

# Deep Learning for Photovoltaic Generation Forecast in Active Solar Trackers

C. Kasburg, and S. Frizzo

**Abstract**—The generation of electricity by photovoltaic panels depends on the position of solar incidence on them. Using active solar trackers may be a maximization of generating capacity. However, if motors that update the position of the panels use more energy than the efficiency in their use, the system becomes ineffective. In this way, solar forecasting can be used to actively determine the generation capacity and to assess whether position updating is efficient. Among the algorithms that can be used to predict photovoltaic generation, stands out the Long Short-Term Memory (LSTM) which is an artificial recurrent neural network architecture used in deep learning. This technique stands out among the others for having the ability to handle complex problems with high nonlinearity. The results of the application of LSTM for photovoltaic generation forecast in active solar trackers are promising as described in this article.

**Index Terms**—Long Short-Term Memory, Solar Active Trackers, Photovoltaic Power Prediction.

## I. INTRODUÇÃO

EXISTE uma grande e crescente necessidade de demanda de energia elétrica [1-2]. Para atender as necessidades dos consumidores os sistemas de geração de energia elétrica precisam ser aprimorados de forma gradativa, para que possam substituir as matrizes energéticas não renováveis [3]. A utilização de seguidores solares pode aumentar a captação de radiação solar em painéis fotovoltaicos (PV) e desta forma aumentar sua eficiência [4].

Com base na necessidade do planejamento energético, sistemas de previsão podem auxiliar a tomada de decisão em relação a utilização dos seguidores solares [5]. Caso o sistema consuma mais energia para atualizar sua posição em relação a quantidade de energia produzida, sua utilização se torna desnecessária [6]. Desta forma, sistemas de previsão de geração são fundamentais para certificar que a atualização dos seguidores solares é interessante para o sistema [7].

Segundo Panait e Tudorache [8] as redes neurais aplicadas a controle de geração solar, são conhecidas por sua habilidade em extrair soluções de problemas não lineares com parâmetros variáveis, que é exatamente o caso do seguidor solar. Alguns

autores desenvolveram algoritmos mais sofisticados para realizar a previsão de geração solar em PVs, conforme discutido na próxima subseção.

### A. Previsão de Geração Fotovoltaica

Baseado em uma abordagem de conjunto artificial otimizado para previsão de potência de geração de energia solar fotovoltaica, em [9] se apresentou um resultado promissor para o cálculo do erro nesta previsão. Em [10] se desenvolveu uma avaliação equivalente para previsão de energia fotovoltaica de curto prazo.

Utilizando neuro-fuzzy foi desenvolvido um estudo em [11] de previsão horária (com um dia de antecedência) para geração de energia fotovoltaica com base em modelos de previsão baseados no clima. Uma análise probabilística resumida para previsão de geração fotovoltaica é apresentada em [12] comparativamente com diversas técnicas. Utilizando um modelo gaussiano [13] e [14] realizaram um estudo completo sobre a capacidade de previsão em sistemas fotovoltaicos de pequeno porte.

Utilizando *deep learning*, Du, Zhang e Tian [15] realizaram uma avaliação de previsão de geração fotovoltaica em um edifício de grande porte. Também baseado em *deep learning* Huang e Kuo [16], avaliaram a previsão de energia fotovoltaica em curto prazo.

Utilizando memória longa de curto prazo (LSTM), equivalente a proposta neste artigo, o trabalho de [17] realiza uma avaliação da capacidade de previsão fotovoltaica com base em um algoritmo híbrido, que utiliza a transformada *wavelet*. Em [18] também utilizando LSTM é apresentado um resultado equivalente para previsão de curto prazo.

Os seguidores solares vêm como uma alternativa para melhorar ainda mais a eficiência de sistemas fotovoltaicos, na próxima subseção serão discutidas algumas formas de aplicação de seguidores solares.

### B. Seguidores Solares

Com base na declinação horária do sol na direção do eixo principal, o trabalho [19] se baseia em uma estratégia de seguimento normal e uma com ajuste diário dos módulos fotovoltaicos, ou seja, ajusta-se o eixo Norte/Sul uma vez ao dia e trabalha com uma velocidade de rotação fixa de 15°/h no eixo Leste/Oeste. O resultado nos testes de geração de energia nos módulos com seguidores solares, apresentou uma média de eficiência energética 23,6% maior em comparação aos módulos fixos, e 31,8% com seguimento diário, demonstrando viabilidade para o desenvolvimento de ambos os seguidores.

Este trabalho teve apoio financeiro do Fundo de Apoio à Manutenção e Desenvolvimento da Educação Superior (FUMDES), patrocinado pelo Governo do Estado de Santa Catarina.

C. Kasburg, estudante de graduação em Engenharia Elétrica na Universidade do Planalto Catarinense (UNIPLAC), Lages, Brasil. christopher.kasburg@uniplaclages.edu.br.

S. Frizzo Stefenon, coordenador do curso de graduação em Engenharia Elétrica na Universidade do Planalto Catarinense (UNIPLAC), Lages, Brasil. stefano@uniplaclages.edu.br.

O trabalho [20] apresenta o desenvolvimento e execução de um sistema seguidor de um eixo utilizando um motor de corrente contínua (CC), controlado por um drive dedicado, para movimentar o painel de acordo com os sinais recebidos de dois sensores de intensidade de luz.

Clifford e Eastwood [21], apresentam uma abordagem com tecnologia mais robusta, por se tratar de um sistema de seguimento passivo onde o seguimento é baseado na expansão térmica de chapas bimetálicas. Aplicando esta solução foi previsto um aumento de eficiência de 23%. Como este sistema é baseado em um controle direto em relação a variação térmica, não é necessário utilizar energia para o processamento dos dados.

Utilizando um sistema de seguimento polar *dual axis*, Alexandru e Pozna [22] desenvolveram um projeto virtual onde o algoritmo leva em conta a quantidade de movimentos realizados no seguimento em relação ao gasto de energia. Neste trabalho foram realizadas apenas simulações para comparação e análise de resultados.

Alguns fatores do dimensionamento de uma usina solar são de extrema importância, tais como orientação, inclinação e disponibilidade solar. Para um bom aproveitamento da disponibilidade solar no hemisfério Sul, os módulos devem estar corretamente orientados para o Norte Geográfico, pois assim irão receber sol em todas as estações do ano ininterruptamente.

A previsão de geração em PVs é consideravelmente importante, sendo que quanto maior a previsibilidade maior será a confiabilidade do sistema. A partir desta necessidade, este artigo propõe desenvolver um protótipo funcional, utilizando diferentes técnicas, e uma avaliação via software para determinar um valor em porcentagem para o aumento da eficiência de PVs usando *solar trackers dual axis*. Além disto, será avaliada a capacidade de previsão da geração deste sistema utilizando *deep learning*, especificamente memória longa de curto prazo para uma rede neural artificial recorrente. Desta forma este artigo apresenta uma avaliação inédita, em que o LSTM é utilizado com sucesso para previsão de geração em um seguidor solar.

Na seção II será discutido sobre o projeto do protótipo e suas características construtivas, na seção III será apresentado o método aplicado para previsão da série temporal e na seção IV serão avaliadas as capacidades de previsão do algoritmo. Por fim, na seção V serão apresentadas as considerações finais sobre a aplicabilidade da técnica.

## II. SEGUIDOR SOLAR DE DOIS EIXOS AZIMUTAL

A estrutura mecânica do sistema *solar trackers dual axis* permite que a posição seja ajustada em dois eixos, de Leste para Oeste (seguimento diário) e de Norte a Sul (conforme sazonalidade) de forma a garantir que os PVs sempre sigam a elevação e a posição do sol. Devido a capacidade de seguimento solar os módulos podem ser direcionados para ter a melhor captação do sol possível [23].

No sistema *dual axis azimutal* o movimento principal é realizado rotacionando os módulos em seu próprio eixo vertical de fixação, em espécie de mastro ou coluna. Assim se

torna necessário que os movimentos nos dois eixos estejam continuamente combinados de modo a obter rotação vertical e o movimento de elevação no eixo horizontal [24].

A quantidade de luz do sol incidente sobre a face do módulo é diretamente dependente do ângulo de incidência da fonte de luz. A maior área disponível para captação ocorrerá sempre quando raios solares estiverem atingindo paralelamente a face do módulo, criando um ângulo normal a superfície. Mantendo este ângulo o mais próximo possível de 0°, haverá a maior potência de saída possível. Este processo de monitorar e seguir a posição do sol é denominado *solar tracking* [25].

A posição dos seguidores solares pode ser calculada por um algoritmo de um controlador que orienta o posicionamento dos módulos de modo otimizado, ou pode ser feita através de sensores que comandam os atuadores. Os *active trackers* são seguidores solares que têm base microprocessada, em que o posicionamento dos módulos é calculado por um algoritmo que faz com que o sistema seja otimizado. Estes sistemas possuem drives de posicionamento operados eletricamente, que precisam de motores controlados, engrenagens e acoplamentos [26].

O método utilizado neste artigo para seguir o sol é um sistema de malha fechada com fotosensores que determinam a posição do sol com base na comparação de incidência luminosa e enviam esses dados ao controlador. O controlador avalia a melhor posição para o PV e manda sinais de comando para os atuadores.

O sistema *dual axis* pode ser considerado como uma estratégia híbrida de controle, pois o controlador além de receber dados dos sensores, calcula a posição do sol com base no horário e data do ano [27]. Utilizando 4 sensores este projeto tende a minimizar erros direcionais, visto que o processamento é adaptativo em relação a informação de luminosidade de cada sensor, desta forma o sistema pode ter um rendimento consideravelmente superior em condições climáticas desfavoráveis, como em dias chuvosos ou com nuvens passageiras [28].

Com base nestas características, foi projetado um seguidor solar modelo *dual axis, active tracker* com sensores resistores dependentes da luz (LDRs), e uma estrutura de dois eixos azimutal, conforme Figura 1. Para confecção do protótipo foi utilizado AutoCad e o corte do material foi realizado através de uma máquina de corte laser da marca Automatisa, modelo Prisma.



Fig. 1. Protótipo do seguidor solar em utilização.

Neste protótipo foram utilizados LDRs de 5 mm para comparação de incidência de luminosidade [29]. Os dados são gravados através de um periférico específico no controlador para gravação de dados em formato *.txt* em um cartão SD.

Para movimentar a estrutura foram necessários dois micro-servos 9g, modelo SG 90, conforme Figura 2, que possuem um movimento de até 180° [30]. Com estes motores é possível determinar quantos passos o eixo do motor deve girar, e consequentemente quantos graus. Os micro-servos 9g possuem um torque de 1,2 kg.cm e operam em 4,8 V através de sinais de controle do tipo *pulse width modulation* (PWM). A alimentação dos motores é realizada por fonte externa para não haver influência na medição da geração do PV.



Fig. 2. Servo-motores para controle de posição do PV.

Neste artigo foram utilizadas células fotovoltaicas de Silício policristalino, de 1.000 mW de potência de 6 VCC, que produzem uma corrente de até 200 mA. Para simular uma carga linear ideal, foram utilizados conjuntos de resistores de 25  $\Omega$  e 1.000 mW de potência. Além destes, foram utilizados resistores para fazer as associações com os LDRs, a fim de que os mesmos atingissem 10 k $\Omega$  e se obtivessem valores adequados de sinal para os controladores.

Para fins de comparação um PV equivalente foi utilizado para realizar a medição sem ação de controle. Este sistema fixo foi posicionado com uma angulação ideal para a latitude local de 23°, orientado para o Norte Geográfico. Na próxima seção será apresentado o método para previsão de geração fotovoltaica baseado em aprendizado profundo (*deep learning*) para este sistema.

### III. PREVISÃO UTILIZANDO APRENDIZADO PROFUNDO COM MEMÓRIA LONGA DE CURTO PRAZO

Na previsão, valores conhecidos da série temporal são utilizados até o ponto no tempo  $t$ , para que seja possível prever o valor em algum ponto no futuro,  $t + P$ . Com isto, se cria um mapeamento a partir dos pontos de dados da amostra  $D$ , amostrados a cada  $\Delta$  unidades no tempo,

$$x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t), \quad (1)$$

para um valor futuro previsto

$$y(t + P) = f(x). \quad (2)$$

Para prever os valores das etapas de tempo futuro de uma sequência, é necessário treinar a LSTM através de regressão da sequência. Desta forma, os dados são particionados para o treinamento e teste. Para se obter um melhor ajuste e evitar

que o treinamento seja divergente, os dados de treinamento são padronizados para terem uma média igual a zero. Os dados de teste são avaliados usando os mesmos parâmetros dos dados de treinamento.

Para prever os valores das etapas de tempo futuro de uma sequência, as respostas das sequências de treinamento são deslocadas por uma etapa de tempo. Com isto, a cada passo de tempo da sequência de entrada, a rede LSTM aprende a prever o valor do próximo passo de tempo.

A LSTM é uma rede neural artificial (RNA) recorrente utilizada na aprendizagem profunda que possui conexões de *feedback* diferentes das redes neurais *feedforward*. Uma unidade LSTM geralmente é composta de uma célula, uma porta de entrada, uma porta de saída e uma porta de esquecimento [31].

Com base em dados de séries temporais, os LSTMs são adequados para fazer previsões. Os LSTMs foram desenvolvidos para lidar com problemas graduais do treinamento de RNAs [32]. As LSTMs podem lembrar o estado da rede entre as previsões, isto é útil quando não se tem a série temporal completa antecipadamente ou se deseja fazer várias previsões em uma série temporal longa [33]. O fluxo de uma série temporal  $x$ , com recursos  $c$ , de comprimento  $s$ , através de uma camada LSTM é apresentado na Figura 3.

Neste caso,  $h_t$  e  $c_t$  denotam a saída e o estado da célula na etapa de tempo  $t$ , respectivamente. O primeiro bloco LSTM utiliza o estado inicial da rede e o primeiro passo de tempo da sequência para calcular a primeira saída e o estado da célula atualizado. Em um intervalo de  $t$ , o bloco usa o estado atual da rede ( $c_{t-1}$ ,  $h_{t-1}$ ) e o próximo passo de tempo da sequência para calcular a saída e o estado da célula atualizado  $c_t$ .

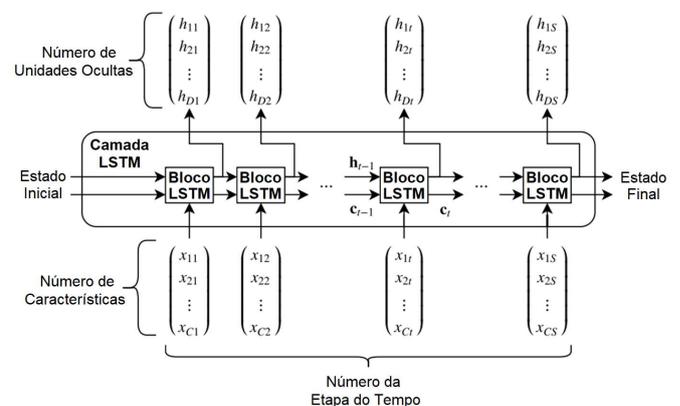


Fig. 3. Fluxo de uma série temporal para LSTM (traduzido de Matlab 2019).

O estado da camada está baseado no estado oculto e no estado da célula. O estado oculto no passo de tempo  $t$  contém a saída da camada LSTM para este intervalo de tempo. O estado da célula contém informações aprendidas nas etapas de tempo anteriores. Em cada etapa de tempo, a camada adiciona informações ou remove informações do estado da célula. A camada controla essas atualizações usando portões.

Os pesos aprendíveis de uma camada LSTM são os pesos de entrada  $W$ , os pesos recorrentes  $R$  e o bias  $b$ . As matrizes  $W$ ,  $R$  e  $b$  são respectivamente as concatenações dos pesos de entrada, dos pesos recorrentes e das tendências de cada

componente, conforme:

$$W = \begin{matrix} W_i \\ W_f \\ W_g \\ W_o \end{matrix}, \quad R = \begin{matrix} R_i \\ R_f \\ R_g \\ R_o \end{matrix}, \quad b = \begin{matrix} b_i \\ b_f \\ b_g \\ b_o \end{matrix}. \quad (3)$$

Sendo que  $i$  denota a porta de entrada para controlar o nível de atualização do estado da célula,  $f$  é o portão de esquecimento do controle de reconfiguração de estado,  $g$  é a célula candidata a adicionar informações e  $o$  é o portão de saída que controla o nível de estado da célula adicionado ao estado oculto. As equações a seguir descrevem os componentes na etapa de tempo  $t$ .

$$\begin{aligned} i_t &= \sigma_g(W_i x_t + R_i h_{t-1} + b_i), \\ f_t &= \sigma_g(W_f x_t + R_f h_{t-1} + b_f), \\ g_t &= \sigma_c(W_g x_t + R_g h_{t-1} + b_g), \\ o_t &= \sigma_g(W_o x_t + R_o h_{t-1} + b_o). \end{aligned} \quad (4)$$

Nessas equações,  $\sigma_g$  denota a função de ativação de *gate* e  $\sigma_c$  a função de ativação de célula, que é usada para atualizar a célula e o estado oculto. Para prever os valores das etapas de tempo futuro de uma sequência, as respostas das sequências de treinamento são deslocadas por uma etapa de tempo. Com isto, a cada passo de tempo da sequência de entrada, a rede LSTM aprende a prever o valor do próximo passo de tempo.

Para avaliar a capacidade do algoritmo, a rede de regressão LSTM pode ser especificada com variações de números de unidades ocultas e também de unidades nas camadas mais profundas. Além disto, é possível avaliar as formas de treinamento.

O algoritmo de descida de gradiente estocástico, atualiza os parâmetros de rede para minimizar a função de perda, tomando pequenos passos em cada iteração na direção do gradiente negativo da perda,

$$\theta_{i+1} = \theta_i - \alpha \nabla E(\theta_i). \quad (5)$$

Em que  $i$  é o número de iterações,  $\alpha$  é a taxa de aprendizado,  $\theta$  é o vetor dos parâmetros e  $E(\theta)$  é a função de perda a ser otimizada. A função  $E(\theta)$  é calculada pela relação do valor atual da rede para o valor desejado. Em cada iteração, o algoritmo de descida de gradiente estocástico avalia o gradiente e atualiza os parâmetros usando um subconjunto dos dados de treinamento. A descida do gradiente é estocástica porque as atualizações de parâmetros calculados são uma estimativa ruidosa da atualização de parâmetros, que resultaria no uso do conjunto de dados completo.

O algoritmo de descida de gradiente estocástico pode oscilar ao longo do caminho de descida mais íngreme em direção ao ótimo. Adicionar um termo de momentum à atualização de parâmetros é uma maneira de reduzir essa oscilação.

A atualização estocástica de gradiente descendente com momento (SGDM) é dada por:

$$\theta_{i+1} = \theta_i - \alpha \nabla E(\theta_i) + \gamma(\theta_i - \theta_{i-1}). \quad (6)$$

Onde  $\gamma$  determina a contribuição do passo do gradiente anterior para a iteração atual. O cálculo do SGDM usa uma única taxa de aprendizado para todos os parâmetros e será utilizado neste artigo.

#### A. Configuração do Algoritmo

Neste artigo para realizar a análise completa foi considerado 21.600 pontos do sinal, correspondendo a 6 horas de gravação por dia (das 12 h às 18 h), durante 6 dias distintos. Durante o dia 1 houve céu limpo, em um dia pós geada, com 0 mm de chuva. No dia 2, houve céu limpo na maior parte do dia, com nebulosidade durante aproximadamente 1h, próximo ao fim da tarde e também não houve chuva.

No dia 3 houve 5 mm de chuva ao fim da tarde (não ocorrendo no período de medição) e houve pouca nebulosidade às 13h e 16h. No dia 4 o céu estava nublado, houve 5 mm de chuva também fora do horário de medição. No dia 5 o céu estava com nuvens na manhã, e limpo a tarde no período de medição, não havendo chuva no dia. No dia 6 o céu estava com poucas nuvens e não houve chuva durante o dia.

Para fins comparativos definiu-se o valor máximo de 100 épocas para o treinamento. Para evitar que os gradientes tenham valores extremos se definiu o limiar igual a 1, com taxa de aprendizagem adaptativa. Após esta etapa as previsões são desnormalizadas usando os parâmetros calculados anteriormente. Para avaliação da performance da rede é avaliado o *root mean square error* (RMSE), da relação entre os valores previstos ( $y_{prev}$ ) com os dados de teste ( $y_{test}$ ).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{prev} - y_{test})^2}. \quad (7)$$

Para uma previsão mais assertiva, a rede é atualizada com valores observados. Nesta nova sequência o estado da rede é redefinido, desta forma não há influência das previsões anteriores nas previsões dos novos valores. Assim, as previsões são mais precisas ao atualizar o estado da rede com os valores observados em vez dos valores previstos.

Após uma avaliação inicial das configurações do algoritmo, os valores de média, variância e covariância são calculados considerando 20 avaliações para os 6 dias de medição. A variância  $V_i$  de cada variável pode ser definida como:

$$V_i = \frac{1}{n-1} \sum_{m=1}^n (y_{im} - \bar{y}_i)^2, \quad (8)$$

onde  $y_{im}$  é o valor da variável  $i$  no objeto  $m$ ,  $\bar{y}_i$  é o valor médio da variável  $i$ ,  $y_{jm}$  é o valor da variável  $j$  no objeto  $m$ ,  $\bar{y}_j$  é o valor médio da variável  $j$ . A covariância  $C_{ij}$  representa o grau de correlação linear entre variáveis e pode ser descrita como:

$$C_{ij} = \frac{1}{n-1} \sum_{m=1}^n (y_{im} - \bar{y}_i)(y_{jm} - \bar{y}_j). \quad (9)$$

O desvio padrão ( $DP$ ) é a raiz quadrada da variância.

$$DP = \sqrt{\frac{1}{n-1} \sum_{m=1}^n (y_{im} - \bar{y}_i)^2}. \quad (10)$$

Com base nos valores próprios e nos vetores próprios, os principais componentes podem ser obtidos considerando a variabilidade percentual acumulada. Os fatores com os autovalores mais altos são selecionados e os indicadores de cada fator são calculados. As características influentes são escolhidas com base na avaliação de indicadores considerando os fatores mais significativos.

#### IV. ANÁLISE E DISCUSSÃO

Inicialmente é realizada a análise comparativa da utilização do seguidor solar em relação ao painel fixo. Apesar de em alguns momentos transitórios o painel com seguidor solar, gerar menos energia em sua atualização de posição, no geral a eficiência do seguidor solar foi de 30 a 50% superior em comparação ao painel fixo.

Como pode ser visto na Figura 4, durante parte de um dos dias (dia 2) houve nebulosidade, o que causou uma menor geração tanto no painel fixo quanto no painel com seguidor solar. Mesmo nesta condição o painel com seguidor solar gerou mais energia comparativamente do que o painel fixo.

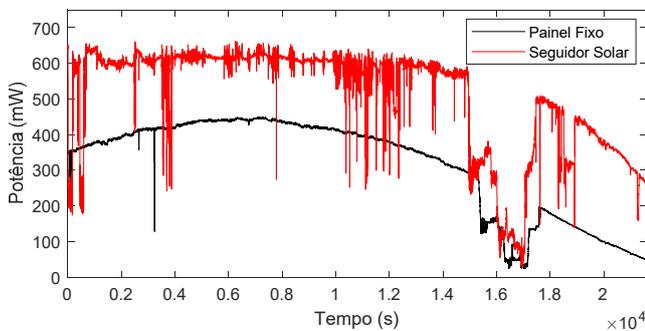


Fig. 4. Comparação de geração do PV fixo com o PV com seguidor solar.

É possível perceber que quanto mais tarde do dia, maior é a diferença de geração do painel com seguidor solar em relação ao painel fixo. Todos os dados foram gravados das 12h às 18h, ou seja, durante  $2,16 \times 10^4$  segundos. A Tabela I apresenta uma avaliação inicial, em relação as características do algoritmo.

Em uma análise preliminar sobre a configuração da rede, percebe-se que a utilização de 10, 25, 50 e 75% dos dados para o treinamento atingem resultados inferiores comparados a utilização de 90%. Utilizando 100 unidades ocultas e 90% dos dados para o treinamento, os resultados tiveram um bom equilíbrio entre o tempo de treinamento e o valor do RMSE. A Figura 5 apresenta o resultado desta avaliação (para o dia 2) em relação a esta configuração.

Número de Unidades Ocultas	Treino Teste (%)	RMSE (mW)	Tempo (s)
50	10_90	42,0430	176,013
	25_75	41,7086	150,812
	50_50	49,7572	139,730
	75_25	32,9779	200,050
	90_10	11,9132	235,095
100	10_90	40,9482	177,611
	25_75	41,0182	147,276
	50_50	49,3778	218,863
	75_25	35,4180	346,841
	90_10	5,0658	421,924
150	10_90	43,6926	164,104
	25_75	40,5581	170,862
	50_50	48,8440	381,347
	75_25	34,8078	527,871
	90_10	8,0404	588,858
200	10_90	41,0001	163,615
	25_75	43,0427	213,507
	50_50	48,3822	413,654
	75_25	35,3839	585,499
	90_10	5,1905	721,473

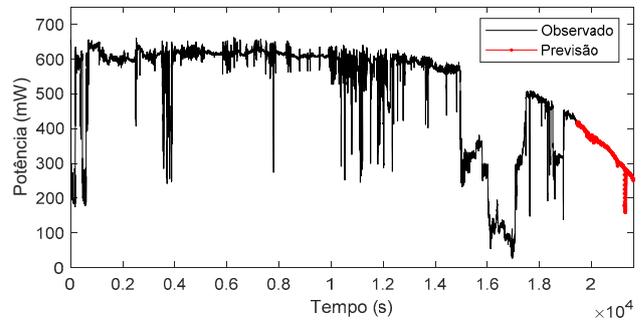


Fig. 5. Análise de geração do seguidor solar utilizando LSTM.

Para uma melhor visualização da diferença entre o valor observado e o valor previsto (Figura 5), a Figura 6 apresenta os resultados de previsão na janela de tempo prevista.

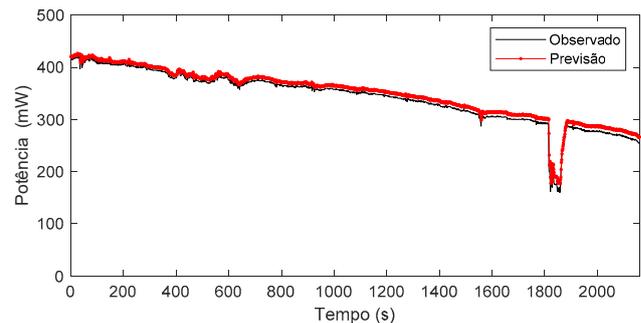


Fig. 6. Previsão de geração do seguidor solar utilizando LSTM.

A Tabela II apresenta os cálculos do RMSE, para todos os dias, em 20 análises utilizando a mesma configuração mencionada anteriormente. Para fins de organização, os valores do RMSE, são apresentados progressivamente.

A janela de tempo apresentada na Figura 6 corresponde aos 10% previstos do sinal completo apresentado na Figura 5. Com base nos valores da Tabela II, é realizado o cálculo estatístico da média, desvio padrão, variância e covariância. Estes valores são apresentados na Tabela III.

TABELA II  
AVALIAÇÃO DO RMSE EM DIFERENTES DIAS

N.	RMSE Dia #1 (mW)	RMSE Dia #2 (mW)	RMSE Dia #3 (mW)	RMSE Dia #4 (mW)	RMSE Dia #5 (mW)	RMSE Dia #6 (mW)
1	3,822	3,639	1,469	3,430	9,855	7,188
2	3,892	3,792	1,755	3,574	10,389	7,292
3	3,899	3,825	1,870	3,597	10,406	7,320
4	3,988	3,850	1,938	3,713	10,571	7,379
5	4,150	3,865	2,564	3,861	10,689	7,440
6	4,360	4,093	3,019	3,917	10,872	7,557
7	4,418	4,155	3,173	3,972	10,929	7,611
8	4,905	4,184	3,362	4,002	11,018	7,681
9	5,384	4,208	3,482	4,073	11,047	7,686
10	6,819	4,373	3,580	4,211	11,091	7,921
11	7,638	4,435	3,840	4,270	11,204	8,536
12	7,814	4,493	3,852	4,312	11,410	8,999
13	9,050	4,793	3,922	4,349	11,695	9,255
14	10,235	4,904	4,093	4,350	11,794	9,825
15	10,358	4,970	4,184	4,410	12,024	10,238
16	10,797	5,267	4,333	4,451	12,240	10,308
17	11,560	5,643	7,216	4,518	12,437	10,632
18	13,184	6,318	8,664	4,727	12,497	11,210
19	14,033	7,472	10,805	4,933	13,345	12,151
20	15,628	8,387	13,276	5,005	16,619	12,854

TABELA III  
ANÁLISE ESTATÍSTICA CONSIDERANDO DIFERENTES DIAS DE MEDIÇÃO

Dia	Média (mW)	Desvio Padrão	Variância	Covariância
1	7,7967	3,8314	14,6794	2,0264
2	4,8333	1,2651	1,6005	0,2521
3	4,5198	3,1123	9,6867	2,0412
4	4,1837	0,4363	0,1904	0,0524
5	11,6065	1,4560	2,1200	0,3617
6	8,9540	1,7655	3,1169	0,2684

Houve uma grande diferença em relação aos resultados dos dias de medição, isto ocorreu devido as condições climáticas serem diferentes. Contudo utilizando a configuração com 90% dos dados para o treinamento e 100 unidades ocultas, o maior RMSE foi de apenas 16,619 mW (ver Tabela II). Este valor corresponde a apenas 1,66% da capacidade de geração do painel (1.000 mW) e desta forma é aceitável para este sistema.

## V. CONCLUSÃO

A utilização do seguidor solar para melhorar a eficiência da geração de energia em painéis fotovoltaicos se mostrou uma boa alternativa a ser utilizada. O algoritmo LSTM gerou um resultado apropriado, que pode ser utilizado como base para o controle em malha fechada de um sistema de PVs.

Houve uma grande variabilidade nos resultados devido a variações nos dias em que foram realizadas as medições, isso poderia ser melhorado utilizando técnicas de *wavelet* para extração de características, ou média móvel [34], desconsiderando assim grandes oscilações causadas por transitórios no sistema.

## AGRADECIMENTOS

Gostaríamos de agradecer ao Fundo de Apoio à Manutenção e Desenvolvimento da Educação Superior (FUMDES), patrocinado pelo Governo do Estado de Santa Catarina, por meio da Secretaria de Estado da Educação de Santa Catarina (SED), com recursos do artigo 171 da

Constituição Estadual, pela concessão de bolsa de iniciação científica de graduação a um dos autores.

## REFERÊNCIAS

- [1] M. P. Corso, S. F. Stefenon, V. F. Couto, S. H. L. Cabral, and A. Nied, "Evaluation of Methods for Electric Field Calculation in Transmission Lines," *IEEE Latin America Transactions*, vol. 16, no. 12, pp. 2970-2976, Dec. 2018, DOI: 10.1109/TLA.2018.8804264
- [2] S. F. Stefenon, J. P. Americo, L. H. Meyer, R. B. Grebogi, and A. Nied, "Analysis of the Electric Field in Porcelain Pin-Type Insulators via Finite Elements Software," *IEEE Latin America Trans.*, vol. 16, no. 10, pp. 2505-2512, Oct. 2018, DOI: 10.1109/TLA.2018.8795129
- [3] H. Ren, J. Ortega, and D. W. Casimis, "Review Of Operating Reserves and Day-Ahead Unit Commitment Considering Variable Renewable Energies: International Experience," *IEEE Latin America Trans.*, vol. 15, no. 11, pp. 2126-2136, Nov. 2017, DOI: 10.1109/TLA.2017.8070418
- [4] O. A. Páramo, J. C. Rivera, and G. A. López, "Effects on Electricity Markets of a Demand Response Model Based on Day Ahead Real Time Prices: Application to the Colombian Case," *IEEE Latin America Trans.*, vol. 16, no. 5, pp. 1416-1423, May 2018, DOI: 10.1109/TLA.2018.8408436
- [5] C. S. Lesse, S. F. Stefenon, J. P. Américo, M. P. Corso, and A. Nied, "Avaliação de Falhas em Redes de Distribuição de Energia Elétrica Através da Corrente de Curto-Circuito," *Revista de Engenharia e Tecnologia*, vol. 11, no. 2, pp. 127-134, Ago. 2019.
- [6] S. M. R. Sanhueza, and S. C. L. Freitas, "Overvoltage Forecast in a Urban Distribution Power Grid Considering PV Systems Connection," *IEEE Latin America Trans.*, vol. 16, no. 8, pp. 2221-2227, Aug. 2018, DOI: 10.1109/TLA.2018.8528238
- [7] J. F. M. Pessanha, and N. Leon, "Long-term forecasting of household and residential electric customers in Brazil," *IEEE Latin America Trans.*, vol. 10, no. 2, pp. 1537-1543, Mar. 2012, DOI: 10.1109/TLA.2012.6187597
- [8] M. A. Panait, and T. Tudorache, "A simple neural network solar tracker for optimizing conversion efficiency in off-grid solar generators," *Renewable Energy and Power Quality Journal*, vol. 1, no. 06, pp. 256-260, 2017.
- [9] S. Al-Dahidi, O. Ayadi, M. Alrbai, and J. Adeeb, "Ensemble Approach of Optimized Artificial Neural Networks for Solar Photovoltaic Power Prediction," *IEEE Access*, vol. 7, pp. 81741-81758, 2019, DOI: 10.1109/ACCESS.2019.2923905
- [10] A. Bracale, G. Carpinelli, and P. Falco, "A Probabilistic Competitive Ensemble Method for Short-Term Photovoltaic Power Forecasting," *IEEE Trans. on Sustainable Energy*, vol. 8, no. 2, pp. 551-560, Apr. 2017, DOI: 10.1109/TSTE.2016.2610523
- [11] C. Huang, S. Chen, S. Yang, and C. Kuo, "One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models," *IET Generation, Transmission & Distribution*, vol. 9, no. 14, pp. 1874-1882, 2015, DOI: 10.1049/iet-gtd.2015.0175
- [12] C. Wan, J. Lin, Y. Song, Z. Xu, and G. Yang, "Probabilistic Forecasting of Photovoltaic Generation: An Efficient Statistical Approach," *IEEE Trans. on Power Systems*, vol. 32, no. 3, pp. 2471-2472, May 2017, DOI: 10.1109/TPWRS.2016.2608740
- [13] H. Sheng, J. Xiao, Y. Cheng, Q. Ni, and S. Wang, "Short-Term Solar Power Forecasting Based on Weighted Gaussian Process Regression," *IEEE Trans. on Industrial Electronics*, vol. 65, no. 1, pp. 300-308, Jan. 2018, DOI: 10.1109/TIE.2017.2714127
- [14] J. Lee *et al.*, "Optimal Operation of an Energy Management System Using Model Predictive Control and Gaussian Process Time-Series Modeling," *IEEE Journal of Emerging and Selected Topics in Power Elect.*, vol. 6, no. 4, pp. 1783-1795, Dec. 2018, DOI: 10.1109/JESTPE.2018.2820071
- [15] L. Du, L. Zhang, and X. Tian, "Deep Power Forecasting Model for Building Attached Photovoltaic System," *IEEE Access*, vol. 6, pp. 52639-52651, 2018, DOI: 10.1109/ACCESS.2018.2869424
- [16] C. Huang, and P. Kuo, "Multiple-Input Deep Convolutional Neural Network Model for Short-Term Photovoltaic Power Forecasting," *IEEE Access*, vol. 7, pp. 74822-74834, 2019, DOI: 10.1109/ACCESS.2019.2921238
- [17] J. Ospina, A. Newaz, and M. O. Faruque, "Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model,"

- IET Renewable Power Generation*, vol. 13, no. 7, pp. 1087-1095, 2019, DOI: 10.1049/iet-rpg.2018.5779
- [18] H. Zhou *et al.*, "Short-Term Photovoltaic Power Forecasting Based on Long Short Term Memory Neural Network and Attention Mechanism," *IEEE Access*, vol. 7, pp. 78063-78074, 2019, DOI: 10.1109/ACCESS.2019.2923006
- [19] Y. Yao, Y. Hu, S. Gao, G. Yang, and J. Du, "A multipurpose dual-axis solar tracker with two Tracking strategies," *Renewable Energy*, vol. 72, pp. 88-98, 2014.
- [20] T. Tiberiu, and K. Liviu, "Design of a Solar Tracker System for PV Power Plants," *Acta Polytechnica Hungarica*, vol. 7, no. 1, pp. 23-39, 2010.
- [21] M. J. Clifford, and D. Eastwood, "Design of a novel passive solar tracker," *Solar Energy*, vol. 77, no. 3, pp. 269-280, 2004.
- [22] C. Alexandru, and C. Pozna, "Simulation of a dual-axis solar tracker for improving the performance of a photovoltaic panel," *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, vol. 224, no. 6, pp. 797-811, 2010.
- [23] J. P. Reges, F. D. L. Moreira, L. D. S. Bezerra, A. R. Alexandria, and P. P. R. Filho, "Thermographic Image Processing Application in Solar Followers," *IEEE Latin America Trans.*, vol. 13, no. 10, pp. 3350-3358, Oct. 2015, DOI: 10.1109/TLA.2015.7387242
- [24] M. M. Macedo, C. E. P. Saldias, and O. H. A. Junior, "Mathematical Modeling of a Solar Tracker System Two Axes for Generation Photovoltaics," *IEEE Latin America Trans.*, vol. 14, no. 9, pp. 4054-4062, Sep. 2016, DOI: 10.1109/TLA.2016.7785933
- [25] Z. Zengwei, Z. Zhen, J. Yongfeng, L. Haolin, and Z. Shengcheng, "Performance Analysis on Bifacial PV Panels With Inclined and Horizontal East-West Sun Trackers," *IEEE Journal of Photovoltaics*, vol. 9, no. 3, pp. 636-642, May 2019, DOI: 10.1109/JPHOTOV.2019.2899472
- [26] A. Sritoklin *et al.*, "A Low Cost, Open-source IoT based 2-axis Active Solar Tracker for Smart Communities," in *Inter. Conf. and Utility Exhibition on Green Energy for Sustainable Development (ICUE)*, Phuket, Thailand, 2018, pp. 1-4.
- [27] A. Sawant, D. Bondre, A. Joshi, P. Tambavekar, and A. Deshmukh, "Design and Analysis of Automated Dual Axis Solar Tracker Based on Light Sensors," in *Inter. Conf. on I-SMAC*, Palladam, India, 2018, pp. 454-459.
- [28] S. V. Mitrofanov, D. K. Baykasenov, and M. A. Suleev, "Simulation Model of Autonomous Solar Power Plant with Dual-Axis Solar Tracker," in *Inter. Ural Conf. on Green Energy (UralCon)*, Chelyabinsk, 2018, pp. 90-96.
- [29] D. A. Hapidin *et al.*, "The Study of Velocity Measurement Using Single Light Dependent Resistor (LDR) Sensor," in *Inter. Seminar on Sensors, Instrumentation, Measurement and Metrology (ISSIMM)*, Depok, Indonesia, 2018, pp. 111-114.
- [30] M. Lv, M. Hu, and X. Yan, "Analysis of Friction Forces in a Micro Servo Valve for Medical Equipment," in *Inter. Conf. on Bioinformatics and Biomedical Engineering*, Shanghai, China, 2008, pp. 1661-1664.
- [31] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu and Y. Zhang, "Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 841-851, Jan. 2019, DOI: 10.1109/TSG.2017.2753802
- [32] Y. Wang, Y. Shen, S. Mao, X. Chen, and H. Zou, "LASSO and LSTM Integrated Temporal Model for Short-Term Solar Intensity Forecasting," *IEEE Internet of Things Journal*, vol. 6, no. 2, pp. 2933-2944, Apr. 2019, DOI: 10.1109/JIOT.2018.2877510
- [33] S. Motepe, A. N. Hasan, and R. Stopforth, "Improving Load Forecasting Process for a Power Distribution Network Using Hybrid AI and Deep Learning Algorithms," *IEEE Access*, vol. 7, pp. 82584-82598, 2019, DOI: 10.1109/ACCESS.2019.2923796
- [34] S. F. Stefenon, J. R. Oliveira, A. S. Coelho and L. H. Meyer, "Diagnostic of Insulators of Conventional Grid Through LabVIEW Analysis of FFT Signal Generated from Ultrasound Detector," *IEEE Latin America Trans.*, vol. 15, no. 5, pp. 884-889, May 2017, DOI: 10.1109/TLA.2017.7910202



**Christopher Kasburg**, nascido em Curitiba, Santa Catarina, Brasil em 1996. Formado no curso Técnico em Eletromecânica pelo Serviço Nacional de Aprendizagem Industrial em Curitiba, Santa Catarina em 2014 e cursando Engenharia Elétrica pela Universidade do Planalto Catarinense em Lages, Santa Catarina com conclusão prevista para 2019. De 2016 a 2019, ele trabalhou como Assistente Técnico na empresa Sol Central Energias Alternativas. Seus interesses de pesquisa incluem eficiência energética e geração de energia elétrica sustentável.



**Stéfano Frizzo Stefenon**, cursando Doutorado em Engenharia Elétrica pela Universidade do Estado de Santa Catarina, Mestre em Engenharia Elétrica (Sistemas de Potência) e Graduado em Engenharia Elétrica pela Universidade Regional de Blumenau, Especialista em Engenharia de Segurança do Trabalho pela Universidade do Planalto Catarinense. Professor e coordenador do curso de Engenharia Elétrica na Universidade do Planalto Catarinense. Tem experiência na área de Engenharia Elétrica, com foco em classificação de isoladores, inspeção do sistema elétrico de potência, aplicação de técnicas de inteligência artificial para identificação de falhas no sistema elétrico. Líder do Grupo de Pesquisa Avançado em Sistemas Elétricos (GPASE) da Universidade do Planalto Catarinense.