

## Rastreamento Solar Inteligente com LSTM para Fogões Parabólicos: Simulação, Otimização e Potencial em Comunidades Sustentáveis

SAULO ALVES DE SOUZA<sup>1</sup>, GABRIEL LIMA COSTA<sup>2</sup> e ERIC BRUNO OLIVEIRA DO NASCIMENTO<sup>3</sup>

<sup>1</sup>Docente, IFBA, Jequié - BA, saulo.alves@ifba.edu.br;

<sup>2</sup>Discente, IFBA, Jequié - BA, 20251CEMEC0004@ifba.edu.br;

<sup>3</sup>Discente, IFBA, Jequié - BA, 20242CEMEC0011@ifba.edu.br

Apresentado no

Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC

06 a 09 de outubro de 2025

**RESUMO:** Este estudo propõe um sistema inteligente de rastreamento solar de dois eixos para fogões parabólicos, combinando simulação astronômica, sensores LDR e redes LSTM. Foram geradas 2.160 instâncias simuladas para Jequié-BA, com dados estruturados em sequências temporais. A rede LSTM de duas camadas foi treinada para prever ângulos solares com base em leituras simuladas com ruído atmosférico. Três funções de ativação foram testadas, e a sigmoide obteve o melhor desempenho, com erro médio absoluto de 2,89°. O modelo demonstrou alta precisão e potencial para otimizar a eficiência térmica de concentradores solares. A solução é promissora para comunidades com recursos limitados e contribui para o avanço das energias renováveis.

**PALAVRAS-CHAVE:** Rastreamento solar; LSTM; Fogão solar parabólico; Sensores fotoelétricos; Simulação astronômica.

### Intelligent Solar Tracking with LSTM for Parabolic Cookers: Simulation, Optimization, and Potential in Sustainable Communities

**ABSTRACT:** This work presents the development and evaluation of a two-axis intelligent solar tracking system for a parabolic stove, integrating astronomical simulation, photoelectric modeling, and recurrent neural networks (LSTM). A synthetic dataset of 2,160 instances was generated for Jequié-BA, covering 30 consecutive days at 10-minute intervals. Ideal azimuth and altitude angles, computed via Pysolar, were paired with simulated LDR sensor readings under atmospheric variability and noise. Data were normalized and structured into five-step temporal sequences to train a two-layer LSTM with dropout. Three output activation functions were tested, with the sigmoid model achieving a mean absolute error of 2.89°, demonstrating high accuracy in angle prediction and potential for enhancing thermal efficiency in solar concentrators. The proposed approach contributes to renewable energy technologies and is adaptable to low-resource community contexts.

**KEYWORDS:** Solar tracking; LSTM; Parabolic solar cooker; Photoelectric sensors; Astronomical simulation.

### INTRODUÇÃO

A crescente demanda por fontes de energia limpas e renováveis impulsiona o desenvolvimento de tecnologias solares, essenciais para a sustentabilidade global e a redução da dependência de combustíveis fósseis (Pinho et al., 2014). Nesse cenário, a otimização da captação de energia em coletores solares, como os fogões solares, é de suma importância, particularmente em regiões como o semiárido baiano, onde a acessibilidade a outras fontes de energia é limitada (Andrade Filho, 2021). A manutenção da perpendicularidade do coletor em relação à radiação solar incidente é um fator crucial para a eficiência desses sistemas. Essa tarefa varia continuamente, pois está ligada à posição do Sol ao longo do dia e das estações.

Em contraste com as abordagens convencionais, que evoluíram de configurações fixas para sistemas ativos e híbridos com o intuito de maximizar a exposição solar, os progressos em inteligência

artificial (IA) e aprendizado de máquina (ML) têm transformado o rastreamento solar. Essa revolução tecnológica possibilita uma previsão mais exata da trajetória do sol e uma adaptação flexível às condições climáticas (AL-Rousan, Mat Isa e Mat Desa, 2020). De acordo com Yu et al. (2019), modelos de aprendizado profundo, como redes neurais recorrentes (RNNs) e *Long Short-Term Memory* (LSTMs), demonstram eficácia no controle de rastreadores solares multi-eixos. Esses modelos são capazes de aprender padrões complexos a partir de dados sequenciais, otimizando o posicionamento dos coletores e, conseqüentemente, elevando a eficiência energética. Além disso, a incorporação da Internet das Coisas (IoT) oferece a capacidade de monitoramento em tempo real, análise de desempenho preditiva e a realização de manutenções proativas.

O presente estudo detalha a concepção e a avaliação de um sistema de rastreamento solar inteligente e adaptativo para concentradores parabólicos, empregando simulação computacional para a análise de seu desempenho. O objetivo é aprimorar a captação térmica através da implementação de algoritmos de aprendizado de máquina. A metodologia envolve a criação de um mecanismo de rastreamento simulado que utiliza dados de sensores virtuais e um modelo computacional. O propósito final é otimizar a angulação do refletor para atingir a máxima eficiência energética. Espera-se que, por meio de simulações e comparações, o sistema seja validado como uma solução eficaz na otimização de dispositivos solares térmicos, contribuindo para a resiliência energética e a qualidade de vida em comunidades com recursos limitados.

## MATERIAL E MÉTODOS

Os experimentos foram concebidos para avaliar um sistema de rastreamento solar de dois eixos aplicado a um fogão solar parabólico, combinando modelagem computacional e aprendizagem de máquina para estimar, a partir de leituras fotoelétricas, os ângulos de azimute e altitude de apontamento. Todo o desenvolvimento foi realizado em Python, adotando-se uma arquitetura de controle com dois graus de liberdade, essencial para maximizar a incidência normal da radiação sobre o refletor ao longo do dia. A estratégia metodológica privilegia a geração de dados sintéticos fisicamente plausíveis e sua utilização em um modelo recorrente que captura dependências temporais de curto prazo.

A base de dados foi construída por simulação astronômica e ótica para o município de Jequié, Bahia, Brasil (latitude  $-13,856^\circ$ , longitude  $-40,086^\circ$ , altitude 240 m, UTC-3). As efemérides solares foram obtidas para 30 dias consecutivos, iniciando em 28/07/2025, no intervalo diário de 06:00 a 18:00, com passo temporal de 10 minutos (6 amostras/hora), totalizando 72 instâncias por dia e 2.160 instâncias no conjunto. Para cada instante com altitude solar positiva, definiram-se os ângulos ideais de apontamento do rastreador: azimute (M1) e altitude (M2). Ambos receberam ruído gaussiano aditivo com desvio-padrão de  $0,5^\circ$  para simular imprecisões mecânicas, seguidos de saturação aos domínios físicos  $[0^\circ, 360^\circ]$  (azimute) e  $[0^\circ, 90^\circ]$  (altitude). A irradiância base incidente foi aproximada como proporcional à altura solar, e a variabilidade atmosférica foi incorporada por um evento estocástico de “nuvem pesada” com probabilidade de 10% por amostra, que reduz para 30% do valor nominal.

As leituras de quatro sensores fotoelétricos (LDRs) foram simuladas para fornecer sensibilidade diferencial às variações de azimute e altitude. Adotou-se a seguinte geometria: LDR1 (cima) e LDR2 (baixo) sensíveis ao plano vertical (referências em  $90^\circ$  e  $0^\circ$  de altitude), e LDR3 (direita) e LDR4 (esquerda) sensíveis ao plano horizontal (referências em  $90^\circ$  e  $270^\circ$  de azimute). A resposta direcional de cada sensor foi modelada por uma função gaussiana da distância angular em torno de seu eixo, acrescida de ruído gaussiano aditivo de média zero e desvio-padrão de 20 unidades. As leituras foram limitadas ao intervalo  $[0, 1023]$ . Esse arranjo resulta em maior responsividade do par LDR1–LDR2 às mudanças de altitude e do par LDR3–LDR4 às mudanças de azimute, preservando monotonicidade sob céu claro e robustez mínima frente a ruídos e atenuações rápidas.

O *dataset* final, armazenado em CSV, contém *timestamp*, leituras dos quatro LDRs e os ângulos ideais (M1) (azimute) e (M2) (altitude). No pré-processamento, foram incorporadas variáveis defasadas de primeira ordem dos ângulos ideais ( $Azimuth_{t-1}$ ), ( $Altitude_{t-1}$ ), obtidas por deslocamento

temporal de uma amostra; os registros com valores ausentes decorrentes dessa operação foram descartados. As entradas do modelo foram compostas por (LDR1, LDR2, LDR3, LDR4,  $Azimuth_{t-1}$ ,  $Altitude_{t-1}$ ) e as saídas por (M1, M2). Todas as variáveis (entradas e saídas) foram normalizadas individualmente para  $[0,1]$  por escalonamento min-max. Para capturar a dinâmica temporal, os dados foram reestruturados em janelas deslizantes de comprimento  $L=5$  passos (50 minutos), produzindo tensores de entrada com forma  $(L,6)$  por amostra.

A divisão em conjuntos de treino e teste considerou 70% e 30% das sequências, respectivamente, com seleção pseudoaleatória controlada por semente interna de divisão (`random_state=42`). Durante o ajuste, 20% do conjunto de treino foi reservado para validação interna. As previsões do modelo foram posteriormente reconvertidas do espaço normalizado para graus por transformação inversa min-max, garantindo comparabilidade direta com os alvos físicos.

O estimador empregado foi uma rede neural recorrente do tipo LSTM em arquitetura sequencial. A pilha recorrente compreendeu duas camadas LSTM com 50 unidades e ativação interna (*tanh*); a primeira retornou sequências para permitir o empilhamento, e camadas *Dropout* com taxa de 0,3 foram intercaladas para mitigar sobreajuste. A camada de saída foi densa, com dois neurônios correspondentes a (M1) e (M2), e avaliou-se o efeito de três funções de ativação alternativas na saída (linear, sigmoide e tangente hiperbólica). O treinamento utilizou o otimizador Adam em configuração padrão, função de custo baseada no mean absolute error (MAE), 200 épocas e tamanho de lote 32, com monitoramento contínuo das perdas de treino e validação a cada época.

A avaliação considerou, para cada ativação de saída, o MAE médio no conjunto de teste em graus após a dessaturação de escala, e a seleção do melhor modelo foi realizada pelo menor MAE global. Para inspeção qualitativa de aderência dinâmica, foram geradas curvas de perda (treino e validação) e séries temporais comparando valores previstos e observados para azimute e altitude nas primeiras 100 amostras do conjunto de teste, permitindo verificar coerência de fase e amplitude sob variações suaves e sob atenuações simuladas por nuvens.

Algumas limitações metodológicas devem ser consideradas: a modelagem fotoelétrica é isotrópica e não inclui efeitos espectrais, térmicos ou sombreamento; a simulação de nuvens segue processo Bernoulli sem memória; e a divisão aleatória treino-teste pode subestimar desafios de generalização. O azimute foi tratado como variável euclidiana, sem correção de circularidade. Futuras extensões devem considerar representação angular circular, validação walk-forward e análise do impacto térmico do erro angular.

## RESULTADOS E DISCUSSÃO

O desempenho do sistema de rastreamento solar inteligente foi avaliado por simulação computacional para validar sua viabilidade teórica. Para isso, foram utilizados dados de cálculos astronômicos (azimute e altitude do sol) e simulações de leituras de quatro sensores LDR. O modelo de Rede Neural Recorrente LSTM, treinado por 200 épocas, teve seu desempenho avaliado com base no Erro Médio Absoluto (MAE).

Os resultados numéricos, apresentados na Tabela 1, demonstraram a eficácia da abordagem otimizada, com a função de ativação Sigmoide obtendo o melhor desempenho. O MAE de 2.8904 graus indica a capacidade do modelo de generalizar o padrão de rastreamento com base nas leituras dos LDRs e informações de contexto, sugerindo sua viabilidade teórica para a aplicação.

Tabela 1. Desempenho dos modelos de rede neural nos dados de teste.

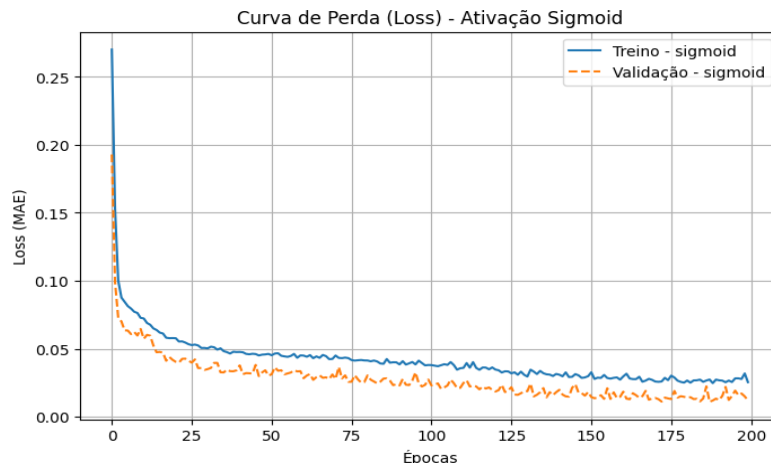
Função de Ativação	Mean Absolute Error (MAE)
Linear	9.1298
Sigmoid	2.8904
Tangente Hiperbólica (Tanh)	7.2761

Fonte: Autores (2025).

A análise do comportamento da curva de perda durante o treinamento, ilustrada na Figura 1, demonstra que a perda de treinamento e a de validação convergiram consistentemente ao longo das épocas. Este comportamento é um forte indicativo de que o modelo não incorreu em *overfitting*, ou

seja, não memorizou os dados de treinamento excessivamente. A capacidade de generalização do modelo é um fator crítico para sua aplicação prática, pois precisará fazer previsões precisas em condições não vistas anteriormente.

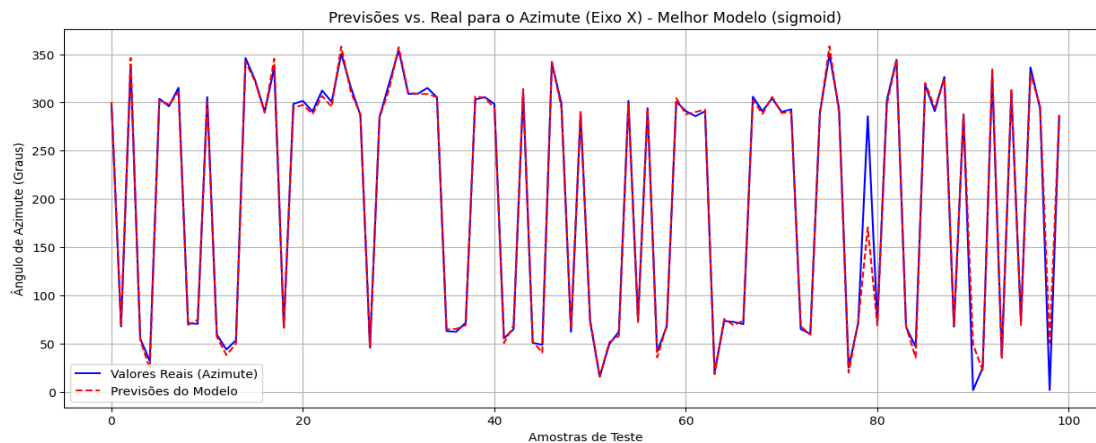
**Figura 1.** Curva de perda durante o treinamento do modelo com função de ativação Sigmoid.



Fonte: Autor (2025).

Para uma visualização mais detalhada da eficácia do modelo, o gráfico de previsão na Figura 2 compara os valores preditos pelo modelo com os valores reais do sol nos dados de teste. A forte correlação observada entre as previsões do modelo e os valores reais para ambos os eixos (azimute e altitude) confirma que a tendência geral do movimento do sol é capturada com alta fidelidade. Embora existam pequenas discrepâncias, a precisão visual reforça o sucesso do modelo preditivo.

**Figura 2.** Comparação das previsões do modelo com os valores reais de azimute.



Fonte: Autor (2025).

Este resultado corrobora com a literatura, onde modelos de aprendizado profundo como as redes LSTM são reconhecidos por sua eficácia no controle de rastreamento solar multi-eixos e na otimização do posicionamento de coletores. Adicionalmente, a análise preditiva de desempenho pode possibilitar o monitoramento em tempo real e a execução de manutenções proativas.

Em comparação com sistemas de rastreamento tradicionais, que dependem de configurações fixas ou lógicas reativas, o uso de inteligência artificial oferece uma predição mais precisa da trajetória solar e uma adaptação dinâmica às variações climáticas simuladas (como a ocorrência de nuvens). A abordagem proposta contribui teoricamente para a otimização da captação térmica em concentradores solares, o que se alinha com a crescente demanda por fontes de energia limpas e renováveis, essenciais para a sustentabilidade global.

## CONCLUSÃO

Os resultados obtidos por simulação demonstram a viabilidade teórica do uso de redes LSTM para rastreamento solar adaptativo em concentradores parabólicos, com destaque para o modelo com ativação sigmoide, que alcançou MAE de 2,89°. A baixa perda de validação indica boa capacidade de generalização e eficácia da metodologia. A integração entre sensores LDR e inteligência artificial permite ajustes precisos do coletor, com potencial para otimizar a captação térmica e beneficiar comunidades com recursos limitados. Para validação futura, recomenda-se a construção de protótipo físico, aprimoramento do hardware, análise comparativa de configurações ópticas e integração com plataformas IoT para monitoramento e manutenção preditiva.

## REFERÊNCIAS

- ACKHARI, O.; BENGHANEM, A.; OUAHIDI, A. A new sun-tracking approach for energy saving. *Renewable Energy*, Elsevier, v. 169, p. 820–835, 2021.
- AL-ROUSAN, N.; Mat Isa, N. A.; Mat Desa, M. K. Efficient single and dual axis solar tracking system controllers based on adaptive neural fuzzy inference system. *Journal of King Saud University - Engineering Sciences*, v. 32, n. 7, p. 459–469, 2020. ISSN 1018-3639. Photovoltaic Materials, Devices and Systems. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1018363920302233>><https://www.sciencedirect.com/science/article/pii/S1018363920302233>.
- ANDRADE FILHO, A. E. d. Fogão solar para cocção de alimentos.: Universidade Federal do Rio Grande do Norte, 2021.
- HINTON, G. E.; SRIVASTAVA, N.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Improving neural networks by preventing co-adaptation of feature detectors. *CoRR*, abs/1207.0580, 2012. Disponível em: <<http://arxiv.org/abs/1207.0580>><http://arxiv.org/abs/1207.0580>.
- PINHO, J. T. et al. Energia eólica: teoria e aplicações.: Rio de Janeiro, 2014. v. 1. 47–499p.