



Trabalho de Conclusão de Curso

Previsão de geração fotovoltaica a partir de dados meteorológicos utilizando rede LSTM

de Ícaro Gabriel Paiva Bastos

orientado por

Prof. Dr. Ícaro Bezerra Queiroz de Araújo

Universidade Federal de Alagoas
Instituto de Computação
Maceió, Alagoas
24 de Julho de 2020

UNIVERSIDADE FEDERAL DE ALAGOAS
Instituto de Computação

PREVISÃO DE GERAÇÃO FOTOVOLTAICA A PARTIR DE DADOS METEOROLÓGICOS UTILIZANDO REDE LSTM

Trabalho de Conclusão de Curso submetido
ao Instituto de Computação da Universidade
Federal de Alagoas como requisito parcial
para a obtenção do grau de Engenheiro de
Computação.

Ícaro Gabriel Paiva Bastos

Orientador: Prof. Dr. Ícaro Bezerra Queiroz de Araújo

Banca Avaliadora:

Erick de Andrade Barboza	Prof. Dr., IC-UFAL
Davi Bibiano Brito	Prof. Dr., IC-UFAL
Tiago Figueiredo Vieira	Prof. Dr., IC-UFAL

Maceió, Alagoas
24 de Julho de 2020

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 - 1767

B327p Bastos, Ícaro Gabriel Paiva.

Previsão de geração fotovoltaica a partir de dados meteorológicos utilizando rede LSTM / Ícaro Gabriel Paiva Bastos. – 2020.

40 f. : il.

Orientador: Ícaro Bezerra Queiroz de Araújo.

Monografia (Trabalho de conclusão de curso em Engenharia de Computação) - Universidade Federal de Alagoas, Instituto de Computação. Maceió, 2021.

Bibliografia: f. 38-40.

1. Energia solar fotovoltaica. 2. *Long Short-Term Memory*. 3. Curto prazo. I. Título.

CDU:004.33+ 620.91

Dedicatória

À minha família, professores e colegas de classe.

Agradecimentos

Primeiramente a Deus por todas as bênçãos e graças derramadas em toda a minha vida;

À Nossa Senhora, mãe de Jesus, por sua fiel intercessão;

À minha família, em especial a minha mãe Maria de Lourdes, ao meu pai Jose Nilton e ao meu irmão Yann Victor. Por terem feito de tudo para que esse sonho pudesse se tornar realidade;

À minha avó Clemilda Paiva, *in memoriam*, e ao meu tio Lauro, *in memoriam*, que não puderam estar presente no fim dessa caminhada mas enquanto estiveram não mediram forças para me ajudar. A minha eterna gratidão;

Ao meu orientador Prof. Dr. Ícaro Bezerra Queiroz de Araújo, que me auxiliou em tudo que foi necessário para conclusão desse trabalho, buscando sempre o meu crescimento profissional e pessoal.

Aos professores Prof. Dr. Davi Bibiano, Prof. Dr. Thiago Cordeiro, Prof. Dr. Erick Barboza e Prof. Dr. Tiago Vieira, que enriqueceram de forma inenarrável a minha formação acadêmica.

À minha namorada Claudijane Matos que esteve sempre comigo me apoiando e acreditando no meu sucesso profissional;

À família EJC, que esteve ao meu lado todo esse tempo fortificando a minha fé em Deus;

Aos meus companheiros de classe Felipe Crispim, Cesar Augusto, Gustavo Costa, Leony Oliveira, Wagner Filho, Allan Amaro, Diego Oliveira e Joicy Soares;

11 de Junho de 2020, Maceió - AL

Quem é o vencedor do mundo senão aquele que crê que Jesus é o filho de Deus?

1 Jo 1,5

Resumo

A natureza estocástica e não linear das condições climáticas, tais como radiação solar, temperatura ambiente, velocidade do vento, influencia diretamente a geração de energia fotovoltaica. Além disso, a estimação da quantidade de energia gerada é de suma importância para a qualidade da produção, podendo evitar problemas na rede elétrica. Com base nessa problemática, este trabalho apresenta uma aplicação de redes LSTM (*Long Short-Term Memory*) para previsão de dados de geração (potência) em painéis fotovoltaicos a partir da utilização de dados meteorológicos. Os dados foram coletados a partir de uma estação solarimétrica de baixo custo próxima a usina de produção. As informações obtidas pela estação incluem: radiação solar, temperatura dos painéis, temperatura ambiente, umidade, velocidade do vento, quantidade de chuva, tensão e corrente. Estas informações são utilizadas para alimentar a rede neural cuja função é a previsão de um vetor correspondente aos próximos segundos de potência gerado pelos painéis solares da usina de produção. Os resultados mostraram que a rede LSTM apresenta bons valores de estimação com erros médio absolutos baixos.

Palavras-chave: Energia Solar Fotovoltaica; LSTM; Previsão de Curto Prazo.

Abstract

The stochastic and nonlinear nature of some meteorological factors, such as the local solar radiance, ambient temperature, wind speed, directly influence photovoltaic energy generation. Furthermore, estimating the produced energy amount is fundamentally important to production quality, which can avoid problems on the electrical network. Based on this problem, this article presents an application of LSTM (LongShort-Term Memory) networks for forecasting generation (power) data on photovoltaic panels using meteorological data. The data were collected from a low-cost solarimetric station close to the production plant. The obtained information includes solar radiance, panels temperature, ambient temperature, humidity, wind speed, rain amount, voltage, and current. It is used to feed a neural network, whose function is the prediction of the next five seconds of power produced by the solar panels. Results show that the LSTW Network presents good estimation values, having a low mean absolute error for each second.

Keywords: Photovoltaic Solar Energy; LSTM; Short-term Forecast.

Lista de Figuras

2.1	Representação simplificada do neurônio biológico.	18
2.2	Comparação entre o neurônio biológico e o computacional.	19
2.3	Rede neural artificial do tipo MLP.	20
2.4	Rede recorrente simples.	21
2.5	Unidade básica de composição de uma rede LSTM.	21
2.6	Desempenho da rede neural com <i>overfitting</i> e <i>underfitting</i>	23
3.1	Fotos da estação solarimétrica e dos painéis solares instalados na UFAL. . .	25
4.1	Séries temporais das variáveis tensão, corrente e potência.	28
4.2	Gráfico de correlação entre as variáveis meteorológicas e a variável de geração fotovoltaica.	29
4.3	Divisão da base de dados.	29
4.4	Arquitetura da rede neural desenvolvida para o presente trabalho.	30
4.5	Etapas do processo de validação cruzada.	31
5.1	Média do erro em função do número de células na camada LSTM.	34
5.2	Média do erro de treinamento e validação em função do número de épocas de treinamento.	34
5.3	<i>Boxplot</i> referente ao erro absoluto da variável potência.	35
5.4	Valores reais da potência(linha vermelha), e previstos pela rede (linha pon- tilhada azul), em função da hora do dia da base de teste [Fonte: Própria]. .	36
5.5	Gráficos de dispersão dos erros absolutos referentes as previsões de um segundo e cinco segundos da potência.	36

Lista de Tabelas

1.1	Trabalhos relacionados que utilizam RNA para prever dados de produção de energia solar fotovoltaica.	16
3.1	Valores máximo e mínimo das variáveis meteorológicas medidas no SI. . . .	26
3.2	Valores máximo e mínimo das variáveis de geração fotovoltaica medidas no SI.	26
5.1	Erro absoluto médio de cada segundo do vetor de potência previsto.	35
5.2	Desvio padrão do erro absoluto referente a cada segundo do vetor de saída da rede LSTM.	37

Lista de Símbolos

w_{kj} matriz de pesos do neurônio j .

σ Função de ativação sigmoide.

\odot produto elemento-a-elemento.

Lista de Abreviaturas

RNA *Artificial Neural Networks*

MLP *Multilayer Perceptron*

RNN *Recurrent Neural Network*

LSTM *Long Short-Term Memory*

DRNN *Doubly-Recurrent Neural Networks*

GM *Gamma Memory*

RPM *Revolutions per minute*

Sumário

1	Introdução	14
1.1	Motivação	14
1.2	Objetivos	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	17
1.3	Organização do Trabalho	17
2	Redes neurais artificiais	18
2.1	Perceptron	19
2.2	<i>Multilayer Perceptron</i>	19
2.3	Rede Neural Recorrente	20
2.3.1	LSTM	21
2.4	Processo de aprendizagem e validação cruzada	22
3	Estação Solarimétrica	24
3.1	Variáveis meteorológicas	24
3.2	Variáveis de geração fotovoltaica	26
3.3	Base de dados	26
4	Metodologia	27
4.1	Divisão da base de dados	28
4.2	Construção da rede neural	29
4.3	Treinamento e teste	30
5	Resultados	33
6	Conclusão	38
	Conclusão	38
	Bibliografia	39

Capítulo 1

Introdução

1.1 Motivação

O aumento da busca por energia elétrica a partir de fontes renováveis e a preocupação pela diversificação da matriz energética, além da progressiva demanda por energia elétrica, têm incentivado a pesquisa de tecnologias que aproveitam recursos naturais de maneira mais eficiente.

A energia emitida pelo Sol em forma de radiação é a principal fonte de energia da Terra e pode ser aproveitada em inúmeras aplicações. Nesse cenário, é possível destacar a produção de energia elétrica por meio de sistemas fotovoltaicos e a energia térmica através de sistemas heliotérmicos.

Considerando a crescente inserção da geração distribuída, em especial a fotovoltaica, o desenvolvimento de modelos de previsão representa um requisito essencial para apoiar o alto grau de compartilhamento de fontes renováveis com as fontes tradicionais como a hidroelétrica. Um modelo de predição que lide com a natureza estocástica e a variabilidade de fontes renováveis é importante para garantir a segurança e confiabilidade da rede elétrica. Em especial, a previsão da geração de energia fotovoltaica em sistemas de micro e minigeração apresentam desafios adicionais para as distribuidoras de energia elétrica, as quais precisam implementar um controle integrado dos fluxos de energia entre cargas e fontes. Neste cenário, previsões mais precisas propiciam menores riscos de restrição no fornecimento de energia elétrica e, conseqüentemente, geram maior confiabilidade nesta fonte de produção.

De acordo com [Guarnieri et al., 2007] e [Machado and Rampinelli, 2018], a previsão da quantidade de energia produzida também contribui para o gerenciamento da transmissão e distribuição de energia na rede elétrica, uma vez que, a radiação solar aquece os cabos, originando perdas de energia. É nesse contexto que a previsão da irradiância e outros dados meteorológicos se tornam importantes para o aproveitamento da energia solar, dado que, a partir desta é possível estimar quanto de energia elétrica será produzida

e, ainda, no caso de sistemas conectados à rede, quanto será injetado ou consumido da mesma.

Segundo [Diaz, 2014] e [Rihbane, 2014], atualmente há uma série de métodos matemáticos e computacionais que podem ser empregados para estimativa de curto prazo de produção de energia elétrica com base em alguns dados meteorológicos, tais como os modelos de regressão linear e não linear, redes neurais artificiais, entre outros. Tais modelos matemáticos de previsão são úteis em diversas etapas da cadeia de produção, desde o projeto de novas usinas até a etapa de auxílio para o inversor de maneira a garantir uma maior eficiência de produção.

Dentre esses estudos, pode-se citar o trabalho de [Sabino et al., 2018], no qual é feito um levantamento das várias técnicas utilizadas para prever dados relativos à produção de energia solar. Ainda neste estudo, são utilizados modelos autorregressivos para se prever a temperatura das células fotovoltaicas.

Os métodos de previsão baseados em séries temporais precisam de dados de medições históricas de geração de energia, para que, a partir destes dados, sejam capazes de prever dados futuros. Contudo, o desempenho de um sistema fotovoltaico conectado à rede depende fortemente das condições climáticas do local de instalação do sistema [Cantor, 2017]. Portanto, para uma previsão realista dos dados de geração futura de um sistema fotovoltaico é preciso considerar os dados climáticos.

Ainda no contexto da previsão de dados relacionados a processos de produção de energia solar, uma ferramenta que pode ser destacada é a utilização de redes neurais artificiais (RNAs) para previsão de potência produzida por painéis fotovoltaicos, ou para previsão de dados climáticos relacionados. A Tabela 1.1 traz um resumo de algumas pesquisas desenvolvidas utilizando RNAs para modelar alguma característica relacionada à produção de energia solar fotovoltaica.

A pesquisa desenvolvida por [Lo Brano et al., 2014], estudou o desempenho de três diferentes tipos de redes neurais como modelo de previsão da potência gerada por painéis fotovoltaicos. Para treinar as redes foram utilizadas como entradas quatro variáveis climáticas: temperatura do ar, irradiância solar, velocidade do vento e temperatura dos painéis fotovoltaicos. E duas variáveis referentes às características dos painéis utilizados, sendo elas: tensão de circuito aberto e corrente de curto circuito. Todas estas variáveis foram capturadas por um sistema de monitoramento climático local que possui uma taxa amostral de trinta minutos.

O trabalho realizado por [Arshi et al., 2019], desenvolveu um estudo no qual utiliza 21 variáveis meteorológicas como entrada em uma rede neural recorrente do tipo LSTM. Este modelo conseguiu fazer a previsão da tensão, corrente, potência e energia geradas por subestações de baixa voltagem e instalações domésticas com alta capacidade de geração fotovoltaica.

Dentre as diversas pesquisas desenvolvidas a que mais se assemelha ao presente tra-

Tabela 1.1: Trabalhos relacionados que utilizam RNA para prever dados de produção de energia solar fotovoltaica.

Trabalhos	Modelo	Variáveis de entrada	Variáveis de saída
[Atsushi Yona et al., 2008]	RNN	Irradiância, temperatura e irradiância atmosférica	potência, irradiância
[Mellit and Pavan, 2010]	MLP	Irradiância, temperatura ambiente	Irradiância
[Lo Brano et al., 2014]	MLP, RNN e GM	temperatura do ar, irradiância solar, velocidade do vento, temperatura dos painéis fotovoltaicos, tensão de circuito aberto e corrente de curto circuito.	Potência
[Alzahrani et al., 2017]	DRNN	Irradiância	Irradiância
[Zhang et al., 2018]	LSTM	Temperatura ambiente, temperatura do painel, irradiância, entre outras	Potência
[De et al., 2018]	LSTM	Temperatura ambiente, temperatura do painel, irradiância, potência, energia acumulada	Potência
[He et al., 2018]	LSTM	Irradiância	Potência
[Arshi et al., 2019]	LSTM	Temperatura ambiente, temperatura do painel, irradiância, velocidade do vento, entre outras	Potência, corrente, tensão e energia
[Abdel and Mahmoud, 2019]	LSTM	Potência	Potência

balho foi feito por [De et al., 2018], na qual foi utilizada uma rede neural recorrente do tipo LSTM para prever a potência dos painéis fotovoltaicos. A principal diferença entre os trabalhos está na quantidade de variáveis climáticas utilizadas como entrada. Diferentemente de [De et al., 2018], neste trabalho não foi utilizada a energia acumulada, porém foi acrescentada, como variável de entrada, a umidade relativa do ar e a velocidade do vento.

Tendo em vista a importância de modelos de previsão na produção de geração elétrica, o presente trabalho utiliza uma rede neural recorrente do tipo LSTM para prever eventos que provocam danos na rede de geração fotovoltaica, e que por fim possa ser utilizado por empresas distribuidoras de energia.

1.2 Objetivos

1.2.1 Objetivo Geral

Com base no exposto, o presente trabalho tem como objetivo avaliar o desempenho da utilização de redes neurais recorrentes do tipo LSTM aplicadas para previsão de um horizonte de cinco segundos da geração de potência elétrica produzida por painéis fotovoltaicos.

1.2.2 Objetivos Específicos

- Construção de rede neural recorrente LSTM como modelo de previsão da geração elétrica a partir de dados meteorológicos;
- Previsão de um horizonte de até cinco segundos à frente;
- Avaliação do desempenho da rede recorrente LSTM em diferentes cenários.

1.3 Organização do Trabalho

Este trabalho encontra-se dividido nos seguintes capítulos: no Capítulo 2 é apresentado um embasamento teórico sobre rede neurais, mais especificamente as recorrentes. No Capítulo 3 são apresentadas algumas características da estação solarimétrica e da base de dados utilizada no trabalho. No Capítulo 4 é demonstrada a metodologia desenvolvida neste trabalho. No Capítulo 5 são expostos os resultados obtidos. Finalmente, no Capítulo 6 são apresentadas as discussões finais sobre o trabalho.

Capítulo 2

Redes neurais artificiais

Com o avanço do poder de processamento computacional e a consolidação das técnicas na área de aprendizagem de máquina, diversos problemas de classificação e regressão são resolvidos de maneira simples, rápida e satisfatória. Dentre as metodologias utilizadas na área de aprendizagem de máquina, uma que tem se destacado é a rede neural artificial, devido a sua capacidade de solucionar problemas complexos e não-lineares. Segundo [Haykin, 2007], a rede neural artificial é um processador paralelamente distribuído formado por unidades simples de processamento, o qual é capaz de adquirir conhecimento e armazená-lo para uso futuro.

As primeiras redes neurais artificiais surgiram na tentativa de modelar a maneira como o cérebro realiza a tarefa de aprendizado e resolve problemas complexos [Haykin, 2007]. O cérebro e o sistema nervoso central são compostos em parte por neurônios. A Figura 2.1 ilustra, de forma simplificada, a composição de um neurônio biológico. Tais células tem na extremidade os dendritos, os quais tem a função de receber os impulsos elétricos provenientes de outros neurônios, que, por sua vez, são transmitidos pelo corpo celular até os axônios. Estes, através das sinapses, podem impor ao neurônio receptivo a excitação ou inibição de um determinado estímulo.

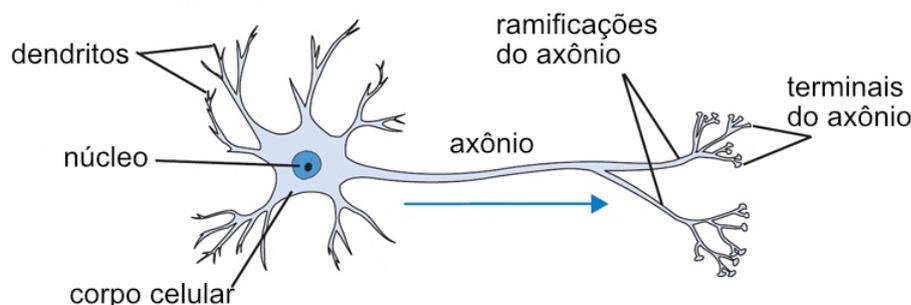


Figura 2.1: Representação simplificada do neurônio biológico.
[Fonte: Google Imagens.]

2.1 Perceptron

O perceptron é considerado o primeiro modelo de neurônio computacional e sua estrutura consiste em um componente denominado Perceptron, ou porta de limiar, inspirado no funcionamento do neurônio biológico. A Figura 2.2 compara o neurônio biológico com o perceptron, onde os impulsos elétricos, x_1 e x_2 , são os sinais de entrada, e que por sua vez, são multiplicados por seus respectivos pesos, w_1 e w_2 . Essas multiplicações são combinadas linearmente através de um somatório (2.1).

$$u_k = \sum_{j=1}^m w_{kj}x_j \quad (2.1)$$

O resultado, u_k , é somado com o *bias*, b_k , e por fim a soma é utilizada como entrada na função de ativação ϕ , Equação (2.2), no qual a saída, y_k , é o resultado do neurônio. A limitação do Perceptron consiste no fato de apenas classificar dados que são linearmente separáveis.

$$y_k = \phi(u_k + b_k) \quad (2.2)$$

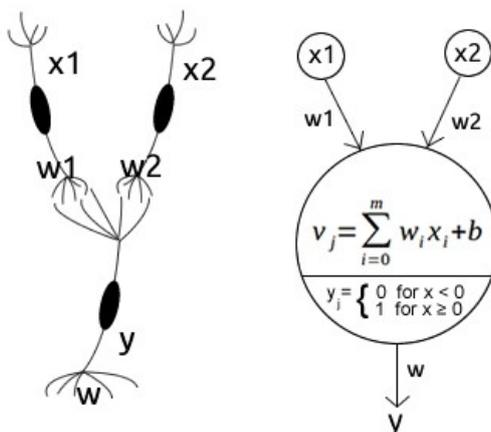


Figura 2.2: Comparação entre o neurônio biológico e o computacional.
Fonte: [Grübler, 2018].

2.2 Multilayer Perceptron

Unir vários neurônios perceptron em uma camada e interligar várias destas camadas, de forma que o neurônio em qualquer camada está conectado a todos os neurônios da camada anterior, forma então a Rede Neural Artificial *MultiLayer Perceptron* (MLP). A Figura 2.3 mostra que a MLP pode conter uma ou mais camadas intermediárias de neurônios, estas por sua vez são chamadas de camadas ocultas, e que seu fluxo de sinal

atravessa a rede da esquerda para direita e de camada em camada. Essa nova topologia de rede possui a capacidade de resolver problemas não lineares como: classificação de sons cardíacos [Gupta et al., 2007], detecção facial e [Shilbayeh and Al-Qudah, 2010], previsão da irradiância solar [Mellit and Pavan, 2010].

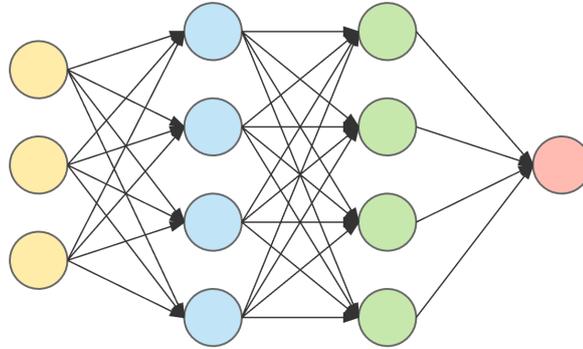


Figura 2.3: Rede neural artificial do tipo MLP.
Fonte: Google Imagens.

2.3 Rede Neural Recorrente

Em aplicações relacionadas a séries temporais, são utilizadas as redes recorrentes. Estas redes compartilham parâmetros (pesos) ao longo de informações sequenciais, o que reduz a quantidade de elementos necessários se comparada a rede tradicional MLP. A recorrência é implementada de tal forma que o estado oculto \bar{h}_t em cada camada no instante de tempo t depende não somente da entrada \bar{x}_t como também do estado anterior, de maneira que, com o uso da tangente hiperbólica como função de ativação, tem-se a função descrita pela Equação 2.3.

$$\bar{h}_t = \tanh(W_{xh}\bar{x}_t + W_{hh}\bar{h}_{t-1}) \quad (2.3)$$

e a saída é estimada pela Equação 2.4.

$$\bar{y}_t = W_{hy}\bar{h}_t \quad (2.4)$$

Como ilustrado na Figura 2.4. Destaca-se ainda que os pesos são compartilhados para os diferentes instantes de tempo t , incorporando memória à topologia e tornando-a capaz de recordar contexto temporal. O contexto temporal faz com que as redes neurais recorrentes adquiram representações de estados, estes, por sua vez, possuem a capacidade de conectar informações passadas à tarefa atual, ou seja, as saídas passadas influenciam diretamente na saída atual da rede.

Esta característica tem levado as redes recorrentes a serem muito usadas nos problemas de previsões não lineares, tendo até um desempenho melhor do que os métodos

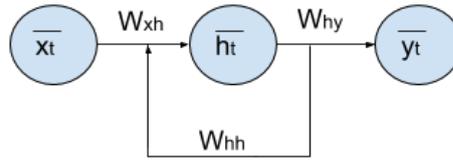


Figura 2.4: Rede recorrente simples.
Modificado de: [Bastos et al., 2020].

matemáticos de previsão [Yu et al., 2019].

2.3.1 LSTM

Ao lidar com sequências longas, a rede recorrente simples sofre com a dissipação ou, em contraste, a saturação do gradiente durante o processo de retro-propagação temporal, tornando-a incapaz de atualizar os pesos correspondentes aos estados no início da sequência. Visando amenizar tal limitação, a rede *Long Short-Term Memory*, Figura 2.5, permite a propagação da informação em longas sequências através de variáveis de esquecimento, \bar{f} , e atualização \bar{i} .

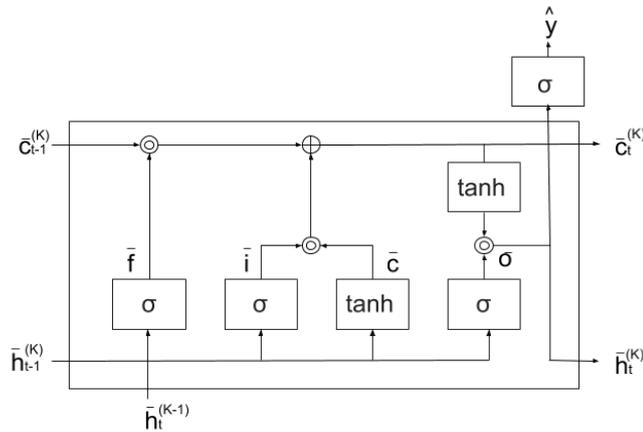


Figura 2.5: Unidade básica de composição de uma rede LSTM.
Modificado de: [Bastos et al., 2020].

Assim têm-se que a cada passo de tempo, t , essas variáveis interferem na decisão de esquecer, aproximar a zero, ou incrementar, adicionar às camadas escondidas, a informação atual no momento t como demonstra a Equação 2.5

$$\bar{c}_t^{(k)} = \bar{f} \odot \bar{c}_{t-1}^{(k)} + \bar{i} \odot \bar{c} \quad (2.5)$$

onde t é o instante de tempo na sequência; k corresponde ao índice da camada escondida; \odot representa produto elemento-a-elemento.

A célula LSTM é formada por três portões, *gates*, onde cada um tem a sua função específica, as Equações 2.6 e 2.7 mostram os elementos que os constituem, no qual \bar{h} é a concatenação de $\bar{h}_t^{(k-1)}$ e $\bar{h}_{t-1}^{(k)}$; W^k é a matriz de peso; σ denota a função sigmoide e \tanh é a função da tangente hiperbólica. O primeiro portão é o do esquecimento, \bar{f} , este é responsável por remover informações que não são importantes, enquanto que o produto das variáveis, \bar{i} e \bar{c} , formam o portão de entrada que tem a função de adicionar novas informações para a célula.

$$\bar{i}, \bar{f}, \bar{o} = \sigma(W^k \bar{h}), \quad (2.6)$$

$$\bar{c} = \tanh(W^{(k)} \bar{h}) \quad (2.7)$$

Por fim, o último portão tem o objetivo calcular a saída, \hat{y}_t , correspondente da célula atual e para tal utiliza-se das Equações 2.8 e 2.9 respectivamente.

$$\bar{h}_t^{(k)} = \bar{o} \odot \bar{c}_t^{(k)} \quad (2.8)$$

$$\hat{y}_t = \sigma(\bar{h}_t^{(k)}) \quad (2.9)$$

De fato, redes LSTM mostram-se superiores as redes convencionais e as redes recorrentes simples, isto ocorre devido à sua capacidade de lembrar de padrões por grandes períodos de tempo fazendo com que a previsão atual esteja inserida em um contexto temporal. Neste trabalho a rede LSTM é utilizada para realizar a previsão da potência usando como dados de entrada parâmetros climáticos coletados a partir de uma estação solarimétrica descrita na próxima seção.

2.4 Processo de aprendizagem e validação cruzada

Uma das grandes vantagens da rede neural artificial é a capacidade de aprender a partir de estímulos do ambiente no qual está inserido. Essa aprendizagem ocorre através de um processo iterativo de ajustes nos seus pesos sinápticos [Haykin, 2007]. A forma como esses pesos vão ser atualizados depende do algoritmo de aprendizagem escolhido, mas é comum para todos a utilização de uma base de treinamento, na qual os dados serão utilizados para encontrar a configuração que minimize o erro da rede.

Cada amostra da base de treinamento consiste em um sinal de entrada e uma resposta esperada, estas amostras são apresentadas a rede para que os pesos sejam atualizados a fim de minimizar a diferença entre a resposta desejada e a resposta prevista pela rede. O processo é repetido até que a rede convirja para um estado estável, este estado é alcançado quando a rede possui uma generalização satisfatório sobre amostras que não estavam presente no processo de aprendizagem.

Um das dificuldades das redes neurais consiste no fato de assegurar que o aprendi-

zado tenha sido satisfatório, evitando problemas como o *overfitting* ou o *underfitting*. A Figura 2.6a mostra que o *underfitting* ocorre quando os parâmetros da rede generalizam demais os dados, tendo sempre uma predição muito longe do valor real. Enquanto que no *overfitting* a rede aprende tão bem sobre os dados de treinamento que não tem a capacidade de generalizar, fazendo que, ao testar a rede com novas amostras, o erro de predição seja elevado, como mostra a Figura 2.6b.

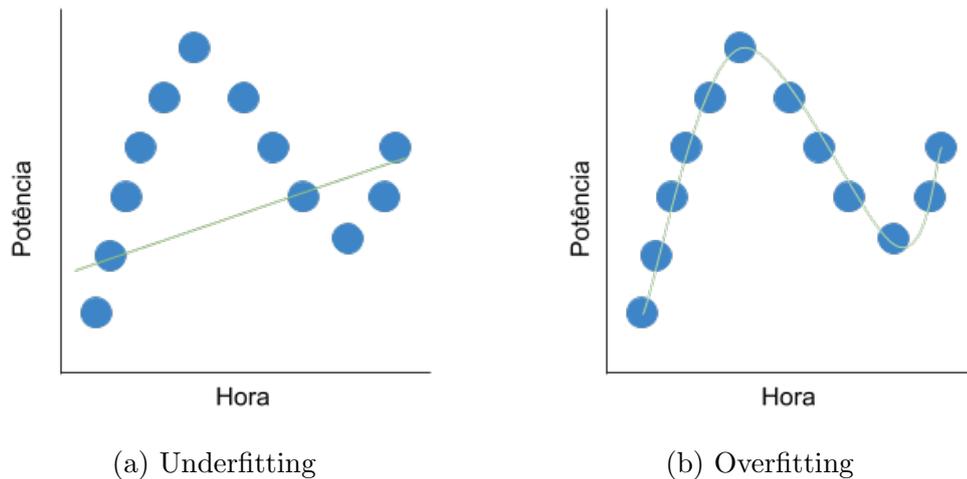


Figura 2.6: Desempenho da rede neural com *overfitting* e *underfitting*.

Para avaliar a capacidade de generalização e verificar se o modelo está preparado para trabalhar com novos dados, pode ser utilizada alguma técnica de validação cruzada durante o treinamento do modelo. Entre as técnicas existentes pode-se citar o *K-Fold*, que consiste na divisão da base de treinamento em K *folds* distintos e cada *fold* será utilizado em algum momento como conjunto de teste, isto é, o algoritmo de aprendizagem será executado K vezes e a cada interação $(K-1)$ *folds* será usado para treinar a rede e o um *fold* para validar os parâmetros encontrados [Bengio and Grandvalet, 2004]. Por fim o erro é calculado através da média dos erros de cada interação.

Capítulo 3

Estação Solarimétrica

Os parâmetros climáticos, como a irradiância solar no plano do gerador fotovoltaico e a temperatura ambiente, podem melhorar a precisão da previsão quando medições reais são usadas como dados de entrada para prever a potência de saída do sistema fotovoltaico. Além disso, a velocidade do vento e temperatura dos painéis também têm uma influência relevante nas previsões de energia fotovoltaica, levando a estimativas mais precisas.

Os dados utilizados neste trabalho foram obtidos a partir de uma estação solarimétrica de baixo custo localizada na Universidade Federal de Alagoas, Campus A.C Simões, como mostra a figura 3.1a. A figura 3.1b mostra um pequeno arranjo fotovoltaico composto por 4 painéis solares de 250Wp que está instalado ao lado da estação. A estação é capaz de capturar dez variáveis, sendo oito referentes a dados meteorológicos e duas referentes a geração fotovoltaica. Todos esses dados são obtidos com uma taxa de amostragem de um segundo, o que pode facilitar o trabalho dos métodos de previsão orientados a dados, como o caso da LSTM, que tendem a ter desempenho diretamente proporcional à quantidade de dados utilizados. É importante destacar que esta estação foi construída utilizando materiais e sensores de baixo custo, sem perda de qualidade, visando assim, diminuir o impacto financeiro na aquisição de uma estação semelhante para ser utilizada em um conjunto diferente de painéis solares.

As variáveis meteorológicas medidas e utilizadas são: temperatura ambiente, temperatura do painel fotovoltaico, pressão atmosférica, umidade, irradiância, quantidade de chuva acumulada, velocidade e direção do vento. Já os dados da geração fotovoltaica são: tensão e corrente do módulo fotovoltaico.

3.1 Variáveis meteorológicas

As variáveis meteorológicas apresentam comportamento estocástico e introduzem flutuações aleatórias na geração de energia fotovoltaica, assim a coleta precisa dos dados meteorológicos é fundamental na obtenção dos dados meteorológicos.



(a) Estação solarimétrica

(b) Paineis Soláres

Figura 3.1: Fotos da estação solarimétrica e dos painéis solares instalados na UFAL.

Para capturar a irradiância solar foi utilizado um piranômetro de baixo custo da empresa LuZdoSOL com intervalo de medição variando entre 0 e $1479W/m^2$. A medição de temperatura do módulo fotovoltaico é realizada através do sensor DS18B20 [Max, 2019], que possui um intervalo de leitura de $-55^{\circ}C$ a $125^{\circ}C$, entretanto a temperatura ambiente é medida através do barômetro BME280 da Bosch [Bos, 2019], que possui uma faixa de leitura entre $-40^{\circ}C$ e $85^{\circ}C$. As variáveis pressão e umidade são medidas através do mesmo barômetro utilizado na medição da temperatura ambiente, a escala de umidade varia entre 0% e 100%, e a pressão entre 300 hPa e 1100 hPa.

A velocidade do vento é medida através de um anemômetro modelo SV10. Este anemômetro utiliza o efeito Hall, o que permite a contagem de rotações dos copos em um período de tempo. A intensidade do vento é proporcional à velocidade de rotação do eixo. É possível estimar a velocidade do vento através das equações 3.1 e 3.2.

$$RPM = (ContadordePulsos * 60)/(Periodo/1000) \quad (3.1)$$

$$WindSpeed = (((4 * Raio * RPM)/60)/1000) * 3.6 \quad (3.2)$$

A direção do vento é medida através de um indicador de direção analógico. Por fim, o último parâmetro meteorológico capturado é a quantidade de chuva acumulada

monitorada por um pluviômetro. Como já citado anteriormente, a estação meteorológica foi inserida ao lado de um painel solar de maneira a apresentar dados climatológicos próximos aos presentes no painel.

3.2 Variáveis de geração fotovoltaica

A tensão e corrente referentes a geração fotovoltaica são medidas através de transdutores da marca SECON [SEC, 2019]. O transdutor de tensão transforma uma tensão de entrada de 0 a 1000 V em uma tensão de saída de 0 a 5 V, enquanto o transdutor de corrente converte uma entrada de 0 a 10 A em uma saída de 0 a 5V. As leituras das saídas são feitas em intervalos de um segundo e anexadas as variáveis meteorológicas referentes a aquele instante. Portanto, ao fim de um dia existem 86400 medições contendo as variáveis meteorológicas e as variáveis de geração.

3.3 Base de dados

A base de dados possui um total de vinte e quatro dias, nos quais foram coletados em dias específicos nos meses de agosto a outubro. A quantidade de chuva acumulada e a direção do vento não foram utilizadas pois não possuem características de série temporal. A Tabela 3.1 mostra os valores máximo e mínimo de cada variável meteorológica em toda a base de dados, enquanto a tabela 3.2 é referente aos valores de tensão e corrente.

Tabela 3.1: Valores máximo e mínimo das variáveis meteorológicas medidas no SI.

	Temp. Ambiente	Temp. Painel	Irradiância	Umidade	Pressão	Velocidade
Máx	33,04 °C	54 °C	1456W/m ²	98%	1013 hPa	60 km/h
Min	19,36 °C	17 °C	0W/m ²	0%	1003 hPa	0 km/h

Tabela 3.2: Valores máximo e mínimo das variáveis de geração fotovoltaica medidas no SI.

	Tensão	Corrente
Máx	268 V	3,48 A
Min	0 V	0,014 A

Por fim a base de dados possui uma tabela com 2.073.600 linhas e oito colunas, sendo duas colunas referentes as variáveis de geração fotovoltaica e seis colunas pertencentes as variáveis meteorológicas.

Capítulo 4

Metodologia

Para desenvolver o presente trabalho, foi necessário submeter a base de dados por algumas etapas de tratamento. Na primeira etapa, foi verificado que durante o período da madrugada certas medições dos sensores de tensão e irradiância tiveram valores abaixo de zero, esses valores atípicos aconteceram devido a natureza analógica dos sensores e por causa da quase inexistência de tensão e irradiância nesse intervalo de tempo, para resolver esse problema os valores das medições foram substituídas por zero.

A segunda etapa constitui na substituição das variáveis de geração fotovoltaica, tensão e corrente, pela potência elétrica, no qual é obtida através da Equação (4.1)

$$P = V * I \quad (4.1)$$

A Figura 4.1 ilustra a justificativa pela qual foi necessária fazer essa transformação. Como pode ser observado, durante o período do início da manhã e ao anoitecer, a tensão apresenta uma elevada oscilação. Esta, por sua vez, é causada pelo inversor de potência ao tentar rastrear o ponto de máxima potência dos módulos fotovoltaicos. Porém, durante esse intervalo de tempo, as medições da variável corrente tem valores bem ínfimos, fazendo com que ao multiplicar com a tensão a oscilação seja minimizada e não tenha ênfase na série temporal da potência.

O próximo passo é a criação da matriz de correlação de Pearson para visualizar o grau de correlação entre as variáveis meteorológicas e a variável de geração fotovoltaica. Essa correlação é calculada através da Equação 4.2:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (4.2)$$

Em que \bar{X} e \bar{Y} são as médias de cada variável e o resultado r tem valor entre -1 e +1, no qual representa o grau de associação linear entre as duas variáveis. A Figura 4.2 mostra que as variáveis que possuem uma correlação positiva estão com as intersecções pintadas entre as cores azul e branco, aquelas que por sua vez tem correlação negativa estão pintadas

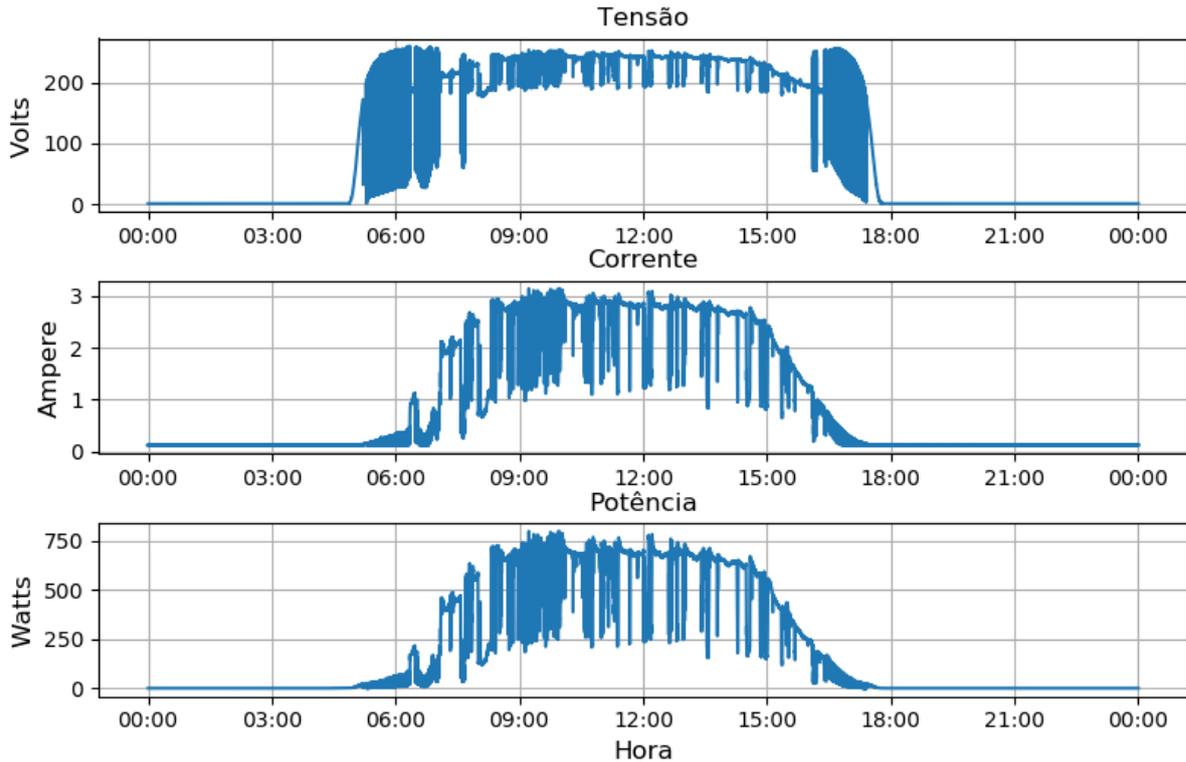


Figura 4.1: Séries temporais das variáveis tensão, corrente e potência.

entre as cores vermelho e branco, vale ressaltar que quanto mais escuro estiver maior é a correlação. Na matriz é possível notar que a variável pressão tem uma correlação baixa com as demais variáveis meteorológicas e praticamente nula com a potência gerada pelos painéis fotovoltaicos. Devido a sua baixa influência no sistema, a mesma foi retirada do banco de dados.

4.1 Divisão da base de dados

A base de dados foi dividida aleatoriamente em vinte três dias para base de treinamento e um dia para a base de teste, como o intervalo amostral é de apenas um segundo e um dia possui 86400 segundos, a base de treinamento ficou com um total de 1987200 amostras enquanto a base de treino com 86400 amostras.

A Figura 4.3 mostra que, além da divisão entre treino e teste, a base de treinamento foi repartida em oito *folds* distintos, no qual os sétimos primeiros *folds* ficaram com três dias, 259200 amostras, e o oitavo com dois dias, 172800 amostras. A intenção desses novos subconjuntos é permitir a utilização da técnica de validação cruzada, *K-fold*, enquanto a rede recorrente LSTM estiver sendo treinada.

A base de teste foi utilizada após o ajuste da configuração da rede LSTM durante o processo de validação cruzada. Fazendo isso, foi possível mostrar o desempenho da rede sobre dados que não foram utilizados durante o processo de treinamento e validação, simu-

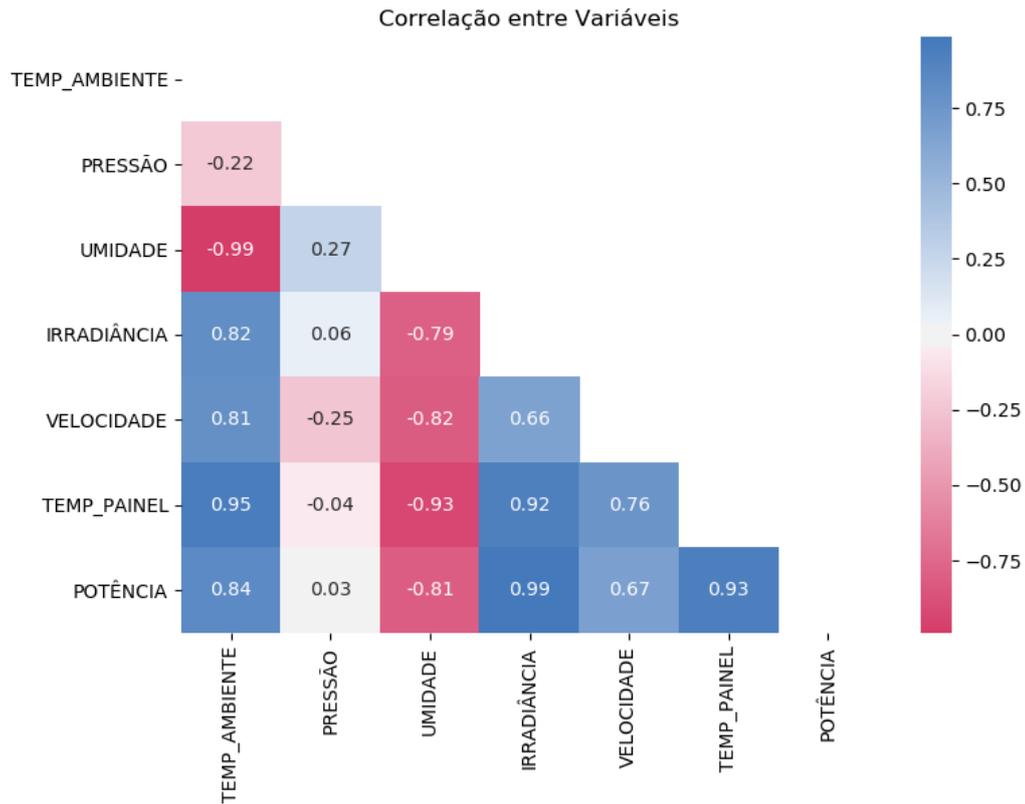


Figura 4.2: Gráfico de correlação entre as variáveis meteorológicas e a variável de geração fotovoltaica.



Figura 4.3: Divisão da base de dados.

lando também a atuação da rede em um cenário verdadeiro de monitoramento. A próxima seção destaca aspectos relativos a construção da estrutura da rede neural utilizada.

4.2 Construção da rede neural

Para a implementação da estrutura LSTM, foi escolhida a linguagem de programação Python 3.6, assim como as bibliotecas de código aberto: KERAS [Chollet et al., 2015] e scikit-learn [Buitinck et al., 2013] por possuírem um bom desempenho para implementação de redes neurais. Os códigos implementados estão disponíveis no repositório¹

A Figura 4.4 mostra a estrutura da LSTM utilizada neste trabalho. A entrada da rede é uma janela de tempo de 20 segundos, onde cada valor de entrada X é constituído

¹Disponível em <https://github.com/EngIcaro/tcc>

pelos valores de leitura dos sensores meteorológicos naquele segundo, ou seja, uma entrada da rede é formada por 20 amostras da base de dados. Todos os "X" dessa janela são inseridos como entrada para todas as células da camada LSTM, essas constituem a primeira camada da rede. As saídas de cada célula LSTM são passadas para a camada densamente conectada, "Dense", que gera como saída um vetor de valores referente aos próximos cinco segundos da potência, ou seja, dado as leituras dos sensores referente aos vinte segundos anteriores é possível estimar a potência dos próximos cinco segundos futuros. Uma configuração similar de rede neural recorrente foi utilizado no trabalho [Qing and Niu, 2018].

A escolha de quantas células vão compor a primeira camada foi determinada pelo resultado da validação cruzada, onde foram testados os valores 20, 40, 60, 80, 100 e 120 para a variável w da camada LSTM. Cada célula possui uma sequência de neurônios LSTM realimentados, no qual a saída de cada sequência LSTM retorna um valor que é passado como entrada para os cinco neurônios da camada DENSE, estes por sua vez possuem a mesma estrutura do perceptron e através da função de ativação linear produzem como resultado um vetor referente aos próximos cinco segundos da variável potência prevista.

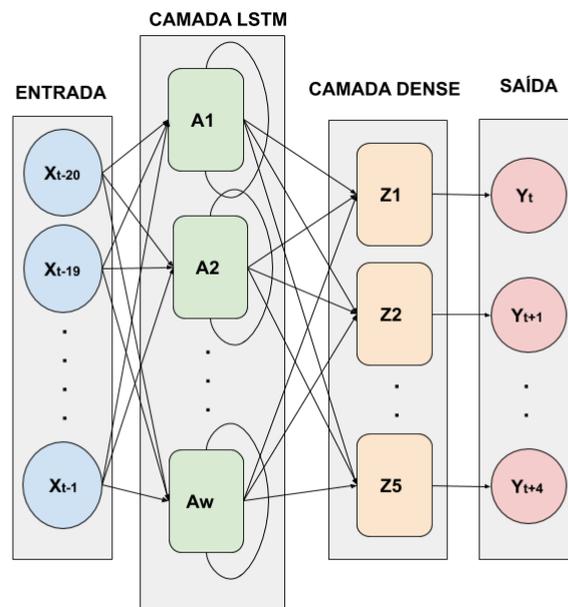


Figura 4.4: Arquitetura da rede neural desenvolvida para o presente trabalho.

4.3 Treinamento e teste

Para o treinamento da LSTM foram utilizadas como variáveis de entradas: temperatura do painel, temperatura ambiente, velocidade do vento, irradiância e umidade, a variável potência foi utilizada como saída esperada da rede neural. Todas essas variáveis foram

normalizadas utilizando a equação (4.3), no quais os novos valores das variáveis ficam em um intervalo entre 0 e 1.

$$X_{new} = \frac{X_i - \min(X)}{\max(X) - \min(X)} \quad (4.3)$$

Para o treinamento foram escolhidos o otimizador Adam [Kingma and Ba, 2014] e a função de perda erro quadrático médio, essa é uma escolha padrão na maioria dos casos em que se utiliza LSTM [Qing and Niu, 2018]. O tamanho do *batch* foi setado para 500. Foram considerados dois critérios de parada: quando o treinamento atinge cem épocas ou quando a função de perda tem uma melhoria inferior a 1×10^{-10} em relação à época anterior.

Para avaliar a capacidade de generalização da rede neural foi utilizada a técnica de validação cruzada *K-fold*. A Figura 4.5 mostra a sequência de treinos que a rede foi submetida, onde no primeiro treino foram utilizados os *folds* de 2 à 8 para calcular os parâmetros da rede e o *fold* 1 para avaliar o desempenho da rede com esses novos parâmetros, a cada época do treino foi salvo o erro quadrático médio tanto do conjunto de treinamento quanto de validação, este processo é repetido até que todos os *folds* sejam utilizados como validação. A utilização da validação cruzada *K-fold* permitiu a escolha do melhor modelo, pois foi possível comparar o desempenho entre todas as topologias de redes criada.

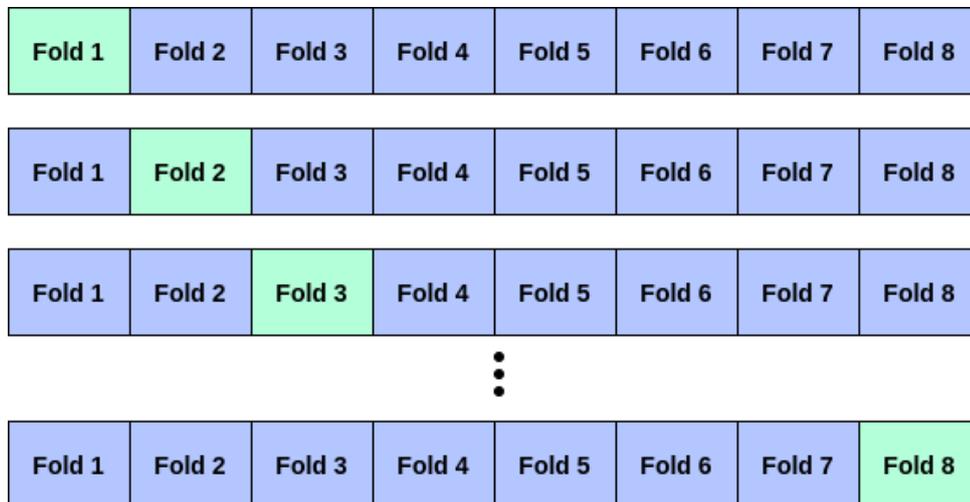


Figura 4.5: Etapas do processo de validação cruzada.

Após o ajuste da melhor configuração da rede LSTM utilizando a validação cruzada, foi realizado um novo treinamento, mas dessa vez utilizando toda a base de treino. O motivo deste novo treinamento está no fato de poder medir o desempenho da rede com dados que não foram utilizados durante o processo de treinamento, podendo assim simular uma futura atuação da rede em um cenário real. Após calculado os novos parâmetros foi possível medir o desempenho da rede utilizando todas as amostras da base de teste como entrada e calculando o erro entre a potência prevista e a potência esperada para cada

segundo do vetor de saída. Todos estes resultados estão descritos no próximo capítulo.

Capítulo 5

Resultados

Para medir o desempenho de cada topologia de rede testada, foi calculado a média da função de erro da última época em cada etapa do processo de validação cruzada. A Equação 5.1 faz a média da função de erro sobre a base de treinamento, onde o somatório percorre todas as oito etapas do processo de validação cruzada e Et_n é o erro de treinamento da última época. Da mesma forma, a Equação 5.2 calcula a média da função de erro sobre cada *fold* que foi utilizado como conjunto de validação, onde Ev_n é o erro de validação da última época.

$$e_t = \sum_{n=1}^8 \frac{Et_n}{8} \quad (5.1)$$

$$e_v = \sum_{n=1}^8 \frac{Ev_n}{8} \quad (5.2)$$

Os resultados das equações acima para cada rede neural são mostrado na Figura 5.1, onde o eixo x representa a quantidade de células utilizada na camada LSTM, e o eixo y é a média da função de erro. A linha em laranja é referente ao erro sobre os dados da validação, enquanto que a linha em azul é obtido sobre os dados de treinamento. O gráfico mostra que a rede neural com 60 células na primeira camada foi a que obteve ao mesmo tempo um erro de treinamento baixo e a melhor capacidade de generalização sobre os dados de validação.

Com a quantidade células na camada LSTM fixada em 60, foi gerado a Figura 5.2, no qual mostra o processo de aprendizagem da rede durante todos os treinos da validação cruzada, em função do número de épocas de treinamento. A curva em azul é referente ao erro médio do treinamento, é possível perceber que com o passar das épocas existe uma diminuição no erro de treinamento, o que comprova que o processo de aprendizagem da rede funcionou. Além disso, é possível perceber que o valor de erro não apresentou diminuição significativa na época 58, atingindo assim o ponto de parada estabelecido durante a construção da rede. A curva em laranja mostra que os parâmetros encontrados no treinamento possuem uma boa capacidade de generalização sobre os dados de validação,

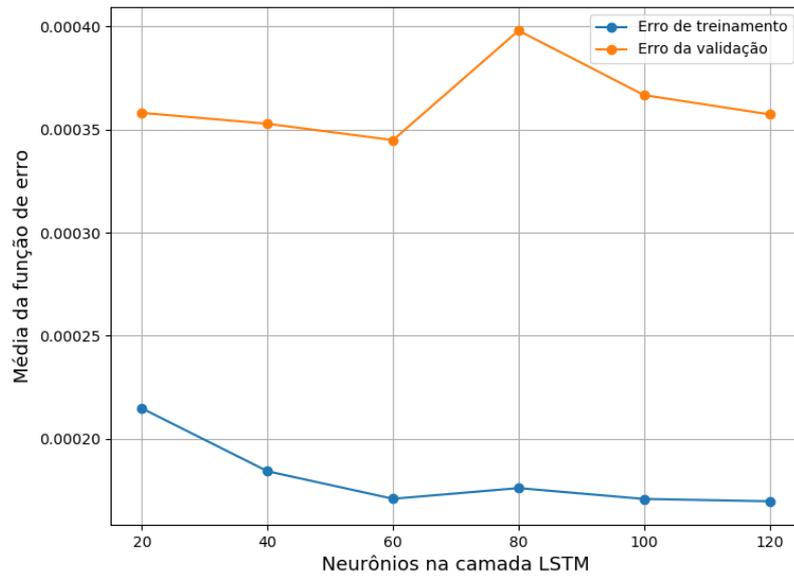


Figura 5.1: Média do erro em função do número de células na camada LSTM.

tendo o erro médio próximo ao erro médio de treinamento. Além disso percebe-se que após a época 30 a rede já estava próximo ao seu estado de convergência.

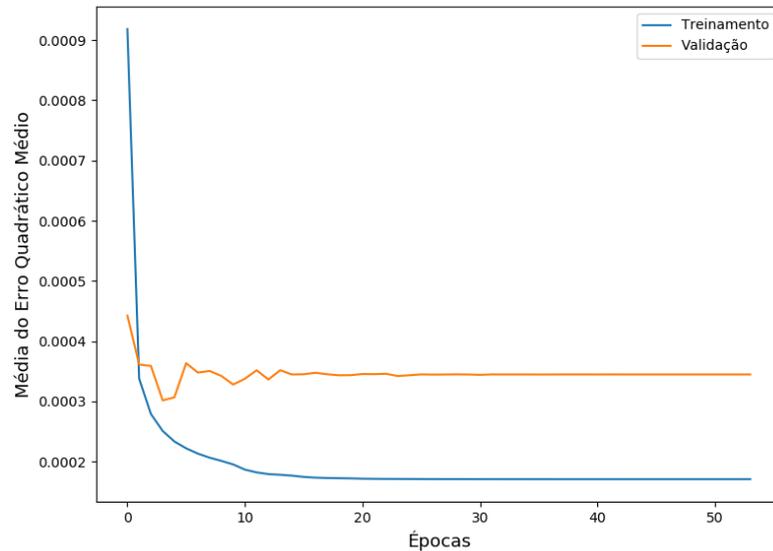


Figura 5.2: Média do erro de treinamento e validação em função do número de épocas de treinamento.

Com a rede neural treinada, a partir de toda a base de treino, foi possível fazer a previsão da variável potência utilizando a base de teste. O resultado foi analisado individualmente para cada segundo do vetor de potência. A Tabela 5.1 mostra o valor do erro médio absoluto para cada segundo da potência prevista, onde é possível perceber que erro médio absoluto referente a previsão de um segundo é muito próximo a de dois

segundos, porém a partir do terceiro segundo o erro começa a aumentar significativamente, tendo no quinto segundo um erro de 48% maior do que o primeiro segundo.

Tabela 5.1: Erro absoluto médio de cada segundo do vetor de potência previsto.

	Um segundo	Dois segundos	Três segundos	Quatro segundos	Cinco segundos
Erro médio absoluto	6.2134 W	6.7602 W	7.5165 W	8.3875 W	9.2315 W

Para realizar uma melhor análise do desempenho da previsão foi gerado o gráfico *boxplot* referente ao erro absoluto entre os valores reais de potência com os valores previstos pela rede neural. A Figura 5.3 mostra que as medianas dos erros absolutos estão com valores muito próximos, tomando a previsão de um segundo à frente como referência temos que durante todo o dia 50% dos erros estão abaixo de 1.375 W, tendo em vista que a maior potência registrada foi de 800.37 W, 1.375 W corresponde a apenas 0.17% do maior valor de potência.

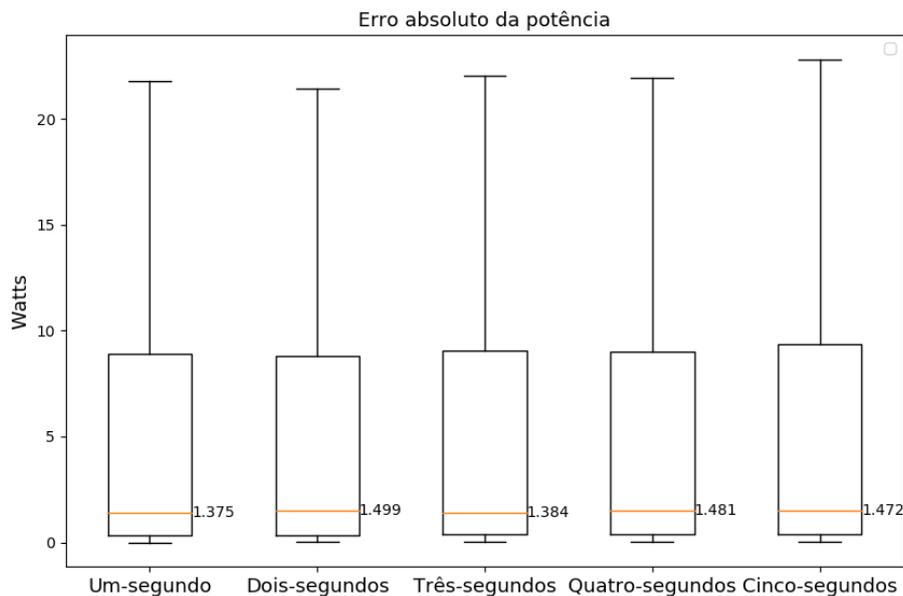


Figura 5.3: *Boxplot* referente ao erro absoluto da variável potência.

O resultado da previsão da potência do quinto segundo referente a toda a base de teste está ilustrada na Figura 5.4. A série representada na linha vermelha são os valores reais de potência gerados pelos painéis fotovoltaicos, enquanto que a série representada pela linha pontilhada azul compõe os valores previstos pela rede. Visualmente é possível perceber que a rede conseguiu um bom desempenho na previsão da potência durante todo o dia, com exceção do início da manhã e ao anoitecer que são os horários onde a tensão dos painéis sofre uma elevada oscilação.

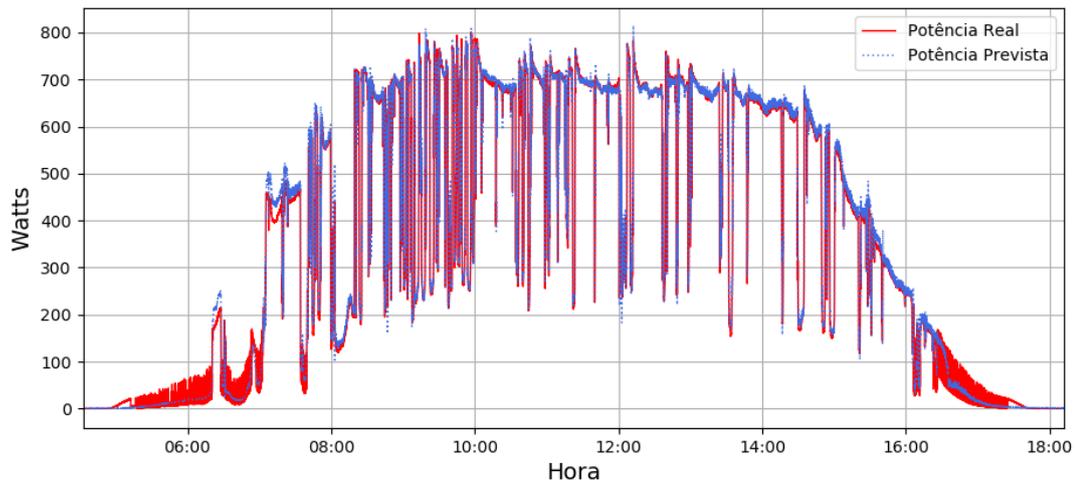
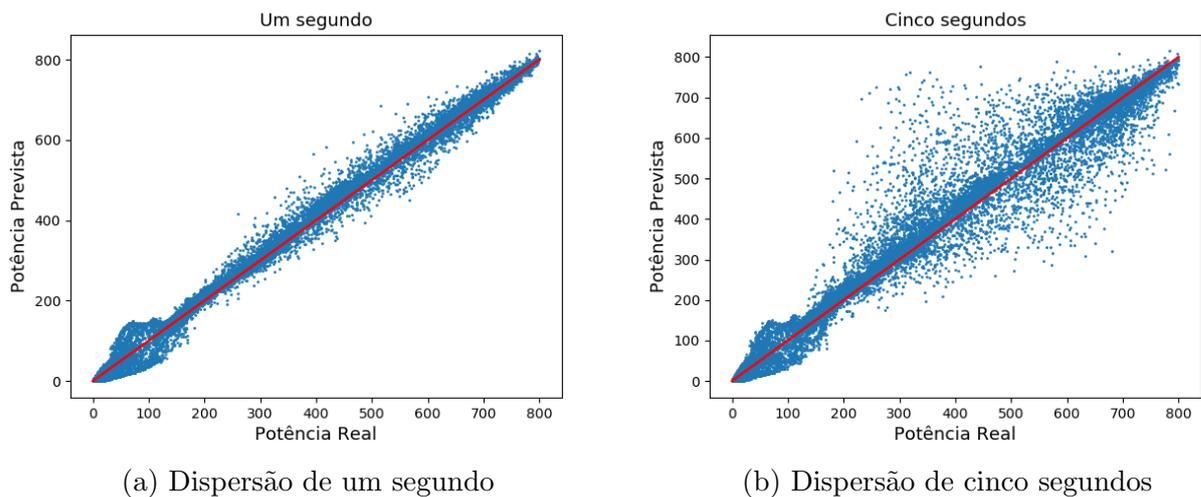


Figura 5.4: Valores reais da potência (linha vermelha), e previstos pela rede (linha pontilhada azul), em função da hora do dia da base de teste [Fonte: Própria].

Uma outra maneira de analisar as previsões da rede LSTM é com o gráfico de dispersão do erro. A Figura 5.5a mostra a dispersão do erro referente a um segundo e a Figura 5.5b o erro de cinco segundos. O eixo na horizontal representa os valores reais gerados pelos painéis solares, o eixo vertical são os valores previstos pela rede e a reta em vermelho representa o caso ideal em que a rede neural consegue prever sem erro todos os valores.



(a) Dispersão de um segundo

(b) Dispersão de cinco segundos

Figura 5.5: Gráficos de dispersão dos erros absolutos referentes as previsões de um segundo e cinco segundos da potência.

Ao analisar a Figura 5.5 é possível perceber que as previsões de um segundo tiveram uma dispersão do erro menor do que a previsão de cinco segundos, ficando com valores muito próximos aos valores reais, enquanto que a previsão de cinco segundos teve a dispersão do erro mais espalhada o que significa que algumas previsões ficaram longes do valor esperado. Para comprovar a diferença da dispersão do erro referente a cada segundo do vetor de potência foi gerada a tabela 5.2, no qual mostra o desvio padrão do erro abso-

Tabela 5.2: Desvio padrão do erro absoluto referente a cada segundo do vetor de saída da rede LSTM.

	Um segundo	Dois segundos	Três segundos	Quatro segundos	Cinco segundos
Desvio Padrão	11.312	13.894	17.357	21.121	24.486

luto . É notório que existe um crescimento do desvio padrão a medida que o horizonte de previsão aumenta, demonstrando que a dispersão do erro em torno da média fica maior e conseqüentemente a previsão da rede começa a ficar mais longe em relação ao valor esperado. Mesmo assim, a rede está conseguindo prever com eficiência o comportamento temporal da potência de cada segundo.

Capítulo 6

Conclusão

O presente trabalho apresenta a utilização de rede neural recorrente LSTM como modelo de previsão da geração elétrica por sistema fotovoltaico a partir de dados meteorológicos. Os resultados apresentados sugerem que mesmo com a utilização de parâmetros provenientes de uma estação solarimétrica de baixo custo a rede neural recorrente LSTM consegue obter um bom desempenho na previsão da variável potência.

Observou-se que nos horários em que a tensão teve uma grande oscilação a rede LSTM divergiu ao tentar prever os valores reais da potência, esta oscilação é proveniente da baixa qualidade do inversor e da variação da radiação solar sobre o painel fotovoltaico nestes períodos do dia. Contudo, no início do dia e ao anoitecer a geração de energia é muito menor se comparada com a energia gerada durante os outros horários do dia. Nos horários em que a geração de energia é maior o erro de previsão de um segundo à frente da rede ficou, em média, abaixo de 0.17%.

O estudo demonstrou também que a rede LSTM foi capaz de prever um horizonte de cinco segundos futuros da potência, onde as medianas dos erros absolutos tiveram valores baixos e muito próximos entre si. Tal desempenho indica que redes LSTM podem ser consideradas como um bom modelo de previsão ao se criarem ferramentas para, por exemplo, a previsão de surtos na geração de energia.

Como trabalho futuro pretende-se desenvolver um estudo sobre o impacto da taxa de amostragem dos dados nos modelos de predição. Por fim, será possível criar modelos de predição mais precisos e capazes de prever com maior antecedência.

Bibliografia

- [Bos, 2019] (2019). Bosch sensortec, bme 280. https://www.bosch-sensortec.com/bst/products/all_products/bme280. Accessed: 2020-06-05.
- [Max, 2019] (2019). Ds18b20 programmable resolution 1-wire digital thermometer. <https://www.maximintegrated.com/en/products/sensors/DS18B20.html>. Accessed: 2020-06-05.
- [SEC, 2019] (2019). Transdutores/transmissores para medidas de parâmetros elétricos. <https://www.secon.com.br/grupo.php?id=16>. Accessed: 2020-06-05.
- [Abdel and Mahmoud, 2019] Abdel, M. and Mahmoud, K. (2019). Accurate photovoltaic power forecasting models using deep lstm-rnn. *Neural Computing and Applications*, 84(5):2727–2740.
- [Alzahrani et al., 2017] Alzahrani, A., Shamsi, P., Dagli, C., and Ferdowsi, M. (2017). Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, 114:304 – 313. Complex Adaptive Systems Conference with Theme: Engineering Cyber Physical Systems, CAS October 30 – November 1, 2017, Chicago, Illinois, USA.
- [Arshi et al., 2019] Arshi, S., Zhang, L., and Strachan, B. (2019). Weather based photovoltaic energy generation prediction using lstm networks.
- [Atsushi Yona et al., 2008] Atsushi Yona, Tomonobu Senjyu, Saber, A. Y., Toshihisa Funabashi, Hideomi Sekine, and Kim, C. (2008). Application of neural network to 24-hour-ahead generating power forecasting for pv system. In *2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, pages 1–6.
- [Bastos et al., 2020] Bastos, , Melo, G., Araújo, I., et al. (2020). Previsão de geração fotovoltaica a partir de dados meteorológicos utilizando rede lstm. In *VIII CBENS - Congresso Brasileiro de Energia Solar*, Fortaleza.
- [Bengio and Grandvalet, 2004] Bengio, Y. and Grandvalet, Y. (2004). No unbiased estimator of the variance of k-fold cross-validation. *Journal of machine learning research*, 5(Sep):1089–1105.

- [Buitinck et al., 2013] Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., and Varoquaux, G. (2013). API design for machine learning software: experiences from the scikit-learn project. In *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, pages 108–122.
- [Cantor, 2017] Cantor, G. A. R. (2017). Influência dos fatores climáticos no desempenho de módulos fotovoltaicos em regiões de clima tropical. Master’s thesis, Universidade Federal Da Paraíba.
- [Chollet et al., 2015] Chollet, F. et al. (2015). Keras. <https://keras.io/getting-started/faq>. Accessed: 2020-06-05.
- [De et al., 2018] De, V., Teo, T. T., Woo, W. L., and Logenthiran, T. (2018). Photovoltaic power forecasting using lstm on limited dataset. In *2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*, pages 710–715.
- [Diaz, 2014] Diaz, M. B. (2014). Análise de diferentes métodos de preenchimento de falhas nos fluxos de CO_2 : *estimativassobrearrozirrigado*. Master’s thesis, Universidade Federal Da Santa Maria.
- [Grübler, 2018] Grübler, M. (2018). Entendendo o funcionamento de uma rede neural artificial. <https://medium.com/brasil-ai/entendendo-o-funcionamento-de-uma-rede-neural-artificial-4463fcf44dd0>. Accessed: 2020-06-05.
- [Guarnieri et al., 2007] Guarnieri, R., Pereira, E., Fernando, M., et al. (2007). Previsões de radiação solar utilizando modelo de mesoescala: Refinamento com redes neurais. In *CBENS - Congresso Brasileiro de Energia Solar*, Fortaleza.
- [Gupta et al., 2007] Gupta, C. N., Palaniappan, R., Swaminathan, S., and Krishnan, S. M. (2007). Neural network classification of homomorphic segmented heart sounds. *Applied Soft Computing*, 7(1):286 – 297.
- [Haykin, 2007] Haykin, S. (2007). *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman, 2 edition.
- [He et al., 2018] He, H., Hu, R., Zhang, Y., Zhang, Y., and Jiao, R. (2018). A power forecasting approach for pv plant based on irradiance index and lstm. *2018 37th Chinese Control Conference (CCC)*, pages 9404–9409.
- [Kingma and Ba, 2014] Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization.

- [Lo Brano et al., 2014] Lo Brano, V., Ciulla, G., and Di Falco, M. (2014). Artificial neural networks to predict the power output of a pv panel. *International Journal of Photoenergy*, 2014.
- [Machado and Rampinelli, 2018] Machado, A. and Rampinelli, G. (2018). Avaliação de métodos probabilísticos para preenchimento de lacunas de dados solarimétricos e previsão da irradiância solar de curto prazo. In *VII CBENS - Congresso Brasileiro de Energia Solar*, Gramado.
- [Mellit and Pavan, 2010] Mellit, A. and Pavan, A. M. (2010). 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*, 84(5).
- [Qing and Niu, 2018] Qing, X. and Niu, Y. (2018). Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, 148(C):461–468.
- [Rihbane, 2014] Rihbane, F. E. C. (2014). Preenchimento de falhas aleatórias de séries temporais micrometeorológicas pela técnica de monte carlo. Master’s thesis, Universidade Federal Da Mato Grosso.
- [Sabino et al., 2018] Sabino, E., Petribú, L., Heitor, B., et al. (2018). Previsão de temperatura ambiente horária voltada para auxiliar previsões de geração de potência fotovoltaica. In *VII CBENS - Congresso Brasileiro de Energia Solar*, Gramado.
- [Shilbayeh and Al-Qudah, 2010] Shilbayeh, N. and Al-Qudah, G. (2010). Face detection system based on mlp neural network. pages 238–243.
- [Yu et al., 2019] Yu, Y., Cao, J., and Zhu, J. (2019). An lstm short-term solar irradiance forecasting under complicated weather conditions. *IEEE Access*, 7:145651–145666.
- [Zhang et al., 2018] Zhang, J., Chi, Y., and Xiao, L. (2018). Solar power generation forecast based on lstm. In *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*, pages 869–872.