



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANNA GABRIELLY DE LIMA COELHO

**APLICAÇÃO DE REDE NEURAL ARTIFICIAL PARA DETECÇÃO DE ANOMALIAS EM
USINAS FOTOVOLTAICAS**

Recife
2024

ANNA GABRIELLY DE LIMA COELHO

**APLICAÇÃO DE REDE NEURAL ARTIFICIAL PARA DETECÇÃO DE
ANOMALIAS EM USINAS FOTOVOLTAICAS**

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientador(a): Prof. Dr. José Filho da Costa Castro

Coorientador: Prof. Dr. Jeydson Lopes da Silva

Recife
2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Coêlho, Anna Gabrielly de Lima.

Aplicação de rede neural artificial para detecção de anomalias em usinas
fotovoltaicas / Anna Gabrielly de Lima Coêlho. - Recife, 2024.

50 p. : il., tab.

Orientador(a): José Filho da Costa Castro

Coorientador(a): Jeydson Lopes da Silva

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia Elétrica -
Bacharelado, 2024.

Inclui referências.

1. fotovoltaica. 2. inversor. 3. detecção de anomalias. 4. inteligência
artificial. 5. autoencoder. I. Castro, José Filho da Costa. (Orientação). II. Silva,
Jeydson Lopes da. (Coorientação). IV. Título.

620 CDD (22.ed.)

ANNA GABRIELLY DE LIMA COELHO

APLICAÇÃO DE REDE NEURAL ARTIFICIAL PARA DETECÇÃO DE ANOMALIAS EM USINAS FOTOVOLTAICAS

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovado em: 12/08/2024.

BANCA EXAMINADORA

Prof. Dr. José Filho da Costa Castro (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Jeydson Lopes da Silva (Coorientador)
Universidade Federal de Pernambuco

Prof. Dr. Douglas Contente Pimentel Barbosa (Examinador Interno)
Universidade Federal de Pernambuco

Eng. M.Sc. André Victor Rodrigues Nascimento da Silva (Examinador Externo)
Aeroespacial

Dedico este trabalho à minha avó, Maria Alice (in memoriam), pois, sem seu amor e cuidado, eu não teria chegado tão longe.

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, que me protegeu e iluminou meus caminhos durante toda a minha jornada. À minha mãe, Anna Paula, por todo o amor, carinho e compreensão nos momentos difíceis; à minha irmã, Anna Júlia, por compartilhar as madrugadas de estudo; e à minha tia, Pollyanna, pela torcida, apoio e orações.

Expresso minha profunda gratidão aos meus amigos da empresa Aeroespacial: Paulo, Caarem, André e Thomás, pelos ensinamentos, sugestões de melhorias e pela motivação durante o processo de elaboração do TCC.

RESUMO

A geração de energia solar vem crescendo no mundo e no Brasil, por ser uma fonte considerada limpa e segura. No entanto, as Usinas Fotovoltaicas (UFV) enfrentam desafios significativos, especialmente a vulnerabilidade a falhas que frequentemente resultam em perdas de energia e, conseqüentemente, prejuízos econômicos. Entre os componentes, o inversor possui um papel essencial na geração de energia fotovoltaica. Seu desempenho pode afetar diretamente a eficiência de conversão, os benefícios econômicos e a confiabilidade operacional de todo o sistema de geração de energia. Caso o inversor apresente falhas, isso terá um impacto significativo na operação do sistema de geração de energia. Para garantir a operação confiável e segura das instalações fotovoltaicas, além de reduzir o trabalho de inspeção e investigação do pessoal de manutenção, faz-se necessário o uso de sistemas para detectar anomalias. Muitos métodos de detecção de falhas em sistemas fotovoltaicos têm sido estudados, incluindo técnicas de inteligência artificial, em especial redes neurais artificiais. Uma Rede Neural Artificial (ANN – *Artificial Neural Network*) é um tipo de ferramenta de aprendizado supervisionado baseado em um modelo simplificado do cérebro humano, consistindo em conexões de neurônios. Uma das configurações de ANNs mais utilizada para detecção de falhas são os Autoencoders, modelos que reconstróem a entrada original e a diferença entre a entrada e a saída pode ser usada para identificar anomalias nos dados (facilitando a detecção de falhas). Os Autoencoders podem ser combinados com outros tipos de redes, como Redes Neurais Convolucionais (CNN – *Convolutional Neural Networks*), que se destacam em desvendar relações espaciais inerentes aos dados, e Redes Neurais Recorrentes (RNN - *Recurrent Neural Network*) como LSTM (*Long Short-Term Memory*), que são modelos baseados em sequências, capazes de estabelecer correlações temporais entre informações passadas e presentes. Neste trabalho são propostos três modelos: Autoencoder (AE), Autoencoder com Redes Convolucionais (AE-CNN) e Autoencoder com LSTM (AE-LSTM). Os três modelos são avaliados em quatro cenários de anomalias de produção de um inversor de uma usina fotovoltaica real no nordeste brasileiro.

Palavras-chave: fotovoltaica; inversor; detecção de anomalias; inteligência artificial; autoencoder.

ABSTRACT

Solar energy has been growing worldwide and in Brazil as a clean and safe energy source. However, photovoltaic plants face significant challenges, especially their vulnerability to failures, which often result in considerable energy losses and economic damage. Among the components, the inverter plays an essential role in the photovoltaic energy generation. Its performance can directly affect the conversion efficiency, economic benefits, and operational reliability of the entire power generation system. If the inverter fails, it will have a significant impact on the operation of the energy generation system. To ensure the reliable and safe operation of photovoltaic installations, as well as to reduce the inspection and investigation workload of maintenance personnel, it is necessary to use systems to detect anomalies. Many methods for detecting faults in photovoltaic systems have been studied, including artificial intelligence techniques, especially artificial neural networks. An Artificial Neural Network (ANN) is a type of supervised learning model based on a simplified model of the human brain, consisting of neuron connections. The most used types of ANNs for fault detection are Autoencoders. These models reconstruct the original input, and the difference between the input and output can be used to identify data anomalies, facilitating fault detection. Autoencoders can be combined with other types of networks, such as Convolutional Neural Networks (CNN), which excel at uncovering spatial relationships inherent in the data, and Recurrent Neural Networks (RNN) like LSTM (Long Short-Term Memory), which are sequence-based models capable of establishing temporal correlations between past and present information. In this work, three models are proposed: Autoencoder (AE), Autoencoder with Convolutional Networks (AE-CNN), and Autoencoder with LSTM (AE-LSTM). The three models are evaluated in four scenarios of production anomalies of an inverter in a real photovoltaic plant in northeastern Brazil.

Keywords: photovoltaic; inverter; anomaly detection; artificial intelligence; autoencoder.

LISTA DE ILUSTRAÇÕES

Figura 1 – Tipos de falhas em sistemas fotovoltaicos.....	16
Figura 2 - Estrutura de uma usina fotovoltaica centralizada.....	17
Figura 3 – Porcentagem de falha por componente e portfólio.....	19
Figura 4 – Exemplificação de uma rede neural artificial.	21
Figura 5 - Ilustração de arquitetura Autoencoder (AE).....	22
Figura 6 - Ilustração de arquitetura CNN.....	23
Figura 7 - Ilustração das portas de LSTM.	24
Figura 8 - Diagrama unifilar ilustrativo.....	25
Figura 9 – Mapa da irradiação global horizontal e usinas em operação comercial. ..	26
Figura 10 - Matriz de correlação das variáveis.....	28
Figura 11 – Perfil diário de produção do inversor em estudo.	29
Figura 12 – Perfil diário de tensão do inversor em estudo.	29
Figura 13 - Perfil diário da irradiação no plano inclinado do módulo fotovoltaico.	30
Figura 14 – Perfil diário da temperatura do módulo fotovoltaico.	30
Figura 15 – Gráfico de produção de energia e irradiação com anomalias nos dados originais.....	34
Figura 16 - Gráfico de produção de energia e irradiação com anomalias do tipo 1. .	35
Figura 17 - Gráfico de produção de energia e irradiação com anomalias do tipo 2. .	35
Figura 18 – Erro de reconstrução do treinamento do modelo AE.....	36
Figura 19 - Distribuição do erro do modelo AE.....	37
Figura 20 - Anomalias detectadas pelo algoritmo AE nos dados originais.	38
Figura 21 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE.	38
Figura 22 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE.	39
Figura 23 – Erro de reconstrução do treinamento do modelo AE-CNN.....	40
Figura 24 - Distribuição do erro do modelo AE-CNN.....	40
Figura 25 - Anomalias detectadas pelo algoritmo AE-CNN nos dados originais.	41
Figura 26 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE-CNN.	42
Figura 27 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE-CNN.	42
Figura 28 – Erro de reconstrução do treinamento do modelo AE-LSTM.....	43
Figura 29 - Distribuição do erro do modelo AE-LSTM.....	43
Figura 30 - Anomalias detectadas pelo algoritmo AE-LSTM nos dados originais.	44

Figura 31 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE-LSTM.	45
Figura 32 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE-LSTM.	45

LISTA DE TABELAS

Tabela 1 - Resumo do portfólio de usinas fotovoltaicas com registros de manutenções coletadas.	18
Tabela 2 - Detalhe do modelo de rede neural Autoencoder (AE).....	31
Tabela 3 - Detalhe do modelo de rede neural Autoencoder com CNN (AE-CNN). ...	32
Tabela 4 - Detalhe do modelo de rede neural Autoencoder com LSTM (AE-LSTM).	33
Tabela 5 - Comparativo dos modelos propostos.	46
Tabela 6 – Porcentagem de dados anômalos identificados por modelo.	46

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
AE	Autoencoder
ANN	Rede Neural Artificial
ANOVA	Análise de Variância
CA	Corrente Alternada
CC	Corrente Contínua
CNN	Rede Neural Convolutacional
DL	<i>Deep Learning</i>
ECM	Medição de Capacitância da Terra
IA	Inteligência Artificial
IGBT	Transistor Bipolar de Porta Isolada
GAN	Rede Adversárias Generativas
GRU	<i>Gated Recurrent Unit</i>
kNN	<i>K-Nearest Neighbors</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
MPPT	Rastreamento de Máxima Potência
NREL	<i>National Renewable Energy Laboratory</i>
ONS	Operador Nacional do Sistema
PV	Fotovoltaica
RNN	Rede Neural Recorrente
SNL	<i>Sandia National Laboratories</i>
SSTDR	Reflectometria de Espelho Espalhado
SVM	<i>Support Vector Machine</i>
TDR	Reflectometria no Domínio do Tempo
UFV	Usina Fotovoltaica

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVOS	14
1.1.1	Geral.....	14
1.1.2	Específicos	14
1.2	ORGANIZAÇÃO DO TRABALHO.....	15
2	REVISÃO BIBLIOGRÁFICA – FALHAS EM USINAS FOTOVOLTAICAS .	16
3	INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE ANOMALIAS.....	20
4	MÉTODO PROPOSTO PARA ESTUDO DE CASO	25
4.1	ANÁLISE DOS DADOS	27
4.2	MODELOS E MÉTODO DE DETECÇÃO.....	31
4.3	DESCRIÇÃO DOS CENÁRIOS DE TESTES	33
5	RESULTADOS NUMÉRICOS	36
6	CONCLUSÕES E PROPOSTAS DE CONTINUIDADE	47
6.1	PROPOSTAS DE TRABALHOS FUTUROS	47
	REFERÊNCIAS.....	49

1 INTRODUÇÃO

No ano de 2023, a energia renovável atingiu uma capacidade total de 3.870 gigawatts (GW) globalmente. A energia solar foi responsável por 73% do crescimento renovável atingindo 1.419 GW, seguida pela energia eólica com 24% de participação na expansão renovável no mundo [1]. No Brasil, as usinas solares atingiram 10,4 gigawatts (GW) de capacidade instalada, com 18,1 mil unidades de geradores solar centralizados que podem ser despachados pelo Operador Nacional do Sistema (ONS) [2].

O crescimento da energia solar deve-se às suas vantagens: operação silenciosa, modularidade, facilidade de instalação, baixo custo de manutenção e disponibilidade gratuita e renovável da energia solar em escala global. Em contraste, as usinas fotovoltaicas apresentam alguns desafios, que incluem alto custo inicial, baixa eficiência de conversão da irradiação solar em energia elétrica, dependência das condições ambientais e vulnerabilidade a falhas [3] [4].

As falhas em Usinas Fotovoltaicas (UFV) frequentemente levam a um aumento nos custos de manutenção e a uma diminuição na eficiência, ocasionando perdas de energia, bem como problemas de segurança e prejuízos econômicos. Um método de detecção de anomalias em sistemas PV (*photovoltaic*) pode identificar e localizar falhas em tempo hábil, melhorando a eficiência e a confiabilidade dos sistemas, ao mesmo tempo, evita a propagação de falhas, garantindo a operação com confiabilidade do sistema elétrico. Além disso, pode reduzir o número de horas de trabalho em inspeção e investigação do pessoal de manutenção [5] [6].

O inversor fotovoltaico é um dos equipamentos essenciais para a geração de energia fotovoltaica [7]. De todos os componentes das usinas fotovoltaicas, os inversores apresentam a taxa de falha mais elevada, representando entre 52% e 60% das falhas totais do sistema [8]. De acordo com a literatura, falhas envolvendo inversores podem atingir 25% da perda de receita por perda de produção de energia [9].

Desde o início do século XXI, a indústria solar começou a explorar o uso de inteligência artificial (IA), concentrando-se principalmente em algoritmos de aprendizado de máquina para previsão de geração de energia e monitoramento do

desempenho do sistema. Na década de 2010, a aplicação de IA no campo PV tornou-se mais extensa e profunda, abrangendo tarefas mais complexas, como otimização de design de sistemas PV, detecção e diagnóstico de falhas, e previsão de manutenção. Em comparação com técnicas tradicionais que exigem mais tempo de computação e expertise humana, os algoritmos de *Machine Learning* (ML) e *Deep Learning* (DL), subcampos da IA, são mais rápidos e eficientes em fornecer soluções de diagnóstico. Em sistemas PV de grande escala, a IA é utilizada para detectar falhas que são quase impossíveis de identificar por inspeção manual tradicional, devido à magnitude das instalações [6] [15].

Neste contexto, o presente trabalho tem como objetivo aplicar modelos avançados de redes neurais artificiais para detectar anomalias nos dados de produção de energia de inversores localizados em uma usina fotovoltaica em operação no nordeste brasileiro. As técnicas propostas podem contribuir para a criação de sistemas de alerta para as equipes de manutenção e operação sobre possíveis problemas (não conformidades operativas) envolvendo os inversores e os demais componentes conectados à rede elétrica.

1.1 Objetivos

Este tópico apresenta os objetivos gerais e específicos do trabalho de conclusão.

1.1.1 Geral

Aplicar técnicas de inteligência artificial para detectar anomalias na produção de energia de inversor localizado em uma usina fotovoltaica no nordeste brasileiro.

1.1.2 Específicos

Avaliar o desempenho de três modelos de redes neurais artificiais em quatro cenários de falhas na produção de energia do inversor em estudo.

Análise da aplicação da metodologia desenvolvida em um estudo de caso de usina fotovoltaica do sistema interligado nacional (SIN).

1.2 Organização do Trabalho

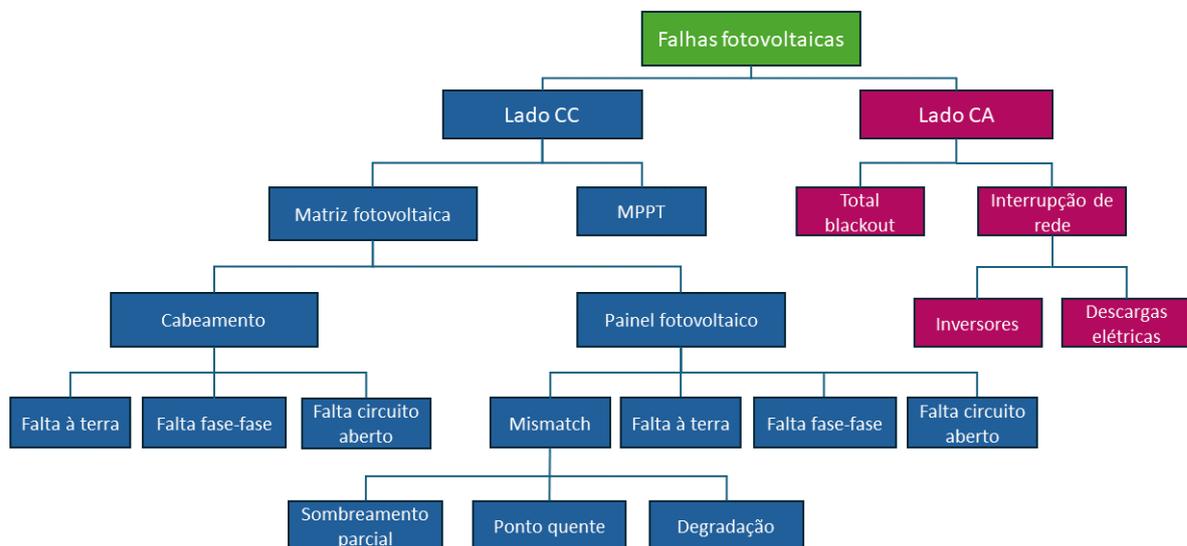
Este trabalho está estruturado da seguinte forma: a seção 2 apresenta uma revisão bibliográfica sobre as principais falhas que podem ocorrer em usinas fotovoltaica. Na seção 3 são apresentadas as técnicas de inteligência artificial para detecção de anomalias e modelos de redes neurais utilizadas na literatura. O estudo de caso e os resultados da aplicação dos métodos propostos são discutidos na seção 4.

2 REVISÃO BIBLIOGRÁFICA – FALHAS EM USINAS FOTOVOLTAICAS

Devido ao ambiente em que são instaladas, as usinas fotovoltaicas são suscetíveis a vários tipos de falhas e anormalidades. Essas falhas podem causar impactos significativos na produção de energia, no desempenho da planta e na redução da vida útil dos equipamentos. Um estudo realizado no Reino Unido observou uma redução de cerca de 18,9% na geração de energia devido a falhas em sistemas fotovoltaicos [10].

As falhas podem ocorrer tanto no lado de corrente contínua (CC) quanto no lado de corrente alternada (CA). Exemplos de falhas no lado CC incluem “falta” à terra, falhas de circuito aberto, falhas no Rastreamento do Ponto de Máxima Potência (MPPT) e desajustes que ocorrem quando há alteração nos parâmetros elétricos de uma célula ou grupo de células (falha *mismatch*). No lado CA, as falhas podem ser causadas por raios, desequilíbrio de tensão, além de interrupções na rede devidas a sobrecorrentes e sobretensões [3].

Figura 1 – Tipos de falhas em sistemas fotovoltaicos.



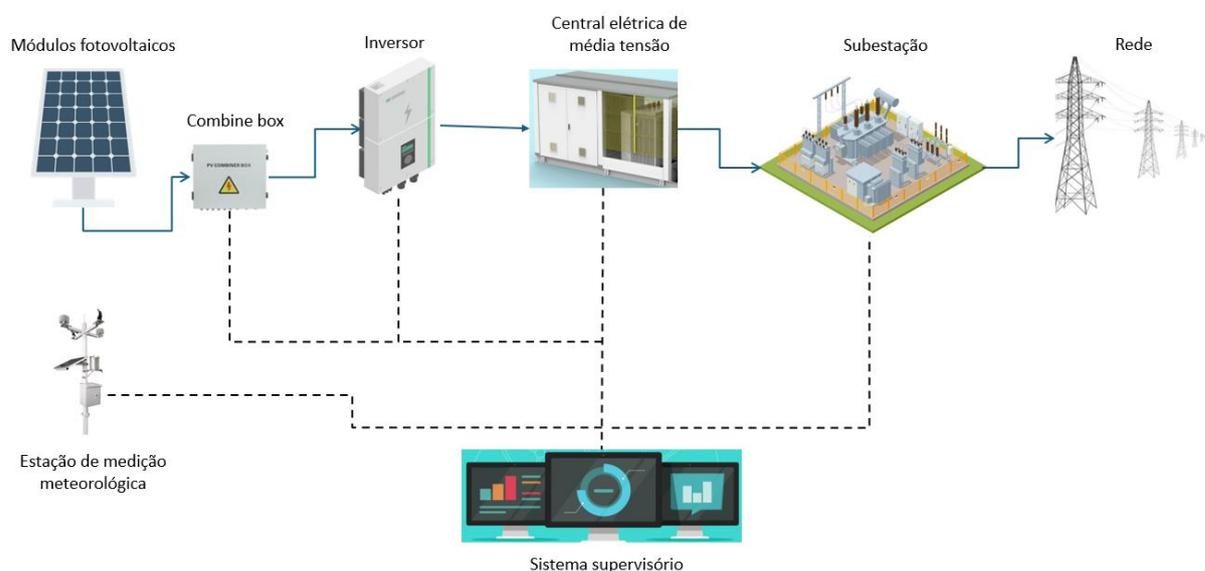
Fonte: Adaptado de [3].

As falhas podem ser classificadas de acordo com suas características de tempo em três categorias [11]:

1. **Falhas Temporárias:** São aquelas que ocorrem temporariamente e mudam ao longo do tempo, como o sombreamento parcial ou total devido ao movimento das nuvens.
2. **Falhas Permanentes:** Estas ocorrem instantaneamente e incluem curtos-circuitos entre linhas ou entre linha e terra, falhas na caixa de junção, desconexão de conectores e falhas de circuito aberto.
3. **Falhas Incipientes:** Estas são falhas em estágio inicial que podem causar danos graduais, potencialmente levando a falhas graves. Exemplos de falhas incipientes no lado CC (módulos fotovoltaicos e conversor CC/CC) incluem defeitos nos módulos fotovoltaicos, como amarelamento e escurecimento das células solares, delaminação, bolhas, rachaduras, lacunas e outros defeitos. No lado CA (inversor e lado da rede), as falhas incluem falhas de Transistor Bipolar de Porta Isolada (IGBT), degradação da fiação, envelhecimento, ilhamento e superaquecimento.

Uma configuração padrão de sistema PV inclui módulos fotovoltaicos, inversores integrados à rede, módulos de comunicação de dados do inversor, cabos de corrente contínua e cabos associados [6]. A Figura 2 ilustra uma estrutura de uma usina fotovoltaica centralizada.

Figura 2 - Estrutura de uma usina fotovoltaica centralizada.



Fonte: Próprio autor.

O inversor fotovoltaico é um componente essencial e central de um sistema de geração de energia fotovoltaica. Em sistemas PV conectados à rede, ele lida com um alto nível de fluxo de energia e opera em um ambiente de alta temperatura, o que degrada a confiabilidade do inversor e aumenta o risco de falhas por envelhecimento dos componentes [12]. A confiabilidade do inversor depende da performance de cada componente.

Entre os equipamentos de uma usina PV, o inversor é o componente que mais recebe chamadas de serviços para operação e manutenção, constituindo entre 43% e 70% das chamadas. Além disso, falhas no inversor contribuem com 36% das perdas de energias entre as falhas totais [13].

Uma força tarefa conjunta da *Sandia National Laboratories* (SNL) e *National Renewable Energy Laboratory* (NREL) coletou e analisou dados de manutenção de componentes fotovoltaicos com o objetivo de fornecer uma visão estatística de como os componentes apresentam falhas em um sistema fotovoltaico ou usina de energia [14]. Os dados de manutenção coletados compreendem os anos de 2003 a 2017 e são separados por portfólios de usinas A, B, C e D. O resumo dos portfólios é mostrado na Tabela 1.

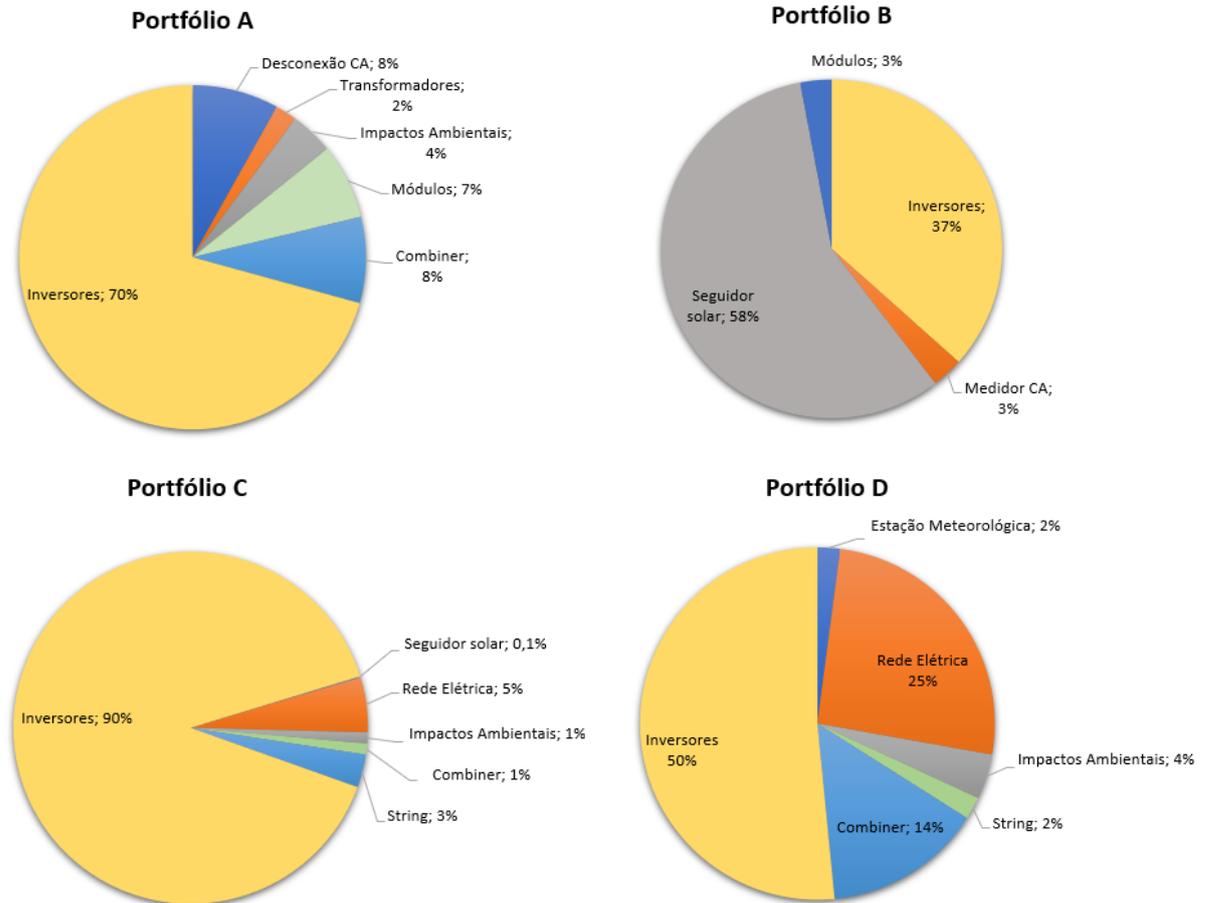
Tabela 1 - Resumo do portfólio de usinas fotovoltaicas com registros de manutenções coletadas.

Portfólio	Ano de comissionamento	Período de dados coletados	Número de sistemas fotovoltaicos	Potência CC (MWp)	Geração distribuída (%)	Geração centralizada (%)
A	2003	2003-2008	1	3,5	0	100
B	2008-2009	2012-2014	2	1,75	100	0
C	2008-2016	2015-2016	180	578	3,4	96
D	2010-2017	2013-2017	61	25,6	100	0

Fonte: Adaptado de [14].

A porcentagem de diferentes falhas relativa a cada componente por portfólio é apresentada na Figura 3. Nota-se que as falhas envolvendo inversores são iguais ou maiores que 50% dos eventos nos portfólios, A, C e D.

Figura 3 – Porcentagem de falha por componente e portfólio.



Fonte: Adaptado de [14].

Dado o percentual significativo de chamados de manutenções e impacto na perda de produção de energia, é proposto um algoritmo de detecção de falhas que seja capaz de identificar anomalias durante a operação diária de um inversor.

3 INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE ANOMALIAS

Na literatura há uma variedade de métodos que podem ser usados para detectar e diagnosticar falhas em sistemas fotovoltaicos:

- **Testes estatísticos:** grupo de métodos matemáticos computacionais que permitem tirar conclusões por meio de testes estatísticos, como a média e o desvio padrão de uma população de dados ou como diferentes populações de dados diferem entre si. Exemplos são Teste de Hipótese, Análise de Variância (ANOVA), *Bootstrapping* [15];

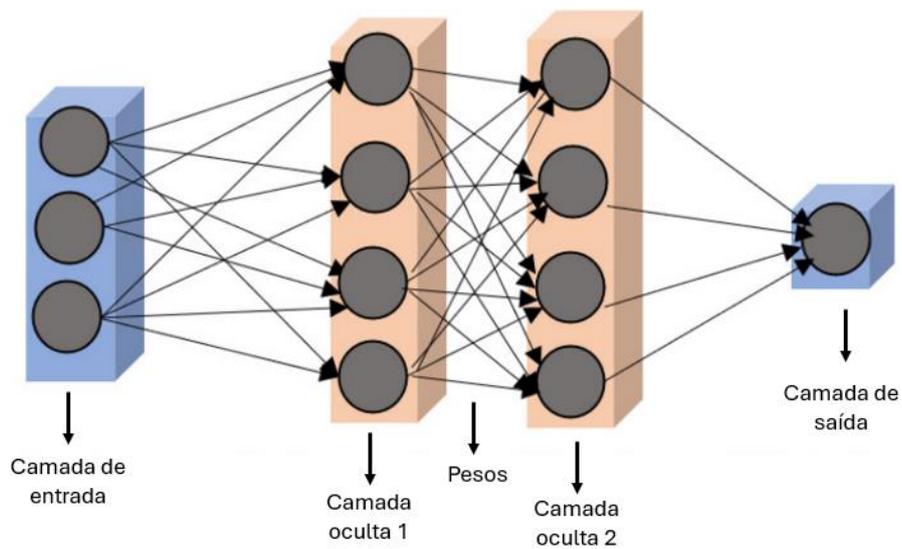
- **Processamento estatístico de sinal:** métodos baseados na análise de sinais de forma de onda, por exemplo, Reflectometria no Domínio do Tempo (TDR), Reflectometria de Espectro Espalhado (SSTDR) e Medição de Capacitância da Terra (ECM) são usados para detectar e localizar módulos fotovoltaicos defeituosos [4];

- **Algoritmos de Aprendizado de Máquina:** Regressão Linear, Regressão Logística, Redes Neurais Artificiais (ANN), *Support Vector Machines* (SVMs), *K-Nearest Neighbors* (kNN), *K-Means clustering* [16].

Vários artigos têm demonstrado a eficácia das técnicas de inteligência artificial na melhoria do diagnóstico do sistema, modelagem, controle e previsão [17] [18] [4]. As Redes Neurais Artificiais (ANN), um subcampo da IA, são os modelos mais incluídos na área de estudos para detecção de falhas.

Uma ANN é um tipo de modelo de aprendizado supervisionado baseado em um modelo simplificado do cérebro humano. Essas redes consistem em muitos neurônios, e as conexões entre esses neurônios possuem coeficientes de pesos por meio do qual é possível o aprendizado [17] [6]. Uma estrutura de rede hierárquica é sempre uma rede, consistindo em uma camada de entrada, várias camadas ocultas e uma camada de saída, com numerosos neurônios em cada camada, como mostrado na Figura 4.

Figura 4 – Exemplificação de uma rede neural artificial.

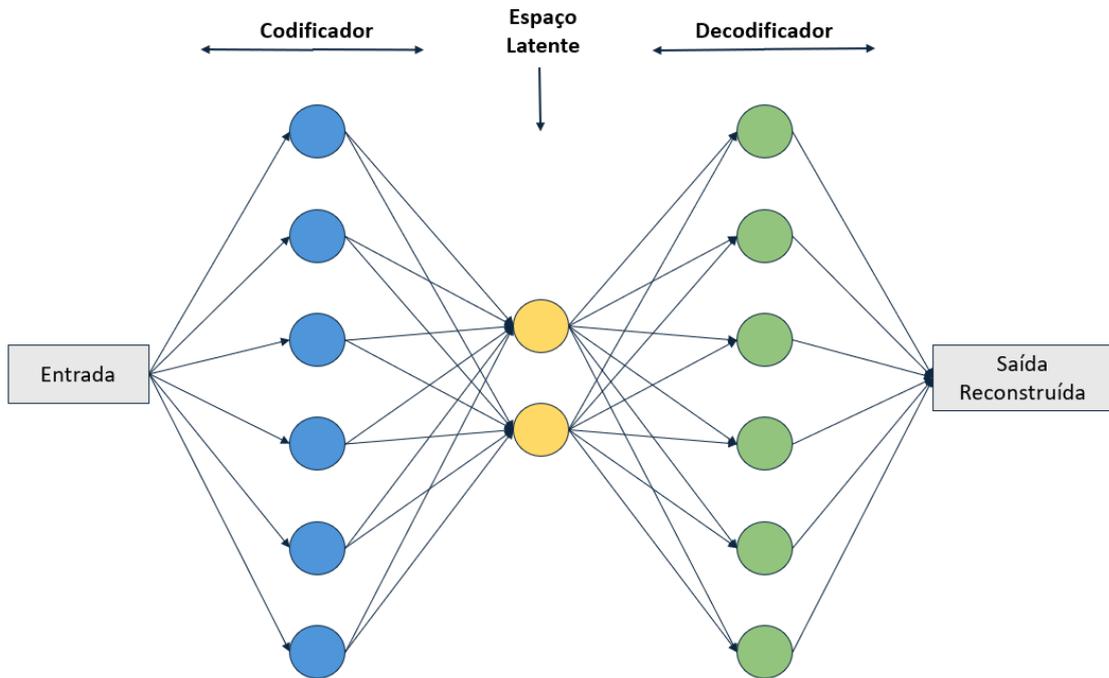


Fonte: Adaptado de [17].

As arquiteturas ANNs mais utilizadas para detecção de falhas são Autoencoders (AE), Redes Neurais Convolucionais (CNN), Redes Neurais Recorrentes (RNN), além de redes adversárias generativas (GANs) [19].

Um Autoencoder (AE) é um algoritmo de aprendizado não supervisionado que consiste em um codificador e um decodificador [5], como ilustra a Figura 5. O codificador transforma a entrada em uma representação de dimensão menor, chamada de espaço latente, e o decodificador reconstrói a entrada original a partir da dimensão reduzida do espaço latente. A diferença entre a entrada original e a saída reconstruída pode ser usada para identificar anomalias nos dados e, assim, detectar a presença de falhas.

Figura 5 - Ilustração de arquitetura Autoencoder (AE).



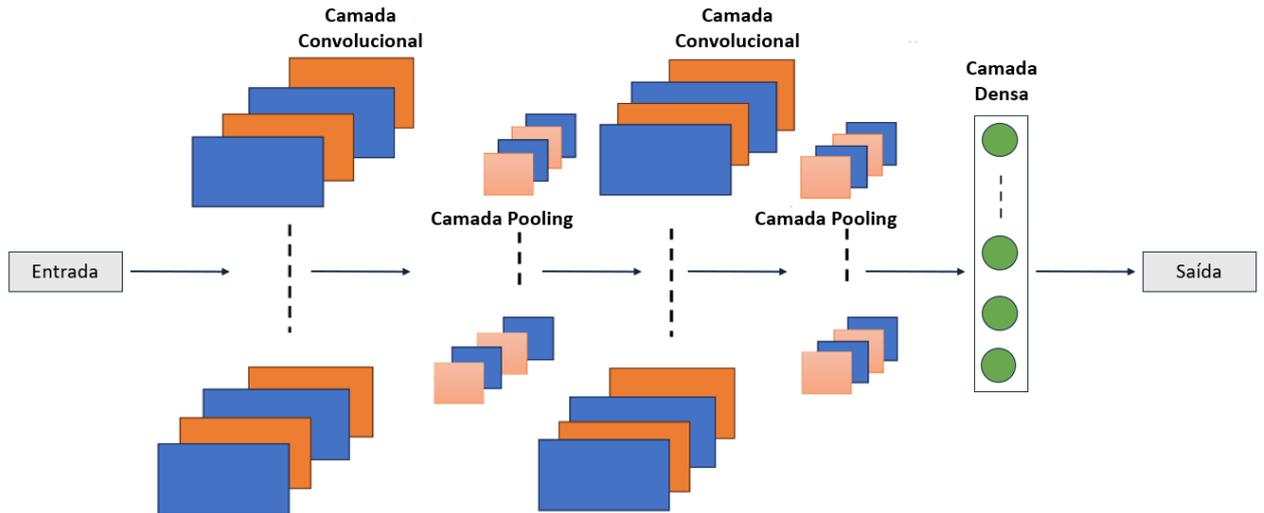
Fonte: Adaptado de [5].

Em [5], é utilizado um Autoencoder para detecção e classificação de faltas envolvendo acúmulo de sujeira, sombreamento, degradação e curto-circuito em arranjos fotovoltaicos. O algoritmo apresentou uma acurácia de 89,97%.

As Redes Neurais Convolucionais (CNNs) são uma classe supervisionada de algoritmos e diferem das redes neurais clássicas por usar convolução nas camadas, em vez de multiplicação de matrizes [20]. Uma CNN é composta por três camadas, como é ilustrada na Figura 6:

- **Camada convolucional:** extrai características dos dados de entrada;
- **Camada de pooling:** reduz o tamanho espacial da característica convolucionada, diminuindo a potência computacional necessária para processar os dados e camada totalmente conectada;
- **Camada densa:** é destinada à classificação por meio do aprendizado de combinações não lineares.

Figura 6 - Ilustração de arquitetura CNN.



Fonte: Adaptado de [20].

As CNNs se destacam em desvendar relações espaciais inerentes aos dados. Essa capacidade é fundamental para compreender de forma abrangente a evolução e manifestação de falhas dentro do sistema fotovoltaico [11].

Em [21], é proposto um método automático de detecção e classificação com CNN. O estudo é focado em quatro tipos de faltas principais, sendo falhas de curto-circuitos, circuito aberto, sombreamentos parciais e degradação. A acurácia obtida foi de 97,64%, enquanto outras redes ANNs apresentaram 92,64%.

As Redes Neurais Recorrentes (RNNs) são modelos baseados em sequências, capazes de estabelecer correlações temporais entre informações passadas e presentes. Uma RNN permite que informações de entradas históricas sejam armazenadas no estado interno da rede, aproveitando assim todas as informações de entrada disponíveis no momento [22]. Os tipos de RNN mais usados são LSTM (*Long Short-Term Memory*) e GRU (*Gated Recurrent Unit*).

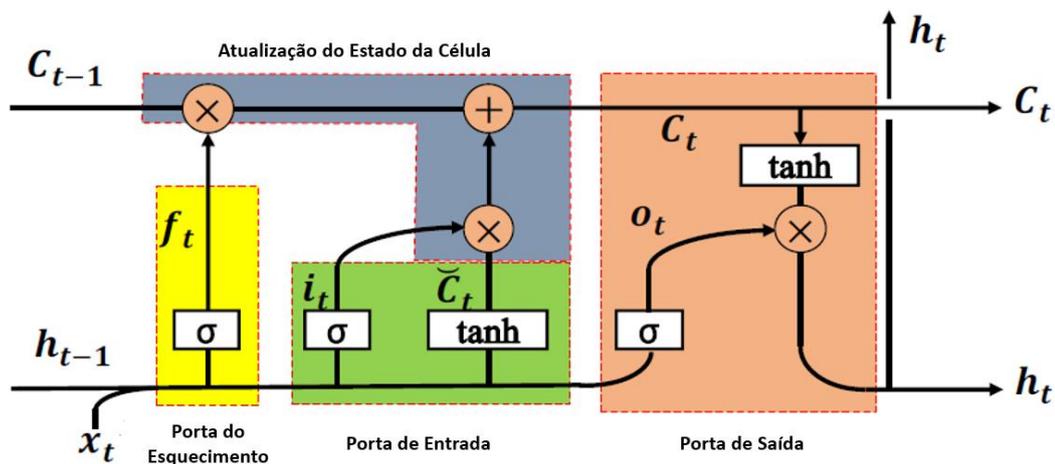
As redes LSTM mantêm e atualizam informações ao longo de longas sequências temporais, tornando-as eficazes para aprender dependências de longo prazo em séries temporais e outros dados sequenciais [23]. As redes LSTM são compostas por três portas, como ilustrado na Figura 7:

- **Porta de entrada:** controla a quantidade de informação que entra no estado da célula.

- **Porta de esquecimento:** determina a quantidade de informação do estado anterior que deve ser descartada.

- **Porta de saída:** decide a quantidade de informação do estado da célula que será utilizada como saída.

Figura 7 - Ilustração das portas de LSTM.



Fonte: adaptado de [23].

O estudo em [22] utilizou um modelo de LSTM para identificar e classificar as faltas em sistema fotovoltaico. A acurácia de classificação e diagnóstico de falhas foram baseadas em dados sem ruído, para condições normais de operação, falhas de ponto quente e falta fase-fase são de 100%, 100% e 99,03%, respectivamente. No caso de dados com ruído, a técnica proposta demonstrou robustez ao ruído com precisões médias de classificação de falhas de 99,23%, 98,78% e 97,66% para condições normais de operação, falhas de "hot spot" (ponto quente) e falta fase-fase, respectivamente.

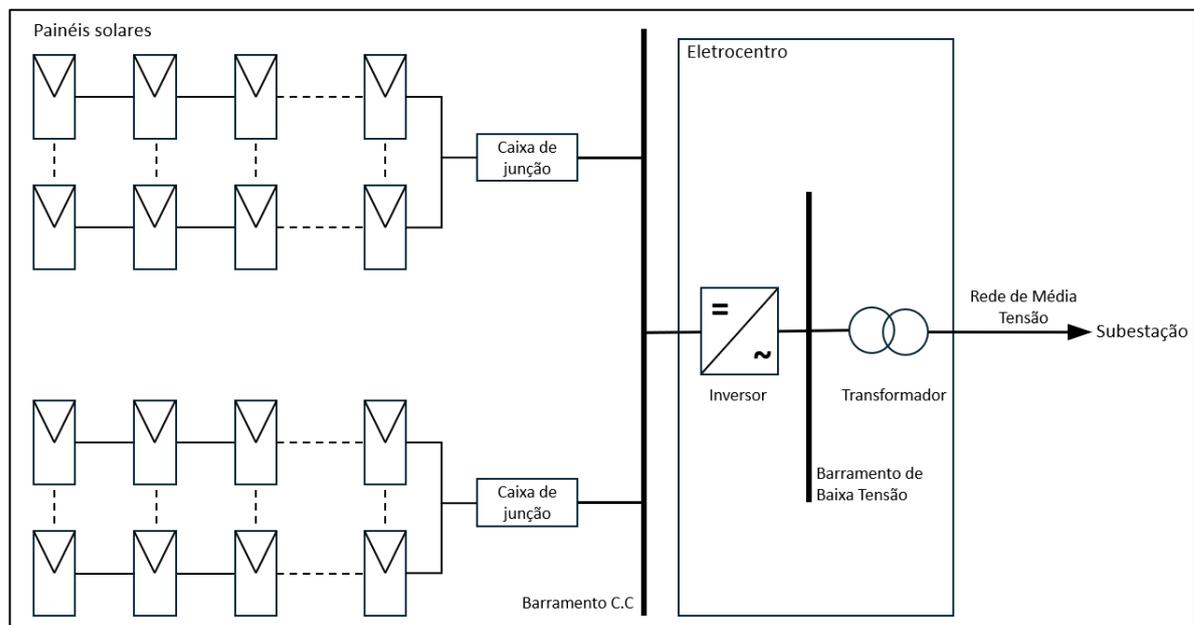
Alguns modelos propostos utilizam mais de uma arquitetura de redes neurais, como no modelo em [24] que combina as capacidades de um AE com as de uma rede LSTM para detectar anomalias. O Autoencoder reconstrói os dados de entrada e o LSTM captura dependências temporais de longo prazo. Outra técnica, em [25], utiliza AE com CNN para remover ruído dos dados de entrada, melhorando assim a qualidade dos dados e para aprender e capturar as características de séries temporais.

4 MÉTODO PROPOSTO PARA ESTUDO DE CASO

O estudo de caso envolve a aplicação de três modelos de redes neurais profundas para a detecção de anomalias na produção de energia de um inversor. Os dados de entrada incluem variáveis meteorológicas como irradiação solar, temperatura e velocidade do vento, juntamente com medições de potência e tensão de um inversor de 1 megawatt (MW) de potência nominal.

O inversor, objeto do presente estudo, é empregado em uma central geradora fotovoltaica, equipada com módulos fotovoltaicos do tipo bifacial, montados em um rastreador (*tracker*) de eixo único, localizada no nordeste brasileiro, atualmente em operação comercial e com contrato de venda de energia no Ambiente de Contratação Livre (ACL). O diagrama unifilar do inversor é apresentado na Figura 8.

Figura 8 - Diagrama unifilar ilustrativo.

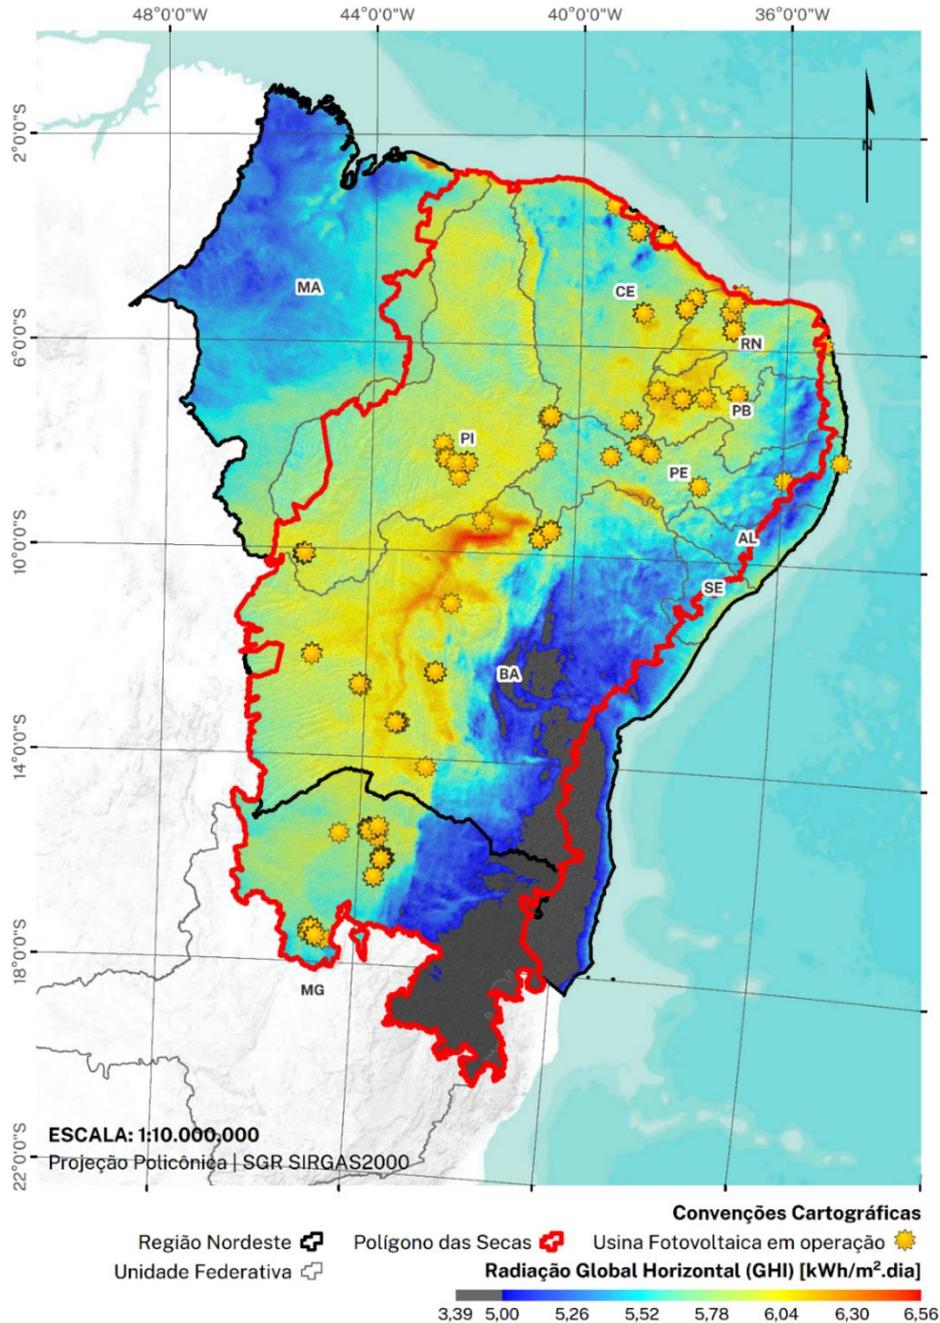


Fonte: próprio autor.

A usina fotovoltaica encontra-se no interior do chamado Polígono das Secas, Figura 9, região com delimitação geográfica determinada pela legislação brasileira, que tem como principal característica a ocorrência de longos períodos de estiagem, pela aridez dos solos e pela vegetação típica da caatinga. Essa região abrange oito estados do nordeste brasileiro (o Maranhão é a exceção) e parte de Minas Gerais.

Também, face às condições climáticas dessa região, os valores de irradiação solar tendem a ser mais elevados do que em outras áreas do país.

Figura 9 – Mapa da irradiação global horizontal e usinas em operação comercial.



Fonte: próprio autor.

A análise dos dados de entrada é apresentada no tópico 4.1, a descrição dos modelos de detecção e os cenários de teste nos tópicos 4.2 e 4.3, respectivamente.

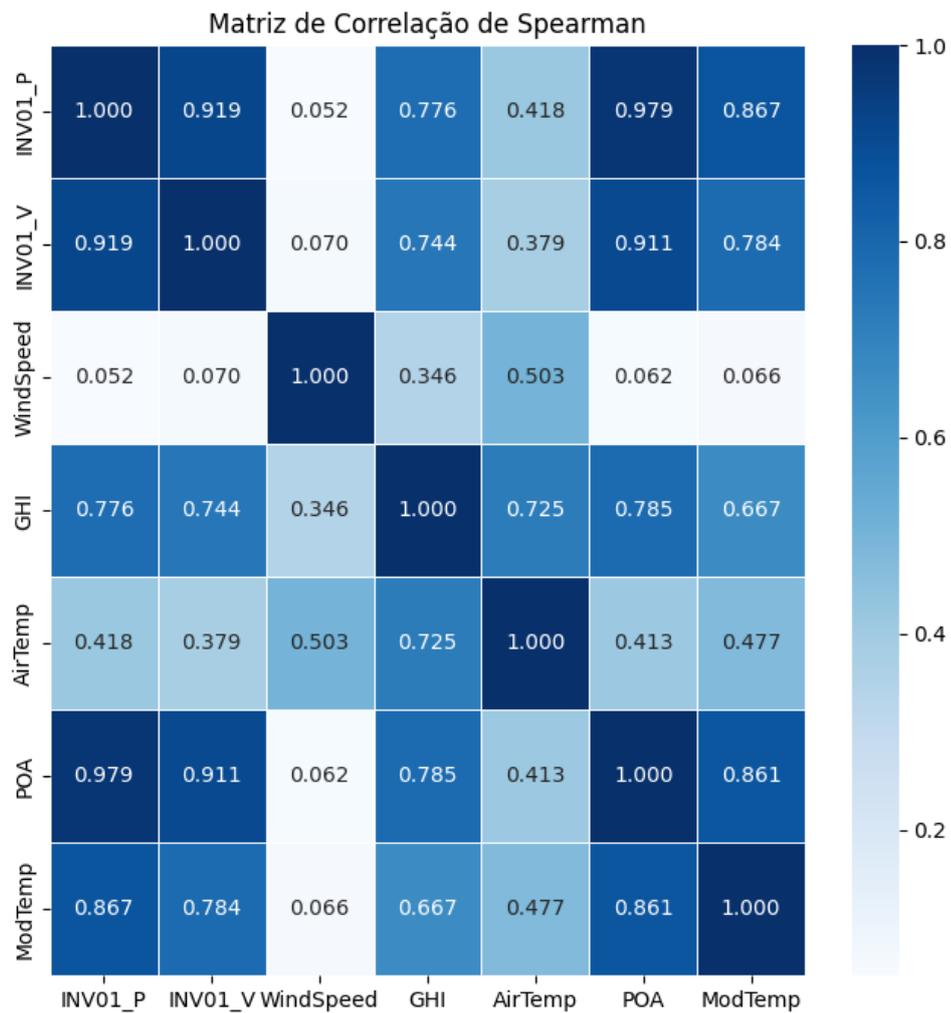
4.1 Análise dos dados

Os dados utilizados são provenientes de usina fotovoltaica localizada no nordeste brasileiro e modificados para realização de testes do algoritmo de detecção. Os dados de entrada possuem amostragem de 10 minutos e compreendem o período de 01/09/2023 a 25/09/2023. As variáveis disponíveis são:

- Dados de medição do inversor:
 - INV01_P: Potência no lado CA do inversor 1 (MW);
 - INV01_V: Tensão do inversor 1(V);
- Dados meteorológicos:
 - GHI: Irradiância Global Horizontal (W/m^2);
 - POA: Irradiância no plano inclinado do módulo fotovoltaico (W/m^2);
 - AirTemp: Temperatura do ar ($^{\circ}C$);
 - ModTemp: Temperatura do módulo fotovoltaico ($^{\circ}C$).

As variáveis utilizadas como entrada do modelo são determinadas com base nas melhores correlações com a variável alvo, que é a potência. As correlações entre as variáveis estão na Figura 10. Observa-se que, as variáveis com a melhor correlação com a potência do inversor são os dados tensão do inversor, a irradiância no plano inclinado e a temperatura do módulo fotovoltaico.

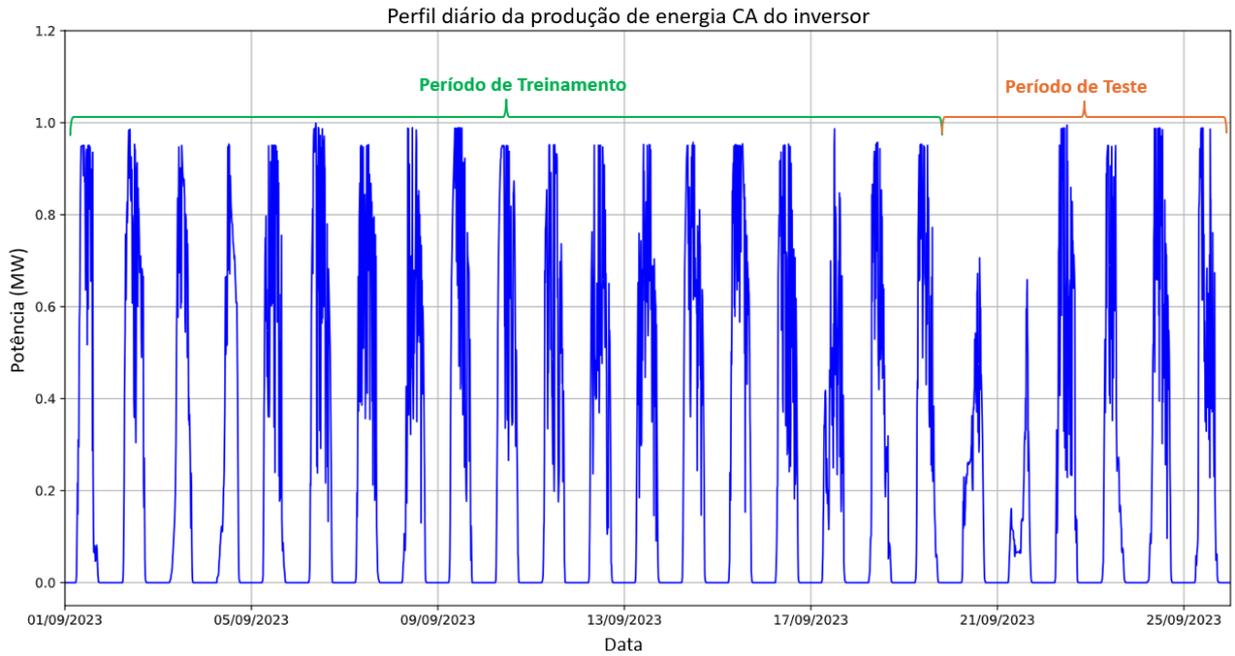
Figura 10 - Matriz de correlação das variáveis.



Fonte: próprio autor.

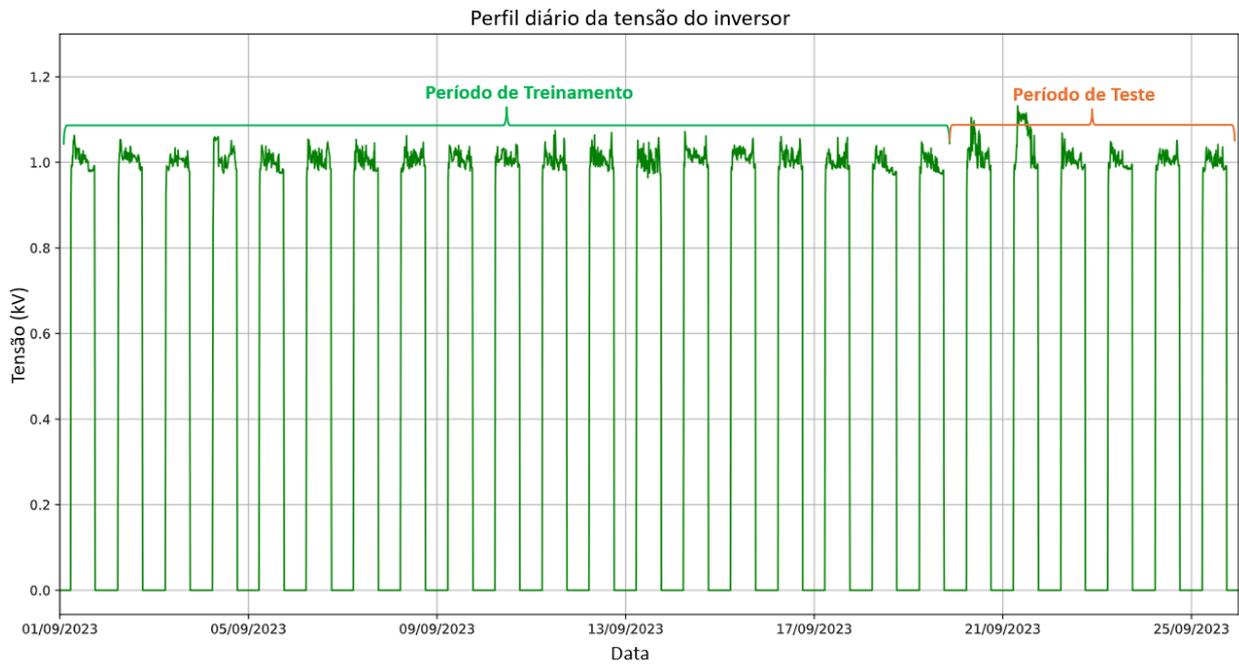
Durante o tratamento dos dados foram separados os períodos para treinamento e período de teste. A Figura 11 e Figura 12 apresenta a série temporal de produção de energia e a tensão medida do inversor em estudo, respectivamente, além dos períodos de teste e treinamento.

Figura 11 – Perfil diário de produção do inversor em estudo.



Fonte: próprio autor.

Figura 12 – Perfil diário de tensão do inversor em estudo.

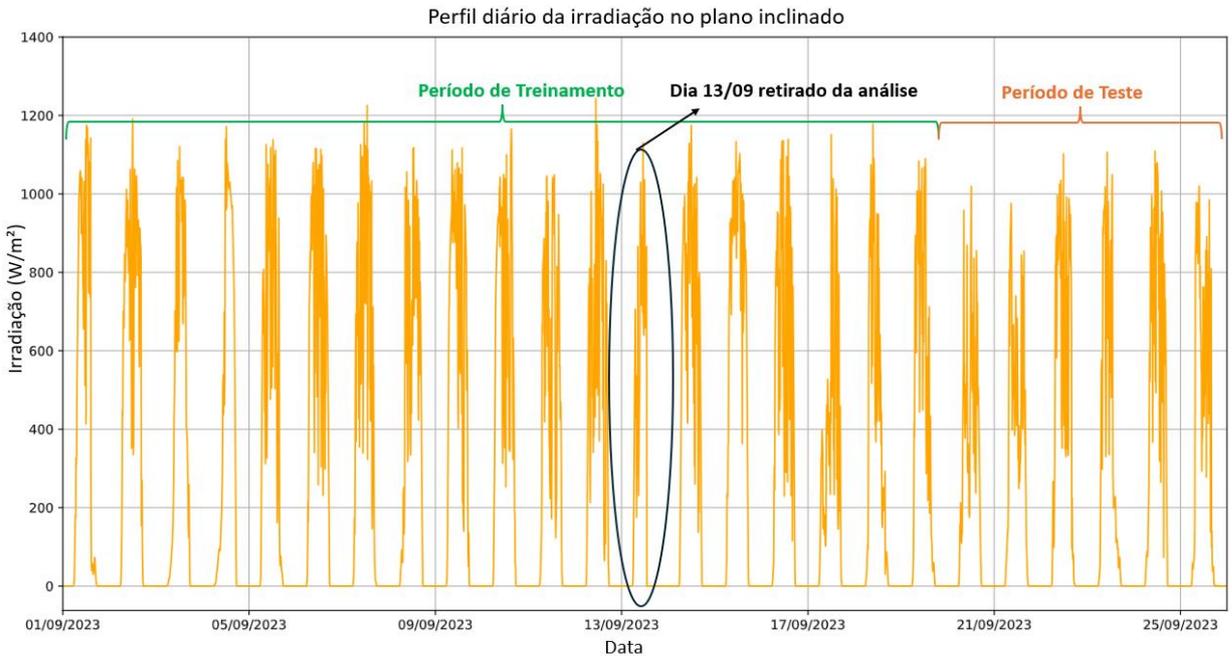


Fonte: próprio autor.

A Figura 13 e a Figura 14 apresentam a série temporal da irradiação no plano inclinado e a temperatura no módulo fotovoltaico, respectivamente. O treinamento do

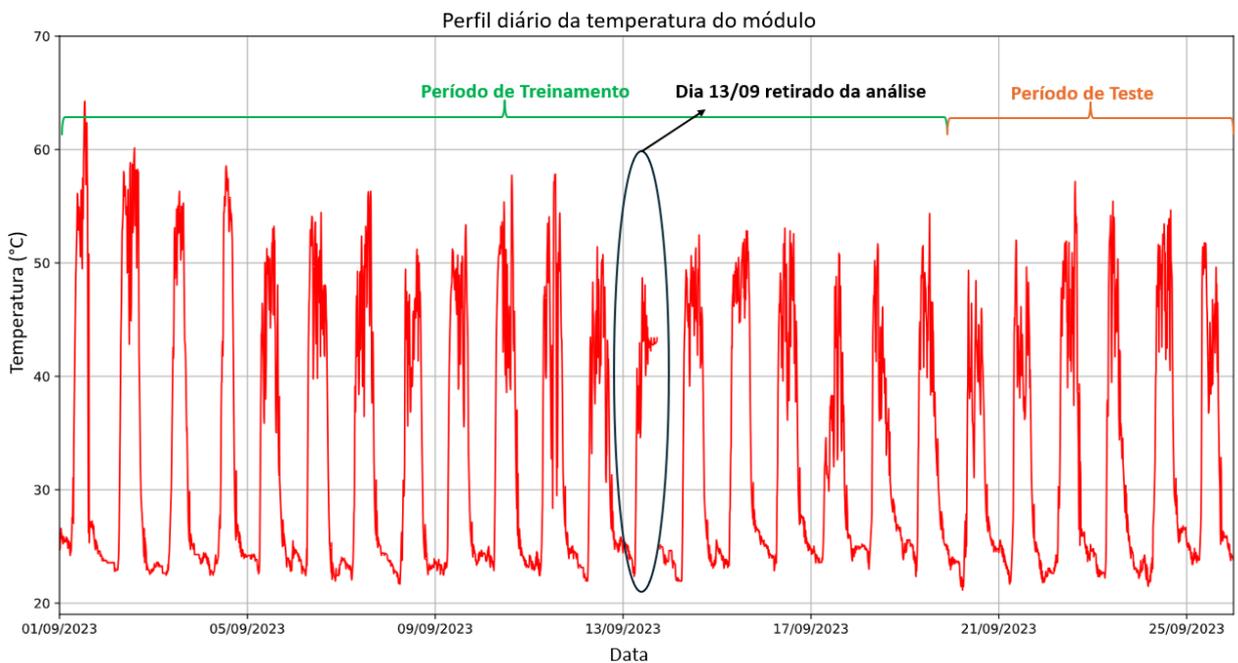
algoritmo requer dados sem anomalias. Assim, o dia 13/09/2023 foi retirado do treinamento por apresentar falhas dos dados meteorológicos.

Figura 13 - Perfil diário da irradiação no plano inclinado do módulo fotovoltaico.



Fonte: próprio autor.

Figura 14 – Perfil diário da temperatura do módulo fotovoltaico.



Fonte: próprio autor.

4.2 Modelos e método de detecção

São propostas três redes neurais para detecção de anomalias na produção de energia do inversor. Todos os modelos têm como base a arquitetura de reconstrução Autoencoder, com variações nas camadas empregadas, que são:

- Autoencoder (AE): rede neural construída utilizando o Autoencoder, com camadas densas;
- Autoencoder com CNN (AE-CNN): rede neural com arquitetura de um Autoencoder e camadas convolucionais;
- Autoencoder com LSTM (AE-LSTM): rede neural com arquitetura de um Autoencoder e camadas de LSTM.

A construção dos modelos foi realizada na linguagem de alto nível Python, utilizando as bibliotecas TensorFlow e Keras para aprendizado profundo.

O modelo AE utiliza camadas densas e estratégia de *Dropout*, onde em cada camada uma certa porcentagem de pesos é aleatoriamente definida como zeros. Esse mecanismo reduz o problema de sobreajuste (*overfitting*) do modelo [5]. A Tabela 2 apresenta os detalhes do modelo AE, onde a coluna "Camadas" descreve as funções, unidades e parâmetros utilizados na rede neural.

Tabela 2 - Detalhe do modelo de rede neural Autoencoder (AE).

Componente	Camadas	Descrição
Entrada	Sequências de dados de forma (sequência = 1, variáveis = 4)	Dados de entrada, onde cada sequência possui 1 passo temporal e 4 variáveis.
Codificador	Camadas densas com ativação ReLU (128, 64 unidades) e Dropout (0.2)	Converte a entrada em uma representação densa, reduzindo dimensionalidade e aplicando <i>Dropout</i> para prevenir sobreajuste.
Espaço latente	Camada Flatten() para transformar em vetor 1D	Transforma a saída do codificador em um vetor unidimensional, comprimindo a informação.
Decodificador	Camadas densas com ativação ReLU (128, 64 unidades) e Dropout (0.2)	Reconstrói a sequência a partir do vetor latente comprimido, utilizando <i>Dropout</i> para melhorar a generalização do modelo.
Saída	Camada TimeDistributed(Dense)	Reconstrói a série temporal aplicando uma camada densa a cada passo temporal.

Fonte: próprio autor.

O modelo AE-CNN utiliza camadas convolucionais e estratégia de *Dropout* para reconstruir a sequência temporal extraído as características espaciais dos dados de entrada. A Tabela 3 apresenta os detalhes de cada camada do modelo AE-CNN.

Tabela 3 - Detalhe do modelo de rede neural Autoencoder com CNN (AE-CNN).

Componente	Camadas	Descrição
Entrada	Sequências de dados de forma (sequência = 1, variáveis = 4)	Dados de entrada, onde cada sequência possui 1 passo temporal e 4 variáveis.
Codificador	Primeira camada do codificador Conv1D (32 filtros, kernel = 4) com ativação ReLU e Dropout (0.2)	Extraí características espaciais dos dados de entrada, reduzindo dimensionalidade e aplicando <i>Dropout</i> para prevenir overfitting.
	Segunda camada do codificador Conv1D (32 filtros, kernel = 4) com ativação ReLU e Dropout (0.2)	
Espaço Latente	Saída da última camada convolucional do codificador	Representação comprimida das características espaciais extraídas pelo codificador.
Decodificador	Camada Conv1D (32 filtros, kernel = 4) com ativação ReLU	Reconstrói os dados de entrada a partir da representação comprimida aprendida pelo codificador.
Saída	Conv1DTranspose(4 filtros, kernel = 4) de saída com ativação sigmoide	Gera a sequência reconstruída utilizando a função de ativação sigmoide.

Fonte: próprio autor.

O modelo AE-LSTM utiliza camadas LSTM com unidades variáveis para extrair as características temporais e reconstruir a sequência dos dados de entrada. A Tabela 4 apresenta os detalhes de cada camada do modelo AE-LSTM.

Tabela 4 - Detalhe do modelo de rede neural Autoencoder com LSTM (AE-LSTM).

Componente	Camadas	Descrição
Entrada	Sequências de dados de forma (sequência = 1, variáveis = 4)	Dados de entrada, onde cada sequência possui 1 passo temporal e 4 variáveis.
Codificador	Primeira camada do codificador LSTM (128 unidades, ativação ReLU)	Camada LSTM que processa sequências de entrada, extraindo características temporais complexas.
	Segunda camada do codificador LSTM (64 unidades, ativação ReLU)	
Espaço latente	RepeatVector() para repetir a última saída da segunda camada do codificador	Repete a saída final da camada codificadora para preparar os dados para o decodificador.
Decodificador	Primeira camada do codificador LSTM (128 unidades, ativação ReLU)	Camada LSTM que recebe o vetor do espaço latente expandido e reconstrói sequências de saída.
	Segunda camada do decodificador LSTM (64 unidades, ativação ReLU)	
Saída	TimeDistributed(Dense)	Gera a sequência reconstruída, aplicando operações densas a cada passo temporal.

Fonte: próprio autor.

Os modelos irão receber os dados de entrada e tentar reconstruí-los o mais próximo possível dos dados originais. A diferença entre as variáveis reconstruídas e originais de entrada resulta no erro de reconstrução [26].

As variáveis de entrada dos modelos são: produção de energia do inversor, tensão do inversor, a irradiância no plano inclinado e a temperatura do módulo fotovoltaico. As saídas dos modelos são as quatro variáveis reconstruídas.

As redes neurais são treinadas para aprender as relações e padrões a partir dos dados de treino, que são livres de anomalias. Quando em contato com dados anômalos que não foram apresentados na fase de treinamento, o modelo é incapaz de reconstruir com precisão os dados, ocasionando um grande erro de reconstrução. Este erro é utilizado para a detecção em casos em que as reconstruções ultrapassem um determinado limiar desse erro.

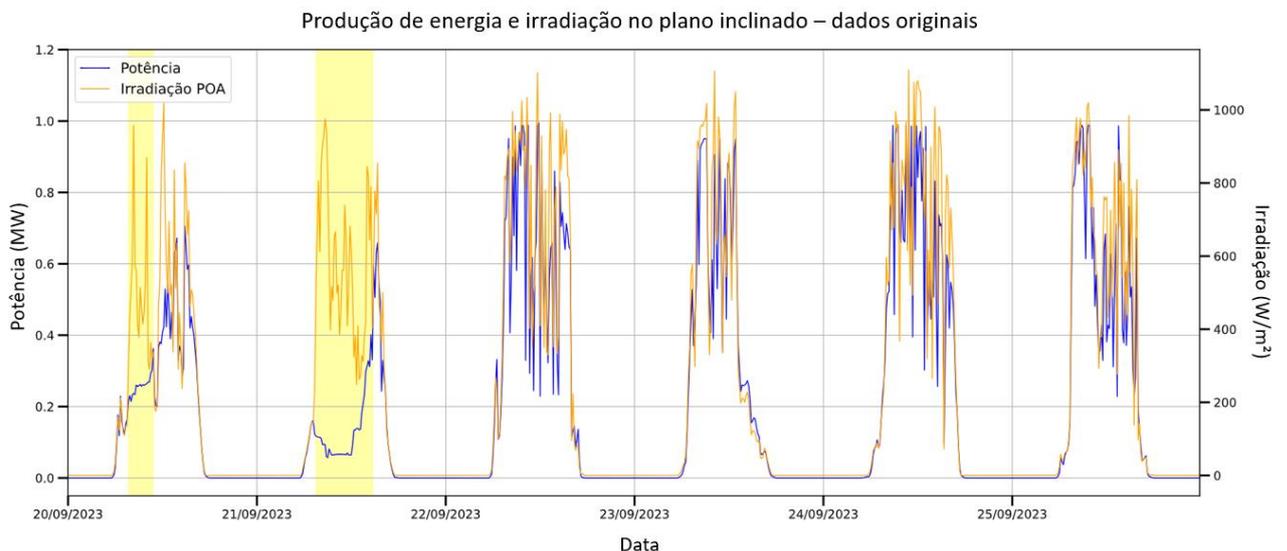
4.3 Descrição dos cenários de testes

As redes neurais devem ser capazes de identificar anomalias presentes em três cenários: anomalias nos dados originais, anomalias de defeito tipo 1, anomalias defeito de tipo 2.

Os defeitos tipo 1 e 2 foram inseridos artificialmente, inserindo falhas nos dados de produção de inversor, mantendo inalteradas as variáveis de temperatura do módulo, irradiação no plano inclinado e tensão do inversor. A criação dos cenários com defeitos tem como objetivo a avaliação dos algoritmos propostos em diferentes eventos de falhas.

A Figura 15 apresenta o primeiro cenário com anomalias nos dados originais. As janelas temporais em amarelo são os períodos em que os algoritmos devem apontar como anomalias.

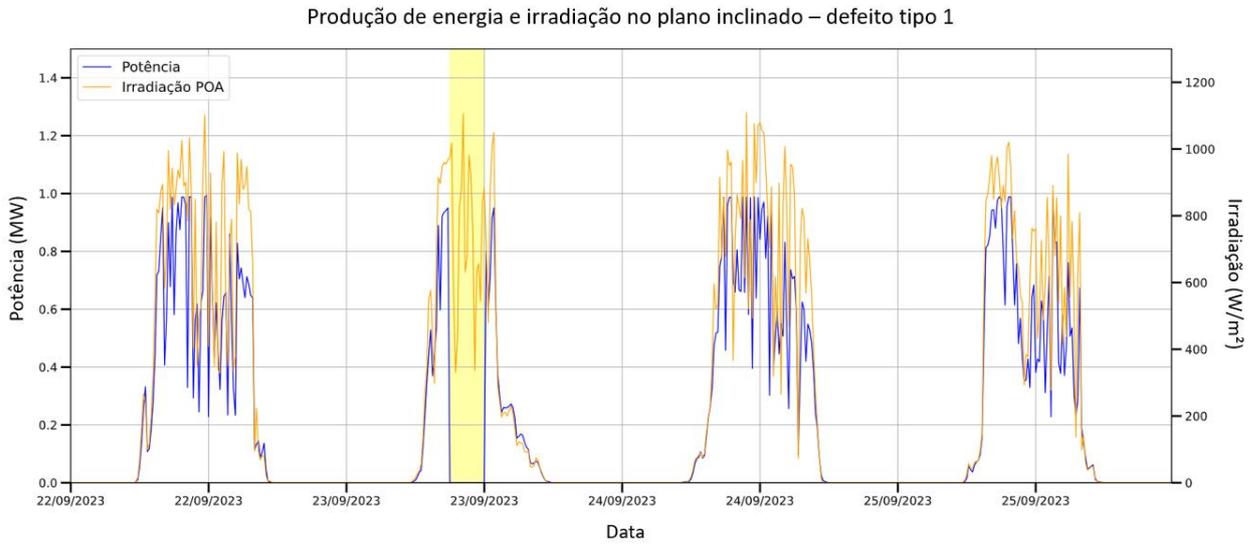
Figura 15 – Gráfico de produção de energia e irradiação com anomalias nos dados originais.



Fonte: próprio autor.

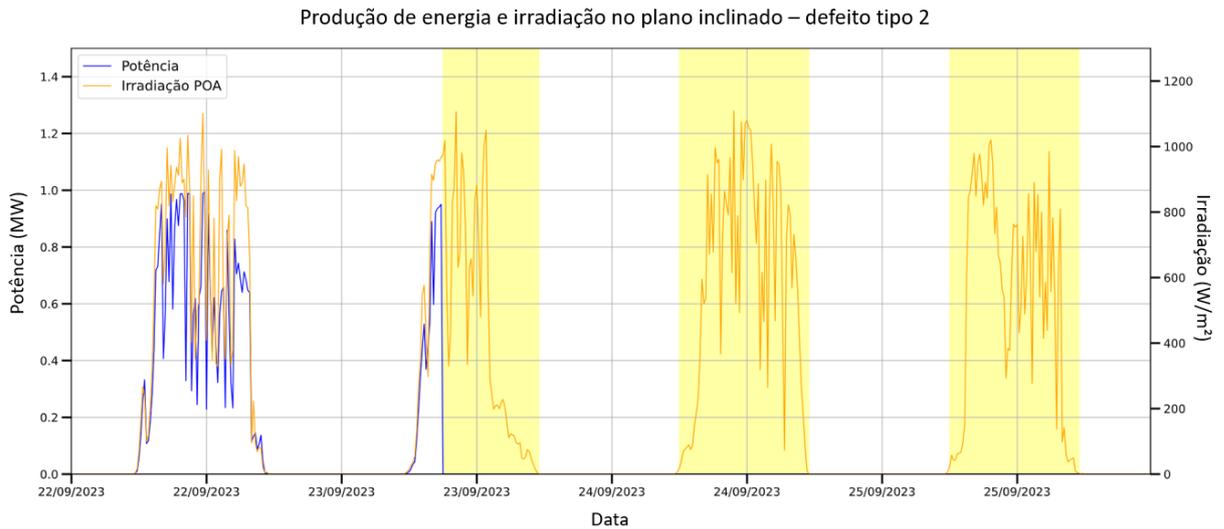
A Figura 16 mostra a janela temporal com anomalias de defeito tipo 1, em que há um defeito total temporário no inversor.

Figura 16 - Gráfico de produção de energia e irradiação com anomalias do tipo 1.



A Figura 17 apresenta as janelas temporais com anomalias de defeito tipo 2, onde há um defeito total permanente no inversor por mais de dois dias consecutivos.

Figura 17 - Gráfico de produção de energia e irradiação com anomalias do tipo 2.



5 RESULTADOS NUMÉRICOS

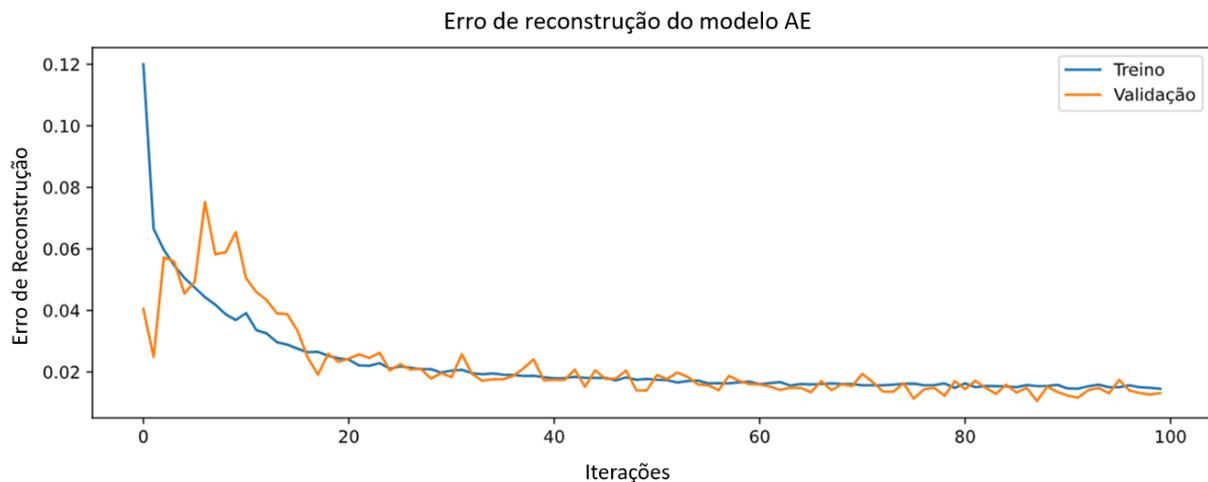
Cada modelo foi treinando utilizando 100 iterações (epochs) e 20 lotes (batches), com otimizador Adam e erro médio absoluto (MAE) para cálculo de erro de reconstrução entre as variáveis originais e reconstruídas.

Os dados para treino das redes neurais profundas são os dados do período de treinamento apresentado no tópico 4.1, separados em 80% para treino e 20% para validação. Os dados de entrada do modelo são produção de energia e tensão do inversor, irradiação do plano inclinado e temperatura do módulo.

A cada iteração do treinamento do modelo é calculado um único erro de reconstrução para as quatro variáveis. Quanto menor o erro do modelo, melhor é a reconstrução dos dados de entrada.

O erro de reconstrução do modelo Autoencoder durante a fase de treinamento é mostrada na Figura 18. É possível ver um rápido aprendizado até a vigésima iteração e depois uma convergência em torno de 0,02.

Figura 18 – Erro de reconstrução do treinamento do modelo AE.

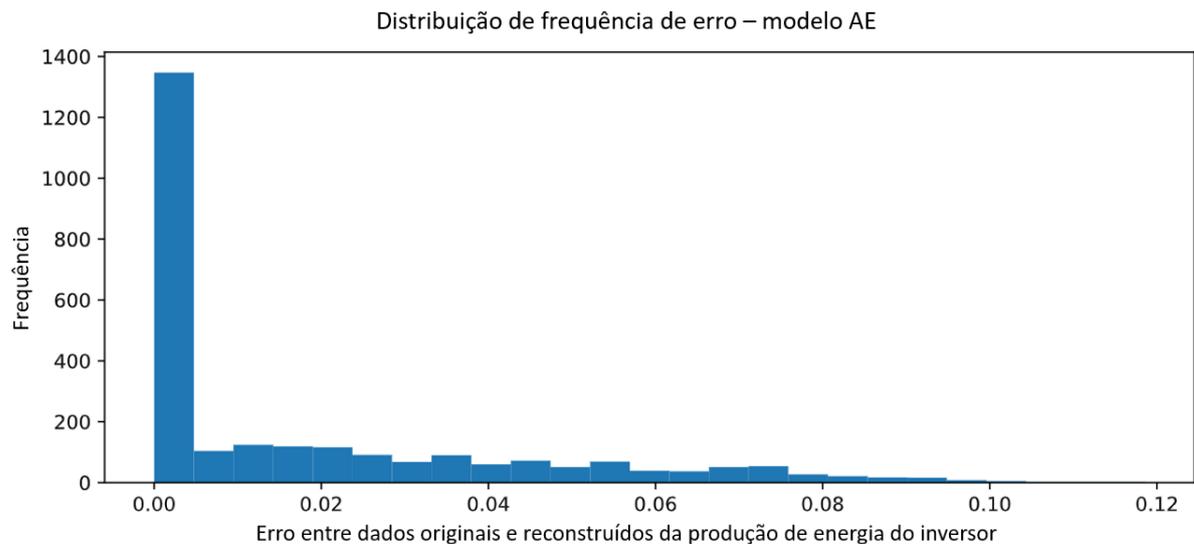


Fonte: próprio autor.

Os dados de treino são novamente passados pelo modelo AE já treinado para gerar uma reconstrução das séries temporais. A partir dessa reconstrução, calcula-se o erro absoluto entre os dados reconstruídos e os dados originais da produção de energia do inversor. Em seguida, é feita uma análise da distribuição de frequência do

erro da produção. Um limiar de erro é estabelecido na extremidade dessa distribuição, onde as frequências de erro são menores. Quando o erro ultrapassa esse limiar, o algoritmo identifica os dados como possíveis anomalias. A distribuição do erro do modelo AE é apresentada na Figura 19, com limiar de erro definido em 0,10.

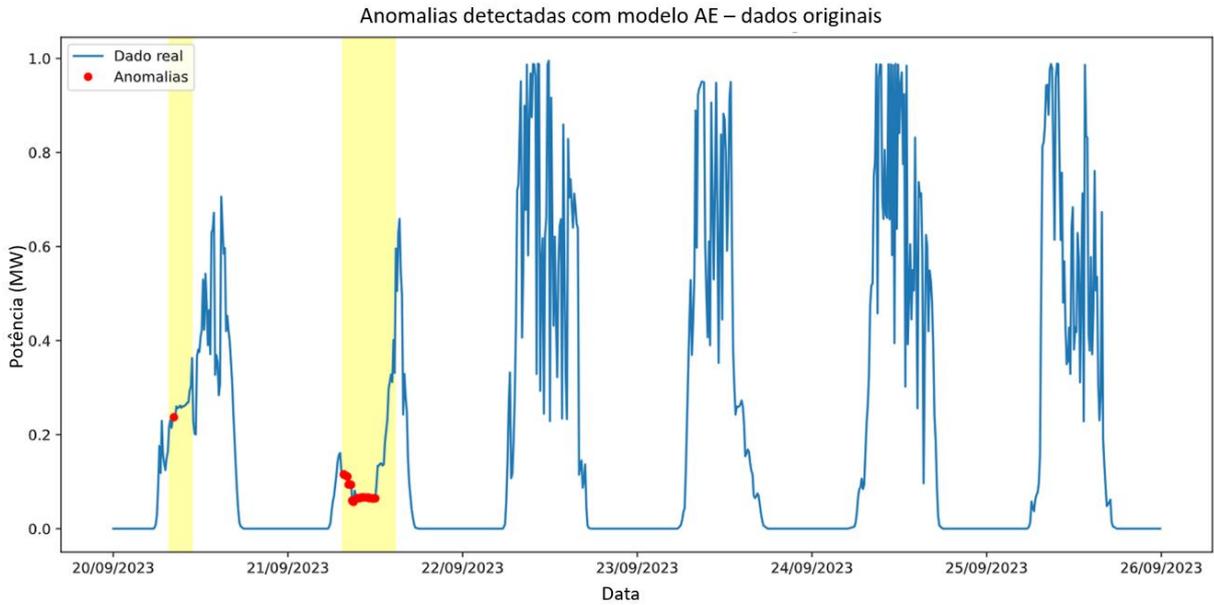
Figura 19 - Distribuição do erro do modelo AE.



Fonte: próprio autor.

A aplicação do modelo AE para identificação de anomalias no dado original pode ser visto na Figura 20, onde a janela de dados que deve ser detectada está em amarelo e os pontos identificados pelo modelo como anomalias estão em vermelho. Para o dia 20/09/2023 apenas um único ponto foi identificado como anomalia, representando 5% dos dados anômalos no período, e para o dia 21/09/2023 foram identificados aproximadamente 50% dos dados anômalos.

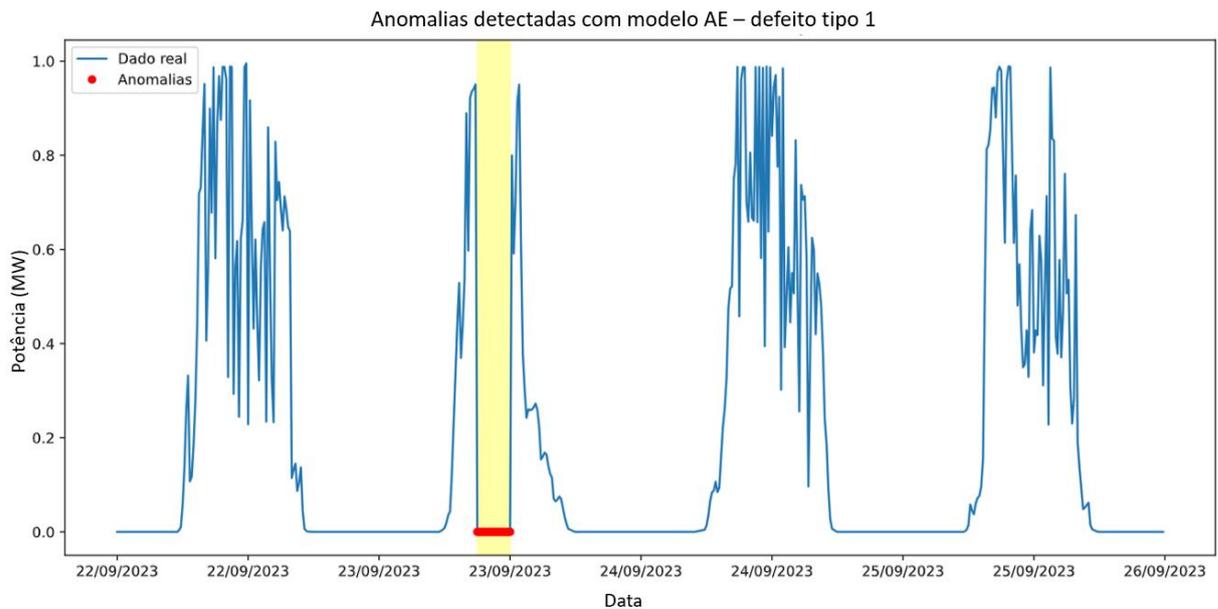
Figura 20 - Anomalias detectadas pelo algoritmo AE nos dados originais.



Fonte: próprio autor.

O resultado da detecção da anomalia de defeito tipo 1 pelo modelo AE é apresentado na Figura 21. O modelo identificou 100% dos dados dentro do período de anomalia.

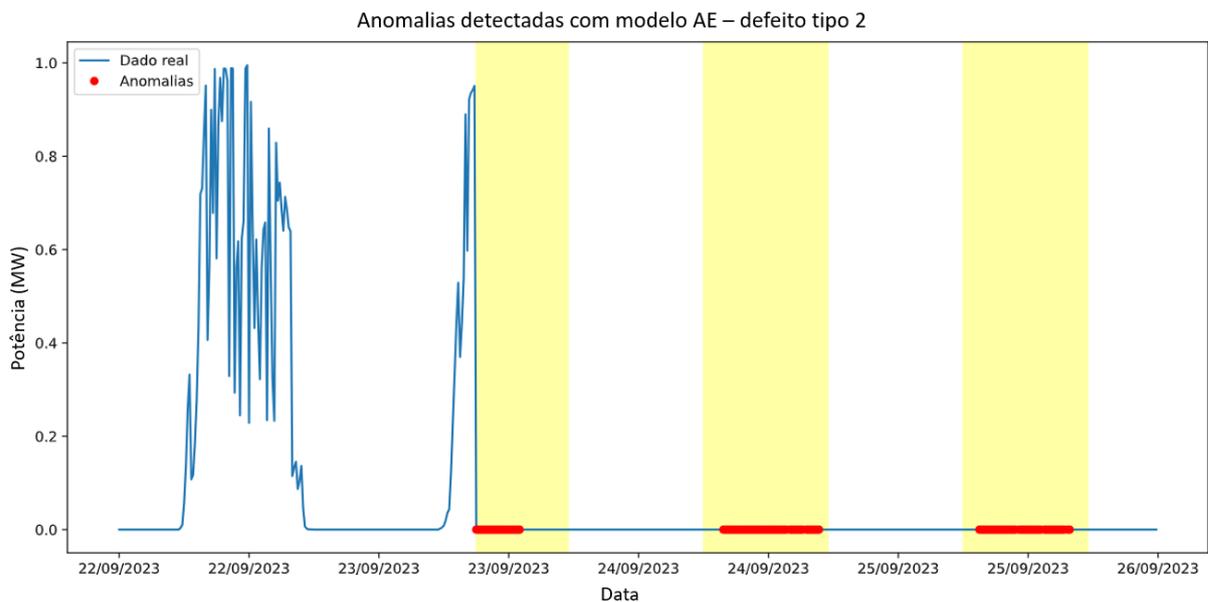
Figura 21 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE.



Fonte: próprio autor.

O resultado da detecção da anomalia de defeito tipo 2 pelo modelo AE é apresentado na Figura 22. Observa-se que os dados apontados como anomalias apresentam erro no começo e final do dia de produção. O dia 23/09/2023 foram identificados cerca de 48% de dados de anomalias em relação aos dados da janela em amarelo. Para os dias 24/09/2023 e 25/09/2023, foram identificados 68% e 74% dos dados anômalos, respectivamente.

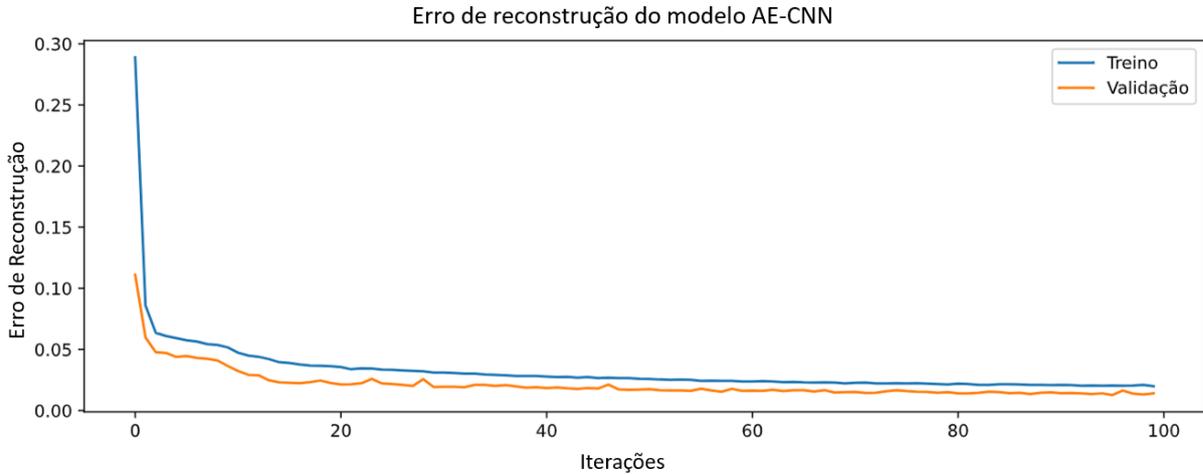
Figura 22 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE.



Fonte: próprio autor.

O erro de reconstrução para cada iteração de treinamento do segundo modelo de rede neural AE-CNN nos dados de treinamento e validação é mostrada na Figura 23. Nas primeiras cinco iterações o modelo aprende rapidamente e depois converge em torno de 0,02.

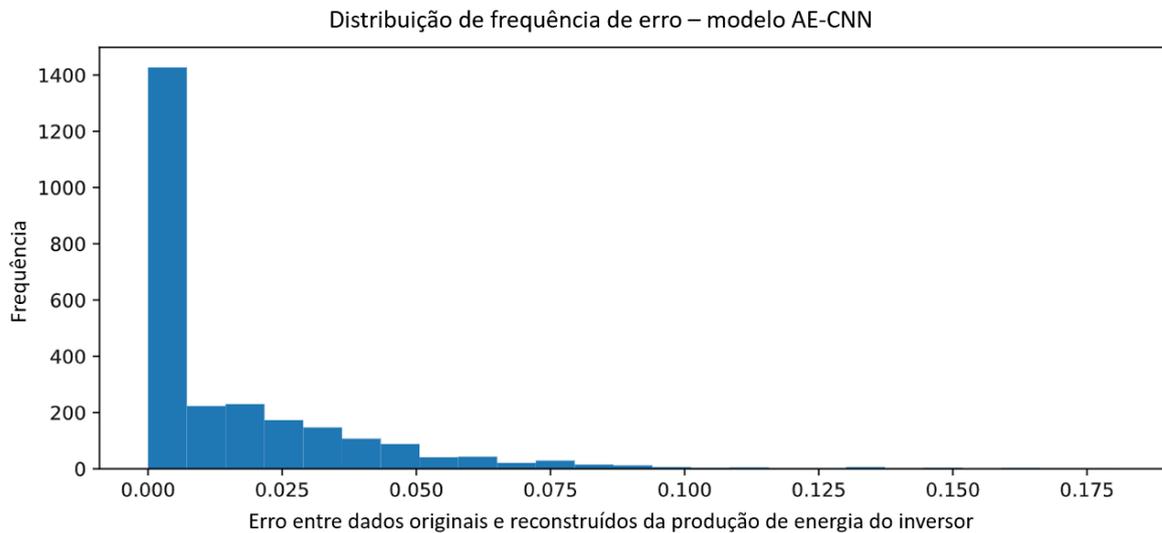
Figura 23 – Erro de reconstrução do treinamento do modelo AE-CNN.



Fonte: próprio autor.

A distribuição do erro do modelo AE-CNN é apresentada na Figura 24. O limiar de erro a partir do qual o modelo identificará dados como possivelmente anômalo foi definido em 0,175.

Figura 24 - Distribuição do erro do modelo AE-CNN.

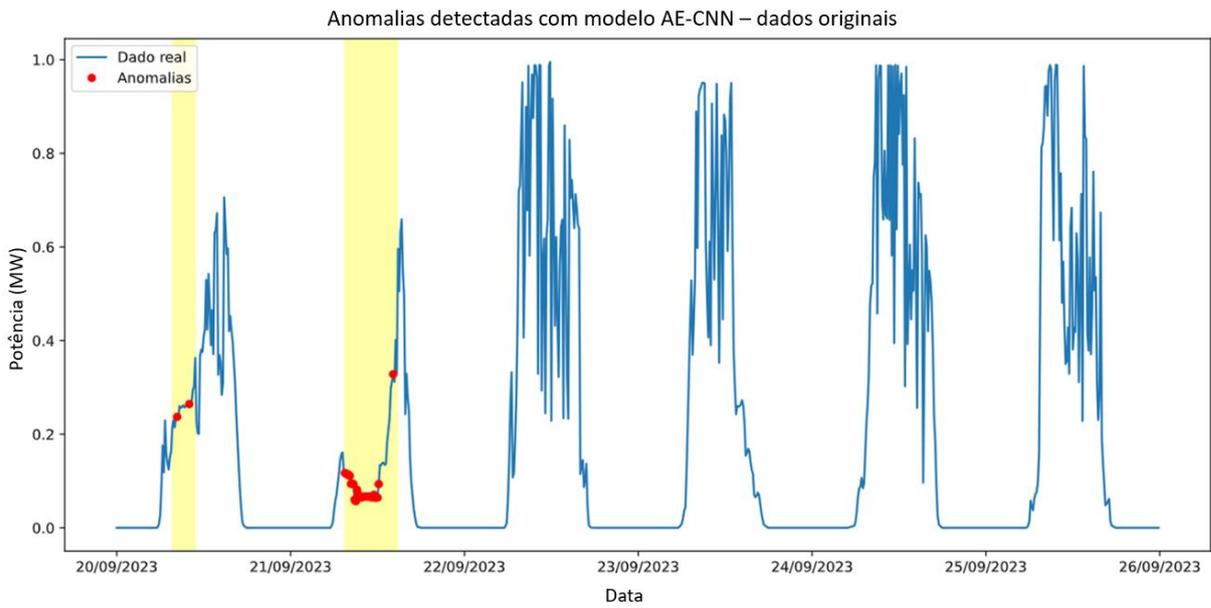


Fonte: próprio autor.

A detecção do modelo AE-CNN de anomalias nos dados originais é apresentada na Figura 25. Para período de 20/09/2023 e 21/09/2023 foram identificados 10% e 68% dos dados anômalo, respectivamente. Em relação ao modelo AE, foram

identificados alguns pontos a mais, mas, no geral, para a detecção de anomalias nos dados de teste originais, os dois modelos tiveram desempenhos semelhantes.

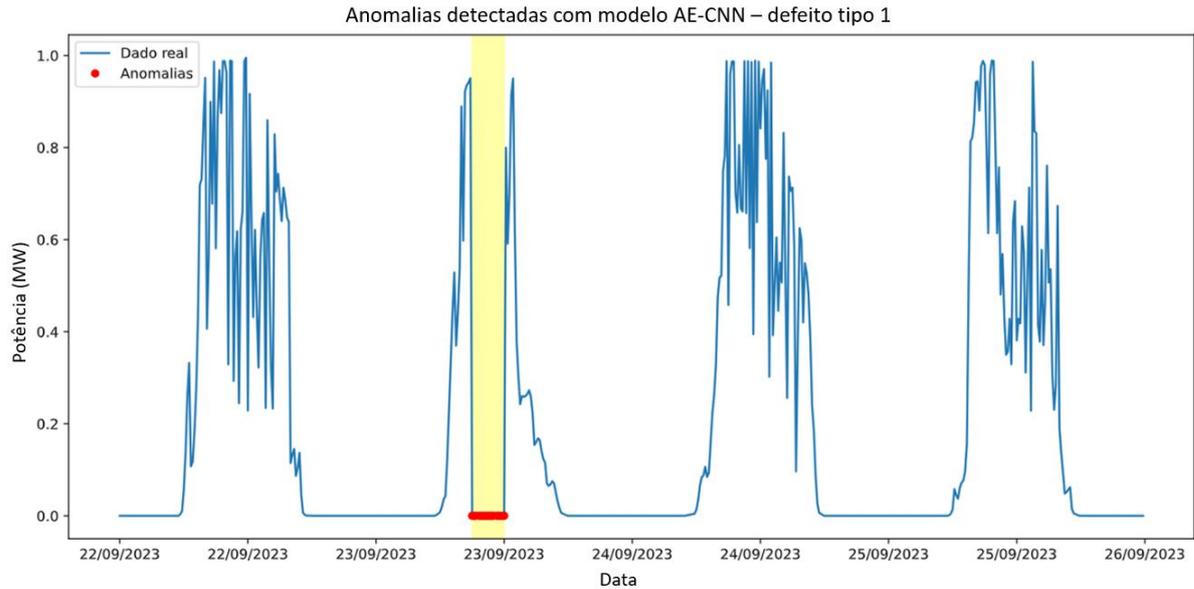
Figura 25 - Anomalias detectadas pelo algoritmo AE-CNN nos dados originais.



Fonte: próprio autor.

A detecção das anomalias de defeito tipo 1 pelo modelo AE-CNN é apresentado na Figura 26. O modelo identificou 100% dos pontos dentro da janela de anomalias.

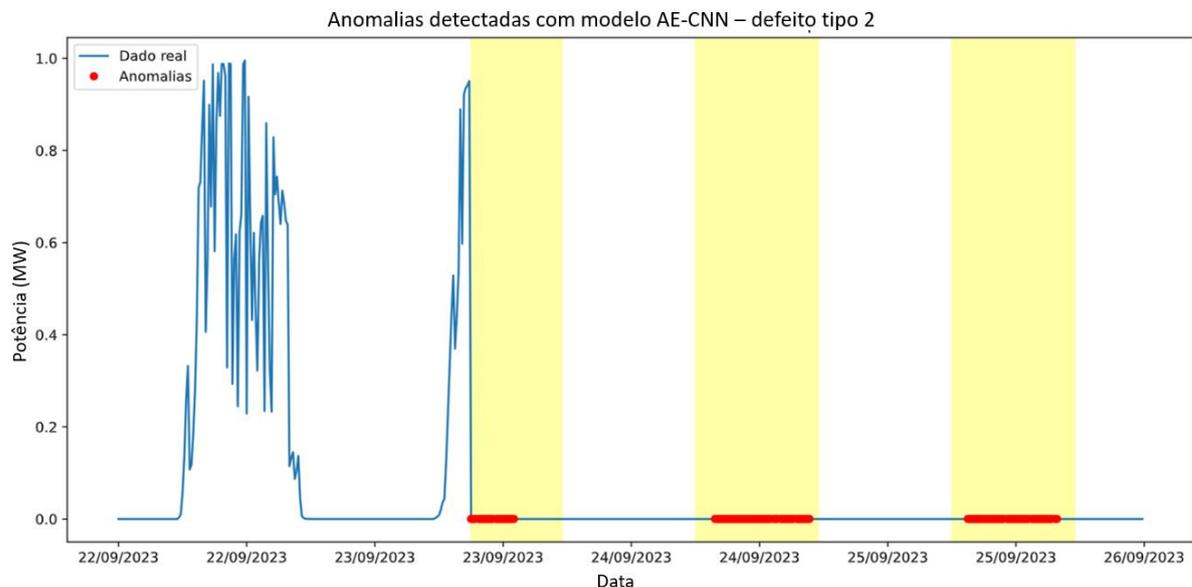
Figura 26 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE-CNN.



Fonte: próprio autor.

O resultado da detecção da anomalia de defeito tipo 2 pelo modelo AE-CNN é apresentado na Figura 27. Para os dias 23/09/2023, 24/09/2023 e 25/09/2023 foram identificados 44%, 73% e 68% dos dados anômalos, respectivamente para cada janela temporal. Semelhantemente ao modelo AE, o modelo AE-CNN possui erro na identificação de anomalias ao começo e final do dia de produção.

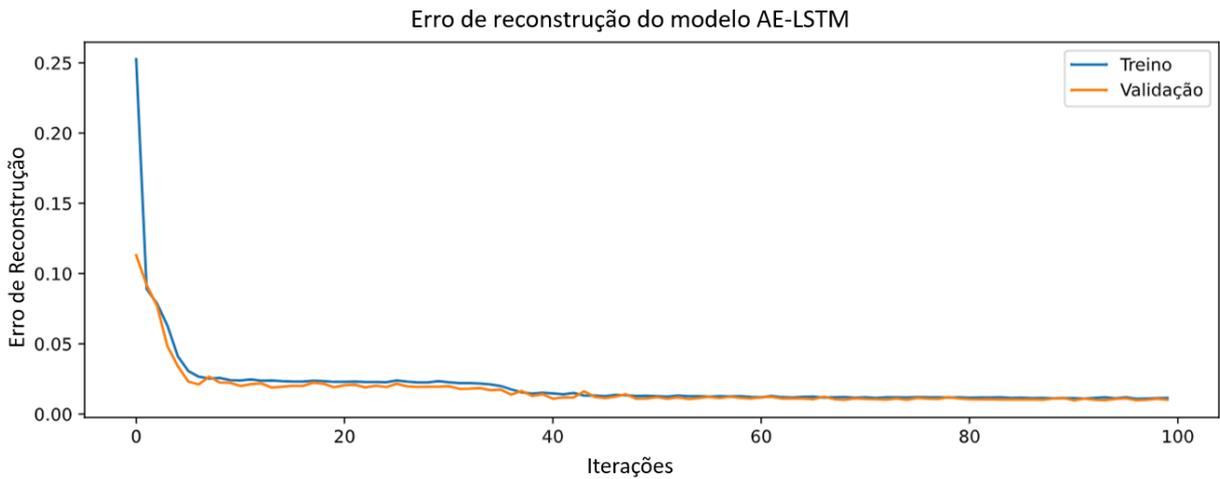
Figura 27 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE-CNN.



Fonte: próprio autor.

O erro de reconstrução do terceiro modelo de rede neural AE-LSTM nos dados de treinamento e validação é mostrada na Figura 28. Nas dez primeiras iterações o modelo aprende rapidamente e depois converge em torno de 0,01.

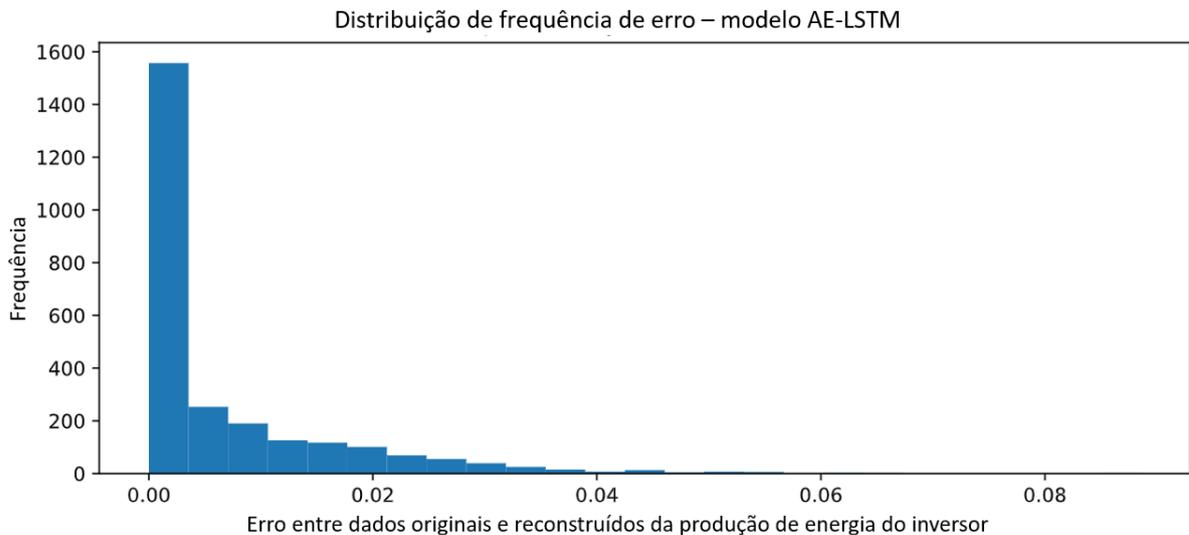
Figura 28 – Erro de reconstrução do treinamento do modelo AE-LSTM.



Fonte: próprio autor.

A distribuição do erro do modelo AE-LSTM é apresentada na Figura 29. O limiar de erro para detecção de anomalias foi definido em 0,07.

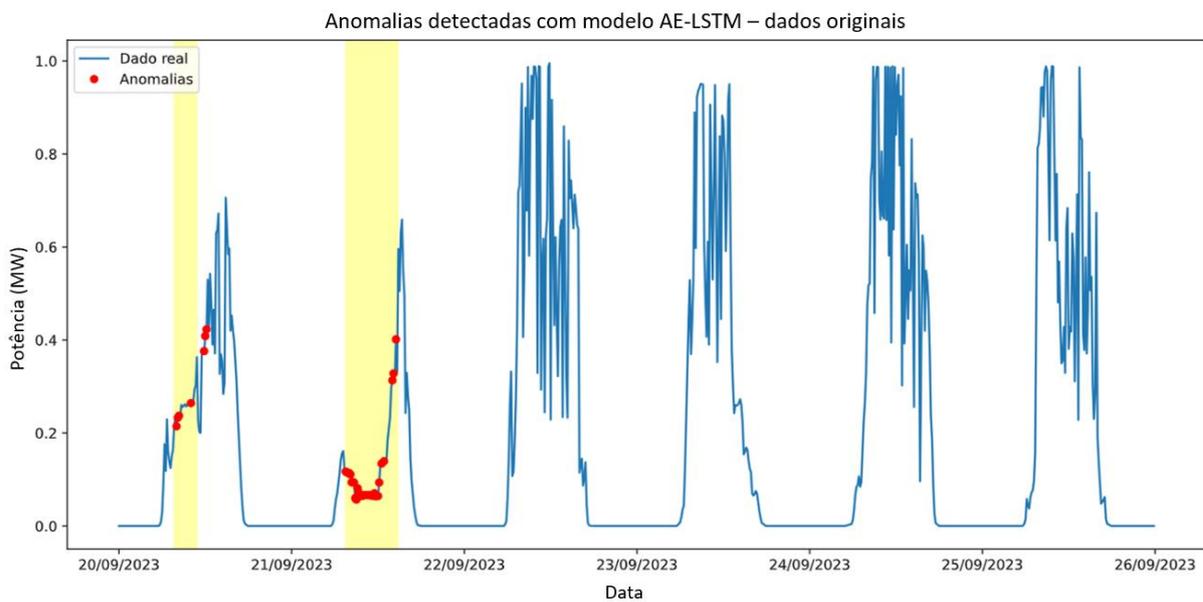
Figura 29 - Distribuição do erro do modelo AE-LSTM.



Fonte: próprio autor.

A detecção do modelo AE-LSTM de anomalias nos dados originais é apresentada na Figura 30. Para o dia 20/09/2023 foram identificados 20% dos dados no período em amarelo, além de alguns dados fora do período. A janela temporal do dia 21/09/2023 foram identificados 77% dos dados como anômalos. O modelo AE-LSTM foi capaz de identificar melhor as anomalias nos dados de teste originais, quando comparado aos modelos anteriores.

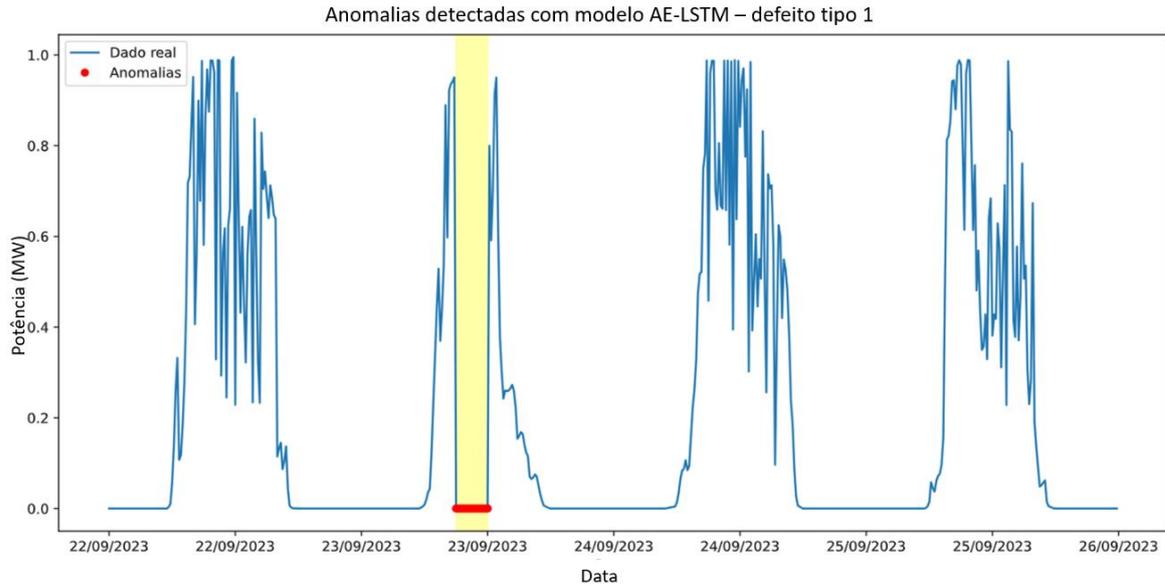
Figura 30 - Anomalias detectadas pelo algoritmo AE-LSTM nos dados originais.



Fonte: próprio autor.

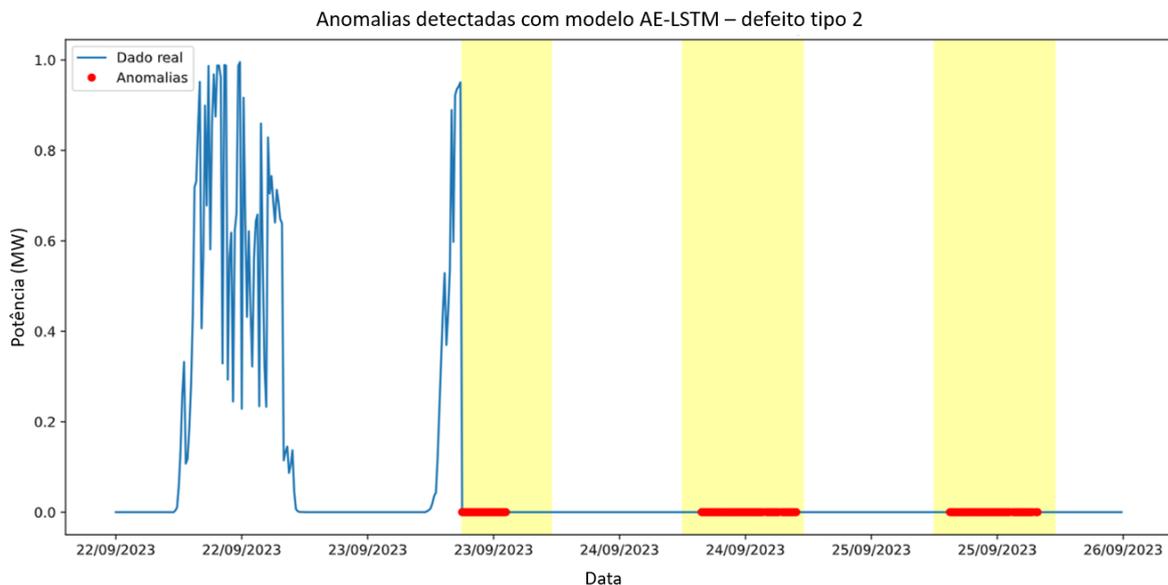
A detecção das anomalias de defeito tipo 1 pelo modelo AE-LSTM é apresentado na Figura 31. Foram identificados 100% dos pontos anômalos no cenário de defeito total temporário.

Figura 31 - Anomalias de defeito tipo 1 detectadas pelo algoritmo AE-LSTM.



O resultado da detecção da anomalia de defeito tipo 2 pelo modelo AE-LSTM é apresentado na Figura 32. Foram identificados 50%, 76% e 70% dos dados anômalos nas janelas dos dias 23/09/2023, 24/09/2023 e 25/09/2023, respectivamente. O modelo AE-LSTM apresentou um desempenho semelhantemente aos modelos AE e AE-CNN para o cenário de um defeito total permanente.

Figura 32 - Anomalias de defeito tipo 2 detectadas pelo algoritmo AE-LSTM.



A partir dos dados de treinamento, foram calculadas três métricas estatísticas, além do erro absoluto médio, utilizando tanto os dados originais quanto as séries reconstruídas por cada modelo treinado, com o objetivo de comparar o desempenho de reconstrução de cada rede neural artificial.

A Tabela 5 apresenta o comparativo estatístico entre os modelos. A raiz do erro médio quadrático (RMSE) reflete a diferença em energia entre os modelos durante a reconstrução dos dados de entrada. Os resultados indicam que o AE apresentou uma diferença de 31,4 kW, o AE-CNN de 28,2 kW e o AE-LSTM de 12,2 kW.

Além disso, o coeficiente de determinação (R^2), que mede a qualidade da reconstrução dos dados durante o treinamento, demonstrou performances similares entre os modelos. No entanto, houve uma melhora significativa no método utilizando uma rede neural recorrente (AE-LSTM), indicando uma superioridade na capacidade de reconstrução deste modelo em relação aos demais.

Tabela 5 - Comparativo dos modelos propostos.

Tipo de rede neural	MSE	RMSE	R^2 (%)
AE	0,0010	0,0314	99,17
AE-CNN	0,0008	0,0282	99,33
AE-LSTM	0,0001	0,0122	99,87

Fonte: próprio autor.

A Tabela 5 apresenta a porcentagem média de dados identificados como anômalos, considerando todos os períodos e cenários. Entre os três modelos, o AE-LSTM foi o que identificou a maior porcentagem de dados anômalos tanto nos dados originais quanto no cenário com defeito do tipo 2.

Tabela 6 – Porcentagem de dados anômalos identificados por modelo.

Tipo de rede neural	Cenários		
	Anomalia nos dados originais	Anomalia de defeito tipo 1	Anomalia de defeito tipo 2
AE	34%	100%	65%
AE-CNN	50%	100%	63%
AE-LSTM	59%	100%	67%

Fonte: próprio autor.

6 CONCLUSÕES E PROPOSTAS DE CONTINUIDADE

Este estudo abordou a aplicação de técnicas de inteligência artificial na detecção de anomalias em usinas fotovoltaicas. Foram exploradas as falhas envolvendo o inversor, devido ao seu grande impacto na perda de energia de uma usina e por ser o componente com maiores números de registros de manutenções.

Foram propostos três modelos de redes neurais profundas: AE, AE-CNN e AE-LSTM. Esses modelos atingiram uma taxa de reconstrução de dados superior a 99% durante o treinamento e apresentaram desempenho semelhante na detecção de falhas.

As redes neurais foram testadas em cenários abrangendo diferentes tipos de anomalias que poderiam ocorrer em uma operação diária de inversor. No primeiro cenário, que envolve nos dados originais da usina em estudo, o modelo AE apresentou o pior desempenho, identificando apenas 34% dos dados anômalos. Na situação em que houve uma falha temporária (anomalia de defeito tipo 1), todos os modelos identificaram 100% das anomalias. Para o cenário em que a produção foi interrompida por mais de dois dias consecutivos (anomalia de defeito tipo 2), o desempenho dos modelos foi semelhante, com a porcentagem de detecção acima de 60% dos dados anômalos. O modelo AE-LSTM se destacou por conseguir detectar uma maior quantidade de dados anômalos, considerando os todos os períodos e cenários.

Para aprimorar a detecção de falhas, os modelos avaliados podem ser aperfeiçoados expandindo a quantidade de dados na fase de treinamento e ajustando parâmetros de treino, como o número de iterações e o tamanho dos lotes. Além disso, podem ser implementadas outras variações de redes neurais, como a combinação de CNN-LSTM, o uso de LSTM bidirecionais e a implementação de *Variational Autoencoder* como alternativas para a detecção de anomalias.

6.1 Propostas de trabalhos futuros

Como trabalhos futuros, pode-se associar os modelos de detecção com outras redes neurais para a classificação dos tipos de falhas em inversores. Adicionalmente, o modelo pode ser integrado em soluções envolvendo inspeções visuais por drones

para a detecção de problemas na parte de corrente contínua. Problemas em *strings* e módulos afetam a produção do inversor, embora não sejam falhas específicas do equipamento. A utilização de drones para inspeção visual permite identificar esses problemas de maneira mais eficiente e precisa, complementando a detecção de falhas nos inversores.

REFERÊNCIAS

1. POWER capacity additions reached a new benchmark of 473 gigawatts in 2023, but many countries are cut off from the benefits of energy transitions, 27 março 2024. Disponível em: <<https://www.irena.org/News/pressreleases/2024/Mar/Record-Growth-in-Renewables-but-Progress-Needs-to-be-Equitable>>. Acesso em: 17 junho 2024.
2. ENERGIA solar: usinas centralizadas ultrapassam os 5% na matriz elétrica brasileira, com 10,4 GW instalados, 12 setembro 2023. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/noticias/2023/energia-solar-usinas-centralizadas-ultrapassam-os-5-na-matriz-eletrica-brasileira-com-10-4-gw-instalados>>. Acesso em: 17 junho 2024.
3. PAUL, M. M. R. et al. Classification and Detection of Faults in Grid Connected Photovoltaic System. **International Journal of Scientific & Engineering Research**, v. 7, p. 149-154, 2016.
4. MELLIT, A.; TINA, G. M.; KALOGIROU, S. A. Fault detection and diagnosis methods for photovoltaic systems: A review. **Renewable and Sustainable Energy Reviews**, v. 91, p. 1-17, 2018.
5. RAO, S. et al. Dropout and Pruned Neural Networks for Fault Classification in Photovoltaic Arrays. **IEEE Access**, 2021. 120034-120042.
6. HU, J. et al. A Comprehensive Review of Artificial Intelligence Applications in. **CAAI Artificial Intelligence Research**, v. 3, 2024.
7. ZHANG, X.; LIU, H.; MIAO, L. Fault analysis of photovoltaic inverter. **Journal of Physics: Conference Series**, 2023.
8. HASSAN, Y. B.; ORABI, M.; GAAFAR, M. A. Failures causes analysis of grid-tie photovoltaic inverters based on faults signatures analysis (FCA-B-FSA). **Solar Energy**, v. 262, 2023.
9. PEREIRA, F.; SILVA, C. Machine learning for monitoring and classification in inverters from solar photovoltaic energy plants. **Solar Compass**, mar. 2024. 100066.
10. PILLAI, D. S.; RAJASEKAR, N. A comprehensive review on protection challenges and fault diagnosis in PV. **Renewable and Sustainable Energy Reviews**, v. 91, p. 18-40, Ago. 2018.
11. MANSOURI, M. et al. Deep Learning-Based Fault Diagnosis of Photovoltaic Systems: A Comprehensive Review and Enhancement Prospects. **IEEE Access**, v. 9, p. 126286-126306, 2021.
12. LILLO-BRAVO, I. et al. Impact of Energy Losses Due to Failures on Photovoltaic Plant Energy Balance. **Energies**, v. 11, n. 363, 2018.
13. NAGARAJAN, A. et al. **Photovoltaic Inverter Reliability Assessment**. [S.l.]. 2019. (NREL/TP-5D00-74462).
14. KLISE, G.; LAVRORA, O.; GOODING, R. **PV System Component Fault and Failure Compilation and Analysis**. [S.l.]. 2018. (SAND2018-1743).
15. RAPAPORT, et al. **The Use of Advanced Algorithms in PV Failure Monitoring**. International Energy Agency. [S.l.]. 2021. (ISBN 978-3-907281-07-9).

16. ET-TALEBY, A. et al. Applications of Machine Learning Algorithms for Photovoltaic Fault Detection: a Review. **Statistics, Optimization & Information Computing**, v. 11, n. 1, p. 168-177, 2023.
17. TCHIO, G. M. T. et al. A Comprehensive Review of Supervised Learning Algorithms for the Diagnosis of Photovoltaic Systems, Proposing a New Approach Using an Ensemble Learning Algorithm. **Applied Sciences**, v. 14, 2024.
18. ROMERO, H. F. M. et al. Applications of Artificial Intelligence to Photovoltaic Systems: A Review. **Applied Sciences**, v. 12, 2022.
19. EL-BANBY, G. M. et al. Photovoltaic system fault detection techniques: a review. **Neural Computing and Applications**, 03 October 2023. 24829-24842.
20. AMIRI, A. F. et al. Fault Detection and Diagnosis of a Photovoltaic System Based on Deep Learning Using the Combination of a Convolutional Neural Network (CNN) and Bidirectional Gated Recurrent Unit (Bi-GRU). **Sustainability**, 24 January 2024. 1012.
21. MEMON, S. A. et al. A Machine-Learning-Based Robust Classification Method for PV Panel Faults. **Sensors**, 22 November 2022. 8515.
22. APPIAH, A. Y. et al. Long Short-Term Memory Networks based Automatic Feature Extraction for Photovoltaic Array Fault Diagnosis. **IEEE Access**, 2017. 30089-30101.
23. HU, D. et al. Anomaly Detection of Power Plant Equipment Using Long Short-Term Memory Based Autoencoder Neural Network. **Sensors**, 29 October 2020. 6164.
24. IBRAHIM, M. et al. Machine Learning Schemes for Anomaly Detection in Solar Power Plants. **Energies**, 1 February 2022. 1082.
25. PARK, T. et al. Convolutional Autoencoder-Based Anomaly Detection for Photovoltaic Power Forecasting of Virtual Power Plants. **Energies**, 11 July 2023. 5293.
26. TORABI, H.; MIRTAHERI, S. L.; GRECO, S. Practical autoencoder based anomaly detection by using vector reconstruction error. **Cybersecurity**, v. 6, n. 1, p. 13, janeiro 2023.