

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

**Icaro Gabriel Paiva Bastos** (UFAL) - igpb@ic.ufal.br

**Gustavo Costa Gomes** (UFAL) - gustavocosta@ic.ufal.br

**Ícaro Bezerra Queiroz Araújo** (UFAL) - icaro@ic.ufal.br

**Erick de Andrade Barboza** (UFAL) - erick@ic.ufal.br

**Tiago Vieira** (UFAL) - tvieira@ic.ufal.br

**Davi Bibiano Brito** (UFAL) - davi@ic.ufal.br

## **Resumo:**

*A natureza estocástica das condições climáticas, tais como radiação solar, temperatura ambiente, velocidade do vento, influencia diretamente a geração de energia fotovoltaica. Em decorrência, estimar a quantidade de energia gerada é de suma importância para a qualidade da produção, de maneira a evitar problemas na rede elétrica. Este trabalho apresenta uma aplicação de redes LSTM (Long Short-Term Memory) para previsão de dados de geração (tensão e corrente) 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 e quantidade de chuva. Estas informações são utilizadas para alimentar uma rede neural do tipo LSTM cuja função é a predição dos dados de corrente e tensão produzidos pelos painéis solares. Os resultados mostraram que a rede LSTM apresenta bons valores de estimação, tendo um erro médio absoluto menor do que 1%, tanto para a corrente quanto para a tensão.*

**Palavras-chave:** *Energia Solar Fotovoltaica, LSTM, Previsão de Curto Prazo*

**Área temática:** *Radiação Solar*

**Subárea temática:** *Outros Dados Meteorológicos aplicados à energias renováveis*

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

Ícaro Gabriel Paiva Bastos – igpb@ic.ufal.br  
Gustavo Costa Gomes de Melo – gustavocosta@ic.ufal.br  
Ícaro Bezerra Queiroz de Araújo – icaro@ic.ufal.br  
Erick de Andrade Barboza – erick@ic.ufal.br  
Tiago Figueiredo Vieira – tvieira@ic.ufal.br  
Davi Bibiano Brito – davi@ic.ufal.br  
Universidade Federal de Alagoas, Instituto de Computação

**Resumo.** A natureza estocástica das condições climáticas, tais como radiação solar, temperatura ambiente, velocidade do vento, influencia diretamente a geração de energia fotovoltaica. Em decorrência, estimar a quantidade de energia gerada é de suma importância para a qualidade da produção, de maneira a evitar problemas na rede elétrica. Este trabalho apresenta uma aplicação de redes LSTM (Long Short-Term Memory) para previsão de dados de geração (tensão e corrente) 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 e quantidade de chuva. Estas informações são utilizadas para alimentar uma rede neural do tipo LSTM cuja função é a predição dos dados de corrente e tensão produzidos pelos painéis solares. Os resultados mostraram que a rede LSTM apresenta bons valores de estimação, tendo um erro médio absoluto menor do que 1%, tanto para a corrente quanto para a tensão.

**Palavras-chave:** Energia Solar Fotovoltaica, LSTM, Previsão de Curto Prazo

### 1. INTRODUÇÃO

O aumento da busca por fontes de 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 busca por novas tecnologias que aproveitam recursos naturais de maneira mais eficiente possível. A energia emitida pelo Sol em forma de radiação é a principal fonte de energia da Terra e pode ser aproveitada em inúmeras aplicações. 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 com 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 pequeno porte de micro e minigeração apresentam desafios adicionais para as distribuidoras de energia que 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 e 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 capaz 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 tensão e corrente produzidos por painéis fotovoltaicos, ou para previsão de dados climáticos relacionados. A Tab. 1 traz um resumo de algumas pesquisas desenvolvidas utilizando RNAs para modelar alguma característica relacionada à produção de energia solar fotovoltaica.

Tabela 1 - Trabalhos relacionados que utilizam RNA para prever dados de produção de energia solar fotovoltaica.

Trabalho	Modelo utilizado	Variáveis de entrada	Variáveis de saída
(De et al., 2018)	LSTM	Temperatura ambiente, Temperatura do painel, Irradiância, Potência, Energia Acumulada	Potência
(He et al., 2018)	LSTM	Irradiância	Potência
(Mahmoud et al., 2017)	LSTM	Potência	Potência
(Mellit et al., 2010)	MLP	Irradiância, Temperatura ambiente	Irradiância

Com base no exposto, o presente trabalho busca avaliar o desempenho da utilização de redes neurais recorrentes do tipo LSTM aplicadas para previsão da geração de corrente e tensão produzidas por painéis fotovoltaicos a partir de dados reais obtidos por uma estação solarimétrica de baixo custo construída no Instituto de Computação da Universidade Federal de Alagoas. Neste sentido, a importância do presente trabalho reside no fato de que aqui é apresentada uma solução de baixo custo capaz de promover um aumento no desempenho da produção de energia elétrica a partir da previsão dos valores de tensão e corrente.

Este trabalho encontra-se dividido nas seguintes seções: Na seção 1 é apresentada a introdução, na seção 2 é feita uma introdução sobre topologias de redes neurais recorrentes, na seção 3 são apresentadas algumas características da estação solarimétrica utilizada. Na seção 4 é apresentada a metodologia e os resultados obtidos são expostos na seção 5. Finalmente, na seção 6 são apresentadas as conclusões e discussões sobre o trabalho.

## 2. REDES NEURAS RECORRENTES

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.

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

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

e a saída é estimada por

$$\bar{y}_t = W_{hy}\bar{h}_t \quad (2)$$

como ilustrado na Fig. 1a. 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. Essa característica tem levado as redes recorrentes a serem muito usadas nos problemas de predição, tendo até um desempenho melhor do que os métodos matemáticos de previsão (Yu et al., 2019, He et al., 2018).




Figura 1 - Exemplos de redes neurais recorrentes. (a) Rede recorrente simples. (b) Unidade básica de composição de uma rede *Long Short-Term Memory* (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* (cf. Fig. 1b) permite a propagação da informação em longas sequências através de variáveis de *esquecimento* (ou *forget*,  $\bar{f}$ ) e *atualização* (*input*,  $\bar{i}$ ). Isto é, 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 segue

$$\bar{c}_t^{(k)} = \bar{f} \odot \bar{c}_{t-1}^{(k)} + \bar{i} \odot \bar{c}, \quad (3)$$

onde  $t$  é o instante de tempo na sequência;  $k$  corresponde ao índice da camada escondida;  $\odot$  representa produto elemento-a-elemento;  $\sigma$  denota a função sigmoide; e

$$\bar{i}, \bar{f}, \bar{o} = \sigma(W^{(k)}\bar{h}), \quad (4)$$

$$\bar{c} = \tanh(W^{(k)}\bar{h}) \quad (5)$$

e  $\bar{h}$  é a concatenação de  $\bar{h}_t^{(k-1)}$  e  $\bar{h}_{t-1}^{(k)}$ . Finalmente, os estados escondidos são atualizados pelos valores dos estados das células que devem ser memorizadas;

$$\bar{h}_t^{(k)} = \bar{o} \odot \bar{c}_t^{(k)}. \quad (6)$$

Finalmente, a predição é dada por  $\hat{y}_t = \sigma(\bar{h}_t^{(k)})$ .

De fato, redes LSTM mostram-se capazes de considerar influências de variáveis de entrada após vários passos de tempos e, neste trabalho, a utilizamos para realizar a previsão de valores de tensão e corrente utilizando como dados de entrada parâmetros climáticos coletados a partir de uma estação climatológica descrita na próxima seção.

### 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 Fig. 2a. A Fig. 2b 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.

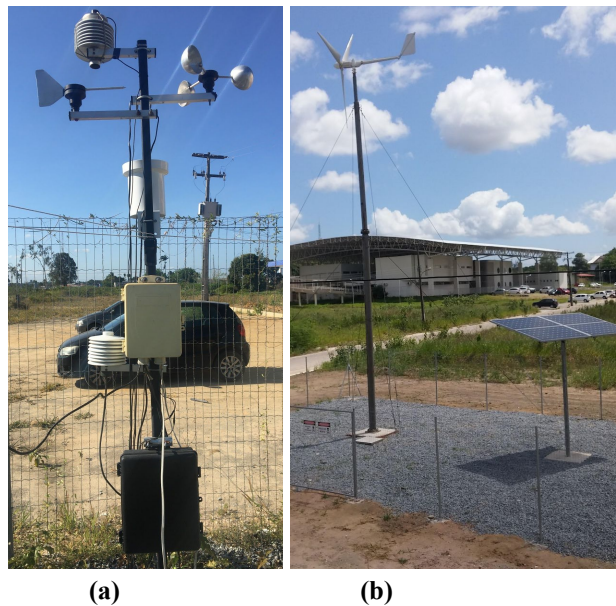


Figura 2 - Fotos da (a) estação solarimétrica e dos (b) painéis solares instalados na UFAL.

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.

Para capturar a irradiância solar foi utilizado um piranômetro de baixo custo da empresa LuZdoSOL com intervalo de medição variando entre 0 e 1479 W/m<sup>2</sup>. A medição de temperatura do módulo fotovoltaico é realizada através do sensor DS18B20 (Maxi Integrated, 2019), que possui um intervalo de leitura de -55°C a 125°C, entretanto a temperatura ambiente é medida através do barômetro BME280 da Bosch (Bosch Sensortec, 2019), que possui uma faixa de leitura entre -40°C e 85°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 Eq. (7) e (8).

$$RPM = (Contador\ Pulsos * 60) / (Periodo / 1000) \quad (7)$$

$$WindSpeed = (((4 * \pi * Raio * RPM) / 60) / 1000) * 3.6 \quad (8)$$

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 (Grupo SECON, 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 trinta dias, nos quais foram coletados em dias específicos nos meses de agosto a outubro. A quantidade de chuva acumulada não foi utilizada pois não possui características de série temporal. Por fim a base de dados possui uma tabela com 2.592.000 linhas e oito colunas. A Tab. 2 mostra os valores máximos e mínimos de cada variável em toda a base de dados coletada.

Tabela 2 - Valores máximo e mínimo de todas as variáveis medida no SI.

	Temperatura Ambiente	Temperatura a Painel	Irradiância	Umidade	Pressão	Velocidade	Tensão	Corrente
Máx.	33,04 °C	54 °C	1456 W/m <sup>2</sup>	98%	1013 hPa	60 km/h	268 V	3,48 A
Mín.	19,36 °C	17 °C	0 W/m <sup>2</sup>	0%	1003 hPa	0 km/h	0 V	0,014 A

## 4. METODOLOGIA

Para a implementação da estrutura LSTM, foi escolhida a linguagem de programação Python 3.6, assim como as bibliotecas de código aberto: KERAS (Chollet, 2015), scikit-learn (Pedregosa, 2011) por possuírem um bom desempenho para implementação de redes neurais.

A Fig. 3 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 pelos valores de leitura dos sensores meteorológicos naquele segundo. 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 os valores de tensão e corrente referentes ao próximo segundo, ou seja, dado as leituras dos sensores referente aos vinte segundos anteriores é possível estimar a tensão e a corrente do próximo segundo futuro. Uma configuração similar de rede neural recorrente foi utilizado no trabalho (Qing et al., 2018).

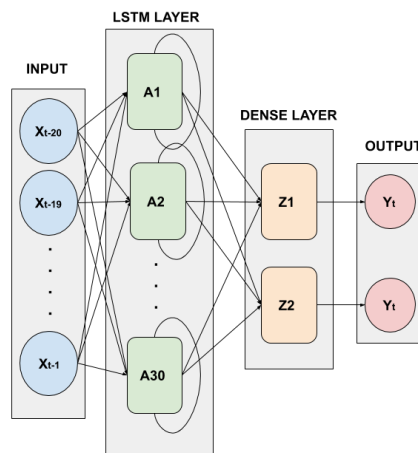


Figura 3 - Arquitetura da rede neural desenvolvida para o presente trabalho

Para o treinamento da LSTM foi necessário o tratamento dos dados coletados pela estação solarimétrica. Neste tratamento foram excluídos os dias que apresentaram erros de leitura em qualquer um dos sensores durante um grande período de amostras, e no dia em que algum sensor teve um dado faltante foi retirada a linha referente aquele instante. Após este tratamento a base de dados ficou constituída por uma série temporal de vinte e quatro dias. A base de dados foi dividida em vinte três dias para base de treinamento e um dia para a base de teste, cada dia possui intervalo amostral de apenas um segundo, isto é, um dia possui 86400 amostras tanto das variáveis de entradas quanto das variáveis de saída. Foram utilizadas como variáveis de entradas: temperatura do painel, temperatura ambiente, pressão, velocidade do vento, irradiância e umidade, as variáveis tensão e corrente foram utilizadas como saídas esperadas da rede neural. Estas variáveis foram normalizadas em um intervalo de 0 a 1.

A estrutura da rede é composta por trinta células na primeira camada, onde cada célula possui uma sequência de neurônios LSTM realimentados. A saída de cada sequência LSTM retorna um valor que é passado como entrada para as duas células da camada DENSE, estas por sua vez possuem a função de ativação linear, assim os resultados dessa última camada são as variáveis tensão e corrente previstas.

Durante a fase de treinamento foram definidos os pesos das conexões de forma que a obter um menor erro de predição nas variáveis saída. Para o treinamento foram escolhidos o otimizador Adam e a função de perda erro quadrático médio, essa é uma escolha padrão na maioria dos casos em que se utiliza LSTM (Qing et al., 2018). Foram considerados dois critérios de parada: quando o treinamento atinge cem épocas ou quando a função de perda tem uma melhoria inferior a  $1 \times 10^{-10}$  em relação à época anterior.

Para avaliar o desempenho da rede neural treinada foram criadas janelas de tempo com os dados da base de teste, os dados dentro da janela foram inserido como entrada na rede, as saídas gerada por cada entrada foram desnormalizadas e comparadas com os valores reais de leitura do sensor naquele instante. A métrica escolhida para avaliar a qualidade do modelo de predição foi erro absoluto.

## 5. RESULTADOS

A Fig. 4 mostra o erro de treinamento (erro quadrático médio) em função do número de épocas de treinamento. É possível perceber que com o passar das épocas de treinamento existe uma diminuição do 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 78, atingindo assim o ponto de parada estabelecido durante a construção da rede, comprovando mais uma vez que a rede utilizada atingiu o seu estado de convergência.




Figura 4 - Erro de treinamento (erro quadrático médio) em função do número de épocas de treinamento.

Com a rede neural treinada foi possível fazer a previsão das variáveis tensão e corrente da base de teste. O resultado está ilustrado na Fig. 5. A série representada na linha vermelha apresenta os valores reais de tensão e corrente medidos pela estação, já a série representada pela linha pontilhada azul constitui os valores previstos pela rede. Visualmente é possível perceber que a rede conseguiu um bom desempenho na previsão das variáveis de saída durante o período das 8:00 até às 16:00 horas, que é o período de maior produção de energia elétrica do painel solar, porém não conseguiu prever a elevada oscilação da tensão durante o início da manhã e ao anoitecer.

Esta oscilação de tensão é causada pelo inversor de potência ao tentar rastrear o ponto de máxima potência dos módulos fotovoltaicos. Com a baixa irradiância, a geração fotovoltaica possui uma região de rastreamento do máximo ponto de potência (MPP) limitada, fazendo com que o inversor cause mudanças bruscas na tensão e corrente de operação dos módulos. O estudo realizado em (Mills, 2009) observou que no início da manhã e ao anoitecer as alterações nos níveis de radiação solar em um determinado ponto podem atingir até 60% dos seus valores de picos em questão de segundos.




Figura 5 - Valores de tensão e corrente reais (linha vermelha), e previstos pela rede (linha pontilhada azul), em função da hora de um dos dias considerados.

Para realizar uma melhor análise do desempenho da previsão foram gerados os gráficos *boxplots* referente ao erro absoluto entre os valores reais de tensão e corrente com os valores previstos pela rede neural, o resultado em relação a tensão é mostrado na Fig. 6a e a Fig. 6b mostra o erro referente a corrente. A Fig. 6b mostra que durante o período, das 8 às 16 horas, 50% dos erros absolutos estão abaixo de 0,031 A, tendo em vista que a maior corrente registrada nesse horário foi de 3,14 A, 0,031 A corresponde a apenas 0,98% do maior valor de corrente.

O mesmo acontece na Fig. 6a, onde o *boxplot* mostra que 50% dos erros absolutos estão abaixo de 1,71 V, isto corresponde a apenas 0,67% do maior valor de tensão registrada nesse horário. Ao analisar em relação ao dia todo a mediana sobe para 1,907 e o valor máximo sobe  $\sim 3$  V, isto acontece devido ao acréscimo dos erros durante o período do amanhecer e ao anoitecer.

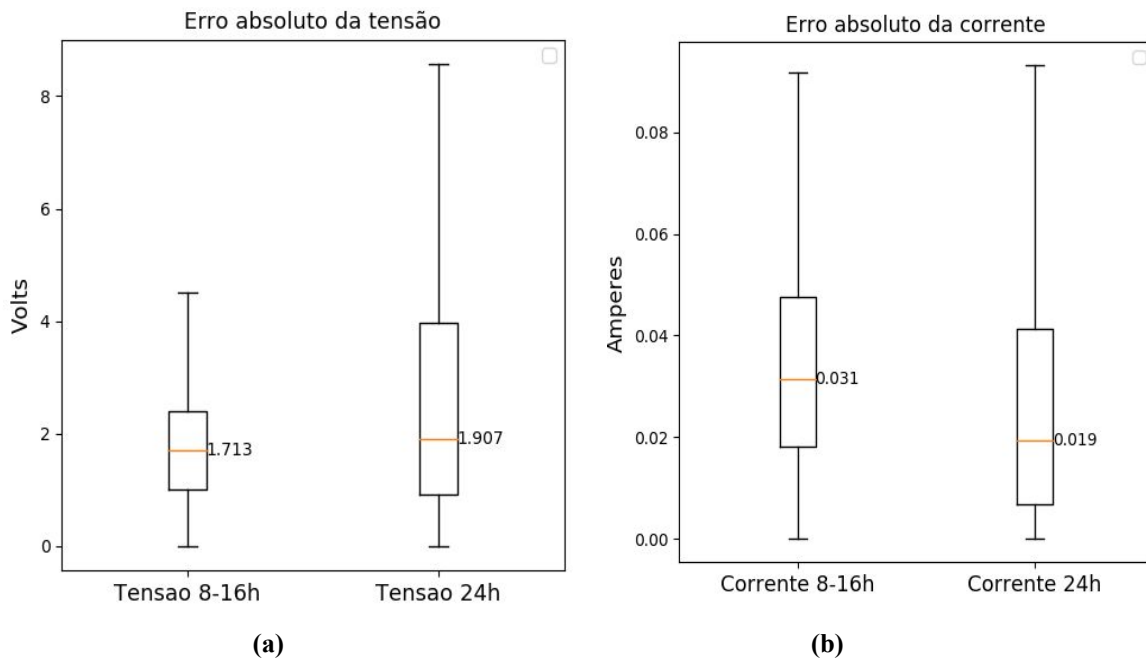


Figura 6 - Boxplots referente ao erro absoluto das variáveis de saídas. (a) Variável Tensão. (b) Variável corrente.

Durante os períodos de grande variação nos valores de tensão, a rede neural não consegue prever o comportamento oscilatório, divergindo muito do valor real. Para demonstrar este fato foi gerado o gráfico de dispersão do erro durante o dia todo (Fig. 7a) e apenas no intervalo das 8:00 às 16:00 horas (Fig. 7b). O eixo na horizontal representa os valores reais lidos pelos sensores, 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 com exatidão todos os valores.

Ao comparar os gráficos, pode-se afirmar que os pontos da Fig. 7a que estão afastados da reta vermelha, sem possuir uma característica linear, não pertencem ao intervalo de 8 às 16 horas. A Fig. 7b mostra que a previsão da tensão durante o período de maior geração elétrica do painel fotovoltaico foi precisa, possuindo um erro médio absoluto baixo.

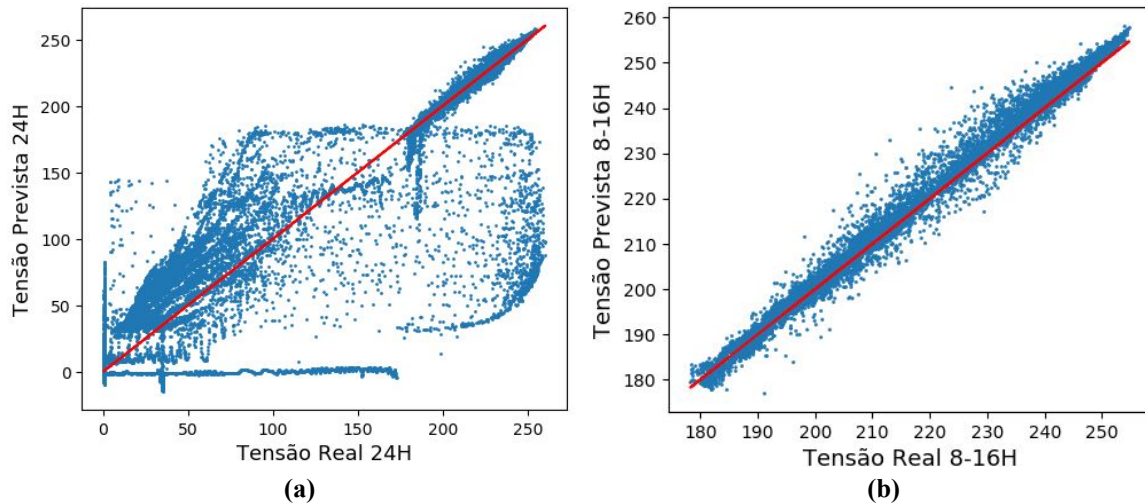


Figura 7 - Gráfico de dispersão referente ao erro absoluto da variável tensão. (a) Período de 24 horas. (b) Período de 8:00 às 16:00 horas




Figura 8 - Gráfico de dispersão referente ao erro absoluto da variável corrente. (a) Período de 24 horas. (b) Período de 8:00 às 16:00 horas

Por outro lado, a Fig. 8 mostrou que o erro absoluto da corrente obteve o mesmo comportamento durante todo o dia, ou seja, independente do horário, a dispersão do erro não variou significativamente, concluindo assim que a rede está conseguindo prever com eficiência o comportamento temporal da corrente, independente da hora do dia.

## 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 das variáveis de tensão e corrente.

Observou-se que nos horários em que a tensão teve uma grande oscilação a rede LSTM divergiu ao tentar prever os valores reais, 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 da rede ficou, em média, abaixo de 1%. 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 trabalhos futuros pretende-se verificar o impacto de cada variável meteorológica para criação de modelos de previsão. Além disso, com base na estação meteorológica criada, será feito um estudo sobre o impacto da taxa de amostragem dos dados nos modelos de previsão. Por fim, será possível criar modelos de previsão mais precisos e capazes de prever com maior antecedência.

### Agradecimentos

Os autores agradecem o apoio da Agência Nacional de Energia Elétrica (ANEEL) e do Grupo Equatorial de Energia.

### REFERÊNCIAS

- Abdel-Nasser, M., & Mahmoud, K., 2019. Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Computing and Applications*, vol. 31(7), pp. 2727-2740.
- Bosch Sensortec, 2019. BME 280. URL: [https://www.bosch-sensortec.com/bst/products/all\\_products/bme280](https://www.bosch-sensortec.com/bst/products/all_products/bme280). Acessado: 30/11/2019.
- Cantor, G. A. R., 2017. Influência dos fatores climáticos no desempenho de módulos fotovoltaicos em regiões de clima tropical.
- Coimbra, I. L., et al., 2018. Análise da previsão do vento em um parque eólico costeiro no Nordeste brasileiro. VII CBENS - Congresso Brasileiro de Energia Solar. Gramado.
- Chollet, F., et al, keras 2015: disponível em: <https://keras.io/getting-started/faq/>. Acesso em: 25/11/2019
- De, V., Teo, T. T., Woo, W. L., & Logenthiran, T., 2018. Photovoltaic power forecasting using LSTM on limited dataset. In *2018 IEEE Innovative Smart Grid Technologies-Asia, Asia*, pp. 710-715.
- Grupo SECON, 2019. Transdutores/Transmissores para Medidas de Parâmetros Elétricos. URL: <https://www.secon.com.br/grupo.php?id=16>. Acesso: 30/11/2019
- Guarnieri, R. A., et al., 2007. Previsões de Radiação Solar Utilizando Modelo de Mesoescala: Refinamento com Redes Neurais, I CBENS - I Congresso Brasileiro de Energia Solar, Fortaleza.
- Gupta, C. N., Palaniappan, R., Swaminathan, S., & Krishnan, S. M., 2007. Neural network classification of homomorphic segmented heart sounds. *Applied soft computing*, vol. 7(1), pp. 286-297.
- Haykin, S. Redes Neurais: Princípios e Prática. 2. ed. Porto Alegre: Bookman, 2007
- He, H., Hu, R., Zhang, Y., Zhang, Y., & Jiao, R., 2018. A Power Forecasting Approach for PV Plant based on Irradiance Index and LSTM. In *2018 37th Chinese Control Conference (CCC)*, (pp. 9404-9409).
- Machado, A. B., Rampinelli, G. A., 2018. Avaliação de métodos probabilísticos para preenchimento de lacunas de dados solarimétricos e previsão da irradiância solar de curto prazo. VII CBENS - Congresso Brasileiro de Energia Solar. Gramado.
- Maxi Integrated, 2019. DS18B20 Programmable Resolution 1-Wire Digital Thermometer. URL: <https://www.maximintegrated.com/en/products/sensors/DS18B20.html>. Acessado: 30/11/2019.
- Mellit, A., & 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*, vol. 84(5), pp. 807-821.
- Mills, A., 2009. Understanding variability and uncertainty of photovoltaics for integration with the electric power system.
- Pedregosa, et al. scikit-learn 2011: disponível em: <https://scikit-learn.org/stable/index.html>. Acesso em: 25/11/2019
- Qing, X., & Niu, Y., 2018. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, vol. 148, pp. 461-468.
- Sabino, E. R. C., et al., 2018. Previsão de temperatura ambiente horária voltada para auxiliar previsões de geração de potência fotovoltaica. VII CBENS - Congresso Brasileiro de Energia Solar. Gramado.
- Shilbayeh, N., & Al-Qudah, G., 2008. Face detection system based on MLP neural network. *Recent Advances in Neural Networks, Fuzzy Systems & Evolutionary Computing*, pp. 238-243.
- Yu, Y., Cao, J., & Zhu, J., 2019. An LSTM Short-Term Solar Irradiance Forecasting Under Complicated Weather Conditions. *IEEE Access*, vol. 7, pp. 145651-145666.

## PHOTOVOLTAIC GENERATION FORECASTING FROM METEOROLOGICAL DATA USING LSTM NETWORK

**Abstract.** Stochastic nature of some meteorological factors, such as the local solar radiance, ambient temperature, wind speed, directly influences photovoltaic energy generation. Due to this, estimate the produced energy amount is fundamentally important to production quality, in what to avoid problems on electrical network. Therefore, this article presents an analysis of prediction methods for generation data (voltage and current) on photovoltaic panels from meteorological data usage. The data were collected from an low-cost solarimetric station close to the production plant. Obtained information include: solar radiance, panels temperature, ambient temperature, humidity, wind speed and rain amount, used to feed an Long Short-Term Memory (LSTM) neural network, whose function is the prediction of current and voltage produced by the solar panels data. Results show that the LSTM Network presents good estimation values, having an average error lower than 1%, both for current and voltage.

**Key words:** Photovoltaic Solar Energy, LSTM, Short-term Forecast