de energia para abastecer um pequeno conjunto de cargas (lâmpadas e tomadas), são realizadas três medições: tensão, corrente (portanto, potência) e irradiância solar de um sensor de medição externo.

A corrente e a tensão vêm do inversor instalado e todas essas medidas são armazenadas como dados de séries temporais. Os dados são processados usando alguns scripts python para serem usados como informações de entrada para métodos de reconhecimento de padrões. No entanto, para validar dados de pequena escala em usinas maiores, usamos dados adquiridos de inversores comerciais e estação meteorológica.

Esse problema se encaixa normalmente em métodos de regressão. A análise de regressão é um conjunto de processos estatísticos para estimar as relações entre uma variável dependente (*geralmente chamada de variável de resultado ou alvo*) e uma ou mais variáveis independentes (*geralmente chamadas de recursos, preditores ou covariáveis*). O objetivo da regressão no aprendizado de máquina é prever valores contínuos, como energia gerada.

Na Figura 14 é vista a representação completa para o sistema de detecção de falhas em painéis solares, uma abordagem utiliza de imagens em uma segunda abordagem.

Figura 14 – Sistema off-Grid usando MPPT



Fonte: o autor.

3.2 Sistema de geração distribuída de energia

A micro geração de energia solar refere-se à geração de energia elétrica em pequena escala usando painéis solares instalados em uma residência, edifício comercial ou propriedade rural. Essa energia pode ser usada para alimentar as necessidades energéticas da propriedade.

Para instalar um sistema de micro geração de energia solar, são necessárias algumas etapas:

1. **Avaliação:** Antes de instalar um sistema de energia solar, é importante avaliar a viabilidade do projeto. Isso pode envolver uma avaliação da exposição solar da propriedade, o consumo de energia atual e a análise financeira.
2. **Design do sistema:** Com base nos resultados da avaliação, o sistema de energia solar pode ser projetado para atender às necessidades energéticas da propriedade. Isso inclui a seleção do tipo e tamanho dos painéis solares, inversor, baterias (se houver) e outras peças de equipamento necessárias.
3. **Instalação:** Após o projeto, os painéis solares são instalados no telhado da propriedade e conectados ao sistema elétrico da propriedade. Isso requer conhecimentos técnicos e habilidades elétricas, por isso é recomendável contratar um instalador profissional.
4. **Monitoramento:** Depois que o sistema é instalado, ele deve ser monitorado regularmente para garantir que esteja funcionando corretamente. Isso pode incluir a monitoração do consumo de energia, a manutenção do sistema de baterias (se houver) e a limpeza dos painéis solares.
5. **Financiamento:** A instalação de um sistema de energia solar pode ter um custo inicial elevado, mas existem várias opções de financiamento disponíveis para ajudar a cobrir esses custos. Essas opções incluem empréstimos bancários, programas de financiamento governamentais e programas de financiamento de terceiros.
6. **A micro geração de energia solar pode ter muitos benefícios, incluindo a redução das contas de energia, a redução das emissões de gases de efeito estufa e a independência energética. Além disso, em muitos casos, pode gerar economias financeiras a longo prazo.**

A microgeração de energia solar pode ser alcançada por meio da instalação de painéis solares fotovoltaicos no telhado ou em outro local ensolarado, como na Figura 15. Esses painéis convertem a luz solar em eletricidade, que pode ser usada diretamente pelo proprietário da residência ou empresa. A eletricidade que não é utilizada pode ser armazenada em baterias ou vendida de volta à rede elétrica convencional.

Figura 15 – Telhado IFCE, Campus Fortaleza



Fonte: o autor.

Os benefícios da microgeração de energia solar incluem a redução dos custos de energia elétrica, a independência da rede elétrica convencional, a redução da pegada de carbono e a geração de energia limpa e renovável. No entanto, a instalação de painéis solares pode ser cara e requer espaço adequado e um investimento inicial significativo.

No campus Fortaleza do IFCE, há instalado diversas usinas geradoras de energia, são divididas fisicamente nos blocos didáticos da instituição e cada uma funciona independentemente da outra, caso uma dê problema, não interfere no funcionamento das outras. Cada estação geradora é ligada à rede elétrica trifásica 380V, há um conjunto de proteções para garantir o funcionamento correto e evitar possíveis danos em caso de problemas.

Por conseguinte, os inversores são ligados também a rede de internet do campus, conectando ao servidor para que seus dados de medição, estado do sistema seja compartilhados.

Dessa forma é passível a aquisição de dados por meio do sistema fornecido pelo fabricante dos inversores.

3.3 Inversores Fotovoltaicos

Os inversores fotovoltaicos são equipamentos que convertem a energia elétrica produzida pelos painéis solares fotovoltaicos de corrente contínua (CC) em energia elétrica de corrente alternada (CA) utilizável em residências, empresas e outros tipos de edifícios.

Os inversores têm uma função fundamental nos sistemas de energia solar fotovoltaica, pois permitem que a energia elétrica produzida pelos painéis solares seja usada para alimentar aparelhos e equipamentos elétricos que usam a corrente alternada (CA). Sem os


inversores, a energia elétrica produzida pelos painéis teria que ser utilizada diretamente pela carga, sendo assim a carga teria que está preparada para utilizar eletricidade CC.

Os inversores também têm outras funções importantes, como o controle da tensão e corrente de saída, a maximização da produção de energia dos painéis solares e a comunicação com a rede elétrica, Inversores MPPT. Alguns modelos de inversores também incluem recursos adicionais, como monitoramento remoto, integração com sistemas de armazenamento de energia e gerenciamento inteligente de energia.

Existem vários tipos de inversores disponíveis no mercado, incluindo inversores centrais, inversores de string e microinversores. Os inversores centrais são usados em sistemas de grande porte, enquanto os inversores de string são usados em sistemas de tamanho médio. Os microinversores são usados em sistemas de pequena a grande porte e têm a vantagem de serem instalados em cada painel solar ou pequenos grupos, permitindo um melhor controle e monitoramento da produção de energia, permitindo também a escalabilidade, e a separação dos módulos. Desta forma os módulos defeituosos não podem interferir nos módulos bons.

A escolha do tipo de inversor fotovoltaico depende das características específicas do sistema de energia solar fotovoltaica, como o tamanho do sistema, a configuração dos painéis solares e as condições de instalação. É importante escolher um inversor de alta qualidade e adequado para o sistema para garantir a máxima eficiência e desempenho.

Figura 16 – Teste de Campo com inversor não-linear



Fonte: o autor.

Na Figura 16 temos um inversor off-gride ligado em um painel com três cargas resistivas, lâmpadas de 60W, esse inversor foi alimentado por bateria e por um controlador de carga PWM que drenava corrente CC de dois módulos solares de 50W. O propósito do

teste foi verificar se o inversor conseguiria entregar a potência nominal para o sistema, o inversor atendeu bem a carga, mas a bateria foi insuficiente, tivemos que dobrar a carga das baterias de sete para 14 Ah.


3.4 Coleta de dados

A coleta de dados de medição é um processo importante para monitorar e controlar vários sistemas e processos, incluindo os sistemas de geração de energia solar. A medição e coleta de dados precisos são fundamentais para avaliar o desempenho do sistema e identificar oportunidades de melhoria.

No caso dos sistemas de geração de energia solar, a coleta de dados de medição pode incluir informações como a quantidade de energia elétrica produzida pelos painéis solares, a quantidade de energia elétrica consumida pelos usuários, a temperatura dos painéis solares, a velocidade do vento, a temperatura ambiente e outras variáveis relevantes para a operação e manutenção do sistema.

Existem diferentes maneiras de coletar dados de medição em sistemas de geração de energia solar. Uma das formas mais comuns é através do uso de equipamentos de monitoramento e medição específicos, como sensores de temperatura, medidores de energia elétrica e sistemas de monitoramento remoto. Esses equipamentos podem ser instalados nos próprios painéis solares, inversores e outros componentes do sistema para fornecer informações precisas sobre a operação e desempenho do sistema.

Figura 17 – Sistema com Medidor Bidirecional



Fonte: <https://homeassistantbrasil.com.br>


Além disso, as concessionárias de energia elétrica muitas vezes exigem que os sistemas de geração de energia solar estejam equipados com medidores de energia bidirecional como na Figura 17, que permitem a medição da energia elétrica produzida e da energia elétrica consumida pelo sistema. Esses medidores permitem que os usuários vendam o excesso de energia elétrica produzida pelos painéis solares de volta para a rede elétrica e também fornecem informações valiosas sobre o desempenho do sistema.

A coleta de dados de medição é essencial para garantir a eficiência e a confiabilidade dos sistemas de geração de energia solar. Os dados coletados permitem que os usuários monitorem e gerenciem o desempenho do sistema ao longo do tempo, identificando possíveis problemas e oportunidades de otimização.

3.4.1 Hardware de aquisição de dados

Há vários sistemas capazes de coleta e armazenamento de dados, como não tínhamos a proposta de armazenar muitas grandezas, optamos por construir uma solução de hardware capaz e fazer medições de energia, corrente e tensão, e outros valores importantes como temperatura e irradiância e armazenar em um sistema conectado a uma rede *IoT* utilizando o protocolo MQTT.

Figura 18 – Case do ESP32 e sensores conectados



Fonte: O autor.

Composto de uma case Figura 18, impressa em impressora 3D, um esp32, sensor de corrente ACS712 e um piranômetro ALS20 é um módulo solar de 50W, foi contraído uma

solução de hardware e software para testes, aquisição de dados e detecção das melhores variáveis para treinamento do regressor.

3.4.2 Protocolo MQTT

O MQTT (Message Queuing Telemetry Transport) é um protocolo de mensagens leve e de baixa largura de banda projetado para comunicação de dispositivos de Internet das Coisas (IoT). O protocolo MQTT foi desenvolvido para ser eficiente e confiável em redes de baixa largura de banda e alta latência, tornando-o ideal para uso em sistemas de IoT que usam dispositivos com recursos limitados.

O MQTT é baseado em um modelo de publicação/assinatura, onde os dispositivos publicam mensagens em tópicos e outros dispositivos podem se inscrever em tópicos específicos para receber essas mensagens. Os tópicos no MQTT são strings hierárquicas que podem ser usadas para organizar e filtrar mensagens.

O protocolo é baseado em um modelo de conexão cliente/servidor. O cliente MQTT pode ser um dispositivo IoT ou um aplicativo em execução em um servidor. O servidor MQTT é responsável por encaminhar mensagens entre os clientes, mantendo a conexão com os clientes e gerenciando a assinatura e publicação de tópicos.

Quando um dispositivo cliente MQTT deseja publicar uma mensagem, ele se conecta ao servidor MQTT e envia a mensagem para um tópico específico. O servidor MQTT então encaminha essa mensagem para todos os dispositivos clientes que se inscreveram nesse tópico. Quando um dispositivo cliente deseja receber uma mensagem em um tópico específico, ele se conecta ao servidor MQTT e se inscreve nesse tópico. O servidor MQTT então envia todas as mensagens publicadas nesse tópico para o dispositivo cliente.

O MQTT usa um modelo de comunicação assíncrona, o que significa que os dispositivos clientes não precisam manter uma conexão ativa com o servidor MQTT o tempo todo. Em vez disso, os dispositivos clientes podem estabelecer uma conexão com o servidor MQTT quando desejam publicar ou receber mensagens e desconectar quando a comunicação é concluída.

O protocolo MQTT suporta várias características importantes, incluindo qualidade de serviço (QoS), que controla a confiabilidade da entrega de mensagens, e Last Will and Testament (LWT), que permite que um dispositivo publique uma mensagem de "testamento" em caso de desconexão inesperada.

Em resumo, o protocolo MQTT é uma tecnologia eficiente e confiável para comunicação em sistemas de IoT. Ele usa um modelo de publicação/assinatura baseado em tópicos e suporta recursos importantes, como QoS e LWT, tornando-o uma escolha popular para a comunicação de dispositivos de IoT.

3.4.3 Controlador ESP 32

O ESP32 é um microcontrolador baseado no chip ESP32 da Espressif Systems, que possui conectividade WiFi e Bluetooth integrada, e é amplamente utilizado para projetos de Internet das Coisas (IoT), utilizamos o ESP32 nas dependências do IFCE-Fortaleza, logo a conectividade com o Wifi foi facilitada, assim conseguimos fazer medições utilizando POST na plataforma Tago Io.

Para programar o ESP32, você pode usar várias opções, incluindo a plataforma Arduino IDE ou o ambiente de desenvolvimento integrado (IDE) do ESP-IDF (ESP32 IoT Development Framework).

Além da IDE do arduino, utilizamos, várias bibliotecas para facilitar a conexão MQTT, leitura de sensores, conexão WiFi entre outras necessidades.

3.4.4 Calibração do sensor Piranômetro

Um piranômetro é um instrumento utilizado para medir a irradiância solar total que incide em uma superfície. Ele é projetado para medir a radiação solar direta e difusa em um determinado local.

O funcionamento básico de um piranômetro é relativamente simples. Ele consiste em um sensor sensível à radiação solar, geralmente uma célula termopilha, que é capaz de detectar a energia radiante que incide em sua superfície. Essa célula é cercada por um material com alta reflectância, geralmente uma camada de tinta branca, para minimizar a influência das fontes de radiação fora do campo de visão direto da célula.

A célula termopilha é constituída por vários termopares unidos em série, que geram uma tensão elétrica quando a radiação solar incide sobre ela. Essa tensão elétrica é proporcional à irradiância solar, que é medida em watts por metro quadrado (W/m^2).

O piranômetro é geralmente colocado em um suporte horizontal, e deve estar sempre apontado para o cenit (direção zenital). Dessa forma, a célula termopilha recebe apenas a radiação solar direta e a radiação solar difusa que incide diretamente sobre sua superfície. O piranômetro deve estar livre de obstruções, como árvores ou edifícios, que possam bloquear a radiação solar direta e difusa.

Utilizando-se do piranômetro digital da Figura 20, foi possível calibrar o nosso piranômetro ligado ao ESP32, é fácil ver que a medição perto do meio dia é mais ou menos $1000 Wm^2$, dentro do IFCE-Fortaleza, com nuvens esparsas, esse valor foi utilizado para calibrar o valor medida do piranômetro da Figura 19.

Figura 19 – Calibração Piranômetro



Fonte: O autor.

Figura 20 – Piranômetro Digital



Fonte: O autor.

Os piranômetros são amplamente utilizados em estudos climatológicos e meteorológicos, bem como em aplicações industriais e de energia solar. Eles são capazes de fornecer informações precisas sobre a quantidade de energia solar disponível em uma determinada região, o que é importante para o planejamento e a operação de sistemas de energia solar e outras aplicações que dependem da energia solar.


3.4.5 Aquisição de dados temporais

A aquisição de dados temporais refere-se à coleta de informações em diferentes momentos ao longo do tempo. Essa coleta de dados é fundamental em muitas áreas, como ciência, engenharia, medicina, finanças e outras, para monitorar e analisar o comportamento de sistemas e processos ao longo do tempo.

Existem várias maneiras de adquirir dados temporais. Uma delas é por meio de sensores, que são dispositivos projetados para medir e registrar dados em intervalos regulares ou em resposta a eventos específicos. Por exemplo, um sensor de temperatura pode ser usado para registrar a temperatura de um ambiente a cada 10 segundos, permitindo que sejam analisados como esses dados mudam ao longo do tempo.

Outra maneira de adquirir dados temporais é por meio de registros manuais, em que uma pessoa registra manualmente as informações em intervalos regulares. Embora essa abordagem possa ser mais demorada e propensa a erros do que o uso de sensores, ela ainda é comum em muitos campos.

Figura 21 – Parte do Dashboard do inversor



Fonte: O autor.

As tecnologias de aquisição de dados temporais podem variar dependendo do tipo de dados que está sendo coletado. Nós baixamos diretamente do inversor os dados brutos sequencialmente, catalogados em séries temporais, listados por dia, mês, e ano.

Foram aplicando algumas algoritmos para remover linhas sem informação ou repetições, algumas colunas indiferentes para nosso processamento também foram removidas.

Na Figura 21 está representado parte do dashboard do inversor, conseguimos ver o modelo a potência nominal de 50KW e outros valores.

Uma vez que os dados temporais são coletados, eles foram armazenados em um banco de dados ou planilha para posterior análise.

O uso de técnicas de análise de dados, como gráficos, regressão e análise de séries temporais, pode ajudar a identificar padrões e tendências nos dados ao longo do tempo, permitindo que os usuários entendam melhor o comportamento do sistema e tomem decisões informadas.

Em resumo, a aquisição de dados temporais é uma técnica essencial para monitorar e analisar o comportamento de sistemas e processos ao longo do tempo. Existem várias maneiras de adquirir dados temporais, incluindo o uso de sensores e registros manuais, e a análise desses dados pode fornecer informações valiosas para melhorar o desempenho e tomar decisões informadas.

3.5 Predição com Aprendizado de Máquina

Para os treinamentos e validações dos algoritmos comumente aplicados para regressão usando técnicas de aprendizado de máquina, optou-se pelo uso das bibliotecas do **Pycaret**. Pycaret é uma biblioteca de código aberto utilizada para aprendizado de máquina com pouco código em Python que automatiza fluxos de trabalho recorrentes com um mesmo *dataset* (pycaret.gitbook, 2022). Pycaret é uma ótima ferramenta de aprendizado de máquina e gerenciamento de modelos de ponta a ponta que acelera exponencialmente o ciclo de experimentos de modelos, no Pycaret é possível criar vários modelos de classificação, regressão, clusterização e outros.

Foi utilizado o Pycaret para a criação e avaliação dos modelos com uma base de dados adquiridos, um conjunto de dados com aproximadamente

3.5.1 Aprendizado supervisionado

O aprendizado supervisionado é aplicado quando tenta encontrar a relação entre a variável de alvo e as variáveis independentes. Uma das características mais importantes neste aprendizado é que os dados usados no treino do modelo devem ser “rotulados”, ou seja, nos dados de treino é preciso ter os dados anotados com os valores corretos e então, encontra o resultado de saída. Este tipo de aprendizado é aplicado em 2 tipos de problemas: Classificação e Regressão.

O Módulo de Classificação do PyCaret é um módulo de aprendizado de máquina supervisionado usado para classificar elementos em grupos. O objetivo é prever os rótulos de classe categórica que são discretos e não ordenados (pycaret.gitbook, 2022).

O Módulo de Regressão do PyCaret é um módulo de aprendizado de máquina supervisionado que é usado para estimar as relações entre uma variável dependente (geralmente chamada de 'variável de resultado' ou 'alvo') e uma ou mais variáveis independentes (geralmente chamadas de 'recursos', 'preditores', ou 'covariáveis'). O objetivo da regressão é prever valores contínuos, como prever o valor das vendas, prever a quantidade, prever a temperatura, etc (pycaret.gitbook, 2022).

3.5.2 Treinando com lightGBM

LightGBM (KE et al., 2017) estende o algoritmo Gradient Boosting Regressor (GBR) (FRIEDMAN, 2001) adicionando um tipo de seleção automática de recursos, bem como focando em exemplos de aumento com gradientes maiores. Isso pode resultar em uma aceleração dramática do treinamento e desempenho preditivo aprimorado. Lateral é preferível para nossa abordagem.

LightGBM é uma biblioteca de gradient boosting baseada em árvore de decisão, desenvolvida pela Microsoft. É uma técnica avançada de machine learning que utiliza árvores de decisão e uma abordagem de boosting para criar um modelo preditivo mais preciso e rápido.

O LightGBM utiliza o algoritmo de Gradient Boosting para construir modelos preditivos. Esse algoritmo é baseado na ideia de que um conjunto de modelos fracos pode ser combinado para formar um modelo mais forte. cada modelo fraco utilizado no LightGBM é uma árvore de decisão. As árvores de decisão dividem o espaço de características em regiões e fazem previsões com base nas características dos dados.

Uma das principais características do LightGBM é a abordagem de split de folha. Ao construir uma árvore de decisão, o LightGBM divide as folhas com os maiores gradientes em primeiro lugar. Essa abordagem permite que o algoritmo concentre a aprendizagem nas regiões com maior erro, o que pode levar a modelos mais precisos.

O LightGBM também utiliza a distribuição paralela para acelerar o treinamento de modelos em grandes conjuntos de dados. Ele divide os dados em partições menores e treina cada partição em paralelo. Isso pode levar a uma redução significativa no tempo de treinamento, e ainda utiliza uma estrutura de dados chamada Histograma de Gradiente para armazenar informações de gradiente. Isso permite que o algoritmo utilize a memória de forma mais eficiente e treine modelos em conjuntos de dados maiores.

O LightGBM é uma técnica de machine learning que utiliza árvores de decisão e a abordagem de boosting para criar modelos preditivos mais precisos e eficientes. Ele também usa a distribuição paralela e uma estrutura de dados eficiente em termos de memória para acelerar o treinamento em grandes conjuntos de dados.

Alguns passos foram seguidos para fazer o treinamento no LightGBM:

1. Preparação dos dados: Utilizando a plataforma dos inversores do IFCE, foi escrito um algoritmo Python para baixar os dados, muitas colunas foram descartadas por se tratarem de dados com relação direta, foram cruzado dados da estação meteorológica, juntamente com os dados medição do bloco central.
2. Definição dos parâmetros do modelo: Os parâmetros foram obtidos utilizando o regressor com diferentes entradas, os dados foram divididos em dois conjuntos, treinamento e teste..
3. Treinamento do modelo: O modelo foi treinado e foram obtido diversos parâmetros para aplicação em novos treinamentos.
4. Teste do modelo: O modelo foi testado com o conjunto de dados completo.

3.6 Integração do Sistema Distribuído MPI para Predição e Mapeamento de Sombreamento

3.6.1 Introdução

A continuidade da pesquisa apresentada nesta dissertação resultou na elaboração de um protótipo de processamento distribuído voltado para a otimização do desempenho de usinas fotovoltaicas. O trabalho publicado no Encontro Regional de Alto Desempenho (ERAD 2024) descreve o uso de um cluster de dispositivos Raspberry Pi interligados por uma rede Wi-Fi e coordenados via Message Passing Interface (MPI), possibilitando a execução de algoritmos de aprendizado de máquina diretamente na usina.

Essa extensão está em consonância com os objetivos centrais desta dissertação, que envolvem a identificação de falhas e anomalias em sistemas fotovoltaicos por meio da análise multivariada e técnicas de aprendizado de máquina. Enquanto os capítulos anteriores discutiram a coleta de dados, calibração de sensores e o treinamento do modelo LightGBM em ambiente controlado, o presente capítulo demonstra como esse modelo pode ser distribuído e executado localmente, reduzindo a dependência de infraestrutura em nuvem e garantindo maior resiliência operacional.

3.6.2 Motivação e Contexto

Conforme apresentado na seção 1.1 desta dissertação, as usinas solares frequentemente se localizam em áreas remotas, onde a infraestrutura de comunicação é limitada. A transmissão contínua de dados para servidores externos aumenta a latência e o custo de operação, dificultando a análise em tempo real.

O sistema proposto no artigo ERAD responde a essa limitação utilizando processamento local paralelo em dispositivos de baixo custo. A motivação é a mesma que norteia este trabalho: melhorar a confiabilidade e eficiência das usinas fotovoltaicas, assegurando que a detecção de falhas e a predição de potência possam ocorrer no próprio local de geração, mesmo com restrições de rede.

3.6.3 Arquitetura Distribuída com MPI

O Message Passing Interface (MPI) é um padrão de comunicação que permite que múltiplos processos executem tarefas paralelas e troquem mensagens entre si. No contexto desta pesquisa, cada Raspberry Pi atua como um nó de processamento, responsável por:

- Coletar dados de irradiância, temperatura e potência dos inversores;
- Processar localmente os dados com o algoritmo LightGBM;
- Enviar os resultados parciais para um nó mestre responsável pela consolidação.

Essa topologia cria um cluster heterogêneo e tolerante a falhas: qualquer nó pode assumir a função de mestre caso ocorra falha em outro. Essa característica é crucial para ambientes de campo, onde substituições de hardware precisam ser rápidas e de baixo custo.

A Figura 22 (que pode ser adaptada da Figura 1 do artigo) ilustra a arquitetura geral do cluster, destacando os módulos de aquisição, processamento e sincronização via MPI.

3.6.4 Integração com a Metodologia da Dissertação

Os algoritmos e as etapas descritos nos capítulos 1 e 2 — aquisição de dados, tratamento e treinamento de regressão com LightGBM — foram expandidos e adaptados para execução paralela. O dataset multivariado, originalmente composto por medições elétricas e meteorológicas obtidas no IFCE-Fortaleza, foi dividido entre os nós do cluster. Cada nó processa um subconjunto das instâncias e calcula os gradientes locais do LightGBM, que são sincronizados pelo MPI para atualização global do modelo.

Essa integração mantém o mesmo objetivo definido na dissertação: a identificação e predição de falhas, mas adiciona a camada de processamento distribuído. O uso do MPI permite que o modelo seja continuamente atualizado e implantado por meio de um pipeline CI/CD, automatizando as etapas de MLOps e ampliando a escalabilidade do sistema.

3.6.5 Implementação Experimental

Os experimentos realizados no âmbito do artigo ERAD envolveram a simulação de uma usina de 10 hectares composta por 100 Raspberry Pi equipados com sensores de

irradiância e conectados a inversores locais. A rede de comunicação foi estabelecida sobre uma malha Wi-Fi 6, garantindo baixa latência e cobertura uniforme.

O tempo médio de treinamento distribuído do LightGBM foi de aproximadamente 12 minutos por nó, para um conjunto de 8 000 instâncias e 100 iterações de boosting. O sistema demonstrou robustez e capacidade de auto-recuperação, redistribuindo o processamento automaticamente em caso de falha de algum nó.

Esses resultados complementam os experimentos de regressão apresentados no Capítulo 4, nos quais o LightGBM apresentou $R^2 = 0,87$ em ambiente centralizado. No cluster MPI, o desempenho manteve-se estável, com variação inferior a 2% entre o modelo global agregado e os modelos locais, comprovando a eficácia do paralelismo distribuído para tarefas de predição em tempo real.

3.6.6 Geração de Mapa Virtual de Sombreamento

Além do treinamento do modelo preditivo, o sistema distribuído é responsável pela criação de um mapa virtual de sombreamento da usina fotovoltaica. Cada nó do cluster calcula o nível de irradiância local e compartilha essas informações com os demais nós. A partir dessa troca de mensagens via MPI, é possível gerar um mapa dinâmico que representa a distribuição da luz solar sobre os módulos em tempo real.

Esse mapa serve como insumo adicional para o modelo LightGBM descrito na dissertação, aprimorando a correlação entre variáveis ambientais e a potência gerada. Essa abordagem de análise espacial multivariada reforça o caráter inovador da pesquisa, permitindo antecipar quedas de produção e identificar regiões críticas de sombreamento dentro da planta solar.

3.7 Comparação entre Abordagens de Detecção de Falhas

A detecção de falhas em sistemas fotovoltaicos pode ser realizada por diferentes abordagens, sendo as principais: (i) monitoramento de grandezas elétricas como tensão e corrente, e (ii) análise de imagens do painel associada a fatores ambientais, como irradiância e temperatura.




Figura 22 – Arquitetura proposta para o cluster MPI em usinas fotovoltaicas.
Fonte: O autor.

3.7.1 Medições Elétricas

A análise de sinais elétricos permite identificar desvios no comportamento típico das curvas I-V (corrente versus tensão) e P-V (potência versus tensão). Alterações como sombreamento, sujeira ou falhas internas nas células podem ser observadas como reduções abruptas na corrente de curto-circuito ou mudanças na tensão de circuito aberto.




Figura 23 – Comparação entre curva I-V em condições normais e com falha
Fonte: O autor.

3.7.2 Imagens e Dados Ambientais

A utilização de imagens visuais ou térmicas tem crescido como alternativa complementar ao monitoramento elétrico. Imagens capturadas por drones ou câmeras fixas

podem ser analisadas por redes neurais convolucionais para detecção de anomalias visuais como pontos quentes, trincas ou delaminação.

Aliado a isso, sensores de irradiância, temperatura ambiente e temperatura do módulo ajudam a contextualizar os dados, permitindo a normalização de medições elétricas e imagens, tornando a detecção de falhas mais robusta.



Figura 24 – Imagem térmica de painel fotovoltaico indicando célula com ponto quente
Fonte: O autor.

3.7.3 Considerações Comparativas

A Tabela 1 apresenta uma comparação entre as abordagens discutidas, considerando aspectos como custo, sensibilidade a falhas e necessidade de infraestrutura.

Tabela 1 – Comparação entre métodos de detecção de falhas

Critério	Medições Elétricas	Imagens e Ambiente
Custo	Baixo (sensores simples)	Médio a alto (câmeras, drones)
Detecção de falhas internas	Alta sensibilidade	Média
Visualização direta da falha	Não aplicável	Sim
Dependência de condições climáticas	Alta	Alta
Facilidade de automação	Alta	Alta (com IA)

4 Resultados

Foi desenvolvido um sistema de aquisição de dados baseado no microcontrolador ESP32, com capacidade de leitura contínua de grandezas elétricas e meteorológicas e transmissão dos dados para armazenamento em nuvem. As variáveis coletadas — tensão, corrente, potência e irradiância solar — serviram de base para o treinamento e validação do modelo preditivo, responsável pela detecção de falhas em módulos fotovoltaicos.

Para ampliar a precisão e a capacidade generalizadora do regressor, foram incorporadas múltiplas bases de dados provenientes de medições reais e simulações. O sistema também passou a incluir dados de módulos com diferentes tipos de defeitos físicos e elétricos, permitindo ao modelo aprender padrões mais complexos de degradação e comportamento anômalo.

Com o intuito de garantir maior fidedignidade ao conjunto de dados, as medições foram extraídas diretamente dos bancos de dados dos inversores e da estação meteorológica do IFCE – Campus Fortaleza. A infraestrutura local é composta por dezenas de strings de painéis solares, totalizando centenas de módulos, organizados em blocos independentes, cada qual com um inversor de 50 kVA.

A volumetria de dados obtida permitiu a criação de um dataset multivariado robusto, que alimentou tanto os experimentos centralizados descritos nesta dissertação quanto os testes distribuídos realizados no cluster MPI apresentado no ERAD. Essa integração possibilitou o aperfeiçoamento do modelo LightGBM, resultando em melhor desempenho preditivo, maior estabilidade estatística e redução dos erros médios absolutos, evidenciando a aplicabilidade da solução em ambientes reais de geração fotovoltaica.

4.1 Conjunto de dados de medição de PV

Os dados foram coletados ao longo de 6 meses no nordeste do Brasil durante 2021, onde o sol está disponível na maior parte do tempo. Para procedimentos de treinamento e validação, adquirimos dados de um inversor comercial conectado a algumas strings de painéis solares e, também, a uma estação meteorológica. Os dados foram combinados no tempo para vincular as medidas. Os inversores podem lidar com vários módulos MPPT e, portanto, permitem melhores cenários de layout.

Tabela 2 – Medidas cruzadas de dados de inversores e estação meteorológica.

DATETIME	IRRADI	StTEMP	WINDSPEED	PnTEMP	POWER
01/05/2021 13:21	570	31.3	2.4	51	11831
01/05/2021 13:22	109	31.3	2.2	50	11369
01/05/2021 13:23	109	31.3	2.2	50	42979
01/05/2021 13:24	111	31.3	2.4	50	10729
01/05/2021 13:25	111	31.3	2.4	50	44491
01/05/2021 13:26	563	31.3	2.4	50	44106
01/05/2021 13:27	563	31.3	2.4	51	42212
01/05/2021 13:28	84	31.3	1.8	51	8825
01/05/2021 13:29	84	31.3	1.8	51	8386

Fonte: o autor. Resultados experimentais.

Existem muitas medidas de saída da fonte de dados. No entanto, muitos deles podem ser calculados a partir das outras colunas. A pré-análise mostra características não relevantes e esclarece outras, como irradiação solar e temperatura. De fato, como os painéis transformam a luz solar em energia, a irradiância desempenha um papel fundamental na produção. Porém, não se pode desconsiderar que a temperatura e até mesmo a velocidade do vento (que ajuda a resfriar os painéis) contribuem diretamente para o melhor desempenho na geração de energia. Assim, o conjunto de dados é fornecido conforme mostrado na Tabela 2 com 35336 linhas e 6 colunas.

4.2 Comparando métodos

A Tabela 3 apresenta a comparação dos métodos de regressão ordenados por R^2 , o coeficiente de determinação indicando a proporção de variação entre a potência gerada e sua previsão.

Embora o tempo de treinamento para o método Light Gradient Boosting Machine (lightgbm) seja o mais longo, preferimos usá-lo como o melhor resultado sabendo que o tempo de treinamento não tem muito impacto na aplicação final.

Além disso, sempre é possível diminuir esse tempo computando em GPUs. Ainda observando os resultados, é importante observar que outros métodos como o Random Forests (BREIMAN, 2001) apresentam ganhos expressivos. O baixo tempo de treinamento possui um bom valor de R^2 e apresenta melhor resultado para a precisão indicada no Erro Percentual Absoluto Médio (MAPE). Este método é um excelente candidato quando o tempo de treinamento é um fator crítico na implementação da aplicação.

Tabela 3 – Métodos regressão.

Model	MAE	MSE	RMSE	R^2	RMSLE	MAPE	TT (Sec)
lightgbm	2953.3167	3.523394e+07	5933.3738	0.8705	0.5873	0.1750	300
gbr	3076.8711	3.620912e+07	6014.6031	0.8670	0.6267	0.2085	2.186
rf	2821.3143	3.858068e+07	6209.9684	0.8582	0.4255	0.1496	9.808
knn	3200.9721	4.239244e+07	6508.1509	0.8442	0.4262	0.1769	231
lr	4094.1461	4.443212e+07	6662.7248	0.8367	0.8606	0.4469	403
lasso	4092.0608	4.443848e+07	6663.1764	0.8367	0.8591	0.4479	62
ridge	4093.5858	4.443253e+07	6662.7510	0.8367	0.8601	0.4469	36
lar	4094.5139	4.443441e+07	6662.8956	0.8367	0.8635	0.4468	41
br	4092.0380	4.443597e+07	6662.9925	0.8367	0.8584	0.4474	77
llar	4120.2396	4.489454e+07	6696.9883	0.8351	0.8407	0.4629	40
et	2879.3797	4.660053e+07	6825.7398	0.8288	0.4145	0.1501	9.893
en	4542.0858	5.224133e+07	7223.4427	0.8081	0.9578	0.7955	84
omp	4672.4580	5.351067e+07	7310.9689	0.8034	0.8998	0.5791	27
huber	3771.4987	5.446469e+07	7374.9502	0.7999	0.6986	0.2994	1.293
ada	5317.3509	5.663545e+07	7524.5133	0.7919	0.7790	0.4537	635
dt	3354.4411	6.235039e+07	7894.1402	0.7708	0.4479	0.1737	186
par	4750.7526	7.142720e+07	8354.1221	0.7377	0.7240	0.3689	179
dummy	14337.4690	2.723538e+08	16502.6821	-0.0008	1.6260	4.1296	29


Fonte: o autor. Resultados experimentais.

4.3 Treinamento do Regressor

Um erro de previsão plota os alvos reais (energia gerada nos painéis) do conjunto de dados em relação aos valores previstos gerados por nosso modelo. Isso nos permite ver quanta variação há no modelo. O modelo de regressão tem uma linha de identidade bem ajustada ao comparar com a linha de 45 graus, onde a previsão corresponde exatamente ao modelo, Figura 25.


Uma curva de aprendizado mostra a pontuação de validação e treinamento do estimador para vários números de amostras de treinamento. Isso nos permite descobrir o quanto nos beneficiamos ao adicionar mais dados de treinamento e se o estimador sofre mais com um erro de variância ou um erro de viés. Na Figura 26, tanto a pontuação de validação cruzada quanto a pontuação de treinamento convergem para um valor bastante baixo com o aumento do tamanho das instâncias de treinamento.

Figura 25 – Gráfico de erro de previsão.



Fonte: o autor. Resultados experimentais.

Figura 26 – Curva de aprendizado para lightGBM.




Fonte: o autor. Resultados experimentais.

No conceito de predição, o peso das variáveis tem bastante influência na construção do modelo de predição, há no caso dois tipos de variáveis na criação de modelos. Variável independente ou preditora: é aquela que será passada para o modelo, tendo influência na variável que queremos encontrar. Variável alvo ou dependente: é a variável que queremos prever.

Neste estudo, a variável alvo, é derivada da potencia de saída do sistema, a importância das variáveis, retornará um array onde cada elemento é um variável do nosso modelo. Ele lhe dirá, em proporções, o quão importante é aquela variável para o modelo, onde quanto maior o valor, mais importante é a variável para o modelo. Como esperado, a irradiância é a característica mais importante do modelo, Figura 27. Porém, não é função direta da geração e, nos casos em que há interferências externas como sujeira nos painéis, esta variável pode indicar um padrão anômalo na geração.

Figura 27 – Importância das variáveis



Fonte: o autor. Resultados experimentais.

Na Figura 27, as variáveis ENVTEMPSTATION, ENVTEMPPANELS, temperatura da Estação e temperatura dos painéis, bem como a variável WINDSPEED, velocidade do vento, são também variáveis de grande importância para o regressor, isso porque uma grande característica dos módulos solares é que há uma temperatura de operação ideal, quanto mais baixa a temperatura, maior será a geração de energia, alguns fatores como, velocidade do vento, pode ajudar a resfriar os módulos e assim melhorar na eficiência da estação.

4.4 Cluster MPI

Os experimentos confirmam que a utilização de clusters de baixo custo com MPI é uma alternativa viável à computação em nuvem para o monitoramento e a predição de energia em usinas solares. Entre as principais vantagens observadas estão:

- Baixa latência e resposta imediata a variações ambientais;
- Escalabilidade linear, permitindo adicionar novos nós sem reconfigurações complexas;
- Tolerância a falhas, essencial para ambientes remotos;
- Custo reduzido de implantação e manutenção.

Em comparação aos resultados centralizados desta dissertação, o ambiente distribuído mostrou melhor desempenho operacional, mantendo a precisão do modelo e reduzindo o tempo de atualização de predições. Isso demonstra a aplicabilidade prática do sistema de análise multivariada quando combinado a uma infraestrutura de processamento paralela.

4.4.1 Conclusões e Trabalhos Futuros

A incorporação do cluster MPI à metodologia desta dissertação representa uma evolução da arquitetura proposta, permitindo a execução distribuída dos modelos de aprendizado de máquina em tempo real. O uso do LightGBM em ambiente paralelo consolidou-se como a abordagem mais eficiente para predição de potência e detecção de falhas sob restrições de hardware.

Como continuidade, pretende-se:

- Integrar técnicas de aprendizado profundo (deep learning) para detecção de padrões mais complexos;
- Testar a infraestrutura com hardware heterogêneo, combinando Raspberry Pi e NVIDIA Jetson;
- Incorporar o mapa de sombreamento como entrada direta no sistema de predição descrito nesta dissertação, fechando o ciclo de monitoramento autônomo.

A integração entre o sistema de análise multivariada e o cluster MPI confirma a viabilidade de uma solução descentralizada e inteligente para monitoramento de usinas fotovoltaicas. O sistema resultante combina:

1. Coleta de dados multivariada e detecção de falhas (núcleo da dissertação);
2. Processamento paralelo e distribuído (proposto no artigo ERAD);
3. Mapeamento dinâmico de sombreamento, agregando dimensão espacial à análise.

Essa abordagem fornece um modelo completo de computação embarcada e distribuída, capaz de operar de forma autônoma, escalável e de baixo custo — características essenciais para a próxima geração de sistemas inteligentes de geração de energia renovável.

5 Conclusão

Este trabalho apresentou uma proposta completa para análise multivariada e detecção de falhas em sistemas de geração fotovoltaica, fundamentada em técnicas modernas de aprendizado de máquina e em uma infraestrutura experimental de aquisição de dados desenvolvida especificamente para este fim. A solução proposta combina medições de grandezas elétricas e meteorológicas em um conjunto de dados multifonte, capaz de representar de forma fidedigna as condições reais de operação de uma usina solar.

A pesquisa resultou em duas contribuições principais para a área de monitoramento e análise de sistemas fotovoltaicos:

1. Criação de um dataset multivariado inédito, composto por medições de parâmetros elétricos (tensão, corrente e potência) e variáveis ambientais (irradiância, temperatura e velocidade do vento), coletados de uma planta experimental no IFCE – Campus Fortaleza. Esse conjunto de dados foi estruturado e tratado para ser utilizado em algoritmos de aprendizado de máquina voltados à previsão de desempenho e à identificação de anomalias em módulos solares.
2. Desenvolvimento de um sistema de leitura de multivariáveis, baseado em microcontroladores ESP32 e sensores calibrados, capaz de realizar a aquisição simultânea de dados elétricos e ambientais e executar uma previsão de carga em tempo real com base nessas medições. Esse sistema foi projetado para ser escalável, de baixo custo e de fácil integração com plataformas de monitoramento e análise, permitindo sua aplicação prática em usinas solares distribuídas.

Embora o foco principal tenha sido o uso de métodos de inteligência artificial computacional, em especial o algoritmo LightGBM, o estudo também abordou desafios estruturais que impactam o desempenho desses modelos, como a escassez de datasets representativos e a limitação de processamento em ambientes remotos. Assim, além de construir um modelo preditivo robusto, a dissertação estabeleceu uma arquitetura de aquisição e processamento de dados replicável e escalável, que pode servir de base para futuras pesquisas e implantações em campo.

A integração deste trabalho com o artigo publicado no Encontro Regional de Alto Desempenho (ERAD 2024) ampliou ainda mais suas contribuições, ao incorporar uma camada de processamento distribuído via cluster MPI, composto por dispositivos Raspberry Pi interconectados. Essa arquitetura permitiu executar o treinamento e a predição dos modelos LightGBM diretamente no ambiente da usina, eliminando a dependência de

serviços em nuvem e garantindo resposta rápida e resiliência operacional mesmo em locais com infraestrutura limitada.

Os resultados obtidos — tanto na versão centralizada quanto na distribuída — demonstraram que o LightGBM é altamente eficaz para aplicações de regressão em sistemas fotovoltaicos, apresentando coeficiente de determinação (R^2) elevado e baixa margem de erro. A combinação entre o dataset criado e o sistema embarcado de leitura permitiu atingir previsões precisas da potência gerada e detecção antecipada de anomalias, validando a aplicabilidade da solução em ambientes reais de geração de energia solar.

O modelo desenvolvido pode ser facilmente embarcado em hardware de baixo custo, como o ESP32 ou os nós Raspberry Pi do cluster MPI, possibilitando o monitoramento inteligente e em tempo real de usinas fotovoltaicas. Essa abordagem contribui diretamente para o aumento da eficiência energética, a redução de custos operacionais e a autonomia tecnológica das plantas solares.

Como trabalhos futuros, propõe-se:

- a aplicação de técnicas de aprendizado profundo (Deep Learning) para a detecção de padrões complexos de falhas e degradações;
- a integração de dados de imagens térmicas e visuais ao dataset já existente, enriquecendo a análise multivariada;
- e a ampliação do sistema distribuído desenvolvido no ERAD, transformando-o em uma plataforma completa de monitoramento preditivo e diagnóstico automatizado de sistemas fotovoltaicos.

Com essas contribuições, a dissertação consolida uma base científica e tecnológica sólida para o avanço de soluções de monitoramento inteligente em energia solar, alinhando-se aos objetivos de eficiência, descentralização e sustentabilidade que caracterizam a transição energética contemporânea.

5.1 Agradecimentos

Esta pesquisa contou com o apoio da FUNCAP e da CAPES. Agradecemos aos nossos colegas do Departamento de Telemática e Indústria do IFCE que forneceram informações e conhecimentos que ajudaram muito na pesquisa, embora eles possam não concordar com todas as interpretações deste artigo.

Referências

ANCUTA, F.; CEPISCA, C. Fault analysis possibilities for pv panels. In: *Proceedings of the 2011 3rd International Youth Conference on Energetics (IYCE)*. [S.l.]: IEEE, 2011. p. 1–5.

BALZATEGUI, J.; ECIOLAZA, L.; MAESTRO-WATSON, D. Anomaly detection and automatic labeling for solar cell quality inspection based on generative adversarial network. *Sensors*, MDPI AG, v. 21, n. 13, p. 4361, Jun 2021. ISSN 1424-8220. Disponível em: <<http://dx.doi.org/10.3390/s21134361>>.

BOUTASSETA, N. et al. Implementation of MPPT methods for improving the performance of photovoltaic systems. In: *2021 International Conference on Recent Advances in Mathematics and Informatics (ICRAMI)*. IEEE, 2021. Disponível em: <<https://doi.org/10.1109/icrami52622.2021.9585933>>.

BREIMAN, L. Random forests. *Machine Learning*, Springer Science and Business Media LLC, v. 45, n. 1, p. 5–32, 2001. Disponível em: <<https://doi.org/10.1023/a:1010933404324>>.

BURTA, A.; SZABO, R. Solar irradiance measurement for a thermo-electric hybrid solar system. In: *2020 5th International Conference on Smart and Sustainable Technologies (SpliTech)*. IEEE, 2020. Disponível em: <<https://doi.org/10.23919/splitech49282.2020.9243761>>.

CAMPANELLI, M. B.; OSTERWALD, C. R. Effective irradiance ratios to improve i–v curve measurements and diode modeling over a range of temperature and spectral and total irradiance. *IEEE Journal of Photovoltaics*, Institute of Electrical and Electronics Engineers (IEEE), v. 6, n. 1, p. 48–55, jan. 2016. Disponível em: <<https://doi.org/10.1109/jphotov.2015.2489866>>.

canalsolar. *MPPT canalsolar*. 2023. <https://canalsolar.com.br/wp-content/uploads/2019/03/Screenshot_1-4.jpg>. Accessed: 2023-02-20.

CHEN, H. et al. Solar cell surface defect inspection based on multispectral convolutional neural network. *Journal of Intelligent Manufacturing*, Springer Science and Business Media LLC, v. 31, n. 2, p. 453–468, Dec 2018. ISSN 1572-8145. Disponível em: <<http://dx.doi.org/10.1007/s10845-018-1458-z>>.

eco-greenenergy.com. *Montagem do MFV*. 2022. <<https://www.eco-greenenergy.com/pt-pt/o-que-e-o-eva/>>. Accessed: 2022-10-01.

FATEMI, S. M.; SHADLU, M. S.; TALEBKHAH, A. Comparison of three-point mathsemicolon and hill climbing methods for maximum power point tracking in PV systems. In: *2019 10th International Power Electronics, Drive Systems and Technologies Conference (PEDSTC)*. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/pedstc.2019.8697273>>.

FATEMI, S. M.; SHADLU, M. S.; TALEBKHAH, A. A new method for maximum power point tracking in solar PV systems by combining extremum seeking method (ESM) and model predictive control (MPC). In: *2020 11th Power Electronics, Drive*

- Systems, and Technologies Conference (PEDSTC)*. IEEE, 2020. Disponível em: <<https://doi.org/10.1109/pedstc49159.2020.9088424>>.
- FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 29, n. 5, out. 2001. Disponível em: <<https://doi.org/10.1214/aos/1013203451>>.
- GABOR, A. M. et al. The impact of cracked solar cells on solar panel energy delivery. In: *2020 47th IEEE Photovoltaic Specialists Conference (PVSC)*. IEEE, 2020. Disponível em: <<https://doi.org/10.1109/pvsc45281.2020.9300743>>.
- GARG, U.; CHOCHAN, D. K.; DOBHALL, D. C. The prediction of power in solar panel using machine learning. In: *2021 International Conference on Computational Performance Evaluation (ComPE)*. IEEE, 2021. Disponível em: <<https://doi.org/10.1109/compe53109.2021.9751901>>.
- GAVANKAR, S.; SAWARKAR, S. Decision tree: Review of techniques for missing values at training, testing and compatibility. In: *2015 3rd International Conference on Artificial Intelligence, Modelling and Simulation (AIMS)*. IEEE, 2015. Disponível em: <<https://doi.org/10.1109/aims.2015.29>>.
- HIDAYAT, M. N.; LI, F. Impact of distributed generation technologies on generation curtailment. In: *2013 IEEE Power & Energy Society General Meeting*. IEEE, 2013. Disponível em: <<https://doi.org/10.1109/pesmg.2013.6672607>>.
- KE, G. et al. Lightgbm: A highly efficient gradient boosting decision tree. In: GUYON, I. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2017. v. 30. Disponível em: <<https://proceedings.neurips.cc/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>>.
- KIM, K. A.; KREIN, P. T. Reexamination of photovoltaic hot spotting to show inadequacy of the bypass diode. *IEEE Journal of Photovoltaics*, Institute of Electrical and Electronics Engineers (IEEE), v. 5, n. 5, p. 1435–1441, set. 2015. Disponível em: <<https://doi.org/10.1109/jphotov.2015.2444091>>.
- KRAUTER, S. C. W. Solar electric power generation. In: *Springer, New York, NY, USA*, [S.l.]: IEEE, 2006.
- LARI, A. J. et al. Photovoltaic system ensemble prediction system. In: *2021 International Conference on Electrical, Computer and Energy Technologies (ICECET)*. IEEE, 2021. Disponível em: <<https://doi.org/10.1109/icecet52533.2021.9698546>>.
- LIM, V. C. H. et al. Pulsed solar panel light current-voltage characterization based on zener diode. In: *2016 IEEE Conference on Systems, Process and Control (ICSPC)*. IEEE, 2016. Disponível em: <<https://doi.org/10.1109/spc.2016.7920725>>.
- MA, X. et al. Data-driven $\text{\$}\text{\$}$ feature extraction for photovoltaic modules. *IEEE Journal of Photovoltaics*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 5, p. 1405–1412, set. 2019. Disponível em: <<https://doi.org/10.1109/jphotov.2019.2928477>>.
- MEDDAGE, D. P. P. et al. Tree-based regression models for predicting external wind pressure of a building with an unconventional configuration. In: *2021 Moratuwa Engineering Research Conference (MERCon)*. IEEE, 2021. Disponível em: <<https://doi.org/10.1109/mercon52712.2021.9525734>>.

- NEACA, M. I. Solar tracking system for several groups of solar panels. In: *2021 International Conference on Applied and Theoretical Electricity (ICATE)*. IEEE, 2021. Disponível em: <<https://doi.org/10.1109/icate49685.2021.9465057>>.
- PARIKH, H. R. et al. Solar cell cracks and finger failure detection using statistical parameters of electroluminescence images and machine learning. *Applied Sciences*, MDPI AG, v. 10, n. 24, p. 8834, dez. 2020. Disponível em: <<https://doi.org/10.3390/app10248834>>.
- PAUL, R.; SEN, A.; DEY, B. Study of application of smart grid on solar energy. *SSRN Electronic Journal*, Elsevier BV, 2019. Disponível em: <<https://doi.org/10.2139/ssrn.3492860>>.
- PLATONOVA, E. V.; TOROPOV, A. S.; TULIKOV, A. N. Simulation of energy input to solar panels. In: *2019 International Ural Conference on Electrical Power Engineering (UralCon)*. IEEE, 2019. Disponível em: <<https://doi.org/10.1109/uralcon.2019.8877633>>.
- portalsolar. *Cálculo de PFV: portalsolar*. 2022. <<https://www.portalsolar.com.br>>. Accessed: 2022-12-03.
- pycaret.gitbook. *get-started: pycaret*. 2022. <<https://pycaret.gitbook.io/docs/get-started>>. Accessed: 2022-10-01.
- SILVA, A. W. de B. et al. Methodology based on artificial neural networks for hourly forecasting of PV plants generation. *IEEE Latin America Transactions*, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 4, p. 659–668, abr. 2022. Disponível em: <<https://doi.org/10.1109/tla.2022.9675472>>.
- SOLANKI, D. et al. Solar energy prediction using meteorological variables. In: *2018 International Conference on Recent Innovations in Electrical, Electronics Communication Engineering ICRIEEECE*. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/icrieece44171.2018.9009175>>.
- SUMATHI, S.; KUMAR, L. A.; SUREKHA, P. *Solar PV and Wind Energy Conversion Systems*. Springer International Publishing, 2015. Disponível em: <<https://doi.org/10.1007/978-3-319-14941-7>>.
- SUN, Q. et al. Review of smart grid comprehensive assessment systems. *Energy Procedia*, Elsevier BV, v. 12, p. 219–229, 2011. Disponível em: <<https://doi.org/10.1016/j.egypro.2011.10.031>>.
- —