

Monitoramento Remoto para Detecção e Classificação de Falhas em Sistemas Fotovoltaicos: Abordagem com *Wavelet* e Desvio Relativo Local

Vinícius Faria Costa Mendanha, Gilberto Lopes Filho, Gustavo Souto de Sá e Souza e Flávio Henrique Teles Vieira

Resumo— Em monitoramento remoto de plantas fotovoltaicas via redes *IoT* de baixa capacidade, flutuações ambientais nos sinais elétricos dificultam a detecção de falhas. Propõe-se desvio relativo local e decomposição *Wavelet* para normalização e extração de características em dispositivos de borda, classificadas por um *ensemble* assimétrico de Floresta Aleatória e Máquina de Vetores de Suporte, combinando robustez e precisão em classes de assinatura espectral distinta (circuito aberto atingiu *F1-score* de 92,7%). O processamento local viabiliza *gateways* LoRaWAN com mais nós, alcançando *F1-score* macro de 87,8% e acurácia balanceada de 90,9%.

Palavras-Chave— Classificação, Decomposição *Wavelet*, Desvio Relativo Local, Detecção de Falhas, Internet das Coisas.

Abstract— In remote monitoring of photovoltaic plants via low-capacity *IoT* networks, environmental fluctuations in electrical signals hinder fault detection. A local relative deviation and *Wavelet* decomposition are proposed for signal normalization and feature extraction on edge devices, classified by an asymmetric RF+SVM ensemble combining robustness and precision for classes with distinct spectral signatures (open-circuit reached *F1-score* of 92.7%). Local processing enables LoRaWAN gateways to support more nodes, achieving a macro *F1-score* of 87.8% and balanced accuracy of 90.9%.

Keywords— Classification, Fault Detection, Internet of Things, Local Relative Deviation, *Wavelet* Decomposition.

I. INTRODUÇÃO

A geração de energia elétrica utilizando sistemas fotovoltaicos (FV) tornou-se a principal fonte de expansão da capacidade elétrica global, atingindo 1.865 GW instalados em 2024, com adição recorde de 452 GW em um único ano [1]. Apesar desse crescimento, falhas em plantas FV impedem que os sistemas atinjam sua potência nominal, comprometendo a eficiência e a confiabilidade da geração [2]. A crescente adoção de sistemas FV distribuídos exige soluções de monitoramento remoto que operem eficientemente sobre redes de comunicação com largura de banda limitada, motivando abordagens projetadas para dispositivos de borda.

Entre as falhas mais recorrentes, estão: curto-circuito, circuito aberto e sombreamento parcial, cujos efeitos manifestam-se nos sinais elétricos de tensão e corrente das *strings* em corrente contínua [3]. Entretanto, a identificação automática

dessas falhas é dificultada pela forte dependência dos sinais elétricos em relação às condições ambientais: a corrente gerada é proporcional à irradiância incidente, enquanto a tensão de circuito aberto varia com a temperatura do módulo [4], de modo que variações naturais ao longo do dia produzem flutuações nos sinais que podem mascarar os efeitos das falhas. Além disso, o severo desbalanceamento entre classes agrava o problema, já que condições normais são amplamente majoritárias em relação às classes de falha [5]. Esse desbalanceamento significa que as janelas correspondentes a falhas representam uma fração reduzida do conjunto de dados, de modo que um classificador que otimize a acurácia global pode atingir desempenho aparentemente elevado simplesmente rotulando todas as amostras como operação normal, ignorando justamente os eventos de interesse.

Métodos baseados em modelos físicos e aprendizado de máquina [3], [5]–[7], decomposição *Wavelet* para extração de padrões tempo-frequência [8]–[10] e estratégias para desbalanceamento por meio de redes neurais e modelos híbridos [11]–[13] têm sido empregados nesse diagnóstico. Contudo, essas abordagens frequentemente dependem de modelos físicos, conjuntos de dados balanceados artificialmente ou arquiteturas computacionalmente complexas.

Desse modo, como lacuna relevante, tem-se o desbalanceamento de dados, tratado predominantemente na etapa de classificação por meio de sobreamostragem ou pesos diferenciados, enquanto a etapa de representação do sinal permanece pouco explorada como alternativa para reduzir esse efeito. Além disso, abordagens dependentes de modelos físicos podem limitar a generalização entre diferentes plantas FV. Diante disso, este trabalho propõe uma abordagem baseada em desvio relativo local para normalizar os sinais elétricos em relação ao comportamento nominal instantâneo da planta. Essa técnica reduz a influência de irradiância e temperatura sem depender de modelos físicos complexos, sendo compatível com execução em dispositivos de borda. Aliada a isso, emprega-se a decomposição *Wavelet* para detecção e classificação robusta de falhas em sistema fotovoltaico real. As principais contribuições são:

- 1) a proposta do desvio relativo local como mecanismo adaptativo de pré-processamento e normalização dos sinais elétricos, compatível com execução em dispositivos de borda;
- 2) a extração de características estatísticas e espectrais por janelamento temporal a partir dos coeficientes *Wavelet*;

- 3) um classificador híbrido por *ensemble* assimétrico de Floresta Aleatória (RF) e Máquina de Vetores de Suporte (SVM), motivado pela complementaridade entre os modelos, verificada experimentalmente pela ausência de ganho de F1-score macro ao incluir o K-Vizinhos Mais Próximos (KNN) no *ensemble*, apesar de seu desempenho individual competitivo; e
- 4) avaliação experimental rigorosa em protocolo *Leave-Some-Events-Out* sobre conjunto de dados público com forte desbalanceamento natural entre classes, com comparação entre quatro classificadores (RF, SVM, KNN e o *ensemble* proposto) avaliados por F1-score macro, acurácia balanceada e AUC-PR.

II. TRABALHOS RELACIONADOS

Sistemas *IoT* para monitoramento remoto de plantas FV têm sido investigados. Por exemplo, Srisiri et al. [14] propuseram um sistema de baixo custo baseado em rede de longa distância para classificação de falhas em plantas FV, alcançando 94% de acurácia em ambiente real. Além disso, Lodhi et al. [15] apresentaram uma arquitetura de *edge computing* com classificador Res-BiLSTM, com capacidade de operação *offline* em ambientes de conectividade intermitente.

No âmbito do processamento de sinais e aprendizado de máquina, Badr et al. [5] propuseram classificadores supervisionados (Árvore de Decisão, KNN e SVM), com otimização Bayesiana para ajuste de hiperparâmetros em diagnóstico de falhas em arranjos FV. Ademais, Rao et al. [16] desenvolveram redes neurais com *dropout* e poda, reduzindo a complexidade computacional e superando classificadores tradicionais. Lazzaretto et al. [3], responsáveis pelo conjunto de dados utilizado neste trabalho, implementaram monitoramento *online* baseado em modelos físicos e análise direta dos sinais elétricos.

Contudo, nenhum desses trabalhos incorpora normalização adaptativa dos sinais antes da transmissão ou classificação. A maioria opera sobre sinais brutos, cujas magnitudes variam com as condições ambientais, exigindo maior complexidade computacional ou consumo desnecessário de banda. A proposta deste artigo preenche essa lacuna introduzindo o desvio relativo local como etapa de pré-processamento embarcável, que normaliza os sinais em relação à tendência nominal instantânea, produzindo representações mais compactas e discriminativas com menor dependência das condições ambientais. Em particular, os trabalhos que combinam decomposição *Wavelet* e aprendizado de máquina aplicam a transformada diretamente sobre os sinais elétricos brutos, cuja magnitude varia com a irradiância e a temperatura. Neste trabalho, a decomposição opera sobre o sinal de desvio relativo, já normalizado pela tendência nominal instantânea, de forma que as características espectrais extraídas dependem menos das condições de operação.

III. METODOLOGIA

A. Conjunto de Dados

O conjunto de dados utilizado foi coletado em uma planta FV de 5 kW, localizada na Universidade Tecnológica Federal do Paraná (UTFPR), Curitiba, Brasil, composta por

duas *strings* de oito módulos, monitorada durante 16 dias de operação a 1 Hz [3]. As variáveis disponíveis são tensão (v_1 , v_2), corrente (i_1 , i_2), irradiância (G) e temperatura do módulo (T), sendo os índices 1 e 2 correspondentes a cada uma das duas *strings* do arranjo. Os rótulos avaliados são: operação normal, curto-circuito, circuito aberto e sombreamento, com distribuição fortemente desbalanceada: 84,7%, 0,4%, 0,4% e 13,7% dos dados, respectivamente, além de uma condição não analisada. Como as falhas analisadas somente se manifestam sob geração, a análise é restrita aos períodos diurnos ($G > 50 \text{ W/m}^2$), resultando em 16.363 janelas.

B. Desvio Relativo Local

Os sinais elétricos de sistemas FV variam naturalmente em função de G e T , dificultando a comparação direta entre amostras [4]. Assim, propõe-se o desvio relativo local como mecanismo de normalização adaptativa, minimizando a dependência de modelos físicos. A referência local de cada sinal $x[n]$ é estimada por uma média móvel centrada de janela $W_r = 900$ s, suficientemente longa para suavizar oscilações de baixa frequência e preservar a tendência nominal, conforme (1).

$$\mu_x[n] = \frac{1}{W_r} \sum_{k=-W_r/2}^{W_r/2-1} x[n-k] \quad (1)$$

A janela centrada requer o armazenamento de $W_r/2 = 450$ amostras posteriores ao instante avaliado, introduzindo um atraso de até 7,5 min entre a ocorrência da falha e a emissão do alerta. Esse atraso é compatível com o monitoramento de falhas persistentes, como as consideradas neste trabalho, mas não com aplicações de proteção em tempo real.

Em seguida, o desvio relativo local é calculado conforme (2), sendo $d_x[n]$ o desvio adimensional do sinal $x[n]$ em relação à sua referência local $\mu_x[n]$ e $\varepsilon = 10^{-6}$ uma constante de regularização.

$$d_x[n] = \frac{x[n] - \mu_x[n]}{|\mu_x[n]| + \varepsilon} \quad (2)$$

O procedimento é aplicado a oito sinais, sendo quatro medidos diretamente (v_1 , v_2 , i_1 , i_2) e quatro derivados ($P_1 = v_1 i_1$, $P_2 = v_2 i_2$, $\rho_V = v_2/v_1$ e $\rho_I = i_2/i_1$), representando as razões entre as *strings*, com ρ_V e ρ_I sensíveis a falhas assimétricas.

C. Extração de Características

Os sinais de desvio são segmentados em janelas de $L = 64$ amostras com passo $S = 32$ amostras (sobreposição de 50%), definido como compromisso entre resolução temporal e estabilidade estatística das características *Wavelet*.

Sobre cada janela, aplica-se a Transformada *Wavelet* Discreta (DWT), que decompõe o sinal em componentes de diferentes resoluções por meio da aplicação recursiva de filtros passa-baixa $h[n]$ e passa-alta $g[n]$, seguida de subamostragem por fator 2 [17], conforme (3), sendo $a_0[n] = d_x[n]$ o sinal de entrada.

$$a_j[n] = \sum_k h[k] a_{j-1}[2n-k], \quad c_j[n] = \sum_k g[k] a_{j-1}[2n-k] \quad (3)$$

Utiliza-se a *wavelet* db4, pois sua regularidade e suporte compacto são adequados para representar transientes suaves como os associados a falhas FV [8], com $J = 3$ níveis de decomposição. Esse valor é compatível com a frequência de amostragem de 1 Hz e o comprimento de janela adotado, separando componentes de alta frequência, associados a transientes de falha, dos de baixa frequência, associados à tendência nominal [17]. Obtêm-se $J + 1 = 4$ sub-bandas: $\mathbf{a}_3$, $\mathbf{c}_3$, $\mathbf{c}_2$ e $\mathbf{c}_1$, com 14, 14, 21 e 35 coeficientes, respectivamente, para $L = 64$ amostras e extensão simétrica das bordas.

Para cada sub-banda $\mathbf{b} \in \{\mathbf{a}_3, \mathbf{c}_3, \mathbf{c}_2, \mathbf{c}_1\}$, extraem-se a energia média $E(\mathbf{b})$ e o desvio padrão $\sigma(\mathbf{b})$, conforme (4), sendo b_k o k -ésimo coeficiente e $\bar{b}$ a média dos coeficientes da sub-banda.

$$E(\mathbf{b}) = \frac{1}{|\mathbf{b}|} \sum_k b_k^2, \quad \sigma(\mathbf{b}) = \sqrt{\frac{1}{|\mathbf{b}|} \sum_k (b_k - \bar{b})^2} \quad (4)$$

Adicionalmente, sete características estatísticas são extraídas de cada sinal de desvio: média, desvio padrão, mínimo, máximo, percentis p_5 e p_{95} e desvio absoluto médio (MAD). O vetor final possui 120 características (8×15), sendo 15 atributos por sinal: 8 espectrais (2 por sub-banda) e 7 estatísticos.

D. Classificação por Ensemble Assimétrico

Os vetores são padronizados por *z-score*, com parâmetros estimados exclusivamente no conjunto de treinamento. A classificação $\hat{y}$ é realizada por votação suave entre Floresta Aleatória (RF) e Máquina de Vetores de Suporte (SVM), conforme (5), em que p_{RF} e p_{SVM} são as probabilidades estimadas por cada modelo para a classe c e $\mathbf{f} \in \mathbb{R}^{120}$ é o vetor de características da janela.

$$\hat{y} = \arg \max_c [w_{\text{RF}} p_{\text{RF}}(c | \mathbf{f}) + w_{\text{SVM}} p_{\text{SVM}}(c | \mathbf{f})] \quad (5)$$

Os pesos $w_{\text{RF}} = 1$ e $w_{\text{SVM}} = 2$ refletem a complementaridade entre os modelos: a SVM apresentou melhor desempenho em classes com distribuições mais definidas no espaço de características, como circuito aberto, enquanto a RF é mais equilibrada nas demais. Ambos utilizam pesos de classe balanceados para compensar o desbalanceamento natural dos dados [6]. Para reduzir o custo de treinamento da SVM avaliada individualmente, as classes normal e sombreamento foram subamostradas para no máximo 3.000 janelas cada; a SVM integrante do *ensemble* é ajustada sobre o conjunto de treinamento completo. Adicionalmente, o K-Vizinhos Mais Próximos (KNN) foi avaliado como classificador de referência, tanto individualmente quanto em combinação com o *ensemble* proposto; verificou-se que sua inclusão não melhorou o desempenho coletivo, confirmando a escolha do par RF+SVM como configuração final.

Os hiperparâmetros foram ajustados por busca em grade (*grid search*) no conjunto de treinamento, maximizando o

F1-score macro, sobre as faixas: RF com profundidade máxima em {irrestrita, 20, 30}, mínimo de amostras por folha em {1, 2} e fração de atributos por divisão em $\{\sqrt{p}, 0,3\}$, sendo p o número total de características; SVM com *kernel* RBF [5], $C \in \{10, 50, 100\}$ e $\gamma \in \{\gamma_{\text{scale}}, 0,01\}$; KNN com $k \in \{5, 10, 15, 20, 25, 30, 35, 40, 50, 60, 75, 100\}$ e ponderação por distância; e pesos $(w_{\text{RF}}, w_{\text{SVM}}) \in \{(1, 1), (2, 1), (1, 2)\}$. Foram selecionadas as configurações: RF com 300 árvores, profundidade irrestrita e $\sqrt{p}$ atributos por divisão; SVM com $C = 10$ e $\gamma = \gamma_{\text{scale}}$; KNN com $k = 30$; e $w_{\text{RF}} = 1$ e $w_{\text{SVM}} = 2$.

E. Protocolo de Avaliação

A avaliação segue o protocolo *Leave-Some-Events-Out* (LSEO): os últimos 30% dos eventos de cada classe de falha são reservados para teste, preservando a ordem temporal e evitando o vazamento de informação presente em divisões aleatórias. O desempenho é medido por três métricas complementares: F1-score macro, que trata todas as classes igualmente e é adequado para avaliação sob desbalanceamento; acurácia balanceada, que pondera o acerto por classe independentemente de sua frequência; e a área sob a curva precisão-revocação (AUC-PR), especialmente informativa para classes minoritárias, calculada como média macro sobre as quatro classes.

IV. RESULTADOS E DISCUSSÃO

A Fig. 1 ilustra o impacto do desvio relativo local sobre o sinal de tensão $v_2[n]$ durante um evento de curto-circuito. No sinal bruto da Fig. 1(a), a magnitude absoluta varia continuamente em função da irradiância e da temperatura, dificultando a comparação entre amostras de instantes distintos.




Fig. 1. Desvio relativo local sobre $v_2[n]$ em curto-circuito: (a) sinal bruto; (b) sinal normalizado. Região sombreada indica a falha.

Após a aplicação do desvio relativo local na Fig. 1(b), o sinal expressa o desvio em relação à tendência nominal instantânea, tornando a falha identificável independentemente das condições ambientais. Comportamento análogo é observado para o sombreamento no sinal de corrente $i_2[n]$, embora com maior sobreposição em relação ao comportamento normal, o que é consistente com o desempenho de classificação mais baixo nessa classe.

A análise das sub-bandas *Wavelet* do sinal $d_{v2}[n]$, ilustrada na Fig. 2, revela que todas as classes concentram a maior parte da energia na sub-banda de aproximação a_3 , associada a variações de baixa frequência. A distinção entre classes ocorre nas sub-bandas de detalhe: curto-circuito e sombreamento apresentam maior energia relativa em c_3 e c_2 em comparação ao circuito aberto, cuja assinatura espectral é mais concentrada em a_3 .




Fig. 2. Perfil de energia relativa normalizada por sub-banda *Wavelet* do sinal $d_{v2}[n]$ por classe de falha (valores adimensionais, normalizados pela energia total da janela).

A Tabela I apresenta as métricas de avaliação para os quatro modelos sob o protocolo LSEO, em que CC, CA e Somb. referem-se às falhas de curto-circuito, circuito aberto e sombreamento, respectivamente.

TABELA I
MÉTRICAS DE DESEMPENHO DOS CLASSIFICADORES AVALIADOS SOB O PROTOCOLO LSEO

Modelo	F1-score por classe				F1 macro	Acurácia balanceada	AUC-PR macro
	Norm.	CC	CA	Somb.			
RF	92,0%	88,7%	83,8%	84,2%	87,2%	92,9%	96,6%
SVM	88,7%	87,5%	94,4%	78,2%	87,2%	87,7%	95,1%
KNN ($k=30$)	89,1%	97,0%	94,5%	77,5%	89,6%	87,8%	94,8%
Ensemble RF+SVM	90,4%	87,5%	92,7%	80,7%	87,8%	90,9%	96,5%

Da Tabela I, destaca-se que o KNN ($k = 30$) obteve o melhor F1-score macro (89,6%) e 97,0% no curto-circuito. A RF apresenta a maior acurácia balanceada (92,9%) e a maior AUC-PR macro (96,6%), enquanto o *ensemble* RF+SVM figura em segundo lugar em ambas as métricas (90,9% e 96,5%), superando SVM e KNN. A ausência de ganho ao incluir o KNN no *ensemble* RF+SVM ressalta a complementaridade específica entre RF e SVM: a primeira equilibra o desempenho

entre classes majoritárias, enquanto a segunda maximiza a precisão nas classes com assinatura espectral mais definida, como o circuito aberto.

A Fig. 3 apresenta as curvas Precisão-Revocação por classe de falha para os quatro classificadores. O circuito aberto e o curto-circuito apresentam AUC-PR elevadas em todos os modelos, refletindo sua alta separabilidade no espaço de características. Para o circuito aberto, o *ensemble* RF+SVM e a RF atingem AUC-PR de 99,4% e 99,6%, respectivamente, enquanto o sombreamento exibe as curvas mais baixas e próximas entre si.




Fig. 3. Curvas de Precisão-Revocação por classe de falha para os quatro classificadores avaliados. O valor entre parênteses na legenda indica a AUC-PR de cada modelo na respectiva classe.

O *ensemble* assimétrico RF+SVM não maximiza isoladamente nenhuma das métricas agregadas, mas oferece o melhor compromisso entre os dois modelos que o compõem. Em relação à RF, recupera grande parte do desempenho da SVM no circuito aberto (F1-score de 92,7% contra 83,8%), ao custo de perdas de no máximo 3,5 pontos percentuais nas demais

classes, o que resulta em *F1-score* macro superior (87,8% contra 87,2%). Em relação à SVM, preserva a robustez da RF na classe normal (90,4% contra 88,7%) e no sombreamento (80,7% contra 78,2%), elevando a acurácia balanceada de 87,7% para 90,9%. O KNN, por sua vez, atinge 97,0% no curto-circuito, classe representada por apenas três eventos no conjunto de teste, o que restringe a generalidade dessa vantagem; sua inclusão no *ensemble* não produziu ganho de *F1-score* macro, indicando que a combinação RF+SVM já reúne informações complementares sem redundância.

Em uma arquitetura de monitoramento remoto com processamento na borda, o método proposto opera localmente no dispositivo sensor, transmitindo apenas a classe predita ou um alarme em caso de falha detectada. Em contraste com a transmissão contínua dos sinais brutos, a qual requer 128 bps considerando os quatro canais medidos em *float32* e taxa de amostragem de 1 Hz (os demais sinais são derivados no próprio dispositivo), a transmissão de alarmes reduz a taxa para menos de 1 bps. Isso viabiliza o uso em redes *IoT* de baixa capacidade, como LoRaWAN (tipicamente limitada a 50–250 bps por nó) e NB-IoT. Essa característica reduz o consumo energético do nó sensor, prolongando sua autonomia, além de permitir que um único *gateway* suporte múltiplos nós simultaneamente. Dessa forma, viabiliza-se o monitoramento de plantas FV em áreas rurais com conectividade limitada a redes LPWAN, por exemplo.

V. CONCLUSÕES

Para monitoramento remoto em dispositivos de borda, uma abordagem baseada em desvio relativo local e decomposição *Wavelet* para detecção e classificação de falhas em sistema fotovoltaico real foi proposta. O *ensemble* RF+SVM, avaliado sob o protocolo *Leave-Some-Events-Out* sobre conjunto de dados com forte desbalanceamento natural, alcançou *F1-score* macro de 87,8% e acurácia balanceada de 90,9%. Em contrapartida, o KNN, embora competitivo individualmente, não melhorou o *ensemble*. O processamento local reduz a taxa de transmissão de 128 bps para menos de 1 bps, viabilizando o monitoramento remoto via redes LPWAN de baixa capacidade, como LoRaWAN e NB-IoT. Como limitações, a avaliação restringe-se a uma única planta e partição temporal, com poucos eventos de falha no conjunto de teste. Como trabalho futuro, destacam-se a implementação embarcada em dispositivos de borda e a validação em múltiplas plantas com análise de significância estatística.

AGRADECIMENTOS

Os autores agradecem ao Centro de Excelência em Redes Inteligentes Sem Fio e Serviços Avançados (CERISE) e à Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) pelo apoio e financiamento à pesquisa nos termos do Convênio nº. 05/2023/FAPEG.

REFERÊNCIAS

- [1] International Renewable Energy Agency, “Renewable capacity statistics 2025,” IRENA, Abu Dhabi, Tech. Rep., 2025. [Online]. Available: <https://www.irena.org>
- [2] K. Osmani, A. Haddad, T. Lemenand, B. Castanier, M. Alkhedher, and M. Ramadan, “A critical review of pv systems’ faults with the relevant detection methods,” *Energy Nexus*, vol. 12, p. 100257, Dec. 2023. [Online]. Available: <http://dx.doi.org/10.1016/j.nexus.2023.100257>
- [3] A. E. Lazzaretti, C. H. d. Costa, M. P. Rodrigues, G. D. Yamada, G. Lexinoski, G. L. Moritz, E. Oroski, R. E. d. Goes, R. R. Linhares, P. C. Stadzisz, J. S. Omori, and R. B. d. Santos, “A monitoring system for online fault detection and classification in photovoltaic plants,” *Sensors*, vol. 20, no. 17, p. 4688, Aug. 2020. [Online]. Available: <http://dx.doi.org/10.3390/s20174688>
- [4] H. P. Correa and F. H. T. Vieira, “Explicit two-piece quadratic current–voltage characteristic model for solar cells,” *IEEE Transactions on Electron Devices*, vol. 68, no. 12, p. 6273–6278, Dec. 2021. [Online]. Available: <http://dx.doi.org/10.1109/TED.2021.3122407>
- [5] M. M. Badr, M. S. Hamad, A. S. Abdel-Khalik, R. A. Hamdy, S. Ahmed, and E. Hamdan, “Fault identification of photovoltaic array based on machine learning classifiers,” *IEEE Access*, vol. 9, p. 159113–159132, 2021. [Online]. Available: <http://dx.doi.org/10.1109/ACCESS.2021.3130889>
- [6] A. F. Amiri, H. Oudira, A. Chouder, and S. Kichou, “Faults detection and diagnosis of pv systems based on machine learning approach using random forest classifier,” *Energy Conversion and Management*, vol. 301, p. 118076, Feb. 2024. [Online]. Available: <http://dx.doi.org/10.1016/j.enconman.2024.118076>
- [7] M. Hojabri, S. Kellerhals, G. Upadhyay, and B. Bowler, “IoT-based pv array fault detection and classification using embedded supervised learning methods,” *Energies*, vol. 15, no. 6, p. 2097, Mar. 2022. [Online]. Available: <http://dx.doi.org/10.3390/en15062097>
- [8] A. Teta, B. Korich, D. Bakria, N. Hadroug, A. Rabehi, M. Alsharef, M. Bajaj, I. Zaitsev, and S. S. M. Ghoneim, “Fault detection and diagnosis of grid-connected photovoltaic systems using energy valley optimizer based lightweight cnn and wavelet transform,” *Scientific Reports*, vol. 14, no. 1, Aug. 2024. [Online]. Available: <http://dx.doi.org/10.1038/s41598-024-69890-7>
- [9] M. Ahmadipour, M. Murtadha Othman, M. Alrifayy, R. Bo, and C. Kit Ang, “Classification of faults in grid-connected photovoltaic system based on wavelet packet transform and an equilibrium optimization algorithm-extreme learning machine,” *Measurement*, vol. 197, p. 111338, 2022. [Online]. Available: <http://dx.doi.org/10.1016/j.measurement.2022.111338>
- [10] J. Wang, D. Gao, S. Zhu, S. Wang, and H. Liu, “Fault diagnosis method of photovoltaic array based on support vector machine,” *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, vol. 45, no. 2, p. 5380–5395, 2019. [Online]. Available: <http://dx.doi.org/10.1080/15567036.2019.1671557>
- [11] N.-C. Yang and H. Ismail, “Voting-based ensemble learning algorithm for fault detection in photovoltaic systems under different weather conditions,” *Mathematics*, vol. 10, no. 2, p. 285, Jan. 2022. [Online]. Available: <http://dx.doi.org/10.3390/math10020285>
- [12] M. Dhimish and A. M. Tyrell, “Photovoltaic bypass diode fault detection using artificial neural networks,” *IEEE Transactions on Instrumentation and Measurement*, vol. 72, p. 1–10, 2023. [Online]. Available: <http://dx.doi.org/10.1109/TIM.2023.3244230>
- [13] Y.-Y. Hong and R. A. Pula, “Diagnosis of photovoltaic faults using digital twin and pso-optimized shifted window transformer,” *Applied Soft Computing*, vol. 150, p. 111092, Jan. 2024. [Online]. Available: <http://dx.doi.org/10.1016/j.asoc.2023.111092>
- [14] W. Srisiri, N. T. Le, M. A. Saleem, P. Kaewplung, S. Chaitusaney, and W. Benjapolakul, “Artificial intelligence-based fault classification on photovoltaic plants using a low-cost open-source iot system,” *Scientific Reports*, vol. 16, no. 1, Dec. 2025. [Online]. Available: <http://dx.doi.org/10.1038/s41598-025-30678-y>
- [15] E. Lodhi, X. Liu, G. Xiong, M. A. Khan, Z. Lodhi, T. Nawaz, A. Dilawar, S. Tarkoma, and F. Wang, “Smartpv-aiot: an aiot-integrated framework for fault diagnosis and remote monitoring in photovoltaic systems,” *Energy Conversion and Management: X*, vol. 27, p. 101117, 2025. [Online]. Available: <http://dx.doi.org/10.1016/j.ecmx.2025.101117>
- [16] S. Rao, G. Muniraju, C. Tepedelenlioglu, D. Srinivasan, G. Tamizhmani, and A. Spanias, “Dropout and pruned neural networks for fault classification in photovoltaic arrays,” *IEEE Access*, vol. 9, p. 120034–120042, 2021. [Online]. Available: <http://dx.doi.org/10.1109/ACCESS.2021.3108684>
- [17] N. Ahmed, A. A. Hashmani, S. Khokhar, M. A. Tunio, and M. Faheem, “Fault detection through discrete wavelet transform in overhead power transmission lines,” *Energy Science & Engineering*, vol. 11, no. 11, p. 4181–4197, 2023. [Online]. Available: <http://dx.doi.org/10.1002/ese3.1573>