

# **Desenvolvimento de uma Metodologia Para Detecção de Anomalias em Usinas Fotovoltaicas de Grande Porte**

RESUMO ESTENDIDO - Disciplina de TCC029009

**Lucas Coelho Raupp**

Estudante do Curso de Engenharia de Telecomunicações

**Mario de Noronha Neto, Dr.**

Professor orientador

Semestre 2024.1

**Resumo-** *Diante da crescente demanda por fontes energéticas limpas, a energia solar tem se destacado globalmente por sua capacidade e eficiência. No entanto, diversas anomalias tendem a afetar o rendimento de suas usinas, resultando em redução na geração de energia e acarretando desafios significativos para os operadores, que precisam dedicar esforços e recursos para identificar e corrigir tais problemas. Nesse contexto, este trabalho visa desenvolver uma metodologia baseada em algoritmos de Machine Learning (ML) para detectar, classificar e quantificar as possíveis anomalias em usinas fotovoltaicas de grande porte.*

**Palavras-chave:** Energia solar. Usinas fotovoltaicas de grande porte. Anomalias. Machine Learning.

## **1 Introdução**

No século XXI, a energia solar surgiu como uma fonte de energia limpa e sustentável, se tornando o segmento energético que mais cresce no Brasil e no mundo. Para usufruir desse recurso, usinas fotovoltaicas de grande porte começaram a ser implantadas no estado de Minas Gerais e no Nordeste, regiões mais próximas da linha do Equador e com menor cobertura florestal se comparados com o restante do território verde e amarelo. A caráter de comparação, em outubro de 2023, essa fonte representava 5,27% da matriz energética brasileira, totalizando 10,4 GW (GOV.BR, 2023).

Comparativamente à Alemanha, um dos líderes mundiais em energia solar, as regiões menos ensolaradas do Brasil podem gerar mais energia do que as áreas mais ensolaradas do país europeu. No entanto, a eficiência das usinas está sujeita a múltiplas variáveis, como temperatura, sujeira nos módulos fotovoltaicos e sombreamento, representando perdas na potência total de 4,68%, 6,26% e 15%, respectivamente. Sendo assim, a capacidade de identificar essas anomalias de forma automatizada, possibilitaria a redução das perdas de geração, melhorando a eficiência operacional e prolongando a vida útil dos equipamentos (TONOLO, 2019).

Para detectar essas anomalias, foram propostas diversas abordagens, como métodos estatísticos, monitoramento do índice de rendimento fotovoltaico (PR), relação entre a produtividade e a quantidade de horas de sol incidentes no painel, e técnicas de aprendizado de máquina.

Considerando que uma usina fotovoltaica pode conter até 30% de dados anômalos, as técnicas de pré-processamento utilizando ML têm se tornando cada vez mais comuns. Especificamente, o modelo convolucional *autoencoder* tem se destacado devido às suas capacidades de lidar com grandes volumes de amostras e identificar padrões complexos em conjuntos de dados multivariados, contribuindo para a redução do erro de predição em até 23% (PARK et al., 2023).

## **1.1 Objetivo Geral**

Com base neste contexto, este trabalho tem como objetivo desenvolver uma metodologia para detectar anomalias em usinas fotovoltaicas de grande porte, utilizando técnicas de aprendizado de máquina, dados de geração de energia e condições climáticas.

## **1.2 Objetivos Específicos**

Para alcançar o objetivo geral, serão aplicados os seguintes objetivos específicos:

- Avaliar bases de dados disponíveis;
- Realizar o tratamento e processamento da base de dados selecionada;
- Definir as entradas da metodologia a ser desenvolvida;
- Gerar uma base de dados para treinamento dos algoritmos de aprendizado de máquina;
- Desenvolver a metodologia para detecção de anomalias;
- Implementar uma *dashboard* para visualização dos resultados;

## **2 Metodologia**

Para atingir o objetivo da proposta abordada, o presente trabalho se desdobrou nas seguintes etapas:

### **2.1 Definição dos Objetivos**

O primeiro passo consistiu em definir os objetivos geral e específicos, identificando assim as questões centrais e estabelecendo uma direção clara para a obtenção dos resultados esperados.

### **2.2 Limpeza dos Dados**

Antes de inserir os dados para o treinamento de uma ML, será desenvolvido um método para para limpeza e o processamento dos mesmos. Isso envolverá considerar as variáveis disponíveis em uma usina solar de grande porte e determinar como aplicar o processamento nessas informações.

### **2.3 Método para Detecção de Anomalias**

O método escolhido foi o modelo convolucional *autoencoder*. Este modelo é uma forma de rede neural artificial não supervisionada, ou seja, opera com dados não rotulados para descobrir padrões e estruturas ocultas. Ele codifica a informação de entrada em uma representação compacta e, em seguida, a decodifica para que a saída seja semelhante à entrada (BANK; KOENIGSTEIN; GIRYES, 2020).

### **2.4 Ferramentas Utilizadas**

Neste trabalho, serão utilizadas ferramentas para facilitar e gerenciar a implementação da proposta. Na parte da infraestrutura, será utilizado o *Docker*, devido a sua versatilidade e escalabilidade.

Para o treinamento da inteligência artificial, será adotada a linguagem *Python* no ambiente de desenvolvimento integrado (IDE) *Jupyter Notebook*. Essa ferramenta possibilita a criação de documentos iterativos compostos por códigos, textos formatados, imagens, gráficos e equações matemáticas, facilitando a programação iterativa e permitindo uma abordagem passo a passo na análise dos dados.

Na parte da visualização dos resultados, será empregado o *framework Streamlit*. Essa ferramenta permite transformar *scripts Python* em aplicativos interativos na *web* para exibição de *dashboards*.

### 3 Considerações Parciais

O método proposto neste trabalho poderá ser aplicado modularmente em diversas usinas fotovoltaicas de grande porte, permitindo estimar e quantificar possíveis anomalias e, conseqüentemente, perdas na geração dessas usinas. Além disso, poderá servir como exemplo para pesquisas relacionadas ao aprimoramento da eficiência energética, podendo ser adaptado para operar em diferentes fontes de energia renovável.

#### Referências

BANK, D.; KOENIGSTEIN, N.; GIRYES, R. Autoencoders. *CoRR*, abs/2003.05991, 2020. Disponível em: <<https://arxiv.org/abs/2003.05991>>. Acesso em: 02 abr. 2024.

GOV.BR. *Energia solar: usinas centralizadas ultrapassam os 5% na matriz elétrica brasileira, com 10,4 GW instalados*. 2023. Disponível em: <<http://tiny.cc/mullxz>>. Acesso em: 30 mar. 2024.

PARK, T. et al. Convolutional autoencoder-based anomaly detection for photovoltaic power forecasting of virtual power plants. *Energies*, 2023. Disponível em: <<https://www.mdpi.com/1996-1073/16/14/5293#>>. Acesso em: 30 mar.2024.

TONOLO, A. Análise dos fatores de perdas nos sistemas fotovoltaicos da UTFPR Campus Curitiba. 2019. Disponível em: <[https://repositorio.utfpr.edu.br/jspui/bitstream/1/4664/1/CT\\_PPGSE\\_M\\_Tonolo%2C%20%20C3%89dwin%20Augusto\\_2019.pdf](https://repositorio.utfpr.edu.br/jspui/bitstream/1/4664/1/CT_PPGSE_M_Tonolo%2C%20%20C3%89dwin%20Augusto_2019.pdf)>. Acesso em: 02 abr. 2024.