

APRIMORAMENTO DO MHP COM APRENDIZADO PROFUNDO E REGRESSORES DE SÉRIES TEMPORAIS

Jonathan Ariel Salinas Espinola¹, Jorge Javier Gimenez Ledesma¹, Leandro Augusto Ensina², Oswaldo Hideo Ando Junior³, Joylan Nunes Maciel¹

¹Universidade Federal da Integração Latino-Americana (UNILA), Laboratório de Computação Aplicada (LACA), Foz do Iguaçu, Paraná, Brasil
(jas.espinola.2022@aluno.unila.edu.br)

²Universidade Tecnológica Federal do Paraná (UTFPR), Campo Mourão, Paraná, Brasil

³Universidade Federal da Paraíba (UFPB), Grupo de Pesquisa em Energia e Sustentabilidade Energética (GPeNSE), João Pessoa, Paraíba, Brasil

Resumo: A previsão de curto prazo da irradiância solar é essencial para mitigar a intermitência da geração fotovoltaica. Este estudo compara dez algoritmos de Deep Learning e Time Series Regressors (TSR) integrados ao Método Híbrido de Predição (MHP), em quatro horizontes (1 a 30 min). O TimeCNN obteve o melhor desempenho médio, o TSFresh o menor erro em 1 minuto, e o DrCIF a melhor alternativa entre os TSR. Os resultados evidenciam o compromisso entre custo de treinamento e desempenho preditivo do MHP.

Palavras-chave: Irradiância solar; Predição de curto prazo; Deep learning; Time series regressors; Energia fotovoltaica.

INTRODUÇÃO

A previsão da irradiância solar é essencial para mitigar os efeitos da intermitência da geração fotovoltaica e do fluxo de potência reverso, decorrentes da variabilidade das condições atmosféricas, em especial do deslocamento e da dinâmica das nuvens. Prever essas variações em horizontes de curto prazo (abaixo de 60 minutos) apoia o planejamento energético, a operação mais segura do sistema elétrico e a integração de fontes renováveis à rede (Maciel; Ledesma; Ando Junior, 2021).

Métodos preditivos baseados em imagens *all-sky* são empregados para caracterizar a dinâmica atmosférica e apoiar a previsão da irradiância solar, que constitui o principal fator da geração de energia fotovoltaica (Blaga et al., 2019). O Método Híbrido de Predição (MHP), proposto por Maciel, Ledesma e Ando Junior (2024a), combina o processamento de imagens *all-sky* (180°) com algoritmos de *Machine Learning* (ML) para a previsão de curto prazo. A abordagem extrai um conjunto de características das imagens (m_1 a m_8) para representar as condições atmosféricas que servem de entrada para uma Rede Neural Artificial (RNA) do tipo *Multi-Layer Perceptron* (MLP). O MHP demonstrou resultados competitivos com a literatura (Maciel et al., 2025).

O desenvolvimento de técnicas de *Deep Learning* (DL) ampliou a modelagem de dependências temporais em séries de dados. Arquiteturas

recorrentes, como *Long Short-Term Memory* (LSTM) (Hochreiter; Schmidhuber, 1997) e *Gated Recurrent Unit* (GRU) (Yu et al., 2019), usam mecanismos de controle do fluxo de informação para representar dependências em diferentes escalas temporais. Em comparação à LSTM, a GRU possui uma estrutura mais compacta e menos parâmetros, o que tende a torná-la computacionalmente mais eficiente. Como alternativa às arquiteturas recorrentes, as *Time Convolutional Neural Networks* (TimeCNN) aplicam convoluções unidimensionais para identificar padrões locais em sequências temporais (Lim; Zohren, 2021).




Figura 1. Método Híbrido de Predição (MHP).
Fonte: (Maciel; Ledesma; Ando Junior, 2024a).



Os *Time Series Regressors* (TSR) formam uma classe de métodos desenvolvidos especificamente para a análise e a previsão de séries temporais, com diferentes estratégias de representação dos dados (Guijo-Rubio et al., 2023; Tan et al., 2021). Entre elas, destacam-se os métodos baseados em características (*feature-based*), que extraem atributos estatísticos e estruturais; os baseados em intervalos (*interval-based*), que analisam diferentes regiões da série; os baseados em transformações convolucionais (*convolution-based*), que empregam representações obtidas por filtros e kernels; e os fundamentados em medidas de distância temporal. Essas abordagens são alternativas aos modelos de DL e podem estabelecer diferentes relações entre desempenho preditivo e custo computacional.

Apesar dos resultados do MHP, sua formulação original não incorporou arquiteturas recentes de DL nem uma avaliação sistemática de algoritmos especializados em séries temporais. Permanece em aberto, portanto, se substituir ou ampliar o modelo preditivo original produz ganhos de desempenho e de eficiência computacional na previsão de curto prazo da irradiância solar.

Este artigo apresenta uma avaliação sistemática do MHP por meio de uma comparação controlada entre modelos de DL e algoritmos de TSR em diferentes horizontes de previsão da irradiância solar. Foram avaliados os modelos GRU, LSTM e TimeCNN, bem como algoritmos TSR baseados em características, intervalos, transformações convolucionais e medidas de distância temporal, analisando-se tanto o desempenho preditivo quanto o custo computacional de cada abordagem.

MATERIAL E MÉTODOS

Os experimentos foram conduzidos em ambiente computacional controlado, utilizando um computador MacBook Pro equipado com processador Apple M1 e 8 GB de memória RAM. O ambiente de desenvolvimento foi configurado com *Python 3.10*, *TensorFlow 2.15.0* e o *framework Aeon 0.9.0*. Foi empregado o conjunto de dados disponibilizado por Maciel, Ledesma e Ando Junior (2024b), composto por um mês completo de observações (janeiro de 2015), com frequência de amostragem de um minuto e registros compreendidos entre 06h00 e 20h00.

A base de dados foi particionada de forma fixa e cronológica em três subconjuntos: treinamento (18 dias, 58%), validação (6 dias, 19%) e teste (7 dias, 23%). Essa divisão preservou a ordem temporal das observações e buscou manter proporções equivalentes de dias ensolarados, parcialmente nublados e nublados/chuvosos, classificados com base nos índices de claridade e de variabilidade atmosférica mensal.

Todos os modelos foram avaliados sob a mesma configuração experimental, utilizando as mesmas variáveis de entrada, a mesma estratégia de particionamento dos dados, uma janela temporal de cinco passos (*timesteps*) e horizontes de previsão de 1, 5, 15 e 30 minutos. Os hiperparâmetros dos modelos de *Deep Learning* (DL) foram otimizados por meio de busca bayesiana (*Bayesian Search*), implementada com o *framework Optuna* (Yang; Shami, 2020). A Tabela 1 exibe o espaço de busca e hiperparâmetros adotados no protocolo experimental.

Tabela 1. Hiperparâmetros dos modelos.

Algoritmo	Hiperparâmetro	Espaço de Busca	Valor Ótimo
GRU	Layers/Units	{1,2}/{32,64,128}	2 / 64
	Dropout int./out.	{0.1,0.4}	0.12/0.38
	Learning rate	[1e-4,1e-2]	0.00854
LSTM	Layers/Units	{1,2}/{32,64,128}	2 / 64
	Dropout int./out.	{0.1,0.4}	0.1/0.24
	Learning rate	[1e-4,1e-2]	0.00854
TimeCNN	Layers/Filters	{1,3}/{32,64,128}	1 / 64
	Kernel/LR	{3,5}/[1e-4,1e-2]	3 / 0.00054
ROCKET/			
MULTIRO	n_kernels	{500,1000,2000}	1000
CKET			
DrCIF	n_estimators	{25,50,100}	100
KNN-DTW	n_neighbors	{1, 3, 5, 7}	5
TimeSeries Forest	n_estimators	{25,50,100}	100
Catch22	n_estimators/outlier	{25,50,100}/Bool	100/True

Todos os modelos empregaram *seed=42*.

As entradas dos modelos são o conjunto de características (m_1 a m_8) fornecidas pelo MHP, complementadas pelas variáveis temporais. Foram avaliados dez algoritmos distribuídos em duas categorias. A categoria DL compreendeu os modelos GRU, LSTM e TimeCNN, enquanto a categoria *Time Series Regression* (TSR) incluiu os algoritmos Catch22, TSFresh, ROCKET, MultiROCKET, KNN-DTW, TimeSeriesForest e DrCIF. O desempenho preditivo foi quantificado por meio das métricas *Root Mean Squared Error* (RMSE) e *Mean Absolute Error* (MAE) (Gueymard, 2014), enquanto o custo computacional foi caracterizado pelos tempos de treinamento e de previsão, expressos em segundos. A RMSE é a métrica mais adotada na literatura de previsão da irradiância solar (Blaga et al., 2019).

A comparação entre os modelos foi realizada por meio de análise descritiva e quantitativa, considerando o desempenho individual dos dez algoritmos nos quatro horizontes de previsão. Foram analisados os valores de RMSE e MAE para cada horizonte, bem como os tempos de treinamento e de previsão. Para caracterizar o desempenho global de cada algoritmo, foram calculadas as médias das métricas de erro.

RESULTADOS E DISCUSSÃO

Os resultados obtidos para os quatro horizontes de previsão (1, 5, 15 e 30 minutos) são apresentados na

Tabela 2, que reúne as métricas de desempenho preditivo (RMSE e MAE) e os respectivos tempos de treinamento dos dez algoritmos avaliados. Complementarmente, a Figura 2 apresenta a variação do RMSE em função do horizonte de predição, permitindo uma comparação visual do comportamento dos modelos, permitindo visualizar um padrão de maiores erros entre horizontes de 1 a 5 minutos.

Tabela 2. Métricas de erro e tempos de treinamento.

Algoritmo	Horizonte (min)	RMSE (W/m ²)	MAE (W/m ²)	Tempo de treino (s)
GRU (DL)	1	58,65	34,14	325,47
	5	68,99	39,63	325,52
	15	70,17	41,39	320,73
	30	75,64	47,70	319,55
LSTM (DL)	1	61,22	37,72	352,43
	5	61,49	37,67	351,92
	15	66,86	42,61	343,95
	30	75,36	49,81	342,06
TimeCNN (DL)	1	54,33	33,93	799,2
	5	57,65	36,81	731,98
	15	64,09	41,96	710,47
	30	71,52	47,13	704,7
Catch22 (TSR)	1	66,99	43,74	23,08
	5	71,46	46,90	19,67
	15	75,54	49,86	19,32
	30	84,32	56,10	19,4
DrCIF (TSR)	1	56,71	34,94	907,18
	5	61,12	38,27	907,01
	15	66,46	43,39	866,88
	30	73,34	48,30	813,05
KNN-DTW (TSR)	1	82,28	51,35	0,022
	5	86,96	54,81	0,014
	15	86,11	54,36	0,014
	30	98,8	64,07	0,012
MultiROCKET (TSR)	1	69,5	47,35	1327,55
	5	75,88	52,45	1238,06
	15	76,89	54,33	1171,25
	30	87,5	60,63	1921,04
ROCKET (TSR)	1	69,74	45,42	254,55
	5	76,59	50,78	227,24
	15	78,58	51,74	206,89
	30	91,46	60,86	195,47
TimeSeriesForest (TSR)	1	64,11	39,28	325,53
	5	68,51	42,77	320,45
	15	70,06	45,68	318,71
	30	77,63	51,74	299,64
TSFresh (TSR)	1	53,71	34,81	808,51
	5	61,72	38,59	669,2
	15	73,48	45,76	650,36
	30	83,32	52,87	605,4

A análise da Tabela 2 evidencia que o aumento do horizonte de predição resultou em crescimento progressivo dos erros para todos os algoritmos avaliados, com destaque para 1 e 5 minutos. Considerando o desempenho médio global, o TimeCNN apresentou os menores valores de RMSE (61,90 W/m²) e MAE (39,96 W/m²), seguido pelo DrCIF. Entre os modelos de DL, o TimeCNN apresentou o menor RMSE em todos os horizontes e o menor MAE nos horizontes de 1, 5 e 30 minutos; no horizonte de 15 minutos, a GRU obteve o menor MAE

(41,39 W/m²), levemente inferior ao do TimeCNN (41,96 W/m²).

No horizonte de 1 minuto, o TSFresh superou o TimeCNN (RMSE de 53,71 W/m² contra 54,33 W/m²), porém, com custo computacional próximo (808,51s contra 799,20s de tempo de treinamento) e substancialmente superior ao da GRU (325,47s). Nos horizontes de 5, 15 e 30 minutos, o TimeCNN manteve a superioridade em desempenho, e o DrCIF foi o método TSR que mais se aproximou de seus resultados. Isto sugere que a abordagem baseada em intervalos representa adequadamente os padrões temporais da irradiância solar, ainda que com elevado tempo de treinamento.





Figura 2. RMSE dos modelos avaliados em diferentes horizontes de predição da irradiância solar.

Os resultados também evidenciam diferenças expressivas quanto ao custo computacional entre os algoritmos avaliados. O TimeCNN apresentou tempos de treinamento entre 704,70 e 799,20s, enquanto o DrCIF variou de 813,05 a 907,18s. O maior tempo de treinamento foi observado para o MultiROCKET, que atingiu 1.921,04s no horizonte de 30 minutos. Conforme esperado, os modelos GRU e LSTM apresentaram tempos de treinamento similares, aproximadamente metade do tempo requerido pelo TimeCNN, porém com desempenho preditivo inferior. Entre os métodos TSR, Catch22 e KNN-DTW destacaram-se pelo reduzido custo computacional de treino, embora tenham apresentado erros significativamente superiores aos demais.

Os resultados evidenciam que ambos os grupos de DL e TSR, conforme o horizonte preditivo, podem ser aplicados no MHP. Os modelos que alcançaram maior acurácia, como TimeCNN, DrCIF e TSFresh, demandaram tempos de treinamento substancialmente maiores, enquanto algoritmos computacionalmente mais eficientes, como Catch22 e KNN-DTW, apresentaram menor capacidade preditiva. Esse comportamento indica que, no contexto do MHP, a seleção do modelo deve considerar simultaneamente o desempenho preditivo requerido(a) e as restrições computacionais da aplicação.



CONCLUSÃO

Este estudo comparou modelos de DL e TSR integrados ao MHP, que realiza a predição da irradiância solar de curto prazo (1, 5, 15 e 30 minutos). O TimeCNN apresentou o melhor desempenho médio geral entre os dez algoritmos avaliados, enquanto o TSFresh destacou-se no horizonte de 1 minuto e o DrCIF foi a alternativa mais competitiva entre os métodos TSR. Os resultados evidenciam um compromisso entre desempenho preditivo e custo computacional quando utilizados com os dados do MHP: os algoritmos mais precisos (TimeCNN, DrCIF e TSFresh) exigiram maior tempo de treinamento, enquanto Catch22 e KNN-DTW, computacionalmente mais eficientes, apresentaram desempenho inferior.

Modelos de DL e métodos TSR constituem alternativas viáveis à predição de curto prazo da irradiância solar, contribuindo para o aprimoramento do MHP. Portanto, arquiteturas convolucionais profundas e métodos baseados em intervalos, no contexto do MHP, foram as abordagens de maior acurácia preditiva para esse tipo de aplicação. As conclusões devem ser interpretadas considerando as limitações do protocolo experimental, que utilizou um único mês de dados e uma divisão cronológica fixa entre treinamento, validação e teste, sem avaliar variabilidade sazonal sob diferentes particionamentos. Trabalhos futuros devem ampliar a avaliação para um conjunto de dados inter-anual mais extenso, incluindo novas arquiteturas de DL.

AGRADECIMENTOS

Os autores agradecem à Secretaria da Ciência, Tecnologia e Ensino Superior do Paraná (SETI) e à Fundação Araucária (FA) pelo apoio financeiro, por meio do Projeto nº PBA2025201000102, no âmbito da Chamada Pública nº 23/2024. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo fomento nº 460014/2025-0. Agradecemos ao Laboratório de Computação Aplicada (LACA) da UNILA e ao Grupo de Pesquisa em Energia e Sustentabilidade Energética (GPEnSE) da UFPB, pela infraestrutura e apoio.

REFERÊNCIAS

- BLAGA, Robert *et al.* A current perspective on the accuracy of incoming solar energy forecasting. **Progress in Energy and Combustion Science**, v. 70, p. 119–144, 2019.
- GUEYMARD, Christian A. A review of validation methodologies and statistical performance indicators for modeled solar radiation data: Towards a better bankability of solar projects. **Renewable and Sustainable Energy Reviews**, v. 39, p. 1024–1034, 2014.

- GUIJO-RUBIO, David *et al.* Unsupervised feature based algorithms for time series extrinsic regression. **arXiv preprint arXiv:2305.01429**, 2023.

- HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 1 nov. 1997.

- LIM, Bryan; ZOHREN, Stefan. Time-series forecasting with deep learning: a survey. **Philosophical transactions of the royal society a: mathematical, physical and engineering sciences**, v. 379, n. 2194, 2021.

- MACIEL, Joylan Nunes *et al.* Optimizing Solar Irradiance Prediction: Feature Selection for All-Sky Image Processing Using a Hybrid Prediction Method. **IEEE Latin America Transactions**, v. 23, n. 1, p. 50–57, jan. 2025.

- MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. Forecasting Solar Power Output Generation: A Systematic Review with the Proknow-C. **IEEE Latin America Transactions**, v. 19, n. 4, p. 612–624, abr. 2021.

- MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. Hybrid prediction method of solar irradiance applied to short-term photovoltaic energy generation. **Renewable and Sustainable Energy Reviews**, v. 192, p. 114185, mar. 2024a.

- MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. Dataset for Machine Learning: Explicit All-Sky Image Features to Enhance Solar Irradiance Prediction. **Data**, v. 9, n. 10, p. 113, 29 set. 2024b.

- TAN, Chang Wei *et al.* Time series extrinsic regression: Predicting numeric values from time series data. **Data Mining and Knowledge Discovery**, v. 35, n. 3, p. 1032–1060, maio 2021.

- YANG, Li; SHAMI, Abdallah. On hyperparameter optimization of machine learning algorithms: Theory and practice. **Neurocomputing**, v. 415, p. 295–316, 20 nov. 2020.

- YU, Yong *et al.* A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. **Neural Computation**, v. 31, n. 7, p. 1235–1270, jul. 2019.