



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA

DIEGO RAMIRO MELO MONTEIRO

**PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA UTILIZANDO
TRANSFORMAÇÃO DE SÉRIES TEMPORAIS EM IMAGENS E REDES NEURAIS
CONVOLUCIONAIS BIDIMENSIONAIS**

BELÉM – PA
2023

DIEGO RAMIRO MELO MONTEIRO

**PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA UTILIZANDO
TRANSFORMAÇÃO DE SÉRIES TEMPORAIS EM IMAGENS E REDES NEURAIS
CONVOLUCIONAIS BIDIMENSIONAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – PGEE, do Instituto de Tecnologia – ITEC, da Universidade Federal do Pará – UFPA, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica, na área de Computação Aplicada.

Linha de Pesquisa: Inteligência Computacional.

Orientadora: Profa. Dra. Adriana Rosa Garcez Castro

BELÉM – PA
2023

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

M772p Monteiro, Diego Ramiro Melo.
Previsão de geração de energia fotovoltaica utilizando
transformação de séries temporais em imagens e redes neurais
convolucionais bidimensionais / Diego Ramiro Melo Monteiro. —
2023.
xi, 77 f. : il. color.

Orientador(a): Prof^ª. Dra. Adriana Rosa Garcez Castro
Dissertação (Mestrado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, Belém, 2023.

1. Geração de energia fotovoltaica. 2. Redes neurais
convolucionais. 3. Campo angular gramiano. 4. Gráfico de
recorrência. 5. Séries temporais. I. Título.

CDD 006.32

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA UTILIZANDO
TRANSFORMAÇÃO DE SÉRIES TEMPORAIS EM IMAGENS E REDES NEURAIAS
CONVOLUCIONAIS BIDIMENSIONAIS**

AUTOR: DIEGO RAMIRO MELO MONTEIRO

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE **MESTRE** EM ENGENHARIA ELÉTRICA NA ÁREA DE **COMPUTAÇÃO APLICADA**.

APROVADA EM: **26 de outubro de 2023**.

BANCA EXAMINADORA:

Profa. Dra. Adriana Rosa Garcez Castro
Orientadora – PPGEE/UFPA

Profa. Dra. Maria Emília de Lima Tostes
Avaliadora Interna – PPGEE/UFPA

Prof. Dr. Marcio José Moutinho da Ponte
Avaliador Externo – UFOPA

VISTO:

Prof. Dr. Diego Lisboa Cardoso
Coordenador do PPGEE/ITEC/UFPA

Aos meus sobrinhos Pedro, Gabriel e Davi.

Que esta janela que se abre seja legado e
inspiração.

AGRADECIMENTOS

Minha mais profunda gratidão à minha brilhante Orientadora, Profa. Dra. Adriana Castro, por ter me acolhido, ensinado, incentivado e tranquilizado nos momentos de desespero.

Ao CEAMAZON, especialmente na figura da Profa. Dra. Emília Tostes, pela disponibilização dos dados, fundamentais para o desenvolvimento deste trabalho.

Ao meu marido, Diego, pelo sempre pronto auxílio nas edições de figura e pela paciência nos momentos de ausência.

À minha mãe, à minha irmã, às minhas tias, ao meu primo e aos chegados amigos, pela torcida incessante.

E ao meu grande colega Vanderson, por ter envidado todos os esforços possíveis para que essa jornada fosse possível.

RESUMO

Este trabalho apresenta uma nova abordagem baseada em Rede Neural Convolutiva Bidimensional (*Convolutional Neural Network* – CNN) e técnicas de transformação de séries temporais em imagens, como Campo Angular Gramiano (*Gramian Angular Field* – GAF) e Gráfico de Recorrência (*Recurrence Plot* – RP), para previsão em curto prazo da geração de energia elétrica de uma microssistema fotovoltaica conectada à rede elétrica, localizada no Centro de Excelência em Eficiência Energética da Amazônia – CEAMAZON, da Universidade Federal do Pará (UFPA). As técnicas de GAF e de RP foram utilizadas para transformação das séries temporais em imagens para serem utilizadas como entrada para a CNN. A previsão de geração de energia elétrica com maior precisão possibilita ao usuário conhecer com maior grau de acerto quais os possíveis custos para implantação da rede e os prazos para retorno financeiro, além de avaliar com maior assertividade a disponibilidade de carga que poderá ser conectada ao sistema. Os resultados da previsão com a utilização de GAF e RP em rede CNN 2D foram comparados com resultados utilizando outros tipos de rede neurais já consolidadas na área, como a *Perceptron* Multicamadas e a CNN 1D, tendo a CNN 2D obtido em alguns casos valores RMSE próximos ou um pouco inferiores, mostrando assim a aplicabilidade da utilização de imagens obtidas através de transformação das séries temporais de energia fotovoltaica em rede CNN 2D para o problema.

Palavras-chave: geração de energia fotovoltaica; redes neurais convolucionais; campo angular Gramiano; gráfico de recorrência; séries temporais; previsão; inteligência computacional.

ABSTRACT

This research presents a novel approach based on a Bidimensional Convolutional Neural Network (CNN) and techniques for transforming time series data into images, such as Gramian Angular Field (GAF) and Recurrence Plot (RP), for short-term forecast of electricity generation from a photovoltaic microgrid connected to the electrical grid, located at the Center of Excellence in Energy Efficiency of the Amazon (Centro de Excelência em Eficiência Energética da Amazônia – CEAMAZON) at the Federal University of Pará (Universidade Federal do Pará – UFPA). The GAF and RP techniques were employed to transform the time series data into images, which were used as input for the CNN. More accurate electricity generation forecasts enable users to better estimate the potential costs for grid implementation and the payback periods, as well as assess the available load capacity that can be connected to the system with higher precision. The prediction results using GAF and RP with a 2D CNN were compared with results obtained using other established neural network architectures in the field, such as Multilayer Perceptron and 1D CNNs, yielding satisfactory Root Mean Square Error (RMSE) values. This demonstrates the applicability of using images generated from the transformation of photovoltaic time series data in a 2D CNN for this problem.

Keywords: photovoltaic power generation; convolutional neural networks; Gramian Angular Field; recurrence plot; time series; forecast; computational intelligence.

LISTA DE FIGURAS

Figura 1 - Matriz Elétrica Mundial em 2020.....	13
Figura 2 - Matriz Elétrica Brasileira em 2021.....	13
Figura 3 - Esquema de Célula Fotovoltaica.....	18
Figura 4 - Modelo de Módulo Fotovoltaico.	19
Figura 5 - Curva típica de relação I-V e P-V de módulo fotovoltaico.	20
Figura 6 - Modelo de neurônio tipo <i>Perceptron</i>	24
Figura 7 - Modelo de RNA tipo Perceptron Multicamadas.....	25
Figura 8 - Estrutura típica de CNN.....	27
Figura 9 - Exemplificação de operação de convolução.....	28
Figura 10 - Operação de max-pooling, com dimensão 2x2.....	29
Figura 11 - Série Temporal de Geração de Energia Fotovoltaica.....	31
Figura 12 - Demonstração do processo de Codificação de Campo Angular Gramiano.	33
Figura 13 - Exemplificação de transformação em imagem GAF de uma série temporal senoidal.....	34
Figura 14 - Exemplificação de transformação em imagem RP de uma série temporal senoidal.	36
Figura 15 - Sistema de geração híbrida instalado no CEAMAZON.	40
Figura 16 - Diagrama de fluxo da metodologia proposta.....	41
Figura 17 - Sistema de geração híbrida instalado no CEAMAZON.	42
Figura 18 - Trecho exemplificativo dos dados de geração fotovoltaica obtidos do sistema do CEAMAZON.	43
Figura 19 - Divisão da base de dados em Treinamento, Validação e Teste.....	47
Figura 20 - Exemplo de série temporal com $j = 1$ e transformações em imagem por URP, GASF e GADF.....	50
Figura 21 - Exemplo de série temporal com $j = 3$ e transformações em imagem por URP, GASF e GADF.....	50
Figura 22 - Modelo de CNN proposto, para 24 saídas.....	51
Figura 23 - Modelo de CNN proposto, para 1 saída.....	51
Figura 24 - Curvas de geração de energia para o dia 23/08/2022.	65
Figura 25 - Curvas de geração de energia para o dia 20/09/2022.	65
Figura 26 - Curvas de geração de energia para o dia 10/11/2022.....	65
Figura 27 - Curvas de geração de energia para o dia 25/11/2022.....	65
Figura 28 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 23/08/2022.....	66
Figura 29 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 20/09/2022.....	66
Figura 30 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 10/11/2022.....	66
Figura 31 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 25/11/2022.....	66
Figura 32 - Rede com Saída Energia Total – Energia prevista para o dia 23/08/2022.....	67
Figura 33 - Rede com Saída Energia Total – Energia prevista para o dia 20/09/2022.....	67
Figura 34 - Rede com Saída Energia Total – Energia prevista para o dia 10/11/2022.....	67
Figura 35 - Rede com Saída Energia Total – Energia prevista para o dia 25/11/2022.....	67

LISTA DE TABELAS

Tabela 1 - Distribuição percentual de dados não numéricos por mês	44
Tabela 2 - Quantidade de dados não numéricos na base de dados,	45
Tabela 3 - Amostras de uma série temporal exemplificativa para apresentação a uma rede neural com janela igual 3 e número de saídas igual a 2.	48
Tabela 4 - Dimensão das imagens de entrada e quantidade de imagens utilizadas para treinamento, de acordo com a variação da janela j	49
Tabela 5 - Dimensão das imagens de entrada e quantidade de imagens utilizadas para teste, de acordo com a variação da janela j	49
Tabela 6 - Parâmetros de treinamento e propriedades da rede.	52
Tabela 7 - Menor RMSE para redes MLP e CNN 1D com saída Energia 24 horas.	55
Tabela 8 - Menor RMSE para redes MLP e CNN 1D com saída Energia Total.	55
Tabela 9 - Melhores valores médios de RMSE para redes usando GASF, com saída Energia 24h.	56
Tabela 10 - Configurações da rede com menor valor de RMSE, usando GASF e saída Energia 24h.	56
Tabela 11 - Melhores valores médios de RMSE para redes usando GADF, com saída Energia 24h.	57
Tabela 12 - Configurações da rede com menor valor de RMSE, usando GADF e saída Energia 24h.	57
Tabela 13 - Melhores valores médios de RMSE para redes usando GASF, com saída Energia Total.	58
Tabela 14 - Configurações da rede com menor valor de RMSE, usando GASF e saída Energia Total.	58
Tabela 15 - Melhores valores médios de RMSE para redes usando GADF, com saída Energia Total.	59
Tabela 16 - Configurações da rede com menor valor de RMSE, usando GADF e saída Energia Total.	59
Tabela 17 - Melhores valores médios de RMSE para redes usando URP, com saída Energia 24h.	60
Tabela 18 - Configurações da rede com menor valor de RMSE, usando URP e saída Energia 24h.	61
Tabela 19 - Menores valores médios de RMSE para redes usando URP, com saída Energia Total.	61
Tabela 20 - Configurações da rede com menor valor de RMSE, usando URP e saída Energia Total.	62
Tabela 21 - Valores médios de RMSE.	63
Tabela 22 - Valores mínimos de RMSE.	63
Tabela 23 - Erros de previsão para o dia 23/08/2022.	68
Tabela 24 - Erros de previsão para o dia 20/09/2022.	68
Tabela 25 - Erros de previsão para o dia 10/11/2022.	68
Tabela 26 - Erros de previsão para o dia 25/11/2022.	69

LISTA DE ABREVIATURAS

CEAMAZON: Centro de Excelência em Eficiência Energética da Amazônia

CNN: Redes Neurais Convolucionais

GADF: Campo Diferencial Angular Gramiano

GAF: Campo Angular Gramiano

GASF: Campo Somatório Angular Gramiano

GW: Gigawatts

KW: Kilowatt

KWh: Kilowatt-hora

KWp: Kilowatt-pico

LSTM: Memória Longa de Curto Prazo

MLP: Perceptron Multicamadas

ReLU: Unidade Linear Retificada

RP: Gráfico de Recorrência

TRP: Gráfico de Recorrência com Limiar

TW: Terawatt

URP: Gráfico de Recorrência sem Limiar

W/m²: watt por metro quadrado

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contextualização	12
1.2	Objetivo Geral	15
1.3	Objetivos Específicos	15
1.4	Estrutura da Dissertação	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Introdução	17
2.2	Energia Solar	17
2.3	Geração Fotovoltaica	17
2.4	Previsão de Geração de Energia Fotovoltaica	21
2.5	Horizonte de Previsão	22
2.6	Redes Neurais Artificiais	23
2.6.1	Rede <i>Perceptron</i> Multicamadas	24
2.6.2	Algoritmos de Treinamento	24
2.6.3	Aprendizado Profundo	26
2.6.4	Redes Neurais Convolucionais	27
2.6.4.1	Camadas Convolucionais	27
2.6.4.2	Camadas de <i>Pooling</i>	28
2.6.4.3	Camadas <i>Flatten</i> e Totalmente Conectadas	29
2.6.4.4	<i>Dropout</i>	30
2.6.4.5	Normalização de Lotes	30
2.7	Técnicas de Transformação de Séries Temporais em Imagens	30
2.7.1	Campo Angular Gramiano	31
2.7.2	Gráfico de Recorrência	34
2.8	Estado da Arte	36
2.9	Conclusão	39
3	METODOLOGIA	40
3.1	Introdução	40
3.2	Sistema Fotovoltaico	41
3.3	Base de Dados	42
3.4	Pré-Processamento dos Dados	43
3.4.1	Divisão de dados em Treinamento, Teste e Validação	45
3.4.2	Normalização dos Dados	46

3.4.3	Organização dos Dados para Aprendizado	47
3.5	Parâmetros das Redes Neurais Convolucionais.....	51
3.6	Validação Estatística.....	53
4	RESULTADOS E DISCUSSÃO.....	54
4.1	Introdução	54
4.2	Previsão Utilizando GAF	55
4.2.1	Resultados Obtidos com GASF com Saída Energia 24h.....	56
4.2.2	Resultados Obtidos com GADF com Saída Energia 24h	57
4.2.3	Resultados Obtidos com GASF com Saída Energia Total	58
4.2.4	Resultados Obtidos com GADF com Saída Energia Total	59
4.3	Previsão Utilizando RP	60
4.3.1	Resultados Obtidos com URP com Saída Energia 24h.....	60
4.3.2	Resultados Obtidos com URP com Saída Energia Total	61
4.4	Análise Comparativa dos Resultados	62
4.5	Conclusão	69
5	CONCLUSÕES	70
	REFERÊNCIAS	72

1 INTRODUÇÃO

1.1 Contextualização

A corrida para minimizar os impactos nocivos do aquecimento global tem direcionado a discussão acerca da utilização de fontes renováveis de energia elétrica para o desenvolvimento das sociedades. Tão importante é o assunto que, dentre os 17 objetivos estabelecidos pela Organização das Nações Unidas (ONU) para possibilitar o desenvolvimento sustentável do planeta, está o de garantir o acesso à energia limpa e barata a todos os povos (ONU, 2018).

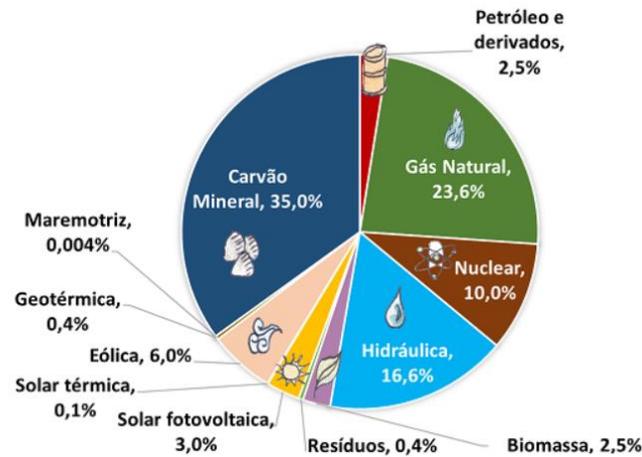
A 6ª edição do relatório da Agência de Ciência Climática da ONU publicado em 2022, nomeado Painel Intergovernamental sobre o Clima (*Intergovernmental Panel on Climate Change - IPCC*), destaca que os sistemas fotovoltaicos instalados em telhados, aliados à utilização de veículos elétricos, poderiam reduzir a emissão de gases do efeito estufa em cerca de 54% a 95% (IPCC, 2022).

Diante da necessidade urgente na utilização de fontes limpas e renováveis de energia elétrica, Smil (2019) destaca a relevância da geração de energia elétrica fotovoltaica, por apresentar maior densidade de potência e pelas características técnicas que permitem grande aproveitamento na geração descentralizada.

Muito embora a matriz elétrica mundial seja majoritariamente dependente de combustíveis fósseis, onde as fontes renováveis corresponderam a 29% do total de energia elétrica gerada no ano de 2020, a matriz elétrica brasileira apresenta maior dependência das fontes ditas limpas, tais como a hídrica, eólica e a solar, onde a geração a partir de recursos renováveis correspondeu a 78,1% do total gerado no Brasil no ano de 2021. As figuras 1 e 2 apresentam a divisão da matriz energética mundial em 2020 e brasileira em 2021, respectivamente.

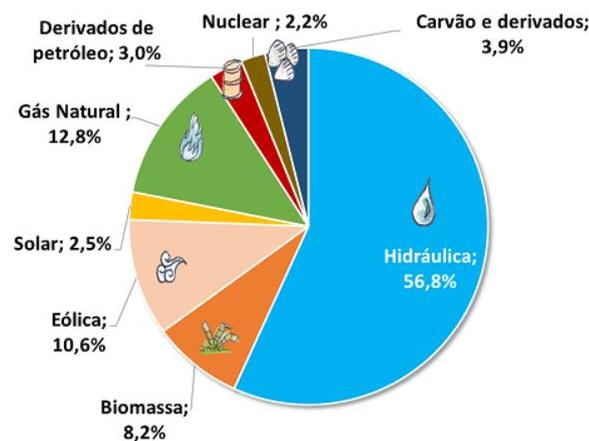
Os recursos hídricos são as principais fontes de geração de energia elétrica no Brasil, tendo sido responsável por 63,8% da geração no ano de 2020, enquanto a energia solar correspondeu a 1,73% do total gerado no mesmo ano, ou 10.748 GWh. Importante observar que, segundo o Balanço Energético Nacional de 2021, a produção de energia solar totalizou 16.752 GWh (2,5% do total produzido) naquele ano, o que corresponde a um incremento expressivo de 55,86% em relação à geração do ano anterior, e gerando 30.126 GWh em 2022, segundo o Balanço Energético Nacional de 2022, demonstrando forte expansão da geração fotovoltaica no contexto nacional.

Figura 1 - Matriz Elétrica Mundial em 2020.



Fonte: EPE, 2023.

Figura 2 - Matriz Elétrica Brasileira em 2021.



Fonte: EPE, 2023.

O avanço nas instalações de geração fotovoltaica, além de ser uma tendência mundial, conforme prevê a *International Energy Agency* (IEA), que sugere o acréscimo de 2.400 GW de potência instalada ao redor do mundo, também é perceptível no Brasil, onde se estima que a capacidade instalada de sistemas fotovoltaicos deverá passar dos atuais 24 GW para 34 GW em 2023, conforme a Associação Brasileira de Energia Solar Fotovoltaica - ABSOLAR (2022).

Em virtude desse novo horizonte, faz-se necessário encontrar técnicas mais aprimoradas para contornar as características estocásticas da energia gerada por fonte solar, principalmente ocasionadas pela movimentação de nuvens, as quais reduzem ou bloqueiam a incidência de raios solares nos sistemas fotovoltaicos, inserindo incertezas na entrega de energia elétrica.

Tal intermitência, intrínseca à geração de energia solar, constitui um obstáculo a ser suplantado para enfim possibilitar a operação eficiente, confiável e segura dos sistemas de

energia elétrica, de tal forma que a utilização de métodos com maior precisão para previsão de geração de energia fotovoltaica é essencial (BRACALE; CARPINELLI; FALCO, 2017).

Conhecer a quantidade de energia elétrica gerada por sistemas fotovoltaicos em horizontes de curto, médio ou longo prazo, de maneira mais precisa possível, garante o funcionamento eficiente do gerenciamento de despacho de energia, minimizando custos com armazenamento, além de melhor operar sistemas distribuídos, microrredes, casas inteligentes ou redes elétricas inteligentes, bem como para possibilitar melhor controle e planejamento pelos usuários finais e pelos operadores do sistema (AGOUA; GIRARD; KARINIOTAKIS, 2018).

Cunha (2021, p. 19) destaca a importância da previsão da geração de energia fotovoltaica da seguinte maneira:

A produção e a demanda de energia devem ter o equilíbrio necessário para permitir que o sistema elétrico seja estável. Contudo, ao adicionar fontes de energia que possuem variação na geração ao longo das horas e dos dias, é vital ter uma maneira eficiente de prever a geração nas próximas horas e/ou no próximo dia. Sendo assim, ao tentar se obter uma boa previsão de energia a ser gerada, é necessário buscar a minimização da diferença existente entre o valor previsto e o valor real medido.

Os métodos mais difundidos na literatura para a realização de previsão de geração de energia fotovoltaica são os modelos físicos e os estatísticos (MEER *et al.*, 2018), onde o primeiro utiliza as características físicas do sistema fotovoltaico e aspectos meteorológicos, e o segundo considera o histórico de dados, extraindo conhecimentos passados para prever uma série temporal.

Dentro da área de aprendizado de máquina, as Redes Neurais Artificiais (RNA) são técnicas que vêm sendo bastante utilizadas na área de previsão de geração de energia fotovoltaica, tendo se mostrado eficientes e com resultados promissores. O sucesso do uso das RNAs na área de previsão se deve principalmente a capacidade que elas apresentam de aprender funções não lineares e a capacidade de generalização (ANTONANZAS *et al.*, 2016).

Dentre os tipos de RNAs utilizadas para previsão, a mais empregada na literatura, segundo Antonanzas *et al.* (2016) é a Rede *Perceptron* Multicamadas (*Multilayer Perceptron – MLP*), a exemplo dos modelos propostos por Chow *et al.* (2012), Monteiro *et al.* (2013) e Wang *et al.* (2016). Alguns autores também vêm utilizando, com resultados promissores, as Redes Neurais Convolucionais 1D para o processo de previsão, como nos trabalhos de Agga, *et al.* (2021), Suresh *et al.* (2020) e Lim *et al.* (2022). Além dessas técnicas, encontra-se na literatura a utilização da arquitetura *Long Short Term Memory* (LSTM) isoladamente e em combinação

com outras técnicas, como proposto por Qing e Niu (2018), Hossain e Mahmood (2020) e Tovar, Robles e Rashid (2020).

1.2 Objetivo Geral

Este trabalho busca apresentar a viabilidade da previsão de geração de energia fotovoltaica através de Redes Neurais Convolucionais (CNN) bidimensionais e técnicas de transformação de séries temporais em formato de imagens, como Campo Angular Gramiano (*Gramian Angular Field* – GAF) e Gráfico de Recorrência (*Recurrence Plot* – RP).

1.3 Objetivos Específicos

Considerando o objetivo geral, este trabalho tem como objetivos específicos:

- Criar modelos de previsão utilizando redes neurais convolucionais, visando prever a energia fotovoltaica a ser gerada no dia seguinte, com base nos dados de um sistema fotovoltaico instalado no CEAMAZON-UFPA;
- Transformar as séries temporais da energia fotovoltaica gerada em imagens, visando explorar todo o potencial de processamento de imagens e extração de características das redes neurais convolucionais, utilizando as imagens criadas como entradas deste tipo de rede;
- Comparar os resultados alcançados pelas propostas elaboradas neste trabalho com dois tipos de redes que vêm sendo utilizadas na literatura para o problema de previsão de geração de energia fotovoltaica, sendo elas uma rede CNN 1D (que utilizou a série temporal direta, sem transformação para imagem) e uma rede MLP.

1.4 Estrutura da Dissertação

O presente trabalho se encontra estruturado em 5 capítulos, incluindo o presente, introdutório.

O capítulo 2 discorre sobre a fundamentação teórica, com revisão bibliográfica da literatura especializada, contendo os principais conceitos, ferramentas e técnicas a serem

abordados ao longo do trabalho, além de apresentar o estado da arte da previsão de geração de energia fotovoltaica e da transformação de séries temporais em imagens.

O capítulo 3 detalha a metodologia proposta para a previsão de geração de energia fotovoltaica, utilizando redes neurais convolucionais e transformação de séries temporais em imagens, detalhando os procedimentos para preparação dos dados, configurações das redes e dos parâmetros de treinamento das redes neurais.

Já o capítulo 4 demonstra os resultados obtidos após o treinamento, validação e teste das redes propostas, além de realizar a comparação dos erros obtidos em cada rede com os erros apresentados pelas técnicas de referência.

Finalmente, o capítulo 5 apresenta as conclusões obtidas a partir dos resultados coletados das redes treinadas e as contribuições do trabalho, bem como perspectivas de melhorias em trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Introdução

Neste capítulo são apresentados os fundamentos teóricos que embasam os tópicos envolvidos no presente trabalho, destacando a energia solar e as técnicas utilizadas para previsão de geração de energia fotovoltaica, incluindo uma revisão sobre redes neurais artificiais, explanação sobre técnicas de transformação de séries temporais em imagens e apresentação do estado da arte para previsão de geração de energia fotovoltaica.

2.2 Energia Solar

A energia irradiada pelo Sol tem fundamental importância na vida terrestre, haja vista que o seu provimento possibilita a ocorrência dos processos naturais no planeta, tanto em sua superfície quanto na atmosfera.

A cada hora, a superfície da Terra recebe energia solar, proveniente da luz e calor do Sol, da ordem de 100.000 TW, o que é suficiente para suprir o consumo energético do mundo por cerca de um ano, de acordo com Schiermeier et al. (2008). O Sol, portanto, é uma poderosa fonte de energia, o que é reforçado pelo fato de que, em dias com céu limpo, emite irradiação à superfície terrestre de cerca de 1.000 W/m² (SMESTAD, 2002).

Tal energia é aproveitada majoritariamente de duas formas: conversão termal e conversão fotovoltaica. Enquanto na primeira a energia solar é convertida na forma de calor, tanto para utilização final quanto para aproveitamento para geração de energia térmica, a qual posteriormente pode resultar na realização de trabalho, na conversão fotovoltaica a energia solar é transformada em energia elétrica através da excitação de elétrons em células solares compostas por materiais semicondutores (SMESTAD, 2002). Diferentemente da conversão térmica, na conversão fotovoltaica a geração de calor é um fator indesejado, indicativo de perda energética.

2.3 Geração Fotovoltaica

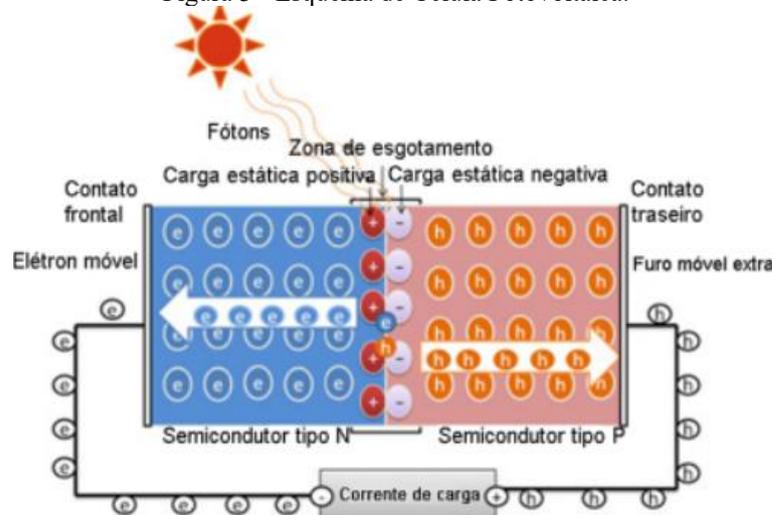
A transformação direta da energia irradiada pelo Sol em energia elétrica, também conhecida como efeito fotovoltaico, é um fenômeno físico que ocorre quando a radiação eletromagnética emitida pelo Sol incide em materiais semicondutores, fornecendo energia aos

elétrons livres do material de tal maneira que estes conseguem romper as barreiras dielétricas intrínsecas ao receptor e, assim, fazer fluir corrente elétrica (VILLALVA, 2012).

Uma célula fotovoltaica típica usa junções de camadas de um material semicondutor, sendo uma camada do tipo N, com excedentes de elétrons, e uma camada tipo P, deficitária em elétrons. As duas camadas são separadas entre si pela zona de esgotamento, ou *gap*. Quando as duas camadas são dispostas em uma junção, os elétrons tendem a migrar para a borda da banda N e as lacunas, espaços anteriormente ocupados por elétrons, para a borda da banda P, criando assim um campo elétrico no interior da célula e, conseqüentemente, uma barreira de potencial entre as duas camadas, a qual perdura enquanto os elétrons não possuírem energia suficiente para saírem da camada tipo N, romperem a zona de esgotamento e migrarem para a camada tipo P (EISBERG; RESNICK, 1994).

A exposição da célula fotovoltaica à luz solar possibilita que a energia da radiação solar (fóton) seja absorvida pelo material semicondutor, transmitindo sua energia aos elétrons da banda de valência, para que tais elétrons superem a banda proibida, e, em caso da existência de contatos externos interligando as camadas P e N, ocorra o fluxo de elétrons e condução de corrente elétrica, conforme ilustrado na figura 3.

Figura 3 - Esquema de Célula Fotovoltaica.



Fonte: Ministério da Defesa (2023).

A grande maioria das células fotovoltaicas produzidas na atualidade é composta de silício, em virtude de sua abundância na natureza e da compatibilidade da energia necessária para a movimentação dos elétrons com a energia emitida pela radiação solar.

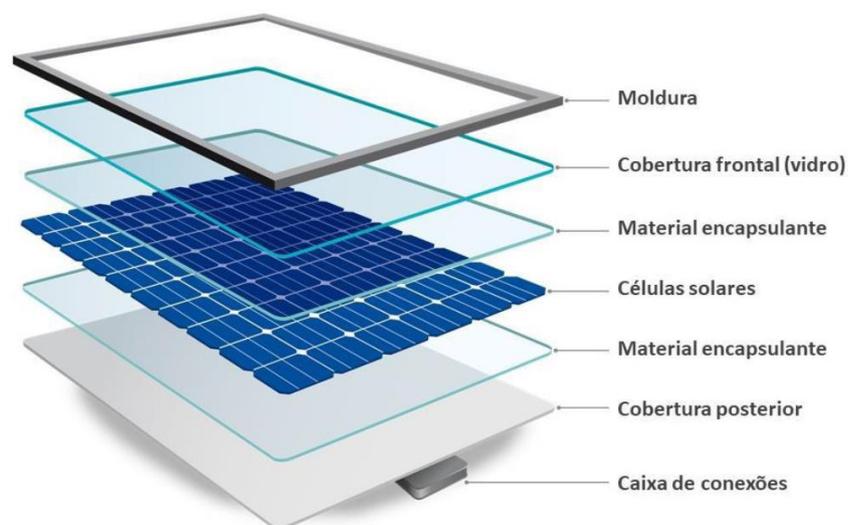
Os átomos de silício possuem quatro elétrons em sua camada de valência, os quais formam ligações covalentes com outros átomos de silício próximos. Para conferir

características especiais de condutividade, possibilitando assim a ocorrência do efeito fotovoltaico, é feita adição de outros elementos ao silício, processo este chamado de dopagem. A banda de valência é criada com a adição de átomos de boro, enquanto a banda de condução é criada com a adição de átomos de fósforo (GREEN, 1982).

Ainda segundo Green (1982), no silício, a banda proibida apresenta 1,1 eV, o que corresponde a um limiar de 1.100 nm de tamanho de onda. Qualquer onda eletromagnética com comprimento menor do que 1.100 nm consegue ser absorvida pela estrutura atômica do silício, transmitindo a energia necessária para a mobilidade dos elétrons e, conseqüentemente, produzindo corrente elétrica.

Os módulos fotovoltaicos padrão são compostos por diversas células fotovoltaicas conectadas em série de modo a possibilitar uma tensão maior da energia a ser gerada. Os demais componentes do módulo servem para sustentação mecânica, proteção e resistência, como a cobertura frontal de vidro temperado, combinada com manta encapsulante, normalmente de EVA ou silicone, envoltos por moldura metálica, encoberta posteriormente por material isolante e anti-umidade, usualmente teflon, conforme exemplificado na figura 4. Os terminais positivo e negativo proveniente das séries de células fotovoltaicas são disponibilizados em uma saída do módulo para possibilitar as conexões elétricas externas.

Figura 4 - Modelo de Módulo Fotovoltaico.



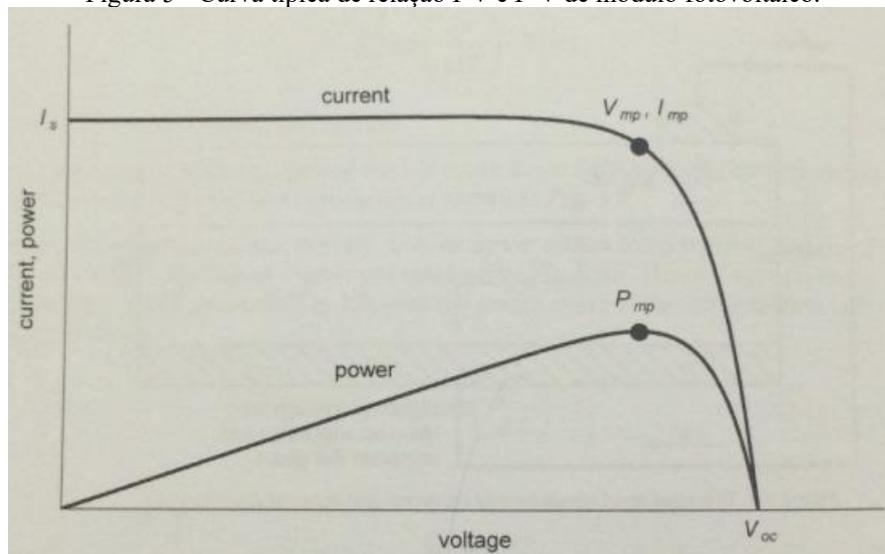
Fonte: Adaptado de Sunbank (2021).

Um módulo fotovoltaico não se comporta como uma fonte de geração de energia elétrica convencional, haja vista que a tensão de saída em seus terminais depende da corrente elétrica que o circula, e vice-versa. Segundo Villalva (2012), os valores de tensão e corrente dependem

da carga conectada aos terminais do módulo, sendo tal relação demonstrada pela curva I-V característica do módulo. A figura 5 demonstra as curvas característica I-V, que relaciona a corrente e a tensão em um módulo fotovoltaico, e P-V, que relaciona a potência e a tensão.

Quando o módulo está em curto-circuito, a corrente percorrida é máxima, enquanto a tensão é nula, e quando os terminais externos do módulo estão sem carga, a tensão está em seu máximo e a corrente é nula, sendo que em ambos os casos a potência do módulo também será nula (KALOGIROU, 2016). A potência máxima entregue pelo módulo fotovoltaico está destacada na figura 5 através da marcação de pontos.

Figura 5 - Curva típica de relação I-V e P-V de módulo fotovoltaico.



Fonte: Wenham et al. (2009).

Muito embora haja abundância no recurso primário para geração de energia elétrica através do efeito fotovoltaico, os módulos existentes e comercializados atualmente ainda encontram limitações em termos de eficiência, onde os módulos fabricados com silício cristalino alcançam eficiência da ordem de 26,7%, com variação percentual de 0,5% (MARTIN et al., 2016). Outro ponto relativo aos módulos fotovoltaicos que requer atenção é a forte correlação da irradiação solar com a geração de energia fotovoltaica, sendo que a irradiação solar recebida na superfície do módulo fotovoltaico varia em decorrência da presença e movimentação de nuvens, além da ocorrência de chuvas (CUI et al., 2019).

A estimativa de geração fotovoltaica é um problema em aberto e de grande importância, sendo bem mais complexa do que a previsão de carga, por exemplo. O erro de previsão de carga é muito baixo (1 a 3%), contudo, considerando a previsão de geração de energia fotovoltaica ou eólica, os erros geralmente são bem mais altos (ZHANG et al., 2015).

Enquanto a carga é bastante previsível devido ao comportamento humano/industrial, a geração solar fotovoltaica é bem menos previsível, por haver flutuações meteorológicas e a mudança de dias ensolarados, para nublados ou chuvosos, interrompendo os padrões de continuidade e produção, alterando a média diária e gerando significativas variações nas séries temporais de produção (ZHANG et al., 2015).

2.4 Previsão de Geração de Energia Fotovoltaica

Conhecer a quantidade de energia elétrica gerada por sistemas fotovoltaicos em horizontes de curto, médio ou longo prazo, de maneira mais precisa possível, garante o funcionamento eficiente do gerenciamento de despacho de energia, minimizando custos com armazenamento, além de melhor operar sistemas distribuídos, microrredes, casas inteligentes ou redes elétricas inteligentes, bem como para possibilitar melhor controle e planejamento pelos usuários finais e pelos operadores do sistema (AGOUA; GIRARD; KARINIOTAKIS, 2018).

As características estocásticas da energia elétrica gerada a partir de fonte solar, principalmente ocasionadas pela movimentação de nuvens, as quais reduzem ou bloqueiam a incidência de raios solares nos sistemas fotovoltaicos, inserem incertezas na entrega de energia elétrica, tornando a etapa de planejamento energético da energia entregue por sistemas fotovoltaicos mais desafiadora.

Para contornar tal limitação e permitir a realização da previsão de geração de energia fotovoltaica com maior precisão, são utilizados modelos apropriados, os quais, segundo Alkhayat e Mehmood (2021), podem ser classificados em: modelos físicos, modelos estatísticos, técnicas de inteligência artificial e os modelos híbridos.

Os modelos físicos, também conhecidos como Modelos de Previsão Numérica (*Numerical Weather Prediction* - NWP), são modelos matemáticos que simulam as dinâmicas meteorológicas com base nos princípios físicos e mecânicos do clima e são utilizados predominantemente para previsões de longo prazo.

Já os modelos estatísticos são utilizados para descobrir a relação matemática entre as entradas e saídas, considerando relações lineares entre estas e aquelas. A principal desvantagem destes modelos são a dificuldade em lidar com não-linearidades.

Métodos de inteligência artificial, como os modelos de Aprendizado Profundo (*Deep Learning* - DL), conseguem superar a deficiência dos modelos estatísticos por terem a possibilidade de trabalhar com não-linearidades nas relações entre as entradas e saídas, além de

apresentarem boa performance. Outros pontos de destaque são a capacidade de generalização e a detecção de padrões ocultos em dados.

Consequentemente, os modelos híbridos utilizam a junção dos demais modelos, de modo a obter melhoria nos resultados de previsão com o uso das maiores vantagens de cada abordagem.

Considerando que a energia elétrica gerada em sistemas fotovoltaicos é diretamente proporcional à irradiação solar disponibilizada ao dado sistema, no que diz respeito a previsão de geração de energia fotovoltaica, existem dois métodos de abordagem largamente utilizados, segundo Antonanzas *et al.* (2016): previsão direta e previsão indireta.

As estimativas indiretas primeiramente realizam a previsão da irradiação solar, para então utilizar estes dados em modelo de performance do sistema fotovoltaico de modo a obter a energia prevista a ser gerada em um dado horizonte de tempo. Já a previsão direta calcula a energia elétrica a ser gerada pelo sistema fotovoltaico de maneira final.

2.5 Horizonte de Previsão

A previsão de geração de energia fotovoltaica também pode ser abordada de acordo com o horizonte em que se almeja estimar a quantidade de energia que estará disponível, ou seja, a pela quantidade de tempo existente entre o momento real e o tempo efetivo de previsão, e tal escolha é determinada pelos propósitos intencionados com a previsão.

Ahmed, Sreeram, Mishra e Arif (2020) classificam os horizontes de previsão de geração de energia de sistemas fotovoltaicos em três categorias: intra-hora, intra-dia e dia à frente.

Previsões intra-hora são de curtíssimo prazo, envolvendo horizonte de alguns segundos até uma hora a frente (Zhang, et al.; 2018), sendo utilizada, por exemplo, para garantia de continuidade de potência em redes elétricas inteligentes e para gerenciamento da taxa de variação de potência gerada por sistemas fotovoltaicos, visando garantir a estabilidade da rede elétrica.

As previsões intra-dia envolvem horizontes de 1 a 6 horas a frente e são aplicadas no controle de zonas específicas de cargas elétricas e no manejo de energia elétrica fora da rede elétrica padrão.

Quando a previsão é realizada entre 6 e 48 horas a frente, esta estimativa é chamada de previsão de dia à frente, comumente utilizada para planejamento energético, programação de operação e despacho energético, além de segurança operacional no mercado e na comercialização de energia elétrica.

2.6 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são métodos de aprendizagem de máquina que modelam a maneira de funcionamento do cérebro humano em determinadas tarefas ou funções.

Haykin (2009, p. 2) define uma RNA como sendo:

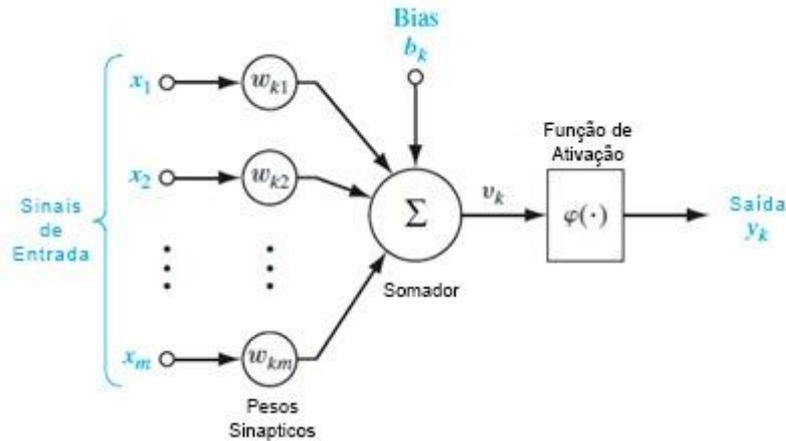
[...] um processador massivo de distribuição paralela criado a partir de unidades simples de processamento que possuem propensão natural ao armazenamento de conhecimento experimental, com grandes semelhanças ao funcionamento do cérebro humano [...].

Dada sua inspiração no funcionamento das redes neurais biológicas, as unidades primárias das redes neurais artificiais são conhecidas como neurônios artificiais, sendo que Haykin (2009) define um neurônio artificial como sendo uma unidade de processamento de informações, tendo como características básicas a adaptação e a representação de conhecimentos baseada em conexões.

O modelo mais simples de neurônio artificial foi proposto pelos pesquisadores McCulloch e Pitts (1943), o qual é capaz de separar duas entradas *booleanas*, contudo o seu treinamento é inviabilizado pela ausência de parâmetros livres, haja vista que os autores não desenvolveram um método para adaptar os pesos dos neurônios em um processo de treinamento ou aprendizagem.

Uma contribuição importante foi apresentada por Rosenblatt (1948), o qual propôs um neurônio artificial não linear, com base nas formulações matemáticas elaboradas por McCulloch e Pitts, chamado de *Perceptron*, sendo composto por: um conjunto de sinapses, ou elos de ligação, as quais são caracterizadas por um peso próprio, sendo estes multiplicados pelos sinais nas entradas das sinapses; um somador, que realiza a adição do produto dos sinais de entrada pelos seus respectivos pesos, tal operação conhecida como combinação linear; e uma função de ativação, responsável pela limitação da amplitude da saída do neurônio. Estas características estão evidenciadas na figura 6.

Apesar dos avanços alcançados pelo modelo *Perceptron*, ainda existiam algumas limitações a serem superadas, como a impossibilidade de resolver os operadores lógicos importantes “ou exclusivo” e “não ou exclusivo”, denotando que a utilização de um único neurônio *Perceptron* é incapaz de lidar com não-linearidades (BORCHARDT, 1988).

Figura 6 - Modelo de neurônio tipo *Perceptron*.

Fonte: Adaptado de Haykin (2009).

2.6.1 Rede *Perceptron* Multicamadas

Uma rede *Perceptron* Multicamadas (*Multilayer Perceptron* - MLP) é caracterizada pela presença de múltiplas camadas de neurônios do tipo *Perceptron*, resultando em uma rede com grande poder de generalização, possibilitando a aplicação em diversas áreas, inclusive podendo lidar com não-linearidades, superando as limitações do modelo *Perceptron* (GUYON, 1991).

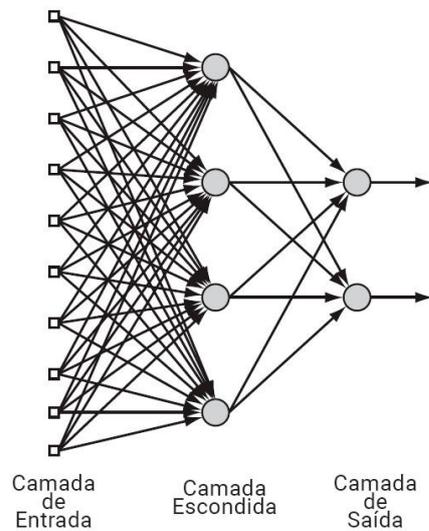
A composição de uma rede MLP inclui, minimamente, uma camada de entrada, uma camada de saída e camadas intermediárias, também denominadas camadas escondidas, sendo que cada camada pode conter diversos neurônios do tipo *Perceptron* e cada saída de neurônio é a entrada da camada subsequente. Nesta arquitetura, o fluxo de informações se inicia na camada de entrada, a qual envia estímulos à camada intermediária imediatamente posterior, propagando este sinal adiante até sensibilizar os neurônios na camada de saída (DA SILVA; SPATTI; FLAUZINO, 2010).

As MLPs possuem treinamento supervisionado, sendo que o algoritmo de treinamento visa ajustar os pesos da rede para, a partir de um conjunto conhecido de valores de entrada e suas respectivas saídas, obter o valor de saída desejado. A figura 7 apresenta um modelo de rede MLP.

2.6.2 Algoritmos de Treinamento

A habilidade de aprendizado e generalização das informações de uma rede neural artificial é um dos seus destaques mais relevantes, sendo possível solucionar problemas complexos e muitas vezes intratáveis.

Figura 7 - Modelo de RNA tipo Perceptron Multicamadas.



Fonte: Adaptado de Haykin (2009).

O processo de treinamento consiste na aplicação das etapas ordenadas necessárias para que ocorra a sintonização dos pesos sinápticos e limiares de seus neurônios, visando a produção da generalização de soluções pelas suas saídas, possibilitando a produção de uma saída adequada, culminando na solução do problema. O objetivo do treinamento, ou aprendizagem, é tornar a aplicação de um conjunto de entrada em um conjunto de saídas desejadas. O conjunto ordenado das etapas visando o treinamento da rede é denominado de algoritmo de treinamento (BISHOP, 2006). Dentre os algoritmos de treinamento mais utilizados está o *Backpropagation*.

O *Backpropagation* consiste em um método que busca minimizar a função erro médio quadrático da rede neural por meio do gradiente descendente da referida função. Este algoritmo possui duas fases de fluxo de dados (uma adiante e uma reversa), através das quais é possível computar o gradiente da função erro da rede em relação a cada peso sináptico, ou seja, o algoritmo consegue calcular como cada peso deve ser ajustado (aumentado ou diminuído) de modo a reduzir o erro da resposta da rede (RUMELHART; HINTON; WILLIAMS, 1985).

Na fase adiante, os sinais são propagados da entrada à saída, passando por todas as camadas da rede, levando em consideração os pesos sinápticos e limiares preestabelecidos para todos os neurônios, os quais permanecem inalterados durante toda a fase. Ao chegar na saída, o sinal obtido é comparado com a resposta desejada, obtendo-se assim o erro. Na fase reversa, o algoritmo calcula a contribuição de cada conexão em todas as camadas para o erro na saída da rede, realizando o ajuste dos valores de cada peso, de maneira a tornar a saída da rede mais próxima do resultado esperado (DA SILVA; SPATTI; FLAUZINO, 2010).

As fases adiante e reversa são aplicadas a todos os conjuntos de dados de entrada e de saída, de maneira que cada vez que todo o conjunto de treinamento é apresentado à rede e passa

pelo algoritmo de treinamento é chamado época. O algoritmo é repetido por diversas épocas, até que o erro alcance um patamar mínimo preestabelecido, ou o número máximo de épocas determinadas seja alcançado, ou ainda que algum critério de parada antecipada seja acionado (GÉRON, 2019).

Entretanto, em casos onde a quantidade de dados para treinamento de uma rede neural é grande, a convergência do algoritmo de treinamento pode ser demorada e computacionalmente custosa. Sendo assim, Kingma e Ba (2015) propuseram um método de otimização na busca pelo gradiente descendente da função erro chamado Estimativa Adaptativa do Momento (*Adaptive Moment Estimation* - ADAM), onde o ajuste dos parâmetros da rede são calculados individualmente, baseados numa taxa de aprendizado proporcional à média dos gradientes das iterações anteriores e da média do quadrado dos gradientes anteriores. Assim, Kingma e Ba (2015, p. 1) classificam o método ADAM como “[...] computacionalmente eficiente, com baixa requisição de memória, invariante a reescalonamento diagonal dos gradientes e bem ajustado a problemas que possuem muitos dados ou parâmetros”.

2.6.3 Aprendizado Profundo

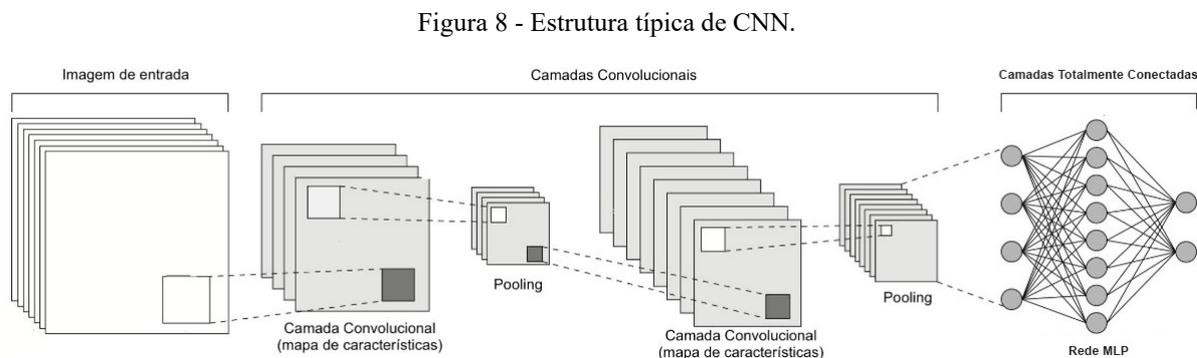
O Aprendizado Profundo é baseado em uma RNA com grande número de camadas escondidas em sua arquitetura, sendo entendido como um aprendizado que é feito com base em diversas camadas de representações sucessivas (CHOLLET *et al.*, 2018). O termo “profundo”, neste contexto, denota a quantidade de camadas intermediárias que compõem a rede, onde usualmente as RNA tradicionais contam com poucas camadas escondidas, enquanto as redes profundas podem ter centenas delas (LECUN *et al.*, 2015). Desta forma, o DL se destaca pela possibilidade de executar tarefas mais complexas, como reconhecimento de textos, imagens e vídeos, processamento de áudio e reconhecimento de fala, através de extração de características dos dados apresentados à rede em diferentes níveis de abstração.

O principal obstáculo para a implementação do algoritmo *Backpropagation* em redes com grande número de camadas é o desaparecimento ou explosão do gradiente, isto é, o valor do gradiente sendo retro propagado causando uma diminuição de seus valores e reduzindo drasticamente a taxa de atualização dos pesos sinápticos, ou até mesmo fazendo com que os valores dos pesos não sejam alterados, impedindo o processo de aprendizagem da rede, problema este conhecido como problema de desaparecimento de gradiente (MAAS; HANNUN; NG, 2013).

Uma forma para resolver o problema de desaparecimento de gradiente, proposta por Glorot e Bengio (2010), é a inicialização aleatória dos pesos sinápticos da rede baseada em uma distribuição uniforme, tendo como parâmetro o tamanho de cada camada.

2.6.4 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNN) são redes de aprendizado profundo que usam o método matemático da convolução em pelo menos uma de suas camadas e são especializadas em processar dados formatados em topologia espacial, tais como imagens (GOODFELLOW; BENGIO; COURVILLE, 2016), sendo uma arquitetura originalmente proposta por LeCun, Hafner, Bottou e Bengio (1999), inspirada no funcionamento do córtex cerebral visual primário, que é responsável pelo processamento dos impulsos visuais. Uma estrutura típica de CNN, além de englobar camadas de MLP, também conhecidas como camadas totalmente conectadas, utiliza camadas de convolução e de *pooling*, conforme exemplificado na figura 8.



Fonte: Adaptado de Baldominos, Saez e Isasi (2017).

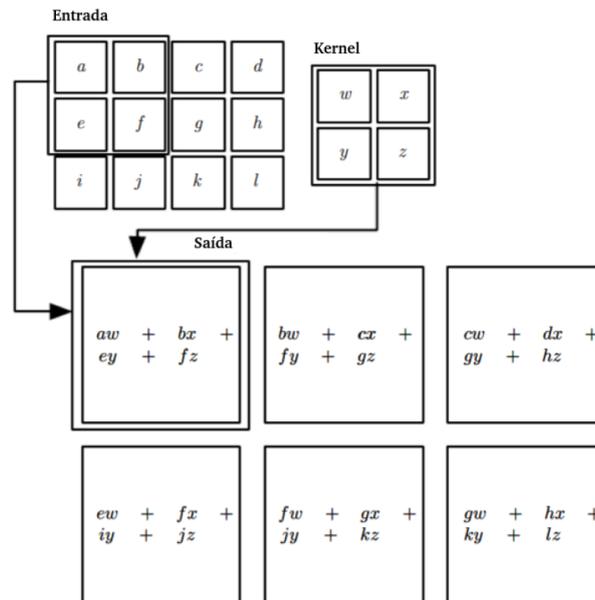
2.6.4.1 Camadas Convolucionais

As camadas convolucionais representam parte crucial em uma CNN, sendo responsáveis pela extração de características dos dados apresentados à entrada da rede, aprendendo, portanto, informações relevantes dos dados de entrada.

Os neurônios nestas camadas funcionam como filtros aplicados ao dado de entrada, sendo que tais filtros são matrizes de pesos que percorrem a informação apresentada à entrada da rede, realizando operação de convolução, gerando como resultado mapas de características (ARAUJO, 2021). Este processo está demonstrado na figura 9.

Após o cômputo dos mapas de características, usualmente é realizada a aplicação de uma função de ativação não-linear em cada elemento dos mapas, para que o resultado dessa transformação sirva de entrada à próxima camada na sequência da rede (BALDOMINOS; SAEZ; ISASI, 2017).

Figura 9 - Exemplificação de operação de convolução.



Fonte: Adaptado de Goodfellow et al. (2016).

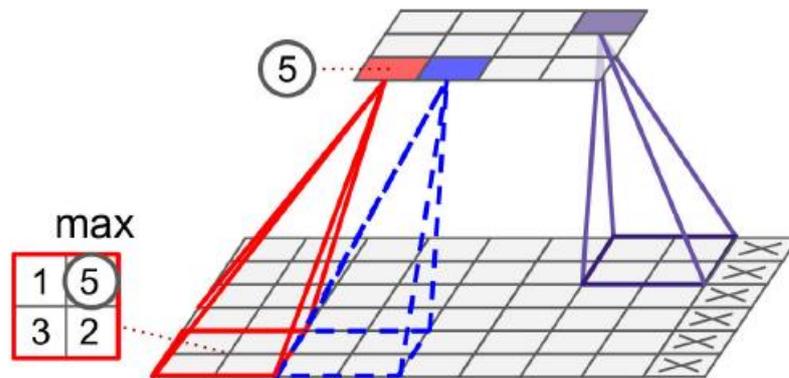
2.6.4.2 Camadas de *Pooling*

As camadas de *pooling* são opcionalmente utilizadas para reduzir as dimensões dos dados de entrada, de modo a diminuir o esforço computacional, o uso de memória e o número de parâmetros treináveis da rede, minimizando assim o tempo necessário para o treinamento da rede (GERON, 2019). Além disso, as camadas de *pooling* tornam a rede invariante a translações, ou seja, caso haja uma leve translação nos dados de entrada, grande parte da saída da camada de *pooling* permanecerá inalterada.

Assim como nas camadas convolucionais, cada neurônio na camada de *pooling* é conectado a um número limitado de neurônios da camada anterior, fazendo a união das entradas através de uma função estatística de agregação, como a *max-pooling*, onde a saída corresponde ao maior valor do campo receptivo de entrada do neurônio (ZHOU; CHELLAPA, 1988), conforme demonstrado na figura 10. O passo que o mapa da camada de *pooling* dá para percorrer o mapa de características proveniente da camada convolucional é também conhecido

por *stride* e influencia diretamente na redução da saída da camada de *pooling*, ou seja, quanto maior o valor do *stride*, menor será a saída resultante.

Figura 10 - Operação de max-pooling, com dimensão 2x2.



Fonte: Geron (2019).

2.6.4.3 Camadas *Flatten* e Totalmente Conectadas

Após a extração das características dos dados apresentados à rede, os mapas de características resultantes das camadas convolucionais, reduzidos ou não pelas camadas de *pooling*, podem então ser apresentados a camadas MLP, doravante denominadas Camadas Totalmente Conectadas. Para viabilizar a apresentação dos mapas de características às entradas da camada totalmente conectada, tais mapas devem ser redimensionados, passando de formato tabular para formato vetorial, tarefa esta realizada pela Camada *Flatten*, a qual não possui parâmetros.

Após tornar os dados provenientes das camadas convolucionais e de *pooling* em formato unidimensional, as camadas totalmente conectadas realizam a tarefa de classificação ou regressão, de acordo com a necessidade do problema proposto. Os parâmetros das camadas totalmente conectadas, como número de camadas escondidas, número de neurônios por camada escondida ou funções de ativação utilizadas, dentre outros, são dependentes da tarefa a ser desempenhada pela rede (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.6.4.4 Dropout

Um dos pontos de atenção ao se treinar redes profundas, conforme destaca Haykin (2009, p. 314) é que “a informação contida em um conjunto de treinamento não é suficiente para reconstruir o mapeamento de entrada-saída de maneira singular – gerando assim a possibilidade de sobreajuste (*overfitting*) de *machine learning*”. Para contornar este problema, são utilizados métodos de regularização, com o objetivo de reduzir o erro de generalização da rede, sem reduzir o seu erro de treinamento.

Neste contexto, o método *Dropout* consiste na remoção temporária e aleatória de alguns neurônios das camadas escondidas durante cada etapa de treinamento, ou seja, a cada época do treinamento, cada neurônio possui a probabilidade p de ser temporariamente ignorado durante aquela época, podendo ser reativado na época seguinte, onde o parâmetro p é a taxa de *dropout* (SRIVASTAVA et al., 2014).

2.6.4.5 Normalização de Lotes

Em vista da dificuldade de treinamento de redes neurais profundas, ocasionada pelo fato de que a distribuição das entradas de cada camada varia durante o treinamento por conta da variação dos parâmetros das camadas anteriores, o que reduz a velocidade de treinamento da rede, Ioffe e Szegedy (2015) propuseram um método onde os dados a serem utilizados para treinamento são divididos em subconjuntos, ou mini lotes, e realizar a normalização dos mini lotes (*batch normalization*).

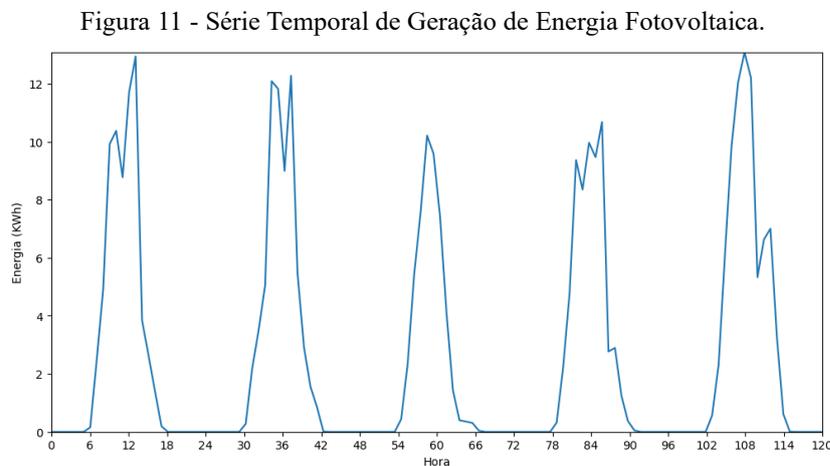
Através da normalização dos mini lotes, a distribuição dos dados que entram em cada camada é alterada durante o treinamento e esta reparametrização redundante na redução de problemas com a coordenação das atualizações dos parâmetros das diversas camadas que compõem a rede neural profunda.

2.7 Técnicas de Transformação de Séries Temporais em Imagens

Uma série temporal é, segundo Montgomery, Jennings e KulaHCI (2008, p. 2), “uma sequência cronológica, ou com orientação temporal, de observações de uma determinada variável de interesse”. Uma característica importante das séries temporais é que as observações adjacentes apresentam dependência serial, isto é, dependência entre instantes de tempo. A energia gerada em sistemas fotovoltaicos, por exemplo, é considerada uma série temporal,

apresentando características cíclicas de repetições periódicas, principalmente em decorrência da atividade solar. A figura 11 apresenta um exemplo de série temporal de geração de energia fotovoltaica.

Nesse contexto, a análise de séries temporais é crucial para extração de informações dos padrões intrínsecos a esses dados, além de ser de grande aplicabilidade em problemas que envolvem previsões, por exemplo: os dados de uma variável aleatória z (consumo de energia) no instante t , com t variando de 1 até N (número total de observações), devem, de certa maneira, conter informações necessárias para que seja determinado o valor dessa variável no instante $t+1$ (BOX; JENKINS; REINSEL, 2008).



Fonte: Autor.

Técnicas para transformação de séries temporais em imagens vêm sendo utilizadas com o objetivo de tirar proveito do potencial das CNNs em lidar com imagens e extrair características destas, conforme explanado na seção 2.5.2. Dentre as técnicas mais utilizadas para transformação de séries temporais e imagens, destacam-se o Campo Angular Gramiano (*Gramian Angular Field* - GAF) e o Gráfico de Recorrência (*Recurrence Plot* - RP).

2.7.1 Campo Angular Gramiano

O Campo Angular Gramiano é uma técnica, proposta por Wang e Oates (2015), que visa transformar uma série temporal em imagem, sendo a série temporal representada em um sistema de coordenadas polares.

Considerando-se uma série temporal $X = \{x_1, x_2, \dots, x_n\}$ composta por n observações, onde n é um número real, X é normalizado de forma que todos os valores de suas observações estejam dentro do intervalo $[0, 1]$ ou $[-1, 1]$, utilizando-se, para tanto, as seguintes equações:

$$\tilde{x}_i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (1)$$

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (2)$$

Então, a série temporal normalizada \tilde{X} pode ser representada em coordenadas polares, através de:

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (3)$$

onde o arco cosseno do valor da observação é o ângulo da coordenada e o instante temporal da observação é o raio da coordenada, sendo que t_i representa o instante temporal da observação e N é uma constante utilizada para padronizar a variação do sistema de coordenada polar.

Esta codificação em coordenadas polares apresenta a vantagem de ser bijetora, ou seja, a série temporal produz uma representação em coordenadas polares única com transformação inversa de coordenadas polares para série temporal também de maneira única. Além disso, as coordenadas polares, ao contrário das coordenadas cartesianas, mantêm preservadas as relações temporais da série temporal.

Após a codificação da série temporal normalizada em coordenadas polares, é possível realizar a correlação temporal entre cada instante de observação através da diferenciação ou soma trigonométrica entre os instantes, resultando em dois gráficos distintos: o Campo Somatório Angular Gramiano (*Gramian Summation Angular Field* - GASF) e o Campo Diferencial Angular Gramiano (*Gramian Difference Angular Field* - GADF). O GASF e o GADF são definidos pelas seguintes equações:

$$GASF = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$

$$GASF = \tilde{X}^T \cdot \tilde{X} - \sqrt{I - \tilde{X}^2}^T \cdot \sqrt{I - \tilde{X}^2} \quad (5)$$

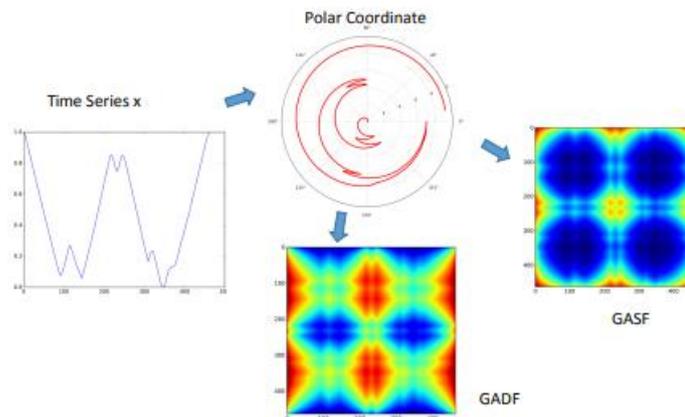
$$GADF = \begin{bmatrix} \text{sen}(\phi_1 + \phi_1) & \dots & \text{sen}(\phi_1 + \phi_n) \\ \text{sen}(\phi_2 + \phi_1) & \dots & \text{sen}(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \text{sen}(\phi_n + \phi_1) & \dots & \text{sen}(\phi_n + \phi_n) \end{bmatrix} \quad (6)$$

$$GADF = \sqrt{I - \tilde{X}^2}^T \cdot \tilde{X} - \tilde{X}^T \cdot \sqrt{I - \tilde{X}^2} \quad (7)$$

onde I é um vetor unitário $[1, 1, \dots, 1]$.

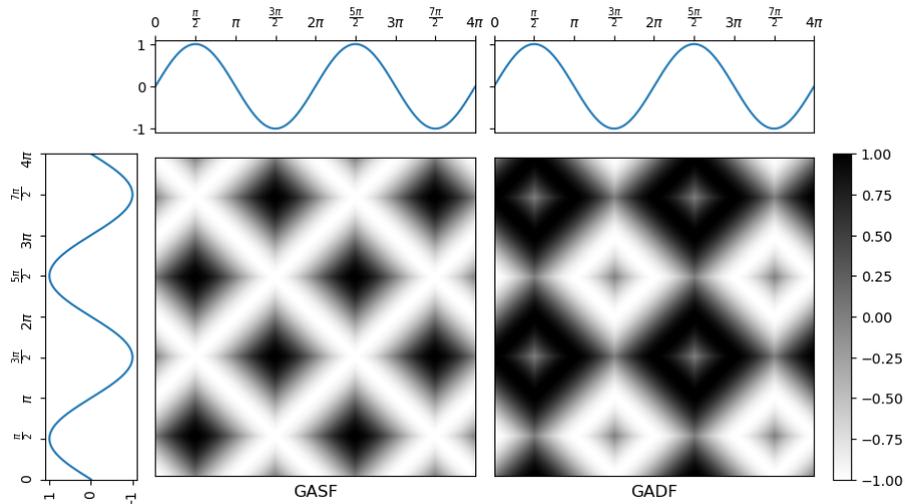
As matrizes das equações (4) e (6) contém correlações temporais entre cada observação da série temporal e demonstram a evolução do tempo à medida em que a posição da matriz avança do canto superior esquerdo até o canto inferior direito. As posições das matrizes são preenchidas com valores que variam no intervalo $[-1, 1]$, representando um mapa de calor. A figura 12 demonstra o processo de codificação de uma série temporal para coordenadas polares e posteriormente para GASF e GADF, enquanto a figura 13 apresenta um exemplo de transformação de uma série temporal utilizando GAF, onde a série considerada é uma função senoidal no intervalo $[0, 4\pi]$ e são demonstrados os dois gráficos resultantes, sendo que o gráfico à direita representa o GASF e o à esquerda representa o GADF.

Figura 12 - Demonstração do processo de Codificação de Campo Angular Gramiano.



Fonte: Adaptado de Wang e Oates (2015).

Figura 13 - Exemplificação de transformação em imagem GAF de uma série temporal senoidal.



Fonte: Autor.

2.7.2 Gráfico de Recorrência

Um sistema dinâmico, conforme Baker (1996), é um sistema que evolui a cada instante de acordo com um conjunto de regras fixas que determinam como um estado do sistema se altera para um outro. Já o espaço de fases de um sistema dinâmico é um espaço matemático formado a partir de coordenadas ortogonais representando cada uma das variáveis necessárias para especificar o estado instantâneo de um determinado sistema.

Uma série temporal, enquanto um sistema dinâmico, constitui-se de um conjunto de dados dos quais se conhecem apenas duas variáveis: aquela que define o fenômeno estudado e a variável associada ao tempo. Trata-se, portanto, da representação de um sistema dinâmico multidimensional cujos dados são relatados de forma unidimensional, por não se conhecerem as demais variáveis do sistema.

Assim, para recuperar as outras dimensões do espaço de fase do sistema que uma série temporal representa, Eckman, Kamphorst e Ruelle (1987) propuseram uma ferramenta denominada Gráfico de Recorrência (*Recurrence Plot - RP*), utilizada para visualização de comportamentos recorrentes no espaço de fase de sistemas dinâmicos. Neste contexto, a recorrência é definida por Poincaré (1890) como a característica de certos sistemas em retornar a um estado muito próximo ao estado inicial em um determinado período de tempo.

Considerando-se uma determinada série temporal S como um conjunto de N medidas escalares:

$$S = \{S_1, S_2, S_3, \dots, S_N\} \quad (8)$$

de onde se podem tomar vetores de estado, com dimensão d , construídos através de um procedimento conhecido como representação vetorial de atraso:

$$x_k = \{S_k, S_{k+\tau}, S_{k+2\tau}, \dots, S_{k+(d-1)\tau}\} \quad (9)$$

onde τ é o parâmetro de atraso.

Assim, um estado x_k é dito recorrente de outro se, durante a trajetória do sistema, este estiver próximo o bastante de um outro estado x_i no espaço de fases, respeitando um limiar ε , de onde se extrai a formulação matemática que define a matriz de recorrência R :

$$R_{i,j} = \Theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \vec{x}_{i,j} \in \mathfrak{R}, i, j = 1, \dots, N \quad (10)$$

onde $\|\cdot\|$ é a norma euclidiana e Θ é a função Degrau.

$$\Theta(z) = \begin{cases} 0, & \text{se } z < 0 \\ 1, & \text{caso contrário} \end{cases} \quad (11)$$

Sendo assim, este RP, conhecido como Gráfico de Recorrência com Limiar (*Thresholded Recurrence Plot* - TRP), é uma matriz binária, onde seus elementos com valores iguais a 1 representam graficamente um pequeno quadrado preto e os elementos iguais a 0 representam graficamente um pequeno quadrado branco.

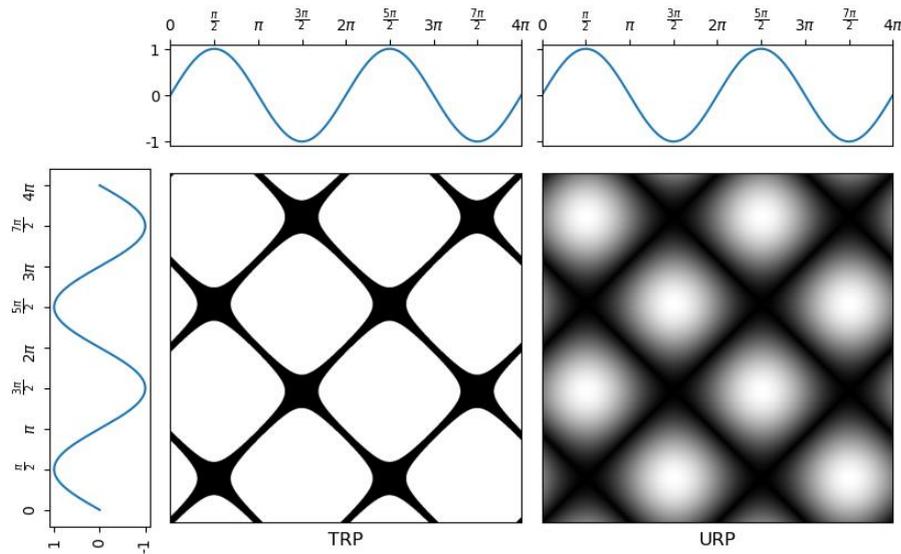
Neste caso, determinar o valor de ε é um fator de extrema importância na criação do TRP, sendo que, um valor muito pequeno de ε acaba por não extrair todas as características intrínsecas à série temporal analisada, enquanto um valor muito alto de ε induz à contabilização de pontos de recorrência não relevantes ao problema, criando um gráfico ilusório (HENRY et al., 2020).

Uma variação do RP foi então proposta por Iwanski e Bradley (1998), onde o limiar e a função degrau não foram consideradas, gerando, portanto, um Gráfico de Recorrência sem Limiar (*Unthresholded Recurrence Plot* - URP), com o propósito de extrair o máximo de características do sistema dinâmico em observação. Neste caso, os pontos do URP recebem coloração na escala de cinza, variando de acordo com a distância calculada entre os instantes observados da série temporal, sendo que pontos mais claros denotam maiores distâncias entre as observações, enquanto pontos mais escuros demonstram que as amostras estão mais próximas entre si.

$$URP_{i,j} = \|\vec{x}_i - \vec{x}_j\|, \vec{x}_{i,j} \in \mathfrak{R}, i, j = 1, \dots, N \quad (12)$$

A figura 14 demonstra a transformação em imagem de uma série temporal senoidal, no intervalo $[0, 4\pi]$, em gráficos de recorrência, sendo que o gráfico à esquerda da figura representa o TRP, com limiar igual a $\pi/18$, e o gráfico à direita representa o URP.

Figura 14 - Exemplificação de transformação em imagem RP de uma série temporal senoidal.



Fonte: Autor.

2.8 Estado da Arte

Modelos de previsão de geração de energia fotovoltaica estão entre as principais estratégias de apoio ao rápido crescimento da geração de energia solar fotovoltaica, mitigando as dificuldades de gerenciamento de sistemas conectados à rede. Alguns trabalhos aplicados em previsão de geração de energia fotovoltaica são apresentados a seguir.

Melit et al. (2010) utilizaram uma rede MLP para previsão da irradiação solar das 24 horas do dia seguinte, tendo como entrada a média diária de irradiação solar, a média diária da temperatura e o dia do mês. Os dados meteorológicos que compõem a base de dados utilizada pelos autores foram coletados na cidade italiana de Trieste, envolvendo os períodos de 01/07/2008 a 23/05/2009 e de 23/11/2009 a 24/01/2010. Os valores de irradiação preditos pelo modelo proposto pelos autores foram utilizados para calcular a energia a ser gerada por um sistema fotovoltaico instalado em um determinado prédio na cidade mencionada, para então ser calculado o RMSE normalizado de alguns dias selecionados pelos autores, erros estes que variaram entre 0,3298 e 0,7540.

O trabalho de Leva et al. (2015) apresenta um modelo de previsão de geração de energia de um sistema fotovoltaico instalado na Itália, utilizando MLP, com dados meteorológicos como entrada e a sendo a energia horária do dia seguinte a saída da rede proposta. Além disso, utilizou-se um índice de classificação de cobertura do céu, para avaliar a quantidade de nuvens no dia da medição, o que afeta diretamente a produção de energia elétrica do sistema fotovoltaico. A base de dados utilizada pelos autores consiste em informações meteorológicas e de energia gerada pelo sistema estudado correspondente a 8 meses consecutivos. Os autores apresentaram os RMSEs normalizados para dois dias aleatoriamente escolhidos, cujos valores foram 0,2400 e 0,3690.

Os dados meteorológicos e de energia gerada por um sistema fotovoltaico instalado em Beijing são utilizados por He et al. (2018) em um modelo de Memória Longa de Curto Prazo (*Long Short-Term Memory* - LSTM) para previsão da energia elétrica a ser gerada nas 24 horas seguintes. Os autores classificam os dados, que correspondem ao período de 06/11/2016 a 28/10/2017, de acordo com a estação do ano e com a cobertura do céu, e posteriormente comparam os resultados obtidos pelo modelo proposto com MLP e *Extreme Learning Machine* (ELM), sendo que todas as métricas de erro computadas para o modelo LSTM proposto foram menores que os erros obtidos com MLP e ELM, demonstrando boa performance do modelo.

A previsão da energia total a ser gerada no dia seguinte é proposta por Agga et al. (2021) através da utilização de CNN 1D tendo como entrada os dados de energia gerada por um sistema fotovoltaico de 15 KW, empilhados de forma a constituir uma entrada com diversos canais. O *dataset* utilizado pelos autores corresponde a um período de 2 anos, a saber, entre julho de 2019 e maio de 2021, onde o valor da energia total gerada pelo sistema foi armazenado diariamente. Os resultados obtidos com a proposta apresentada no trabalho foram comparados com as respostas recebidas por uma rede CNN 1D sem empilhamento em canais, demonstrando redução nos valores das métricas de erro.

Os autores Suresh et al. (2020) propuseram 3 modelos usando CNN 1D para previsão de geração de energia de um sistema fotovoltaico de 5 KW instalado na cidade de Wrocław. Foram utilizados, como dados de entrada, a irradiação solar, a velocidade do vento, a temperatura ambiente e a temperatura do módulo fotovoltaico e como saída a energia gerada pelo sistema fotovoltaico. Os dados utilizados no treinamento da rede foram tomados a cada 15 minutos e abrangem o período de 01/03/2012 a 31/12/2018. Os resultados obtidos pelo modelo proposto superaram, em termos de RMSE, 0,051, os resultados observados com os modelos Autorregressivo de Médias Móveis (*Autoregressive Moving Average* - ARMA) e Regressão Linear Múltipla (*Multiple Linear Regression* - MLR), respectivamente 0,192 e 0,258.

Tovar, Robles e Rashid (2020) propõem a utilização de um sistema híbrido CNN-LSTM, onde os dados meteorológicos coletados em uma cidade do México, onde está instalada uma usina fotovoltaica de 1,7 KW, foram utilizados para a entrada da rede, em formato unidimensional (CNN 1D), sendo que tanto a parte CNN do modelo, quanto a parte LSTM, tiveram 5 camadas cada. A saída do modelo foi a energia elétrica, sendo que os valores de RMSE obtidos pelo modelo foram comparados com o erro calculado em modelo exclusivamente formado por LSTM e em modelo híbrido CNN-LSTM com 2 camadas cada. O RMSE do modelo proposto pelos autores alcançou 0,0830, enquanto o modelo LSTM apresentou RMSE de 0,2924 e o CNN-LSTM com 2 camadas obteve RMSE de 0,2430.

Uma metodologia para previsão de geração de energia fotovoltaica de uma determinada região geográfica usando redes CNNs 2D foi abordada por Huang et al. (2022), que utilizaram a energia gerada por um sistema fotovoltaico, com potência de 5 KW, e resolução de informações de 15 minutos. Os dados de energia gerada da planta são agrupados somente do horário entre 07:00 e 19:00, onde há efetiva geração de energia, totalizando 48 pontos de energia por dia. Além disso, os dados foram divididos de acordo com as condições climáticas do dia, sendo separados em dia ensolarado, dia nublado, dia chuvoso e condições climáticas severas. A entrada da CNN foi o arranjo dos 48 pontos de energia em uma matriz 4x12. Os resultados obtidos pelos autores, em termos de RMSE, foram 0,056, 0,189, 0,360 e 0,478 respectivamente para os casos de dia ensolarado, dia nublado, dia chuvoso e condições climáticas severas.

Barra et al. (2020) propuseram a codificação da série temporal de um determinado índice do mercado de ações estadunidense em imagens através do uso de GADF, com posterior apresentação das imagens resultantes à uma rede CNN 2D, visando prever a tendência do mercado de ações para o dia seguinte, a saber: vender ou comprar a ação no dia seguinte. A base de dados utilizada foi referente ao período de 01/02/2009 a 31/07/2014, sendo que a imagem originada através do GADF possuiu tamanho 40×40×3. Os resultados alcançados pela metodologia proposta pelos autores foram comparados com técnicas específicas do mercado de ações (presunção aleatória e estratégia B&H) e com rede CNN 1D, sendo que, pelos valores de acurácia, uma das métricas de avaliação de resultados adotada pelos autores, a rede proposta conseguiu resultados mais próximos da realidade.

No estudo de Ahmad et al. (2021), foi proposta a classificação de batimentos cardíacos em eletrocardiogramas através da transformação da série temporal dos sinais de eletrocardiogramas em imagens, com o uso de GAF, RP e de Campos de Transição de Markov (*Markov Transition Field* – MTF), visando auxiliar no diagnóstico de doenças cardíacas. Em uma das abordagens para o problema, foram geradas três imagens, uma para cada técnica de

transformação de séries temporais em imagem, as quais foram fundidas em uma única imagem a ser apresentada a uma rede CNN 2D de classificação comumente utilizada em problemas similares, conhecida como AlexNet. Os resultados obtidos pelo modelo proposto no trabalho foram comparados com os resultados alcançados por abordagens diferentes propostas por outros autores, sendo que a fusão das imagens alcançou melhores resultados em acurácia.

2.9 Conclusão

Este capítulo apresentou uma revisão sobre os princípios de energia solar e geração de energia fotovoltaica, métodos e horizontes de previsão de geração de energia fotovoltaica, redes neurais artificiais e redes convolucionais, além de discorrer sobre técnicas de transformação de séries temporais em imagens, como Campo Angular Gramiano e Gráfico de Recorrência.

O capítulo seguinte detalha a metodologia proposta para a previsão de geração de energia fotovoltaica para o dia seguinte do sistema instalado no CEAMAZON.

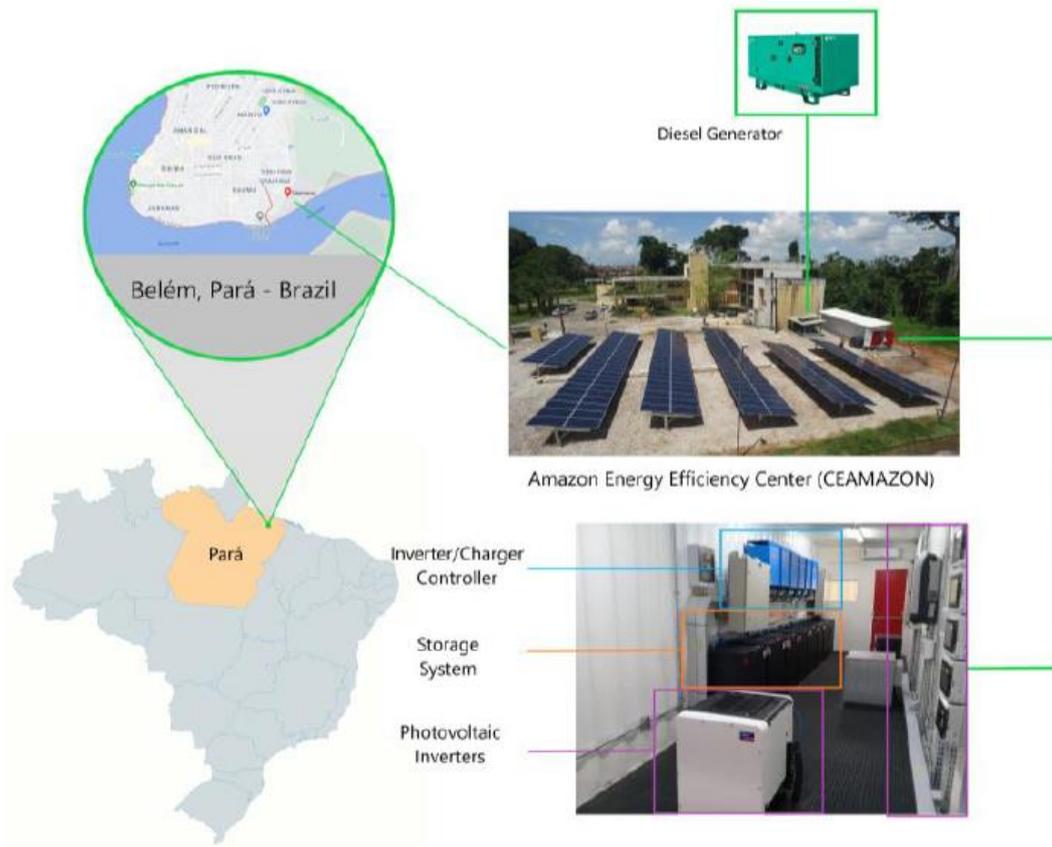
3 METODOLOGIA

3.1 Introdução

Este capítulo apresenta a metodologia adotada para o desenvolvimento dos sistemas propostos para previsão de um dia a frente da energia elétrica gerada pela miniusina de geração fotovoltaica instalada nas dependências do CEAMAZON, na UFPA, localizada em Belém/PA, nas coordenadas geográficas latitude 1,4668° Sul e longitude 48,447° Oeste, fruto do Projeto de P&D ANEEL 07427-0319/2019, Chamada 022/2018, “Sistema Inteligente de Gestão Eficiente de Mobilidade Elétrica Multimodal”. A figura 15 apresenta o sistema de geração híbrida instalado no CEAMAZON objeto deste estudo.

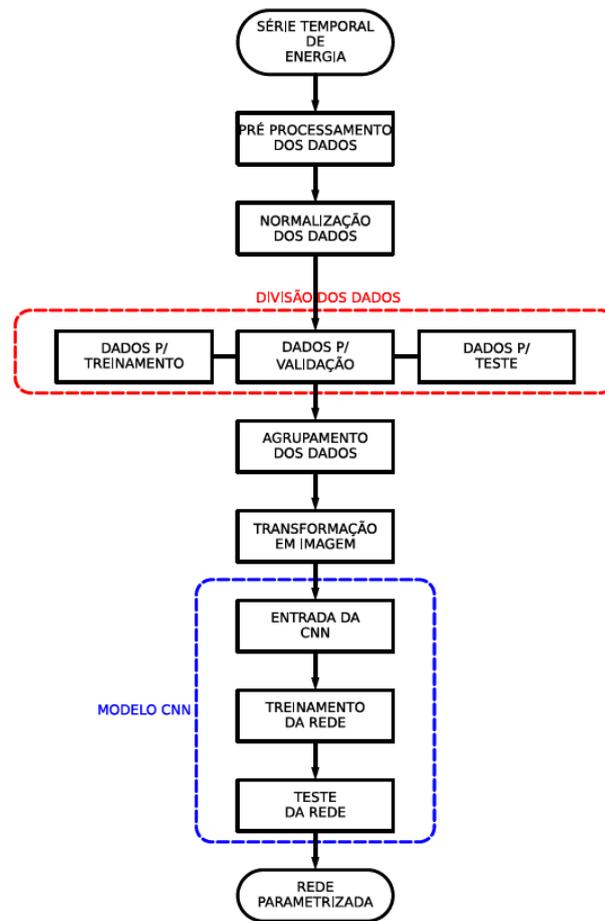
Os sistemas de previsão propostos se baseiam em CNNs 2D que utilizam a transformação das séries temporais de energia gerada pela miniusina em imagens, as quais são apresentadas à entrada da rede para previsão dos valores desejados. O diagrama da figura 16 apresenta todas as etapas da metodologia adotada.

Figura 15 - Sistema de geração híbrida instalado no CEAMAZON.



Fonte: Tabora et al. (2021).

Figura 16 - Diagrama de fluxo da metodologia proposta.



Fonte: Autor.

Na proposta deste trabalho, os dados do sistema fotovoltaico do CEAMAZON são primeiramente pré-processados, inclusive com remoção dos dados faltosos. Todos os valores são posteriormente normalizados para posteriormente ser realizada a divisão dos dados em conjuntos de dados de treinamento, validação e teste. Então é feita a transformação das séries temporais em imagens, as quais são apresentadas à entrada do modelo de CNN elaborado. Após o treinamento e teste da rede, obtém-se a rede parametrizada.

A seguir, será apresentada a base de dados usada para desenvolvimento dos sistemas e as etapas que compõem a metodologia.

3.2 Sistema Fotovoltaico

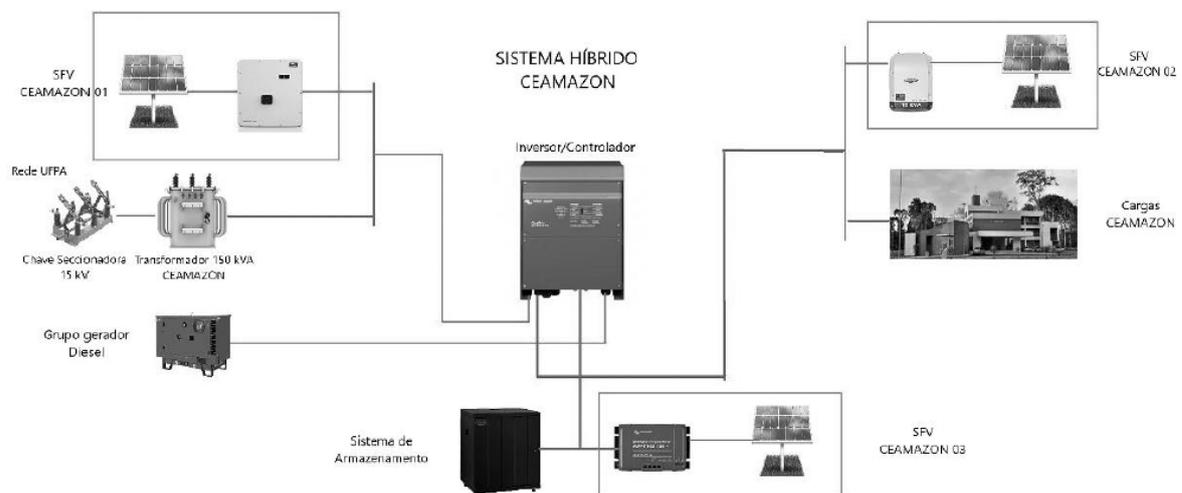
O sistema de geração implementado no CEAMAZON é híbrido, sendo composto por um gerador a diesel de 63 kVA, um banco de baterias e três sistemas fotovoltaicos: SFV-

CEAMAZON 01 (58 KWp), SFV-CEAMAZON 02 (16 KWp) e SFV-CEAMAZON 03 (6 KWp), totalizando 80 KWp. A figura 17 ilustra os componentes do sistema.

Todos os painéis fotovoltaicos do sistema em questão foram instalados em suportes de solo, com alinhamento norte e inclinação azimutal de 12°.

O SFV-CEAMAZON 01 é conectado à rede elétrica de distribuição interna da UFPA, portanto sua operação ocorre somente em condições normais de funcionamento da rede elétrica, e possui um inversor trifásico de 50 KW.

Figura 17 - Sistema de geração híbrida instalado no CEAMAZON.



Fonte: Andrade et al. (2021).

O SFV-CEAMAZON 02 é conectado diretamente ao barramento das cargas instaladas no CEAMAZON, portanto seu funcionamento independe do estado de operação da rede de distribuição da UFPA, e possui um inversor trifásico de 15 KW.

Já o SFV-CEAMAZON 03 é ligado diretamente ao banco de baterias, gerando energia em corrente contínua, que pode ser tanto armazenada quanto utilizada pelas cargas, não sendo realizada diretamente a inversão de frequência da energia, existindo, porém inversor associado.

3.3 Base de Dados

O sistema de geração do CEAMAZON possui equipamento de monitoramento de grandezas, que inclui o registro de informações tomadas minuto a minuto, como dia, mês, ano, horário, tensão por fase, corrente por fase, potência ativa instantânea por fase, dentre outros, sendo tais dados relativos a cada inversor dos sistemas fotovoltaicos. A figura 18 apresenta um

exemplo da organização dos dados obtidos junto ao CEAMAZON, com informações das potências instantâneas por fase, em watts, do SFV-CEAMAZON 02 (PV Inverter [20]), além das informações de data e hora.

A base de dados disponibilizada pelo CEAMAZON corresponde às informações dos sistemas fotovoltaicos relativos ao período de 01 de janeiro de 2021 a 31 de dezembro de 2022, totalizando dados correspondentes a 730 dias.

Figura 18 - Trecho exemplificativo dos dados de geração fotovoltaica obtidos do sistema do CEAMAZON.

	timestamp	PV Inverter [20]		
	America/Sao_Paulo (-03:00)	L1 Power	L2 Power	L3 Power
	Unnamed: 0_level_2	W	W	W
2200	2021-01-01 09:32:01	3164.0	3156.0	3172.0
2201	2021-01-01 09:33:01	3198.0	3191.0	3206.0
2202	2021-01-01 09:34:01	3183.0	3177.0	3195.0
2203	2021-01-01 09:35:01	3232.0	3224.0	3241.0
2204	2021-01-01 09:36:01	3260.0	3252.0	3268.0
2205	2021-01-01 09:37:01	3250.0	3241.0	3259.0
2206	2021-01-01 09:38:01	3297.0	3287.0	3306.0
2207	2021-01-01 09:39:01	3351.0	3344.0	3360.0
2208	2021-01-01 09:40:01	3386.0	3380.0	3398.0
2209	2021-01-01 09:41:01	3400.0	3390.0	3404.0
2210	2021-01-01 09:42:01	3407.0	3402.0	3421.0
2211	2021-01-01 09:43:02	3450.0	3445.0	3464.0

Fonte: Autor.

Para o desenvolvimento deste trabalho, foram levadas em consideração as potências ativas instantâneas por fase, as quais passaram pelo devido tratamento de modo que os dados usados para treinamento das redes neurais foram a energia elétrica total horária gerada pelos sistemas.

3.4 Pré-Processamento dos Dados

As informações dos sistemas fotovoltaicos em análise foram coletadas minuto a minuto, sendo que, durante os horários sem incidência normal de irradiação solar, a saber, entre o pôr

do sol de um dia e o nascer do sol do dia seguinte, o equipamento de aferição de dados apresenta algumas entradas repetidas para o mesmo minuto, porém com potência ativa instantânea registrada igual a zero.

Desta forma, foi realizada a averiguação da integridade das informações disponibilizadas, visando mensurar a quantidade de dados válidos e de dados não numéricos relativos às potências ativas instantâneas de cada sistema. A tabela 1 apresenta a distribuição de dados não numéricos ao longo dos meses para cada sistema. Já a tabela 2 mostra a quantidade total de entradas existentes e o quantitativo absoluto e percentual de dados não numéricos para cada sistema.

Tabela 1 - Distribuição percentual de dados não numéricos por mês

(continua)

	SFV-CEAMAZON 01	SFV-CEAMAZON 02	SFV-CEAMAZON 03
Jan/2021	100%	0,34%	100%
Fev/2021	100%	0,51%	1,72%
Mar/2021	88,35%	1,13%	0,00%
Abr/2021	100%	100%	0,00%
Mai/2021	100%	0,00%	0,00%
Jun/2021	100%	0,28%	0,00%
Jul/2021	100%	1,88%	0,00%
Ago/2021	100%	0,00%	0,00%
Set/2021	100%	0,01%	0,00%
Out/2021	100%	0,07%	0,00%
Nov/2021	100%	0,00%	0,00%
Dez/2021	100%	0,00%	0,00%
Jan/2022	100%	0,08%	0,00%
Fev/2022	16,19%	0,01%	0,00%
Mar/2022	91,95%	0,00%	0,00%
Abr/2022	100%	0,00%	0,00%
Mai/2022	100%	0,01%	0,00%
Jun/2022	50,29%	0,16%	0,00%
Jul/2022	7,00%	0,00%	0,00%
Ago/2022	4,61%	0,03%	0,00%

Tabela 1 – Distribuição percentual de dados não numéricos por mês

(conclusão)

	SFV-CEAMAZON 01	SFV-CEAMAZON 02	SFV-CEAMAZON 03
Set/2022	6,82%	1,06%	0,01%
Out/2022	8,59	0,15%	0,03%
Nov/2022	4,55%	0,05%	0,01%
Dez/2022	3,43%	0,63%	0,03%

Fonte: Autor.

Tabela 2 - Quantidade de dados não numéricos na base de dados,
em valores absolutos e relativos

	SFV- CEAMAZON 01	SFV- CEAMAZON 02	SFV- CEAMAZON 03
Total de dados	2.600.435		
Dados não numéricos (absoluto)	1.871.028	120.507	147.138
Dados não numéricos (percentual)	72,04%	4,64%	5,66%

Fonte: Autor.

Posteriormente, realizou-se a mudança na resolução dos dados, de tal forma que as potências ativas trifásicas de uma mesma hora foram somadas e divididas pelo número de minutos utilizados para a integralização, resultando na energia elétrica, cuja unidade é quilowatt-hora (KWh), que será utilizada tanto para entrada da rede a ser treinada, quanto na sua saída. Destaca-se que, caso um conjunto de dados de uma mesma hora totalizasse menos de 30 minutos, a hora inteira foi descartada. Por semelhante modo, caso um dia possuísse menos de 9h de dados dentro do período de efetiva geração de energia, o dia era excluído integralmente.

3.4.1 Divisão de dados em Treinamento, Teste e Validação

Após a remoção dos dados faltosos ou inconsistentes, contabilizaram-se os dados de energia gerada em 674 dias. Desta feita, é importante que os dados existentes sejam separados em dados para treinamento, teste e validação da rede neural.

O conjunto de dados de treinamento representa a quantidade de dados usados para efetivamente realizar o processo de aprendizagem da rede neural, a partir dos dados históricos, com o objetivo de prever dados em momento futuro.

Os dados separados para validação são utilizados para se obter uma visão mais assertiva acerca dos ajustes da rede durante o processo de aprendizagem (capacidade de generalização), enquanto os dados de treinamento são apresentados ao modelo para ajuste de parâmetros.

O conjunto de dados de teste é utilizado após a rede estar devidamente treinada, visando determinar se o modelo treinado possui bom desempenho quando são apresentados na sua entrada dados não utilizados durante a fase de treinamento e validação, ou seja, dados nunca vistos pela rede na fase de ajustes de parâmetros.

Para efeitos de treinamento e teste, os dados foram divididos na proporção 80/20, onde 80% dos dados disponíveis foram utilizados para o treinamento, a saber, dados de 535 dias, e 20% dos dados, ou seja, 139 dias, para teste.

Dos dados disponibilizados para treinamento, 10% foram utilizados para validação da rede. Tais dados de validação correspondem ao trecho final da série temporal de treinamento, com o objetivo de, simultaneamente, evitar o sobre-treinamento da rede e de possibilitar a parada antecipada do treinamento, garantindo ainda que os dados de validação mantenham as dependências temporais do sinal de entrada apresentado à rede.

Desta forma, o conjunto de dados de treinamento corresponde aos dados disponíveis no período de 01/01/2021 a 06/05/2022, os dados utilizados para validação englobam o período de 07/05/2022 a 31/07/2022, enquanto o conjunto de dados de teste corresponde ao período de 01/08/2022 a 31/12/2022. Importante destacar que, conforme mencionado na tabela 1, não existem dados disponibilizados para o mês de abril/2021 no SF-CEAMAZON 02.

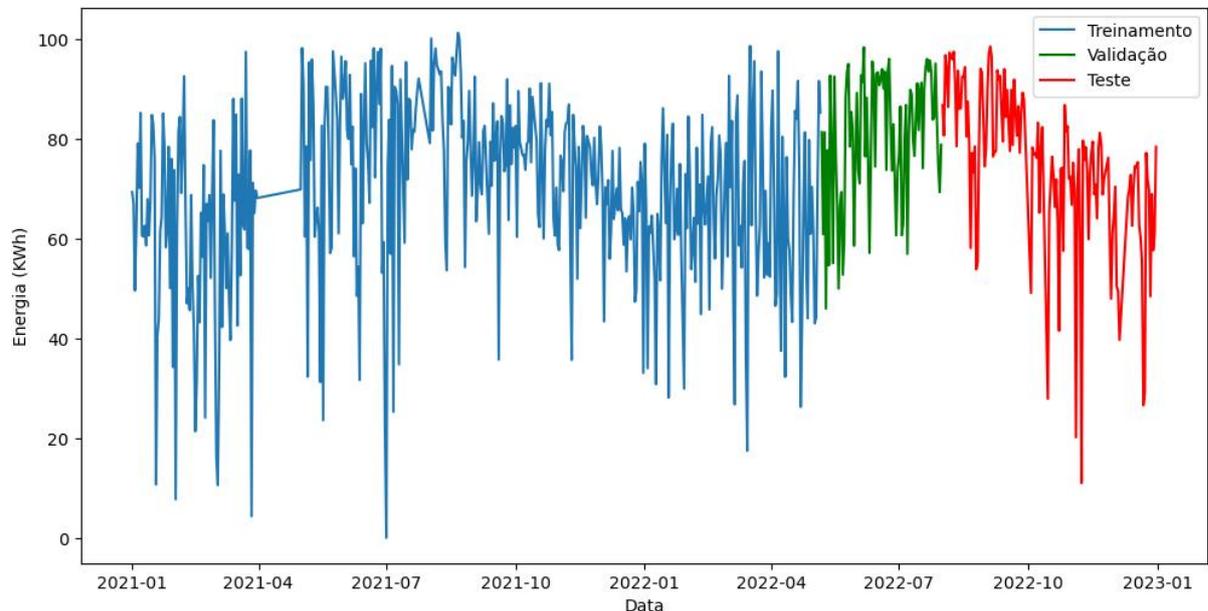
3.4.2 Normalização dos Dados

Um passo importante no pré-processamento dos dados é a normalização dos valores que serão apresentados ao modelo a ser treinado, que transforma ou escalona os dados em uma faixa de valores de tal forma que, após a normalização, os valores mais altos possuam contribuição numérica equivalente aos valores mais baixos, para que todos os dados contribuam igualmente no processo de aprendizagem (SING, D; SING, B., 2020).

Neste trabalho foi utilizada a normalização Min-Max, que realiza uma transformação escalar linear nos dados com base em limites superior e inferior pré-determinados (HAN, J.; KAMBER, M.; PEI, J, 2011), sendo escolhidos os limites [0, 1] ou [-1, 1], sendo que as

equações (1) e (2) apresentam respectivamente as formulações matemáticas para a normalização Min-Max nos limites mencionados.

Figura 19 - Divisão da base de dados em Treinamento, Validação e Teste.



Fonte: Autor.

3.4.3 Organização dos Dados para Aprendizado

Para a utilização dos dados da série temporal no treinamento da rede, esta deve receber sequências de observações temporais como entrada e uma sequência de observações ou um valor de observação na saída.

Desta forma, os conjuntos de dados de treinamento, validação e teste foram agrupados através de uma adaptação da técnica de janela deslizante (LAZZERI, F., 2021), onde é definido o tamanho de uma janela que percorre a série temporal, representando quantos dados anteriores da série serão utilizados para previsão do próximo valor na sequência.

Para o caso de uma série temporal exemplificativa de uma única variável [0, 1, 2, 3, 4, 5, 6, 7, 8, 9] e adotando uma janela no tamanho 3, visando prever os próximos dois valores, a série temporal será transformada em 6 amostras, conforme demonstrado na tabela 3.

Tabela 3 - Amostras de uma série temporal exemplificativa para apresentação a uma rede neural com janela igual 3 e número de saídas igual a 2.

Entrada 1	Entrada 2	Entrada 3	Saída 1	Saída 2
0	1	2	3	4
1	2	3	4	5
2	3	4	5	6
3	4	5	6	7
4	5	6	7	8
5	6	7	8	9

Fonte: Autor.

Considerando que a resolução dos dados de energia do problema em questão é horária, existindo, portanto, 24 valores de energia por dia, os dados apresentados às entradas das redes neurais, ou seja, a janela utilizada neste trabalho, foram as informações de energia em j dias, onde j variou de 1 a 5.

Em virtude do objetivo deste trabalho ser a previsão da quantidade de energia a ser gerada pelo sistema em análise no dia seguinte, foram propostas duas abordagens ao problema, mais precisamente no que diz respeito à estruturação dos dados a serem coletados na saída das redes neurais. A primeira realiza a previsão de energia gerada no dia seguinte, hora a hora, tendo a rede, portanto, 24 saídas. Já a segunda abordagem realiza a previsão de energia total gerada no dia seguinte, tendo a rede, portanto, 1 saída correspondente ao somatório de toda a energia gerada ao longo do dia.

Os dados a serem apresentados à entrada da rede foram transformados em imagem utilizando as técnicas de GAF e RP, conforme explanado nas seções 3.7.1 e 3.7.2, respectivamente. O tamanho das imagens resultantes varia conforme o valor da janela j , assumindo as dimensões destacadas na tabela 4, onde também estão as quantidades de imagens utilizadas para o treinamento das redes de acordo com a variação de j .

Por semelhante modo, a quantidade de imagens utilizadas pro conjunto de dados de teste também varia conforme o valor da janela j , conforme demonstrado na tabela 5.

As figuras 20 e 21 exemplificam a transformação de série temporal em imagens, onde a figura 20 relaciona informações de geração de energia com janela igual a 1 e a figura 21 apresenta os dados relativos à janela igual a 3. Em ambas as figuras estão demonstradas a curva de geração de energia ao longo do tempo, a imagem gerada através de URP, a imagem gerada

através de GASF e a imagem gerada através de GADF, respectivamente identificados por (a), (b), (c) e (d).

Tabela 4 - Dimensão das imagens de entrada e quantidade de imagens utilizadas para treinamento, de acordo com a variação da janela j .

j	Dimensão da imagem	Quantidade de imagens
1	24x24	535
2	48x48	534
3	72x72	533
4	96x96	532
5	120x120	531

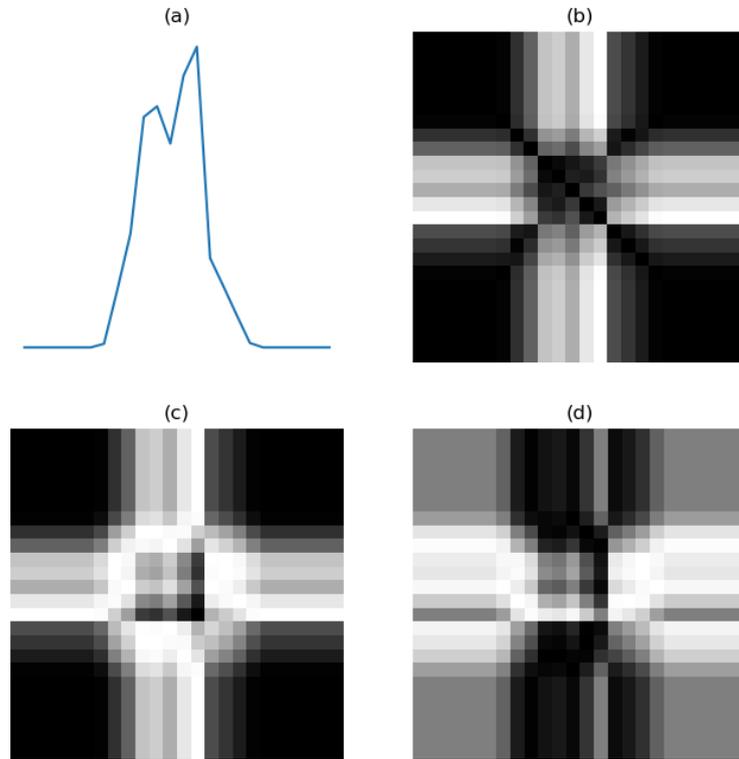
Fonte: Autor.

Tabela 5 - Dimensão das imagens de entrada e quantidade de imagens utilizadas para teste, de acordo com a variação da janela j .

j	Dimensão da imagem	Quantidade de imagens
1	24x24	139
2	48x48	138
3	72x72	137
4	96x96	136
5	120x120	135

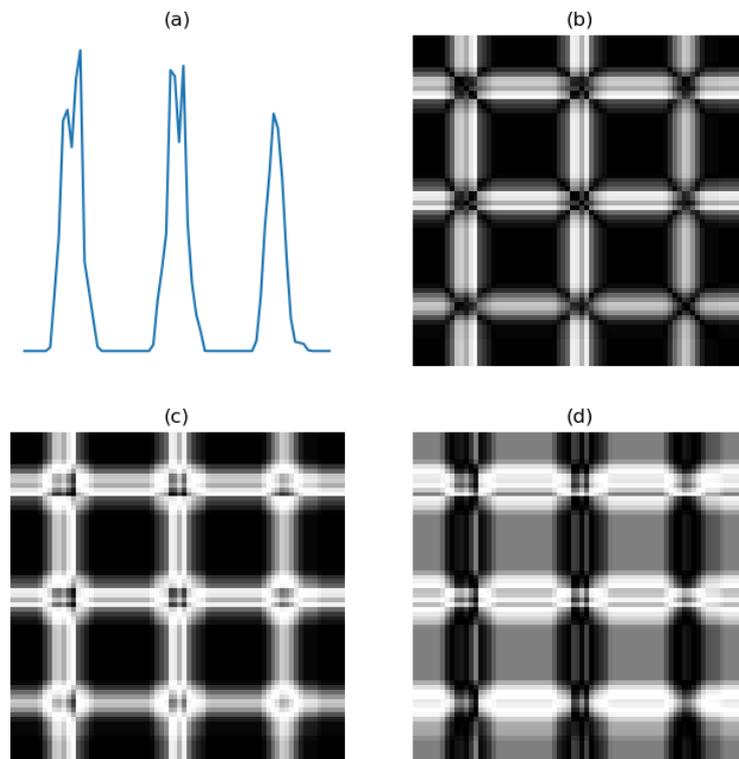
Fonte: Autor.

Figura 20 - Exemplo de série temporal com $j = 1$ e transformações em imagem por URP, GASF e GADF.



Fonte: Autor.

Figura 21 - Exemplo de série temporal com $j = 3$ e transformações em imagem por URP, GASF e GADF.

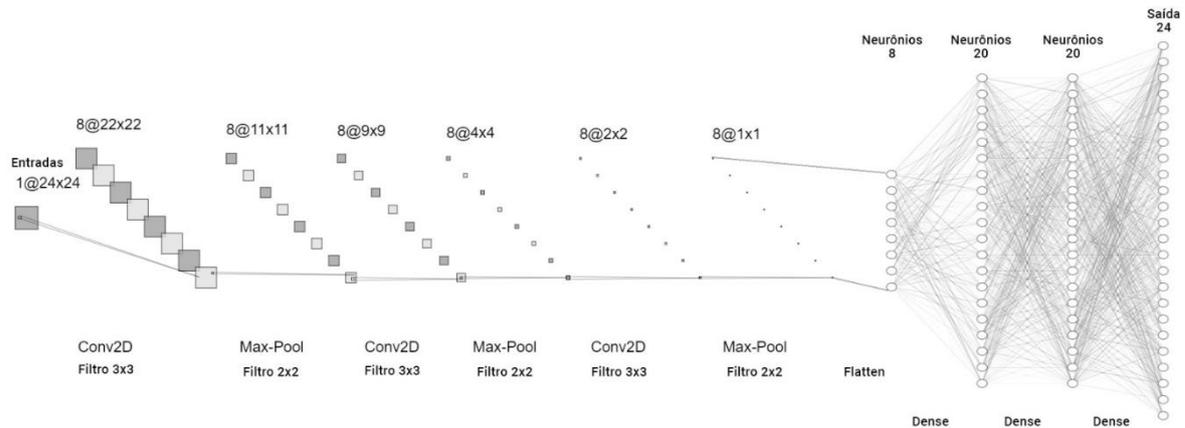


Fonte: Autor.

3.5 Parâmetros das Redes Neurais Convolucionais

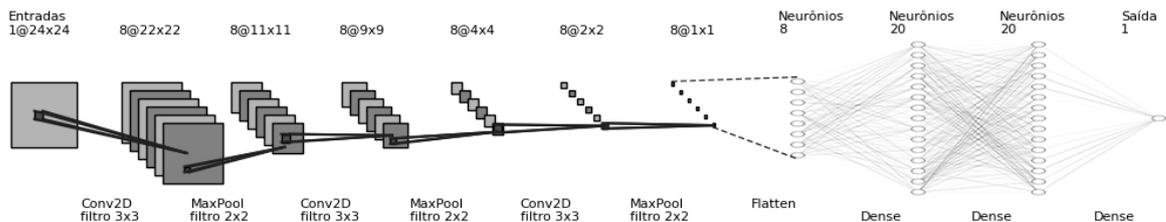
O modelo proposto no presente trabalho busca utilizar o potencial principal da CNN, que é a extração de informações contidas em dados bidimensionais, tal como imagens. As configurações de arquitetura da CNN proposta para o problema objeto deste trabalho estão representadas nas figuras 22 e 23.

Figura 22 - Modelo de CNN proposto, para 24 saídas.



Fonte: Autor.

Figura 23 - Modelo de CNN proposto, para 1 saída.



Fonte: Autor.

No modelo proposto, foram usadas camadas de convolução (Conv2D) com tamanho de filtros 3x3, onde o número de filtros foi fixado em 8. Associado à Conv2D foram aplicadas normalização de lotes e função de ativação Unidade Linear Retificada (*Rectified Linear Unit – ReLU*), proposta por Fukushima (1969).

Já na camada de *pooling*, que utilizou a função estatística de agregação *max-pooling* (MaxPool), a dimensão utilizada foi 2x2, com número de *strides* variável, igualado ao valor de $j+1$. À camada de *Dropout* foi atribuído o valor de 20% de neurônios anulados randomicamente. Posteriormente, utilizou-se uma camada *Flatten*.

Então seguiu-se à implementação de camadas totalmente conectadas (*Dense*), cujo número de camadas foi variado entre 1 e 3 e o número de neurônios de cada camada foi variado entre 20 e 90, com acréscimo em múltiplos de 10. Após as camadas *Dense*, tem-se a camada de saída, com 24 ou 1 neurônio, dependendo da abordagem utilizada, conforme discriminado na seção 3.3.3.

Todas as funções de ativação dos neurônios das Camadas *Dense* e da camada de saída foram ReLU. Os parâmetros de treinamento e propriedades da rede proposta estão resumidos na tabela 6.

O algoritmo utilizado para o treinamento das redes foi o ADAM. A métrica de avaliação de desempenho utilizada durante o treinamento foi o Erro Médio Quadrático (*Mean Squared Error* – MSE).

Todos os treinamentos foram feitos com até 1.000 épocas (sendo época a denominação para quando todo o conjunto de dados de treino passa pelas iterações para ajuste dos pesos sinápticos), sendo que foi utilizado o critério de parada antecipada, baseada no desempenho do erro verificado nos dados de validação.

Tabela 6 - Parâmetros de treinamento e propriedades da rede.

Item	Descrição
Número de Épocas	1.000
Tamanho dos mini-lotes	32
Algoritmo de Treinamento	ADAM
Métrica de avaliação de desempenho do modelo	MSE
Número de camadas convolucionais/ <i>pooling</i>	3
Tamanho dos filtros da camada convolucional	3x3
Número de filtros da camada convolucional	8
Tamanho da janela de <i>pooling</i>	2x2
Número de <i>strides</i>	$j+1$
Número de camadas <i>Dense</i>	1 a 3
Número de neurônios nas camadas <i>Dense</i>	20 a 90
Função de ativação	ReLU

Fonte: Autor.

Os dados de treinamento foram divididos em 32 mini lotes, que são subconjuntos do conjunto de dados de treinamento utilizados para reduzir o esforço computacional do algoritmo

que ajusta os pesos da rede neural, além de tornar o treinamento mais rápido. No treinamento utilizando mini lotes, os parâmetros da rede são atualizados ao final da passagem dos dados contidos no subconjunto (BOTTOU, L., 2010).

O pré-processamento dos dados deste trabalho, assim como a modelagem e treinamento das redes, foram feitos em computador com processador AMD *Ryzen 5* 2,1 GHz, memória RAM de 16 GB DDR4, em *Python* 3.10.10, usando *Jupyter Lab*. As ferramentas para aprendizado de máquina utilizadas foram *Tensorflow* e *Keras*, além de *Sci-kit Learn* e outras bibliotecas básicas de Python usadas para processamento de dados e visualizações gráficas, como *Numpy*, *Matplotlib*, *DateTime*, *Pandas* e *Pyts*.

3.6 Validação Estatística

O desempenho de um modelo de previsão é analisado através da utilização de medidas que observam quanto o valor previsto se aproxima do valor real aferido. Dentre as diversas métricas utilizadas para a verificação da precisão de um determinado preditor, este trabalho utiliza as metodologias de validação estatística Erro Médio Absoluto (*Mean Absolute Error* – MAE), Erro Médio Quadrático (*Mean Squared Error* – MSE) e Raiz do Erro Médio Quadrático (*Root Mean Squared Error* – RMSE), demonstradas nas equações 13, 14 e 15, respectivamente, onde N é o número total de amostras, y é o valor real medido e \hat{y} é o valor previsto pelo modelo. Os erros foram computados utilizando o módulo *Metrics* da biblioteca *Sci-kit Learn*.

$$MAE = \frac{1}{N} \sum_{k=1}^N |y_k - \hat{y}_k| \quad (13)$$

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2} \quad (15)$$

4 RESULTADOS E DISCUSSÃO

4.1 Introdução

Este capítulo apresenta os resultados obtidos pelos modelos propostos, avalia o desempenho das redes e aplica as métricas de validação estatística para comparar os valores dos erros dos modelos propostos com os valores dos erros de redes de referência.

Para apresentação dos dados às redes CNNs testadas, foram utilizadas, separadamente, as metodologias de transformação de séries temporais em imagens GAF e RP, segundo discriminado na seção 2.6, com variação da janela j e conseqüente variação da dimensão das imagens de entrada, detalhado na tabela 4.

Tanto para o caso da saída desejada ser a energia gerada no dia seguinte, hora a hora, como para saída desejada sendo a energia total gerada no dia seguinte, diversas configurações de CNNs foram treinadas com variação no valor da janela j , conforme detalhado na seção 3.3.3, no número de camadas totalmente conectadas e no número de neurônios em tais camadas, conforme discriminado na seção 3.4 e na tabela 5.

Então, para cada configuração de rede foram realizadas 100 repetições de treinamento (100 inicializações dos pesos das redes), com o devido registro dos RMSEs de cada treinamento, tanto em valores normalizados quanto em valores sem normalização, bem como armazenamento dos pesos da rede com melhor performance em termos de RMSE.

Durante o treinamento, implementou-se a parada antecipada com o auxílio do módulo *Early Stopping* da biblioteca *Keras*. O parâmetro monitorado foi o erro no conjunto de dados de validação, com limite mínimo de variação aceitável de 0,01, tanto para o aumento quanto para a diminuição do erro, sendo aguardadas até 10 épocas de treinamento sem melhoria no erro. Após a parada, são retornados os pesos do melhor resultado encontrado.

Para a validação do modelo proposto no presente trabalho, foi feita a comparação do resultado obtido por meio do uso de transformação de séries temporais em imagens aplicadas a redes CNN 2D com modelos de redes MLP e CNN 1D, estes sem transformação da série temporal para imagens. Nestes casos, também se variou a janela j de 1 a 5, o número de camadas escondidas (*Dense*) de 1 a 3 e o número de neurônios nas camadas *Dense* de 20 a 90, em passos de 10. Além disso, na CNN 1D, utilizou-se de 1 a 3 camadas Convolucionais combinadas com camadas de *pooling*, com filtros fixados em 8.

Os menores RMSEs obtidos no conjunto de dados de teste para estes dois modelos de rede, tanto em valores normalizados quanto em valores reais, estão discriminados nas tabelas 7

e 8. Importante destacar que todos os valores de erro avaliados neste capítulo, para definição do melhor modelo, foram calculados com base no conjunto de dados de teste. A avaliação do desempenho do modelo, de acordo com as métricas de erro discriminadas na seção 3.6, aplicada no conjunto de dados de teste é de fundamental importância para indicar a capacidade de generalização do modelo treinado.

Tabela 7 - Menor RMSE para redes MLP e CNN 1D com saída Energia 24 horas.

Rede	j	Camadas Convolucionais	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
MLP	1	-	2	50	0,0842	1,2562
CNN 1D	1	1	3	70	0,0856	1,2767

Fonte: Autor.

Tabela 8 - Menor RMSE para redes MLP e CNN 1D com saída Energia Total.

Rede	j	Camadas Convolucionais	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
MLP	1	-	2	60	0,1312	13,2758
CNN 1D	1	1	2	30	0,1328	13,4370

Fonte: Autor.

4.2 Previsão Utilizando GAF

Os resultados desta seção são referentes à utilização de GAF, nas variações GADF e GASF, na série temporal dos dados de geração de energia fotovoltaica do SFV-CEAMAZON 02 para treinamento e teste do modelo de previsão em diferentes configurações, tendo como entrada a imagem gerada pela referida técnica de transformação, com variação da dimensão da imagem, e como saída a energia elétrica a ser gerada no dia seguinte em 24 valores horários (Saída Energia 24h) ou em 1 valor correspondente ao total da energia gerada no dia a ser predito (Saída Energia Total).

4.2.1 Resultados Obtidos com GASF com Saída Energia 24h

Considerando a utilização da técnica GASF, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste para cada variação de janela e número de camadas *Dense*, com saída Energia 24h, estão demonstradas na tabela 9, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 10.

Tabela 9 - Melhores valores médios de RMSE para redes usando GASF, com saída Energia 24h.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	90	0,1316	1,9638
1	2	50	0,1386	2,0678
1	3	40	0,1503	2,2416
2	1	20	0,1334	1,9894
2	2	20	0,1471	2,1944
2	3	40	0,1614	2,4076
3	1	30	0,1355	2,0218
3	2	40	0,1479	2,2066
3	3	30	0,1570	2,3426
4	1	40	0,1334	1,9906
4	2	90	0,1337	1,9945
4	3	70	0,1447	2,1584
5	1	20	0,1392	2,0786
5	2	20	0,1490	2,2231
5	3	60	0,1619	2,4150

Fonte: Autor.

Tabela 10 - Configurações da rede com menor valor de RMSE, usando GASF e saída Energia 24h.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	2	80	0,0859	1,2817

Fonte: Autor.

4.2.2 Resultados Obtidos com GADF com Saída Energia 24h

Considerando a utilização da técnica GADF, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste para cada variação de janela e número de camadas *Dense*, com saída Energia 24h, estão demonstradas na tabela 11, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 12.

Tabela 11 - Melhores valores médios de RMSE para redes usando GADF, com saída Energia 24h.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	30	0,1272	1,8969
1	2	20	0,1357	2,0248
1	3	80	0,1480	2,2074
2	1	60	0,1234	1,8412
2	2	40	0,1338	1,9961
2	3	90	0,1464	2,1833
3	1	30	0,1376	2,0531
3	2	40	0,1460	2,1782
3	3	40	0,1583	2,3623
4	1	70	0,1296	1,9336
4	2	90	0,1345	2,0063
4	3	50	0,1454	2,1694
5	1	20	0,1285	1,9165
5	2	40	0,1378	2,0553
5	3	70	0,1536	2,2909

Fonte: Autor.

Tabela 12 - Configurações da rede com menor valor de RMSE, usando GADF e saída Energia 24h.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	2	40	0,0893	1,3323

Fonte: Autor.

4.2.3 Resultados Obtidos com GASF com Saída Energia Total

Considerando a utilização da técnica GASF, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste para cada variação de janela e número de camadas *Dense*, com saída Energia Total, estão demonstradas na tabela 13, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 14.

Tabela 13 - Melhores valores médios de RMSE para redes usando GASF, com saída Energia Total.

<i>j</i>	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	60	0,1801	18,2279
1	2	40	0,1872	18,9467
1	3	30	0,1847	18,6866
2	1	20	0,1773	17,9389
2	2	60	0,1673	16,9286
2	3	50	0,1691	17,1127
3	1	30	0,2756	27,8860
3	2	40	0,1696	17,1618
3	3	20	0,1726	17,4683
4	1	20	0,4329	43,8096
4	2	20	0,1798	18,1922
4	3	60	0,1781	18,0209
5	1	40	0,1724	17,4493
5	2	90	0,1835	18,5664
5	3	80	0,1908	19,3131

Fonte: Autor.

Tabela 14 - Configurações da rede com menor valor de RMSE, usando GASF e saída Energia Total.

<i>j</i>	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	3	40	0,1309	13,2504

Fonte: Autor.

4.2.4 Resultados Obtidos com GADF com Saída Energia Total

Considerando a utilização da técnica GADF, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste para cada variação de janela e número de camadas *Dense*, com saída Energia Total, estão demonstradas na tabela 15, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 16.

Tabela 15 - Melhores valores médios de RMSE para redes usando GADF, com saída Energia Total.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	70	0,1877	18,9940
1	2	30	0,1840	18,6161
1	3	30	0,2041	20,6504
2	1	90	0,1911	19,3426
2	2	60	0,2056	20,8022
2	3	40	0,2200	22,2594
3	1	40	0,1905	19,2731
3	2	40	0,1983	20,0666
3	3	50	0,2157	21,8229
4	1	50	0,1861	18,8277
4	2	80	0,1863	18,8486
4	3	30	0,2050	20,7473
5	1	20	0,1693	17,1312
5	2	50	0,1774	17,9536
5	3	30	0,1754	17,7505

Fonte: Autor.

Tabela 16 - Configurações da rede com menor valor de RMSE, usando GADF e saída Energia Total.

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	3	40	0,1307	13,2291

Fonte: Autor.

4.3 Previsão Utilizando RP

Os resultados desta seção são referentes à utilização de RP na série temporal dos dados de geração de energia fotovoltaica do SFV-CEAMAZON 02 para treinamento e teste do modelo de previsão em diferentes configurações, tendo como entrada a imagem gerada pela referida técnica de transformação, com variação da dimensão da imagem, e como saída a energia elétrica a ser gerada no dia seguinte em 24 valores horários (Saída Energia 24h) ou em 1 valor correspondente ao total da energia gerada no dia a ser predito (Saída Energia Total).

4.3.1 Resultados Obtidos com URP com Saída Energia 24h

Considerando a utilização da técnica URP, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste para cada variação de janela e número de camadas *Dense*, com saída Energia 24h, estão demonstradas na tabela 17, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 18.

Tabela 17 - Melhores valores médios de RMSE para redes usando URP, com saída Energia 24h.

(continua)

j	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	70	0,1596	2,3810
1	2	60	0,1657	2,4713
1	3	50	0,1765	2,6326
2	1	30	0,1633	2,4356
2	2	30	0,1698	2,5330
2	3	50	0,1756	2,6194
3	1	30	0,1626	2,4258
3	2	20	0,1724	2,5725
3	3	60	0,1797	2,6808
4	1	80	0,1659	2,4752
4	2	70	0,1610	2,4014

Tabela 17 – Melhores valores médios de RMSE para redes usando URP, com saída Energia 24h.

(conclusão)

<i>j</i>	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
4	3	90	0,1666	2,4852
5	1	50	0,1788	2,6675
5	2	80	0,1749	2,6089
5	3	80	0,1768	2,6371

Fonte: Autor.

Tabela 18 - Configurações da rede com menor valor de RMSE, usando URP e saída Energia 24h.

<i>j</i>	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	20	0,0970	1,4474

Fonte: Autor.

4.3.2 Resultados Obtidos com URP com Saída Energia Total

Considerando a utilização da técnica URP, as informações das redes com os melhores valores médios de RMSE no conjunto de dados de teste, para cada variação de janela e número de camadas *Dense*, com saída Energia Total, estão demonstradas na tabela 19, enquanto os dados para a rede que apresentou o menor valor de RMSE estão demonstrados na tabela 20.

Tabela 19 - Menores valores médios de RMSE para redes usando URP, com saída Energia Total.

(continua)

<i>j</i>	Camadas Dense	Neurônios nas Camadas Dense	RMSE Normalizado	RMSE Real
1	1	50	0,1727	17,4736
1	2	40	0,1776	17,9687
1	3	40	0,1662	16,8167

Tabela 19 – Menores valores médios de RMSE para redes usando URP, com saída Energia Total.

(conclusão)

j	Camadas Dese	Neurônios nas Camadas Dese	RMSE Normalizado	RMSE Real
2	1	40	0,1948	19,7118
2	2	30	0,1993	20,1729
2	3	20	0,2085	21,0947
3	1	20	0,1954	19,7704
3	2	30	0,2072	20,9640
3	3	30	0,2172	21,9767
4	1	40	0,1857	18,7920
4	2	20	0,1971	19,9476
4	3	30	0,2075	20,9931
5	1	40	0,1875	18,9744
5	2	40	0,1833	18,5531
5	3	20	0,1783	18,0395

Fonte: Autor.

Tabela 20 - Configurações da rede com menor valor de RMSE, usando URP e saída Energia Total.

j	Camadas Dese	Neurônios nas Camadas Dese	RMSE Normalizado	RMSE Real
1	3	80	0,1288	13,0302

Fonte: Autor.

4.4 Análise Comparativa dos Resultados

Após a realização dos testes, foi possível verificar que os menores valores de RMSE, em termos absolutos, foram alcançados com o menor valor de janela, ou seja, fazendo-se j igual a 1, para todas as redes testadas, com os dois modos de organização de saída dos dados considerados no estudo.

A tabela 21 demonstra os valores médios de RMSE (com e sem normalização) para todas as redes testadas, inclusive com o RMSE das redes MLP e CNN 1D, para as redes com

saída Energia 24h e redes com saída Energia Total. Já a tabela 22 apresenta os valores mínimos de RMSE (com e sem normalização) para todas as redes testadas, inclusive com o RMSE das redes MLP e CNN 1D, para as redes com saída Energia 24h e redes com saída Energia Total.

Ao verificar os menores valores de RMSE para cada tipo de rede, conforme demonstrado na tabela 22, é possível observar que as redes propostas neste trabalho, com transformação de séries temporais em imagens e utilização de CNN 2D, conseguiram valores de RMSE menores ou muito próximos aos valores de RMSE obtidos utilizando MLP e CNN 1D. Este comportamento foi averiguado tanto nas redes com organização dos dados de saída em Energia 24h quanto com os dados de saída Energia Total. Os valores de erro normalizados alcançados pelos modelos propostos neste trabalho foram menores do que os erros obtidos pelos trabalhos de Melit et al. (2010) e Leva et al. (2015), mencionados na seção 2.7.

Tabela 21 - Valores médios de RMSE.

Rede	Saída Energia 24h		Saída Energia Total	
	Com normalização	Sem normalização	Com normalização	Sem normalização
MLP	0,1531	2,2837	0,2409	24,3771
CNN 1D	0,1838	2,7422	0,2513	25,4337
GASF	0,1485	2,2158	0,2539	25,6929
GADF	0,1429	2,1323	0,2068	20,9233
URP	0,1744	2,6017	0,2105	21,2980

Fonte: Autor.

Tabela 22 - Valores mínimos de RMSE.

Rede	Saída Energia 24h		Saída Energia Total	
	Com normalização	Sem normalização	Com normalização	Sem normalização
MLP	0,0860	1,2832	0,1312	13,2758
CNN 1D	0,0867	1,2934	0,1328	13,4370
GASF	0,0859	1,2817	0,1309	13,2504
GADF	0,0893	1,3323	0,1307	13,2291
URP	0,0970	1,4474	0,1288	13,0302

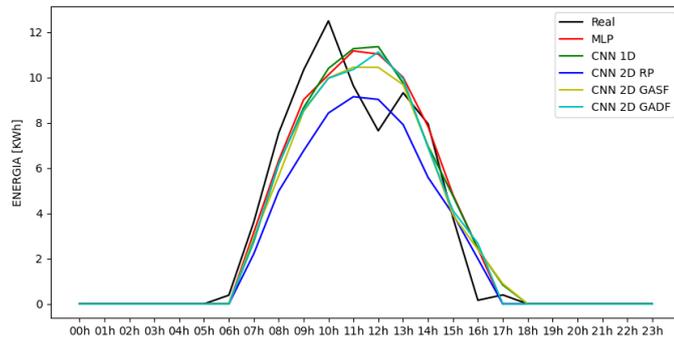
Fonte: Autor.

As figuras 24 a 27 apresentam, a título de ilustração, a comparação entre as curvas de geração de energia prevista nos dias 23/08, 20/09, 10/11 e 25/11/2022 pelas redes neurais propostas com as curvas reais de geração de energia do sistema fotovoltaico em consideração. Tais figuras foram obtidas com os dados das redes com configuração de saída Energia 24h que alcançaram os menores valores de RMSE, e nelas é possível observar que praticamente todas as metodologias propostas neste trabalho obtiveram resultados muito próximos ou até superiores às metodologias tradicionais, com exceção à rede CNN 2D com transformação dos dados usando URP, que, para a configuração de saída Energia 24h, apresentou resultado ligeiramente aquém das outras metodologias propostas.

Já as figuras 28 a 35 apresentam gráficos comparativos entre os resultados obtidos nos dias 23/08, 20/09, 10/11 e 25/11/2022 pelas metodologias propostas com a energia prevista utilizando-se MLP e CNN 1D, referenciando todos os resultados à energia efetivamente gerada pelo sistema fotovoltaico. Os gráficos demonstrados nas figuras 28 a 31, relativos aos resultados das redes com configuração de saída Energia 24h, foram obtidos através do somatório das energias horárias de cada rede, enquanto os gráficos demonstrados nas figuras 32 a 35 são relativos aos resultados das redes com configuração de saída Energia Total.

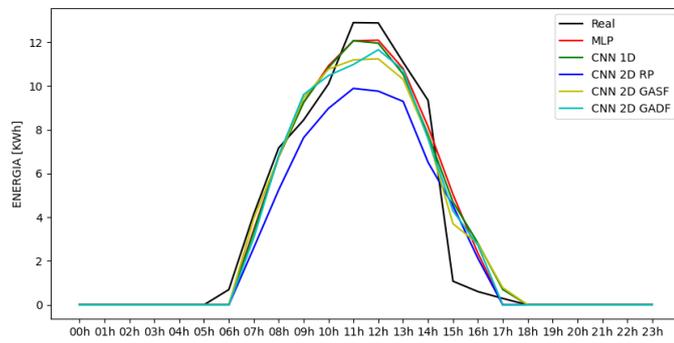
Em relação ao dia 23/08/2022, conforme observado nas figuras 28 e 32, a energia total gerada foi da ordem de 73,25 KWh, enquanto a energia prevista pelas redes CNN 2D com saída Energia 24h, com transformação em GASF, GADF e URP, foram, respectivamente, 71,79 KWh, 72,61 KWh e 60,00 KWh. Já os valores de energia previstos pelas redes CNN 2D com saída Energia Total foram 74,27 KWh, 70,80 KWh e 73,72 KWh, respectivamente para as redes com transformação em GASF, GADF e URP. É possível inferir que a rede com transformação em URP obteve resultados mais próximos aos valores reais na configuração de saída Energia Total. Os valores dos erros de previsão para cada rede, em relação ao total de energia gerada no dia 23/08/2022 estão dispostos na tabela 23. As tabelas 24, 25 e 26 apresentam os valores dos erros de previsão para cada rede, em relação ao total de energia gerada nos dias 20/09, 10/11 e 25/11/2022, respectivamente.

Figura 24 - Curvas de geração de energia para o dia 23/08/2022.



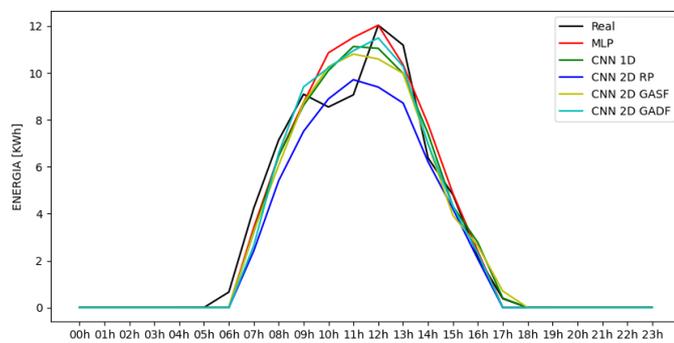
Fonte: Autor.

Figura 25 - Curvas de geração de energia para o dia 20/09/2022.



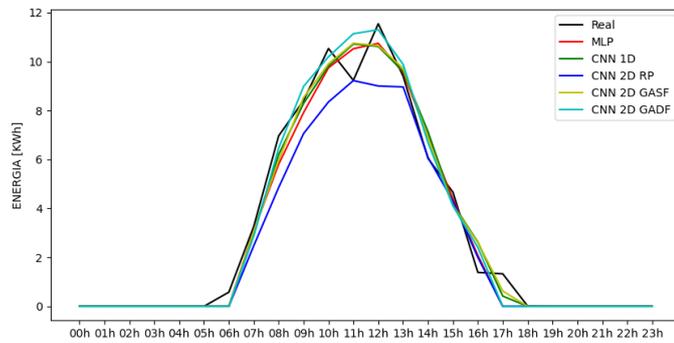
Fonte: Autor.

Figura 26 - Curvas de geração de energia para o dia 10/11/2022.



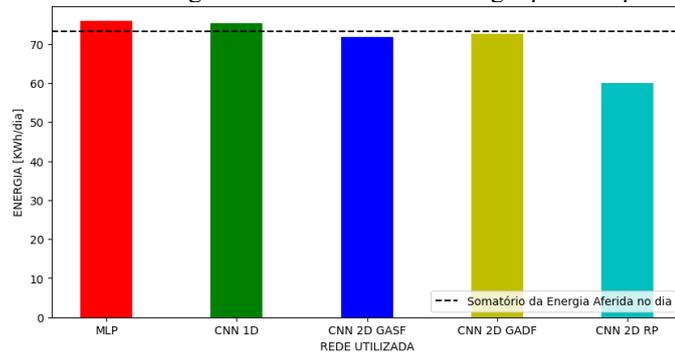
Fonte: Autor.

Figura 27 - Curvas de geração de energia para o dia 25/11/2022.



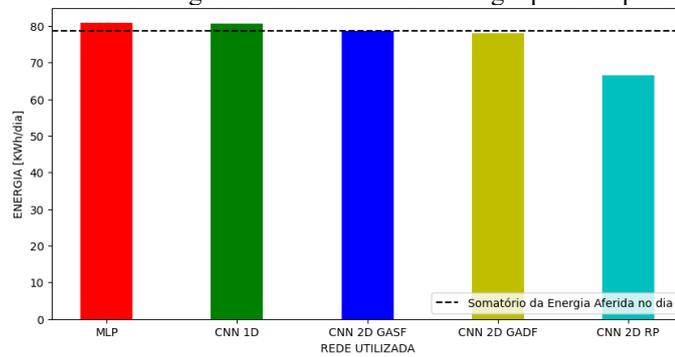
Fonte: Autor.

Figura 28 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 23/08/2022.



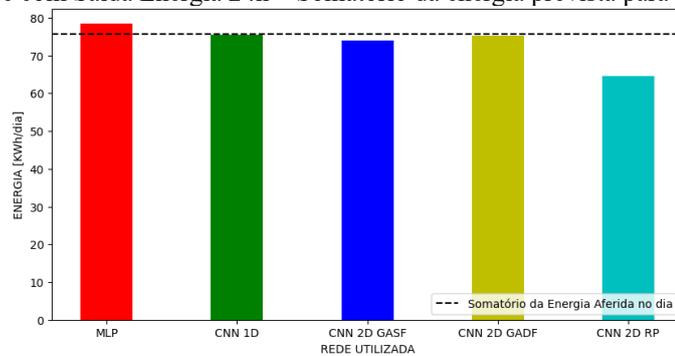
Fonte: Autor.

Figura 29 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 20/09/2022.



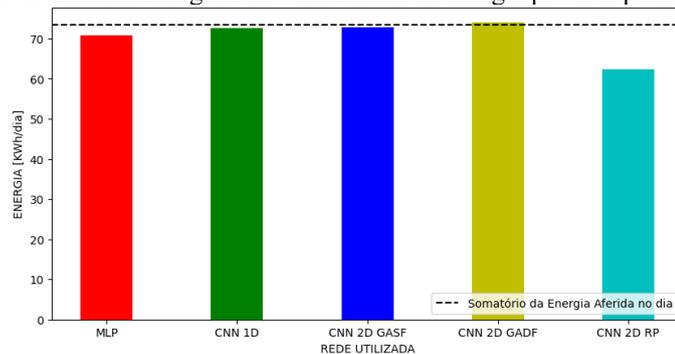
Fonte: Autor.

Figura 30 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 10/11/2022.



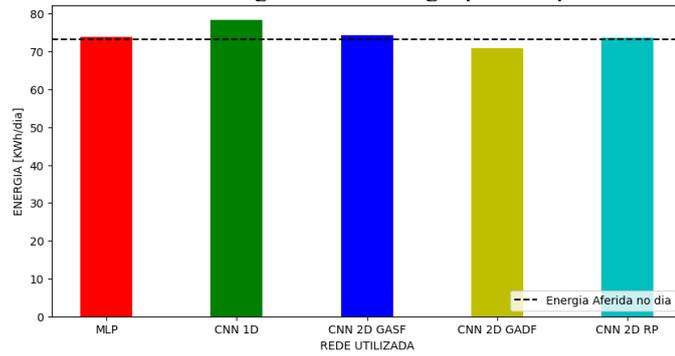
Fonte: Autor.

Figura 31 - Rede com Saída Energia 24h – Somatório da energia prevista para o dia 25/11/2022.



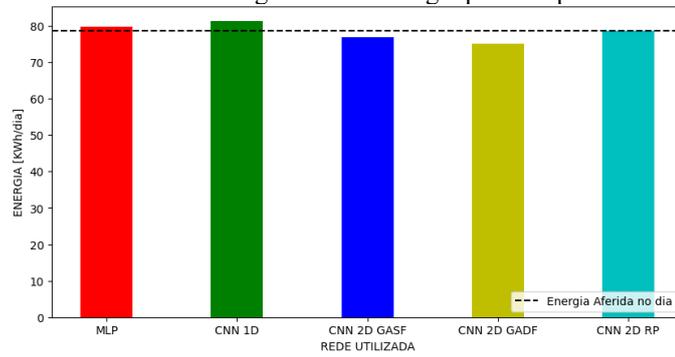
Fonte: Autor.

Figura 32 - Rede com Saída Energia Total – Energia prevista para o dia 23/08/2022.



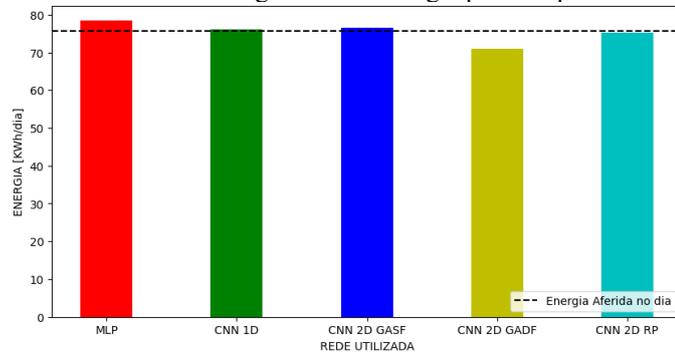
Fonte: Autor.

Figura 33 - Rede com Saída Energia Total – Energia prevista para o dia 20/09/2022.



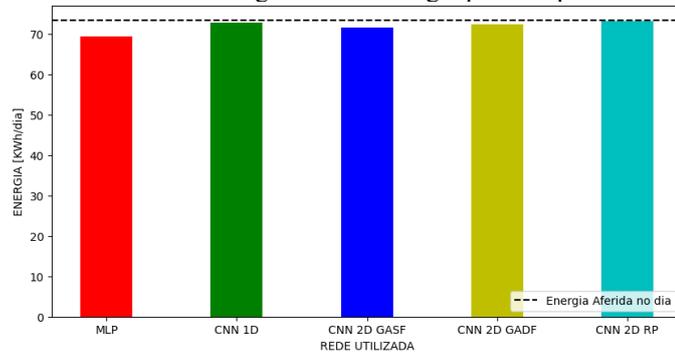
Fonte: Autor.

Figura 34 - Rede com Saída Energia Total – Energia prevista para o dia 10/11/2022.



Fonte: Autor.

Figura 35 - Rede com Saída Energia Total – Energia prevista para o dia 25/11/2022.



Fonte: Autor.

Tabela 23 - Erros de previsão para o dia 23/08/2022.

Rede	Saída Energia 24h	Saída Energia Total
MLP	2,6540 KWh	0,5627 KWh
CNN 1D	2,0887 KWh	5,0937 KWh
GASF	1,4678 KWh	1,0181 KWh
GADF	0,6432 KWh	2,4484 KWh
RP	13,2498 KWh	0,4618 KWh

Fonte: Autor.

Tabela 24 - Erros de previsão para o dia 20/09/2022.

Rede	Saída Energia 24h	Saída Energia Total
MLP	2,1291 KWh	0,9572 KWh
CNN 1D	1,9972 KWh	2,5596 KWh
GASF	0,1519 KWh	1,9126 KWh
GADF	0,7885 KWh	3,5380 KWh
RP	12,1466 KWh	0,1182 KWh

Fonte: Autor.

Tabela 25 - Erros de previsão para o dia 10/11/2022.

Rede	Saída Energia 24h	Saída Energia Total
MLP	2,7358 KWh	2,7175 KWh
CNN 1D	0,2390 KWh	0,3639 KWh
GASF	1,7992 KWh	0,8562 KWh
GADF	0,5449 KWh	4,7115 KWh
RP	11,1706 KWh	0,5695 KWh

Fonte: Autor.

Tabela 26 - Erros de previsão para o dia 25/11/2022.

Rede	Saída Energia 24h	Saída Energia Total
MLP	2,5768 KWh	4,0789 KWh
CNN 1D	0,7050 KWh	0,6768 KWh
GASF	0,5347 KWh	1,8485 KWh
GADF	0,6668 KWh	1,0271 KWh
RP	11,0349 KWh	0,1506 KWh

Fonte: Autor.

4.5 Conclusão

Os resultados alcançados pelas metodologias apresentadas neste trabalho, com a transformação das séries temporais dos dados de energia gerada pelo sistema fotovoltaico instalado no CEAMAZON em imagens, demonstram a viabilidade deste tipo de abordagem para o problema proposto. Dos valores contidos na tabela 21, é possível observar que os valores da média dos RMSE de todos os modelos com transformação de imagem e 24 saídas foram menores do que a média dos RMSE da metodologia CNN 1D, sendo que, na comparação com a média dos RMSE quando se empregou MLP na previsão, os modelos com as variações de GAF tiveram valores menores. Na tabela 22, que descreve os menores valores de RMSE alcançado pelas redes, observa-se que todos os modelos com transformação em imagem e 1 saída obtiveram valores menores do que os valores de RMSE das redes MLP e CNN 1D, tanto em valores médio e mínimo. Mesmo nos casos onde os valores dos erros médio e mínimo de RMSE alcançados pelas redes com transformação de imagem não foram menores do que os valores de RMSE das redes MLP e CNN 1D, ainda assim os erros dos modelos propostos foram bastante próximos aos dos modelos de referência.

5 CONCLUSÕES

Prever a energia gerada por uma planta fotovoltaica é um passo importante para o sistema de energia elétrica, seja para melhorar o gerenciamento da rede, seja para o planejamento e operação da distribuição de energia elétrica, ou para otimizar custos e tempo de utilização de equipamentos em um contexto residencial ou comercial, por exemplo. Porém, a previsão de geração de energia fotovoltaica pode ser desafiadora, muito em virtude da intermitência dos fatores climáticos e da irradiação solar.

Nesse contexto, este trabalho buscou apresentar uma proposta de uma nova abordagem para previsão, de maneira mais acurada, da energia gerada pelo sistema fotovoltaico instalado na UFPA, nas dependências do CEAMAZON, onde os resultados obtidos demonstraram a viabilidade do uso de transformação de séries temporais de geração de energia fotovoltaica em imagens, através do uso de GAF e RP, com aplicação em CNNs bidimensionais, para previsão da energia a ser gerada nas 24 horas posteriores.

A nova abordagem proposta baseada em CNN 2D conseguiu obter valores de RMSE próximos aos RMSE de técnicas comumente empregadas em problemas similares, como as redes MLP e CNN 1D, tendo em alguns casos até apresentando erro menor, demonstrando que, ao se realizar a transformação da série temporal de energia elétrica gerada por fonte fotovoltaica em imagens, foi possível utilizar o potencial máximo das características de extração de informações da CNN 2D, originalmente construída para trabalhar com entradas em formato tabular.

Os valores de RMSE obtidos com transformação GASF e GADF, tanto em termos médios quanto em valores mínimos, mostraram-se bastante competitivos nas duas configurações de saída. As redes com transformação em URP apresentaram valores de RMSE mais baixos, em termos mínimo e médio, para a configuração de saída Energia Total, apresentando RMSE mais altos para a configuração de saída Energia 24h.

Desta forma, o modelo proposto neste trabalho, embora estruturalmente mais complexo que o modelo de previsão que utiliza MLP, por exemplo, alcançou o objetivo estabelecido, sinalizando que há ainda espaço para inserção de outros ajustes para se alcançar resultados ainda melhores do que os ora apresentados neste trabalho.

Foi avaliado também o impacto do tamanho da janela temporal de dados para obter a previsão de geração de energia de um dia à frente. No problema ora analisado, o aumento da janela se mostrou pouco benéfico em todas as redes testadas, sendo que os menores valores de RMSE foram alcançados por todas as redes quando o valor da janela j foi igualado a 1.

Em trabalhos futuros, podem ser acrescentadas às entradas das redes os dados meteorológicos mais relevantes, tanto utilizando variáveis coletadas localmente, quanto usando dados provenientes de sistemas de monitoramento espacial, como satélites, visando gerar previsões mais precisas.

Outro meio de aprimoramento da precisão dos resultados da rede é a divisão dos dados segundo a época do ano, haja vista a variação da incidência de irradiação solar de acordo com a estação, o que influencia direta e proporcionalmente a geração de energia em um sistema fotovoltaico. Entretanto, para a implementação desta metodologia, será necessária a disponibilização de maior volume de dados do que o utilizado para o presente estudo, em virtude da necessidade de apresentar à rede o comportamento sazonal da geração fotovoltaica do sistema em questão.

Além disso, é possível também criar sistemas híbridos, mesclando a metodologia proposta neste trabalho com redes LSTM, que foram projetadas para processar dados sequenciais, com grande capacidade de reter informações anteriores, sendo utilizadas em trabalhos recentes para solucionar problemas relacionados a predição de séries temporais, como proposto por Siami-Namini, Tavakoli e Namin (2018), podendo, desta forma, gerar um aumento na acurácia já alcançada pelo modelo ora proposto. Outra abordagem possível seria utilizar outras técnicas de transformação de séries temporais em imagens, a exemplo de Markov Transition Field, buscar um valor adequado de limiar para aplicação de TRP no problema em questão, e também utilizar simultaneamente diferentes técnicas de transformação de séries temporais em imagens em uma mesma rede, a exemplo do proposto por Ahmad, Tabassum, Guan e Khan (2021).

REFERÊNCIAS

- AGGA, A.; ABBOU, A.; LABBADI, M.; EL HOUM, Y. Convolutional Neural Network (CNN) Extended Architectures for Photovoltaic Power Production Forecasting. **International Conference on Smart Grid and Clean Energy Technologies (ICSGCE)**, n. 9, 2021, Sarawak, Malaysia, p. 104-108.
- AGOUA, X. G.; GIRARD, R.; KARINIOTAKIS, G. Short-term spatio-temporal forecasting of photovoltaic power production. **IEEE Transactions on Sustainable Energy**, v. 9, n. 2, p. 538–546, 2018.
- AHMAD, Z.; TABASSUM, A.; GUAN, L.; KHAN, N. M. ECG Heartbeat Classification Using Multimodal Fusion. **IEEE Access**, v. 9, p. 100615-100626, 2021.
- AHMED, R. et al. A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 124, p. 109792, 2020.
- ALKHAYAT, G.; MEHMOOD, R. A review and taxonomy of wind and solar energy forecasting methods based on deep learning. **Energy and AI**, Elsevier, p. 100060, 2021.
- ANDRADE, V. B. et al. Modelagem e simulação de cenários da operabilidade de uma mini rede híbrida com geração fotovoltaico-diesel, armazenamento de energia conectada à rede elétrica. *In: Congresso Brasileiro de Planejamento Energético*. nº 12, 2020.
- ANTONANZAS, J.; OSORIO, N.; ESCOBAR, R.; URRACA, R.; MARTINEZ-DE PISON, F. J.; ANTONANZAS-TORRES, F. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, p. 78–111, jul. 2016.
- BAKER, G. L.; GOLLUB, J. P. **Chaotic Dynamics: an introduction**. New York: Cambridge University Press, 1996. 182 p.
- BALDOMINOS, A.; SAEZ, Y.; ISASI, P. Evolutionary convolutional neural networks: An application to handwriting recognition. **Neurocomputing**, v. 283, p. 38-52, 2018.
- BARRA, S. et al. Deep Learning and Time Series-to-Image Encoding for Financial Forecasting. **IEEE/CAA Journal of Automatica Sinica**, v. 7, nº 3, p. 693-692, 2020.
- BISHOP, C. M. **Pattern recognition and machine learning**. v. 4. n. 4. New York: Springer, 2006. 749 p.
- BORCHARDT, F. L. Neural Network Computing and Neural Language Processing. **Calico Journal**, v. 5, n. 4, p. 63-75, 1988.
- BOTTOU, L. Large-scale Machine Learning with Stochastic Gradient Descent. *In: International Conference on Computational Statistics*, nº 19, 2010, Paris.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4. ed. New Jersey: Wiley, 2008. 746 p.

BRACALE, A.; CARPINELLI, G.; FALCO, P. D. A probabilistic competitive ensemble method for short-term photovoltaic power forecasting. **IEEE Transactions on Sustainable Energy**, v. 8, n. 2, p. 551–560, 2017.

CASARIN, R. Brasil deverá acrescentar mais de 10 GW de energia solar em 2023. Portal Solar. 07 dezembro 2022. Disponível em: <https://www.portalsolar.com.br/noticias/operacao-e-expansao/oem/brasil-devera-acrescentar-mais-de-10-gw-de-energia-solar-em-2023>. Acesso em: 05 outubro 2023.

CHOLLET, F. et al. **Deep learning with Python**. 1. ed. New York: Manning, 2018. 313 p.

CHOW, S. K. H. et al. Short-term prediction of photovoltaic energy generation by intelligent approach. **Energy and Buildings**, v. 55, p. 660-667, dez. 2012.

CUI, S. et al. Residential virtual power plant with photovoltaic output forecasting and demand response. **Asian Journal of Control**, Wiley Online Library, 2019.

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010. 399 p.

DE ARAUJO, D. M. N. Filtragem de Ruído em Projeções de Tomossíntese **MAMÁRIA UTILIZANDO APRENDIZADO PROFUNDO**. 2021. 188 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Estadual Paulista, Rio Claro, 2021.

ECKMANN, J. P.; KAMPHORST, S. O.; RUELLE, D. Recurrence Plots of Dynamical Systems. **Europhysics Letters**, v. 4, p. 973-977, 1987.

EISBERG, R.; RESNICK, R. **Física Quântica: Átomos, Moléculas, Sólidos Partículas**. 9. ed. Rio de Janeiro: Editora Campus, 1994.

EMPRESA DE PESQUISA ENERGÉTICA, Balanço Energético Nacional 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2021>. Acesso em: 05 outubro 2023.

EMPRESA DE PESQUISA ENERGÉTICA, Balanço Energético Nacional 2022. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2022>. Acesso em: 05 outubro 2023.

EMPRESA DE PESQUISA ENERGÉTICA. Matriz Energética e Elétrica. Disponível em: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>. Acesso em: 05 outubro 2023.

FUKUSHIMA, K. Visual Feature Extraction by a Multilayered Network of Analog Threshold Elements. **IEEE Transactions on Systems Science and Cybernetics**, v. 5, n.º. 4, p. 322-333, out. 1969.

GERON, A. **Hands-on Machine Learning with Scikit-Learn, Keras & Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2. ed. Sebastopol: O'Reilly, 2019. 484 p.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. *In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND STATISTICS*. n° 30, 2010. p. 249-256.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. 1. ed. Massachusetts. MIT Press, 2016.

GREEN, M. A. et al. Solar cell efficiency tables (Version 60). **Progress in Photovoltaics: Research and Applications**. 2022; v. 30(7), p. 687- 701, jun. 2022.

HAN, J.; PEI, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. 3. ed. Waltham: Elsevier, 2011. 703 p.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Ontario: Pearson Education, 2009. 906 p.

HE, H. et al. A Power Forecasting Approach for PV Plant based on Irradiance Index and LSTM. *In: Chinese Control Conference*. n° 37, 2018.

HENRY, Y. Y. S.; ALDRICH, C.; ZABIRI, H. Detection and severity identification of control valve stiction in industrial loops using integrated partially retrained CNN-PCA frameworks. **Chemometrics Intell Lab Syst**, v. 206, p. 104-143, 2020.

HOSSAIN, M. S.; MAHMOOD, H. Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast. **IEEE Access**, v. 8, p. 172524-172533, out. 2020.

HUANG, R. et al. Forecast Method of Distributed Photovoltaic Power Generation Based on EM-WS-CNN Neural Networks. **Frontiers in Energy Research**, v. 10, 2022.

IOFFE, S.; SZEGEDY, C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING*. n° 32, 2015.

IPCC, 2022: **Climate Change 2022: Impacts, Adaptation, and Vulnerability**. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Löschke, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA.

IWANSKI, J.S.; BRADLEY, E. Recurrence plots of experimental data: to embed or not to embed? **Chaos**, v. 8, n. 4, p. 861–871, 1998.

KALOGIROU, Soteris A. **Engenharia de energia solar: processos e sistema**. 2. ed. Rio de Janeiro: Elsevier, 2016.

KINGMA, D. P.; BA, J. Adam: A Method for Stochastic Optimization. *In: INTERNATIONAL CONFERENCE FOR LEARNING REPRESENTATIONS*, n° 3, 2015, San Diego.

- LAZZERI, F. **Machine Learning for time series forecasting with Python®**. 1. ed. Indianapolis: Willey, 2021, 206 p.
- LECUN, Y. et al. Convolutional networks for images, speech, and time series. **The handbook of brain theory and neural networks**, v. 3361, n. 10, p. 255-258, 1998.
- LECUN, Y.; HAFFNER, P.; BOTTOU, L.; BENGIO, Y. Object recognition with gradient-based learning. **Shape, Contour and Grouping in Computer Vision**, Springer, p. 319–345, 1999.
- LEVA, S.; DOLARA, A.; GRIMACCIA, F.; MUSSETTA, M.; OGLIARI, E. Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. **Mathematics and Computers in Simulation**, v. 131, p. 88-100, 2017.
- LIM, S.-C.; HUH, J.-H.; HONG, S.-H.; PARK, C.-Y.; KIM, J.-C. Solar Power Forecasting Using CNN-LSTM Hybrid Model. **Energies**, v. 15, n. 21, p. 8233, nov. 2022.
- MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier nonlinearities improve neural network acoustic models. *In*: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, n° 30, 2013, p. 1–6.
- MEER, D. van der; MOULI, G. R. C.; MOULI, G. M.-E.; ELIZONDO, L. R.; BAUER, P. Energy management system with pv power forecast to optimally charge evs at the workplace. **IEEE Transactions on Industrial Informatics**, v. 14, n. 1, p. 311–320, jan. 2018.
- MELLIT, A.; PAVA, A. M. A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. **Solar Energy**, v. 84, p. 807-821, 2010.
- MINISTÉRIO DA DEFESA. Portaria DOM/DEC/C E x n° 061, de 2023. Disponível em: http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao%28ci%29/port_n_061_dec_13jan2023.html. Acesso em: 05 outubro 2023.
- MONTEIRO, C. et al. Short-Term Forecasting Models for Photovoltaic Plants: Analytical versus Soft-Computing Techniques. **Mathematical Problems in Engineering**, v. 2013, nov. 2013.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. New Jersey: Wiley, 2008. 445 p.
- POINCARÉ, H. Sur le problème des trois corps et les équations de la dynamique. **Acta Mathematica**, v. 13, n. 1, p. A3-A270, 1890.
- QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. **Energy**, v. 148, p. 461-468, fev. 2018.
- ROSENBLATT, F. The Perceptron: A probabilistic Model for Information Storage and Organization in the Brain. **Psychological Review**, v. 65, n° 6, 1958.
- SCHIERMEIER, Q.; TOLLEFSON, Jeff.; SCULLY, T.; WITZE, A.; MORTON, O. Electricity Without Carbon. **Nature**. 2008, p. 454-816.

SIAMI-NAMINI, S.; TAVAKOLI, N.; SIAMI NAMIN, A. A Comparison of ARIMA and LSTM in Forecasting Time Series, *In: IEEE International Conference on Machine Learning and Applications (ICMLA)*, nº 17, 2018, Orlando, p. 1394-1401.

SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. **Applied Soft Computing**, v. 97, parte B, dez. 2020.

SMESTAD, Greg P. *Optoelectronics of Solar Cells*. 1. ed. Bellingham: SPIE, 2002. 118 p.

SMIL, V. Distributed Generation and Megacities: Are Renewables the Answer?, **IEEE Power and Energy Magazine**, Nova York, vol. 17, n. 2, p. 37-41, mar. 2019.

SRIVASTAVA, N. et al. Dropout: A simple Way to Prevent Neural Networks from Overfitting. **Journal of Machine Learning Research**, v. 15, p. 1929-1958, 2014.

SUNBANK. Sunbank Solar Panel Breakdown. Disponível em: <https://mysunbank.com.au/pv-solar/solarpanel-howitsmade>. Acesso em: 05 outubro 2023.

SURESH, V. et al. Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. **Energies**, v. 13, 2020.

SURESH, V.; JANIK, P.; REZMER, J.; LEONOWICZ, Z. Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. **Energies**, v. 13, n. 3, p. 723, fev. 2020.

TABORA, J. M. et al. Hybrid System Assessment in On-Grid and Off-Grid Conditions: A Technical and Economical Approach. **Energies**, v. 14, 2021.

TOVAR, M.; ROBLES, M.; RASHID, F. PV Power Prediction, Using CNN-LSTM Hybrid Neural Network Model. Case of Study: Temixco-Morelos, México. **Energies**, 13, n. 24, p. 6512, dez. 2020.

UNITED NATIONS, The 2030 Agenda and the Sustainable Development Goals: An opportunity for Latin America and the Caribbean (LC/G.2681-P/Rev.3), Santiago, 2018.

VILLALVA, M. G. **Energia Solar Fotovoltaica: conceitos e aplicações**. 1. ed. São Paulo: Érica, 2012. 224 p.

WANG, G.; SU, Y.; SHU, L. One-day-ahead daily power forecasting of photovoltaic systems based on partial functional linear regression models. *Renewable Energy*, v. 96 parte A, p. 469-478, out. 2016.

WANG, Z. G.; OATES, T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks. *In: AAAI Conf. Artificial Intelligence*. nº 29, 2015.

WENHAM, S. R. et al. **Applied photovoltaics**. 2 ed. Australia: Centre for Photovoltaic Engineering of UNSW, 2009.

ZHANG, J. et al. Deep Photovoltaic Nowcasting. **Solar Energy**, v. 176, p. 267-276, 2018.

ZHOU, Y.; CHELLAPPA, R. (1988). Computation of optical flow using a neural network. **Neural Networks**, 1988., IEEE International Conference on, p. 71–78.