



OTIMIZAÇÃO DOS HIPERPARÂMETROS DA LSTM POR METAHEURÍSTICAS PARA PREVISÃO DE ENERGIA SOLAR FOTOVOLTAICA

MANOEL HENRIQUE DE OLIVEIRA CAMARGO - manelhro@gmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS – PUC GO

MARIA JOSÉ PEREIRA DANTAS - mjdantas@pucgoias.edu.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS – PUC GO

ÁREA: 3. PESQUISA OPERACIONAL

SUBÁREA: 3.7 – INTELIGÊNCIA COMPUTACIONAL

RESUMO: ESTE TRABALHO INVESTIGA A APLICAÇÃO DE METAHEURÍSTICAS NA OTIMIZAÇÃO DE HIPERPARÂMETROS DE REDES LSTM PARA PREVISÃO DE GERAÇÃO DE ENERGIA SOLAR FOTOVOLTAICA. UTILIZOU-SE UMA BASE DE DADOS DE UMA USINA EM NASIK (ÍNDIA), ABRANGENDO O PERÍODO DE 15 DE MAIO A 17 DE JUNHO DE 2020. DUAS METAHEURÍSTICAS, ALGORITMO GENÉTICO (AG) E FIREFLY ALGORITHM (AF), FORAM EMPREGADAS PARA AJUSTAR PARÂMETROS COMO TAXA DE APRENDIZADO, REGULARIZAÇÃO E ESTRUTURA DA REDE. OS MODELOS FORAM AVALIADOS POR MSE, MAE, RMSE E COEFICIENTE DE DETERMINAÇÃO (R^2), COM O AG ALCANÇANDO DESEMPENHO SUPERIOR EM COMPARAÇÃO AO AF. OS RESULTADOS DEMOSTRAM QUE A OTIMIZAÇÃO VIA AG PROPICIA PREVISÕES MAIS PRECISAS E CONFIÁVEIS, RESSALTANDO A RELEVÂNCIA DA ESCOLHA ADEQUADA DE HIPERPARÂMETROS E DA QUALIDADE DO CONJUNTO DE DADOS PARA APRIMORAR MODELOS DE PREVISÃO.

PALAVRAS-CHAVES: REDES NEURAIIS, LSTM, PREVISÃO SOLAR, METAHEURÍSTICAS, OTIMIZAÇÃO.

1. INTRODUÇÃO

A energia é um pilar muito importante para o desenvolvimento e sustentabilidade. A humanidade poderá esgotar os recursos naturais nos próximos 50 anos utilizando fontes de energia não renováveis como os combustíveis fósseis (Silva; Araújo, 2022). Energia solar, eólica, hidrelétrica, biomassa, geotérmica e hidrogênio estão sendo utilizadas para diminuir o uso de energias não renováveis (Ang et al., 2022). Dentre os recursos energéticos existentes, a energia solar é a mais abundante, a radiação solar recebida na terra é mais de 7.500 vezes o consumo total de energia primária. A sua geração é feita a partir da conversão da radiação solar em energia elétrica através de Painéis Fotovoltaicos (*PV*) ou em energia térmica através do Sistema Termo-Solar de Concentração (*CSP*) (Ludin et al., 2018; Li et al., 2022). Dessa forma, a geração de energia renovável conhecida também como energia limpa reduz efetivamente a geração de carbono (CO_2) além de gerar menos gases, reduzindo o efeito estufa (Jaiswal et al., 2022).

Com a necessidade de descobrir novas fontes de energias renováveis para acompanhar a evolução da humanidade, a geração de energia solar fotovoltaica tem se destacado cada vez mais. Segundo a Agência Internacional de Energia ou *International Energy Agency (IEA)* entre 2024 e 2030, espera-se que essa energia seja responsável por 80% do crescimento da capacidade renovável global, e até no final desta década ela se torne a maior fonte renovável, passando a energia hidrelétrica que atualmente é a maior fonte de geração de energia limpa (IEA, 2025).

No Brasil a energia solar fotovoltaica é representada por cerca de 22.7% da matriz energética brasileira, ficando atrás apenas da energia hidrelétrica, segundo os dados da Associação Brasileira de Energia Solar Fotovoltaica (ABSOLAR, 2025). Dito isso, o crescimento do uso da geração de energia não está ligado apenas ao fato da abundância de recursos energéticos, mas na queda de valores dos módulos fotovoltaicos na última década e o risco de os combustíveis fósseis perderem o seu valor econômico (Green, 2019).

Prever a geração de energia solar fotovoltaica é fundamental para a estruturação e o gerenciamento do sistema, pois estimativas imprecisas podem afetar a distribuição de energia na rede, comprometendo sua estabilidade e segurança, e até mesmo provocando danos e aumentando os custos financeiros da operação (Zhang et al., 2021). Fazer a previsão dessa energia é uma etapa muito complexa devido a intermitência solar, como essa energia necessita dos raios solares, a sua produção está fadada a ser afetada por fatores do clima como a

irradiância solar, temperatura do ar, tipos de nuvens, direção e velocidade dos ventos (Liu et al., 2018). A irradiância solar é um dos fatores que estão diretamente ligados a geração de energia solar fotovoltaica, os modelos mais utilizados para realizar essa previsão são os analíticos, estocásticos, empíricos, estatísticos e redes neurais artificiais (RNAs) (Rodrigues et al., 2022).

Atualmente a rede neural recorrente ou *recurrent neural network (RNN)* do tipo *Long Short-Term Memory (LSTM)* está sendo amplamente utilizada para previsão de series temporais, pois ela lida com o problema do gradiente evanescente (*vanish gradient problem*), onde ela tem melhor desempenho em previsões de series longas (Liu et al., 2021).

A maioria dos algoritmos de aprendizado de máquina são configurados com um conjunto de hiperparâmetros, onde os valores de cada um devem ser escolhidos de forma cautelosa pois eles impactam consideravelmente o desempenho do treinamento (Bischl et al., 2021). As técnicas de otimização de hiperparâmetros (OHP) serve para automatizar a seleção de valores que serão utilizados pelos mesmos, pois isso reduz o esforço humano e o tempo para a seleção desses valores. Alguns exemplos de técnicas são pesquisa em grade (PG), busca aleatória (BA), otimização Bayseana (OB) e as metaheurísticas como algoritmos genéticos e *PSO (Particle Swarm Optimization)* que vem sendo amplamente utilizadas em problemas difíceis de otimização (Huang; Li; Yao, 2020; Yang; Shami, 2020).

Neste cenário, torna-se relevante compreender como as metaheurísticas fazem para encontrar os valores dos hiperparâmetros da LSTM, a fim de diminuir o tempo e a complexidade necessárias para achar um conjunto ótimo de hiperparâmetros.

A análise desenvolvida nesse trabalho foi realizada usando a rede LSTM e baseou-se em dados temporais disponíveis na plataforma Kaggle. Duas metaheurísticas foram selecionadas a fim de otimizar o conjunto de hiperparâmetros dessa rede. Em seguida, o modelo foi treinado e o erro (MSE) foi avaliado.

Após esta sessão de introdução, o resto do artigo foi dividido em quatro sessões. A segunda sessão aborda os materiais e métodos, descrevendo a base de dados, o funcionamento da LSTM, as metaheurísticas e os hiperparâmetros. A terceira sessão apresenta os resultados obtidos. Por fim, a última sessão mostra de uma forma resumida as conclusões, a partir dos resultados obtidos.

2. MATERIAIS E MÉTODOS

Esta sessão aborda a base de dados, o funcionamento da LSTM, as metaheurísticas usadas e os hiperparâmetros.

2.1 Base de Dados

A base de dados é de uma usina em Nasik, Maharashtra na Índia, e foi obtida através da plataforma Kaggle, disponível em <https://www.kaggle.com/datasets/anikannal/solar-power-generation-data/data>. A base contém dados de geração de energia solar fotovoltaica referente ao período entre 15 de maio a 17 de junho de 2020. Foram realizadas manipulações na base para ser utilizada e a Tabela 1 apresenta um trecho da base, com as variáveis disponibilizadas.


TABELA 1 - Dados de treinamento

<i>DATE TIME</i>	<i>AC POWER</i>	<i>AMBIENT TEMP.</i>	<i>MODULE TEMP.</i>	<i>IRRADIATION</i>
2020-05-15 0:00:00	0.0	27.004764	25.060789	0.0
2020-05-15 0:15:00	0.0	28.880811	24.421869	0.0
2020-05-15 0:30:00	0.0	26.682055	24.427290	0.0
....				
2020-06-17 23:15:00	0.0	23.354743	22.492245	0.0
2020-06-17 23:30:00	0.0	23.291048	22.373909	0.0
2020-06-17 23:45:00	0.0	23.202871	22.535908	0.0

Fonte: Autor

A Figura 1 mostra o perfil de geração de potência do sistema fotovoltaico a partir das 00h00 do dia 25/05/2020 até as 00h00 do dia 26/05/2020. Observa-se que a geração começa por volta das 06 horas e a maior parte da geração está entre 10 e 15 horas, depois desse horário a potência gerada começa a cair até chegar a 0 kW.

FIGURA 1: Perfil de Geração de Potência




Fonte: Autor

2.2 Long Short-Term Memory (LSTM)

A LSTM é um tipo de rede neural recorrente proposta por Hochreiter e Schmidhuber (1997). Na arquitetura original, cada célula de memória possuía apenas duas portas principais, porta de entrada (*input gate*) e porta de saída (*output gate*). Entretanto, Gers et al. (2000) identificaram que, em fluxos de dados contínuos, os estados internos das células podiam crescer sem controle, comprometendo a estabilidade do aprendizado. Para resolver essa limitação, introduziu-se a terceira porta, chamada porta de esquecimento (*forget gate*). Além disso, essa combinação de portas mitiga o problema do gradiente evanescente, permitindo que a rede aprenda dependências de longo prazo sem que os gradientes se anulem. A arquitetura final está representada na Figura 2.

FIGURA 2 - Arquitetura da célula da LSTM



Fonte: Adaptado de (RADZI et al., 2023).

As funcionalidades de cada porta são (Radzi et al., 2023):

Porta de esquecimento: decide quais informações da memória de longo prazo da célula devem ser descartadas ou esquecidas por não serem mais relevantes. Ele filtra as informações que passarão para as próximas etapas.

Porta de entrada: responsável por decidir quais novas informações serão armazenadas na memória da célula. Isso é feito através das funções sigmoide e tanh. A função tanh cria os valores candidatos, e a sigmoide decide quais desses valores serão efetivamente adicionados.

Estado da célula: é a memória principal da célula. Ela é atualizada a primeiro esquecer as informações (conforme decidido pela porta de esquecimento) e depois ao


adicionar as novas informações (conforme a porta de entrada).

Porta de saída: decide qual será a saída (o próximo estado oculto) da rede naquele momento. A saída é uma versão filtrada do estado atual da célula, processada pelas funções tanh e sigmoide para determinar o que é relevante para a previsão atual.

2.3 Algoritmo Genético (AG)

A Figura 3, representa o funcionamento do AG.

Figura 3 - Funcionamento do AG



Fonte: Autor

O AG é uma metaheurística que faz parte da subdivisão da maior área da computação chamada de computação evolutiva. Ela foi baseada na evolução biológica e é aplicada na resolução de problemas complexos. A ideia central é que, ao longo das gerações, uma população de soluções candidatas pode “evoluir” em direção a uma solução ótima ou próxima da ótima. Para isso ela usa as operações de seleção, cruzamento e mutação (Lambora et al., 2019).

Seleção: é o processo de escolher, a cada geração, quais indivíduos da população serão os pais dos próximos, que geralmente são os indivíduos com melhor “aptidão” segundo a função objetivo.

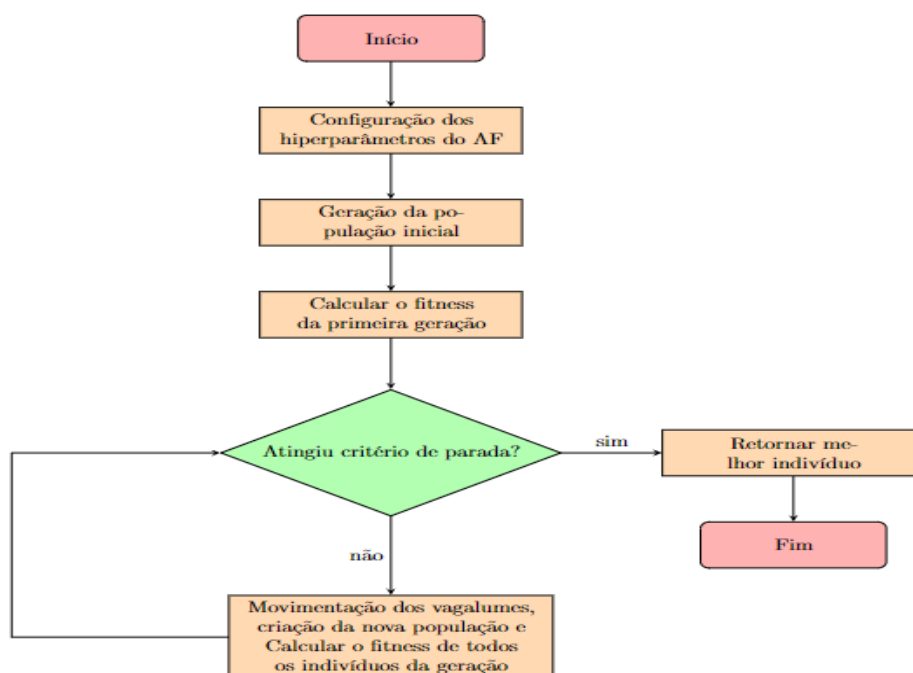
Cruzamento: é o operador que combina os indivíduos (pais) retornados pela seleção para fazer a próxima geração. Ele pega trechos de valores dos pais para criar combinações características.

Mutação: é o operador que altera aleatoriamente partes do cromossomo de um indivíduo, ele evita que o algoritmo fique preso em soluções locais.

2.4 Algoritmo *Firefly* (AF)

O funcionamento do AF está representado na Figura 4.

Figura 4 - Funcionamento do AF



Fonte: Autor

O AF é um algoritmo do domínio da Inteligência de Enxame. Ele foi inspirado no comportamento de atratividade dos vaga-lumes, eles usam a luz intermitente para atrair parceiros. Para realizar a busca, o algoritmo segue três regras idealizadas (Yang, 2010):

- Todos os vaga-lumes são unissex, o que significa que qualquer vaga-lume será atraído por outro vaga-lume.
- A atratividade é proporcional ao seu brilho, o que significa que o vaga-lume menos brilhante se moverá em direção ao mais brilhante.
- A intensidade da luz do vaga-lume é afetada pela paisagem da função objetivo.

2.5 Hiperparâmetros utilizados

Como já foi mencionado anteriormente, a LSTM necessita de uma configuração de hiperparâmetros. A Tabela 2 mostra a descrição. As metaheurísticas também tem os seus próprios hiperparâmetros que precisam ser otimizados, as Tabelas 3 e 4 mostram os hiperparâmetros utilizados nos testes. Neste trabalho a literatura foi utilizada para se ter uma base de valores para cada modelo (AG e AF).

Tabela 2 - Hiperparâmetros da LSTM

HIPERPARÂMETROS		DESCRIÇÃO
Otimizador		ADAM, ADAMW, ADAFACTOR, ADAMAX, RMSPROP
Ativador		RELU, TANH
Loss		MSE
Batch Size		16, 32, 64, 128, 256
Kernel Initializer		GLOROT_UNIFORM, HE_NORMAL
Weight Decay		0.01, 0.001, 0.0001, 0.0
Activity Regularizer		L1, L2
Kernel Regularizer		L1, L2
Taxa de Aprendizagem		0.001, 0.002, 0.003, 0.004, 0.005, 0.006, 0.007, 0.008, 0.009
Números de camadas Ocultas		1, 2, 3, 4
Neurônios		32, 50, 64, 75, 128, 256
Dropout		0.1, 0.2, 0.3, 0.4, 0.5
Semente (seed)		42

Fonte: Autor

Tabela 3 - Hiperparâmetros do AG

	Tamanho da População	Número de Gerações	Taxa de Mutação	Número de Pais	Semente
GA	30	50	0.2	2	42

Fonte: Autor

Tabela 4 - Hiperparâmetros do AF

	Tamanho da População	Número de Gerações	Intensidade de Luz Absoluta	Parâmetro Aleatório	Atratividade Base	Semente
AF	30	50	1.0	0.2	1.0	42

Fonte: Autor

3. RESULTADOS

Para realizar essa pesquisa, foi utilizado um computador com as seguintes configurações: Placa Mãe: ASUS Prime Z790-A, GPU: Geforce RTX 4070 Super, Processador: Intel(R) core (TM) I7 14700k, RAM: 32gb a 4800MHz, SO: Ubuntu 24.04.2 LTS. Para complementar foi utilizado *python* na versão 3.12.11, *keras* na versão 3.10.0 e o *tensorflow* na versão 2.18.0

Após os testes realizados levando em conta a Tabela 2, o melhor conjunto de hiperparâmetros encontrados pelas metaheurísticas estão representados na Tabela 5.

Tabela 5 - Hiperparâmetros retornados pelas metaheurísticas

HIPERPARÂMETROS	AG	AF
Otimizador	ADAM	ADAMAX
Ativador	TANH	TANH
Loss	MSE	MSE
Batch Size	16	32
Kernel Regularizer	GLOROT_UNIFORM	GLOROT_UNIFORM
Weight Decay	0.0	0.0
Activity Regularizer	0.01	0.01
Kernel Regularizer	0.01	0.01
Taxa de Aprendizagem	0.009	0.009
Número de Camadas Ocultas	1	1
Neurônios	128	256
Dropout	0.4	0.2

Fonte: Autor

Para a obtenção dos valores, a base de dados foi dividida em três partes: treino, validação e teste. O treino teve 70% dos dados, a validação 15% dos dados e o teste com 15% dos dados.

Foi utilizada uma semente (*seed* = 42) em todos os testes para tornar os resultados reprodutíveis. Para avaliar os modelos, foram utilizadas quatro métricas *Mean Square Error* (*MSE*), *Mean Absolute Error* (*MAE*), *Root Mean Square Error* (*RMSE*) e R^2 , com os valores apresentados na Tabela 6.

Tabela 6 - Métricas do conjunto de Teste


	MSE	MAE	RMSE	R ²
AG	0.0077	0.0577	0.0879	0.8263
AF	0.0120	0.0809	0.1096	0.7467

Fonte: Autor

O *MSE* obtido para os duas metaheurísticas, que avalia as diferenças entre as previsões e os valores reais, foram menores quando a busca por hiperparâmetros foi feita pelo AG, consequentemente, o *RMSE* por ser a raiz quadrada do *MSE* é menor também.


Em relação ao *MAE*, que mede o erro absoluto médio, mostra novamente que o AG supera o AF, indicando uma menor discrepância média ponto a ponto. Finalmente, analisando o R^2 que demonstra que o modelo calibrado pelo AG explica cerca de 82.6% da variabilidade dos dados, enquanto o AF explica aproximadamente 74,7%.

Figura 5 - Valores do AG



Fonte: Autor

Figura 6 - Valores do AF



Fonte: Autor 1

Para complementar a análise dos resultados da Tabela 6, as Figuras 5 e 6 mostram o gráfico de paridade entre os valores reais (eixo X) e os valores preditos pelo modelo LSTM (eixo Y): cada ponto azul corresponde a uma previsão para uma amostra de teste, enquanto a linha vermelha tracejada $y = x$ representa o cenário ideal de predição perfeita, indicando onde os pontos cairiam caso não houvesse erro. Dessa forma, a dispersão dos pontos em torno dessa reta fornece um indicativo visual da acurácia do modelo e evidencia possíveis tendências de superestimação (pontos acima) ou subestimação (pontos abaixo).

Para se ter uma base sobre os resultados retornados pela pesquisa, foi comparado com Cunha (2024), onde ele obteve resultados do MSE para duas metaheurísticas avaliadas, o AG com 0.01066977 de erro e o PSO com 0.018290916. Nesse trabalho, o AG, também, foi mais promissor.

4. CONCLUSÃO

Como demonstrado anteriormente, a geração de energia solar fotovoltaica está sujeita a incertezas decorrentes da intermitência da radiação solar. Por isso, prever adequadamente essa geração é fundamental tanto para sua integração eficiente à rede elétrica quanto para apoiar o desenvolvimento sustentável.

As redes LSTM são adequadas para predições devido às suas características inerentes, mas a otimização de hiperparâmetros é essencial para aprimorar sua acurácia, e é neste ponto que as metaheurísticas podem contribuir de forma decisiva.

Os resultados mostraram que o Algoritmo Genético obteve o melhor desempenho, mas que ainda pode ser refinado para melhorar a precisão, sobretudo nos valores mais elevados da geração de energia.

Outros aspectos podem ser explorados em trabalhos futuros são: abordar outras metaheurísticas e hibridizações: testar algoritmos como PSO, ou híbridos (por exemplo, GA + PSO) à procura de convergência mais rápida e soluções mais robusta; incorporar dados meteorológicos, como nuvens, velocidade do vento ou previsões de modelos físicos (NWP) para enriquecer a base de entrada; e testar a implementação em ambiente de produção, analisando latência, requisitos computacionais e capacidade de adaptação em diferentes regiões geográficas.

REFERÊNCIAS

ANG, Tze-Zhang *et al.* *A comprehensive study of renewable energy sources: classifications, challenges and suggestions.* **Energy Strategy Reviews**, Amsterdam, v. 43, art. 100939, 2022. Disponível em: <<https://doi.org/10.1016/j.esr.2022.100939>>. Acesso em: 22 mai 2025.

ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA. **Panorama da solar fotovoltaico no Brasil e no mundo.** São Paulo: ABSOLAR, [s.d.]. Disponível em: <<https://www.absolar.org.br/mercado/infografico/>>. Acesso em: 30 mai 2025.

BISCHL, B. *et al.* *Hyperparameter optimization: foundations, algorithms, best practices, and open challenges.* **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, Hoboken, v. 13, e1484, 2021. Disponível em: <<https://doi.org/10.1002/widm.1484>>. Acesso em: 26 mai 2025.

GERG, F. A.; SCHMIDHUBER, J.; CUMMINS, F. *Learning to forget: continual prediction with LSTM.* **Neural Computation**, Cambridge, MA, v. 12, n. 10, p. 2451-2471, out. 2000. Disponível em: <<https://doi.org/10.1162/089976600300015015>>. Acesso em: 26 mai 2025.

GREEN, Martin A. *Photovoltaic technology and visions for the future.* **Progress in Energy**, Bristol, v. 1, n. 1, p. 013001, jul. 2019. Disponível em: <<https://doi.org/10.1088/2516-1083/ab0fa8>>. Acesso em: 22 mai 2025.

HOCHREITER, S.; SCHMIDHUBER, J. *Long short-term memory.* **Neural Computation**, Cambridge, MA, v. 9, n. 8, p. 1735-1780, nov. 1997. Disponível em: <<https://doi.org/10.1162/neco.1997.9.8.1735>>. Acesso em: 26 mai 2025.

HUANG, C.; LI, Y.; YAO, X. *A survey of automatic parameter tuning methods for metaheuristics*. **IEEE Transactions on Evolutionary Computation**, Piscataway, v. 24, n. 2, p. 201-216, 2020. Disponível em: <<https://doi.org/10.1109/TEVC.2019.2921598>>. Acesso em: 21 mai 2025.

INTERNATIONAL ENERGY AGENCY. **Solar PV**. Paris: IEA, 3 fev. 2025. Disponível em: <<https://www.iea.org/energy-system/renewables/solar-pv>>. Acesso em: 22 mai 2025.

JAISWAL, Krishna Kumar *et al.* *Renewable and sustainable clean energy development and impact on social, economic, and environmental health*. **Energy Nexus**, Amsterdam, v. 7, art. 100118, 2022. Disponível em: <<https://doi.org/10.1016/j.nexus.2022.100118>>. Acesso em: 21 mai 2025.

KANNAL, Anik. *Solar power generation data*. **Kaggle**, 2017. Disponível em: <<https://www.kaggle.com/datasets/anikannal/solar-power-generation-data/data>>. Acesso em: 21 jun. 2025. Acesso em: 21 jun. 2025.

LAMBORA, Annu; GUPTA, Kunal; CHOPRA, Kriti. Genetic Algorithm- A Literature Review. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, BIG DATA, CLOUD AND PARALLEL COMPUTING (COMITCon), 2019, Faridabad. **Anais [...]**. Faridabad: IEEE, 2019. p. 380-384. Disponível em: <<https://doi.org/10.1109/COMITCon.2019.8862255>>. Acesso em: 17 jun. 2025.

LI, G. *et al.* *Solar energy utilisation: current status and roll-out potential*. **Applied Thermal Engineering**, Amsterdam, v. 209, art. 118285, 2022. Disponível em: <<https://doi.org/10.1016/j.applthermaleng.2022.118285>>. Acesso em: 22 mai 2025.

LIU, Luyao *et al.* *Prediction of short-term PV power output and uncertainty analysis*. **Applied Energy**, Amsterdam, v. 228, p. 700-711, 2018. Disponível em: <<https://doi.org/10.1016/j.apenergy.2018.06.112>>. Acesso em: 21 mai 2025

LIU, Zhenyu *et al.* *Forecast methods for time series data: a survey*. **IEEE Access**, Piscataway, v. 9, p. 91896-91912, 2021. Disponível em: <<https://doi.org/10.1109/ACCESS.2021.3091162>>. Acesso em: 26 mai 2025.

LUDIN, Norasikin Ahmad *et al.* *Prospects of life cycle assessment of renewable energy from solar photovoltaic technologies: a review*. **Renewable and Sustainable Energy Reviews**, Amsterdam, v. 96, p. 11-28, 2018. Disponível em: <<https://doi.org/10.1016/j.rser.2018.07.048>>. Acesso em: 22 mai 2025.

RADZI, Mohamad; AKHTER, M. N.; MEKHILEF, Saad; SHAH, N. M. Review on the application of photovoltaic forecasting using machine learning for very short- to long-term forecasting. **Sustainability, Basel**, v. 15, n. 4, p. 2942, 2023. Disponível em: <<https://doi.org/10.3390/su15042942>>. Acesso em: 21 jun. 2025.

RODRIGUES, B. Modelling and forecasting for solar irradiance from solarimetric station. *IEEE Latin America Transactions*, 2022. Disponível em: <https://doi.org/10.1109/TLA.2022.9661464>. Acesso em: 30 mai. 2025.

SILVA, Heitor Marques Francelino da; ARAÚJO, Francisco José Costa. Energia solar fotovoltaica no Brasil: uma revisão bibliográfica. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, São Paulo, v. 8, n. 3, p. 859-869, mar. 2022. Disponível em: <<https://doi.org/10.51891/rease.v8i3.4654>>. Acesso em: 30 mai 2025.

Cunha, Victor Honorato. *Predição de Energia Solar com base na Seleção e Otimização de Hiperparâmetros de Redes Neurais LSTM*. 2024. 75 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas) - Pontifícia Universidade Católica de Goiás, Goiás, 2024.

YANG, Li; SHAMI, Abdallah. *On hyperparameter optimization of machine learning algorithms: theory and practice*. *Neurocomputing*, Amsterdam, v. 415, p. 295-316, 2020. Disponível em: <<https://doi.org/10.1016/j.neucom.2020.07.061>>. Acesso em: 26 mai 2025.

YANG, X. S. Firefly algorithm, stochastic test functions and design optimisation. *International Journal of Bio-Inspired Computation*, v. 2, n. 2, p. 78-84, mar. 2010. Disponível em: <https://doi.org/10.1504/IJBIC.2010.032124>. Acesso em: 26 jun. 2025.

ZHANG, S. *et al.* Prediction of energy photovoltaic power generation based on artificial intelligence algorithm. *Neural Computing & Applications*, London, v. 33, p. 821-835, 2021. Disponível em: <<https://doi.org/10.1007/s00521-020-05249-z>>. Acesso em: 21 mai 2025.

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante Manoel Henrique de Oliveria Camargo do Curso de Engenharia da Computação matrícula 20212003300361, telefone: (62) 993485896 e-mail manelhro@gmail.com, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Otimização dos Hiperparâmetros da LSTM por Metaheurísticas para Previsão de Energia Solar Fotovoltaica, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 30 de setembro de 2025.

Assinatura do autor:  Documento assinado digitalmente
MANOEL HENRIQUE DE OLIVEIRA CAMARGO
Data: 30/09/2025 18:41:23-0300
Verifique em <https://validar.iti.gov.br>

Nome completo do autor: Manoel Henrique de Oliveira Camargo

Assinatura do professor-orientador:  Documento assinado digitalmente
MARIA JOSE PEREIRA DANTAS
Data: 19/12/2025 08:46:49-0300
Verifique em <https://validar.iti.gov.br>

Nome completo do professor-orientador: Maria José Pereira Dantas