

# **PREVISÃO DE GERAÇÃO FOTOVOLTAICA UTILIZANDO REDES NEURAIIS RECORRENTES**

## **PHOTOVOLTAIC GENERATION FORECAST USING RECURRENT NEURAL NETWORKS**

**Diogo Alves Amorim**

daa@discente.ifpe.edu.br

**Regina Maria de Lima Neta**

regina.lima@pesqueira.ifpe.edu.br

---

### **RESUMO**

Diante do crescimento do uso da energia solar fotovoltaica (FV) no Brasil nos últimos anos, é importante poder mensurar quanto as usinas geram nas próximas horas ou dias, para que seja feito um planejamento do setor elétrico de forma confiável, garantindo a qualidade e o fornecimento contínuo de energia elétrica. Sendo assim, esse trabalho consistiu em determinar os melhores hiperparâmetros para a construção de um modelo de previsão de energia solar FV utilizando a rede neural recorrente *Long Short-Term Memory* (LSTM). Após a construção do modelo, foram realizados testes com os dados históricos de geração da usina solar de Pirapora – MG, com o objetivo de fazer a previsão dos valores de geração de forma diária e horária. Utilizando as métricas de erro, Raiz do Erro Médio Quadrático (RMSE), Erro Médio Absoluto (MAE) e Erro Médio Absoluto Percentual (MAPE), foram encontrados valores de 467,95 kWh, 329,25 kWh e 23,23% para o teste de forma diária e 41,21 kWh, 27,50 kWh e 36,07% no teste de forma horária, em que, para ambos os casos o período de teste foi de 6 meses. Além disso, também foram obtidos os valores do RMSE, MAE e MAPE para as primeiras 120 horas do teste, que foram 19,47 kWh, 13,83 kWh e 16,05% para o período em questão, respectivamente. Os resultados encontrados para as duas formas de previsão foram considerados eficientes, visando que foi utilizada apenas uma entrada na rede neural.

Palavras-chave: Previsão de geração solar. Rede neural recorrente. LSTM.

### **ABSTRACT**

In view of the growth in the use of photovoltaic (PV) solar energy in Brazil in recent years, it is important to be able to measure how much the plants will generate in the next few hours or days, so that the electrical sector can be planned reliably, guaranteeing the quality and continuous supply of electricity. Therefore, this work consisted of determining the best hyperparameters for building a PV solar energy forecast model using the Long Short-Term Memory (LSTM) recurrent neural network.

After building the model, tests were carried out with the historical generation data of the solar plant in Pirapora - MG, with the objective of forecasting the generation values on a daily and hourly basis. Using the error metrics, Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE), values of 467.95 kWh, 329.25 kWh and 23.23% were found for the daily test and 41.21 kWh, 27.50 kWh and 36.07% in the hourly test, in which, for both cases, the test period was 6 months. In addition, RMSE, MAE and MAPE values were also obtained for the first 120 hours of the test, which were 19.47 kWh, 13.83 kWh and 16.05% for the period in question, respectively. The results found for the two forms of prediction were considered efficient, considering that only one input was used in the neural network.

Keywords: Solar generation forecast. Recurrent neural network. LSTM.

## 1 INTRODUÇÃO

Nas últimas décadas, o uso da Energia Solar Fotovoltaica (FV) cresceu em todo o mundo. O Brasil tem um grande potencial quando se trata desse tipo de energia, já que a radiação solar recebida é de grande intensidade (PINHEIRO, LOVATO, RÜTHER, 2017).

Com o intuito de mostrar como tem crescido o uso da energia FV no país, foram coletados os dados da geração de energia elétrica do Brasil do ano de 2011, a partir de uma pesquisa feita por Mendes (2011), e do momento atual através do site da Agência Nacional de Energia Elétrica (ANEEL), como pode ser observado na Tabela 1. Vale ressaltar que foram obtidos apenas os valores da Potência Fiscalizada, pois, é esta a potência que realmente está disponível para o consumo.

**Tabela 1 – Matriz elétrica dos anos de 2011 e 2022**

Fonte de Geração	2011		2022	
	Potência Fiscalizada (kW)	Percentual de Potência Fiscalizada (%)	Potência Fiscalizada (kW)	Percentual de Potência Fiscalizada (%)
Usina Hidrelétrica	77.285.939	67,75	103.177.222	55,49
Usina Termelétrica	30.136.419	26,42	45.399.933	24,41
Central Geradora Eólica	928.986	0,81	22.514.193	12,11
Usina Fotovoltaica	87	0,00	6.452.992	3,47
Pequena Central Hidrelétrica	3533.532	3,10	5.569.350	3,00
Usina Termonuclear	2.007.000	1,76	1.990.000	1,07
Central Geradora Hidrelétrica	188.701	0,17	847.895	0,46

Fonte: Adaptado de Mendes (2011) e ANEEL (2022).

Ao analisar os dados percentuais de potência fiscalizada da energia FV, percebe-se que essa geração era de apenas 87 kW em 2011, representando uma participação quase nula diante do total da energia gerada. Atualmente verifica-se que a matriz elétrica brasileira mudou bastante, em todos os setores energéticos. Em especial,

observa-se que a energia FV saiu de um patamar de quase 0% para 3,47% em relação ao total de energia elétrica fornecida ao país, mostrando um grande avanço do setor. Tendo em vista esse avanço nos últimos anos, a geração de energia FV foi o foco principal desta pesquisa.

O Operador Nacional do Sistema Elétrico (ONS) enfrenta um problema que consiste em equilibrar o quanto de energia elétrica está sendo gerada e o quanto efetivamente está sendo consumida. Então, para que não haja um desequilíbrio entre a demanda e a oferta é importante estimar como será a geração das usinas elétricas (PINHEIRO, LOVATO, RÜTHER, 2017).

Segundo os mesmos autores, uma das principais formas de prever a geração FV é por meio de *softwares*, que utilizam de artifícios computacionais para analisar o *comportamento do sol* em um determinado lugar. Um destes artifícios é chamado de Redes Neurais Artificiais (RNAs). Com isso, é possível estimar quanta incidência solar haverá naquela determinada área, que em conjunto com os dados de períodos anteriores permitirá quantificar a geração de energia elétrica na região. Assim, é notório que as RNAs têm uma grande utilidade no setor elétrico.

Antes de iniciar de fato essa pesquisa, foi levantado o seguinte questionamento: *quais estudos sobre redes neurais artificiais aplicadas à previsão de geração de energia FV já foram desenvolvidos até agora?* Diante dessa pergunta, foi realizado um levantamento sobre a existência de trabalhos relacionados a este que já foram publicados até o momento. Dos diversos estudos encontrados na Literatura, foram selecionados apenas alguns, conforme Tabela 2.

**Tabela 2 – Pesquisas na Literatura relacionadas com a temática**

Título da Pesquisa	Autores e Ano de Publicação	Localidade	RNA Utilizada	Ferramenta Computacional Utilizada
Utilização das Redes Neurais Artificiais para Previsão de Radiação Solar	OLIVEIRA, G. L. S.; SILVA, M. S. (2022).	Pesqueira - PE	PMC	Matlab
Metodologia Baseada em Redes Neurais Artificiais para Previsão da Geração de Plantas Fotovoltaicas	ARAÚJO <i>et al.</i> (2022).	Fortaleza - CE	PMC e SOM	Matlab
Previsão Intra-Diária de Geração Fotovoltaica Usando Redes Neurais Recorrentes do tipo LSTM e dados Históricos de Energia	CUNHA, B. A.; MARAFÃO, F. P.; MARTINS, A. C. G. (2021).	Bauru - SP	LSTM	Google Colab
Previsão Probabilística de Energia Solar Utilizando Redes Neurais com Inferência Bayesiana e Mistura de Gaussianas	MARTINS, R. P.; FERREIRA, V. H.; LOPES, T. T. (2018).	Niterói - RJ	PMC	Matlab
Aplicação de redes neurais artificiais para previsão da incidência solar na cidade de Belo Horizonte	DIAS, M. P. A.; INÁCIO, M. J.; JÚNIOR, Á. B. C. (2020).	Belo Horizonte - MG	PMC e RBF	Matlab
<b>Esse estudo</b>	<b>AMORIM, D. A.; LIMA NETA, R. M.</b>	<b>Pesqueira - PE</b>	<b>LSTM</b>	<b>Google Colab</b>

Fonte: Autoria própria (2023).

De acordo com a Tabela 2, dos trabalhos citados foram encontrados os seguintes tipos de RNAs: Perceptron de Multicamadas (PMC), Rede Neural de Kohonen (SOM), Memória de Curto e Longo Prazo (LSTM) e Rede de Função de Base Radial (RBF).

É importante notar que a grande maioria das pesquisas da Tabela 2 são recentes. Sendo assim, esses dados mostram que o interesse em utilizar as RNAs na área de geração de energia FV tem começado a bem pouco tempo, mas vem crescendo nos últimos anos. Tendo em vista que essa não é uma pesquisa pioneira, esse trabalho visa dar continuidade nas pesquisas e estimular ainda mais esse campo da ciência, contribuindo assim como um estudo de caso para a comunidade científica.

O primeiro estudo publicado sobre RNA foi o de Warren McCulloch e Walter Pitts, que escreveram um artigo científico, no ano de 1943, em que estudavam o comportamento do cérebro humano. Com isso, conseguiram propor um modelo matemático a partir do neurônio biológico. Esse modelo foi chamado de neurônio McCulloch-Pitts ou neurônio MCP (FLECK *et al.*, 2016).

Dentre os cientistas que estudaram as RNAs nos anos seguintes, Frank Rosenblatt merece um destaque, pois, ele criou o *Perceptron* no período entre 1957 e 1958 (FURTADO, 2019, p. 3). O portal de ensino *Data Science Academy* em seu livro online intitulado "*Deep Learning Book*" diz que "O *Perceptron*, que resultou dessa pesquisa, foi construído em hardware e é a mais antiga rede neural ainda em uso". Porém, sabe-se que ele é limitado e seu uso é bem pequeno, sendo mais utilizado como meio didático para quem está começando a estudar sobre Inteligência Artificial (IA).

Essa pesquisa teve o objetivo de desenvolver um algoritmo no *Google Colab*, utilizando a linguagem de programação *Python* e a rede LSTM, que é uma Rede Neural Artificial Recorrente (RNR). Com o foco em obter melhor eficiência nos resultados de previsão, foi proposto realizar experimentos para definir os melhores hiperparâmetros da rede. Por fim, utilizar esse algoritmo para prever os valores de geração diária e horária da usina FV localizada em Pirapora – MG.

## 2 FUNDAMENTAÇÃO TEÓRICA

Antes de falar como funcionam as RNRs é importante começar explicando como funcionam as RNAs em si. Então, em seguida será comentado um pouco sobre o Perceptron, já que essa rede neural serve como um meio bastante didático para um melhor entendimento das RNRs. Por fim, serão explicados os conceitos sobre a rede LSTM, a qual será utilizada para fazer a previsão da geração FV do parque solar de Pirapora.

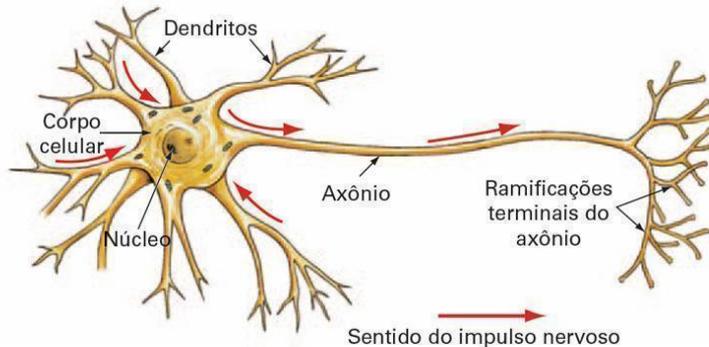
### 2.1 Redes Neurais Artificiais

De acordo com estudiosos as RNAs são algoritmos computacionais inteligentes, que foram inspirados no cérebro humano, sendo então capazes de aprender com os acontecimentos do passado. Com isso, esses algoritmos aprendem a tomar melhores decisões com base no que já foi aprendido (FLECK, *et al.*, 2016). As semelhanças entre ambos, basicamente podem ser vistas ao analisar o funcionamento de processamento de dados do cérebro, ou seja, como as informações são processadas.

No cérebro humano existem bilhões de neurônios biológicos, todos interligados entre si formando uma rede neural e por esses passam todas as informações. A Figura

1 mostra uma representação do neurônio biológico. (DATA SCIENCE ACADEMY, 2023).

Figura 1 – Neurônio Biológico



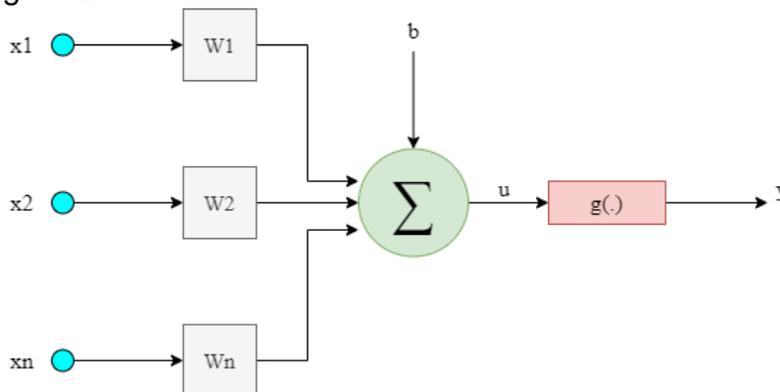
Fonte: Data Science Academy (2023).

Conforme os mesmos autores, o neurônio biológico é composto basicamente por três partes básicas: o corpo celular (também chamado de soma), em que, por ele saem o que são chamados de dendritos e o chamado axônio. Por fim, saem várias ramificações, por onde são transportadas informações para outros neurônios do cérebro.

Segundo Furtado (2019, p. 5-6), os dendritos que saem do corpo celular são os responsáveis por receber as informações e enviá-las através do axônio até o outro lado, ou seja, os dados são recebidos e encaminhados para outro neurônio, que por sua vez faz o mesmo e assim por diante, formando a rede neural.

Inspirado no neurônio biológico surgiu o modelo de neurônio matemático, advindo dos estudos de Warren McCulloch e Walter Pitts. Conforme Figura 2, percebe-se que esse modelo é bem similar ao mostrado anteriormente.

Figura 2 – Modelo do Neurônio Matemático



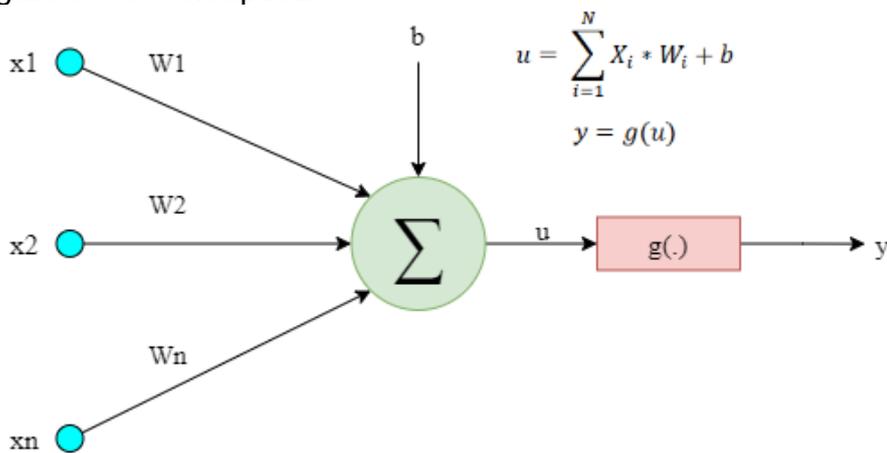
Fonte: Adaptado de Silva, Spatti e Flauzino (2010, p. 34).

Esse neurônio é formado por entradas ( $x_1, x_2, \dots, x_n$ ) que são os dados recebidos, os pesos sinápticos ( $w_1, w_2, \dots, w_n$ ) que representam a “relevância” de cada entrada, o bias ( $b$ ) que regula a função de ativação, o combinador linear ( $\Sigma$ ) que faz a soma ponderada de todos os produtos entre as entradas e os pesos sinápticos, o potencial de ativação ( $u$ ) que faz a subtração do resultado vindo do somatório com o bias, a função de ativação ( $g$ ) que regula o valor da saída do neurônio em um determinado intervalo e a saída ( $y$ ) (SILVA, SPATTI, FLAUZINO, 2010).

### 2.1.1 Rede Perceptron

O modelo de arquitetura *Perceptron* recebe várias entradas ( $x_1, x_2, \dots, x_n$ ), porém fornece apenas dois resultados possíveis em sua saída, ou seja, é uma saída binária. De acordo com a Figura 3, cada saída possui um peso ( $w$ ) que representa a importância daquela entrada vista pela saída ( $y$ ) (PALMIERE, 2016).

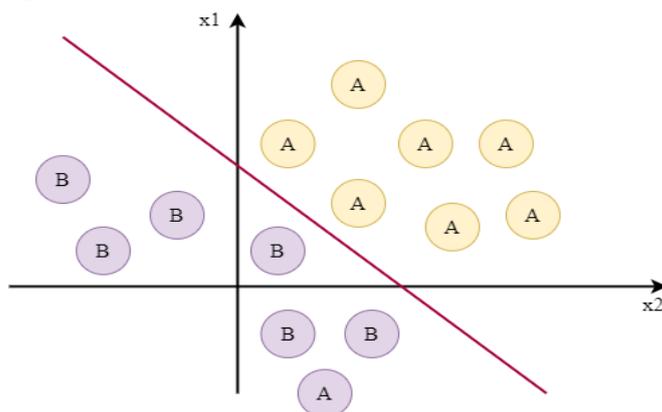
Figura 3 – O Perceptron



Fonte: Adaptado de Herbert (2002).

Inicialmente é feito uma soma ponderada das entradas e pesos sinápticos, em seguida a função de ativação ajusta o valor e encaminha para a saída. De acordo com Herbert (2002) e Palmiere (2016), o *Perceptron* por ter uma única camada (um neurônio) é usado para dividir duas classes que possam ser linearmente separáveis, ou seja, que seja possível traçar uma reta e separar as duas regiões uma da outra como exemplificado na Figura 4.

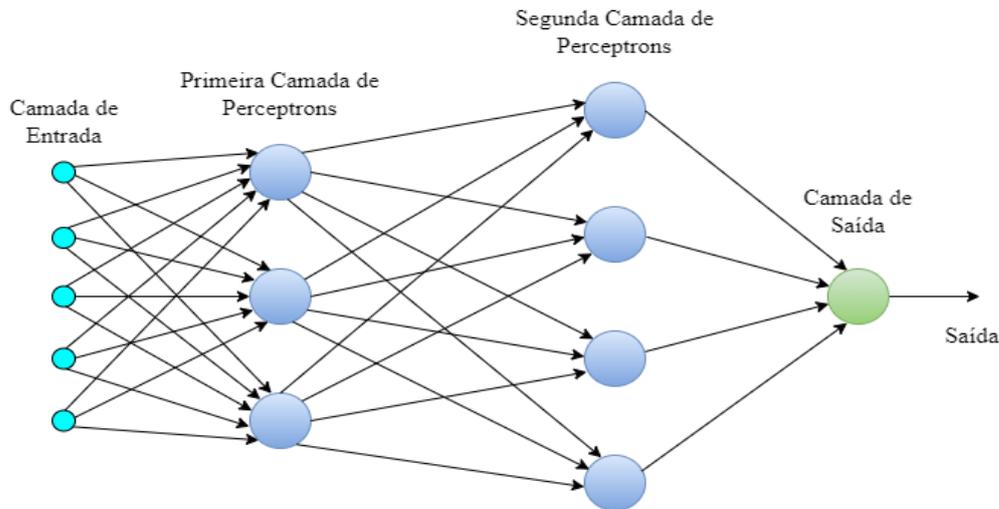
Figura 4 – Sistema possível de separar linearmente



Fonte: Adaptado de Palmiere (2016).

Conforme Figura 4, é possível separar as classes A e B desse sistema em duas regiões do plano apenas traçando uma reta. Mas a pergunta que fica é: *e quando isso não for possível?* então entra em ação o *Perceptron* de Multicamadas (PMC), mostrado na Figura 5.

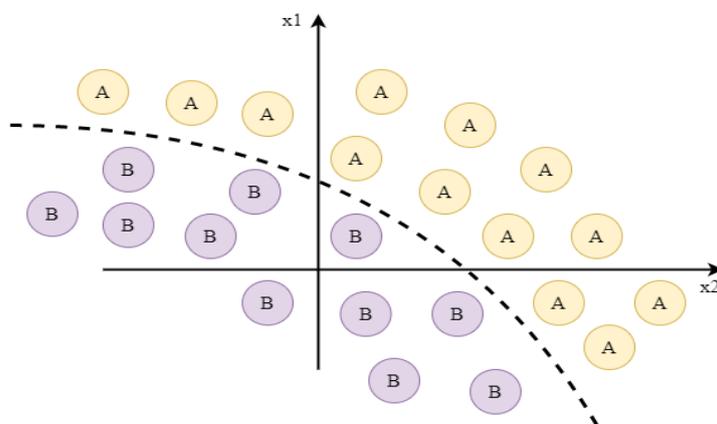
Figura 5 – Perceptron de multicamadas



Fonte: Adaptado de *Data Science Academy* (2023).

O PMC permite que sejam tomadas decisões mais sofisticadas, já que este conta com uma camada extra de neurônio. Diante disso, se torna possível separar duas regiões não linearmente separáveis (ver Figura 6), o que não há como ser feito utilizando o *Perceptron* de uma única camada (*DATA SCIENCE ACADEMY*, 2022).

Figura 6 – Sistema impossível de separar linearmente



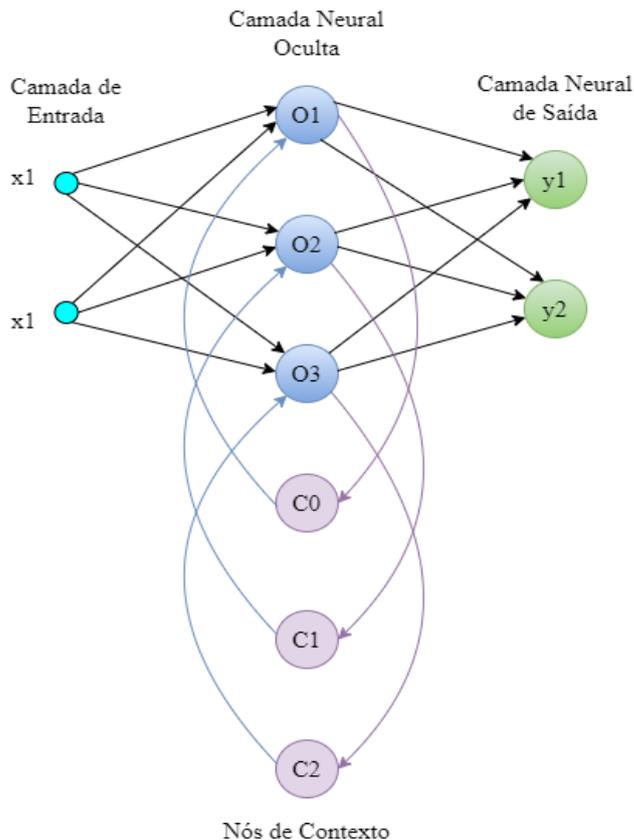
Fonte: Adaptado de Palmiere (2016).

Então, conclui-se que mesmo o *Perceptron* sendo um pouco limitado, ele é bastante interessante, pois é muito fácil e intuitivo, sendo importante para entender melhor os conceitos que virão mais adiante. Com isso, será mostrado a seguir o modelo de Redes Neurais Recorrentes (RNRs), que já é bem mais avançado e permite usos mais sofisticados do que o anterior.

### 2.1.2 Redes Neurais Recorrentes

Diferentemente do *Perceptron* que é uma rede neural do tipo *feedforward*, ou seja, as saídas de uma camada são as entradas para a seguinte, as redes neurais recorrentes contam com uma realimentação, como ilustrado na Figura 7 (*DATA SCIENCE ACADEMY*, 2022).

Figura 7 – Rede neural recorrente



Fonte: Adaptado de Jones (2017).

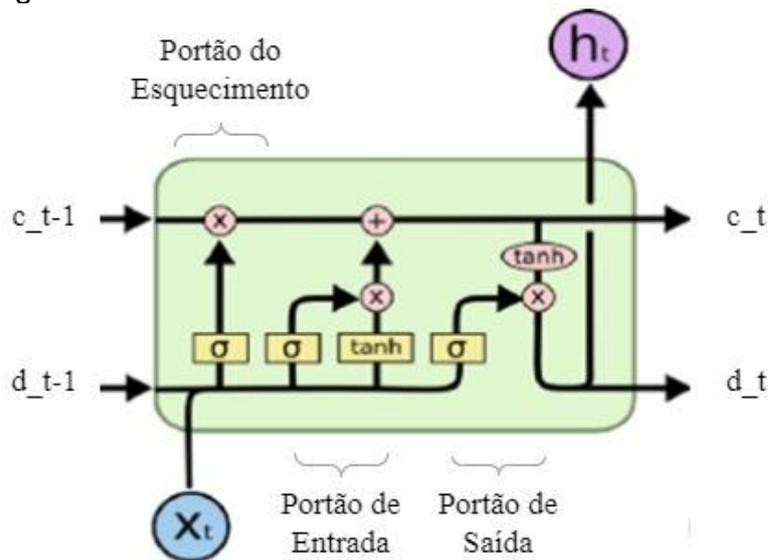
Nota-se que a saída da segunda camada (camada oculta) está retornando para ela mesma, fazendo com que haja a realimentação. Com isso este tipo de rede consegue ter um tipo de memória, armazenando informações sempre que ocorre o *loop* (JONES, 2017). Então, com esse tipo de arquitetura, é possível realizar previsões por meio de séries temporais. Em que, segundo Duarte (2019, p. 1) uma série temporal é “conjunto de observações ordenadas no tempo”, ou seja, são estudos feitos para analisar uma sequência de dados ao longo do tempo.

Nas palavras de estudiosos, para uma rede neural ser considerada recorrente ela necessita ter ao menos uma malha fechada, ou seja, uma camada com retorno para si própria. Então, além de enviar a informação adiante, a camada recorrente também guarda a nova informação em uma memória (*feedback*) (DUARTE, 2019).

### 2.1.2.1 Rede LSTM

A rede LSTM por se tratar de uma rede neural artificial recorrente já possui uma realimentação, o que permite que ela possua uma memória. Em que, essa memória tem o objetivo de lembrar informações de longo prazo (JÚNIOR, 2022). A Figura 8 ilustra um neurônio da rede LSTM, no qual, é composto por três portões chamados de Portão do Esquecimento, Portão de Entrada e Portão de Saída, respectivamente. Além disso, também possui os operadores de multiplicação e adição pontuais (LEANDRO, AMORIM, 2021).

Figura 8 – Neurônio da rede neural LSTM



Fonte: Adaptado de Leandro e Amorim (2021).

Segundo (Oliveira *et al.*, 2020), pode-se identificar cada ponto da Figura 8 como sendo:

- $x_t$ : entrada do instante atual;
- $c_{t-1}$ : estado da célula do instante anterior;
- $d_{t-1}$ : estado oculto do instante anterior;
- $h_t$ : saída final do instante atual;
- $d_t$ : estado oculto do instante atual;
- $c_t$ : estado da célula do instante atual;
- Símbolo de  $\times$ : realiza a operação de multiplicação pontual;
- Símbolo de  $+$ : realiza a operação de adicionar uma nova informação;
- $\sigma$ : função sigmoide;
- $\tanh$ : função tangente hiperbólica.

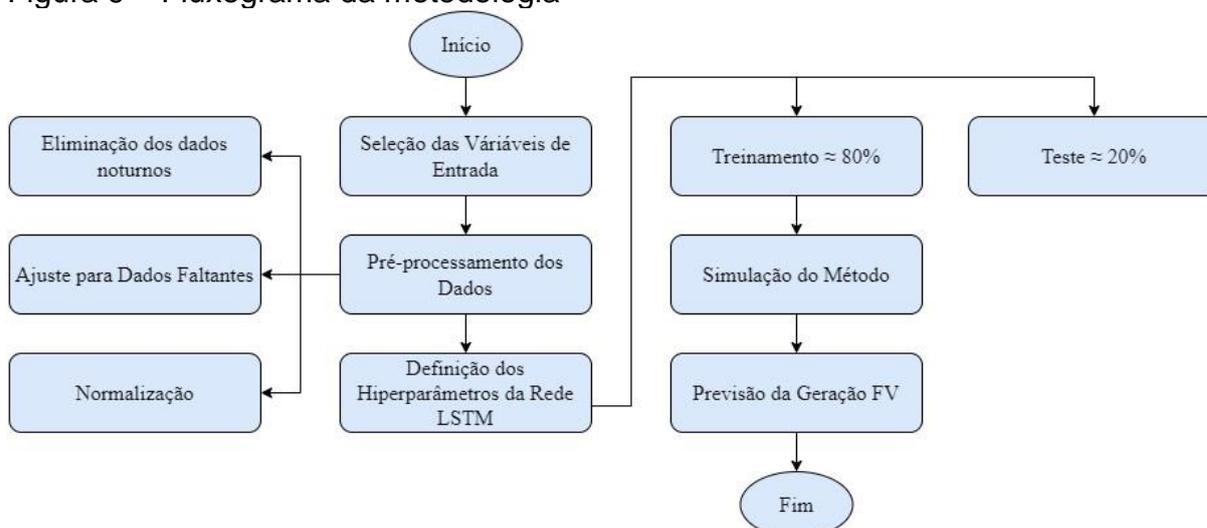
O Portão do Esquecimento tem o objetivo de eliminar informações que não são mais úteis. Dado que a camada sigmoide produz valores entre 0 e 1, e como qualquer número multiplicado por 0 é 0, significa que a informação será esquecida, em contrapartida, um número multiplicado por 1 é ele mesmo, sendo assim, a informação será guardada (JULIANI, 2019).

Ainda de acordo com Juliani (2019), o Portão de Entrada atualiza o estado da célula LSTM, considerando o estado oculto do instante anterior  $d_{t-1}$  e a entrada do instante atual  $x_t$ . Enquanto isso, a função de ativação tangente hiperbólica ( $\tanh$ ), tem como finalidade ajustar os valores entre -1 e 1, visando usar menos recurso computacional. Por fim, no Portão de Saída é feita a passagem da informação pela função sigmoide e tangente hiperbólica, com o objetivo de obter o estado oculto da próxima célula.

### 3 METODOLOGIA

A metodologia dessa pesquisa ocorreu de acordo com o fluxograma da Figura 9, em que, cada bloco correspondente é explicado de forma detalhada a seguir.

Figura 9 – Fluxograma da metodologia



Fonte: Autoria própria (2023).

### 3.1 Seleção das Variáveis de Entrada e Pré-processamento dos Dados

Os dados históricos foram coletados da usina fotovoltaica Pirapora (MG) através do site do ONS, contendo os valores de geração horária em kWh que foram utilizados como a variável de entrada da rede. O período total de dados coletados foi de 3 anos, no intervalo de 01/01/2020 a 31/12/2022, com uma amostra total de 1096 dados para a geração diária e 12034 dados na geração horária.

O pré-processamento dos dados é composto por duas partes que são explicadas de maneira resumida a seguir:

*Eliminação dos Dados Noturnos* – como de conhecimento, a geração solar FV ocorre apenas durante o período do dia, sendo assim, foi considerada apenas a geração entre 07h00 e 17h00, ou seja, foram apagados os dados de geração entre o horário das 18h00 às 06h00.

*Ajuste para Dados Faltantes* – dentre o período de 3 anos da base de dados, havia 6 dias que tinham dados faltantes em determinadas horas do dia. Para completar essas lacunas foi utilizado o princípio da similaridade, em que, foi observado os dias que tinham a geração similar ao dia que estava faltando para que fosse coletado a geração dessa hora e assim repetir esse valor para a hora faltante. Esse processo foi refeito até completar todas as horas faltantes.

*Normalização* – a normalização tem o objetivo de aplicar um fator de escala nos valores para que estes fiquem entre um intervalo definido, normalmente entre 0 e 1, que é exatamente o intervalo que foi adotado na pesquisa. Segundo Oliveira e Silva (2022) uma das técnicas de normalização mais utilizadas quando se trabalha com previsão de geração é a de mínimos e máximos, conforme Eq. (1). Tendo isso em vista, esta foi a técnica utilizada para fazer a normalização dos dados nessa pesquisa.

$$x_{normalizado}(i) = \frac{x(i) - \min(x)}{\max(x) - \min(x)} \quad (1)$$

em que,  $x_{normalizado}(i)$  corresponde a cada valor normalizado obtido no processo,  $x(i)$  representa o valor real, enquanto isso, o  $\max(x)$  e  $\min(x)$  são o maior e o menor valor do conjunto de dados (CUNHA, MARAFÃO, MARTINS, 2021).

### 3.2 Definição dos Hiperparâmetros da Rede LSTM

No Quadro 1 são informados os parâmetros utilizados no treinamento da rede LSTM, para a construção do modelo de previsão de geração diária e horária. A geração de energia foi utilizada como entrada e saída da rede neural, enquanto os demais parâmetros foram escolhidos seguindo os padrões largamente utilizados na literatura, sendo esses: Função de ativação sigmoide, otimizador Adam, taxa de aprendizado 0,001 e as métricas, Erro Médio Quadrático (MSE), Raiz do Erro Médio Quadrático (RMSE) e Erro Médio Absoluto (MAE).

**Quadro 1** – Parâmetros utilizados para treinamento da rede LSTM

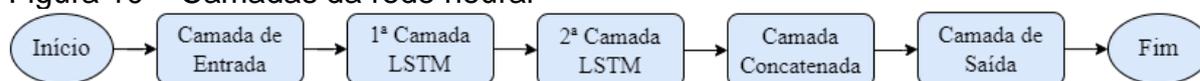
Parâmetro	Geração Diária e Horária
Entrada	Geração (kWh)
Saída	Geração (kWh)
Função de ativação	Sigmoide
Otimizador	Adam
Taxa de aprendizado	0,001
Função de perda	MSE
Métricas	MSE, RMSE e MAE

Fonte: Autoria própria (2023).

Outro parâmetro importante é a quantidade de camadas que se deve utilizar na construção da rede neural. De acordo com Vasco (2020), não há uma definição exata quanto a isso para que se tenha uma melhor eficiência na previsão, sendo assim, foi definido de forma arbitrária que a rede neural seria composta por cinco camadas, sendo: uma de entrada, duas de LSTM, uma de concatenação e uma de saída.

A Figura 10 mostra um fluxograma correspondente as camadas da rede neural, bem como a devida ordem de cada uma no algoritmo.

**Figura 10** – Camadas da rede neural



Fonte: Autoria própria (2023).

No item 4.1 desse trabalho foram realizadas quatro análises com o objetivo de determinar o quantitativo de neurônios por camada, o tamanho do lote, o número de épocas e o tamanho da janela temporal, que melhor se adequassem na construção do modelo. Para cada análise foram realizados cinco experimentos diferentes e escolhido o que apresentou um menor Erro Médio Absoluto Percentual (MAPE) na etapa de teste. Os parâmetros iniciais utilizados para realizar os experimentos estão apresentados no Quadro 2.

## Quadro 2 – Parâmetros iniciais utilizados para fazer as análises

Parâmetro	Geração Diária e Horária
Tamanho do Lote	5
Número de Épocas	30
Tamanho da Janela Temporal	11

Fonte: Autoria própria (2023).

Vale destacar que após realizado cada experimento, o quantitativo que apresentou o menor valor do MAPE foi adotado para a análise seguinte. Por exemplo, no experimento para se determinar o tamanho da janela temporal os valores dos demais parâmetros já estavam definidos a partir das etapas anteriores.

### 3.3 Treinamento e Teste

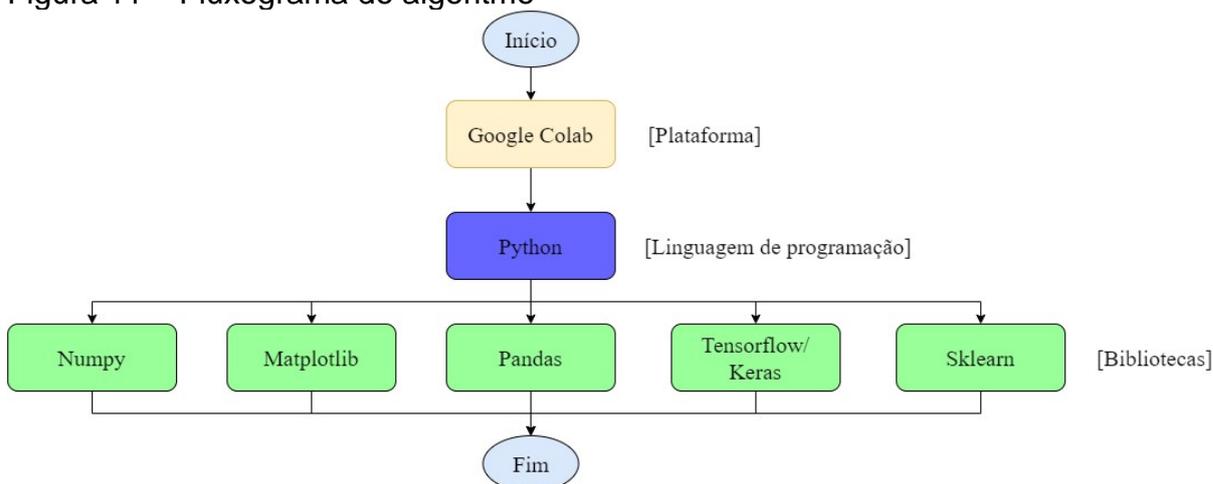
A base de dados coletada teve um período de 3 anos, sendo assim, foi definido que o treinamento da rede seria feito com os primeiros 2 anos e 6 meses (equivalente a 83,33% do período total), no prazo de 01/01/2020 a 30/06/2022.

Após o treinamento da rede, utilizou-se o algoritmo para fazer a previsão da geração diária e horária em kWh e comparar os dados obtidos com os valores de teste, em que, o período de dados de teste foi de 01/07/2022 a 31/12/2022 (6 meses de dados, os quais, equivalem a 16,67% do período total).

### 3.4 Simulação e Avaliação do Método

Para construir o algoritmo e simular o método foram utilizadas as ferramentas que estão expostas no fluxograma da Figura 11.

Figura 11 – Fluxograma do algoritmo



Fonte: Autoria própria (2023).

Conforme a Figura 11, para construir o algoritmo e simular o método foi utilizado o *Google Colab*, que é uma plataforma online que usa a linguagem de programação *Python* para construir, editar e simular códigos. Para isso foi utilizada a biblioteca *Numpy*, que tem a função de se trabalhar com computação numérica, a *Matplotlib*,

com o objetivo de construir os gráficos e as bibliotecas *Keras* e *Sklearn*, utilizadas para criar a rede neural em si.

As métricas utilizadas para avaliar o método no treinamento e no teste foram: o MSE (utilizada apenas no treinamento), a RMSE, o MAE e o MAPE. O MSE calcula a média da diferença quadrática entre os valores previstos e reais, vide Eq. (2). Quando os valores de previsão são muito diferentes dos reais, essa métrica aumenta consideravelmente, sendo a sua unidade de medida o  $(\text{kWh})^2$ . O RMSE calcula a raiz quadrada do MSE, conforme Eq. (3), dessa forma, grandes discrepâncias também são evidenciadas em sua unidade kWh. Enquanto isso, o MAE obtém o valor médio da diferença entre os valores previstos e reais, também em kWh, de acordo com a Eq. (4). Por último, o MAPE também calcula o valor médio das diferenças entre os valores previstos e reais, porém, de forma percentual (%), vide Eq. (5) (JÚNIOR, 2021).

$$MSE = \frac{1}{N} \sum_{t=1}^N (y'(t) - y(t))^2 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y'(t) - y(t))^2} \quad (3)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |y'(t) - y(t)| \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left[ \left( \frac{y'(t) - y(t)}{y(t)} \right) 100 \right] \quad (5)$$

em que,  $y'(t)$  é o valor previsto pelo algoritmo no instante  $t$ ,  $y(t)$  corresponde ao valor real no momento  $t$  e  $N$  é a quantidade total de amostras do conjunto de dados de teste.

#### 4 RESULTADOS E ANÁLISE

Os resultados encontrados nessa pesquisa estão expostos da seguinte forma, no tópico 4.1 e seus subtópicos é apresentado o melhor valor de cada hiperparâmetro encontrado nos experimentos. Em seguida, com o modelo final já definido foram obtidos os valores do RMSE, MAE e MAPE para o período total de 6 meses de teste na geração diária e horária. Além disso, tendo consciência de que a base de dados do período de teste de geração horária é muito maior do que a de geração diária (11 horas de dados por dia), foram obtidos também os valores dos erros para as primeiras 120 horas no teste do segundo caso. Por fim, foi realizada uma pesquisa na Literatura para coletar os resultados encontrados em estudos semelhantes, com o objetivo de verificar se os valores dos erros obtidos nesse trabalho estavam coerentes com as demais pesquisas da área.

## 4.1 Outros Hiperparâmetros

Como mencionado no subtópico 3.2 dessa pesquisa, foram realizados experimentos para determinar a quantidade de neurônios por camada, o tamanho do lote, o número de épocas e o tamanho da janela temporal, em que, os valores definidos foram 100, 15, 30 e 11 para a geração diária e 125, 15, 30 e 33 para a geração horária, respectivamente. Conforme os itens 4.1.1 ao 4.1.4.

### 4.1.1 Quantidade de Neurônios da Rede Neural

A quantidade de neurônios das camadas de entrada e saída foi fixada em 1 neurônio. Em relação às camadas intermediárias, foram realizadas cinco análises com valores iguais a 25, 50, 75, 100 e 125 para cada camada. Com o objetivo de saber qual número de neurônios forneceu um melhor desempenho de previsão, foi calculado o valor do MAPE na etapa de teste. A Figura 11 mostra que o menor erro foi obtido para os quantitativos de 100 e 125 neurônios por camada, para a previsão de geração diária e horária, respectivamente. Com isso, esses valores foram adotados para poder determinar os demais parâmetros.

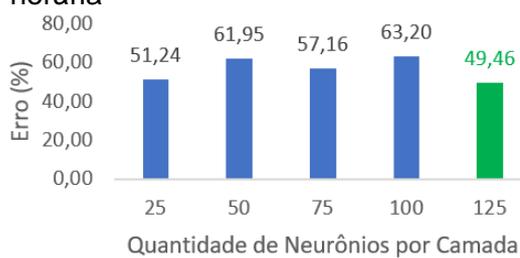
Figura 11 – Quantidade de Neurônios (MAPE)

(a) Valor do MAPE no teste da geração diária



Fonte: Autoria própria (2023).

(b) Valor do MAPE no teste da geração horária



Fonte: Autoria própria (2023).

### 4.1.2 Tamanho do Lote

Com a quantidade de neurônios definida, o próximo passo foi analisar qual o tamanho do lote utilizar na construção do modelo, sendo assim, foram analisados diferentes tamanhos de lotes, sendo esses, 10, 15, 20, 25 e 30 amostras de dados. O menor valor do MAPE foi obtido usando o tamanho de 15 amostras, para os dois modos de previsão.

Figura 12 – Tamanho do Lote (MAPE)

(a) Valor do MAPE no teste da geração diária



Fonte: Autoria própria (2023).

(b) Valor do MAPE no teste da geração horária



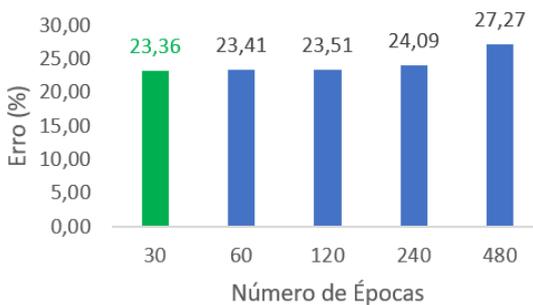
Fonte: Autoria própria (2023).

### 4.1.3 Número de Épocas

Para determinar o número de épocas que melhor se adequasse ao modelo, foram analisados os valores do MAPE no teste para experimentos com 30, 60, 120, 240 e 480 épocas. Em que, os menores valores do erro foram obtidos para as simulações com 30 épocas, em ambos os modos de previsão.

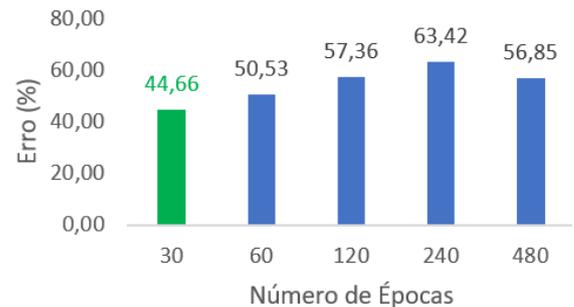
Figura 13 – Número de Épocas (MAPE)

(a) Valor do MAPE no teste da geração diária



Fonte: Autoria própria (2023).

(b) Valor do MAPE no teste da geração horária



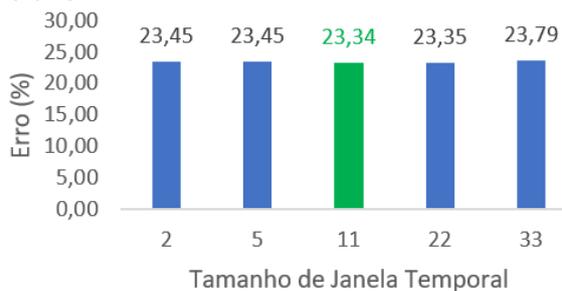
Fonte: Autoria própria (2023).

### 4.1.4 Tamanho da Janela Temporal

Na análise de qual o tamanho da janela temporal utilizar foram feitas cinco simulações com diferentes configurações, sendo elas, 2, 5, 11, 22 e 33 amostras. Os melhores resultados foram encontrados para os tamanhos de janela temporal iguais a 11 e 33, no teste de previsão de geração diária e horária, respectivamente.

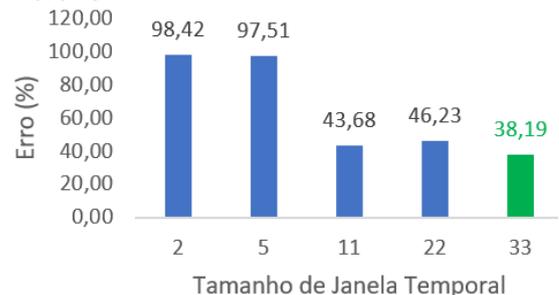
Figura 14 – Tamanho da Janela Temporal (MAPE)

(a) Valor do MAPE no teste da geração diária



Fonte: Autoria própria (2023).

(b) Valor do MAPE no teste da geração horária

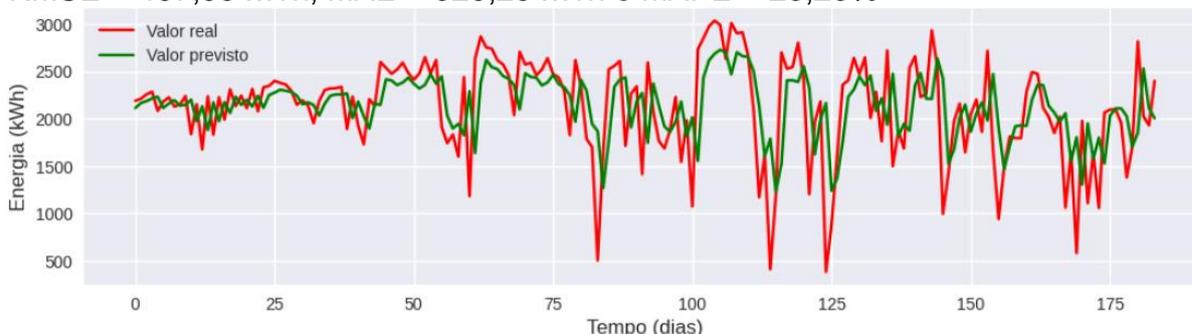


Fonte: Autoria própria (2023).

## 4.2 Previsão Diária da Geração Fotovoltaica

A partir da escolha dos hiperparâmetros que apresentaram os menores valores de MAPE, o algoritmo foi simulado com o objetivo de coletar os valores do RMSE, MAE e MAPE no teste com o modelo final. Os resultados no teste de previsão de geração diária são apresentados na Figura 15.

Figura 15 – Resultados obtidos no teste de previsão de geração diária  
 RMSE = 467,95 kWh, MAE = 329,25 kWh e MAPE = 23,23%



Fonte: Autoria própria (2023).

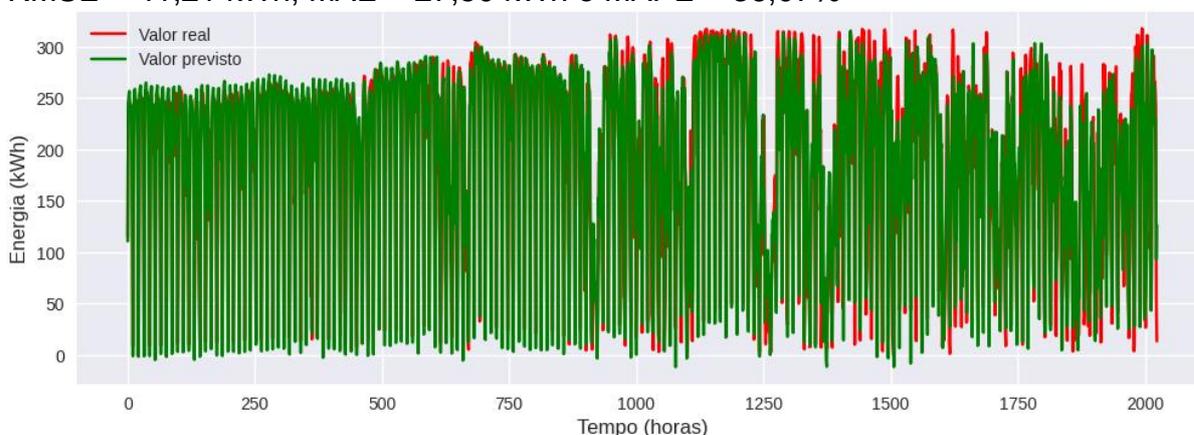
Embora os valores dos erros possam parecer elevados em um primeiro momento, é importante entender exatamente o que esses valores representam e quais conclusões pode-se obter a partir deles. Como o RMSE e o MAE levam em consideração a ordem de grandeza dos dados trabalhados, era esperado que esses dessem valores grandes, isso ocorre porque se está trabalhando com o acumulado de energia do dia inteiro. Para se ter uma ideia, a média de geração real diária do período de teste foi de 2124,84 kWh, e como o valor do MAE foi de 329,25 kWh significa que em média essa é a variação entre o valor real e previsto.

Em contrapartida ao exposto acima, a ordem de grandeza dos valores não importa para o MAPE, diminuindo o risco de haver uma má interpretação do resultado. Como mostra na Figura 15, o MAPE encontrado foi de 23,23%, o que é esperado, tendo em mente que foi utilizada apenas uma entrada para treinar a rede neural.

### 4.3 Previsão Horária da Geração Fotovoltaica

Da mesma forma que no item anterior, depois de definir todos os hiperparâmetros, foi realizada mais uma simulação com o modelo final de geração, agora com a base de dados de geração horária, a fim de coletar os valores das métricas utilizadas no teste. Os resultados obtidos estão representados nas Figuras 16 e 17.

Figura 16 – Resultados obtidos no teste de previsão de geração horária  
 RMSE = 41,21 kWh, MAE = 27,50 kWh e MAPE = 36,07%



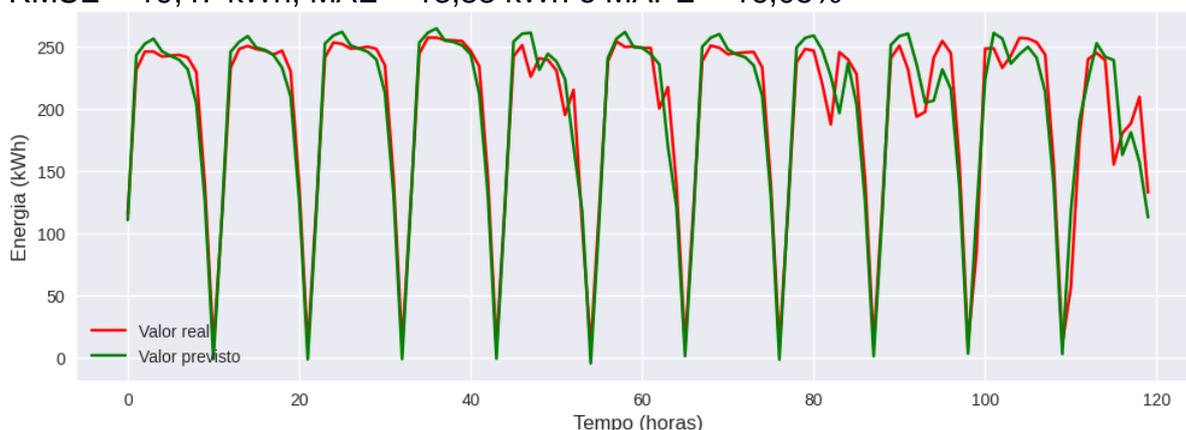
Fonte: Autoria própria (2023).

Como mencionado no item 4.2, o RMSE e o MAE levam em consideração a ordem de grandeza dos valores que se está trabalhando, por isso que esses resultaram em valores significativamente mais baixos no teste de previsão de geração horária, se comparado com o anterior. Nesse caso, o valor médio da geração real no período de teste foi de 193,19 kWh e o MAE teve um valor de 27,50 kWh, ou seja, em média o valor previsto difere do real em 27,50 kWh.

O MAPE obtido foi de 36,07%, e como ele independe da ordem de grandeza dos valores, é importante entender o porquê esse deu um valor consideravelmente maior no teste de previsão horária do que no anterior. Isso ocorreu devido uma maior dificuldade em se prever a geração de forma horária, por conta da grande variação no valor da energia durante o dia, ou seja, nesse caso a variação nos valores da energia é muito maior do que a variação da geração diária ao longo dos dias.

Tendo ciência de que o gráfico da Figura 16 não fornece uma forma de visualização tão adequada quanto o da Figura 15, foi feito um recorte nas primeiras 120 horas no teste de previsão de geração horária, para se ter uma melhor compressão de como ficou a diferença entre os valores de previsão e os valores reais, conforme Figura 17.

Figura 17 – Teste da geração horária para as primeiras 120 horas  
RMSE = 19,47 kWh, MAE = 13,83 kWh e MAPE = 16,05%



Fonte: Autoria própria (2023).

Ao comparar as Figuras 16 e 17, percebe-se que os valores dos erros nas primeiras 120 horas foram menores do que no período total de 6 meses do teste, isso ocorreu devido ao tamanho da janela temporal utilizado, que foi 33. Como esses dados tinham acabado de passar no treinamento ficou mais fácil para fazer a previsão da primeira hora e assim por diante. Enquanto para períodos maiores será mais complexo o processo de previsão, pois, o erro entre os valores reais e previstos poderão se acumular ao longo do teste.

#### 4.4 Comparativo com Outros Estudos

Como forma de entender se os erros de previsão encontrados nesse trabalho foram adequados, foi feita uma pesquisa dos resultados obtidos em estudos com o mesmo tema. Para fazer essa análise foi utilizado os erros encontrados com os valores normalizados, tendo em vista que esse é o padrão utilizado para fazer comparativos entre diferentes trabalhos, conforme Tabela 3.

**Tabela 3 – Comparativo dos resultados com outros estudos da área**

Estudo	Ano	Entrada da Rede	Saída da Rede	Rede	Horizonte de Previsão	Erro(s) de Previsão
CUNHA, B. A.; MARAFÃO, F. P.; MARTINS, A. C. G.	2021	Geração FV	Geração FV	LSTM	1 h	MSE = 0,176 RMSE = 0,419 MAE = 0,305
KONSTANTINO, M.; PERATIKOU, S.; CHARALAMBIDES, A. G.	2021	Geração FV	Geração FV	LSTM	1,5 h	RMSE = 0,093
GENSLER, A.; HENZE, J.; SICK, B.; RAABE, N.	2016	Temperatura, Filtro de céu claro, Radiação direta e difusa	Geração FV	AutoEncoder (AE) e LSTM	1 dia	RMSE = 0,0713
AMORIM, D. A.; LIMA NETA, R. M. (previsão diária)	2023	Geração FV	Geração FV	LSTM	1 dia	MSE = 0,023 RMSE = 0,152 MAE = 0,109
AMORIM, D. A.; LIMA NETA, R. M. (previsão horária)	2023	Geração FV	Geração FV	LSTM	1 h	MSE = 0,014 RMSE = 0,119 MAE = 0,083

Fonte: Autoria própria (2023).

De acordo com a Tabela 3, é possível concluir que os resultados encontrados nessa pesquisa foram promissores, pois, os valores dos erros obtidos em todos os trabalhos foram semelhantes entre si. Deve-se levar em consideração também que foi utilizada apenas uma entrada para o treinamento da rede neural no presente estudo.

## 5 CONSIDERAÇÕES FINAIS E CONCLUSÕES

Essa pesquisa consistiu em criar um algoritmo utilizando a rede neural recorrente LSTM para fazer a previsão de geração solar FV da usina de Pirapora – MG, de forma diária e horária. Para isso, foi utilizada a plataforma online *Google Colab*, que permite criar e editar códigos na linguagem de programação *Python*.

Para fazer o treinamento e teste da rede foram coletados os dados históricos de geração da usina através do ONS. Esses dados foram utilizados para definir os melhores hiperparâmetros da rede, tanto na forma de previsão diária quanto horária, em que, foi encontrado um quantitativo de 100 e 125 neurônios por camada, respectivamente. Foram obtidos um tamanho de lote de 15 e um número de épocas de 30 para ambas as formas de previsão. Enquanto isso, o tamanho da janela temporal definida foi 11 para o primeiro caso e 33 para o segundo.

As métricas utilizadas para avaliar o método na etapa do teste foram o RMSE, MAE e MAPE, que apresentaram valores de 467,95 kWh, 329,25 kWh e 23,23% na forma de previsão diária e 41,21 kWh, 27,50 kWh, 36,07% na horária, considerando um período de teste de 6 meses. Além disso, foram calculados os valores dos erros para um período de 120 horas do teste, no qual, obteve-se um RMSE de 19,47 kWh, um MAE de 13,83 kWh e MAPE de 16,05%. Como mencionado no item 4.4, esses resultados foram de acordo com o esperado, comparando com os demais estudos da área.

A eficiência das redes neurais artificiais recorrentes dependem da quantidade de entradas que são utilizadas para o seu treinamento, sendo assim, para trabalhos futuros é aconselhado aumentar essa quantidade, para que se possa obter menores erros. Por exemplo, poderão ser utilizadas a temperatura e a irradiação como variáveis de entrada para realizar o treinamento da rede neural.

## 6 AGRADECIMENTOS

O autor agradece a grande contribuição da orientadora ao longo do trabalho, aos avaliadores da banca de defesa pelas críticas construtivas que enriqueceram ainda mais esse artigo e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pelo incentivo na elaboração dessa pesquisa.

## REFERÊNCIAS

ANEEL, Agência Nacional de Energia Elétrica. **Sistema de Informações de Geração da ANEEL (SIGA)**. Disponível em: <<https://bit.ly/2lGf4Q0>>. Acesso em: 28 set, 2022.

ARAÚJO, M. S.; ALVES, L. M.; CARVALHO, P. C. M.; CARNEIRO, T. C. Metodologia Baseada em Redes Neurais Para Previsão de Geração de Plantas Fotovoltaicas. Florianópolis (SC): **IX Congresso Brasileiro de Energia Solar**, 2022.

CUNHA, B. A.; MARAFÃO, F. P.; MARTINS, A. C. G. Previsão intra-diária de geração fotovoltaica usando redes neurais recorrentes do tipo LSTM e dados históricos de energia. Bauru (SP): **Universidade Estadual Paulista (UNESP)**, 2021.

Data Science Academy. **Deep Learning Book**, 2022. *E-book*. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 10 jan. 2022.

DIAS, M. P. A.; INÁCIO, M. J.; JÚNIOR, Á. B. C. Aplicação de Redes Neurais Artificiais para Previsão da Incidência Solar na Cidade de Belo Horizonte. **Braz. J. of Develop.**, Curitiba, v. 6, n. 7, p. 52603-52615 jul. 2020. ISSN 2525-8761.

DUARTE, G. Redes Neurais | Redes Neurais Recorrentes. **Medium**. Disponível em: <<https://www.medium.com.br/>>. Acesso em: 15 jun, 2022.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes Neurais Artificiais: Princípios Básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, Paraná, v. 1, n. 13, p. 47-57, jan./jun. 2016 ISSN 2175-1846.

FURTADO, M. I. V. Redes Neurais Artificiais: Uma Abordagem Para Sala de Aula. Ponta Grossa (PR): **Atena Editora**, 2019.

Gensler, A.; Henze, J.; Sick, B.; Raabe, N. Deep Learning for solar power forecasting—An approach using AutoEncoder and LSTM Neural Networks. In Proceedings of the 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Budapest, Hungary, 9–12 October 2016; **Institute of Electrical**

**and Electronics Engineers (IEEE): Piscataway, NJ, USA, 2016; pp. 002858–002865.**

HERBERT, Í. Introdução ao perceptron MLP. **Italo Info**. Disponível em: <<https://www.italoinfo.com.br/>>. Acesso em: 13 jun, 2022.

JONES, M. T. Um mergulho profundo nas redes neurais recorrentes. **iMasters**. Disponível em: <<https://www.imasters.com.br/>>. Acesso em: 15 jun, 2022.

JULIANI, JEFERSON. Gerando Letras Musicais Utilizando Uma Rede Neural Recorrente LSTM - *Long Short-Term Memory*. Russas (CE): **Universidade Federal Do Ceará**, 2019.

JÚNIOR, Clébio. Métricas para Regressão: Entendendo as métricas R<sup>2</sup>, MAE, MAPE, MSE e RMSE. **Medium**. Disponível em: <<https://medium.com/data-hackers/prevendo-n%C3%BAmoros-entendendo-m%C3%A9tricas-de-regress%C3%A3o-35545e011e70>>. Acesso em: 07 maio. 2023.

JÚNIOR, José. Redes Neurais Recorrentes – LSTM. **Medium**. Disponível em: <<https://medium.com/>>. Acesso em: 12 dez. 2022.

KONSTANTINOU, M.; PERATIKOU, S.; CHARALAMBIDES, A. G. Solar Photovoltaic Forecasting of Power Output Using LSTM Networks. **Atmosphere** 2021, 12,124. <https://doi.org/10.3390/atmos12010124>.

LEANDRO, Jhonatan. AMORIM, William. Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras. Dourados (MS): **Universidade Federal Da Grande Dourados (UFGD)**, 2021.

MARTINS, R. P.; FERREIRA, V. H.; LOPES, T. T. Previsão Probabilística de Energia Solar Utilizando Redes Neurais com Inferência Bayesiana e Mistura de Gaussianas. Niterói (RJ): **Universidade Federal Fluminense (UFF)**, 2018.

MENDES, A. L. S. O Papel Da Autoprodução e Produção Independente de Energias Renováveis no Mercado Brasileiro de Energia Elétrica. Vitória (ES). 2011.

OLIVEIRA, E.; OLIVEIRA, L. Análise de Desempenho de Método Baseado em Rede LSTM para Classificação de Falhas em um Processo de Controle de Nível. Natal (RN): **Universidade Federal Do Rio Grande Do Norte**, 2020.

OLIVEIRA, G. L. S.; SILVA, M. S. Utilização das Redes Neurais Artificiais para Previsão de Radiação Solar. Pesqueira (PE): **Instituto Federal de Pernambuco**, 2022.

PALMIERE, S. E. Rede Perceptron de uma única camada. **Embarcados**. Disponível em: <<https://www.embarcados.com.br/>>. Acesso em: 13 jun, 2022.

PINHEIRO, E.; LOVATO, A.; RÜTHER, R. Aplicabilidade de Redes Neurais Artificiais para Análise de Geração de Energia de um Sistema Fotovoltaico Conectado a Rede Elétrica. **Revista Brasileira de Energias Renováveis**, v.6, n.5, p. 875-892, 2017.

SILVA, I. V.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. São Paulo (SP): **Artliber Editora**, 2010.

VASCO, L. P.; CAMARGO, H. A. Um Estudo de Redes Neurais Recorrentes no Contexto de Previsões no Mercado Financeiro. São Paulo (SP). **Universidade Federal de São Carlos – UFSCar**, 2020.