INSTITUTO LATINO-AMERICANO DE TECNOLOGIA, INFRAESTRUTURA E TERRITÓRIO

PROGRAMA DE PÓS-GRADUAÇÃO INTERDISCIPLINAR EM ENERGIA E SUSTENTABILIDADE

MÉTODO HÍBRIDO DE PREDIÇÃO DA IRRADIÂNCIA SOLAR COM PROCESSAMENTO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL APLICÁVEL A GERAÇÃO DE ENERGIA SOLAR FOTOVOLTAICA

JOYLAN NUNES MACIEL

Foz do Iguaçu - PR

2022

INSTITUTO LATINO-AMERICANO DE TECNOLOGIA, INFRAESTRUTURA E TERRITÓRIO

PROGRAMA DE PÓS-GRADUAÇÃO INTERDISCIPLINAR EM ENERGIA E SUSTENTABILIDADE

MÉTODO HÍBRIDO DE PREDIÇÃO DA IRRADIÂNCIA SOLAR COM PROCESSAMENTO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL APLICÁVEL A GERAÇÃO DE ENERGIA SOLAR FOTOVOLTAICA

Tese de Doutorado apresentada ao Programa de Pós-Graduação Interdisciplinar em Energia e Sustentabilidade da Universidade Federal da Integração Latino-Americana, como requisito para à obtenção do título de Doutor em Energia e Sustentabilidade.

Orientador: Prof. Dr. Oswaldo Hideo Ando Junior.

Co-orientador: Prof. Dr. Jorge Javier Gimenez Ledesma.

Foz do Iguaçu - PR

2022

Catalogação elaborada pelo Setor de Tratamento da Informação
Catalogação de Publicação na Fonte. UNILA - BIBLIOTECA LATINO-AMERICANA - PTI

M152
Maciel, Joylan Nunes.
Método Híbrido de Predição da Irradiância Solar com Processamento de Imagens e Inteligência Artificial Aplicável à Geração de Energia Solar Fotovoltaica / Joylan Nunes Maciel. - Foz do Iguaçu, 2022.
146 f.: il., color.

Tese (Doutorado) - Universidade Federal da Integração Latino-Americana, Instituto Latino-Americano de Tecnologia, Infraestrutura e Território, Programa de Pós-Graduação Interdisciplinar em Energia e Sustentabilidade. Foz do Iguaçu - PR, 2022.
Orientador: Oswaldo Hideo Ando Junior.
Coorientador: Jorge Javier Gimenez Ledesma

1. Energia solar. 2. Energia fotovoltaica. 3. Predição de geração de energia. 4. Curto prazo. 5. Inteligência artificial. 6. Aprendizado de máquina. I. Ando Junior, Oswaldo Hideo. II. Gimenez Ledesma, Jorge Javier. III. Título.

CDU 620.91:004.8

MÉTODO HÍBRIDO DE PREDIÇÃO DA IRRADIÂNCIA SOLAR COM PROCESSAMENTO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL APLICÁVEL A GERAÇÃO DE ENERGIA SOLAR FOTOVOLTAICA

Tese de Doutorado apresentada ao Programa de Pós-Graduação Interdisciplinar em Energia e Sustentabilidade do Instituto Latino-Americano de Tecnologia, Infraestrutura e Território da Universidade Federal da Integração Latino-Americana, como requisito para a obtenção do título de Doutor em Energia e Sustentabilidade.

BANCA EXAMINADORA

Documento assinado digitalmente
gov.br
OSWALDO HIDEO ANDO JUNIOR
Data: 14/01/2023 09:54:58-0300
Verifique em https://verificador.iti.br

Orientador: Prof. Dr. Oswaldo Hideo Ando Junior
UNILA

Documento assinado digitalmente
gov.br
JORGE JAVIER GIMENEZ LEDESMA
Data: 16/01/2023 09:10:54-0300
Verifique em https://verificador.iti.br

Coorientador: Prof. Dr. Jorge Javier Gimenez Ledesma
UNILA

Documento assinado digitalmente
gov.br
FABIANO SALVADORI
Data: 14/01/2023 11:13:29-0300
Verifique em https://verificador.iti.br

Prof. Dr. Fabiano Salvadori
UFPB

Documento assinado digitalmente
gov.br
RENATO BOBSIN MACHADO
Data: 15/01/2023 08:56:22-0300
Verifique em https://verificador.iti.br

Prof. Dr. Renato Bobsin Machado
UNIOESTE

Documento assinado digitalmente
gov.br
GIULIANO ARNS RAMPINELLI
Data: 16/01/2023 14:08:47-0300
CPF: ***.085.659-**
Verifique as assinaturas em https://v.ufsc.br

Prof. Dr. Giuliano Arns Rampinelli
UFSC

Foz do Iguaçu, 20 de dezembro de 2022.

AGRADECIMENTOS

Agradeço a Deus e toda minha família, em especial meus pais Lucy e José Alberi pela vida e apoio incondicional. Agradeço a minha amada esposa Ana Luisa Teles Maciel e meu maravilhoso filho Murilo Teles Maciel pela paciência, confiança, apoio incondicional e, principalmente, paciência que foram indispensáveis no desenvolvimento deste estudo. Ao meu orientador Prof. Dr. Oswaldo Hideo Ando Junior pela confiança, estímulo contagiante diário, amizade e oportunidade de conduzirmos, conjuntamente, o desafio deste estudo. Ao meu coorientador Prof. Dr. Jorge Javier Gimenez Ledesma pelas orientações precisas e oportunas. Agradeço ambos os meus orientadores pelos ensinamentos serão úteis por toda minha vida. Aos meus amigos(as) Marcelo N. Kapp, Willian Zalewski, André G. Maletzke e Andrés C. Ferrero e Victor H. Wentz e pela amizade, incentivo, dicas e contribuições úteis no desenvolvimento desta tese. Aos professores Giuliano A. Rampinelli, Fabiano Salvadori e Renato Bobsin Machado, membros da banca, pela disponibilidade e valiosas sugestões. A todos(as) os(as) amigos(as) e professores do PPGIES/UNILA pela amizade, estudos e convivência durante o período do doutorado. A UNILA por existir, possibilitar e contribuir para o desenvolvimento deste estudo. A todas as pessoas que contribuíram, direta ou indiretamente, para a realização deste trabalho.

Lições para a Ciência e para a Vida: 13 Princípios Básicos

1) Instituições científicas, universitárias ou isoladas constroem-se com cérebros e não com edifícios. Escala de prioridades:
   a) cérebros;
   b) cérebros;
   c) cérebros;
   d) bibliotecas;
   e) equipamentos;
   f) edifícios. Isto é importante acentuar porque neste país acreditamos em fachadas.
2) Esses cérebros têm que trabalhar em tempo integral e ter o espírito de idealistas.
3) Não há pesquisa pura ou aplicada. Há boa ou má pesquisa.
4) A hierarquia científica deve ser estabelecida em função da criatividade e não dos títulos acadêmicos. Há doutos que não são doutores e há doutores que não são doutos.
5) A produção científica original é acelerada e multiplicada pela promoção de encontros e reuniões de cientistas de diferentes especialidades (físicos, químicos, biólogos, economistas, arquitetos, médicos) e de programas multidisciplinares. É o princípio da orquestração. O efeito estético obtido por um virtuoso tocando isoladamente jamais alcança o obtido por um quarteto de câmara ou por uma orquestra sinfônica.
6) Em instituições científicas a administração é atividade-meio a serviço dos cientistas que realizam as atividades-fim, buscando remover-lhes as dificuldades e empecilhos burocráticos.
7) O administrador ou dirigente de instituições científicas deve ser ou deve ter sido criador de pensamento original, isto é, um cientista experimentado e, portanto, capaz de compreender os anseios e as dificuldades dos cientistas que dirige, apoiando-os e distribuindo recursos em função da capacidade produtiva.
8) É fundamental o contato direto, sem papéis ou canais burocráticos, entre o dirigente e os cientistas, ouvindo-os, estimulando-os, obviando dificuldades e auxiliando-os ativamente a resolver inclusive problemas humanos que, por vezes, também os afligem. É anseio legítimo do cientista saber que o dirigente, reitor ou diretor, o distingue e tem consciência da importância de seu trabalho.
9) O gigantismo é patológico para indivíduos, para cidades e para instituições científicas porque torna o dirigente científico incapaz de controlar a qualidade da produção científica.
10) O cientista deve ser avaliado e prestigiado não apenas pela própria produção original, mas, e sobretudo, pela capacidade de formar e estimular discípulos que lhe multiplicam a produção, acelerando o caminho da ciência.
11) O dirigente científico deve saber distinguir a meia ciência, mascarada de Ciência, mais prejudicial que a ignorância e sub-repticiamente preocupada em combater a ciência verdadeira.
12) O dirigente científico deve lutar agressivamente contra a mediocridade, a rotina e a inveja. Elas constituem as três forças destrutivas, invejavelmente solidárias, que se opõem tenazmente às forças construtivas do talento, da insatisfação frente ao conhecimento adquirido e do ideal, características dos verdadeiros cientistas e que os levam a remover os horizontes do conhecimento humano.
13) Não interessa ao dirigente científico o pensamento político-ideológico dos cientistas que dirige, contanto que não usem a sua superioridade hierárquica e cultural para doutrinação de seus jovens discípulos. A experiência demonstrou que quando ideologias políticas extremistas entram pela porta das instituições científicas a ciência sai pela janela.

Professor Zeferino Vaz (1908 - 1981)

RESUMO

Existe a necessidade de suprir o aumento do consumo de energia elétrica que vem ocorrendo ao longo dos anos. No Brasil, uma das mais promissoras fontes de energia considerada renovável e utilizada como solução é a energia solar fotovoltaica. No entanto, a energia solar fotovoltaica possui peculiaridades intrínsecas, e não controláveis, que causam intermitências na sua geração. Isto se deve a fatores climáticos, tais como os ventos, as nuvens, a temperatura, a intensidade e a duração da irradiância solar, entre outras peculiaridades. Portanto, torna-se benéfico e relevante a existência de soluções para a predição da geração de energia solar fotovoltaica, possibilitando o aumento da segurança na geração e distribuição da energia elétrica com base na previsão das intermitências decorrentes do processo de geração. Neste contexto, o objetivo desta pesquisa é o desenvolvimento de um Método Híbrido de Predição (MHP) da irradiância solar aplicável a Predição da Geração de Energia Solar Fotovoltaica (PGESF) de curto prazo. A abordagem de execução híbrida do MHP emprega um conjunto de técnicas de Processamento de Imagens (PI), para extração de características do céu, e um modelo de predição baseado em Aprendizado de Máquina (*Machine Learning*). A análise experimental do MHP, realizada em diversos horizontes de predição de curto prazo (1, 5, 10, 15, 30 e 60 minutos), demonstrou que a abordagem proposta proporciona acurácia média de predição superior ao modelo de referência (*Persistence*) em 17,45% para todos os horizontes. Outro ponto de destaque, a acurácia de predição do MHP com o modelo de Aprendizado de Máquina baseado em rede neural artificial *MultiLayer Perceptron* (MLP) é similar ou supera, nos horizontes avaliados, as acurácias de diversos estudos da literatura científica que empregam imagens *all-sky* e utilizam PI, inclusive com métodos mais robustos de Aprendizado de Máquina Profundo (*Deep Learning*). Além disso, o uso do conjunto das métricas de PI do MHP proposto, possibilitou predições com maior acurácia (28% a 44%) em relação ao uso de informações meteorológicas nos modelos de aprendizado de máquina avaliados. Por ser um modelo de predição do tipo caixa-cinza, o MHP pode ser otimizado em relação ao uso de novas métricas de PI e a determinados horizontes de predição. Por fim, destaca-se que o MHP proposto contempla uma nova abordagem de execução híbrida, com extração explícita de um conjunto de características das imagens *all-sky*, que se mostrou viável com resultados satisfatórios, demonstrando um novo caminho em futuros estudos na PGESF.

Palavras-chave: energia solar, energia fotovoltaica, predição de geração, curto prazo, inteligência artificial, aprendizado de máquina.

RESUMEN

Es necesario suplir el aumento del consumo de electricidad que se ha venido produciendo a lo largo de los años. En Brasil, una de las fuentes de energía más prometedoras, considerada renovable y utilizada como solución, es la energía solar fotovoltaica. Sin embargo, la energía solar fotovoltaica tiene peculiaridades intrínsecas e incontrolables que provocan intermitencias en su generación. Esto se debe a factores climáticos, como los vientos, las nubes, la temperatura, la intensidad y la duración de la irradiación solar, entre otras peculiaridades. Por ello, se hace beneficiosa y relevante la existencia de soluciones para la predicción de la generación de energía solar fotovoltaica, que permitan aumentar la seguridad en la generación y distribución de energía eléctrica en base a la predicción de las intermitencias derivadas del proceso de generación. En este contexto, el objetivo de esta investigación es el desarrollo de un Método Híbrido de Predicción (MHP) de la irradiación solar aplicable a la Predicción de la Generación de Energía Solar Fotovoltaica (PGESF) a corto plazo. El enfoque híbrido de ejecución del MHP emplea un conjunto de técnicas de Procesamiento de Imágenes (PI), para la extracción de características del cielo, y un modelo de predicción basado en *Machine Learning*. El análisis experimental del MHP, realizado en varios horizontes de predicción a corto plazo (1, 5, 10, 15, 30 y 60 minutos), mostró que el enfoque propuesto proporciona una precisión de predicción media superior a la del modelo de referencia (*Persistence*) en un 17,45% para todos los horizontes. Otro punto a destacar, la precisión de predicción del MHP con el modelo de *Machine Learning* basado en la red neuronal artificial *MultiLayer Perceptron* (MLP) es similar o supera, en los horizontes evaluados, la precisión de varios estudios en la literatura científica que emplean imágenes *all-sky* y utilizan IP, incluyendo métodos más robustos de *Deep Learning*. Además, el uso del conjunto de métricas IP del MHP propuesto, permitió predicciones con mayor precisión (28% a 44%) en relación al uso de información meteorológica en los modelos de aprendizaje automático evaluados. Al tratarse de un modelo de predicción de tipo caja gris, el MHP puede optimizarse en lo que respecta al uso de nuevas métricas de PI y de determinados horizontes de predicción. Finalmente, se destaca que el MHP propuesto contempla un nuevo enfoque híbrido de ejecución, con extracción explícita de un conjunto de características a partir de imágenes *all-sky*, que se mostró factible con resultados satisfactorios, demostrando un nuevo camino en futuros estudios en el PGESF.

Palabras clave: energía solar, energía fotovoltaica, predicción de generación, corto plazo, inteligencia artificial, aprendizaje automática.

ABSTRACT

There is a need to supply the increase in electricity consumption that has been occurring over the years. In Brazil, one of the most promising energy sources considered renewable and used as a solution is photovoltaic solar energy. However, photovoltaic solar energy has intrinsic, and uncontrollable, peculiarities that cause intermittencies in its generation. This is due to climatic factors, such as winds, clouds, temperature, intensity and duration of solar irradiance, among other peculiarities. Therefore, it becomes beneficial and relevant the existence of solutions for the prediction of the generation of photovoltaic solar energy, enabling increased security in the generation and distribution of electricity based on the prediction of intermittencies arising from the generation process. In this context, the objective of this research is the development of a Hybrid Method for Prediction (MHP) of solar irradiance applicable to short-term Solar Photovoltaic Power Generation Prediction (PGESF). The hybrid execution approach of the MHP employs a set of Image Processing (IP) techniques, for extraction of sky features, and a Machine Learning-based prediction model. Experimental analysis of the MHP, carried out over several short-term prediction horizons (1, 5, 10, 15, 30 and 60 minutes), has shown that the proposed approach provides average prediction accuracy that is 17.45% better than the reference model (Persistence) for all horizons. Another highlight, the prediction accuracy of the MHP with the Machine Learning model based on MultiLayer Perceptron (MLP) artificial neural network is similar or exceeds, at the evaluated horizons, the accuracy of several studies in the scientific literature that employ all-sky images and use IP, including more robust Deep Learning methods. Moreover, the use of the set of IP metrics of the proposed MHP, allowed predictions with higher accuracy (28% to 44%) compared to the use of meteorological information in the evaluated machine learning models. As it is a gray-box prediction model, the MHP can be optimized regarding the use of new IP metrics and certain prediction horizons. Finally, we highlight that the proposed MHP contemplates a new hybrid execution approach, with explicit extraction of a set of features from all-sky images, which proved to be feasible with satisfactory results, demonstrating a new path in future studies in PGESF.

Key words: photovoltaic energy, solar energy, generation forecasting, short-term, artificial intelligence, machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Histórico do crescimento de publicações científicas sobre a PGESF. 28
Figura 2 – Linha do tempo dos principais estudos científicos da PGESF por continente. 34
Figura 3 – Portfólio Bruto de Patentes sobre a PGESF por país de concessão. 38
Figura 4 – Conceitos de desvio, acurácia e precisão. 43
Figura 5 – Relação entre os horizontes HRT e HRE. 45
Figura 6 – Componentes e imagens dos Modelos GBSI e SBSI. 53
Figura 7 – Ambiente, entradas e componentes do modelo predição deste estudo. 58
Figura 8 – Diagrama arquitetural do Método Híbrido de Predição – MHP. 59
Figura 9 – Fluxos de dados e processamento do Método Híbrido de Predição - MHP. 61
Figura 10 – Fluxograma de execução do Método Híbrido Predição (MHP) proposto. 62
Figura 11 – Exemplos de imagens totais do céu respectivos valores de irradiância solar. 63
Figura 12 – Perfil anual da irradiância GHI no *dataset* utilizado neste estudo. 64
Figura 13 – Representação de uma imagem digital no formato *Red-Green-Blue* (RGB). 64
Figura 14 – Perfil da irradiância GHI e respectivas imagens nos três dias de referência. 65
Figura 15 – Exemplos de planificação das imagens totais do céu. 67
Figura 16 – Resultado da métrica *Clouds Movement* para diferentes horizontes. 69
Figura 17 – Interferências nas imagens do *dataset* e capturadas pelo MSE. 70
Figura 18 – Processamento das imagens na métrica de *Clouds Coverage*. 72
Figura 19 – Resultado da métrica de *Clouds Coverage*. 73
Figura 20 – Algoritmo da métrica de *Clouds Around Sun.* 74
Figura 21 – Processamento de imagens da métrica de *Clouds Around Sun* (CAS). 74
Figura 22 – Resultado da métrica de *Clouds Around Sun* (CAS). 75
Figura 23 – Comparação da irradiância *Folsom GHI* e *Clear Sky GHI* (Ineichen-Perez). 76
Figura 24 – Processamento de imagens da métrica de *Sun Luminance*. 77
Figura 25 – Resultado da métrica *Sun Luminance*. 78
Figura 26 – Resultado da métrica *Sun Luminance Adjusted*. 79
Figura 27 – Resultado da métrica *Sun Located*. 80
Figura 28 – Resultado da métrica *White Pixel Ratio* (WPR). 81
Figura 29 – Entradas (*inputs*) e saída (*output Folsom GHI*) do MHP proposto. 82
Figura 30 – Representação de (a) um neurônio artificial e (b) e uma RNA do tipo MLP. 84
Figura 31 – Representação do algoritmo de *Gradient Boosting*. 85
Figura 32 – Delineamento da avaliação experimental do MHP. 86
Figura 33 – Acurácia de predição dos modelos de AM avaliados no MHP. 96
Figura 34 – Predições da irradiância solar do MHP nos três dias de referência. 97
Figura 35 – Acurácia do MHP (MLP e LightGBM) e de estudos da literatura científica. 100
Figura 36 – Acurácia do MHP com Métricas de PI e Informações Meteorológicas. 106
Figura 37 – Predição da irradiância solar com MLP e informação meteorológica. 107
Figura 38 – Predição da irradiância solar com LightGBM e informação meteorológica. 108

LISTA DE TABELAS

Tabela 1 – Eixos, palavras-chave e resultados das buscas nas bases de dados. 25
Tabela 2 – Portfólio Bibliográfico ordenado por citações em 05/09/2022. 26
Tabela 3 – Publicações relacionadas a PGESF de curto prazo na América Latina. 35
Tabela 4 – Palavras-chave, bases de dados e resultados da busca de anterioridade. 37
Tabela 5 – Portfólio de Patentes de Invenção concedidas e relevantes ao tema PGESF. 39
Tabela 6 – Características dos métodos de PGESF existentes e da solução proposta. 42
Tabela 7 – Horizontes de resolução temporal considerados nesta pesquisa. 44
Tabela 8 – Pesquisas usando os principais de Modelos Estatísticos Clássicos (MEC). 48
Tabela 9 – Pesquisas com métodos de Aprendizado de Máquina (AM). 49
Tabela 10 – Pesquisas com modelos de Processamento de Imagens. 53
Tabela 11 – Configuração do algoritmo da planificação das imagens totais do céu. 67
Tabela 12 – Configuração da avaliação experimental. 88
Tabela 13 – Divisão do *dataset* para validação e teste cruzado (*3-folds*) de cada modelo. 88
Tabela 14 – Configuração estrutural e hiperparâmetros dos modelos de AM do MHP. 89
Tabela 15 – Informações do *dataset* (PEDRO; LARSON; COIMBRA, 2019). 90
Tabela 16 – Acurácia de predição da irradiância solar do MHP proposto. 95
Tabela 17 – Acurácia de predição do MHP e estudos similares da literatura científica. 99
Tabela 18 – Acurácia de predição do MHP com Informações Meteorológicas. 105

LISTA DE SIGLAS E ABREVIATURAS

all-sky	Céu total
ANN	*Artificial Neural Network*
AM	Aprendizado de Máquina
AP	Aprendizado Profundo
API	*Application Program Interface*
AR	*Auto Regressive*
ARIMA	*Auto-Regressive Integrated Moving Average*
ARMA	*Auto-Regressive Moving Average*
BAB	Banco Bruto de Artigos
BBP	Base Bruta de Patentes
CDF	*Cloud Distribuition Feature*
CNN	*Convolutional Neural Networks*
dataset	*Base de dados*
DBN	*Deep Belief Networks*
DL	*Deep Learning*
DNI	*Direct Normal Irradiance*
DT	*Decision Tree*
EL	*Ensemble Learning*
FAR	Fontes Alternativas Renováveis
FV	Fotovoltaica(o)
GA	*Genetic Algorithms*
GB	*Giga Bytes*
GBM	*Gradient Boosting Machine*
GBSI	*Ground Based Sky Imagers*
GCM	Modelos Gerais de Circulação
GHI	*Global Horizontal Irradiance*
GP	*Gaussian Process*
GPU	*Graphical Process Unit*
GW	Giga Watts
HRE	Horizonte de Resolução Espacial
HRT	Horizonte de Resolução Temporal
IA	Inteligência Artificial
INPE	Instituto Nacional de Pesquisas Espaciais

INPI	Instituto Nacional de Propriedade de Industrial
Km^2	Quilômetro quadrado
KW/m^2	QuiloWatt por metro quadrado
KWh	QuiloWatt hora
k-NN	*k-Nearest Neighbors*
LTSM	*Long Short-Term Memory*
LightGBM	*Light Gradient Boosting Machine*
MAE	*Mean Absolute Error*
MARS	*Multivariate Adaptive Regression Spline*
MBE	*Mean Bias Error*
MEC	Modelos Estatísticos Clássicos
MH	Modelo Híbrido
MHP	Método Híbrido de Predição
ML	*Machine Learning*
MLP	*MultiLayer Perceptron*
MLR	*Multiple Linear Regression Model*
MME	Modelos de Mesoescala
MP	Modelos Persistentes
mRMR	Máxima Relevância e Mínima Redundância
MSE	*Mean Squared Error*
NWP	*Numerical Weather Predictions*
P2P	*Peer-to-Peer*
PAR	*Periodic AutoRegressive*
PB	Portfólio Bibliográfico
PC	Palavra(s)-Chave
PCA	*Principal Component Analysis*
PGESF	Predição da Geração de Energia Solar Fotovoltaica
ProKnow-C	*Knowledge Development Process – Construtivist*
RBF	*Radial Basis Function*
RF	*Random Forests*
RMSE	*Root Mean Square Error*
RNA	Redes Neurais Artificiais
RNN	*Recurrent Neural Network*
RSG	Radiação Solar Global
R^2	Coeficiente de Determinação

SBSI	*Satellite Based Sky Imagers*
SFCR	Sistemas Fotovoltaicos Conectados à Rede
SS	*Skill Score*
ST	Séries Temporais
SVM	*Support Vector Machine*
VMD	*Variational Mode Decomposition*

SUMÁRIO

1. INTRODUÇÃO 16

1.1. OBJETIVOS, HIPÓTESES E ASSERTIVAS 17
1.2. JUSTIFICATIVA E RELEVÂNCIA 19
1.3. ORIGINALIDADE E CONTRIBUIÇÃO 21
1.4. PUBLICAÇÕES RELACIONADAS AO ESTUDO 22
1.5. CONSIDERAÇÕES FINAIS 23

2. EMBASAMENTO TEÓRICO 23

2.1. LITERATURA CIENTÍFICA 24
2.2. LITERATURA DE PROPRIEDADE INTELECTUAL 37
2.3. PREDIÇÃO DE ENERGIA SOLAR FOTOVOLTAICA 43
2.3.1. Horizontes de Predição 44
2.3.2. Origem e Tipos dos Dados 45
2.3.3. Classes de Modelos 46
2.3.4. Medidas de Acurácia 54
2.4. CONSIDERAÇÕES FINAIS 56

3. MÉTODO HÍBRIDO DE PREDIÇÃO 57

3.1. DATASET 62
3.2. PROCESSAMENTO DE IMAGENS 64
3.2.1. Pré-processamento 66
3.2.2. Métrica de Movimentação das Nuvens 67
3.2.3. Métrica de Cobertura das Nuvens no Céu 70
3.2.4. Métrica de Nuvens Entorno do Sol 73
3.2.5. Irradiância Solar de Céu Limpo 75
3.2.6. Métrica de Luminância do Sol 76
3.2.7. Métrica de Luminância do Sol Ajustada 78
3.2.8. Métrica de Localização do Sol 80
3.2.9. Métrica Taxa de Pixels Brancos 80
3.3. APRENDIZADO DE MÁQUINA 83
3.3.1. MultiLayer Perceptron (MLP) 83
3.3.2. Light Gradient Boosting Machine (LightGBM) 84
3.4. AVALIAÇÃO EXPERIMENTAL 86
3.5. DATASET, MATERIAIS E TECNOLOGIAS 89
3.6. CONSIDERAÇÕES FINAIS 91

4. RESULTADOS E DISCUSSÃO 92

4.1. ACURÁCIA DE PREDIÇÃO 92
4.2. COMPARAÇÃO COM A LITERATURA CIENTÍFICA 98
4.3. ANÁLISE DOS TIPOS DE ENTRADA 103
4.4. VALIDAÇÃO DAS HIPÓTESES 109
4.5. CONSIDERAÇÕES FINAIS 111

5. CONCLUSÃO 112

REFERÊNCIAS 115

1. INTRODUÇÃO

A crescente busca pela diversificação da matriz energética com a inclusão de fontes complementares de energias renováveis tem-se intensificado nos cenários mundial e nacional, pois, além de suprir a crescente demanda de energia elétrica, essa expansão também auxilia no processo de descarbonização do setor elétrico e promove a sustentabilidade energética (MME, 2017). Dentre as fontes de geração de energia sustentável, destacam-se a energia eólica e a solar fotovoltaica (FV), sendo que esta última apresenta o maior crescimento atualmente no Brasil (ABSOLAR, 2022; ANEEL, 2022). Em 2022, a geração de energia solar fotovoltaica alcançou a marca de 14 GW da matriz elétrica brasileira, se tornando a terceira maior fonte de energia renovável do Brasil (ABSOLAR, 2022; ANEEL, 2022). No entanto, assim como em outras fontes de energia renovável, a geração de energia solar fotovoltaica possui características não controláveis e relativas as condições meteorológicas, tais como o movimento, altura e espessura das nuvens, temperatura, intensidade e duração da radiação solar, umidade do ar, entre outras (LAPPALAINEN; VALKEALAHTI, 2017). Tais fatores acarretam em intermitências na produção de energia elétrica, promovendo incertezas de geração e o aumento da instabilidade e a insegurança da rede elétrica (MARCOS et al., 2014; SHIVASHANKAR et al., 2016).

Com a atual e crescente expansão dos Sistemas Fotovoltaicos Conectados à Rede (SFCR), o tema **P**redição da **G**eração de **E**nergia **S**olar **F**otovoltaica (PGESF) tem ganhado destaque e sido amplamente pesquisado na literatura científica internacional (BLAGA et al., 2019; KUMARI; TOSHNIWAL, 2021; MACIEL; LEDESMA; ANDO JUNIOR, 2021). O aumento da participação dos SFCR na matriz elétrica brasileira faz surgir a preocupação com o impacto da mesma, por ser uma fonte intermitente, na estabilidade e segurança no sistema de transmissão e distribuição (SHIVASHANKAR et al., 2016). Dentre os métodos e técnicas para solucionar este problema tem-se a suavização de potência de geração, que vem ganhando destaque com o uso de sistemas de armazenamento de energia, como forma de mitigar as intermitências de geração, mantendo-as dentro de limites pré-estabelecidos (ABUELLA; CHOWDHURY, 2018; DIAZ, 2019; DU; LU, 2014; WEN et al., 2021). No Brasil ainda não se tem regulamentação que estabeleça limites nas intermitências de injeção de potência, havendo apenas padrões mínimos de qualidade da energia elétrica regulamentado pelo Procedimentos de Distribuição - PRODIST (ANEEL, 2020). Os métodos de PGESF de curto prazo contribuem para o desenvolvimento de sistemas de

armazenamento de energia elétrica que utilizam baterias acopladas ao módulo de geração fotovoltaica, pois, possibilita prever a geração futura e assim, a aplicação de técnicas e métodos para contornar (suavizar) as intermitências ocorridas durante o processo de geração de energia solar fotovoltaica (DIAZ, 2019; ELLIS et al., 2012).

Portanto, predizer as intermitências que podem ocorrer durante a geração de energia elétrica a partir da fonte solar fotovoltaica possibilita a otimização do controle e despacho da energia elétrica, e consequentemente, a mitigação da variação da potência injetada no sistema elétrico (DAS et al., 2018; JAMALY; KLEISSL, 2018). Complementarmente, as predições de médio e longo prazo, como por exemplo, um dia a frente, permitem ao operador do sistema conhecer o potencial de geração futura, gerenciando e prevendo antecipadamente o despacho e regulação de energia produzida (ANTONANZAS et al., 2016; VAN DER MEER; WIDÉN; MUNKHAMMAR, 2018). Por estes motivos, o tema PGESF tem sido amplamente estudado na literatura científica (BLAGA et al., 2019; DIAGNE et al., 2013; SHIVASHANKAR et al., 2016) e exibe um crescimento acentuado de novas pesquisas a partir do ano de 2017 (MACIEL; LEDESMA; ANDO JUNIOR, 2021).

Por fim, destacam-se a grande quantidade de pesquisas desenvolvidas em usinas solares fotovoltaicas nos últimos dez anos, principalmente nos países mais desenvolvidos que utilizam a energia fotovoltaica há diversos anos (BLAGA et al., 2019). O uso dessa tecnologia ainda é relativamente recente no Brasil e nos países da América Latina e, portanto, isto reflete na menor quantidade de pesquisas nestes países sobre o tema em relação ao cenário acadêmico mundial (MACIEL; LEDESMA; ANDO JUNIOR, 2021; YANG et al., 2018).

1.1. OBJETIVOS, HIPÓTESES E ASSERTIVAS

O objetivo deste estudo é desenvolver e avaliar um Método Híbrido de Predição (MHP) da irradiância solar aplicável a Predição da Geração de Energia Solar Fotovoltaica (PGESG) em horizontes de curto prazo. O método proposto utiliza imagens totais do céu (*all-sky*, 180°) como entrada e aplica um processamento híbrido composto conjuntamente por técnicas de Processamento de Imagens, para extração de características do céu, e por um modelo de Aprendizado de Máquina (AM) que realiza a predição da Irradiância Global Horizontal (GHI), aplicada na PGESF, em horizontes de curto prazo.

A partir do objetivo principal estabeleceu-se os seguintes objetivos específicos:

1) Revisar, identificar e analisar os métodos utilizados e principais estudos sobre a predição da irradiância solar aplicável a PGESF na literatura científica e de propriedade intelectual;

2) Analisar o uso de imagens locais do céu (*all-sky*) como entrada para o MHP aplicando um conjunto de técnicas de Processamento de Imagens (PI) para extração de características importantes à PGESF de curto prazo;

3) Avaliar quantitativamente a acurácia de predição e qualitativamente as características do MHP desenvolvido, comparando-o com propostas similares da literatura científica.

Os objetivos acima foram definidos sob as seguintes hipóteses de pesquisa:

a) O método de predição utilizando somente imagens *all-sky* e uma abordagem de execução híbrida, baseada em Processamento de Imagens e Aprendizado de Máquina, pode ser aplicado a PGESF de curto prazo e gerar acurácia de predição da irradiância solar igual ou superior a métodos mais complexos existentes na literatura científica, tais como de Aprendizado Profundo;

b) As imagens totais *all-sky* possuem características suficientes que possibilitam a predição da irradiância solar, especificamente a Irradiância Global Horizontal (GHI) empregada na PGESF, com acurácia igual ou superior ao uso de informações meteorológicas, tais como temperatura, umidade, velocidade e direção dos ventos, entre outras;

As hipóteses desta pesquisa foram definidas a partir da análise da literatura, descrita na seção 2, e possibilitou identificar as seguintes assertivas:

i) Historicamente, a maior parte dos estudos científicos frequentemente usam múltiplos tipos de dados meteorológicos, endógenos e exógenos, para a PGESF de curto prazo (BARBIERI; RAJAKARUNA; GHOSH, 2017; KUMARI; TOSHNIWAL, 2021; RAJAGUKGUK; RAMADHAN; LEE, 2020);

ii) As imagens totais do céu, coletadas de câmeras locais, também são empregadas em predições de geração de energia solar fotovoltaica de curto prazo, seja com métodos de Processamento de Imagens (SZELISKI, 2011), e mais recentemente, com o uso de modelos de Aprendizado Profundo (DE FREITAS VISCONDI; ALVES-SOUZA, 2019; LIN; ZHANG; WANG, 2022);

iii) É importante a otimização dos parâmetros de entrada dos métodos empregados na PGESF de curto prazo (AHMED et al., 2020);

iv) Os métodos de Aprendizado de Máquina (*Machine Learning*) e Aprendizado Profundo (*Deep Learning*) são os mais recentes e amplamente empregados na PGESF (RAJAGUKGUK; RAMADHAN; LEE, 2020; TINA et al., 2021). Além do acentuado aumento no uso de imagens do céu em conjunto com métodos de Aprendizado Profundo (DE FREITAS VISCONDI; ALVES-SOUZA, 2019; LIN; ZHANG; WANG, 2022), os resultados destes estudos têm demonstrado os melhores índices de predição na literatura (BLAGA et al., 2019; KUMARI; TOSHNIWAL, 2021; MACIEL; LEDESMA; ANDO JUNIOR, 2021; OBANDO; CARVAJAL; PINEDA AGUDELO, 2019);

v) Historicamente, as informações meteorológicas e de irradiância solar são relevantes e as mais utilizadas nos modelos de Aprendizado de Máquina na PGESF. Logo, essas informações são capturadas por dispositivos adicionais e específicos que demandam, portanto, maior custo de aquisição e de operação para os sistemas de predição (YANG et al., 2018);

vi) A irradiância solar é a principal componente que influencia a variabilidade da geração de energia fotovoltaica (DAS et al., 2018) e sua medição necessita de um dispositivo dedicado, sendo geralmente realizada por um piranômetro (BLUM et al., 2022).

vii) Modelos de predição baseados em imagens *all-sky* têm sido frequentemente utilizados por apresentarem menores custos de aquisição e operação em relação ao uso de imagens de satélites ou redes de sensores (ZHEN et al., 2022).

1.2. JUSTIFICATIVA E RELEVÂNCIA

O cenário (inter)nacional demonstra uma tendência crescente de consumo e demanda de geração de energia elétrica, tornando imprescindível a ampliação das fontes de energias renováveis, com destaque para a energia solar fotovoltaica (ANEEL, 2019; IRENA, 2020). Embora a quantidade de usinas fotovoltaicas e Sistemas Fotovoltaicos Conectados à Rede (SFCR) instalados no Brasil tenham aumentado consideravelmente nos últimos anos, a capacidade atual instalada de produção em 2022 representa apenas 8,1% da matriz elétrica brasileira, havendo ainda grande potencial de expansão (ABSOLAR, 2022; ANEEL, 2022).

O crescimento dos SFCR tornou-se uma realidade no Setor Elétrico Brasileiro. Quando conectados a rede elétrica, a energia produzida pelo SFCR é absorvida o pela rede elétrica que absorve o excedente produzido. Devido à intermitência que ocorre durante o processo de geração de energia solar, torna-se importante a predição desta geração, pois, isto possibilita aos operadores do sistema de energia elétrica realizar a gestão em busca da estabilidade e segurança do sistema elétrico brasileiro, cuja rede de distribuição é uma das maiores do mundo (LUCCHESE et al., 2018; LUIZ; ALMEIDA; ROMEIRO, 2018).

Diversas pesquisas sobre o tema PGESF foram desenvolvidas na última década, principalmente nos países desenvolvidos economicamente, tais como Estados Unidos, China, Alemanha, etc. (BLAGA et al., 2019; MOSAVI et al., 2019). Grande parte destes estudos utilizam dados de dispositivos e sensores específicos para captura de informações empregadas nas predições de geração, tais como informações meteorológicas (temperatura, umidade, velocidade dos ventos, etc.) e de irradiância solar (MACIEL; LEDESMA; ANDO JUNIOR, 2021; YANG et al., 2018). No entanto, poucos estudos nesta temática são observados no Brasil e América Latina na última década (BLAGA et al., 2019), com tímido surgimento de algumas pesquisas a partir de 2017 (MACIEL; LEDESMA; ANDO JUNIOR, 2021).

Com base na literatura científica (seção 2.1) e tecnológica (seção 2.2) da PGESF, destacam-se os seguintes aspectos que tornam relevante o presente estudo:

1) Desenvolvimento e avaliação de um Método Híbrido de Predição (MHP) da irradiância solar aplicável a geração de energia solar fotovoltaica de curto prazo, utilizando somente imagens totais do céu e dispensando a necessidade de dispositivos e recursos adicionais;

2) Proposição e avaliação de uma nova abordagem híbrida de execução das predições que utiliza, conjuntamente, técnicas de Processamento de Imagens e Aprendizado de Máquina da Inteligência Artificial;

3) Avaliação comparativa experimental de acurácia de predição do MHP proposto com diferentes algoritmos de Aprendizado de Máquina e diferentes tipos de entradas (*inputs*) relativas a um conjunto de características extraídas de imagens totais do céu, proposto neste estudo, e informações meteorológicas tradicionais;

4) Desenvolvimento do MHP para compor um sistema de PGESF de baixo custo computacional e operacional, aplicável em sistemas e módulos de geração de energia solar fotovoltaica;

5) Ampliar, disseminar e fomentar o desenvolvimento de novas pesquisas sobre a PGESF no Brasil e América Latina.

1.3. ORIGINALIDADE E CONTRIBUIÇÃO

A partir da revisão literária científica e tecnológica do estado da arte, não se observou propostas com as características do Método Híbrido de Predição (MHP), desenvolvido e avaliado neste estudo. A abordagem híbrida do método criado para processar as predições é original por empregar, conjuntamente, diversas técnicas de Processamento de Imagens para extrair um conjunto de métricas (características) das imagens totais do céu (*all-sky* de 180°), fornecendo-as para um algoritmo de Aprendizado de Máquina realizar o cálculo das predições em múltiplos horizontes de curto prazo.

A partir das características do MHP desenvolvido, as contribuições do presente estudo frente ao estado da arte da PGESF incluem:

Método Híbrido de Predição (MHP): a nova abordagem de execução proposta no MHP de curto prazo é composta pela execução conjunta e sequencial de técnicas de Processamento de Imagens (PI), que extraem características relevantes das imagens *all-sky* (denominadas de Métricas de PI), e um algoritmo de Aprendizado de Máquina, que utiliza tais as Métricas de PI para predizer a irradiância solar (GHI) em horizontes de curto prazo;

Independência de informações meteorológicas e irradiância solar: somente imagens simples de câmeras *all-sky* são necessárias para o processamento das predições nos horizontes de 1 a 60 minutos no MHP. Portanto, sensores ou recursos de *hardware* adicionais (informações meteorológicas ou de irradiância solar) são dispensados, reduzindo o custo de aquisição e operação do sistema de PGESF;

Interpretabilidade de processamento: O MHP proposto enquadra-se como um modelo caixa-cinza ou *gray-box* (LOYOLA-GONZALEZ, 2019), pois, possibilita melhor interpretabilidade humana em relação a características extraídas das imagens e processamento das predições, quando comparado aos modelos recentes de Aprendizado Profundo que utilizam somente imagens. Estes modelos, tais como as *Convolutional Neural Networks* (CNN) de Inteligência Artificial são conhecidos como caixa-preta ou *black-box*

por terem o processamento computacional de difícil interpretação humana (LOYOLA-GONZALEZ, 2019). Além disso, a extração de características no MHP ainda pode ser ampliada e/ou otimizada para determinado horizonte de predição.

Simplicidade, usabilidade e extensibilidade: Com a sua complexidade desenvolvida em software, o MHP proposto necessita somente de um dispositivo de processamentos e outro de captura de imagens, reduzindo a quantidade de dispositivos e sensores para sua execução. Isto facilita seu uso em módulos fotovoltaicos residenciais ou comerciais, de menor escala até usinas e *grids* de maior capacidade de geração. Além disso, futuramente o software do MHP pode ser ampliado, otimizado e estendido a novas funcionalidades de predições.

Dataset* de *benchmarking: O presente estudo possibilitou a elaboração e disponibilização de um *dataset* contendo informações relativas a 8 (oito) características extraídas de imagem *all-sky* originada na etapa de Processamento de Imagens (PI), além de outras informações. O *dataset* pode ser utilizado como *benchmarking* de futuros estudos na PGESF, e assim fomentar o desenvolvimento de novos modelos e métodos de predição da irradiância solar.

1.4. PUBLICAÇÕES RELACIONADAS AO ESTUDO

O desenvolvimento deste estudo possibilitou a publicação, direta e indireta, de dezenove (19) trabalhos[1] na PGESF, sendo: depósito de uma (1) patente de invenção, cinco (5) artigos em periódicos internacionais, dois (2) capítulos de livro, um (1) livro organizado, seis (6) artigos completos e quatro (4) resumos. É importante ressaltar que diversas decisões metodológicas e técnicas desta tese foram principalmente embasadas nas publicações elencadas a seguir:

i) MACIEL, J. N.; ANDO JUNIOR, O. H.; LEDESMA, J. J. G. Método, Dispositivo e Sistema Híbrido de Predição do Potencial de Geração de Energia Solar Fotovoltaica. 2020, Brasil. ***Pedido de Patente: Privilégio de Inovação.*** Número do registro: BR10202001533. Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial. Depósito: 28/07/2020.

ii) WENTZ, V. H.; MACIEL, J. N.; KAPP, M. N.; LEDESMA, J. J. G.; ANDO JUNIOR, O. H. Comparação de Modelos de Redes Neurais Artificiais Para a Predição da Irradiância Solar na Geração de Energia Fotovoltaica. In: ***I Congresso Brasileiro Interdisciplinar de Ciência e Tecnologia,*** Recife-PE. 2020.

[1] A lista detalhada das 19 publicações está disponível em < https://sites.google.com/site/joylan/doutorado >.

iii) MACIEL, J. N.; LEDESMA, J. J. G.; ANDO JUNIOR, O. H. Forecasting Solar Power Output Generation: A Systematic Review with the Proknow-C. ***IEEE Latin America Transactions***, v. 19, n. 4, p. 612–624, 2021. DOI: https://doi.org/10.1109/TLA.2021.9448544

iv) MACIEL, J. N.; WENTZ, V.H.; LEDESMA, J. J. G.; ANDO JUNIOR, O. H. Analysis of Artificial Neural Networks for Forecasting Photovoltaic Energy Generation with Solar Irradiance. ***Brazilian Archives of Biology and Technology (Online)***, 2021. DOI: https://doi.org/10.1590/1678-4324-75years-2021210131

v) URZAGASTI, C.A.; MACIEL, J.N.; WENTZ, V.H.; LEDESMA, J.J.G.; ANDO JUNIOR, O.H. Comparação da Acurácia de Modelos de Redes Neurais Artificiais na Predição da Irradiância Solar e Geração de Energia Fotovoltaica. In: 18º Congresso Latino-americano de Software Livre e Tecnologias Abertas - LatinoWare, 2021, Evento Online. Anais do 3º ***Latin.Science***, 2021.

vi) SERRANO ARDILA, V. M., MACIEL, J. N., LEDESMA, J. J. G., ANDO JUNIOR. Fuzzy Time Series Methods Applied to (In)Direct Short-Term Photovoltaic Power Forecasting. ***Energies***, 15(3), 845, 2022. DOI: https://doi.org/10.3390/en15030845

vii) WENTZ, V. H., MACIEL, J. N., LEDESMA, J. J. G., ANDO JUNIOR. Solar Irradiance Forecasting to Short-Term PV Power: Accuracy Comparison of ANN and LSTM Models. ***Energies***, 15(7), 2457, 2022. DOI: https://doi.org/10.3390/en15072457

1.5. CONSIDERAÇÕES FINAIS

Nesta seção foram apresentadas as principais característica sobre a PGESF no cenário atual. Em seguida foram descritos os objetivos geral e específico, as justificativas, a relevância, a originalidade e os aspectos que contemplam as contribuições desta pesquisa. A próxima seção relata, de modo detalhado, o embasamento teórico científico, tecnológico e os principais conceitos relativos ao tema PGESF que subsidiam o presente estudo.

2. EMBASAMENTO TEÓRICO

Esta seção descreve a revisão literária científica e tecnológica sobre a temática de pesquisa “Predição da Geração de Energia Solar Fotovoltaica (PGESF)” de curto prazo. A primeira revisão refere-se ao histórico dos trabalhos acadêmicos cientificamente relevantes publicados sobre o tema. A segunda revisão reúne e descreve histórico dos registros de propriedade intelectual (Patentes de Invenção) associados ao tema de pesquisa. Posteriormente, são abordados os conceitos fundamentais e os principais métodos computacionais aplicados ao tema PGESF. O embasamento teórico e conceitual subsidiará o desenvolvimento do Método Híbrido de Predição (MHP) proposto neste estudo.

2.1. LITERATURA CIENTÍFICA

O procedimento metodológico descrito nesta seção objetivou a busca, a seleção e a análise dos trabalhos acadêmicos científicos relevantes ao tema da PGESF. A revisão literária foi realizada com o método de abordagem sistemática e construtivista da literatura científica denominada Proknow-C (*Knowledge Development Process – Construtivist*) (ENSSLIN et al., 2010).

Diversos estudos de distintas áreas têm utilizado o instrumento Proknow-C em revisões da literatura acadêmica, sendo dois exemplos relatados em (ENSSLIN et al., 2014; MACIEL; LEDESMA; ANDO JUNIOR, 2021). O método Proknow-C possibilita sistematizar a pesquisa bibliográfica e identificar, de modo estruturado e eficiente, um portfólio bibliográfico com os artigos científicos mais relevantes do tema da pesquisa (ENSSLIN et al., 2010). Para isto, foram realizadas as seguintes etapas do Proknow-C: Seleção do portfólio bibliográfico; Análise bibliométrica do portfólio bibliográfico; Análise sistêmica do portfólio bibliográfico e; Pergunta de pesquisa.

Por meio destas etapas o Proknow-C foi executado para o tema "*predição da geração de energia solar fotovoltaica de curto prazo com o uso de dados terrestres*". Desse modo, foram definidos os três seguintes eixos da pesquisa:

- **Eixo 1**: Predição de curto prazo;
- **Eixo 2**: Geração de energia solar fotovoltaica;
- **Eixo 3**: Uso de informações, dados e imagens.

Posteriormente, selecionou-se as palavras-chave (PC) de cada eixo, cujas combinações baseadas na expressão lógica "Eixo 1 *and* Eixo 2 *and* Eixo 3" foram pesquisadas, na data de 19/01/2022, nas três seguintes bases de dados científicas bibliográficas: Scopus, *Web of Science* (*WoS*) e *Engineering Village*. Ressalta-se que estas bases indexam as principais revistas mundiais na área de pesquisa, tais como do *Institute of Electrical and Electronics Engineers* (IEEE). Essas informações e o resultado quantitativo das buscas são exibidos na Tabela 1, gerando uma Banco Bruto de Artigos (BBA) contendo 2349 títulos.

Tabela 1 – Eixos, palavras-chave e resultados das buscas nas bases de dados.

Palavras-Chave (PC)	**Scopus**	**WoS**	**Eng. Village**
(short-term AND (forecast OR forecasting)) AND (PV OR photovoltaic) AND (ground AND (data OR sensors OR measurements OR image))	338	26	36
(short-term AND (forecast OR forecasting)) AND (PV OR photovoltaic) AND ("ground-based" OR data)	125	12	17
(short-term AND (forecast OR forecasting)) AND ("solar radiation" AND photovoltaic) AND (ground AND (data OR sensors OR measurements OR image))	221	8	8
(short-term AND (forecast OR forecasting)) AND ("solar radiation" AND photovoltaic) AND ("ground-based" OR data)	101	1	1
(short-term AND (forecast OR forecasting)) AND "power output" AND (ground AND (data OR sensors OR measurements OR image))	102	8	8
(short-term AND (forecast OR forecasting)) AND "power output" AND ("ground-based" OR data)	43	6	5
(short-term AND (prediction OR generation)) AND (PV OR photovoltaic) AND (ground AND (data OR sensors OR measurements OR image))	437	30	41
(short-term AND (prediction OR generation)) AND (PV OR photovoltaic) AND ("ground-based" OR data)	136	14	17
(short-term AND (prediction OR generation)) AND ("solar radiation" AND photovoltaic) AND (ground AND (data OR sensors OR measurements OR image))	245	10	12
(short-term AND (prediction OR generation)) AND ("solar radiation" AND photovoltaic) AND ("ground-based" OR data)	103	4	2
(short-term AND (prediction OR generation)) AND "**power** output" AND (ground AND (data OR sensors OR measurements OR image))	152	8	10
(short-term AND (prediction OR generation)) AND "power output" AND ("ground-based" OR data)	46	7	7
Total de artigos	2049	136	164
Banco Bruto de Artigo (BBA)		**2349**	

Fonte: O autor, (2022).

Durante o andamento do processo de revisão foram executadas as seguintes ações definidas pelo método Proknow-C: i) Remoção de artigos duplicados; ii) Leitura de títulos e remoção de artigos com títulos desalinhados ao tema; iii) Levantamento da relevância bibliográfica dos principais artigos por meio de consulta do número de citações no site Google Acadêmico em 05/09/2022; e iv) Leitura de resumos dos artigos classificados por ordem de relevância acadêmica, sendo removidos os artigos desalinhados ao tema.

A execução das ações foi realizada com o auxílio da ferramenta de gestão de referências bibliográficas Mendeley (ELSEVIER, 2019). Ao término de todas as etapas do Proknow-C obteve-se um Portfólio Bibliográfico (PB) compreendendo os 30 artigos mais citados, relevantes e recentes à PGESF durante o período de 2009 a 2022. O PB está detalhado e ordenado pelo número de citações na Tabela 2. Convém destacar que o PB foi periodicamente atualizado e constitui o referencial bibliográfico desta pesquisa.

Tabela 2 – Portfólio Bibliográfico ordenado por citações em 05/09/2022.

Os 30 Artigos Mais Relevantes do Portfólio Bibliográfico (PB) segundo o Google Acadêmico	Citações
1. Chow, Chi Wai, Bryan Urquhart, Matt Lave, and Jan Kleissl. 2011. "Intra-Hour Forecasting with a Total Sky Imager at the UC San Diego Solar Energy Testbed." Pp. 248–56 in 40th ASES National Solar Conference.	624
2. Marquez, Ricardo and Carlos F. M. Coimbra. 2013. "Intra-Hour DNI Forecasting Based on Cloud Tracking Image Analysis." Solar Energy 91:327–36.	388
3. Yang, Dazhi, Panida Jirutitijaroen, and Wilfred M. Walsh. 2012. "Hourly Solar Irradiance Time Series Forecasting Using Cloud Cover Index." Solar Energy 86(12):3531–43.	231
4. Chu, Yinghao, Bryan Urquhart, Seyyed M. I. Gohari, Hugo T. C. Pedro, Jan Kleissl, and Carlos F. M. Coimbra. 2015. "Short-Term Reforecasting of Power Output from a 48 MWe Solar PV Plant." Solar Energy 112:68–77.	219
5. Aguiar, L. Mazorra, B. Pereira, P. Lauret, F. Díaz, and M. David. 2016. "Combining Solar Irradiance Measurements, Satellite-Derived Data and a Numerical Weather Prediction Model to Improve Intra-Day Solar Forecasting." Renewable Energy 97:599–610.	131
6. Huang, Chiou Jye and Ping Huan Kuo. 2019. "Multiple-Input Deep Convolutional Neural Network Model for Short-Term Photovoltaic Power Forecasting." IEEE Access 7:74822–34.	131
7. Dazhi Y, Vishal Sharma, Zhen Ye, Lihong Idris Lim, Lu Zhao, and Aloysius W. Aryaputera. 2015. "Forecasting of Global Horizontal Irradiance by Exponential Smoothing, Using Decompositions." Energy 81:111–19.	120
8. Zhang, Jinsong, Rodrigo Verschae, Shohei Nobuhara, and Jean François Lalonde. 2018. "Deep Photovoltaic Nowcasting." Solar Energy 176(October):267–76.	100
9. Cococcioni, Marco, Eleonora D'Andrea, and Beatrice Lazzerini. 2011. "24-Hour-Ahead Forecasting of Energy Production in Solar PV Systems." Pp. 1276–81 in International Conference on Intelligent Systems Design and Applications, ISDA. Dipartimento di Ingegneria dell'Informazione: Elettronica, Informatica, Telecomunicazioni, University of Pisa, 1, 56122 Pisa, Italy.	85
10. Schmidt, Thomas, John Kalisch, Elke Lorenz, and Detlev HeinemRNA. 2016. "Evaluating the Spatiooral Performance of Sky-Imager-Based Solar Irradiance Analysis and Forecasts." Atmospheric Chemistry and Physics 16(5):3399–3412.	83
11. Elsinga, Boudewijn and Wilfried G. J. H. M. van Sark. 2017. "Short-Term Peer-to-Peer Solar Forecasting in a Network of Photovoltaic Systems." Applied Energy 206:1464–83.	70
12. Li, DRNAy H. W., Wenqiang Chen, Shuyang Li, and Siwei Lou. 2019. "Estimation of Hourly Global Solar Radiation Using Multivariate Adaptive Regression Spline (MARS) – A Case Study of Hong Kong." Energy.	51
13. Wen, H., Du, Y., Chen, X., Lim, E., Wen, H., Jiang, L., Xiang, W. (2021). Deep Learning Based Multistep Solar Forecasting for PV Ramp-Rate Control Using Sky Images. IEEE Transactions on Industrial Informatics, 17(2), 1397–1406.	51
14. Nobre, André M., Carlos A. Severiano, Shravan Karthik, Marek Kubis, Lu Zhao, Fernando R. Martins, Enio B. Pereira, Ricardo Rüther, and Thomas Reindl. 2016. "PV Power Conversion and Short-Term Forecasting in a Tropical, Densely-Built Environment in Singapore." Renewable Energy 94:496–509.	43
15. Bone, Viv, John Pidgeon, Michael Kearney, and Ananthanarayanan Veeraragavan. 2018. "Intra-Hour Direct Normal Irradiance Forecasting through Adaptive Clear-Sky Modelling and Cloud Tracking." Solar Energy 159:852–67.	39
16. Voyant, Cyril, Fabrice Motte, Gilles Notton, Alexis Fouilloy, Marie Laure Nivet, and Jean Laurent Duchaud. 2018. "Prediction Intervals for Global Solar Irradiation Forecasting Using Regression Trees Methods." Renewable Energy 126:332–40.	38
17. Cheng, Hsu Yung and Chih Lung Lin. 2017. "Cloud Detection in All-Sky Images via Multi-Scale Neighborhood Features and Multiple Supervised Learning Techniques." Atmospheric Measurement Techniques 10(1):199–208.	34
18. Xie, Tuo, Gang Zhang, Hongchi Liu, Fuchao Liu, and Peidong Du. 2018. "A Hybrid Forecasting Method for Solar Output Power Based on Variational Mode Decomposition, Deep Belief Networks and Auto-Regressive Moving Average." Applied Sciences (Switzerland) 8(10).	34

19. Melzi, Fateh Nassim, Taieb Touati, Allou Same, and Latifa Oukhellou. 2017. "Hourly Solar Irradiance Forecasting Based on Machine Learning Models." Pp. 441–46 in Proceedings - 2016 15th IEEE International Conference on Machine Learning and Applications, ICMLA 2016. IRT SystemX, Palaiseau, 92400, France: Institute of Electrical and Electronics Engineers Inc.	31
20. Jayadevan, Vijai Thottathil, Jeffrey J. Rodriguez, Vincent P. A. Lonij, and Alexander D. Cronin. 2012. "Forecasting Solar Power Intermittency Using Ground-Based Cloud Imaging." Pp. 2100–2106 in World Renewable Energy Forum, WREF 2012, Vol. 3. Department of Electrical and Computer Engineering, University of Arizona, Tucson, AZ 85721, United States.	28
21. Hu, Keyong, Shihua Cao, Lidong Wang, Wenjuan Li, and Mingqi Lv. 2018. "A New Ultra-Short-Term Photovoltaic Power Prediction Model Based on Ground-Based Cloud Images." Journal of Cleaner Production 200:731–45.	25
22. Voyant, Cyril, Jan G. De Gooijer, and Gilles Notton. 2018. "Periodic Autoregressive Forecasting of Global Solar Irradiation without Knowledge-Based Model Implementation." Solar Energy 174:121–29.	16
23. Paletta, Q., Arbod, G., Lasenby, J. (2021). Benchmarking of deep learning irradiance forecasting models from sky images – An in-depth analysis. Solar Energy, 224(January), 855–867.	14
24. Abuella, Mohamed and Badrul Chowdhury. 2018. "Improving Combined Solar Power Forecasts Using Estimated Ramp Rates: Data-Driven Postprocessing Approach." IET Renewable Power Generation 12(10):1127–37.	12
25. Rajagukguk, R. A., Kamil, R., Lee, H.-J. (2021). A Deep Learning Model to Forecast Solar Irradiance Using a Sky Camera. Applied Sciences, 11(11), 5049.	11
26. Sreekumar, Sreenu, Ayushi Gupta, Sushila, Varun Agarwal, and Rohit Bhakar. 2017. "Matrix Based Univariate and Multivariate Linear Similar Day Approach towards Short Term Solar Radiation Forecasting." in 2016 National Power Systems Conference, NPSC 2016. Electrical Engineering Department, Malaviya National Institute of Technology, Jaipur, 302017, India: Institute of Electrical and Electronics Engineers Inc.	7
27. Du, Peidong, Gang Zhang, Pingli Li, Meng Li, Hongchi Liu, and Jinwang Hou. 2019. "The Photovoltaic Output Prediction Based on Variational Mode Decomposition and Maximum Relevance Minimum Redundancy." Applied Sciences 9(17):3593.	7
28. Yang, H., Wang, L., Huang, C., Luo, X. (2021). 3d-cnn-based sky image feature extraction for short-term global horizontal irradiance forecasting. Water (Switzerland), 13(13).	4
29. Moughyt, Salah, Youssef Zaz, Samia Fathi, and Omar El Kadmiri. 2017. "Sky Status: A Local Analysis of Ground Based Digital Images." Pp. 667–70 in International Conference on Multimedia Computing and Systems -Proceedings. Electronics and Microwave Group, Faculty of Science, Abdelemalek Essaidi University, Tetouan, Morocco: IEEE Computer Society.	3
30. Xiao, C., Chen Z., Ding Y., Zhou H., Ding Jie. 2012. "Study on Very Short-Term Solar Irradiance Forecasting Methods Using Ground Based Cloud Image." Pp. 174–79 in AASRI Procedia. Vol. 2.	2

Fonte: O autor, (2022).

Durante a construção do PB constatou-se uma quantidade elevada de publicações científicas relativas a métodos de predição de geração de energia fotovoltaica na literatura internacional (KUMAR et al., 2020; YANG et al., 2018), assim como o aumento acentuado de publicações a partir de 2017 (MACIEL; LEDESMA; ANDO JUNIOR, 2021). A Figura 1 exibe o perfil histórico do número de publicações (esquerda) e citações (direita) de dois estudos de revisão científica da PGESF recentes, os quais demonstram um cenário crescente e contínuo de aumento das publicações sobre o tema, fato que demonstra sua importância e relevância para o cenário global atual. Portanto, as pesquisas cientificas mais citadas e/ou relevantes à PGESF, de curto prazo, no PB são descritas a seguir.

Figura 1 – Histórico do crescimento de publicações científicas sobre a PGESF.

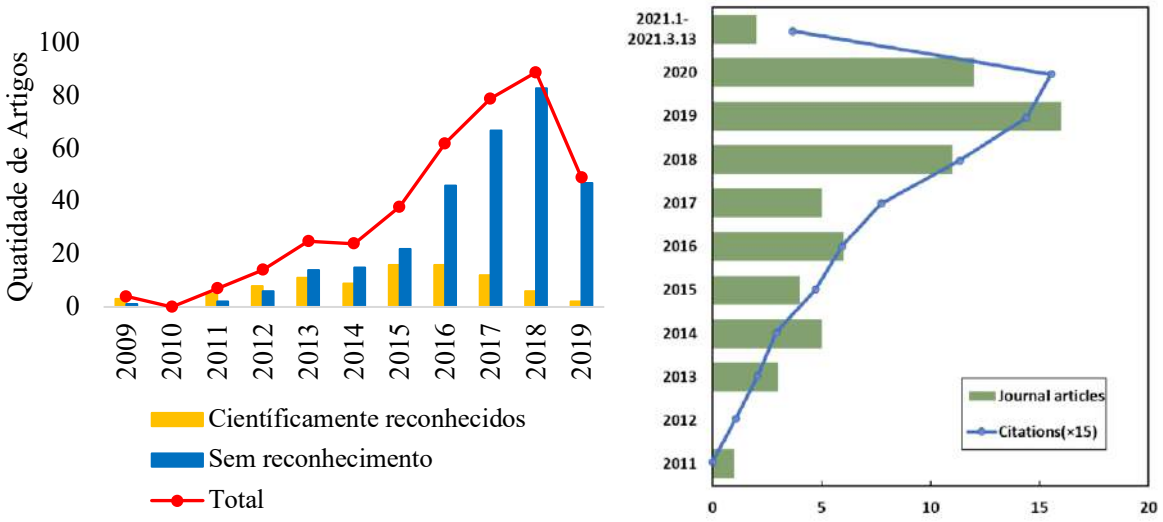

Fonte: Esquerda: Adaptado de (MACIEL; LEDESMA; ANDO JUNIOR, 2021); Direita: Adaptado de (LIN; ZHANG; WANG, 2022).

Em 2011 (CHOW et al., 2011b) propuseram um método para a predição de geração de energia fotovoltaica de curto prazo (*intra-hour*) utilizando técnicas de processamentos de imagens, capturadas a partir de uma câmera local apontada ao céu (*all-sky*), conjuntamente com dados de uma rede de sensores de irradiância solar abrangendo uma área de 4 Km^2. Outra abordagem para predição de um dia a frente (*day-ahead*) utilizou Redes Neurais Artificiais (RNA) Multicamada com Series Temporais (ST) foi publicada por (COCOCCIONI; D'ANDREA; LAZZERINI, 2012). O objetivo foi desenvolver uma ferramenta para possibilitar que técnicos de instalação de painéis solares configurassem o ambiente do sistema fotovoltaico com base nas características particulares de cada sistema.

Na pesquisa (DAZHI; PANIDA; M., 2012) foram analisadas ST para predizer a irradiância solar durante a próxima hora. Três métodos foram propostos utilizando o modelo analítico *Auto-Regressive Integrated Moving Average* (ARIMA) com diferentes dados de entradas (*inputs*). O modelo proposto dispensa o uso de medidas de irradiância solar e empregou ST relativas à cobertura das nuvens. Em outra abordagem as imagens foram capturadas por uma câmera, com ângulo de abertura de 160° e apontada para ao céu. Processamento de imagens e cálculos analíticos foram empregados na detecção de projeções das nuvens (XIAO et al., 2012). Em outro estudo os autores propuseram e analisaram um método de predição baseado em informações de satélite, concluindo posteriormente que devido à natureza dos eventos relacionados as nuvens, os métodos que utilizam informações

meteorológicas e imagens de satélites não são adequados ou suficientes para predições de curto prazo (JAYADEVAN et al., 2012).

A avaliação de um modelo proposto para predizer a irradiância solar em curto prazo, de 3 a 15 minutos, utilizando processamento de imagens capturadas por uma câmera apontada ao céu é descrita em (MARQUEZ; COIMBRA, 2013). Nela, observou-se que uma das principais fragilidades dos métodos de predições baseados em imagens das nuvens no céu é supor a existência nuvens únicas e estacionárias, mas que, todavia, isso pode ser contornado com sistemas de fotos com maior resolução e fotografias em profundidade.

Uma pesquisa que aplicou AM com Programação Genética, RNA e o algoritmo de aprendizado supervisionado *K-Nearest Neighbor* (k-NN) foi publicada em (CHU et al., 2015). A solução proposta permitiu realizar a re-predição de curto prazo (*intra-hour*) para 5, 10 e 15 minutos, com maior precisão que os trabalhos anteriores. Já o método proposto por (NOBRE et al., 2016) utilizou a combinação de informações de diversas estações meteorológicas para efetuar a predição da geração de energia solar PV de curto prazo (HRT < 30 minutos). Nesta mesma linha foi publicada outra pesquisa com dados de irradiância solar, coletados por uma rede de 99 sensores espalhados em uma área de 10x12 Km^2, no qual propuseram um método híbrido com técnicas de processamento de imagens e análise de ST para predição de curto prazo (HRT < 25 minutos) atualizado a cada 15 segundos (SCHMIDT et al., 2016a).

O método *Peer-to-Peer* (P2P) foi proposto para a predição de curto prazo (HRT de 5 a 8 minutos), sendo baseado na correlação de Séries Temporais relativas ao Índice de Claridade do Céu, capturadas a partir de pares de usinas fotovoltaicas e utilizando uma rede de sensores. Os resultados mostraram maior acurácia do modelo proposto para dias com maior variabilidade no período de predição (ELSINGA; VAN SARK, 2017).

A análise literária de trabalhos mais recentes e relativos à predição da geração de energia fotovoltaica de curto prazo (HRT < 24 horas) apresenta muitas pesquisas aplicando técnicas de AM com resultados evoluindo ao logo do tempo em termos de precisão (BLAGA et al., 2019). Um estudo que desenvolveu um modelo híbrido para a predição da irradiância solar diária é descrito em (MELZI et al., 2017). Nesse modelo utilizou como ideia básica à similaridade de geração de energia entre dias tendo o mesmo número de horas solares (*sunshine*) a partir da análise de uma base histórica de 12 anos de irradiância solar. Foram aplicados os seguintes métodos de AM: *Similarity Method* (SIM), *Support Vector Machine*

(SVM) e Redes Neurais Artificiais (RNA) o algoritmo *Autoregressive Moving Average Model* (ARMA) e para análise das ST. Os resultados mais precisos foram obtidos em dias ensolarados com céu claro (MELZI et al., 2017).

Uma recente pesquisa foi apresentada para predição da irradiância solar direta normal (DNI) utilizando imagens locais de uma câmera com imagem total do céu (*all-sky*) em conjunto com sensores de radiação e análise dos movimentos das nuvens (BONE et al., 2018). Os autores descobriram que a acurácia total de predição da irradiância direta normal (DNI) é estatisticamente similar a *benchmarks* de persistência aceitos para predição de curto prazo. A latência da coleta dos dados para a predição é menor que 30 segundos, tornando o método adequado para aplicações de tempo real. Todavia, modelo tem a limitação de não prever o movimento das nuvens em várias direções, nova formação ou dissolução, e a radiação não é prevista em locais distante da câmera (BONE et al., 2018).

Outro método semelhante que empregou câmera *all-sky* para captura de imagens do céu na predição de curto prazo (HRT < 5 minutos) utilizando um o método *Radial Basis Function* (RFB) (HU et al., 2018a). O RFB é composto de três etapas: a) predição da trajetória da nuvem que protege o sol por meio de vetor processamento de imagens para cálculo do vetor de deslocamento; b) extração das características da nuvem por meio de processamento de imagens; e, c) aplicação do modelo RFB que consistiu em uma RNA para realizar a predição. O resultado foi comparado ao modelo *Auto Regressive* (AR) que demonstrou erro de 13,6% enquanto que o RFB exibiu 7,4% de erro, obtendo melhor acurácia especialmente em clima cheio de nuvens (HU et al., 2018a).

Umas das propostas pioneiras a empregar o Aprendizado Conjunto (*Ensemble Learning* – EL) do AM é apresentado na pesquisa (VOYANT; DE GOOIJER; NOTTON, 2018), em que realizaram a predição de curto prazo (HRT de 1 a 6 horas) propondo um método chamado *Periodic AutoRegressive* (PAR). Esse modelo PAR destina-se a Séries Temporais (ST) periódicas e não é restrito a ST estacionárias. Ou seja, não necessita de base de conhecimento histórica para treinamento e os resultados demonstram melhor acurácia que os modelos baseados na irradiância solar utilizando RNA (VOYANT; DE GOOIJER; NOTTON, 2018). Segundo os autores, o modelo é especialmente recomendado como ferramenta de previsão em novas instalações de usinas fotovoltaicas com clima desconhecido. O mesmo autor desenvolveu outro modelo para o mesmo HRT (de 1 a 6 horas)

utilizando modelos de persistência probabilísticos e analisaram quatro métodos de AM baseados em Arvores de Regressão (VOYANT et al., 2018).

Também utilizando técnicas de Aprendizado Conjunto (EL), um método para predição horária, incluindo o próximo dia, foi desenvolvido e avaliado em (ABUELLA; CHOWDHURY, 2018). Nessa proposta foram aplicados os algoritmos de *Multiple Linear Regression Model* (MLR), Rede Neural Artificial (RNA), *Support Vector Regression* (SVR) e *Random Forest* (RF). A contribuição do trabalho consistiu em desenvolver uma abordagem de pós-processamento para melhorar as previsões combinadas, hora a hora, superando a questão dos eventos de rampa em que a produção de energia P no tempo t é positiva $P(t+1) > P(t)$ ou negativa $P(t+1) < P(t)$, exibidas pelas abordagens de modelos estatísticos (ABUELLA; CHOWDHURY, 2018).

Outra pesquisa publicada por (ZHANG et al., 2018b) propôs e analisou a aplicação dos modelos híbridos de Redes Neurais Artificiais (RNA), Redes Neurais Convolucionais (*Convolutional Neural Network* - CNN) e redes *Long Term-Short Memory* (LTSM) na predição de curto prazo (1 a 10 minutos). Os resultados demonstraram que a rede com maior acurácia de predição, dentre as três redes analisadas, foi o modelo baseado em LSTM que pôde aprender as dependências temporais dos dados.

Um modelo híbrido de predição a curto prazo (HRT < 15 minutos) e que aplicou conjuntamente os métodos *Variational Mode Decomposition* (VMD), DBM e ARMA foi apresentado em (XIE et al., 2018). A abordagem proposta decompôs as Séries Temporais (ST) de dados históricos em um conjunto de componentes com diferentes frequências altas (predição com DBN) e frequências baixas (predição com ARMA). O modelo VMD-ARMA-DBN foi comparado com os respectivos modelos simples e obteve melhor acurácia, menores distribuição de erro absoluto e mediana do erro (XIE et al., 2018).

Com base no método proposto por (XIE et al., 2018), outra pesquisa utilizou o método VMD agregando a característica de Máxima Relevância e Mínima Redundância (mRMR) com DBN (DU et al., 2019). O método VMD determina as principais características de cada componente modal da saída fotovoltaica por mRMR. Primeiro é estabelecida uma matriz de características brutas, composta pelo tempo, temperatura, estação, intensidade de radiação e valores históricos da produção fotovoltaica. O modelo DBN é usado para ajustar os componentes modais e seus fatores característicos, e então, os resultados previstos de cada componente modal são sobrepostos para se obter o valor da

predição da saída fotovoltaica. Os resultados demonstraram maior acurácia no método proposto (DU et al., 2019).

O estudo de (LEE; KIM, 2019) aplicou e comparou a acurácia de predição dos algoritmos ARIMA, RNA, CNN e LTSM para predições com HRT horário e diário, empregando informações meteorológicas e características da estação foi publicada por (LEE; KIM, 2019). As entradas dos modelos são a temperatura, umidade, nebulosidade, irradiância solar, mês, ano e estação, utilizadas na estimativa direta da produção de energia fotovoltaica. Constatou-se que os modelo LTSM proposto apresentou melhor acurácia dentre os analisados, principalmente nos dias com grande variabilidade de geração de energia fotovoltaica. Além disso, os modelos de previsão de energia fotovoltaica existentes e baseados em RNA e CNN requerem informações adicionais, como informações sobre condições climáticas que não estão disponíveis em muitos locais.

O modelo proposto por (HUANG; KUO, 2019) é uma rede CNN denominada PVPNet, composta de múltiplas entradas relativas aos últimos aos últimos cinco dias (temperatura, irradiância solar e potencial de geração) e faz a predição de curto prazo (HRT de até 24 horas) do potencial de geração. Os autores compararam a acurácia do modelo PVPNet com diversos trabalhos descritos em (DAS et al., 2018) considerando igual HRT e constataram maior precisão com menores MAE e RMSE. Outra pesquisa recente propôs realizar a predição da irradiância solar global (GHI) horária por meio do método *Multivariate Adaptive Regression Spline* (MARS), sendo utilizada uma base histórica com informações do período de 7 anos. Foram utilizados métodos de regressão e RNA treinados e avaliados considerando diferentes variáveis climáticas de entrada. Os modelos MARS propostos demonstraram bom desempenho, acurácia e interpretabilidade, podendo ser aplicados a diferentes combinações de variáveis de climáticas (LI et al., 2019a).

Umas das mais recentes e emergentes abordagens do AM é o Aprendizado Profundo ou *Deep Learning* (DL). Principalmente a partir do ano de 2017, diversas pesquisas estão aplicando DL por meio de *Convolutional Neural Networks* (CNN), *Long Short-Term Memory Networks* (LTSM) e *Deep Belief Networks* (DBN), no campo da predição do da geração de energia solar fotovoltaica. Exemplos destes estudos propostos podem ser consultados em (DEFRAIGNE, 2017; DU et al., 2019; GENSLER et al., 2017; HUANG; KUO, 2019; HUSEIN; CHUNG, 2019; LAGO et al., 2018; LI et al., 2017, 2020; OGAWA; MORI, 2019; OSPINA; NEWAZ; OMAR FARUQUE, 2019; RAJAGUKGUK; KAMIL;

LEE, 2021; SABRI; EL HASSOUNI, 2022; SIDDIQUI; BHARADWAJ; KALYANARAMAN, 2019; SRIVASTAVA; TIWARI; GIRI, 2018; WEN et al., 2021; WOIWODE et al., 2018; ZHANG et al., 2018b; ZHEN et al., 2022).

Uma pesquisa recente publicada por (RAJAGUKGUK; KAMIL; LEE, 2021) desenvolveu e avaliou um modelo híbrido de predição aplicando técnicas de processamento de imagens e Aprendizado Profundo com redes LSTM na predição de curto prazo (1 a 10 minutos). Além das imagens do céu, o modelo utilizou um índice de céu limpo (*Clear Sky Index*) disponível no *dataset* utilizado. Os resultados demonstraram acurácia superior ao modelo de referência em dias parcialmente (25,1%) e completamente nublados (39,9%).

O estudo de (WEN et al., 2021) foi o pioneiro a aplicar as redes neurais convolucionais (CNN) na PGESF de curto prazo. Utilizando uma técnica de empilhamento de imagens e controle de rampa da potência gerada, a proposta de Wen et al. (2021), demonstrou acurácia 17,7% superior ao modelo de referência. A partir disto, diversos estudos baseados em Aprendizado Profundo na PGESF foram desenvolvidos (CARNEIRO et al., 2022b; JUNCKLAUS MARTINS et al., 2022; KUMARI; TOSHNIWAL, 2021; MASSAOUDI et al., 2021; RAJAGUKGUK; RAMADHAN; LEE, 2020), com destaque para ao estudo recente que originou um novo *dataset* (SKIPP'D) construído para a PGESF, sendo disponibilizado conjuntamente com um modelo de *benchmarking* de Aprendizado Profundo baseado em CNN (NIE et al., 2022).

Historicamente, poucos estudos sobre a PGESF foram realizados na América Latina, em especial no Brasil, ou por pesquisadores destes países latino-americanos (BLAGA et al., 2019; MACIEL; LEDESMA; ANDO JUNIOR, 2021). Nesse sentido, a Figura 2 ilustra um panorama cronológico das publicações identificadas na América Latina, nas quais as referências com cor laranja são publicações relacionadas ao presente estudo. Embora tenham sido identificadas 18 publicações, somente 6 (seis) ou 33% apresenta a proposição de novos modelos de predição da geração de energia solar fotovoltaica (Tabela 3). As demais abordam o tema indiretamente com estudos relacionados à irradiância solar, informações meteorológicas, análise da geração fotovoltaica ou desenvolvimento de dispositivos de captura de dados.

Figura 2 – Linha do tempo dos principais estudos científicos da PGESF por continente.

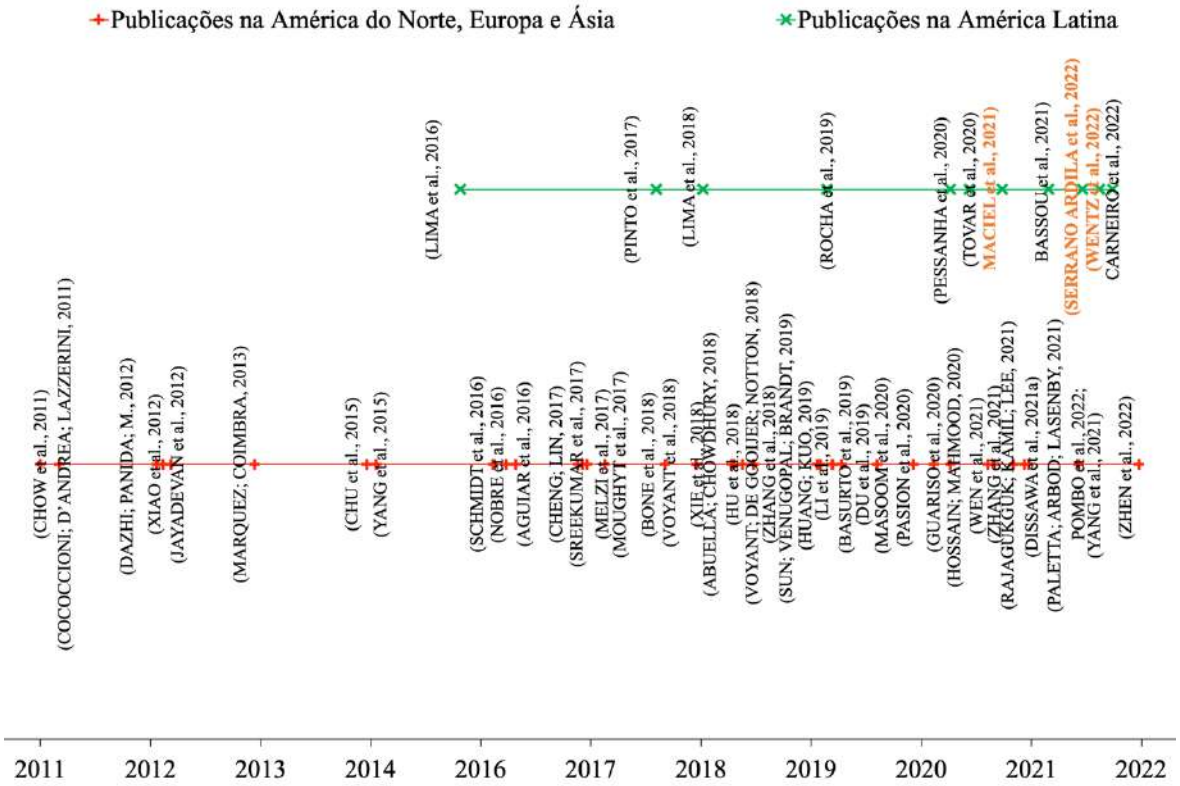

Fonte: O autor, (2022).

O primeiro estudo na América Latina foi publicado em 2016 (LIMA et al., 2016), enquanto que nos outros continentes existem pesquisas desde antes de 2011. É importante destacar ainda que o PB (Tabela 2) contempla as 30 publicações mais relevantes e citadas da literatura da PGESF, sendo que o número real absoluto de publicações neste tema é bastante superior (MACIEL; LEDESMA; ANDO JUNIOR, 2021).

Recentemente, o estudo de (BASSOUS; CALILI; BARBOSA, 2021) desenvolveu um dispositivo de *hardware* para captura de dados para a PGESF. Apesar da pouca quantidade em relação ao cenário internacional, algumas pesquisas têm proposto e avaliado novos métodos e algoritmos na PGESF. Em geral, estes estudos empregam informações meteorológicas e/ ou irradiância solar nas predições. A Tabela 3 exibe tais pesquisas e sugere que, até o momento, os métodos para a PGESF são pouco explorados nos países latino-americanos, demonstrando assim a relevância do presente estudo.

Tabela 3 – Publicações relacionadas a PGESF de curto prazo na América Latina.

#	Referência	Resumo do Objetivo da Publicação	Método de PGESF?
1	(LIMA et al., 2016)	Proposição de uma metodologia para produzir predições de irradiância solar na região Nordeste do Brasil com Redes Neurais Artificiais.	Sim
2	(MONTEIRO et al., 2017)	Avaliação de sete algoritmos usados em Redes Neurais Artificiais para geração de estimar a potência ativa e o estado da rede de distribuição em que os micros geradores estão conectados.	Não
3	(PINTO et al., 2017)	Proposição de uma abordagem híbrida para predição de irradiância solar de curto prazo combinando algoritmos de agrupamento, Redes Neurais Artificiais (RNA) e Máquina de Vetores de Suporte (SVM).	Sim
4	(ALMEIDA et al., 2017)	Avaliação do cálculo da energia entregue a grade de geração no horizonte de uma hora à frente utilizando como entrada variáveis meteorológicas de modelos *Numerical Weather Prediction* (NWP)	Não
5	(INACIO; BORGES, 2018)	Geração de series temporais sintéticas de irradiância solar de curto prazo considerando dados de diversos locais do Brasil.	Não
6	(LUIZ et al., 2018)	Revisão das análises da variabilidade da irradiância solar em diferentes zonas climáticas no Brasil.	Não
7	(LIMA et al., 2018)	Avaliação de Redes Neurais Artificiais (RNA) na predição da irradiância solar com dados coletados em Fortaleza-CE, no Brasil.	Não
8	(SOARES; LIMA; MARTINS, 2019)	Proposição de uma metodologia baseada em Cadeias de Markov para gerar series temporais de irradiância solar avaliada com dados meteorológicos do Brasil.	Não
9	(ROCHA et al., 2019)	Avaliação de um modelo de RNA treinado com 14 anos de informações meteorológicas de Fortaleza-CE, no Brasil, para realizar predições mensais de irradiância solar.	Não
10	(NASCIMENTO et al., 2020)	Comparação do desempenho e perfil de geração de painéis solares fotovoltaicos em distintas regiões do Brasil.	Não
11	(LIMA et al., 2020)	Comparação da irradiância solar em com dados adquiridos em 41 estações meteorológicas do INMET no Brasil.	Não
12	(PESSANHA et al., 2020)	Proposição de uma nova metodologia utilizando técnicas estatísticas, algoritmos de mineração de dados e reanálise, para o tratamento de medições horárias de GHI e geração de energia solar.	Sim
13	(TOVAR; ROBLES; RASHID, 2020)	Proposição de um método de predição usando Aprendizado Profundo com dados reais capturados em Temixco, no México.	Sim
14	(MACIEL et al., 2021)	Avaliações de modelos Aprendizado de Máquina (AM) com RNA e distintas informações meteorológicas aplicados a predição de curto prazo da irradiância solar global (GHI).	Não
15	(BASSOUS; CALILI; BARBOSA, 2021)	Proposição de um dispositivo de baixo custo para captura de imagens e dados úteis na PGESF no Brasil.	Não
16	(SERRANO ARDILA et al., 2022)	Proposição de uma nova metodologia baseada em Lógica Difusa para predição da GHI e geração KWh de curto prazo com dados do Brasil.	Sim
17	(WENTZ et al., 2022)	Avaliação comparativa de modelos de Aprendizado de Máquina (RNA) e Aprendizado Profundo (LSTM).	Não
18	(CARNEIRO et al., 2022a)	Proposição de um novo modelo de Aprendizado Combinado (*Ensemble Learning*) aplicado em dados da Espanha e Brasil.	Sim

Fonte: O autor, (2022).

Esta seção apresentou uma revisão acadêmica científica das principais pesquisas relacionadas ao tema PGESF no cenário mundial e na América Latina. De modo geral é possível descrever as seguintes e principais observações:

a) Existem poucas pesquisas sobre o tema desenvolvidas ou aplicadas na América Latina (MACIEL; LEDESMA; ANDO JUNIOR, 2021);

b) Embora os modelos estatísticos clássicos foram amplamente utilizados no início dos estudos da PGESF, o avanço tecnológico ampliou o uso de estudos com Aprendizado de Máquina e Aprendizado Profundo da Inteligência Artificial;

c) A precisão dos modelos de predição tem evoluído ao longo tempo, principalmente com o uso de técnicas de Aprendizado de Máquina (BLAGA et al., 2019) e, mais recentemente, Aprendizado Profundo com o uso de imagens totais do céu (*all-sky*) (JUNCKLAUS MARTINS et al., 2022; LIN; ZHANG; WANG, 2022);

d) As imagens *all-sky* contém informações relevantes e suficientes para a PGESF de curto prazo;

e) A maior parte das pesquisas identificadas utiliza informações históricas meteorológicas ou de irradiância solar, as quais são coletadas com dispositivos e sensores específicos, como, por exemplo, estações meteorológicas e/ou piranômetros (DE FREITAS VISCONDI; ALVES-SOUZA, 2019), exigindo *hardware* adicional para o sistema de predição. Estes dispositivos e sensores adicionais geram novos custos para a implantação e operação dos sistemas de PGESF de curto prazo.

f) Recentemente, o uso somente de imagens do céu (*all-sky*) na PGESF, essencialmente de curto prazo, cresceu de modo acentuado devido ao avanço na capacidade de processamento computacional (JUNCKLAUS MARTINS et al., 2022);

g) Os modelos de predição híbridos têm demonstrado precisões superiores àqueles únicos ou básicos de AM que, em geral, possuem limitações específicas (KUMARI; TOSHNIWAL, 2021);

h) As métricas de avaliação das predições mais usadas na PGESF são o RMSE e MAE, (JUNCKLAUS MARTINS et al., 2022; YANG et al., 2018);

A revisão científica realizada possibilitou compreender o estado da arte acadêmica da PGESF, proporcionando um caminho que culminou na proposição de um Método Híbrido

de Predição (MHP) para múltiplos horizontes de curto prazo utilizando imagens do céu (*all-sky*).

2.2. LITERATURA DE PROPRIEDADE INTELECTUAL

Esta seção apresenta o resultado do processo de busca, análise e descrição dos registros de patentes de propriedade intelectual internacionais e no Brasil. Tal atividade é estratégica para o planejamento do presente projeto de pesquisa, que visa o desenvolvimento uma solução com potencial de inovação do tipo incremental (TIDD, 2001) aplicável na PGESF de curto prazo.

Considerando a generalidade comumente empregada nos pedidos e registros de propriedade intelectual, afim de ampliar o escopo de proteção, esta seção descreve o processo de busca de anterioridade de patentes relativas a métodos, aparatos e sistemas concedidos internacionalmente e relacionados ao tema: "*predição de geração de energia solar fotovoltaica*".

A Tabela 4 apresenta as palavras-chave, bases de dados e resultados da busca de anterioridade de patentes realizada em 25/02/2021. Os 1803 registros correspondem a Base Bruta de Patentes (BBP) e foram importados para a ferramenta de gestão bibliográfica Mendeley. Em seguida foram removidos os registros duplicados e realizada a leitura dos títulos para remoção daqueles não alinhados ao tema.

Tabela 4 – Palavras-chave, bases de dados e resultados da busca de anterioridade.

Tema: Predição do potencial da geração de energia solar fotovoltaica					
Patentes	**Palavras-chave (PC)**	**Questel Orbit[1]**	**Google Patents[2]**	**Espacenet[3]**	**INPI[4]**
Resultados Brutos	(*prediction* OR *forecast* OR *nowcasting*) AND (*energy* OR *power* OR *output*) AND (*pv* OR *photovoltaic* OR *solar*) AND *generation*	2895	111877	137	0
Resultados Utilizados	(*prediction* OR *forecast* OR *nowcasting*) AND (*energy* OR *power* OR *output*) AND (*pv* OR *photovoltaic* OR *solar*) AND *generation*	666	1000	137	0
	Base Bruta Patentes (BBP)		**1803**		

[1] Selecionadas as 666 famílias de patentes depositadas em mais de um único país (https://www.orbit.com).
[2] Selecionadas as 1000 primeiras patentes por ordem decrescente de relevância no Google Patents (https://patents.google.com).
[3] Selecionadas todas as 137 patentes obtidas (https://lp.espacenet.com).
[4] Nenhum registro retornado mesmo com a tradução das palavras-chave para o Português (https://gru.inpi.gov.br/pePI/jsp/patentes/PatenteSearchBasico.jsp).

Fonte: O autor, (2021).

Deste processo foram selecionadas 155 patentes com títulos alinhados ao tema compondo o Portfólio Bruto de Patentes (PBP). Os países com maior número absoluto e percentual de registro dessas patentes do PBP são apresentados na

Figura 3. Destaca-se que 51 (56,6%) das 90 patentes chinesas correspondem as reivindicações de métodos computacionais (modelos persistentes, estatísticos, NWP, AM ou DP), ou variações destes, aplicados a predição de geração de energia fotovoltaica. Além disso, outra constatação relevante foi a inexistência de Patente de Invenção registradas na base do INPI. Talvez um dos motivos sejam que os investimentos no uso deste tipo de geração de energia renovável são recentes no Brasil.

Figura 3 – Portfólio Bruto de Patentes sobre a PGESF por país de concessão.

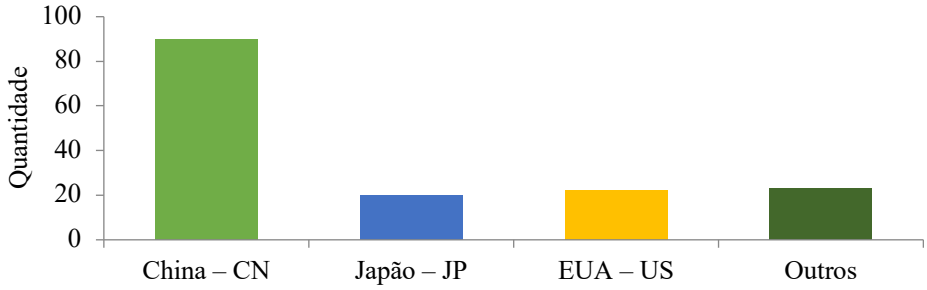

Fonte: O autor, (2021).

Após a leitura dos resumos das 155 patentes foram removidas aquelas não alinhadas ao tema ou reivindicações somente de métodos computacionais sem incluir dispositivos, *hardware*, sensores e ambiente empregado no processo de predição de geração de energia fotovoltaica. O resultado desse processo foi a obtenção de um Portfólio de Patentes de Invenção com 15 registros mais semelhantes e relevantes à pesquisa, cronologicamente listadas na Tabela 5 e detalhadas no decorrer da seção.

As invenções de (RETTGER et al., 2010; ROPP; HUMMEL, 2011) reivindicam métodos de operação de usinas fotovoltaicas, realizando tanto o controle de carga/descarga em cada unidade de produção, bem como a predição de geração por meio de dados meteorológicos e informações sobre as nuvens, sejam coletadas localmente (RETTGER et al., 2010) ou por sistemas de informação meteorológicos ou satélites (ROPP; HUMMEL, 2011). Outro método utiliza informações coletadas localmente ou remotamente, por satélite, e que realiza o processamento de séries temporais para predição da produção de diversos painéis fotovoltaicos é reivindicado por (HOFF, 2013).

A reivindicação feita por (HARTUNG et al., 2013) realiza a predição da irradiância solar com base nas características locais das nuvens. Para esse cálculo são capturadas uma ou mais imagens planas do céu por meio de uma câmera local com lente customizada para captura das imagens planares. Outro método reivindicado em (FENG et al., 2019) define um sistema predição de geração de energia solar para uma área abrangendo a região de uma usina fotovoltaica, empregando como entrada informações meteorológicas e realizando o balanceamento de produção e demanda.

Tabela 5 – Portfólio de Patentes de Invenção concedidas e relevantes ao tema PGESF.

#	Referência	Patente de Invenção
1	(RETTGER et al., 2010)	P. Rettger, M. Keshner, A. Katrina Pligavko, Jackson Moore, and B. W. LittmRNA, "Dynamic power prediction system for distributed photovoltaic power generation system," Patent **US 20100198420**, 2010.
2	(ROPP; HUMMEL, 2011)	M. Ropp and S. G. Hummel, "Systems and Methods for Forecasting Solar Power," Patent **US 20110282514-A1**, 2011.
3	(HOFF, 2013)	T. E. Hoff, "Computer-implemented system and method for generating a probabilistic forecast of photovoltaic fleet power generation," Patent **US 8437959-B2**, 2013.
4	(HARTUNG et al., 2013)	S. M. Hartung *et al.*, "Method and system for predicting cloud movement," Patent **EP 2645135-A1**, 2013.
5	(BING, 2015)	J. M. Bing, "Method and apparatus for forecasting solar radiation and solar power production using synthetic irradiance imaging," Patente **US 2015177415-A1**, 2015.
6	(DOMINGUEZ et al., 2015)	L. Dominguez, M. Mercangoez, A. Cortinovis, and B. Zeydan, "Solar Irradiance Forecasting," Patent **WO 2015104281-A1**, 2015.
7	(DREES, 2017)	K. H. Drees, "Photovoltaic energy system with solar intensity prediction," Patent **US 2017104449-A1**, 2017.
8	(ABEDINI et al., 2017)	M. Abedini, T. M. L. Rahil Garnavi, and C. I. E. M. J. M. Wagner, "Solar irradiation modeling and forecasting using community based terrestrial sky imaging," Patent **US 20170351970-A1**, 2017.
9	(CHANG et al., 2018)	T. C. Chang, J. Ernst, J. R. Wiles, J. Bamberger, and A. Szabo, "Short term cloud forecast, improved cloud recognition and prediction and uncertainty index estimation," Patent **WO-2018151782-A1**, 2018.
10	(PAVLOVSKI; ANICHKOV; KOSTYLEV, 2018)	A. Pavlovski, D. Anichkov, and V. Kostylev, "Method and system for solar power forecasting," Patent **US 20180275314-A1**, 2018.
11	(BIXEL, 2018)	P. S. Bixel, "Method for predicting and mitigating power fluctuations at a photovoltaic power plant due to cloud cover," Patent **US 10133245-B2**, 2018.
12	(FENG et al., 2019)	M. Feng *et al.*, "Forecasting solar power output," Patent **US 2019064392-A1**, 2019.
13	(HOFF, 2019a)	T. E. Hoff, "System and method for correlating point-to-point sky clearness for use in photovoltaic fleet output estimation with the aid of a digital computer," Patent **US 10436942**, 2019.
14	(HOFF, 2019b)	T. E. Hoff, "System and Method for Irradiance - Based Estimation of Photovoltaic Fleet Power Generation With the Aid of a Digital," Patent **US 20190170901-A1**, 2019.
15	(HOFF, 2020)	T. E. Hoff, "System And Method For Estimating Photovoltaic Energy Through Linearly Interpolated Clearness Indexes With The Aid Of A Digital Computer' Patent **US 2020025701-A1**

Fonte: O autor, (2021).

Em outra abordagem é definido um método de predição de curto prazo baseado na irradiância solar por meio do rastreamento de nuvens. Para isso são aplicadas técnicas de processamento de imagens em imagens coletadas por câmera do céu conjuntamente com dados meteorológicos, sendo aplicável a usinas fotovoltaicas (DOMINGUEZ et al., 2015). Já a patente proposta por (DREES, 2017) reivindica um sistema de conversão de energia solar em elétrica integrado a rede elétrica convencional. Descreve um ou mais sensores de irradiância solar que detectam a aproximação de nuvens e um controlador, cujo objetivo é predizer futuras alterações da intensidade de irradiância solar por meio de algoritmo de processamento de Séries Temporais.

Outro método realiza a predição da irradiância solar baseando-se em imagens terrestres para caracterizar as nuvens. Essas imagens são capturadas em diversos locais no solo e por distintos dispositivos, sendo então gerado um modelo de aprendizado de máquina (AM) que prediz a irradiância solar para uma determinada área geográfica, cuja saída um sinal representando a irradiância solar predita (ABEDINI et al., 2017). Já a proposta de (BING, 2015) define um método com rede de sensores de irradiância solar (piranômetros) para obter a irradiância solar associada a células específicas do painel fotovoltaico. Calcula-se então o valor global horizontal do modelo de céu claro de cada célula e a série temporal de cada minuto e dia, relativo ao potencial de geração.

Uma reivindicação aplicando técnicas de Aprendizado de Máquina (AM) para a predição de geração de energia solar para horizonte de predição em escala variável é descrita por (PAVLOVSKI; ANICHKOV; KOSTYLEV, 2018). No método são empregados dados históricos para treinamento de um modelo aprendizado de Inteligência Artificial realizada a predição de geração de energia solar determinando o índice de nebulosidade, a radiação global horizontal, localização e tipos das nuvens para gerar uma predição de geração em um display. Outra reivindicação proposta emprega também uma rede de sensores próximos ao painel fotovoltaico para coleta de informações referentes as nuvens para criar um modelo tridimensional (3D) representando dessas nuvens próximas é proposto em (BIXEL, 2018). O modelo 3D conjuntamente com informações da elevação e azimute do sol são empregados para criar uma projeção bidimensional (2D) da luz solar que incide sobre a Terra, permitindo predizer a intensidade da irradiância solar que atingirá os painéis fotovoltaicos.

Um sistema de predição de curto prazo que inclui a segmentação de nuvens por imagens capturada a partir de uma única câmera total do céu é reivindicado por (CHANG et

al., 2018). O modelo possui um processador de segmentação que calcula a probabilidade de cada *pixel* da imagem ser representativo de uma nuvem, juntamente com um peso dado pelo vetor de deslocamento da nuvem. Ambos representam a probabilidade de a nuvem ocluir o sol no futuro próximo. É definido ainda um processador probabilístico de incertezas que quantifica a acurácia das predições das nuvens combinando-a com o vetor de deslocamento e um índice de incerteza, produzindo assim a predição de curto prazo.

Três reivindicações propostas por Thomas E. Hoff e detalhadas em (HOFF, 2019b, 2019a, 2020), são relacionadas a métodos e dispositivos para a PGESF utilizando imagens de satélite. Em (HOFF, 2019b) é definido um sistema e método para cálculo da variância de uma matriz de coeficiente de correlação para um conjunto de painéis fotovoltaicos feita no espaço linear em função da diminuição da distância entre pares de usinas fotovoltaicas. A partir da obtenção da radiação por imagens de satélite, as estatísticas da radiação de uma área são convertidas em estatísticas de radiação para um ponto médio dentro em um *pixel* da imagem de satélite. As médias estatísticas dos pontos são calculadas para todos os *pixels* da imagem de satélite, determinando a média em toda a região do conjunto de usinas fotovoltaicas. Os coeficientes de correlação na matriz são efetivamente zero onde os pares de sistemas fotovoltaicos estão localizados muito longe um do outro. Por outro lado, a parte do somatório do cálculo é simplificada para eliminar valores zero com base na distância entre os locais dos sistemas fotovoltaicos, diminuindo o tamanho do espaço do problema.

Na mesma linha e ambiente do invento anterior reivindica-se um método que representa estatisticamente a estimação do PGESF ponto-a-ponto e a conversão área-a-ponto da irradiância solar em *pixels* de imagens de satélite (HOFF, 2019a). O método coleta medições de radiação e sobre as nuvens em dois locais dentro da área referente ao conjunto de painéis fotovoltaicos. A precisão relacionada a claridade do céu é delimitada pela avaliação de uma média e desvio padrão de medidas de radiação registradas e previstas. A claridade do céu nos dois locais é relacionada ao coeficiente de correlação obtido pela resolução de uma função exponencial empírica derivada da distância temporal. Cada índice de claridade previsto é multiplicado pelo coeficiente de correlação, formando um conjunto de saída com índices de claridade previstos, a média e o desvio padrão. Além disso, a precisão das imagens de satélite correlacionadas é limitada pela conversão da radiação coletiva em pontos de índices de nitidez. A média e o desvio padrão para o ponto do índice de nitidez é avaliado, sendo a média um conjunto do índice de claridade para a área

delimitada. Para cada ponto a variância do índice de claridade é determinada e a média e o desvio padrão calculada (HOFF, 2019a). Por fim, a reivindicação mais recente desta família descreve um sistema computacional que implementa os métodos anteriores (HOFF, 2020).

A partir das análises destas patentes um modelo de sistema para a PGESF, contemplando o MHP deste estudo, foi projetado e depositado sob a forma de patente de invenção junto ao Instituto Nacional de Propriedade Industrial (INPI) em 28/07/2020 (Registro N° BR 1020200153331) (MACIEL; LEDESMA; ANDO JUNIOR, 2020). A Tabela 6 exibe um resumo de características das patentes similares ao MHP proposto no Portfólio de Patentes.

Tabela 6 – Características dos métodos de PGESF existentes e da solução proposta.

Característica	**Solução Proposta**	(RETTGER et al., 2010)	(ROPP; HUMMEL, 2011)	(FENG et al., 2019)	(HARTUNG et al., 2013)	(HOFF, 2013)	(DOMINGUEZ et al., 2015)	(ABEDINI et al., 2017)	(DREES, 2017)	(BING, 2015)	(PAVLOVSKI; ANICHKOV; KOSTYLEV, 2018)	(BIXEL, 2018)	(HOFF, 2019b, 2019a)	(CHANG et al., 2018)
Usa dispositivo genérico e único de processamento?	✓	✗	✓	✗	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Usa somente uma câmera *all-sky* (180°)?	✓	✓	✗	✗	✗	✗	✗	✗	✗	✗	✗	✗	✗	✗
Usa somente imagem *all-sky* de entrada (*input*)?	✓	✗	✗	✗	✓	✗	✗	✗	✗	✗	✗	✗	✗	✓
Dispensa informações meteorológicas?	✓	✗	✗	✗	✓	✗	✗	✓	✗	✓	✗	✗	✓	✓
Dispensa informações de irradiância solar?	✓	✓	✓	✗	✓	✗	✗	✓	✗	✗	✓	✗	✓	✓
Dispensa dados ou imagens de satélites espaciais?	✓	✓	✗	✓	✓	✗	✓	✓	✓	✗	✓	✓	✗	✓
Predição em múltiplos horizontes de curto prazo?	✓	✗	✓	✓	✓	✓	✓	✓	✓	✓	✗	✓	✓	✓
Método Híbrido de Predição com PI e AM	✓	✗	✗	✗	✗	✗	✓	✓	✓	✗	✓	✗	✓	✗

Legenda: ✓ Contempla e ✗ Não contempla

Fonte: O autor, (2022).

Nota-se que embora existam propostas similares ao proposto MHP, em geral a maioria delas é desenvolvida especificamente para grandes usinas com diversos *arrays* de módulos fotovoltaicos, e assim, utilizam diversos sensores, tais como informações meteorológicas, irradiância solar ou imagens, em geral conectados em rede e geograficamente espalhados. Todas as patentes analisadas contemplam predições de curto

prazo. Por outro lado, as patentes mais similares ao MHP proposto (CHANG et al., 2018; HARTUNG et al., 2013), necessitam de sensores adicionais específicos, ou ainda duas ou mais câmeras para realizar as predições. Portanto, o pedido de patente elaborado e depositado no INPI busca atender as características da Tabela 6.

2.3. PREDIÇÃO DE ENERGIA SOLAR FOTOVOLTAICA

Uma grande quantidade de publicações relacionadas ao tema da **P**redição da **G**eração de **E**nergia **S**olar **F**otovoltaica (PGESF) pode ser observada na literatura, com aumento acentuado a partir do ano de 2017 (MACIEL; LEDESMA; ANDO JUNIOR, 2021). Consequentemente, diversos métodos e algoritmos de predição são propostos, analisados e apresentando resultados com maior acurácia e precisão ao longo dos anos (BLAGA et al., 2019), em especial com o uso recente de métodos de Aprendizados de Máquina e Profundo (KUMARI; TOSHNIWAL, 2021; LIN; ZHANG; WANG, 2022; RAJAGUKGUK; RAMADHAN; LEE, 2020; TINA et al., 2021; WANG et al., 2019).

Os termos de acurácia e precisão na PGESF compreendem medidas distintas, onde a acurácia se refere a proximidade com os valores reais (desvios ou *bias*), ou de referência, já conhecidos, relacionando-se a erros sistemáticos e aleatórios. Por outro lado, a precisão está relacionada ao grau de consistência das medidas obtidas com a sua média e, portanto, se refere à repetição do processo de medição (MARTINEZ; DUMER, 2012; RUSSELL; NORVIG, 2016). A Figura 4 ilustra estes conceitos.

Figura 4 – Conceitos de desvio, acurácia e precisão.

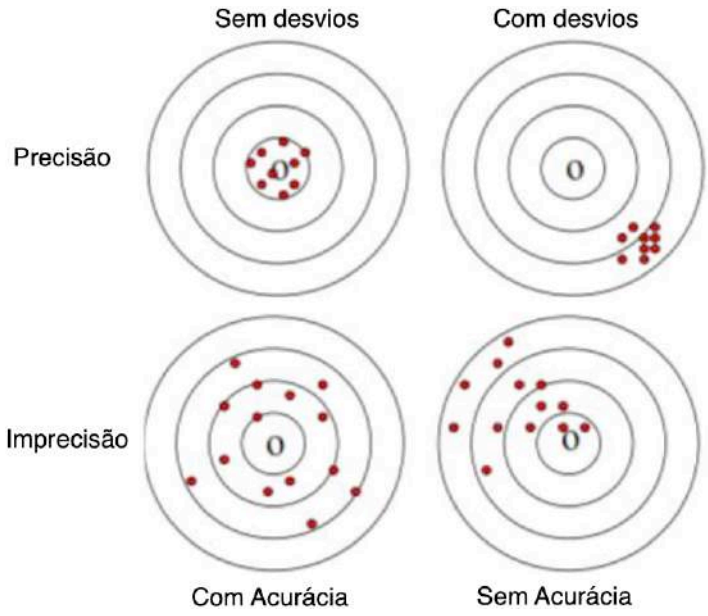

Fonte: Adaptado de (MARTINEZ; DUMER, 2012).

Dentro da PGESF não existe um consenso literário único para classificação dos trabalhos desenvolvidos. Todavia, algumas das principais características que os distinguem são o horizonte de predição, a origem e tipos de dados usados nas predições, as classes de modelos e algoritmos de predições e as métricas de análise de erros utilizadas. Estes conceitos fundamentais à PGESF são descritos a seguir.

2.3.1. Horizontes de Predição

Os modelos de predição de geração de energia fotovoltaica podem ser classificados pelo Horizonte de Resolução Temporal (HRT) das predições e Horizonte de Resolução Espacial (HRE) dos dados de entrada. O HRT consiste no período de tempo futuro em que os métodos realizam a predição e não há um consenso literário sobre a delimitação exata dessas resoluções (ANTONANZAS et al., 2016; DAS et al., 2018; SOBRI; KOOHI-KAMALI; RAHIM, 2018).

Tabela 7 – Horizontes de resolução temporal considerados nesta pesquisa.

HRT	**Termos Relacionados**	**Escala Temporal**
Curtíssimo Prazo	*real time*, *nowcasting, ultra short-term*	de milissegundos até 59 segundos
Curto Prazo*	*intra-hour*, *short-term, intra-day*	de 1 minuto até 24 horas
Médio Prazo	*medium-term, day ahead*	de 24 horas até 1 semana
Longo Prazo	*long term*	de 1 semana ou mais

* Horizonte de predição alvo considerado no presente estudo.
Fonte: O autor, (2022)

A partir das análises das revisões literárias de (ANTONANZAS et al., 2016; DAS et al., 2018; SOBRI; KOOHI-KAMALI; RAHIM, 2018), adotou-se nesta pesquisa as definições de HRT descritas na Tabela 7. Especificamente, a ênfase das predições consideradas no presente estudo compreende o horizonte de curto prazo, variando de 1 até 60 minutos. Ressalta-se que os diferentes horizontes de predição têm importância que variam conforme o objetivo de sua aplicação (BLAGA et al., 2019), assim como os métodos também originam distintos resultados conforme o horizonte de predição (SOBRI; KOOHI-KAMALI; RAHIM, 2018). Por exemplo, para reguladores de mercado é importante prever o potencial de produção do dia seguinte e assim negociar antecipadamente a produção no mercado (DAS et al., 2018). Já em uma usina fotovoltaica é importante obter a predição a curto prazo para que os sistemas de baterias possam prever e compensar a variabilidade intrínseca de geração de energia fotovoltaica, mitigando a variação do potencial e provendo carga adicional ao sistema (SHIVASHANKAR et al., 2016).

O HRT é dependente do Horizonte de Resolução Espacial (HRE) que, por sua vez, corresponde à abrangência, em escala espacial, dos dados de entrada (*inputs*) do modelo de predição. O HRE abrange o alcance territorial dos dados de entrada e sua relação com o HRT é detalhada na Figura 5. Como exemplo, citam-se os dados coletados por dispositivos ou câmeras locais (observações inferiores a 1 quilômetro de distância), sensores ou redes de sensores (observações abrangendo alguns quilômetros) ou ainda dados de maior resolução espacial geralmente originados de satélites, cujas observações abrangem mais de 100 quilômetros (DIAGNE et al., 2013).

Figura 5 – Relação entre os horizontes HRT e HRE.

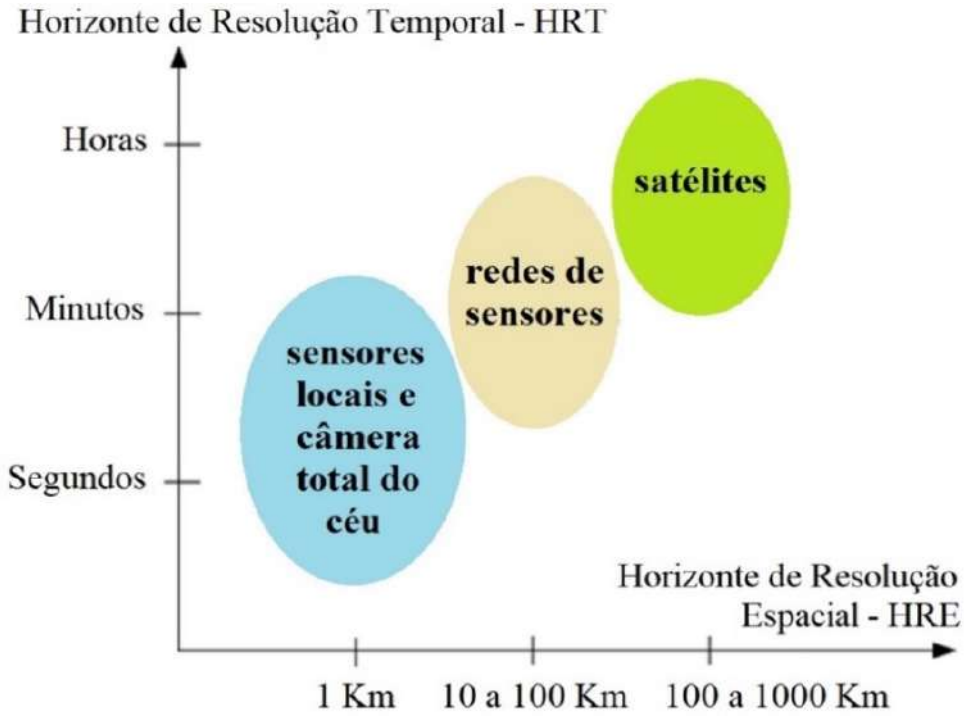

Fonte: Adaptado de (BARBIERI; RAJAKARUNA; GHOSH, 2017).

2.3.2. Origem e Tipos dos Dados

Os modelos literários podem empregar dados de origem interna (*endogenous data*) ou origem externa (*exogenous data*) (ANTONANZAS et al., 2016) para realização das predições. Os métodos contendo dados internos empregam Séries Temporais (ST) atuais e/ou históricas da produção de energia ou irradiância solar em seus cálculos. Por outro lado, os dados externos são provenientes de medições locais (temperatura, umidade relativa do ar, velocidade e direção do vento), informações e imagens completas do céu local, ou ainda imagens e variáveis climáticas fornecidas por satélites, tais como a temperatura, umidade relativa do ar, radiação do sol, cobertura de nuvens, velocidade e direção do vento, etc.

Enquadram-se aqui também os métodos que utilizam informações de estações meteorológicas e ou usinas fotovoltaicas vizinhas (CHOW et al., 2011b; NOBRE et al., 2016; SCHMIDT et al., 2016b).

O tipo ou representação do dado de entrada é uma informação relevante para os métodos de predição, principalmente aquelas utilizadas para treinar e validar os métodos de AM e/ou estatísticos de predição de geração de energia solar. Duas análises da correlação entre o potencial de geração de energia fotovoltaica e variáveis de entradas são apresentadas em (AHMED et al., 2020; DAS et al., 2018), onde identificou-se uma alta correlação (R^2=0,988) entre a Irradiância Global Horizontal (GHI) (W/m^2) e a energia gerada (kW) pelo sistema fotovoltaico. O estudo de (LI; ZHOU; YANG, 2018) também relata esta forte correlação, embora outros fatores como a inclinação e temperatura dos módulos fotovoltaicos possam influenciá-la (NAAMANDADIN; MING; AZANI MUSTAFA, 2018). Destaca-se que dentre as diversas componentes da irradiância solar, as mais comumente utilizadas na PGESF são, respectivamente, a Irradiação Global Horizontal (*Global Horizontal Irradiance* - GHI) e a Irradiação Direta Normal (*Direct Normal Irradiance* – DNI) (VILLALVA, 2015).

No entanto, pequenas usinas FV ou mesmo algumas localidades podem não dispor de determinados sensores para coleta e registro das informações, tais como a irradiância solar, informações sobre ventos e nuvens, até mesmo dados de satélites. Todavia, essas informações podem ser relevantes para alguns métodos ou horizontes. Por exemplo, em diversos modelos publicados na literatura acadêmica, a informação sobre as nuvens (velocidade, direção dos ventos, tipo de nuvem) consistem na principal entrada (JAMALY; KLEISSL, 2018). Por outro lado, em diversas outras abordagens a irradiância solar é o principal componente de entrada (DAS et al., 2018).

2.3.3. Classes de Modelos

Não existe consenso quanto a classificação exata dos modelos de predição. Uma interessante abordagem é proposta por (ANTONANZAS et al., 2016) que classifica os modelos em dois grupos: a predição indireta e a predição direta. As predições indiretas preveem primeiro a irradiância solar e, em seguida, usando um modelo de desempenho fotovoltaico da usina solar e calcula o potencial de energia produzida. A irradiância solar consiste no elemento fundamental e mais difícil de modelar, possuindo ainda outras aplicações além da previsão de energia solar (ANTONANZAS et al., 2016). Esta classe

engloba os denominados métodos físicos, de performance, paramétricos ou de *white-box* (caixa-branca) que empregam equações analíticas na modelagem do sistema e predições. Geralmente, a maioria dos esforços é dedicada a obter predições do principal fator relacionado à produção de energia: a irradiância solar.

Por outro lado, os modelos de previsões diretas predizem diretamente o potencial de energia solar a ser produzido. Essa categoria engloba os métodos estatísticos de regressão e de Aprendizado de Máquina (*Machine Learning* - *AM*) da Inteligência Artificial (IA) que tentam predizer, de modo direto, o potencial de geração de energia PV a partir de análises orientadas a dados, ou sejam, empregam informações históricas para predizer o potencial de geração futuro. Nestes métodos a qualidade dos dados históricos é fundamental para a acurácia dos resultados estatísticos e de AM, os quais geralmente demonstram resultados superiores aos métodos físicos que, em contrapartida, não requerem informações históricas (DIAGNE et al., 2013; KHATIB; MOHAMED; SOPIAN, 2012; YANG et al., 2018).

Ambas as categorias empregam técnicas de processamento da predição semelhantes, e também não há consenso científico quanto ao agrupamento dessas técnicas (ANTONANZAS et al., 2016; BARBIERI; RAJAKARUNA; GHOSH, 2017; BLAGA et al., 2019; DAS et al., 2018; DIAGNE et al., 2013; INMAN; PEDRO; COIMBRA, 2013; SOBRI; KOOHI-KAMALI; RAHIM, 2018; YANG et al., 2018). Talvez uma descrição pioneira completa dessas técnicas tenha sido feita por (INMAN; PEDRO; COIMBRA, 2013). No entanto, nesta pesquisa apresenta-se uma classificação mais recente, atualizada e concisa dessas técnicas baseando-se nas revisões de (ANTONANZAS et al., 2016; BLAGA et al., 2019), e considerando ainda o estado da arte.

2.3.3.1. *Persistentes*

Os Modelos Persistentes (MP) são métodos simples de produzir predições. Para compreendê-lo é necessário conhecer três conceitos de aspecto temporal de predições:

i) **Horizonte de Predição** (*forecast horizon* - f_h): quantidade de tempo presente entre o tempo t e o tempo da efetiva predição;

ii) **Resolução de Predição** (*forecast resolution* - f_r): descreve a frequência em que as predições são realizadas; e

iii) **Intervalo de Predição** (*forecast interval* - f_i): denota a faixa de tempo das predições.

O MP clássico assume que o estado do sistema (irradiância solar, geração, índice de claridade do céu, etc), permanece o mesmo entre o tempo atual t e $t + f_h$. Esses modelos são recomendados quando as series temporais (ST) são estacionárias, sendo a predição de geração no instante de tempo t dada pela Equação (2.1):

$$P_p(t + f_h) = P(t) \tag{2.1}$$

Embora existam variações dos MPs (URRACA et al., 2016; VOYANT; NOTTON, 2018), as seguintes características são desejáveis para um MP: (i) Simplicidade: um método que requer pouca ou nenhum treinamento ou inteligência, (ii) Rapidez: um método computacional rápido de implementar e trivial para fazer as predições e, (iii) Repetibilidade: um método que é determinístico que produz um resultado esperado para uma mesma entrada.

Por fim, é importante ressaltar que, frequentemente, os MPs são utilizados como *benchmarks* ou modelos de referência (*baseline*) para comparação dos resultados qualidade e precisão das predições com outros modelos propostos na literatura. Por este motivo devem ser considerados uma classe distinta (BLAGA et al., 2019).

2.3.3.2. *Estatísticos Clássicos*

Os Modelos Estatísticos Clássicos (MEC) não necessitam de dados internos do sistema para modelar a predição. Representam métodos orientados a dados históricos para predizer comportamentos futuros. Desse modo, a qualidade dos dados é fundamental para a precisão dos métodos desenvolvidos (DAS et al., 2018). Estas pesquisas, listadas na Tabela 8, empregam séries temporais (ST) para fazer predições de curto prazo analisando a alta correlação dos dados históricos de irradiância solar como entrada (BLAGA et al., 2019).

Tabela 8 – Pesquisas usando os principais de Modelos Estatísticos Clássicos (MEC).

Método Utilizado	**Publicações Relacionadas**
Principal Component Analysis – PCA	(DA SILVA FONSECA et al., 2014; YADAV; NATH, 2019; ZHANG; CHI; XIAO, 2019)
Fuzzy Logic	(CHAUVIN et al., 2018a; DEGTYAREV et al., 2018; ORANG et al., 2020; SERRANO ARDILA et al., 2022; SREEKUMAR et al., 2017)
Regressions	(CARNEIRO et al., 2022a; WANG et al., 2021)
Markov Process	(DOU et al., 2018; KANG; TAM, 2013)
Auto-Regressive Moving Average – ARMA	(CHU et al., 2015; FOUILLOY et al., 2018a; JING et al., 2017; LI; SU; SHU, 2014; SERRANO ARDILA et al., 2022; VOYANT et al., 2014; XIE et al., 2018)
Auto-Regressive Integrated Moving Average – ARIMA	(DAZHI; PANIDA; M., 2012; DENIS et al., 2019; SREEKUMAR et al., 2017; ZHANG et al., 2014; ZHOU et al., 2019)

Fonte: O autor, (2022).

2.3.3.3. *Aprendizado de Máquina e Aprendizado Profundo*

O Aprendizado de Máquina também conhecido por *Machine Learning* (AM) é uma área da Inteligência Artificial que desenvolve e estuda algoritmos com o objetivo de aprender, a partir de dados de entrada, e utilizar esse conhecimento para fazer predições ou tomada de decisões. Os algoritmos de AM demonstram resultados bem sucedidos quando os dados são incompletos ou incertos, e principalmente quando não existe dependência linear entre as entradas e saídas do problema. Na área de predição da geração de energia fotovoltaica o AM é, possivelmente, uma das abordagens mais utilizadas (YANG et al., 2018). Duas excelentes revisões dos métodos mais recentes de AM são descritas por (AKHTER et al., 2019; VOYANT et al., 2017). Cada técnica de AM possui suas características, vantagens e desvantagens, cujo detalhamento pode ser observado no estudo de (OBANDO; CARVAJAL; PINEDA, 2019).

O aumento do poder de processamento computacional com a popularização das Unidades Gráficas de Processamento (*Graphical Processing Units* - GPUs) proporcionou o surgimento de modelos mais complexos e robustos, originando uma nova classe de modelos da IA conhecida como Aprendizado Profundo ou *Deep Learning* (DL), uma espécie de "evolução" do ML (GOODFELLOW; BENGIO; COURVILLE, 2016). Dada a crescente quantidade de estudos com modelos de DL na PGESF, diversas revisões científicas tem sido publicadas sobre o tema (KUMARI; TOSHNIWAL, 2021; RAJAGUKGUK; RAMADHAN; LEE, 2020; WANG et al., 2019). A Tabela 9 apresenta alguns dos principais estudo de ML e DL na PGESF.

Tabela 9 – Pesquisas com métodos de Aprendizado de Máquina (AM).

Método Utilizado	**Publicações Relacionadas**
Genetic Algorithms – GA	(CHU et al., 2015; MARZOUQ et al., 2019; WU et al., 2014; XU; LIU, 2017);
Support Vector Machine – SVM	(AI; PENG; WEI, 2017; LI et al., 2019b; MELZI et al., 2017; MO et al., 2018; OLATOMIWA et al., 2015; ZENG; QIAO, 2013; ZHEN et al., 2015; ZHOU et al., 2018);
Gaussian Process – GP	(FOUILLOY et al., 2018b; KHUMMA; CHAIWONG; TAMEE, 2019; SEMERO; ZHANG; ZHENG, 2018);
Fuzzy Logic – FL	(ABDULLAH et al., 2019; CHAUVIN et al., 2018b; DEGTYAREV et al., 2018; LIU et al., 2017; ORANG et al., 2020; PERVEEN; RIZWAN; GOEL, 2019; SERRANO ARDILA et al., 2022; SIVANEASAN; YU; GOH, 2017; SREEKUMAR et al., 2017; VISWAVANDYA et al., 2020; YADAV; PAL; TRIPATHI, 2019)
Random Forests – RF	(ABUELLA; CHOWDHURY, 2017b; ALMEIDA; PERPIÑÁN; NARVARTE, 2015; FOUILLOY et al., 2018b; PASION et al., 2020; SANDERS et al., 2018; WEI; BING; HONGFENG, 2018);
k-Nearest Neighbors – kNN	(CHU et al., 2015; LI et al., 2016; MARZOUQ et al., 2019; WANG et al., 2017);

Decision Trees – DT;	(ARORA; GAMBHIR; KAUR, 2020; MASSUCCO et al., 2019; RAHUL et al., 2021; WANG et al., 2018a)
Artificial Neural Networks – RNA	(CECI et al., 2017; CERVONE et al., 2017; COCOCCIONI; D'ANDREA; LAZZERINI, 2011; DEO; ŞAHIN, 2017; DING; WANG; BI, 2011; FERNANDEZ-JIMENEZ et al., 2012; GUTIERREZ-COREA; MANSO-CALLEJO; ..., 2016; HU et al., 2018b; KHANDAKAR et al., 2019; KHUMMA; CHAIWONG; TAMEE, 2019; LEE; KIM, 2019; LIMA et al., 2018; LO BRANO; CIULLA; DI FALCO, 2014; MACIEL et al., 2021; MARQUEZ; PEDRO; COIMBRA, 2013; PULIPAKA; KUMAR, 2017; QUESADA-RUIZ et al., 2015; ROCHA et al., 2019; SABERIAN et al., 2014; SRIVASTAVA; TIWARI; GIRI, 2018; WENTZ et al., 2020, 2022; ZHU et al., 2016);
Deep Learning com *Convolutional Neural Networks* – CNN	(HUANG; KUO, 2019; LEE; KIM, 2019; RAJAGUKGUK; KAMIL; LEE, 2021; RYU et al., 2019; SABRI; EL HASSOUNI, 2022; SAJJAD et al., 2020; SUN; SZUCS; BRANDT, 2018; SUN; VENUGOPAL; BRANDT, 2018; TOVAR; ROBLES; RASHID, 2020; WEN et al., 2021; YANG et al., 2021; YI et al., 2018; ZANG et al., 2020; ZHANG et al., 2018b, 2018c);
Deep Learning com *Recurrent Neural Networks* – RNN – *e Long Short-Term Memory Networks* – LSTMs	(ABDEL-NASSER; MAHMOUD, 2017; GAO et al., 2019b, 2019a; GUARISO; NUNNARI; SANGIORGIO, 2020; HOSSAIN; MAHMOOD, 2020; HUSEIN; CHUNG, 2019; KONSTANTINOU; PERATIKOU; CHARALAMBIDES, 2021; LI et al., 2019b, 2019c; NIE et al., 2022; OSPINA; NEWAZ; OMAR FARUQUE, 2019; QING; NIU, 2018; SABRI; EL HASSOUNI, 2022; WANG; LIAO; CHANG, 2018; WENTZ et al., 2022; WOJTKIEWICZ et al., 2019; ZAFAR et al., 2021; ZHOU et al., 2019);
Deep Learning com *Deep Belief Networks* – DBN	(DU et al., 2019; LI et al., 2017; XIE et al., 2018);
Ensemble Learning – EL	(ABUELLA, 2015; ABUELLA; CHOWDHURY, 2017a; AL-DAHIDI et al., 2019; EL-KENAWY et al., 2021; GENSLER; SICK; PANKRAZ, 2017; MASSUCCO et al., 2019; NI et al., 2017; POMBO et al., 2022; RANA; KOPRINSKA; AGELIDIS, 2015; SABRI; EL HASSOUNI, 2022; SAJJAD et al., 2020; SEMERO; ZHANG; ZHENG, 2018; SU; LIU; HONG, 2019; VISWAVANDYA et al., 2020; WANG et al., 2018b; YANG, 2020; YANG et al., 2021; ZANG et al., 2020; ZHANG et al., 2019; ZHOU et al., 2018, 2019);

Fonte: O autor, (2022).

Existem ainda os métodos híbridos que combinam mais de um dos métodos citados. Dentre esses algoritmos de AM os mais utilizados na predição de geração de energia fotovoltaica são as RNA (VOYANT et al., 2017). Observa-se também que muitas publicações têm utilizado métodos de *Ensemble Learning* principalmente após o ano de 2017 (BLAGA et al., 2019). Por fim, ressalta-se que o recente estudo de (RAJAGUKGUK; RAMADHAN; LEE, 2020) apontou que os modelos *Ensemble Learning* e híbridos de DL tem apresentados os melhores índices de precisão quando aplicados na PGESF.

2.3.3.4. *Previsões Numéricas do Tempo*

A categoria de Previsões Numéricas do Tempo (*Numerical Weather Predictions* – NWP) é utilizada nas estimativas de previsões climáticas do tempo. Esta classe emprega variáveis climáticas como entrada de modelos matemáticos que descreverem os processos que ocorrem na atmosfera e realizam predições com HRT entre 6 e 72 horas. Os métodos de

NWP podem ser classificados em: Modelos Gerais de Circulação (GCM) aplicados nas predições de escala global e Modelos de Mesoescala (MME) utilizados em uma área restrita (BARBIERI; RAJAKARUNA; GHOSH, 2017; BLAGA et al., 2019). Foi demonstrado que esses modelos têm menor precisão para predições de curto prazo quando comparado a outras abordagens (BLAGA et al., 2019). Entretanto, com aplicação de pós processamento a precisão pode ser aumentada, principalmente para predições de longo prazo. Exemplos de trabalhos com métodos NWP são (AGUIAR et al., 2016b; JAYADEVAN et al., 2012; LARSON; NONNENMACHER; COIMBRA, 2016; LI et al., 2016; TIWARI; SABZEHGAR; RASOULI, 2019).

2.3.3.5. *Processamento de Imagens*

Esta categoria contempla o uso de câmeras fotográficas para captura de imagens digitais que são utilizadas em modelos de predição. Em geral, estes modelos aplicam diversas técnicas de Processamento de Imagens (GONZALEZ; WOODS, 2002; SZELISKI, 2011) nas imagens capturadas. Exemplos de estudos desta categoria são (BLUM et al., 2022; CHOW; BELONGIE; KLEISSL, 2015b; DEV et al., 2019; DISSAWA et al., 2021a; HUANG et al., 2013; NIE et al., 2022; RAJAGUKGUK; KAMIL; LEE, 2021; RICHARDSON et al., 2017; SABRI; EL HASSOUNI, 2022; WANG et al., 2020; YANG et al., 2014, 2021; ZHANG et al., 2018a; ZHEN et al., 2019).

Duas revisões de estudos com modelos de predição baseados em processamento de imagens digitais são relatadas em (BARBIERI; RAJAKARUNA; GHOSH, 2017; JUNCKLAUS MARTINS et al., 2022). Observa-se destes estudos que a maioria dos artigos se baseia em abordagens estatísticas clássicas utilizando dados históricos. Já os métodos mais utilizados com imagens são as Redes Neurais Artificiais (RNAs) e Redes Neurais Convolucionais (CNNs).

Os métodos de predição desta categoria podem ser agrupados nas duas seguintes subclasses, conforme o tipo de câmera ou imagem capturada:

- ***Ground Based Sky Imagers* (GBSI)**: são modelos que capturam localmente as imagens totais do céu, o sol, as nuvens e os movimentos, por meio de sistemas com câmeras *all-sky* apontadas ao céu. Geralmente, estas câmeras possuem lentes de grande angular (olho de peixe) de 180°, possibilitando a captura de todo o céu, mesmo que distorcido. Nestes modelos o objetivo é prever a

irradiância solar ou energia gerada, com técnicas geralmente associadas ao processamento envolvendo as nuvens em imagens digitais do céu. Exemplos destas principais técnicas utilizadas na PGESF são: *Red-Blue-Ratio* (RBR) (SHIELDS; JOHNSON; KOEHLER, 1993), vetores de deslocamento de nuvens (DISSAWA et al., 2021a; JAMALY; KLEISSL, 2018), luminância da imagem (DEV et al., 2016, 2019; ITU, 2015), limiarização (*threshold*) (LI; LU; YANG, 2011; OTSU, 1979), segmentação (ESCRIG et al., 2013; HENSEL et al., 2018), ângulo e inclinação do sol (ASRARI; WU; RAMOS, 2017; NICCOLAI; NESPOLI, 2020; SAHIN, 2018), entre outras.

- ***Satellite Based Sky Imagers*** **(SBSI)**: são modelos que utilizam imagens sequenciais da Terra obtidas via satélite, extraindo o vetor de movimentos das nuvens e informações meteorológicas para realizar predições da irradiância solar em feixe, difusa ou global (AGUIAR et al., 2016a; BRIGHT et al., 2018; LORENZ; HAMMER; HEINEMANN, 2004; MARQUEZ; PEDRO; COIMBRA, 2013; MILLER et al., 2018; YANG et al., 2019). Em geral, esta subclasse de modelos de predição é aplicada majoritariamente em predições de médio e longo prazos (BLAGA et al., 2019), embora também possam ser aplicadas para o curto prazo (HOFF, 2019b, 2019a), principalmente com o aumento da qualidade, resolução e amostras das imagens capturadas por satélites atuais, tais como o LadSat 9 lançado em 2021.

A Figura 6 ilustra graficamente os componentes dos modelos GBSI e SBSI, assim como exemplos de imagens obtidas a partir de uma câmera total do céu capturadas no modelo GBSI, e uma imagem de satélite com informações sobre a classificação das nuvens coletada pelo modelo SBSI. Complementarmente, são apresentadas na Tabela 10 algumas das principais pesquisas científicas aplicando predições com os modelos GBSI e SBSI.

Figura 6 – Componentes e imagens dos Modelos GBSI e SBSI.

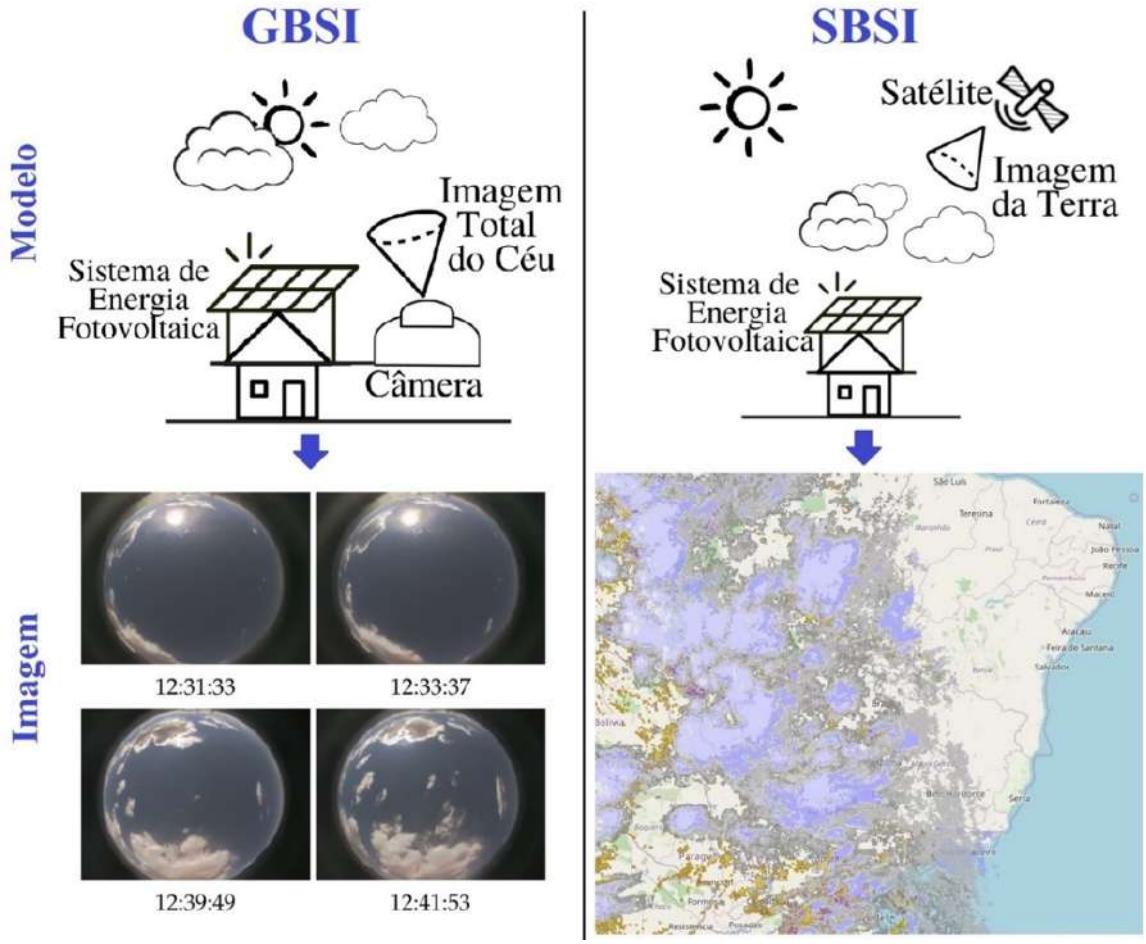

Fonte: Esquerda: sistema de câmera local com de imagem total do céu (*all-sky*), adaptado de (RICHARDSON et al., 2017). Direita: satélite de captura de imagem com classificação nuvens, adaptado de (INPE, 2020).

Tabela 10 – Pesquisas com modelos de Processamento de Imagens.

Método Utilizado	**Publicações Relacionadas**
Processamento de Imagens com Ground Based Sky Imagers – GBSI	(AI; PENG; WEI, 2017; CHAUVIN et al., 2015; CHENG; YU; LIN, 2014; CHOW et al., 2011a, 2011b; CHOW; BELONGIE; KLEISSL, 2015a; DEV et al., 2019; DISSAWA et al., 2021b, 2021a; DU et al., 2018; FU; CHENG, 2013; KAZANTZIDIS et al., 2017; MARQUEZ; COIMBRA, 2013; NIE et al., 2022; RAJAGUKGUK; KAMIL; LEE, 2021; RICHARDSON et al., 2017; TANG et al., 2019; TIWARI; SABZEHGAR; RASOULI, 2019; URQUHART et al., 2013; WANG et al., 2020; WEN et al., 2021; WOJTKIEWICZ et al., 2019; YANG et al., 2014, 2021; ZHANG et al., 2018a).
Processamento de Imagens com Satellite Based Sky Imagers – SBSI	(AGUIAR et al., 2015, 2016a, 2016b; AYET; TANDEO, 2018; BRIGHT et al., 2018; CORNEJO-BUENO et al., 2019; DEO et al., 2019; HAMMER; HEINEMANN; LUCKEHE, 2000; HOFF, 2019b, 2019a; JAMALY; KLEISSL, 2017; LAGO et al., 2018, 2019; LUIZ et al., 2018; MARQUEZ; PEDRO; COIMBRA, 2013; MILLER et al., 2018; SHAO; LU; HAMANN, 2016; SINGH DOORGA et al., 2019; SOARES; LIMA; MARTINS, 2019; SRIVASTAVA; LESSMANN, 2018; WANG et al., 2022; WATANABE; NOHARA, 2019; YANG et al., 2019; YANG, 2018, 2019, 2020)

Fonte: O autor, (2022).

2.3.3.6. *Modelos Híbridos*

Os Modelos Híbridos empregam conjuntamente dois ou mais modelos classificados anteriormente e também são denominados *gray-box* (caixa cinza) (ANTONANZAS et al., 2016). Exemplos de estudos contemplando estes modelos são (DISSAWA et al., 2021a; MELZI et al., 2017; RAJAGUKGUK; KAMIL; LEE, 2021; RAMSAMI; OREE, 2015; SREEKUMAR et al., 2017; ZHOU et al., 2019).

2.3.4. Medidas de Acurácia

Distintas métricas estatísticas podem ser empregadas para avaliar a precisão dos modelos de predição de geração de energia fotovoltaica (DAS et al., 2018). Cada métrica possui características particulares que avalia diferentes atributos relativos à qualidade da acurácia e/ou erros de predição. Uma extensa revisão detalhada das principais métricas estatísticas aplicadas ao tema PGESF é relatada em (GUEYMARD, 2014). Com base neste estudo e no histórico de pesquisas realizadas sobre a PGESF (BLAGA et al., 2019; MACIEL; LEDESMA; ANDO JUNIOR, 2021; YANG et al., 2018), apresentam-se as seguintes métricas para quantificar a acurácia, ou precisão, dos modelos nesta pesquisa: o Coeficiente de Determinação ou *Score* (R^2), o *Mean Bias Error* (MBE), o *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE) e *Mean Absolute Percentage Error* (MAPE), definidas pelas equações 2.2, 2.3, 2.4, 2.5 e 2.6, respectivamente:

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(o_i - p_i)^2}{\sum_{i=1}^{N}(o_i - \mu)^2} \tag{2.2}$$

$$MBE = \frac{1}{N}\sum_{i=1}^{N}(o_i - p_i) \tag{2.3}$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|o_i - p_i| \tag{2.4}$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(o_i - p_i)^2} \tag{2.5}$$

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{o_i - p_i}{o_i} \times 100\right| \tag{2.6}$$

Nas métricas, N representa a quantidade total de pontos dos dados, μ refere-se a média da distribuição observada, p_i ao o i-*ésimo* ponto predito e o_i representa o i-*ésimo* ponto observado. A comparação de acurácia de modelos com amostras de tamanhos diferentes é feita com a normalização de métricas para a média μ (equação 2.7) do dado observado, sendo:

$$\mu = \frac{1}{N}\sum_{i=1}^{N} o_i \tag{2.7}$$

onde então podemos ter $nMBE = MBE/\mu$, $nMAE = MAE/\mu$ e $nRMSE = RMSE/\mu$, respectivamente (BLAGA et al., 2019).

O Coeficiente de Determinação R^2 avalia a qualidade e precisão de ajuste dos preditos em relação aos dados originais, e quanto mais próximo a 1, melhor qualidade e eficiência de precisão possui o modelo predito. Por outro lado, o MBE captura as tendências positivas ou negativas de erros gerais entre os dados preditos e reais. No entanto, estes valores positivos e negativos podem se cancelar mutuamente. O $RMSE$ é a métrica mais utilizada com modelos de regressão na literatura da PGESF (DAS et al., 2018; JUNCKLAUS MARTINS et al., 2022), pois, é dependente de escala e sensível a grandes erros individuais por conter valores ao quadrado. Desse modo, captura a variabilidade dos dados preditos em relação ao original, mas não as tendências gerais (GUEYMARD, 2014). Por sua vez, a métrica MAE posiciona-se dentre as duas anteriores, pois, quantifica a magnitude média dos erros sendo dependente de escala. O valor de MAE=0 indica que as predições do modelo são perfeitas. Por fim, o $MAPE$ representa o erro percentual dos dados preditos em relação aos reais e é independente de escala, facilitando sua interpretação. No entanto, o $MAPE$ tem um conhecido erro de divisão por zero em problemas de regressão (GUEYMARD, 2014). De modo geral, as métricas devem ser normalizadas como indicadores estatísticos na área de predição da geração de energia solar com modelos de regressão (BLAGA et al., 2019).

Por fim, outra abordagem comparativa empregada em estudos recentes consiste no uso da medida de *Skill Score* (SS), a qual quantifica o grau de associação entre a acurácia de um determinado modelo de predição e um modelo de referência base, geralmente chamado de *Persistence*, *Baseline* ou *Benchmark*, conforme a equação (2.7):

$$SS = 100 \times \left(1 - \frac{RMSE_p}{RMSE_b}\right) \tag{2.8}$$

Na equação acima, $RMSE_p$ corresponde a acurácia $RMSE$ de um determinado modelo predito, enquanto $RMSE_b$ é o valor de $RMSE$ para o modelo *Persistence* (referência base ou *benchmarking*). Um $SS = 100\%$ indica predições perfeitamente precisas, enquanto um $SS = 0\%$ demonstra que as predições do modelo avaliado ($RMSE_{pred}$) possui a mesma acurácia do modelo base ($RMSE_{base}$). Valores negativos indicam que o modelo de base supera o modelo avaliado. Além do $RMSE$, outras medidas de acurácia podem ser consideradas no cálculo do SS.

Neste contexto, utilizou-se nas avaliações estatísticas de precisão da presente pesquisa as seguintes métricas identificadas na literatura: o R^2, a $RMSE$, a MAE e SS. Conjuntamente, estas métricas permitem uma mensuração mais ampla dos desvios gerais e individuais relativos aos erros dos modelos, permitindo ainda a comparação dos resultados com modelos de referência e outros estudos científicos da literatura.

2.4. CONSIDERAÇÕES FINAIS

Esta seção apresentou a revisão bibliográfica do estado da arte e de propriedade intelectual sobre a temática da PGESF, detalhando os conceitos fundamentais da temática que embasam a presente pesquisa. A partir da análise literária científica observa-se grande quantidade de estudos, com proposição de métodos e soluções relacionadas ao tema PGESF tem sido publicada (MACIEL; LEDESMA; ANDO JUNIOR, 2021). Devido ao cenário energético atual brasileiro demonstrar acentuada expansão e investimentos na geração de energia solar fotovoltaica (ABSOLAR, 2022; ANEEL, 2016), e ao embasamento teórico científico, detalhado nesta seção, motivou-se a proposição de uma nova solução em PGESF detalhada na próxima seção.

3. MÉTODO HÍBRIDO DE PREDIÇÃO

Nesta seção é apresentada a classificação do método científico deste estudo e o delineamento metodológico contemplando o Método Híbrido de Predição (MHP) desenvolvido. São descritos o projeto arquitetural e análise experimental do MHP, incluindo o banco de dados (*dataset*), as ferramentas e as tecnologias empregadas durante no desenvolvimento.

Segundo (GIL, 2017), a metodologia científica adotada neste estudo se enquadra na seguinte classificação:

i) **Natureza**: pesquisa aplicada, por gerar novos conhecimentos e uma solução de aplicação prática dirigida ao problema de PGESF de curto prazo;

ii) **Forma de abordagem do problema**: pesquisa quali-quantitativa, por realizar análise estatística quantitativa do desempenho de predição (acurácia) da proposta, assim como análises de aspectos qualitativos da solução, como por exemplo o *tradeoff* entre o custo-benefício e características do MHP desenvolvido;

iii) **Objetivo**: pesquisa de caráter exploratório que proporciona maior familiaridade com o problema, assim como a análise de exemplos que estimulam sua compreensão; e

iv) **Procedimentos técnicos**: pesquisa bibliográfica e análise estatística experimental com estudo de caso para avaliação do MHP desenvolvido.

A solução proposta neste estudo compreende um Método Híbrido de Predição (MHP) da irradiância solar, desenvolvido em software, cuja aplicação pode ser utilizada para a PGESF de curto prazo. O software do MHP pode ser executado com *hardware* computacional genérico e de baixo custo, e utiliza como entrada as imagens totais do céu (*all-sky*) capturadas por meio de uma câmera comum com lente grande-angular de 180°. Portanto, o MHP pode ser aplicado na PGESF de curto prazo em sistemas distribuídos, centralizados, *on-grid* ou *off-grid*.

O MHP utiliza um processamento com abordagem híbrida por aplicar, conjuntamente, distintas técnicas de Processamento de Imagens e um algoritmo de Aprendizado de Máquina (AM), a serem descritos posteriormente, para efetuar as predições de curto prazo, Além das imagens totais do céu, informações de geolocalização e

especificação da Unidade de Geração (UG) fotovoltaica são utilizadas. As características da solução proposta compreendem o uso de dispositivos simples, comuns e de baixo custo, para o processamento computacional e a aquisição de imagens, implementando a complexidade do problema em software.

Diante deste contexto, apresenta-se o ambiente e componentes do modelo do sistema e predição que é composto pelo Método Híbrido de Predição (MHP) proposto neste estudo. Na Figura 7 são exibidos os principais componentes e seus relacionamentos de entrada e saída de dados do MHP, desenvolvido e avaliado experimentalmente neste estudo.

Figura 7 – Ambiente, entradas e componentes do modelo predição deste estudo.

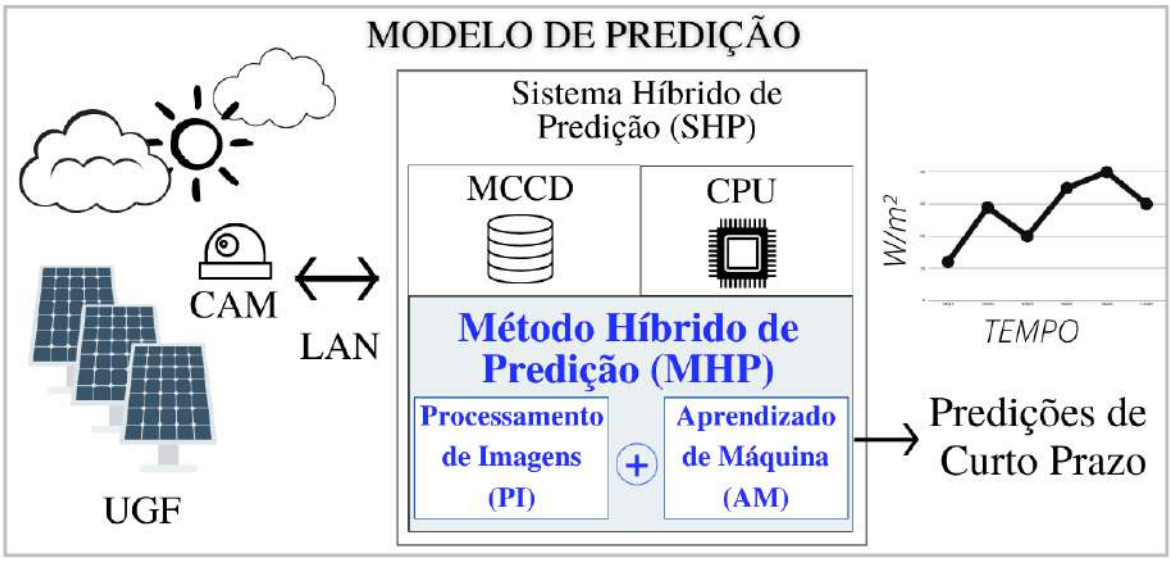

Fonte: O autor, (2022).

- **Unidade de Geração Fotovoltaica (UGF):** compreende o módulo, sistema ou usina de geração de energia solar fotovoltaica, incluindo inversores e componentes relacionados;
- **Rede de Comunicação Local (LAN):** é uma rede de comunicação guiada ou não-guiada, como por exemplo no padrão Wi-Fi IEEE 802.11, que permite ao MHP a comunicação com câmera remota e transferência de dados digitais;
- **Unidade de Processamento Central (CPU) e Câmera (CAM):** consistem em dispositivos comuns e genéricos de processamento computacional e de captura de imagens totais do céu, respectivamente. O MHP desenvolvido pode ser executado a partir de uma CPU Raspberry Pi 4 (GAY, 2014), com 4 GB de memória RAM (≅ R$ 650,00). A câmera de captura das imagens *all-sky* pode

ser genérica com resolução mínima de 2 Megapixels. Como exemplo, um módulo Pi Camera Ov5647 de 5 Megapixel (≅ R$ 30,00) acoplado a um suporte com certificação IP-65 (≅ R$ 50,00) contendo uma com lente grande-angular (olho de peixe) de 180° (≅ R$ 80,00);

- **Módulo de Configuração e Captura dos Dados (MCCD):** componente de software que realiza a captura de informações relativas as imagens e configurações da UG, as quais servirão de entrada para o MHP;
- **Sistema Híbrido de Predição (SHP):** é o componente de software que controla todo o MCCD e o MHP, assim como provê a saída do modelo de predição (Série Temporal) para determinado horizonte de curto prazo;
- **Método Híbrido de Predição (MHP):** é o principal componente de software proposto neste estudo, cuja execução utiliza um processamento híbrido que aplica, conjuntamente, técnicas de Processamento de Imagens (PI) e Aprendizado de Máquina (AM) para realizar a PGESF no curto prazo.

O principal componente de software do modelo de predição considerado neste estudo é o Método Híbrido de Predição (MHP), cuja arquitetura e funcionamento são exibidos na Figura 8. A função geral do MHP é realizar as predições a partir da execução conjunta e sequencial de duas etapas: Processamento de Imagens (PI) e Aprendizado de Máquina (AM). Inicialmente o modelo é configurado com a câmera de captura das imagens e informações relativas à UG, tais como a capacidade nominal da potência instalada, especificação dos módulos fotovoltaicos, localização geográfica (latitude, longitude) e altitude do local de instalação. Em seguida seleciona-se o horizonte de predição de curto prazo com base em intervalos de tempo previamente definidos (1, 5, 10, 15, 30 e 60 minutos).

Figura 8 – Diagrama arquitetural do Método Híbrido de Predição – MHP.

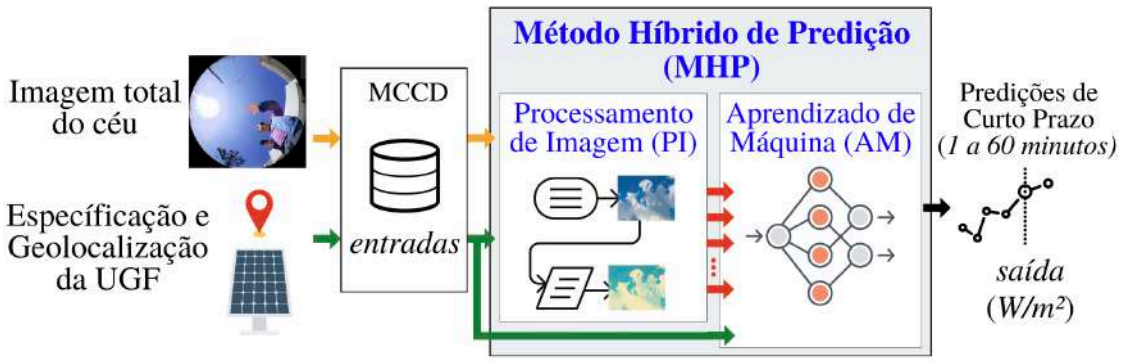

Fonte: O autor, (2022).

O processo de cálculo das predições para determinado horizonte à frente é realizado a partir das entradas (*inputs*) capturadas pelo Módulo de Configuração e Captura de Dados (MCCD), ou seja, as imagens totais do céu local e informações de geolocalização e altitude da UGF. No modelo considerado (Figura 8), o Processamento de Imagens (PI) calcula diversas métricas (características) da imagem total do céu, e as repassa como entrada para um determinado algoritmo de Aprendizado de Máquina (AM) (RUSSELL; NORVIG, 2016), previamente treinado com dados históricos, realizar as predições no horizonte selecionado.

O fluxo de processamento e de dados no MHP é exibido na Figura 9. Em todos os horizontes de curto prazo avaliados (1, 5, 10, 15, 30 e 60 minutos) são utilizadas como entradas as imagens de câmeras locais do céu, as informações de geolocalização (latitude e longitude) e a altitude da UGF. A partir de cada imagem *all-sky* são computadas e extraídas as seguintes características relativas a x_n Métricas de PI, com $n = 11$, sendo: Movimentação das Nuvens (*Clouds Movement*), Cobertura das Nuvens (*Clouds Coverage*), Nuvens no Entorno do Sol (*Clouds Around Sun*), Irradiância Solar de Céu Limpo (*Clear Sky GHI*), localização do sol (*Sun Located*), Luminância do Sol (*Sun Luminance*), Luminância do Sol Ajustada ao irradiância de céu limpo (*Sun Luminance Adjusted*) e a Taxa de Pixels Brancos (*White Pixel Ratio*) na imagem. Além destas, são computadas a data (*Date*), hora e minuto (*Time*), estação climática (*Season*) (Figura 9).

Vale destacar que com o cálculo destas x_{11} métricas, que constituem as entradas (*inputs*) dos modelos de predição, buscou-se com a extração de características do céu que possibilitem e facilitem a predição da irradiância GHI futura, ou seja, buscou-se fornecer novas e relevantes informações para que os modelos de Aprendizado de Máquina executassem as predições a partir de características das imagens totais do céu. Os detalhes das x_n métricas a partir do Processamento de Imagens (PI) são descritos posteriormente.

Em seguida, as x_{11} características são utilizadas por um algoritmo de AM que realiza a predição no horizonte determinado (h). Conforme já mencionado, o algoritmo de predição é baseado em regressão e, portanto, realiza-se o treinamento prévio do algoritmo de AM a partir de dados históricos relativos a imagens *all-sky* e a GHI. Neste estudo foram avaliadas as acurácias de predição dois algoritmos de AM do MHP, sendo uma Rede Neural Artificial *MultiLayer Perceptron* (MLP) e o *Light Gradient Boosting Machine* (LightGBM). Destaca-se que o MHP proposto na Figura 9, classifica-se em uma abordagem híbrida com relação a origem dos dados de entrada, ou seja, são utilizados dados exógenos (imagens do

céu em tempo real) e dados endógenos (histórico de medições) contemplando as imagens *all-sky* e respectivos valores de irradiância GHI, para a realização das predições (ANTONANZAS et al., 2016).

Figura 9 – Fluxos de dados e processamento do Método Híbrido de Predição - MHP.

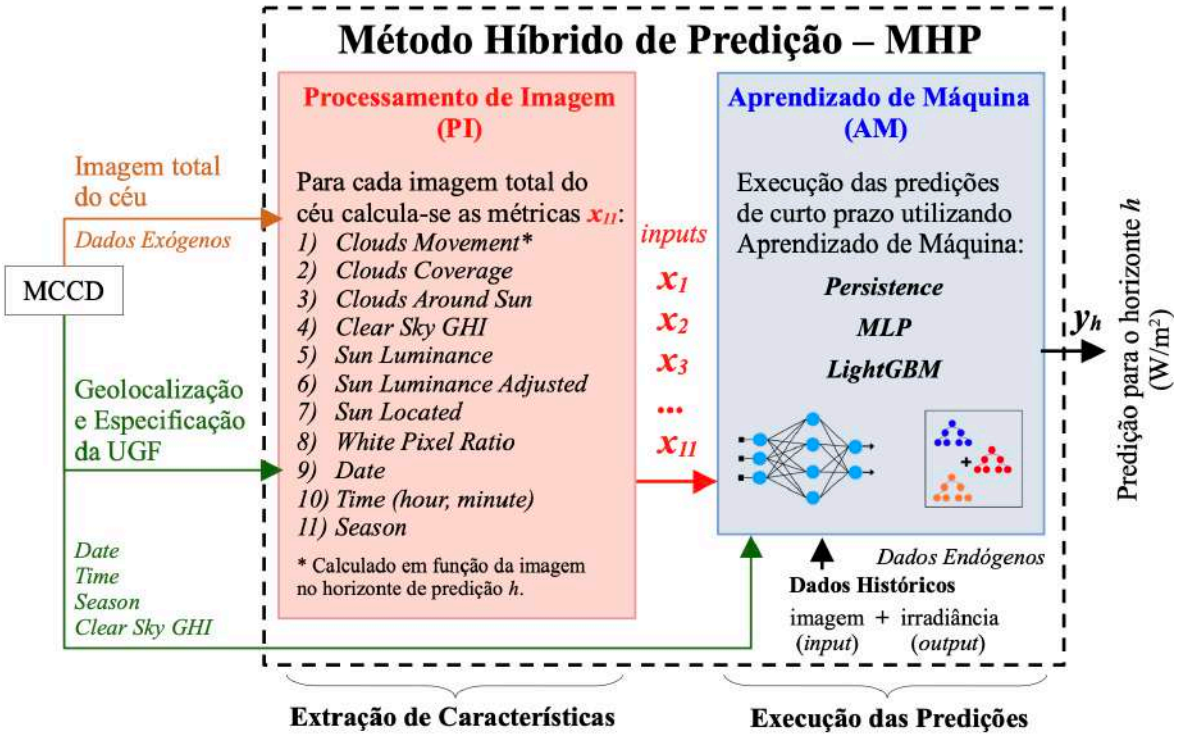

Fonte: O autor, (2022).

Já na Figura 10 é apresentado o fluxograma dos passos de execução das predições com o MHP a partir do tempo t. Inicialmente a câmera é configurada para capturar imagens e o MHP recebe a localização (latitude, longitude), altitude da UGF e o horizonte h das predições. A partir da imagem capturada em t são computadas as características (Métricas de PI $x_1 \ldots x_{11}$) relativas a $imagem(t)$. Estas informações são fornecidas como entrada para um algoritmo Aprendizado de Máquina ou Aprendizado Profundo executar as predições para o horizonte h ($Pred(t+h)$), após ter sido previamente treinado com dados históricos também originados de imagens totais do céu.

A proposta de uso conjunto de todas as características (métricas $x_1 \ldots x_{11}$), consideradas neste estudo é original na PGESF e não foi observada na literatura científica. Diante disto, realizaram-se análises comparativas da acurácia de predição da irradiância GHI com os algoritmos MLP e LightGBM, incluindo trabalhos similares da literatura científica. Além disso, avaliou-se também as acurácias dos modelos de AM comparando-se dois

conjuntos diferentes de dados de entrada, ou seja, o uso de informações meteorológicas tradicionais e o uso das características (Métricas de PI $x_1 \ldots x_8$) extraídas das imagens totais do céu (Figura 10). A avaliação experimental está detalhada na seção 3.4.

Figura 10 – Fluxograma de execução do Método Híbrido Predição (MHP) proposto.

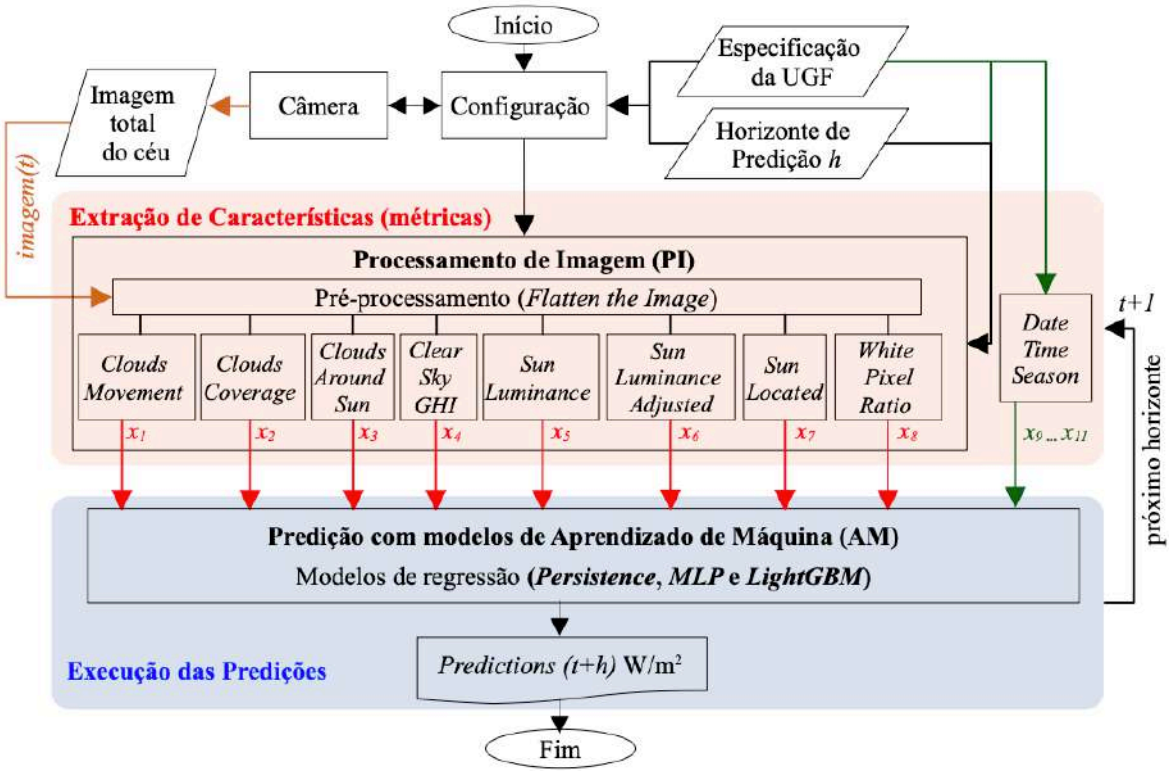

Fonte: O autor, (2022).

Com a intenção de apresentar a abordagem híbrida de execução do MHP proposto, apresenta-se na próxima seção os detalhes do *dataset* e as técnicas de Processamento de Imagens (PI) utilizadas no cálculo das características ($x_1 \ldots x_8$) extraídas das imagens *all-sky*. Posteriormente, são detalhados os modelos de AM clássicos MLP e LightGBM propostos e avaliados neste estudo.

3.1. DATASET

A etapa de extração das características com Processamento de Imagens (PI) e os algoritmos de Aprendizado de Máquina do MHP (MLP e LightGBM), propostos neste estudo, foram desenvolvidos a partir de um banco de dados (*dataset*) público e construído especificamente para o desenvolvimento de métodos de predição de irradiância solar aplicáveis a PGESF (PEDRO; LARSON; COIMBRA, 2019).

O *dataset* empregado é composto por dados endógenos e exógenos relativos a informações meteorológicas, irradiância solar e imagens locais do céu, coletadas durante o período completo de três anos (2014 a 2016). Além disso, as informações são padronizadas e possuem qualidade controlada com taxa mínima amostral de 1 (um) minuto. Todas as informações foram capturadas na cidade de Folsom, Califórnia, Estados Unidos da América (PEDRO; LARSON; COIMBRA, 2019).

Durante todo o período de 2014 a 2016 foram registrados os valores as informações meteorológicas, imagens totais do céu e respectivos valores de irradiância solar a cada minuto, totalizando 775.564 amostras. A Figura 11 exibe exemplos de imagens totais do céu e seus respectivos valores de irradiância durante 7 horas do dia 14/03/2014, considerando o horário *Universal Time Coordinated* (UTC) padrão disponibilizado no *dataset*, ou seja, UTC-00.

Figura 11 – Exemplos de imagens totais do céu respectivos valores de irradiância solar.

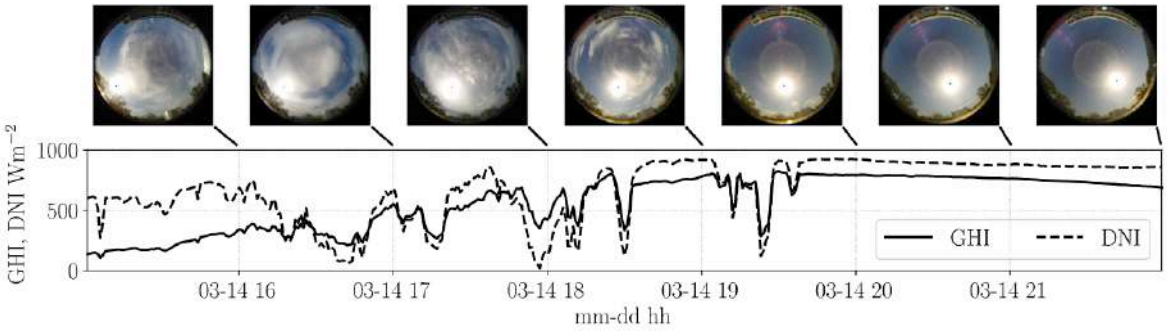

Fonte: Adaptado de (PEDRO; LARSON; COIMBRA, 2019).

Complementarmente, na Figura 12 são apresentados todos os valores e o perfil anual da Irradiância Global Horizontal (GHI), que é a variável alvo a ser predita (*target*) neste estudo. Conforme observado, existem alguns períodos com imagens ou valores de GHI ausentes no *dataset*. Desse modo, as características (métricas $x_1 \ldots x_8$) foram extraídas daquelas imagens existentes e que possuem seus respectivos valores de GHI no *dataset.*

Figura 12 – Perfil anual da irradiância GHI no *dataset* utilizado neste estudo.

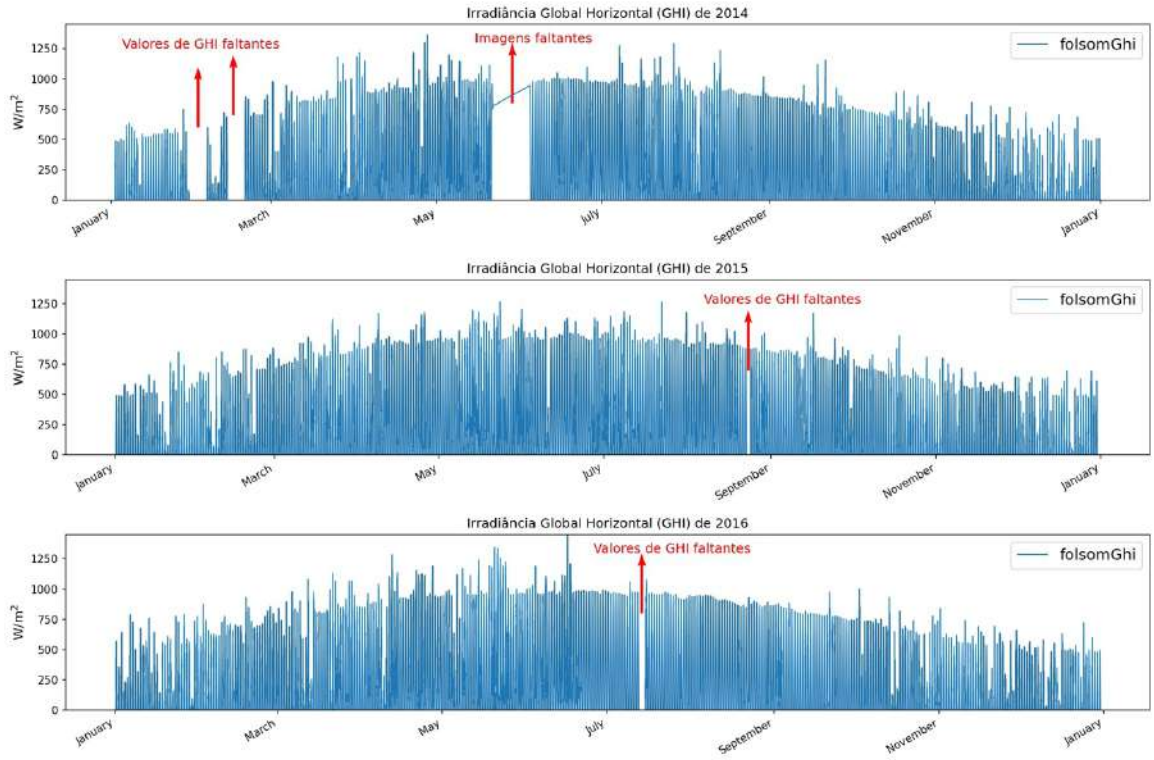

Fonte: O autor, (2022).

3.2. PROCESSAMENTO DE IMAGENS

Dentre os diversos modos de armazenar e representar uma imagem digital, neste estudo foi utilizado o formato *Red-Green-Blue* (RGB) (GONZALEZ; WOODS, 2002). Cada *pixel*, ou ponto da imagem, tem sua cor resultante de três componentes *Red, Green, Blue* (RGB), cujos valores variam entre 0 e 255 (Figura 13 – esquerda).

Figura 13 – Representação de uma imagem digital no formato *Red-Green-Blue* (RGB).

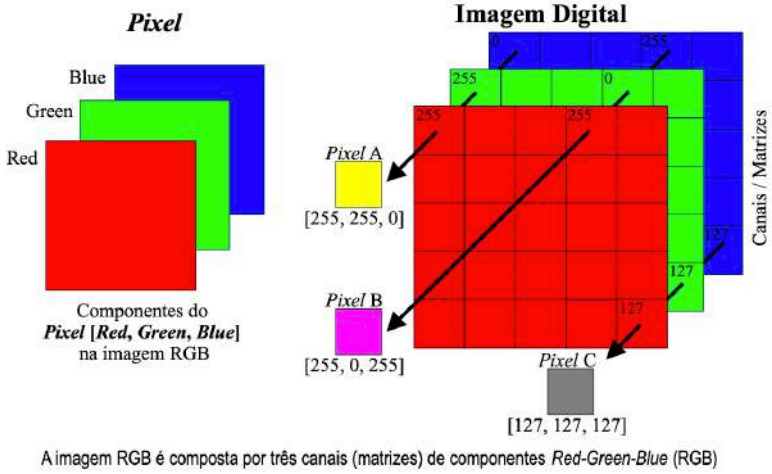

Fonte: O autor, (2022).

Portanto, uma imagem digital no padrão RGB é composta por três canais (matrizes) de *pixels* correspondentes a cada cor. Como exemplo, a cor amarela (*Pixel A*) é formada pelas três componentes *Red* = 255, *Green* = 255 e *Blue* = 0 (Figura 13 - direita).

Com intuito de facilitar a apresentação dos detalhes de funcionamento das métricas que extraem as características ($x_1 \ldots x_8$) das imagens *all-sky*, selecionou-se três dias de referência com diferentes condições meteorológicas e padrões de GHI (Figura 14).

Figura 14 – Perfil da irradiância GHI e respectivas imagens nos três dias de referência.

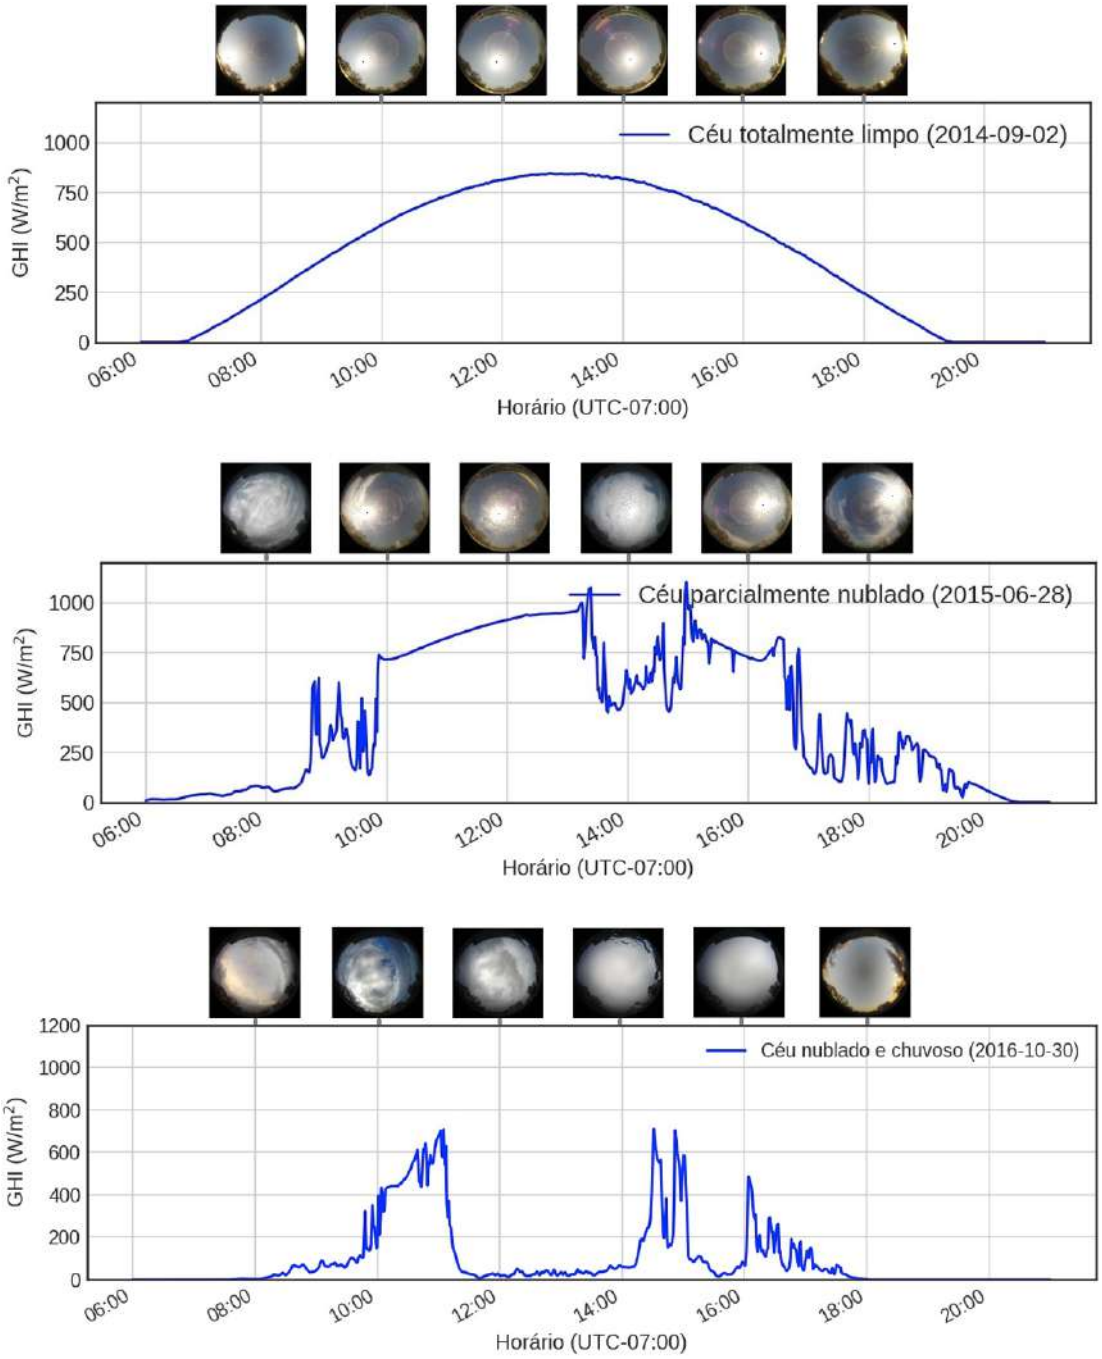

Fonte: O autor, (2022).

Vale destacar que a GHI é a variável alvo (*target*) a ser predita pelo MHP, pois, possui alto grau de correlação com a geração de energia solar fotovoltaica (DAS et al., 2018). Conforme exibido na Figura 14, o primeiro dia (02/09/2014) é caracterizado por ter o céu integralmente limpo durante todo o dia. O segundo dia (28/06/2015) selecionado possui o céu parcialmente nublado, exceto entre 10h00 e 13h00, aproximadamente. Por fim, o terceiro dia (08/12/2016) é representado por um céu predominantemente nublado que se torna chuvoso a partir das 11h40, aproximadamente, e volta a ficar nublado ao final do dia. Este dia foi intencionalmente selecionado para demonstrar o funcionamento do MHP em condições adversas que podem prejudicar seu funcionamento, pois interferências nas imagens ocorrem do gotejamento da chuva.

É importante destacar que para facilitar a leitura dos dados e análise das imagens, a partir da Figura 14, a zona horária UTC das imagens no *dataset* é padrão (UTC-00) e foi atualizada para o horário do local da cidade de Folsom/Califórnia (UTC-07) em que as imagens foram capturadas. Além disso, menor quantidade de amostras no terceiro dia (08/12/2016) é devida ao clima chuvoso e a estação climática de outono, cujo os dias são mais curtos e, portanto, existem menos imagens no horário entre 06h00 e 20h00.

Com base nos dias de referência são apresentadas a seguir os detalhes de processamento das (métricas $x_1 \dots x_8$) que extraem as características de cada imagem total do céu. Inicialmente é descrita a etapa base de Pré-processamento das imagens e, posteriormente, as métricas de: *Clouds Movement* (x_1) - movimentação das nuvens; *Clouds Coverage* (x_2) - cobertura das nuvens; *Clouds Around Sun* (x_3) - taxa de nuvens no entorno do sol; *Clear Sky GHI* (x_4) - irradiância com céu limpo; *Sun Luminance* (x_5) - luminâcia do sol; *Sun Luminance Adjusted* (x_6) - luminâcia do sol ajustada e; *Sun Located* (x_7) - localização do sol; *White Pixels Rate* (x_8) - taxa de *pixels* brancos na imagem. Após calculadas, todas estas métricas são fornecidas como entrada para o algoritmo de Aprendizado de Máquina (AM) executar as predições.

3.2.1. Pré-processamento

A etapa de pré-processamento precede a execução das demais métricas $x_1 \dots x_8$. A função principal do pré-processamento é realizar a planificação da imagem total do céu (*Flatten the Image*), capturada por uma câmera com lente olho de peixe de 180°. Portanto, o objetivo desta etapa é corrigir a distorção da imagem panorâmica original tornando a perspectiva de sua visão plana. A planificação utiliza neste estudo baseou-se no trabalho de

(PEREIRA, 2019), o qual disponibilizou um procedimento que realiza a planificação de qualquer imagem distorcida a partir do centro. Os seguintes parâmetros foram utilizados no processamento da imagem original (Tabela 11):

Tabela 11 – Configuração do algoritmo da planificação das imagens totais do céu.

Parâmetro	**Descrição**	**Valor**
lens type	Tipo de lente (*linear, equalarea, orthographic* e *stereographic*)	linear
image format	formato da imagem (*circular* ou *fullframe*)	fullframe
ifov	Campo de visão (graus) da imagem de entrada	180°
ofov	Perspectiva do campo de visão (graus) da imagem de saída	120°

Fonte: O autor, (2022).

A partir do processamento de planificação da imagem total do céu, realizado com o auxílio do algoritmo detalhado em (PEREIRA, 2019), observa-se na Figura 15 as imagens distorcidas originais (esquerda) e o resultado a imagem processada plana (direita). A imagem planificada é posteriormente utilizada como entrada para o cálculo das métricas ($x_1 \ldots x_8$) que representam diferentes características da imagem.

Figura 15 – Exemplos de planificação das imagens totais do céu.

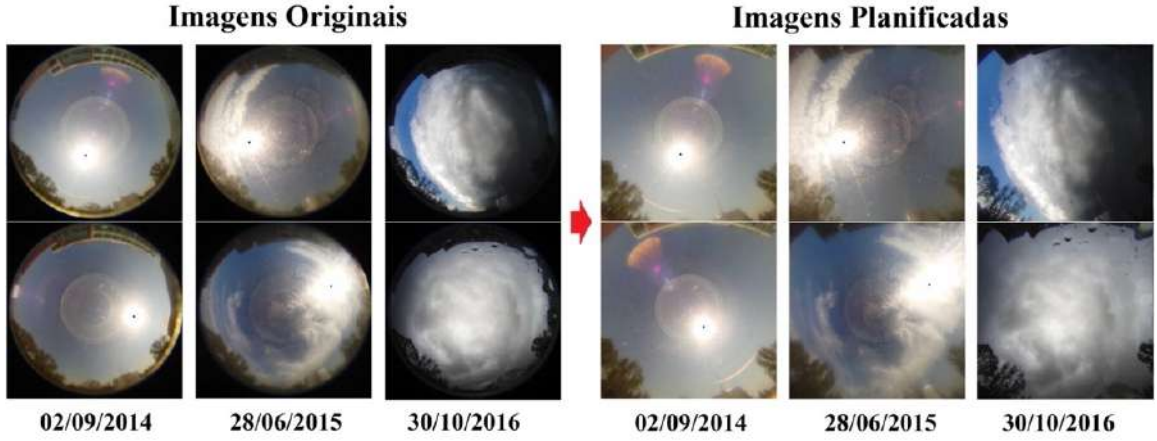

Fonte: O autor, (2022).

É importante destacar que a resolução, dimensões e formato da imagem planificada foi mantido igual à imagem original, ou seja, a imagem plana foi gerada com a resolução de 96 *Dots Per Inch* (DPI), 256 cores (8 *bits*) no formato *Red-Green-Blue* (RGB) e dimensões (largura e altura) de 1536 x 1536 *pixels*.

3.2.2. Métrica de Movimentação das Nuvens

A métrica de movimentação das nuvens (*Clouds Movement*) mensura a característica de movimento das nuvens no céu a partir de duas imagens planas sequencialmente capturadas. O movimento das nuvens no tempo t é calculado a partir da

$imagem(t)$, capturada no tempo t, e da $imagem(t-h)$ previamente capturada no tempo $t-h$, onde h é o horizonte da predição. O cálculo do movimento das nuvens foi realizado a partir de uma abordagem simples e eficiente, que quantifica o grau de diferença entre duas imagens.

Existem diversos métodos aplicáveis à comparação de imagens digitais, tais como o *Mean Square Error* (MSE), *Peak Signal to Noise Ratio* (PSNR), *Structured Similarity Index Method* (SSIM), *Feature Similarity Index Method* (FSIM), entre outros (SARA; AKTER; UDDIN, 2019). Neste estudo, adotou-se o *MSE* por ser uma das abordagens mais aplicadas, possuir implementação simples e um claro significado físico. Além disso, é matematicamente adequado ao contexto de otimização de processamento computacional. A desvantagem do MSE é que seus valores não são representados na escala normalizada (SARA; AKTER; UDDIN, 2019). No entanto, no contexto deste estudo, este processo de normalização é necessário e realizado posteriormente pelos algoritmos de AM utilizados nas predições.

Considerando um determinado instante de tempo t, o horizonte de predição h, x e y as dimensões (largura e comprimento) das duas imagens $\gamma_t(x,y)$ e $\hat{\gamma}_{\mathrm{t-h}}(x,y)$, o MSE_t representa o erro absoluto da diferença entre os *pixels* entre as imagens γ e $\hat{\gamma}$, conforme a equação (3.1) (SARA; AKTER; UDDIN, 2019):

$$MSE_t = \frac{1}{MN}\sum_{x=0}^{M-1}\sum_{y=1}^{N-1}[\gamma_t(x,y) - \hat{\gamma}_{\mathrm{t-h}}(x,y)]^2 \qquad (3.1),$$

onde, M e N correspondem as dimensões (*pixels*) de largura e comprimento das imagens γ_t e $\hat{\gamma}_{\mathrm{t-h}}$. A movimentação das nuvens no céu é um importante fator que, quando próximas ao sol acaba por ocluir os raios solares gerando sombras nos painéis fotovoltaicos, sendo, portanto, a principal causa das intermitências ocasionadas na geração da irradiância solar. Considerando os três dias com diferentes condições climáticas e seus perfis de irradiância GHI (Figura 14), apresentam-se os resultados da métrica *Clouds Movement* nos horizontes de predição de 1, 5, 10, 15, 30 e 60 minutos na Figura 16.

Figura 16 – Resultado da métrica *Clouds Movement* para diferentes horizontes.

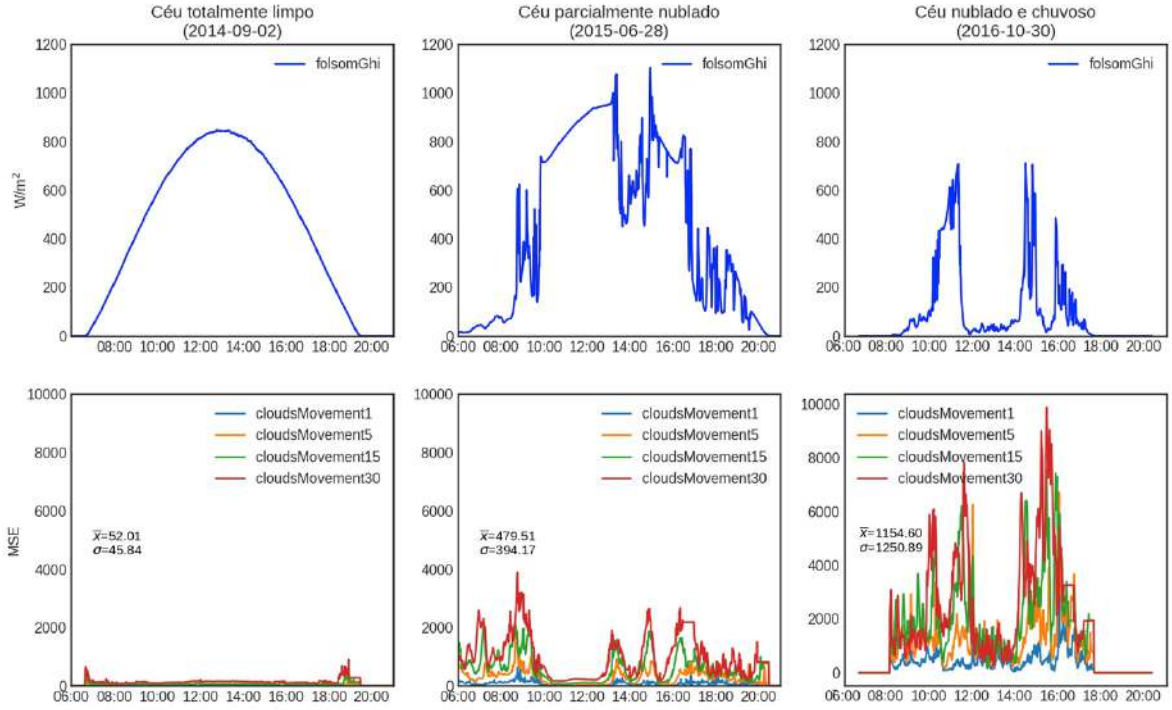

Fonte: O autor, (2022).

Observa-se que a métrica *Clouds Movement* possui a capacidade de fornecer informações relevantes as predições, como por exemplo a ausência de nuvens e informação do movimento destas nuvens em determinado horizonte. No primeiro dia com céu totalmente limpo (02/09/2014), os valores são baixos e aproximadamente constantes, com MSE médio geral de $\bar{x} = 52{,}02$ e Desvio Padrão $(\sigma) = 45{,}84$ de todos os horizontes de predição exibidos. No segundo dia (28/06/2015), com céu parcialmente nublado, os valores de MSE capturam o padrão de existência das nuvens em movimento e do céu limpo, conforme observado na irradiância GHI entre as 10h00 e 20h00. Neste dia, obteve-se um MSE médio geral de $\bar{x} = 479{,}51$ e $\sigma = 994{,}17$ de todos os horizontes de predição exibidos e, portanto, bem superior ao dia de céu totalmente limpo. Por fim, o terceiro dia (30/10/2016) com céu predominantemente nublado (entre 12h00 e 14h00, aproximadamente) também tem seu perfil identificado pelo MSE. No entanto, neste dia os valores absolutos de MSE, cuja média geral é de $\bar{x} = 1154{,}60$ e $\sigma = 1250{,}89$, são bem mais elevados ($MSE > 4000$) devido das gotas de chuva que se movem na lente da câmera, causando a impressão de maior movimentação das nuvens.

No entanto, a métrica de *Clouds Movement* é importante por fornecer informações confiáveis, em condições normais de operação, que possibilitam identificar a existência de nuvens e ventos que a deslocam durante um determinado período. Além disso, a aplicação

desta métrica em todas as imagens do *dataset* resultou em valores discrepantes de MSE (*outliers*) onde constatou-se que, em determinadas períodos e ocasiões, ocorreram problemas técnicos de manutenção ou limpeza da câmera durante os três anos de coleta de dados, conforme observado nos exemplos da Figura 17. As imagens identificadas com interferências foram descartadas das análises.

Figura 17 – Interferências nas imagens do *dataset* e capturadas pelo MSE.

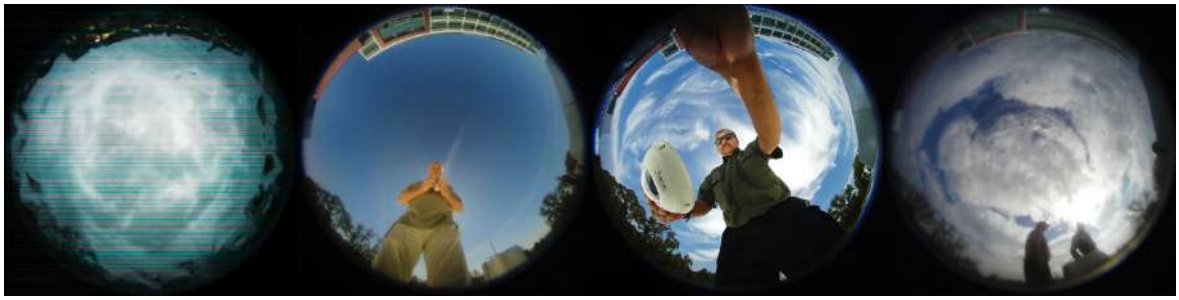

Fonte: Adaptado de (PEDRO; LARSON; COIMBRA, 2019).

3.2.3. Métrica de Cobertura das Nuvens no Céu

A métrica de cobertura das nuvens no céu (*Clouds Coverage*) mensura a porcentagem de nuvens em todo o céu de uma determinada imagem plana no tempo t. Conforme descrito na seção 2.3.3.5, os desafios da identificação entre nuvens e o céu é bastante conhecido na literatura científica, sendo abordado em diversos estudos (CHAUVIN et al., 2015; CHOW et al., 2011c; CHOW; BELONGIE; KLEISSL, 2015b; DISSAWA et al., 2021a; NOU et al., 2018; URQUHART et al., 2013; YANG et al., 2016). No contexto desta pesquisa foi desenvolvido um algoritmo de identificação entre nuvens e o céu que executa os seguintes passos para cada imagem:

1) Redimensionamento da imagem plana (1536×1536 *pixels*) em 30% (460×460 *pixels*) para otimizar os processamentos seguintes;
2) Conversão da imagem para um único canal utilizando a taxa de *Red-Blue-Ratio* (RBR) que foi orginalmente proposta por (SHIELDS; JOHNSON; KOEHLER, 1993). Considerando as diferentes variações do RBR analisadas em (LI et al., 2019d), o presente estudo utilizou o RBR normalizado. O método RBR é capaz de identificar *pixels* do céu e nuvens em uma imagem pela taxa dos pixels dos canais *Red* e *Blue* da imagem, os quais vaiam de 0 a 255. No processamento do RBR, *pixels Blue* com valor 0 são convertidos em 1 para evitar a divisão por 0;
3) Aplicação da limiarização na imagem com o algoritmo *Otsu Threshold* (OTSU,

1979) para classificar os *pixels* pertencentes ao céu e nuvem. De modo simplificado, o *Otsu Threshold* é um método não supervisionado comumente utilizado com imagens na PGESF (CHAUVIN et al., 2015; KAZANTZIDIS et al., 2012; LI; LU; YANG, 2011; LI et al., 2019d; RAJAGUKGUK; KAMIL; LEE, 2021). O algoritmo retorna um limiar de intensidade adaptativo, para cada imagem, que separa os *pixels* em duas classes, ou seja, identifica as nuvens (primeiro plano) e o céu (segundo plano) (OTSU, 1979);

4) Cálculo do percentual de nuvens no céu da imagem no tempo t (CP_t) utilizando a equação (3.2):

$$\mathrm{CP_t} = 100 \times \frac{\sum \rho_{cloud}}{\sum \rho_{sky}} + cf \qquad (3.2),$$

onde, ρ_{cloud} e ρ_{sky} correspondem a quantidade total de *pixels* que presentam as nuvens e o céu, respectivamente, e cfé o fator de ajuste adicionado em função dos objetos que interferem na área do céu da imagem, tais como edifícios ou árvores. Nas imagens do *dataset* (PEDRO; LARSON; COIMBRA, 2019) foi utilizado $cf = 0{,}10$ para corrigir a área do céu encoberta por obstáculos, tais como árvores e edifícios. Caso não haja objetos interferindo na imagem, o valor de cf deve ser zero.

Ressalta-se que, embora a métrica proposta (*Clouds Coverage*) tenha sido inspirada nas propostas de (CHOW et al., 2011c; OTSU, 1979; RAJAGUKGUK; KAMIL; LEE, 2021), a variação do algoritmo desenvolvido neste estudo fornece o valor real da porcentagem da cobertura de nuvens no céu (entre 0 e 100%), distinguindo-se da representação do índice de nuvens de oito classes adotada em (RAJAGUKGUK; KAMIL; LEE, 2021).

Na Figura 18 são exibidos exemplos do processamento da métrica de *Clouds Coverage* em imagens selecionadas, modo aleatório, nos 3 dias de referência com diferentes condições meteorológicas. Embora seja uma área bastante explorada na literatura científica, a abordagem utilizada apresenta inconsistências conhecidas, ocorrendo principalmente em dias chuvosos (30/10/2016), com céu nublado, reflexos (20/09/2014) ou ainda a alteração da tonalidade do céu devido a incidência do ângulo solar (zênite e azimute) (ANTONANZAS-TORRES et al., 2019).

Figura 18 – Processamento das imagens na métrica de *Clouds Coverage*.

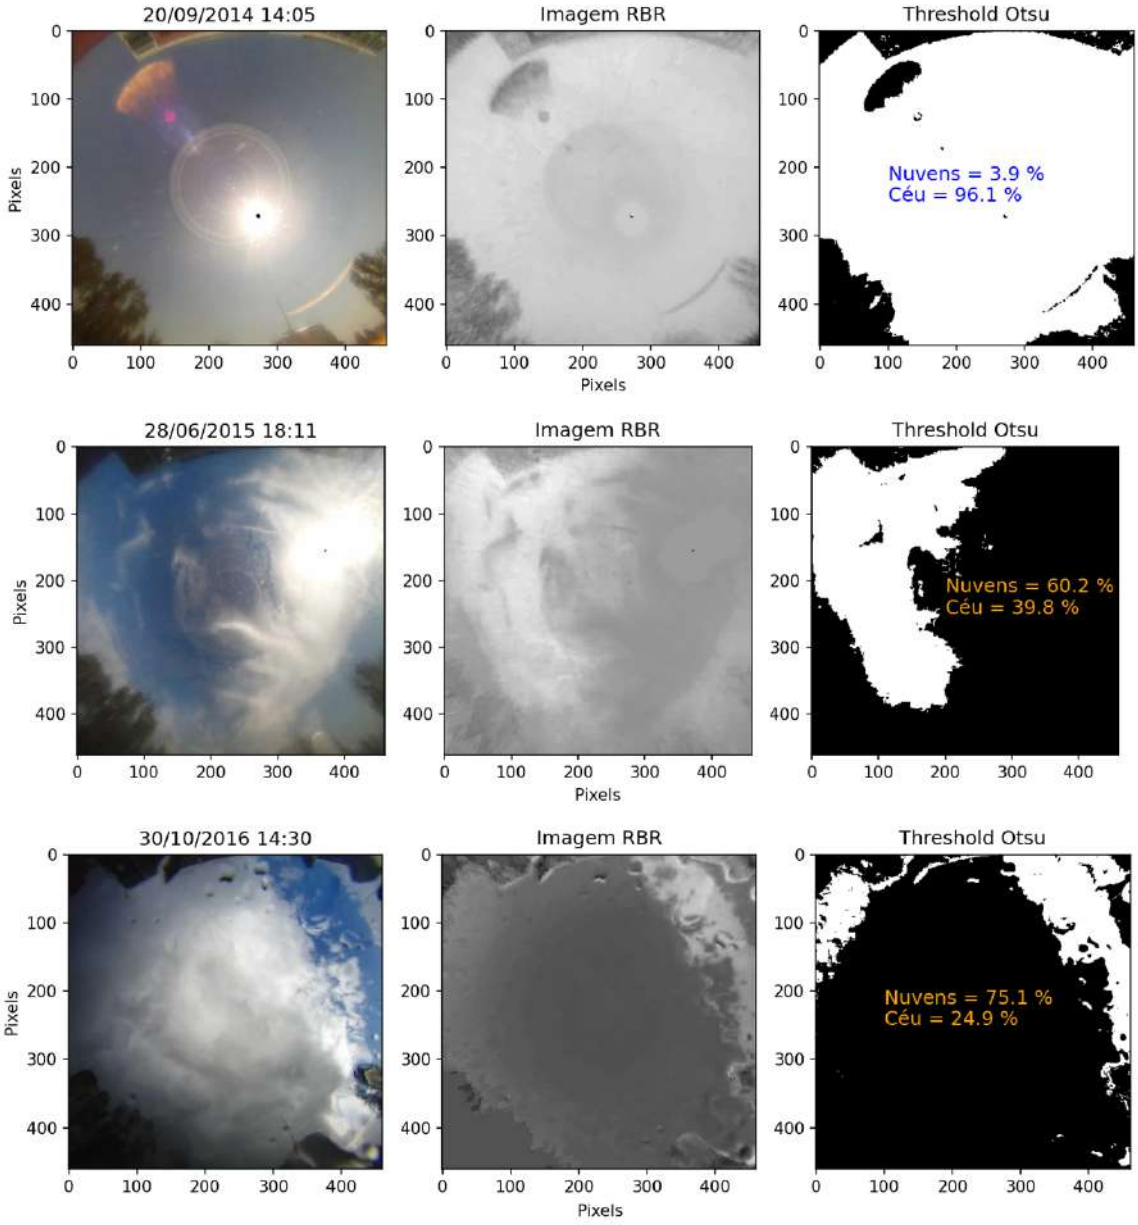

Fonte: O autor, (2022).

Na Figura 19 é exibido o resultado da métrica *Cloud Coverage* calculado a cada um minuto, durante os três dias de referência. Resultados interessantes podem ser observados como, por exemplo, no dia 28/06/2015 em que captura adequadamente, a ausência de nuvens no céu entre 10h00 e 12h00, aproximadamente. Por outro lado, observa-se que no início e no fim do dia ocorrem reflexos equivocamente identificados como nuvens (02/09/2014). Além disso, em dias totalmente nublados ou chuvosos, a métrica perde precisão e confiabilidade (30/10/2016). Considerando tais características, é importante ressaltar que essa métrica é uma das componentes do modelo de predição e, presume-se, que tais

inconsistências sejam capturadas pelo algoritmo de predição baseado em Aprendizado de Máquina.

Figura 19 – Resultado da métrica de *Clouds Coverage*.

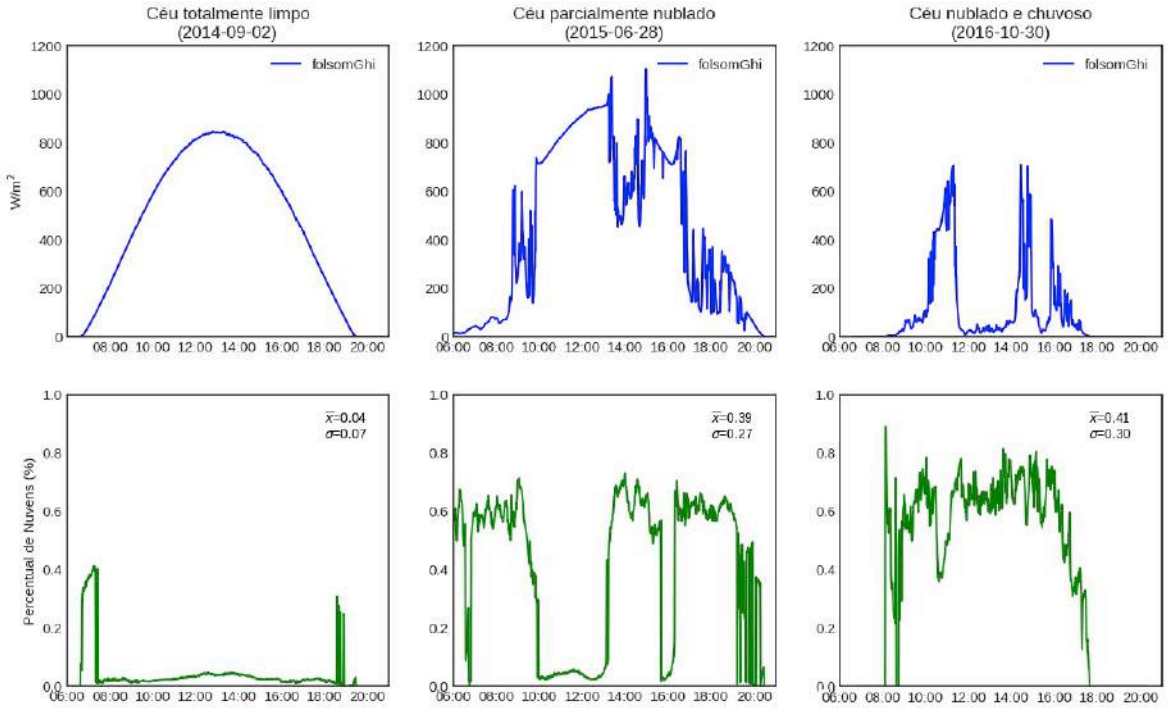

Fonte: O autor, (2022).

3.2.4. Métrica de Nuvens Entorno do Sol

A métrica de cobertura das nuvens em torno da região do sol (*Clouds Around Sun* - CAS) tem seu processamento baseado na métrica anterior de *Clouds Coverage*. No entanto, a métrica *Clouds Around Sun* fornece a porcentagem de nuvens relativa à região ao redor (entorno) do sol na imagem plana no tempo t.

A Figura 20 representa o algoritmo desenvolvido para calcular a métrica *Clouds Around Sun*. Após a leitura da imagem plana, a localização do sol é realizada pela aplicação de um *threshold* de 240 no canal vermelho (*red*) da *imagem(x,y)* (SAVOY et al., 2016). Caso o sol seja localizado, uma área de 300×300 *pixels* em torno do sol é selecionada para transformação (*RBR*), segmentação (*Otsu Threshold*) e cálculo do percentual de nuvens na área entorno do sol. Por outro lado, caso o sol não seja localizado, por exemplo, em dias extremamente nublados ou horários de início e final de dia, a área central de 900×900 *pixels* do céu na imagem é selecionada para o cálculo do percentual de nuvens na imagem.

Figura 20 – Algoritmo da métrica de *Clouds Around Sun.*

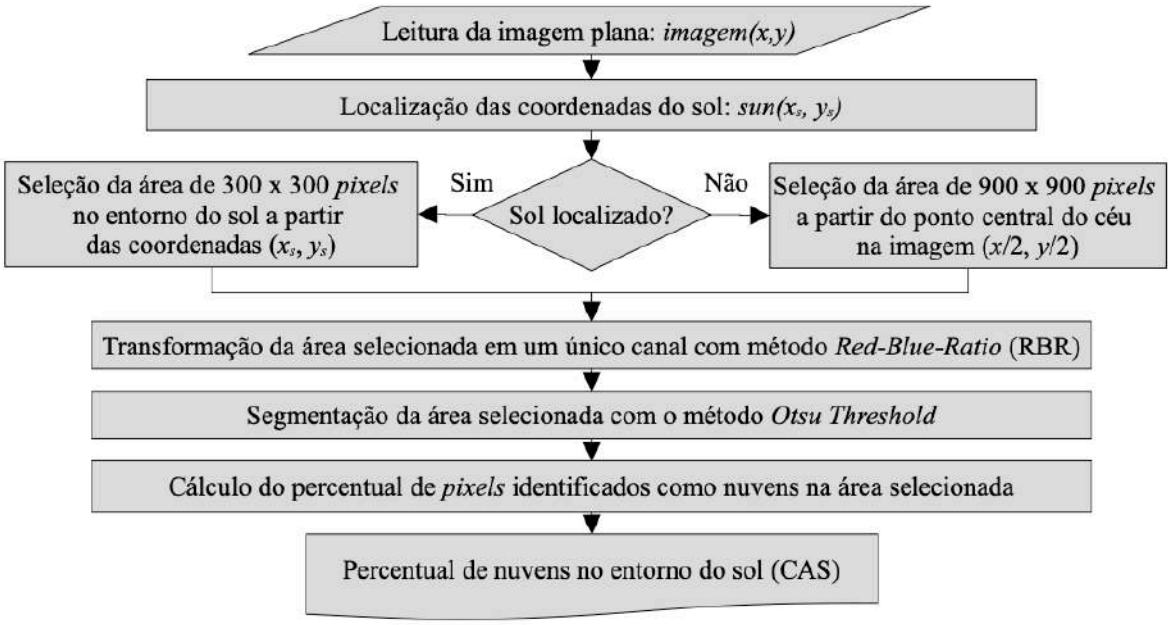

Fonte: O autor, (2022).

O exemplo do processamento das imagens com a métrica CAS é exibido na Figura 21. Já os valores de CAS durante os três dias de referência são detalhados na Figura 22.

Figura 21 – Processamento de imagens da métrica de *Clouds Around Sun* (CAS).

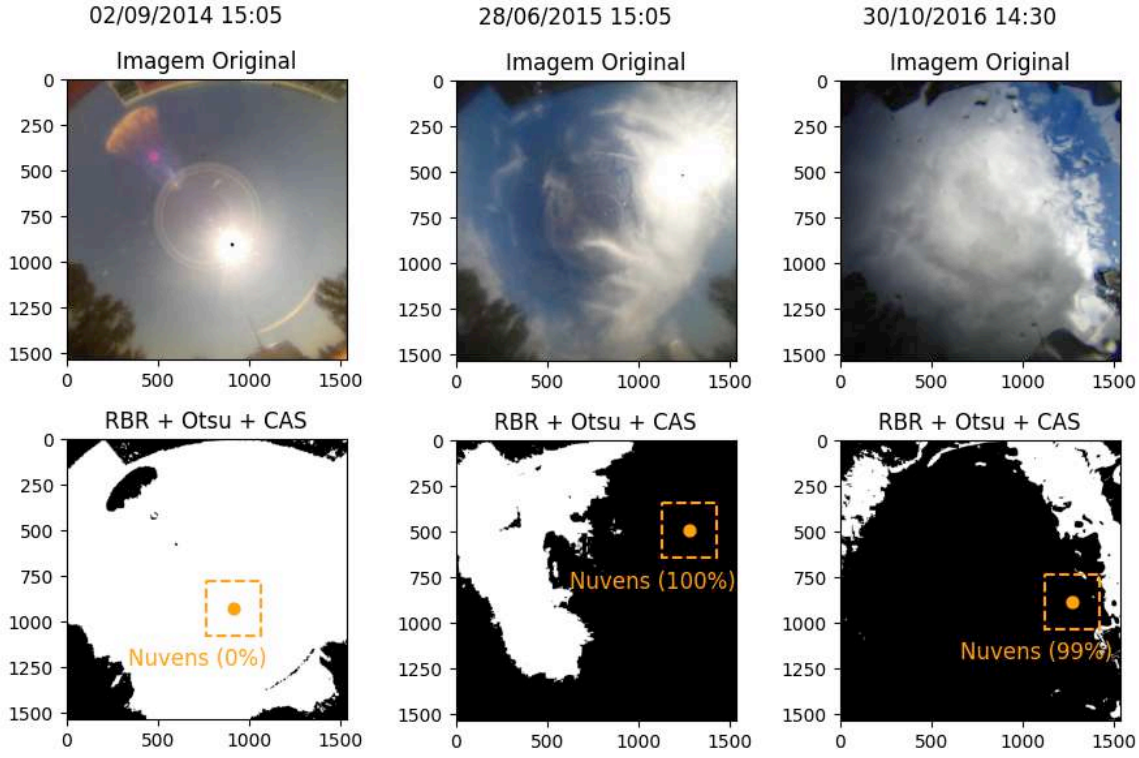

Fonte: O autor, (2022).

Figura 22 – Resultado da métrica de *Clouds Around Sun* (CAS).

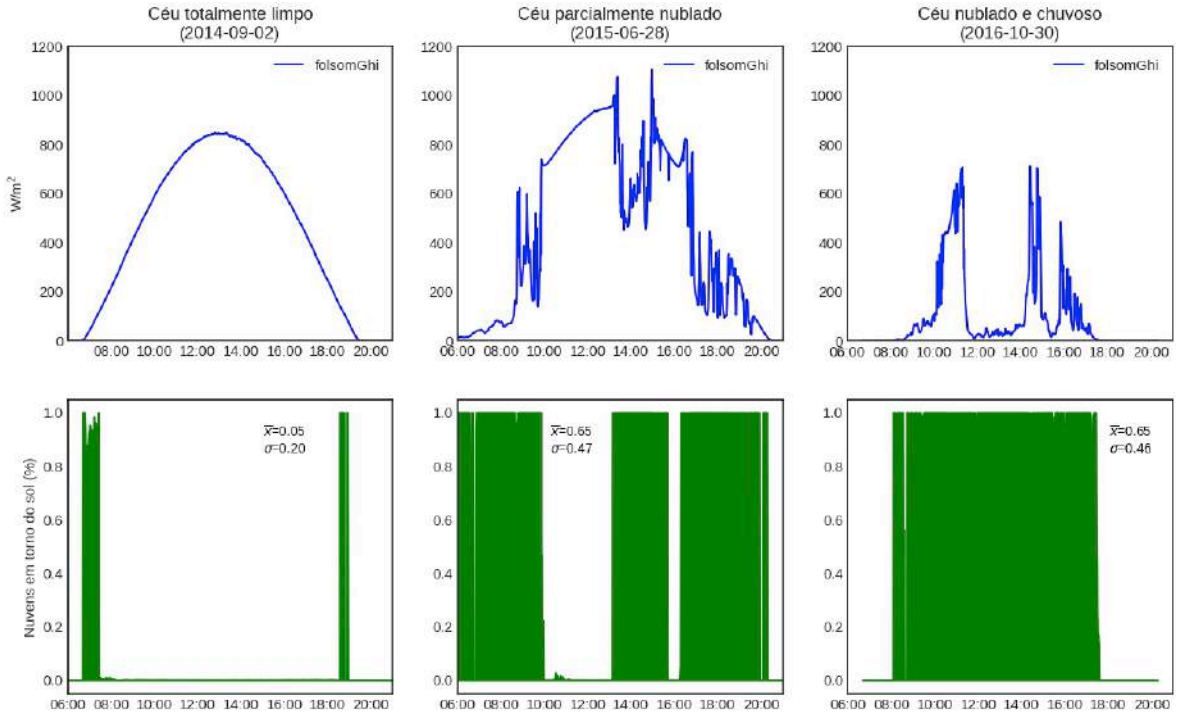

Fonte: O autor, (2022).

Conforme observado, a métrica *Clouds Around Sun* (*CAS*) captura a existência de nuvens na região em torno do sol. No entanto, conforme mencionado, existem inconsistências nos horários de início e final do dia (02/09/2014), assim como originadas pela distinção incorreta entre céu e nuvem dos métodos *RBR* e *Otsu Threshold*.

3.2.5. Irradiância Solar de Céu Limpo

A irradiância solar ideal em dias de céu limpo (*Clear Sky GHI*) pode ser calculada por modelos matemáticos que fornecem a irradiância solar predita para determinados horário e local, independente das imagens totais do céu. Existem dezenas de modelos teóricos propostos e utilizados na literatura científica para predição dos valores de irradiância solar ideal com céu limpo (ANTONANZAS-TORRES et al., 2019). Conforme o modelo, distintos parâmetros de entrada podem ser considerados para as predições de irradiância, tais como os ângulos de altura e de azimute solar, massa de ar, fator de turbidez atmosférica, altitude, localização, temperatura, umidade, horário, data, entre outros (ANTONANZAS-TORRES et al., 2019).

Diante das diversas opções, este estudo utilizou o modelo de Ineichen-Perez (INEICHEN; PEREZ, 2002) com o auxílio da Interface de Programação de Aplicativos (API) *pvlib python* versão 0.9.1 (F. HOLMGREN; W. HANSEN; A. MIKOFSKI, 2018)

para predição da *Clear Sky GHI*. O modelo foi escolhido por sua boa precisão, desempenho de execução e por necessitar somente dos seguintes parâmetros de entrada: data, horário, localização georreferenciada e altitude. Portanto, o cálculo da *Clear Sky GHI* utilizou a localização geográfica da cidade de Folsom/USA (Latitude = 38.6779591 e Longitude = -121.1760583) e sua altitude (67 metros), onde foram coletados os dados (PEDRO; LARSON; COIMBRA, 2019). A Figura 23 exibe exemplos dos valores de irradiância solar GHI (*Clear Sky GHI*) previstos pelo modelo Ineichen-Perez e sua correlação (R^2) com o *Folsom GHI*.

Figura 23 – Comparação da irradiância *Folsom GHI* e *Clear Sky GHI* (Ineichen-Perez).

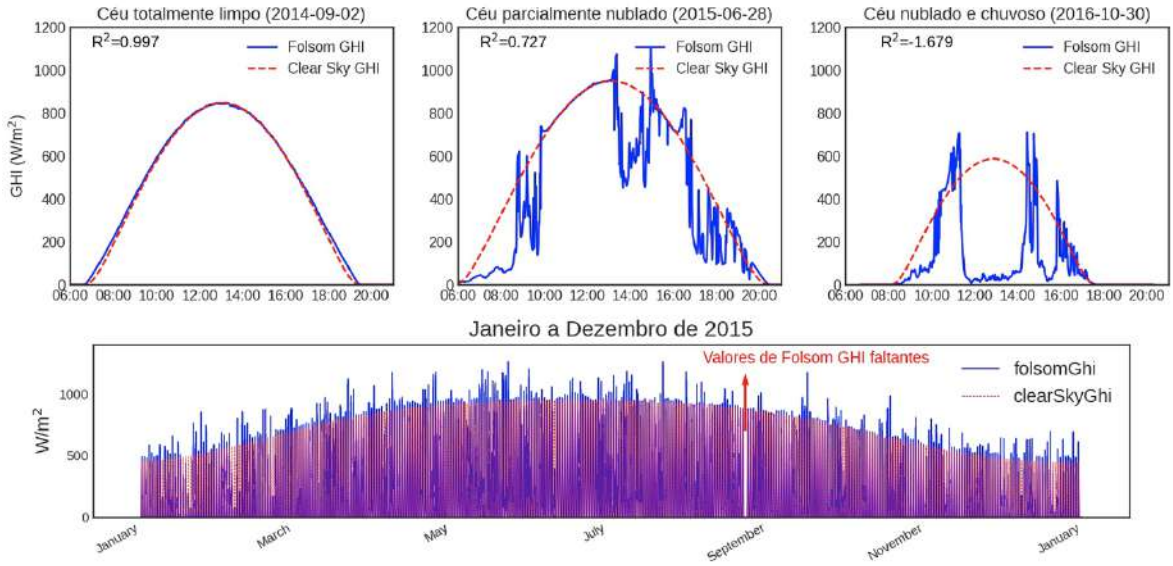

Fonte: O autor, (2022).

Conforme observado acima, os valores de *Folsom GHI* e *Clear Sky GHI* são similares (R^2 = 0,997) para o dia de céu totalmente limpo (02/09/2014). Por outro lado, conforme o esperado devido as condições climáticas, os valores de R^2 diminuem sensivelmente nos outros dois dias de referência. Por fim, vale destacar que o perfil anual e e a intensidade da irradiância *Folsom GHI* de céu limpo, exemplificado pelo ano de 2015, são visivelmente similares ao predito pelo modelo Ineichen-Perez adotado neste estudo.

3.2.6. Métrica de Luminância do Sol

Em imagens digitais é possível calcular a luminância percebida e relativa de uma determinada área da imagem (SZELISKI, 2011). Existem diferentes maneiras de calcular a luminância de um *pixel* conforme o formato da imagem e seu espaço de cores, tais como RGB, HSB, HSL, entre outros (GONZALEZ; WOODS, 2002). Neste estudo foi adotada a

métrica de luminância relativa (Y), a partir da região entorno do sol, denominada de *Sun Luminance*, por meio do padrão ITU-R BT.709-6 (ITU, 2015) e inspirada no estudo de (DEV et al., 2019), os quais definem a luminância (Y) de um *pixel* p sendo computada a partir dos valores lineares dos canais de *Red* (R_{lin}), *Green* (G_{lin}) e *Blue* (B_{lin}) do *pixel* nas imagens RGB, por meio da equação (3.3) (ITU, 2015):

$$Y = 0{,}2126 \times R_{lin} + 0{,}7152 \times G_{lin} + 0{,}0722 \times B_{lin} \quad (3.3),$$

onde, Y representa a luminância relativa do *pixel* p e $R_{lin}, G_{lin}, B_{lin}$ são os lineares valores das componentes de cores vermelho, verde e azul de p.

O estudo de (DEV et al., 2016) avaliou o impacto do tamanho da área a ser considerada no cálculo da luminância em torno do sol e identificou uma correlação de 85% entre a luminância relativa Y e a irradiância GHI diária, durante um mês completo de 2015. Considerando os resultados apresentados por (DEV et al., 2016), o presente estudo adotou a dimensão da área no entorno do sol de 300×300 *pixels*. Vale destacar que a abordagem adotada de cálculo da luminância do sol, adotada no presente estudo, não utilizou os parâmetros da câmera digital, como a abertura (*F-number*), velocidade do obturador (*shutter speed*), e ISO (sensibilidade) considerados em (DEV et al., 2016), pelo fato destes meta dados não estarem disponíveis no *dataset* (PEDRO; LARSON; COIMBRA, 2019). Desse modo, somente foi considerado o uso dos valores da luminância relativa Y (equação (3.3)), posteriormente normalizado.

A Figura 24 representa o processamento de imagens e respectivos valores da métrica *Sun Luminance* nos dias de referências considerados neste estudo. É importante destacar que, caso o sol não seja localizado (Figura 24 – direita), a luminância é calculada para a área central do céu na imagem, ou seja, utilizou-se a mesma estratégia adotada no algoritmo da métrica de *Clouds Around Sun* (Figura 20).

Figura 24 – Processamento de imagens da métrica de *Sun Luminance*.

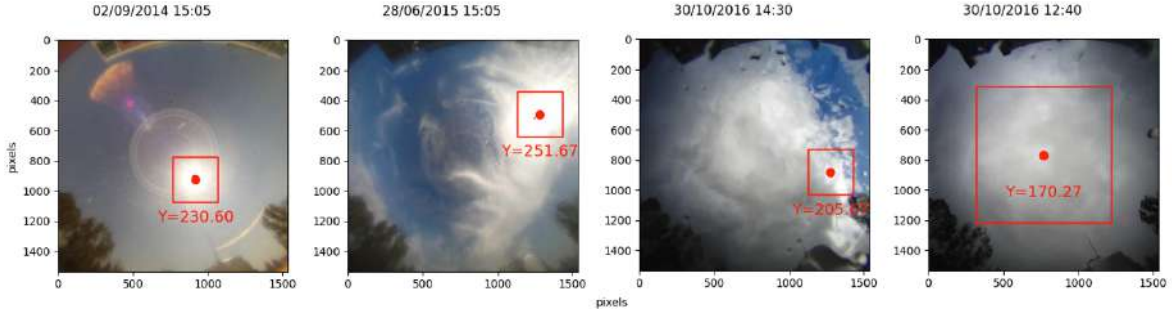

Fonte: O autor, (2022).

Por fim, a Figura 25 mostra o exemplo completo das medidas de *Sun Luminance* normalizadas e produzidas a cada minuto durante os três dias de referência com diferentes condições climáticas. Observa-se um padrão contínuo para o dia de céu limpo (02/09/2014) com Y tendo média $\bar{x} = 0{,}69$ e Desvio Padrão $\sigma = 0{,}31$. Para o dia 28/06/2015 (parcialmente nublado) também se nota um padrão contínuo similar, aproximadamente entre 10h00 e 14h00, quando o céu esteve limpo. Por fim, conforme esperado, no dia com céu nublado e chuvoso (30/10/2016) se observa o menor valor médio de Y ($\bar{x} = 0{,}43$) dentre os três dias de referência.

Figura 25 – Resultado da métrica *Sun Luminance*.

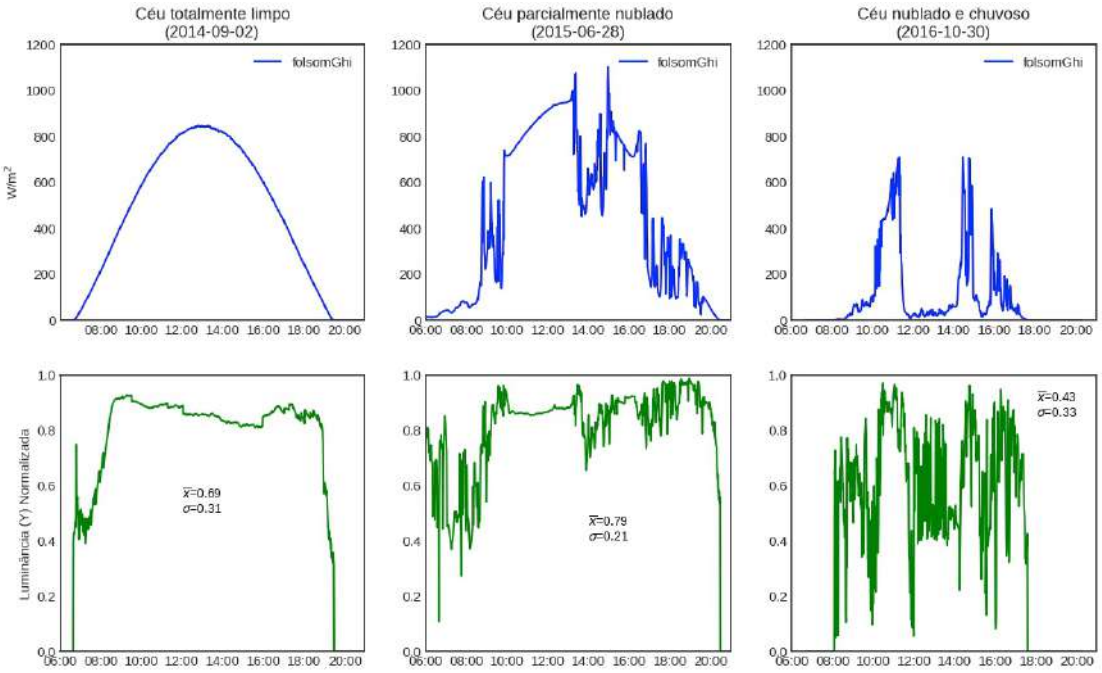

Fonte: O autor, (2022).

3.2.7. Métrica de Luminância do Sol Ajustada

A métrica de luminância do sol ajustada (*Sun Luminance Adjusted*) é calculada para cada imagem de modo igualmente similar a métrica de *Sun Luminance*. No entanto, um pós-processamento adicional é aplicado ao valor da luminância Y_{hm} obtida da imagem plana do céu capturada em determinada hora (h) e minuto (m). Este pós-processamento utiliza um fator de ajuste lf_{hm}, relacionado ao valor de GHI de céu limpo ($clearSkyGHI_{hm}$) esperado na hora h e minuto m em que a imagem foi capturada. Convém destacar que o valores $clearSkyGHI_{hm}$ são produzidos pelo modelo sintético Ineichen-Perez (INEICHEN; PEREZ, 2002), conforme descrito na seção 3.2.5. Desse modo, calcula-se o fator de ajuste lf_{hm} para uma determinada hora h e minuto m do dia em que a imagem foi capturada

(equação (3.4)). Este fator é dado pela razão (proporção) da GHI esperada com céu claro, para aquela hora h e minuto m do dia, em relação a GHI máxima esperada para aquele dia, conforme a equação:

$$lf_{hm} = \frac{clearSkyGHI_{hm}}{max(clearSkyGHI)} \quad (3.4),$$

onde, $clearSkyGHI_{hm}$ é o valor da irradiância GHI de céu limpo no horário $h{:}m$ e fornecido pelo modelo sintético Ineichen-Perez, e $max(clearSkyGHI)$ é o valor máximo diário da irradiância de céu limpo. Por fim, considerando o valor da Luminância Y calculado para a imagem obtida na hora h e minuto m, computa-se o valor da luminância do sol ajustada (Y_{adj}) pela equação (3.5):

$$Y_{adj} = Y_{hm} \times lf_{hm} \quad (3.5),$$

onde, Y_{hm} é luminância do sol obtida na imagem capturada no horário hm, e $lf_{h:m}$ corresponde ao fator de ajuste relativo à irradiância de céu limpo ($clearSkyGHI_{hm}$) para o horário hm. A Figura 26 exibe o resultado gerado pela métrica *Sun Luminance Adjusted* durante os três dias com diferentes condições climáticas. Observa-se que, embora não seja precisa, a métrica captura a tendência das intermitências com o padrão similar a *Clear Sky GHI*.

Figura 26 – Resultado da métrica *Sun Luminance Adjusted*.

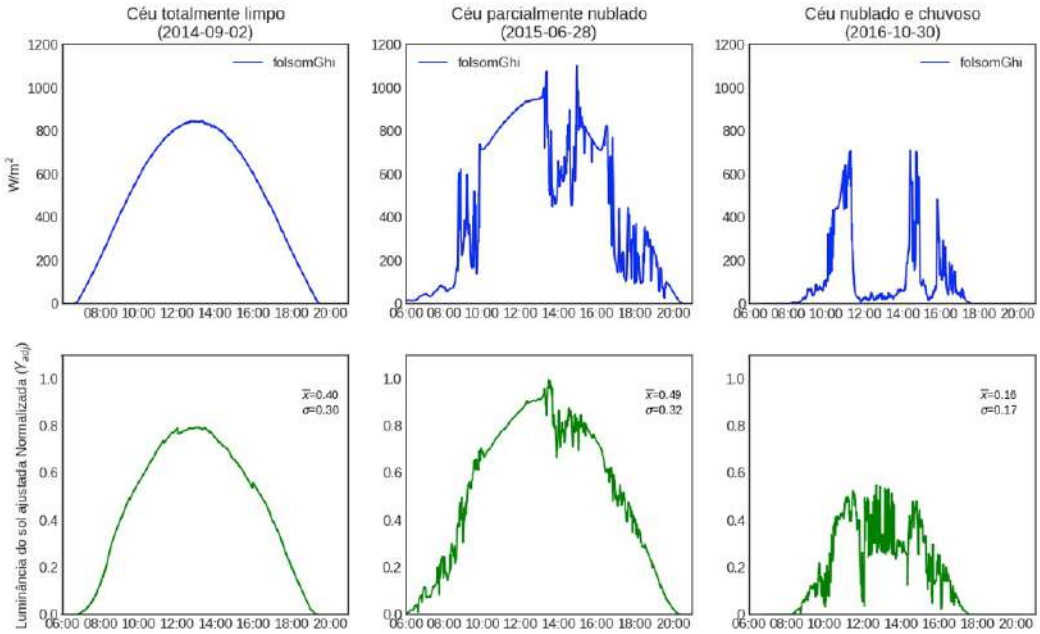

Fonte: O autor, (2022).

3.2.8. Métrica de Localização do Sol

A métrica de localização do sol (*Sun Located*) provê a informação de localização do sol em uma imagem no tempo *t*. Este procedimento é utilizado no algoritmo da métrica de *Clouds Around Sun* (Figura 20). Desse modo, os valores de *Sun Located* relativo a cada imagem plana retorno os valores de 1 (*True*) se o sol foi localizado na imagem, e 0 (*False*) caso contrário. Vale destacar, novamente, que o algoritmo de localização do sol baseia-se no estudo de (SAVOY et al., 2016).

A Figura 27 exibe o resultado da métrica de localização do sol (*Sun Located*) durante os três dias de referência. Observa-se que em determinados períodos dos dias nublado (28/06/2015) e chuvoso (30/10/2016) o sol não foi localizado, possivelmente devido a quantidade e a densidade de nuvens no céu. Além disso, quando o sol nasce ou se põe, ou seja, horários de início e fim do dia, o algoritmo falha em não o localizar, possivelmente devido ao ângulo solar e sua intensidade

Figura 27 – Resultado da métrica *Sun Located*.

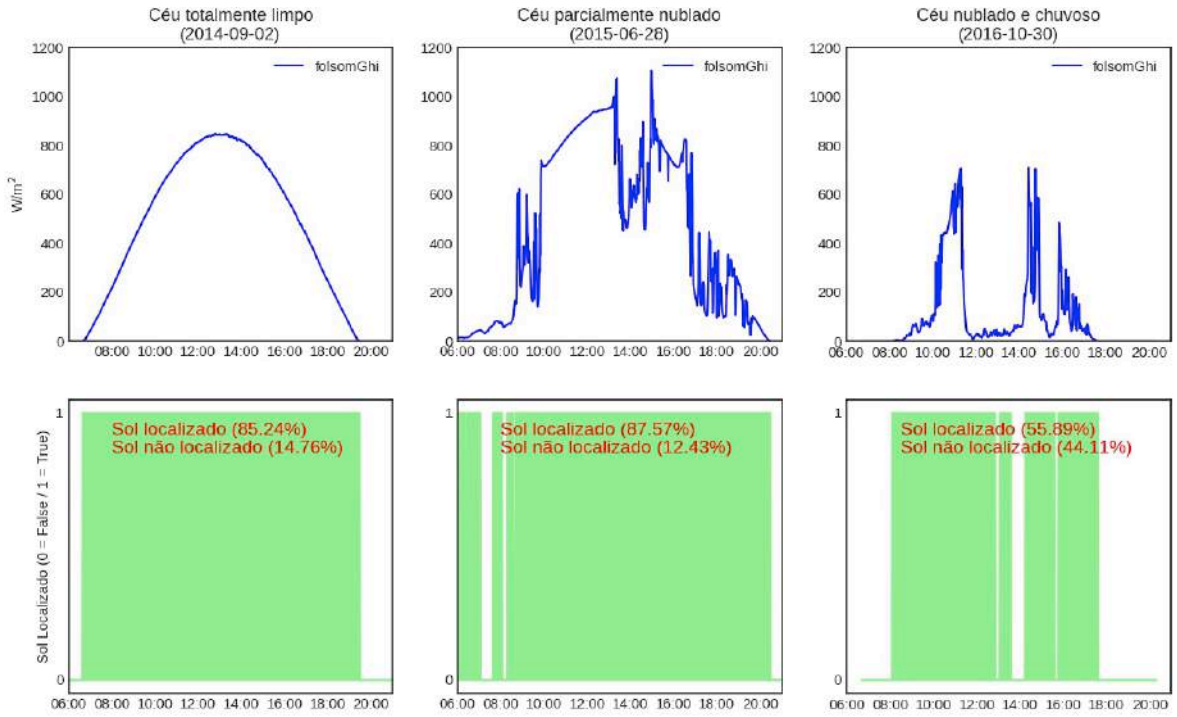

Fonte: O autor, (2022).

3.2.9. Métrica Taxa de Pixels Brancos

Em condições normais podemos olhar para o céu e observar duas cores que se destacam: a cor azul que possui o comprimento de onda mais curto e se espalha mais

intensamente pelas moléculas da atmosfera (Efeito Tyndall) (KERKER, 1971), e a cor branca com variações em tons acinzentados, que são originadas pelas gotículas de água que formam as nuvens em dias nublados. Partindo dessa perspectiva, a métrica *White Pixel Ratio* (WPR) representa a taxa de pixels de cor branca na área relativa ao céu de uma determinada imagem plana, de acordo com a equação (3.6):

$$WPR = 100 \times \frac{totalWhitePixels}{totalSkyAreaPixels} \quad (3.6),$$

onde, $totalWhitePixels$ é quantidade de pixels na imagem com valores >= 240 em qualquer um dos canais de cores R, G e B da imagem, e $totalSkyAreaPixels$ é a quantidade total de pixels existentes na área do céu na imagem. Embora a cor branca seja, geralmente, associada ao valor de 255 nos canais R, G e B, definiu-se neste estudo o limiar de 240 para se incorporar as tonalidades acinzentadas das nuvens mais densas. A Figura 28 exibe os valores da métrica WPR para os três dias de referência com diferentes condições climáticas. Durante os três dias observa-se que existe um padrão capturado pela métrica WPR, principalmente entre períodos de céu limpo e nublado.

Figura 28 – Resultado da métrica *White Pixel Ratio* (WPR).

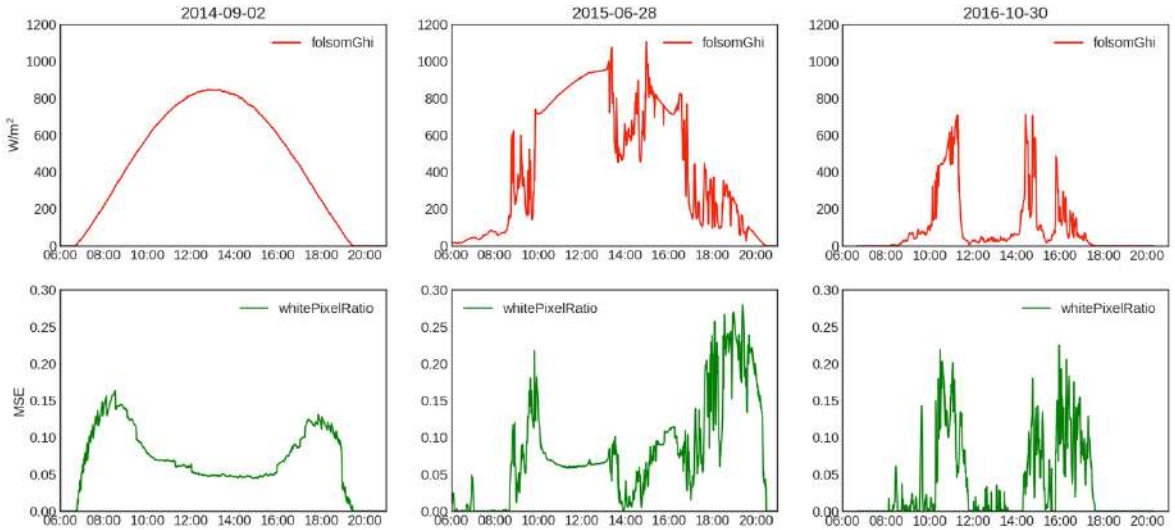

Fonte: O autor, (2022).

Figura 29 – Entradas (*inputs*) e saída (*output Folsom GHI*) do MHP proposto.

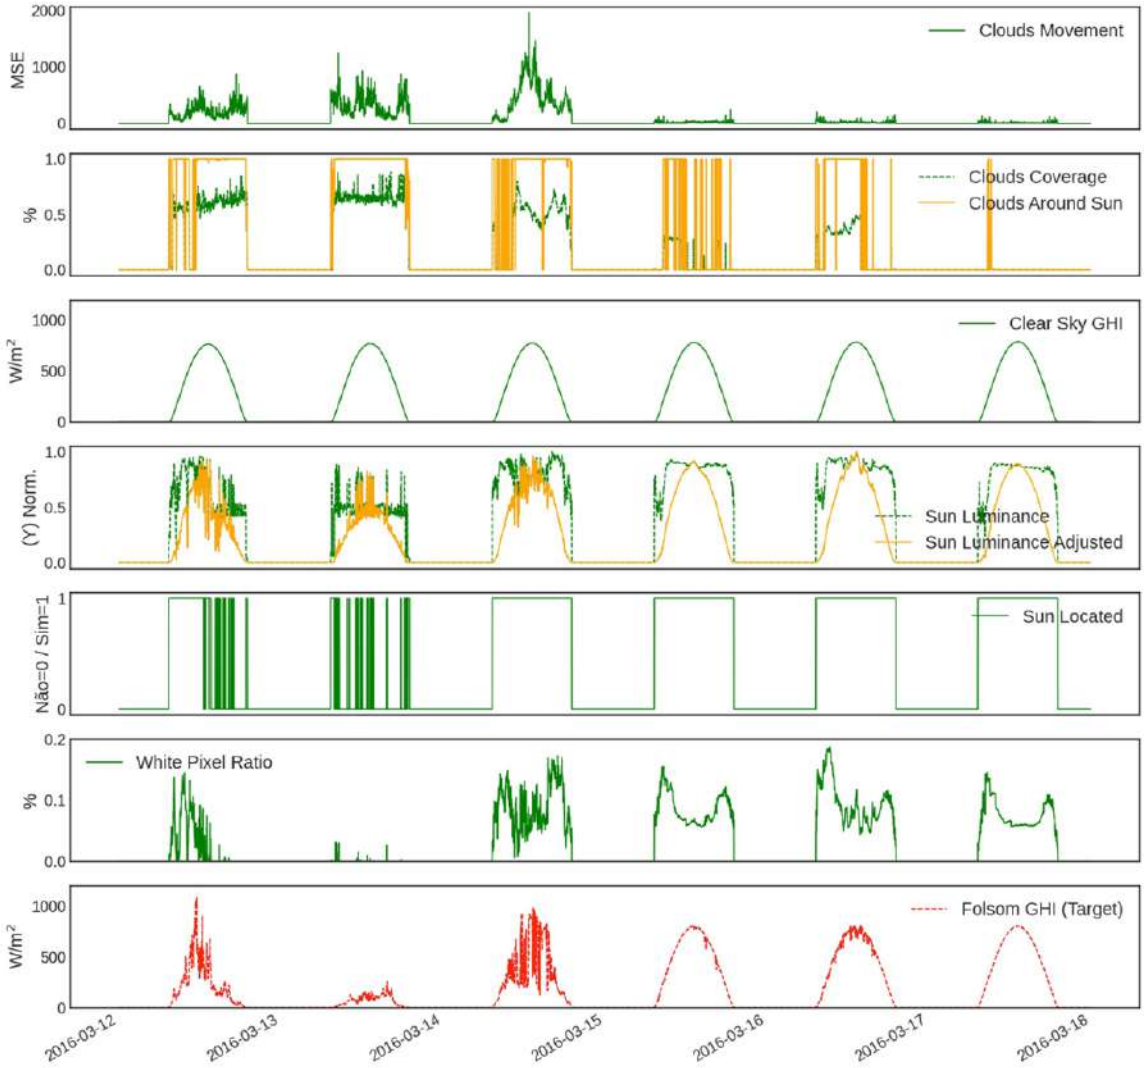

Fonte: O autor, (2022).

A partir do Processamento de Imagens (PI) de cada imagem total do céu, as métricas descritas nesta seção são computadas e fornecidas como entrada (*input*) para os algoritmos de Aprendizado de Máquina (AM) realizarem as predições de curto prazo. Como exemplo, a Figura 29 exibe as entradas (*inputs*) relativas as características ($x_1 \ldots x_8$) calculadas a partir de cada imagem total do céu, bem como a variável alvo (*target*) a ser predita (*Folsom GHI*) durante o período de 6 dias completos (12 a 17/03/2016). Além destas características, os modelos de predição baseados em Aprendizado de Máquina, a serem descritos na próxima seção, utilizam as informações de data, horário, localização (latitude e longitude) e altitude da UG, conforme detalhado na Figura 10.

3.3. APRENDIZADO DE MÁQUINA

Esta seção descreve os dois seguintes modelos de Aprendizado de Máquina (AM) que foram desenvolvidos e avaliados: *MultiLayer Perceptron* (MLP) (RUSSELL; NORVIG, 2016) e *Light Gradient Boosting Machine* (LightGBM) (KE et al., 2017). É importante destacar aqui que o modelo MLP foi selecionado a partir das análises realizadas em estudos previamente publicados neste projeto de pesquisa (MACIEL et al., 2021; MACIEL; LEDESMA; ANDO JUNIOR, 2021; SILVA et al., 2022; WENTZ et al., 2020, 2022). Por outro lado, o modelo LightGBM foi selecionado por apresentar a melhor acurácia de predição dentre diversos modelos de regressão comparados com o framework PyCaret (ALI, 2020).

Conforme descrito na Figura 10, as características $x_1 \ldots x_{11}$ constituem as entradas dos modelos de predição baseados AM. O desempenho da acurácia destes modelos de predição no MHP, considerando os horizontes de curto prazo de 1, 5, 10, 15, 30 e 60 minutos, incluindo de outras propostas existentes na literatura científica serão comparados e avaliados na seção 4.

3.3.1. *MultiLayer Perceptron* (MLP)

Conforme mencionado na seção 2.3, historicamente, o modelo de AM mais utilizado na PGESF são as Redes Neurais Artificiais (RNA) (BLAGA et al., 2019; MACIEL; LEDESMA; ANDO JUNIOR, 2021). Uma RNA funciona de modo similar aos neurônios do cérebro Humano, sendo capaz de resolver problemas de aproximação, classificação, padronização, otimização e predição com regressão (REZENDE, 2003; RUSSELL; NORVIG, 2016).

A Figura 32 (a) exibe o diagrama esquemático de um neurônio artificial, onde x_1, $x_2, \ldots x_n$, correspondem as entradas. Para cada entrada x_i existe um peso w_i correspondente a soma das entradas x_i que é ponderada pelos pesos w_i, e a saída linear u, onde $u = \sum \mathrm{w_i x_i}$. A ativação de saída y do neurônio é obtida pela aplicação da função f a saída linear u, denotada por $y = \mathrm{f(u)}$. A função f é conhecida como função de ativação e pode assumir diversas formas não lineares (REZENDE, 2003).

Já Figura 32 (b) exibe o exemplo de uma RNA composta por 3 entradas, uma única camada oculta com 4 neurônios e duas saídas (y_1 e y_2). No entanto, considerando os resultados observados nas pesquisas previamente publicadas em (MACIEL et al., 2021;

WENTZ et al., 2020, 2022), nas quais foram avaliadas as acurácias de modelos de RNA na PPSEG, este estudo empregou RNA do tipo *MultiLayer Perceptron* (MLP), com a função de ativação *Rectified Liner Unit* (RELu) e algoritmo de treinamento *Backpropagation* (RUSSELL; NORVIG, 2015).

Figura 30 – Representação de (a) um neurônio artificial e (b) e uma RNA do tipo MLP.

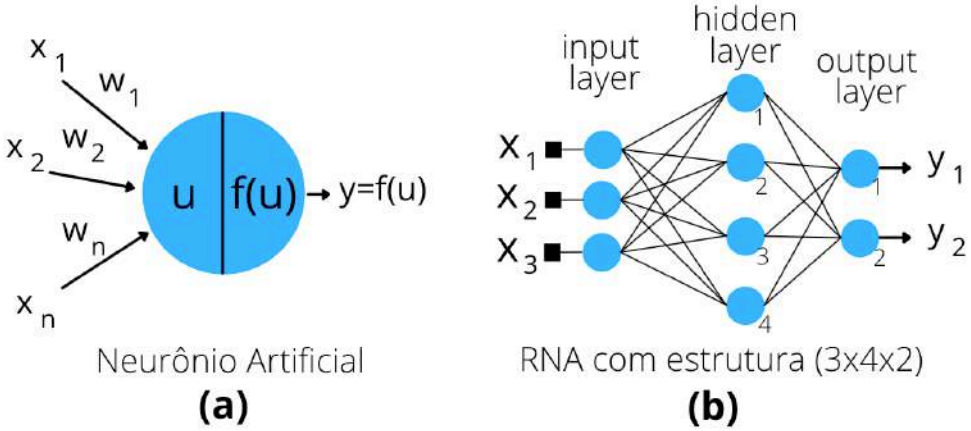

Fonte: O autor, (2022).

3.3.2. *Light Gradient Boosting Machine* (LightGBM)

Existem diversos algoritmos de AM com diferentes abordagens (RUSSELL; NORVIG, 2016) que podem ser usados em problemas de regressão, no qual a variável a ser predita é um valor numérico real, tal como a GHI (*W/m2*) ou energia gerada (*KW/h*). Um conhecido algoritmo aplicado em problemas de classificação e predição é o *Gradiente Boosting* (VOYANT et al., 2017), cujo objetivo consiste em produzir um melhor modelo preditivo a partir da combinação (*Ensemble*) modelos de previsão fracos, geralmente baseados em Árvores de Decisão (*Decision Tree* – DT) (RUSSELL; NORVIG, 2016).

Conforme exibido na Figura 31 (a), uma DT é uma ferramenta de apoio à decisão que usa uma estrutura de árvore para se tomar de decisões condicionais em função das variáveis ($x_1 \ldots x_n$) e gerar os possíveis resultados ($y_a \ldots y_z$) nas folhas. Um regressor baseado em *Gradient Boosting* cria submodelos fracos com DTs Figura 31 (b), que tentam minimizar o erro residual das predições de submodelos anteriores, tanto em problemas de regressão ou classificação. Ao final os submodelos fracos são combinados para compor um modelo de *Gradient Boosting* mais robusto Figura 31 (c).

A partir da abordagem do *Gradient Boosting*, a Microsoft desenvolveu um algoritmo distribuído otimizado e eficiente para a classificação e regressão, denominado

Light Gradient Boosting Machine (LightGBM), que usa duas técnicas adicionais de *Gradient Based On-Side Sampling* (GOSS) e *Exclusive Feature Bundling* (EFB) (KE et al., 2017). A ideia também consiste em construir vários modelos (DT) simples e combiná-los em um modelo *Ensemble* mais robusto, com tempo de treinamento menor e paralelizável.

Figura 31 – Representação do algoritmo de *Gradient Boosting*.

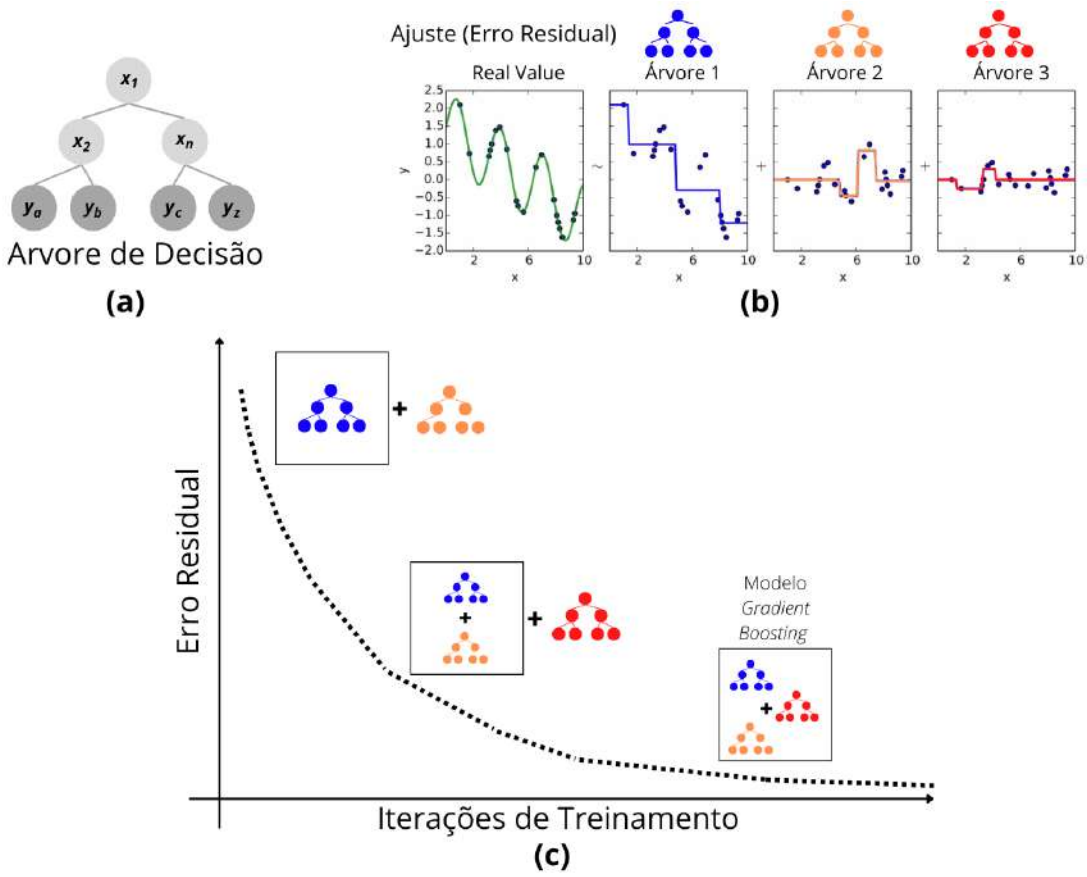

Fonte: O autor, (2022) e (b) Adaptado de (PRETTENHOFER; LOUPPE, 2016).

Neste estudo foi utilizada a implementação do algoritmo LightGBM, disponível no na *Application Program Interface* (API) PyCaret (ALI, 2020), uma biblioteca com código aberto na linguagem Python que automatiza o fluxo de trabalho no desenvolvimento de modelos de AM. Vale ressaltar que o modelo LightGBM foi selecionado por apresentar a melhor acurácia de predição após a análise comparativa realizada na API PyCaret com mais de 20 modelos experimentais de regressão disponibilizados pela ferramenta[2].

Por fim, no sentido de facilitar a reprodutibilidade dos experimentos de análise do MHP desenvolvido no presente estudo, a próxima seção apresenta o método de avaliação

[2] Listagem dos modelos disponível em < https://pycaret.readthedocs.io/en/latest/api/regression.html >

realizado com o MHP, detalhando o protocolo, a estrutura e a configuração experimental utilizadas no Processamento de Imagens (PI) e nas predições dos modelos de Aprendizado de Máquina (AM) e Aprendizado Profundo (AP) avaliados.

3.4. AVALIAÇÃO EXPERIMENTAL

O Método Híbrido de Predição (MHP) proposto na Figura 8 é composto pelos componentes de Processamento de Imagens (PI) e Aprendizado Máquina (AM), ambos detalhados na (Figura 9). Esta seção descreve o método experimental utilizado para analisar e validar, modo quantitativo, a acurácia de predição do MHP desenvolvido. Desse modo, a avaliação experimental quantitativa foi projetada para contemplar as duas seguintes análises, cuja as diferenças estão destacadas em cor vermelha na Figura 32:

Figura 32 – Delineamento da avaliação experimental do MHP.

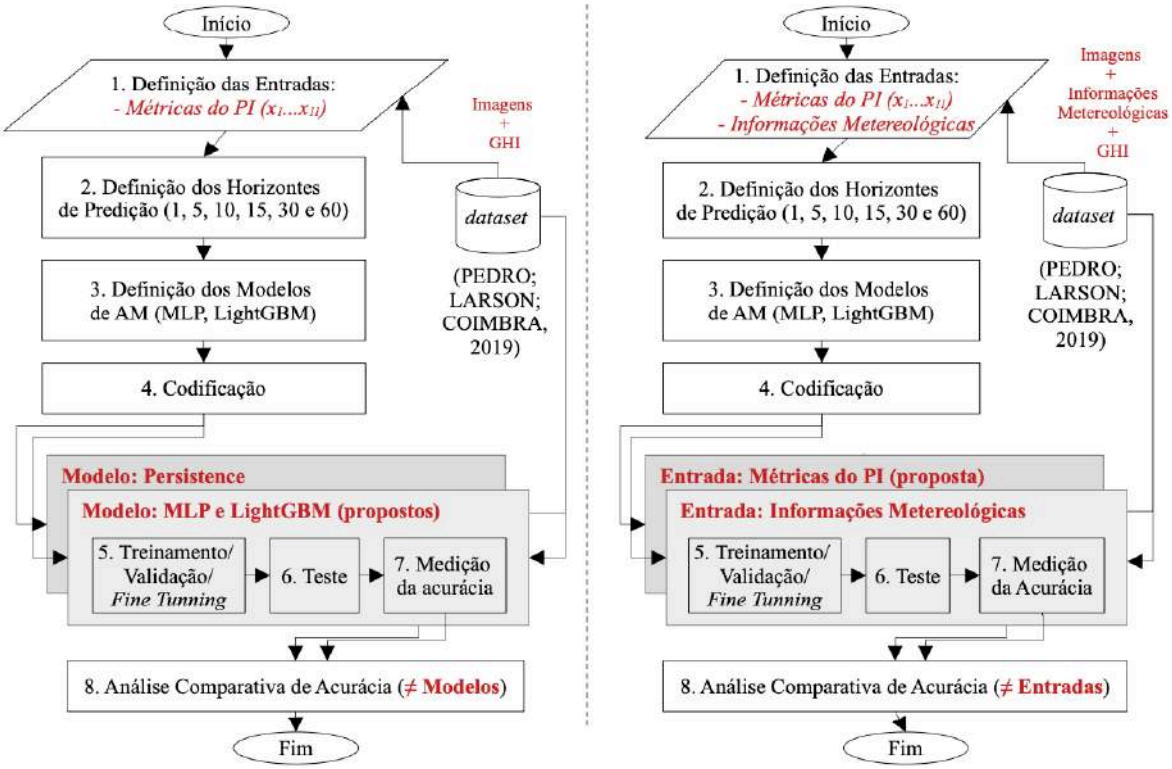

Fonte: O autor, (2022).

(i) **Análise de Modelos de AM**: esta análise tem o objetivo de mensurar a acurácia do MHP desenvolvido com diferentes modelos de predição de AM (*Persistence*, MLP e LightGBM) em cada horizonte de predição considerado (1, 5, 10, 15, 30, e 60 minutos). As entradas desta avaliação (i) são as Métricas do PI ($x_1 \dots x_{11}$) calculadas a partir de cada imagem total do céu, com respectivos valores de saída GHI existentes no *dataset* (PEDRO; LARSON; COIMBRA,

2019). Ao final desta análise busca-se conhecer e mensurar o modelo de AM com a melhor acurácia de predição no MHP desenvolvido, considerando o uso das métricas de PI e os horizontes de predição avaliados. Além da comparação da acurácia com o modelo de referência base *Persistence*, os resultados de estudos similares existentes na literatura científica também são integrados nesta análise;

(ii) **Análise de Tipos de Entrada:** esta análise tem o objetivo de mensurar a acurácia dos modelos de predição a partir de dois conjuntos diferentes dados de entrada (*inputs*), ou seja, se existe diferença na acurácia de predição do MHP entre o uso das métricas do Processamento de Imagens (PI) do céu ($x_1 \ldots x_8$) e o uso de Informações Meteorológicas tradicionais, tais como a temperatura do ar, umidade, pressão atmosférica, velocidade e direção dos ventos, etc. Portanto, a acurácia de modelos de AM similares utilizando estes dois conjuntos de variáveis de entrada, nos horizontes de predição de curto prazos (1, 5, 10, 15, 30, e 60 minutos) são mensuradas e comparadas. Ao final desta análise busca-se conhecer o impacto do uso conjunto das métricas de PI, proposto neste estudo, em relação ao uso de variáveis meteorológicas tradicionalmente aplicadas na PGESF (JUNCKLAUS MARTINS et al., 2022).

A Tabela 12 apresenta a configuração das análises experimentais quantitativas realizadas com o MHP (proposto), e detalha as variáveis de entradas, saída, horizontes e modelos de predição, incluindo os dados utilizados para treinamento, validação, testes e as métricas de desempenho de acurácia empregadas nas análises. Nas análises experimentais do MHP foram considerados dois conjuntos de variáveis de entrada, sendo: as Métricas de PI extraídas das imagens do céu com 8 variáveis, e as Informações Meteorológicas tradicionais, também totalizando 8 variáveis de entrada.

De modo complementar, a Tabela 13 exibe a abordagem *k-fold cross-validation* (RUSSELL; NORVIG, 2016) adotada para o treinamento, validação e testes (com k=3, ou seja, *3-fold*) dos modelos de AM utilizados neste estudo. Ou seja, a partir do período total de 3 anos de informações disponíveis no *dataset*, 2 anos são usados para treinamento dos modelos, dos quais 20% são utilizados para validação durante o treinamento. Ao final, 1 ano completo (33% do *dataset*) é utilizado para teste do modelo considerando abordagem de *3-fold cross-validation* (PEDREGOSA et al., 2011).

Tabela 12 – Configuração da avaliação experimental.

Avaliação Experimental	Análise dos Modelos de AM	Análise dos Tipos de Entrada	
1. Entradas Utilizadas (*inputs*)	***8 Métricas de PI*** Mês, hora e minuto *Clouds Movement* *Clouds Coverage* *Clouds Around Sun* *Clear Sky GHI* *Sun Luminance* *Sun Luminance Adjusted* *Sun Located* *White Pixels Rate*	***8 Métricas de PI*** Mês, hora e minuto *Clouds Movement* *Clouds Coverage* *Clouds Around Sun* *Clear Sky GHI* *Sun Luminance* *Sun Luminance Adjusted* *Sun Located* *White Pixels Rate*	***8 Informações Meteorológicas*** Mês, hora e minuto *Estação do ano* *Temperatura do ar* *Umidade do ar* *Pressão atmosférica* *Velocidade do vento* *Velocidade máxima do vento* *Direção do vento* *Precipitação (chuva)*
2. Saída *(output)*	GHI	GHI	GHI
3. Horizontes de Predição	1, 5, 10, 15, 30 e 60 minutos	1, 5, 10, 15, 30 e 60 minutos	1, 5, 10, 15, 30 e 60 minutos
4. Modelos de Predição	Persistence MLP LightGBM	Persistence MLP LightGBM	Persistence MLP LightGBM
6. Treinamento Validação Teste	2 anos 4,8 meses (20%) 1 ano	2 anos 4,8 meses (20%) 1 ano	2 anos 4,8 meses (20%) 1 ano
7. Medidas de Acurácia	R^2, *(n)RMSE, MAE, MSE* e *SS*	R^2, *(n)RMSE, MAE, MSE* e *SS*	R^2, *(n)RMSE, MAE, MSE* e *SS*

Fonte: O autor, (2022).

É importante destacar que, a natureza sazonal característica do perfil anual de irradiância solar pode variar de um ano para o outro. Por exemplo, um ano pode ter diferentes quantidades e padrões de dias chuvosos ou de céu limpo, em relação a outro. Partindo deste princípio, cada modelo de predição foi treinado, validado e testado 3 vezes, de modo que seu teste contemplou o período integral (3 anos) disponível no *dataset*. Além dos resultados de cada um dos 3-*folds* de teste utilizados, a média aritmética de acurácia destas 3 amostras de cada modelo de predição foi calculada e disponibilizada nas análises.

Tabela 13 – Divisão do *dataset* para validação e teste cruzado (*3-folds*) de cada modelo.

	***fold* /Ano**	**2014**	**2015**	**2016**
Modelo de Predição	*fold-1*	Teste	Treinamento	Treinamento
	fold-2	Treinamento	Teste	Treinamento
	fold-3	Treinamento	Treinamento	Teste

Os dados de validação correspondem a 20% (4,8 meses) dos dados de Treinamento em cada *fold*.

Fonte: O autor, (2022).

Com o intuito de promover a reprodutibilidade deste estudo, a Tabela 14 apresenta a configuração experimental estrutural e de hiperparâmetros adotados em cada modelo de AM avaliado no MHP. A estrutura e parametrização do modelo MLP foi selecionada a partir de estudos previamente publicados nesta linha de pesquisa (MACIEL et al., 2021; MOUSSA et al., 2022; SERRANO ARDILA et al., 2022; WENTZ et al., 2020, 2022).

Tabela 14 – Configuração estrutural e hiperparâmetros dos modelos de AM do MHP.

Modelo	**Estrutura e Valores dos Principais Hiperparâmetros Utilizados**	**Otimização de Hiperparâmetros (*Fine Tunning*)**
Persistence	Equação (2.1) da página 48	Não aplicável
MLP	Activation Function = ReLU Epochs = 200 Learn Rate = 0,001 Batch Size = 128 Structure {input + *hidden(s)_layer(s)* + output} = {11 + *30* + *210* + *150* + 1} Neurons in Input Layer = 11 Hidden Layer(s) Number = 3 Neurons in Output Layer = 1 Total Neurons = 402	*Random Grid Search* com o *framework* Optuna (AKIBA et al., 2019)
LightGBM	bagging_fraction = 0,6; bagging_frequence = 4; boosting_type = 'gbdt'; colsample_bytree = 1,0; feature_fraction = 0,9; importance_type = 'split'; learning_rate = 0,05; max_depth = -1; min_child_samples = 96; min_child_weight = 0,001; min_split_gain = 0,7; n_estimators = 180; num_leaves=10; subsample = 1.0; subsample_freq = 0	*Random Grid Search* com a API PyCaret (ALI, 2020)

Fonte: O autor, (2022).

3.5. DATASET, MATERIAIS E TECNOLOGIAS

A base de dados (*dataset*) é um componente importante para a construção e avaliação de modelos de Aprendizado de Máquina da Inteligência Artificial (RUSSELL; NORVIG, 2016). Este estudo empregou um amplo *dataset* padronizado, com qualidade controlada e que foi construído para especificamente para estudos na PGESF (PEDRO; LARSON; COIMBRA, 2019). O *dataset*, aqui denominado de *Folsom Dataset*, disponibiliza informações históricas de irradiância solar, meteorológicas e imagens totais do céu coletadas na cidade de Folsom na Califórnia, Estados Unidos da América (EUA), durante o período completo de três anos (2014–2016) com amostras disponíveis na resolução temporal mínima de 1 minuto.

A Tabela 15 sumariza o número de amostras anuais e os detalhes de todas as variáveis *dataset,* disponível em (PEDRO; LARSON; COIMBRA, 2019).

Tabela 15 – Informações do *dataset* (PEDRO; LARSON; COIMBRA, 2019).

Variáveis do *dataset*	**Tipo de Informação**	**Horizonte** (minutos)	**Número de Amostras**			
			2014	**2015**	**2016**	**Total**
year, month, day, hour, minute	Temporal	1	250.579	263.023	261.961	775.563
All-Sky Image	Imagem	5	250.574	263.018	261.956	775.548
Air temperature, relative humidity, atmospheric pressure, wind speed, wind direction, maximum wind speed, precipitation	Meteorológica	10	250.569	263.013	261.951	775.533
		15	250.564	263.008	261.946	775.518
		30	250.549	262.993	261.931	775.473
Global Horizontal Irradiance (GHI)	Irradiância	60	250.519	262.933	261.871	775.323

Fonte: O autor, (2022).

O desenvolvimento do MHP proposto neste estudo foi realizado por meio da linguagem de programação Python 8.2 (ROSSUM, 2020), escolhida por seu alto nível de abstração e ampla disponibilidade de Interfaces de Programação Aplicada (API's). As principais API's utilizadas neste estudo contemplam:

- **Programação e processamento de imagens**: *Pandas, Numpy, Seaborn, DateTime* (ROSSUM, 2020), *OpenCV* e *PIL* (GONZALEZ; WOODS, 2002; SZELISKI, 2011) e *pvlib* (F. HOLMGREN; W. HANSEN; A. MIKOFSKI, 2018);
- **Aprendizado de Máquina**: *Scikit-Learn* (PEDREGOSA et al., 2011), Optuna *Optimization Framework* (AKIBA et al., 2019), PyCaret (ALI, 2020), *Tensorflow* e *Keras* (DÜRR; SICK; MURINA, 2020; MINING, 2019);
- **Análise dos resultados**: software de tabulação de dados Libre-Office Calc, linguagem de programação Python com a biblioteca *Matplotlib*;
- **Ambiente de desenvolvimento**: no desenvolvimento das métricas de Processamento de Imagens (PI) utilizou-se o ambiente de desenvolvimento integrado (IDE) PyCharm e Python versão 8.2. A construção dos modelos de Aprendizado de Máquina foi realizada no ambiente de desenvolvimento online de programação colaborativa Google Colab versão Pro (BISONG, 2019).

O hardware utilizado no desenvolvimento (codificação) geral do MHP foi realizado em um computador MacBook Pro M1 (2020), com 8 GB de memória RAM e 512 GB de armazenamento. Os modelos de predição de Aprendizado de Máquina (AM) foram desenvolvidos com máquina virtual do ambiente Google Colab Pro e Unidade de Processamento Gráfico (GPU) Nvidia Tesla T4 e P100, com 12 e 24 GB de memória RAM, respectivamente.

3.6. CONSIDERAÇÕES FINAIS

Esta seção descreveu a metodologia do presente estudo e apresentou o delineamento metodológico, incluindo o *dataset*, os materiais e as adotados no desenvolvimento e análise experimental do Método Híbrido de Predição (MHP) proposto. A próxima seção apresenta os resultados e a discussão sobre o MHP proposto, abordando as métricas de PI, os modelos de predição baseados em AM e os resultados de acurácia do MHP de modo quantitativo e qualitativo.

4. RESULTADOS E DISCUSSÃO

Com o intuito de verificar e responder as hipóteses desta pesquisa (seção 1.1), esta seção apresenta e discute os resultados da avaliação experimental do Método Híbrido de Predição (MHP) proposto neste estudo. Inicialmente é abordada a comparação do desempenho da acurácia do MHP com diferentes modelos de predição (seção 3.3) baseados em Aprendizados de Máquina (AM) (Figura 32 - Análise de Modelos de AM). Em seguida, a comparação empírica da acurácia de predição entre o MHP e estudos similares da literatura científica é apresentada e discutida para os horizontes de predição de curto prazo avaliados (1, 5, 10, 15, 30 e 60 minutos).

Posteriormente, são abordados e discutidos o desempenho de predição do MHP utilizando dois tipos de conjuntos distintos de dados de entrada. O primeiro consiste no uso conjunto das Métricas de Processamento de Imagens (propostas neste estudo e descritas na seção 0). Já o segundo conjunto corresponde ao uso de informações meteorológicas tradicionais (descritas na Tabela 15), conforme delineamento experimental exibido na Figura 32 - Análise de Tipos de Entrada. Por fim, ao final desta seção é apresentada a análise qualitativa das características do MHP proposto e a investigação com a validação das hipóteses desta pesquisa.

4.1. ACURÁCIA DE PREDIÇÃO

O Método Híbrido de Predição (MHP), proposto neste estudo, foi desenvolvido a partir da premissa de que a imagem local do céu (*all-sky*) contém, implicitamente, informações suficientes para predição da irradiância solar, e consequentemente, da energia fotovoltaica gerada em horizontes de curto prazo. Nesse sentido, este estudo desenvolveu e/ou utilizou um grupo de métricas de Processamento de Imagens (PI) (seção 0) que, de modo conjunto, capturam explicitamente características importantes relativas à existência, formato, tipo e movimento das nuvens, as quais influenciam diretamente as intermitências da irradiância solar e podem ser extraídas das imagens *all-sky* em câmeras locais apontadas ao céu.

Embora diferentes técnicas de Processamento de Imagens tenham sido aplicadas na PGESF durante o a última década (seção 2.3.3.5), este estudo propôs e desenvolveu uma inédita abordagem híbrida de predição (MHP) que captura um conjunto de medidas de características (métricas) das imagens *all-sky* relevantes à PGESF, buscando fornecer aos modelos de AM informações úteis e relevantes para subsidiar e facilitar o processamento

das predições de curto prazo (1 a 60 minutos). Portanto, utilizando estas métricas de PI é apresentado o desempenho de predição do MHP com os dois algoritmos de AM adotados neste estudo: o MLP e o LightGBM, ambos detalhados na seção 3.3. Além disso, para fins de comparação com as propostas da literatura científica, também são descritas e discutidas qualidade das predições de modelos de PGESF com características similares ao MHP desenvolvido.

O MHP proposto possui uma abordagem de processamento das predições do tipo caixa-cinza (*gray-box*), pois, realiza predições utilizando um processamento híbrido que, explicitamente, executa a extração de um conjunto de características das imagens do céu (*all-sky*) com técnicas de Processamento de Imagem (PI). Este conjunto de características, também denominadas de métricas de PI, são então fornecidas para os modelos de Aprendizado de Máquina (AM) executarem as predições em determinado horizonte de curto prazo. Com o intuito de se verificar a acurácia de predição do MHP, realizou-se avaliação experimental, detalhada na Figura 32 - Análise dos Modelos de AM (seção 3.4), para os horizontes de 1, 5, 10, 15, 30 e 60 minutos.

Os resultados da acurácia de predição do MHP com os modelos de AM (MLP e LightGBM) aplicando as métricas de PI são exibidos na Tabela 16, conjuntamente com as acurácias do modelo de referência (*Persistence*). As medidas dos erros residuais de RMSE, MAE, nRMSE, R^2 e SS são apresentadas para cada um dos 3-*folds cross-validation*. Além da média ($\bar{x}$) e do desvio padrão (σ) dos modelos, considerando todos os horizontes conjuntamente, também é exibida a Acurácia Média Geral do Modelo que sumariza os erros de cada modelo considerando os 3-*folds cross-validation*.

Os resultados das predições alcançadas com o MHP proposto em relação ao modelo de referência (*Persistence*) demonstram acurácias de SS = -85,9%, -0,6%, 10,4%, 18,6%, 27,3% e 45,6% para horizontes de 1, 5, 10, 15, 30 e 60 minutos, respectivamente. Portanto, o MHP demonstrou uma qualidade de predição inferior ao modelo de referência para o horizonte de 1 minuto, similar para 5 minutos e superior para 10, 15, 30 e 60 minutos.

Observa-se que no modelo de referência, o erro das predições aumenta conforme o horizonte de cresce. Para o horizonte de 1 minuto a frente, o modelo *Persistence* exibe melhor habilidade de predição em relação aos modelos avaliados com o MHP proposto. Conforme observado na literatura (BLAGA et al., 2019; VOYANT; NOTTON, 2018), a acurácia dos modelos de referência, especificamente, aumenta conforme o horizonte de

predição diminui, pois, a partir do tempo *t*, o modelo de referência considera que o valor predito (*P*) no próximo horizonte *h* permanece igual ao atual, ou seja, $P(t+h) = P(t)$. Desse modo, quanto maior o intervalo de medição, maior será a variação, ou taxa de erro, da predição do modelo de referência e, assim, a variação da GHI para o horizonte de 1 minuto é relativamente menor nos horizontes de 5 ou mais minutos avaliados neste estudo.

Além disso, a maioria dos estudos que adotam múltiplos horizontes de predição, poucos apresentam dados para o horizonte de 1 minuto e, simultaneamente outros maiores, sendo uma exceção o estudo de (DISSAWA et al., 2021a) que também é avaliado neste estudo (Tabela 17). Nesse contexto, é importante ressaltar que o MHP desenvolvido não utiliza e dispensa a necessidade de conhecer o valor da irradiância prévia, tal como nos modelos de referência.

Considerando o horizonte de 5 minutos, a precisão das predições entre os modelos MLP, LightGBM do MHP e *Persistence* são similares entre si (RMSE $\cong$ 49 e R^2 = 0,971). Nos demais horizontes de 10, 15, 30 e 60 minutos, as acurácias de ambos os modelos MLP e LightGBM do MHP proposto superam a acurácia do modelo de referência (*Persistence*).

De modo complementar, essas informações podem ser graficamente observadas na Figura 33. Os valores de RMSE e R^2 do MHP exibem uma menor variação de erro das predições em relação ao modelo de referência, conforme o horizonte aumenta. Isto sugere que, nos horizontes avaliados, o MHP possui uma menor amplitude na variabilidade média dos erros das predições, com $\mathrm{RMSE}(\sigma) = 4{,}64$ e $\mathrm{RMSE}(\sigma) = 5{,}26$ para os modelos MLP e LightGBM, respectivamente. Para fins de comparação, obteve-se um $\mathrm{RMSE}(\sigma) = 29{,}80$ para o modelo de referência (Tabela 16).

É importante destacar que a abordagem de predição adotada no MHP foi desenvolvida e avaliada de modo genérico para predições de curto prazo em seis (6) horizontes diferentes. Devido ao MHP ter uma abordagem de predição do tipo caixa-cinza, seu método ainda pode ser otimizado para um determinado horizonte em específico, ou mesmo uma faixa de horizontes com amplitude menor do que os 60 minutos considerados neste estudo.

Tabela 16 – Acurácia de predição da irradiância solar do MHP proposto.

	Horizonte (minuto)	***fold*-1**					***fold*-2**					***fold*-3**					***Acurácia Média Geral do Modelo***				
		MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS (%)	MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS (%)	MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS (%)	**MAE (W/m^2)**	**RMSE (W/m^2)**	**nRMSE**	**R^2**	**SS (%)**
Persistence	1	5,48	26,36	0,019	0,992	-	5,50	26,44	0,018	0,992	-	5,71	26,02	0,021	0,992	-	**5,56**	**26,27**	**0,019**	**0,992**	**-**
	5	14,37	50,04	0,039	0,971	-	14,94	49,86	0,039	0,971	-	14,44	49,12	0,039	0,972	-	**14,58**	**49,67**	**0,039**	**0,971**	**-**
	10	20,21	57,93	0,046	0,960		20,21	57,93	0,046	0,960		21,30	58,70	0,049	0,960		**20,57**	**58,19**	**0,047**	**0,960**	**-**
	15	25,42	65,05	0,051	0,950	-	25,42	65,05	0,051	0,950	-	26,72	66,73	0,056	0,948	-	**25,85**	**65,61**	**0,053**	**0,949**	**-**
	30	38,10	78,23	0,062	0,928	-	38,10	78,23	0,062	0,928	-	39,17	78,11	0,068	0,929	-	**38,46**	**78,19**	**0,064**	**0,928**	**-**
	60	63,28	111,34	0,094	0,854		66,36	113,74	0,095	0,849		65,30	112,92	0,099	0,851	-	**64,98**	**112,67**	**0,096**	**0,851**	**-**
	$\bar{x}$	*27,81*	*64,83*	*0,052*	*0,943*	*-*	*28,42*	*65,21*	*0,052*	*0,942*	*-*	*28,77*	*65,27*	*0,055*	*0,942*	*-*	***28,34***	***65,10***	***0,053***	***0,942***	**-**
	σ	*20,53*	*28,60*	*0,025*	*0,048*	*-*	*21,52*	*29,38*	*0,026*	*0,050*	*-*	*21,17*	*29,26*	*0,027*	*0,049*	*-*	***21,07***	***29,08***	***0,026***	***0,049***	**-**
MLP	1	17,18	46,81	0,034	0,974	-77,57	19,40	49,01	0,039	0,972	-85,36	19,00	50,70	0,035	0,970	-94,87	**18,52**	**48,84**	**0,036**	**0,972**	**-85,89**
	5	17,68	47,74	0,035	0,973	4,59	19,60	50,77	0,040	0,970	-1,82	19,02	51,41	0,035	0,969	-4,66	**18,76**	**49,97**	**0,037**	**0,971**	**-0,60**
	10	19,05	50,70	0,037	0,970	12,47	20,31	52,27	0,041	0,968	9,77	20,25	53,41	0,036	0,967	9,00	**19,87**	**52,13**	**0,038**	**0,968**	**10,41**
	15	19,44	52,19	0,038	0,968	19,76	20,79	53,69	0,042	0,966	17,46	20,08	54,26	0,037	0,966	18,69	**20,10**	**53,38**	**0,039**	**0,967**	**18,64**
	30	21,21	55,75	0,041	0,963	28,73	22,25	57,01	0,045	0,962	27,12	22,72	57,73	0,039	0,961	26,09	**22,06**	**56,83**	**0,042**	**0,962**	**27,32**
	60	24,24	60,59	0,044	0,957	45,58	25,42	60,99	0,048	0,957	46,38	25,81	62,28	0,042	0,955	44,84	**25,16**	**61,29**	**0,045**	**0,956**	**45,60**
	$\bar{x}$	*19,80*	*52,30*	*0,038*	*0,967*	*19,33*	*21,30*	*53,96*	*0,043*	*0,966*	*17,26*	*21,14*	*54,97*	*0,037*	*0,965*	*15,78*	***20,75***	***53,74***	***0,039***	***0,966***	***17,45***
	σ	*2,60*	*5,18*	*0,004*	*0,007*	*-*	*2,27*	*4,39*	*0,003*	*0,006*	*-*	*2,66*	*4,36*	*0,003*	*0,006*	*-*	***2,50***	***4,64***	***0,003***	***0,006***	**-**
LightGBM	1	16,35	42,65	0,03	0,979	-61,81	21,17	51,06	0,040	0,970	-93,10	20,94	51,64	0,035	0,969	-98,46	**19,49**	**48,45**	**0,036**	**0,972**	**-84,40**
	5	16,91	44,85	0,03	0,976	10,37	21,27	52,15	0,041	0,968	-4,60	20,76	52,55	0,036	0,968	-6,98	**19,65**	**49,85**	**0,037**	**0,971**	**-0,36**
	10	18,32	48,85	0,04	0,972	15,67	22,04	53,68	0,042	0,966	7,33	21,46	53,97	0,037	0,966	8,06	**20,61**	**52,17**	**0,038**	**0,968**	**10,34**
	15	19,79	51,72	0,04	0,968	20,49	23,54	55,92	0,044	0,964	14,04	23,63	56,85	0,039	0,963	14,81	**22,32**	**54,83**	**0,040**	**0,965**	**16,43**
	30	22,31	55,78	0,04	0,963	28,69	26,21	59,94	0,047	0,958	23,38	26,46	60,56	0,041	0,957	22,47	**24,99**	**58,76**	**0,043**	**0,960**	**24,85**
	60	25,89	60,09	0,04	0,957	46,03	28,73	62,64	0,049	0,954	44,92	28,57	63,31	0,043	0,954	43,94	**27,73**	**62,01**	**0,046**	**0,955**	**44,96**
	$\bar{x}$	*19,93*	*50,66*	*0,037*	*0,969*	*21,85*	*23,83*	*55,90*	*0,044*	*0,963*	*14,28*	*23,64*	*56,48*	*0,039*	*0,963*	*13,46*	***22,46***	***54,35***	***0,040***	***0,965***	***16,52***
	σ	*3,63*	*6,59*	*0,005*	*0,008*	*-*	*3,05*	*4,57*	*0,004*	*0,006*	*-*	*3,24*	*4,66*	*0,003*	*0,006*	*-*	***3,30***	***5,26***	***0,004***	***0,007***	**-**

Fonte: O autor, (2022).

Figura 33 – Acurácia de predição dos modelos de AM avaliados no MHP.

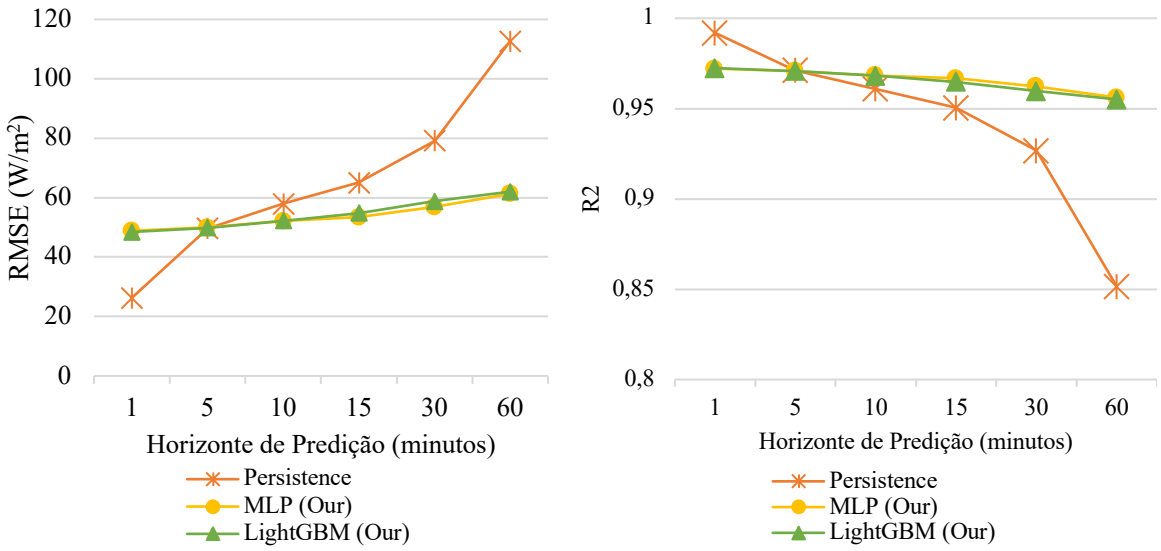

Fonte: O autor, (2022).

Em termos de precisão geral que considera conjuntamente todos os horizontes avaliados, o modelo MLP possui acurácia 17,45% superior ao modelo de referência (*Persistence*), enquanto que o modelo LightGBM possui 16,52% superior. De modo isolado, a partir do horizonte de 10 minutos, o MHP utilizando a MLP apresentou acurácia superior ao modelo de referência em 10,41%, 18,64%, 27,32% e 45,60% para os horizontes de 10, 15, 30 e 60 minutos, respectivamente. Por sua vez, o MHP com o LightGBM demonstrou acurácia superior em 10,34%, 16,43%, 24,85% e 44,96% para os horizontes de 10, 15, 30 e 60 minutos, respectivamente. Conforme observado e esperado, as acurácias das predições nos horizontes menores superam aquelas dos horizontes maiores (Figura 33), demonstrando que o MHP proposto também possui essa característica identificada na maioria dos estudos da literatura da PGESF. Além disso, as acurácias entre os modelos MLP e LightGBM mostraram-se similares em todos os horizontes, com pequena diferença média geral de ≅ 9%, com MAE = 20,75 para o MLP e MAE = 22,56 para o LightGBM.

Além do modelo de *Persistence*, a Figura 34 exibe o exemplo das predições para 1, 5, 15, 30 e 60 minutos do MHP nos três dias de referência com diferentes condições climáticas usados durante este estudo. Para o dia de céu totalmente limpo (02/09/2014), as predições são similares com diminuição da precisão conforme o horizonte aumenta. No dia de céu parcialmente nublado (28/06/2015), as predições dos modelos MLP e LightGBM são bastante similares e conseguem capturar a variabilidade geral da GHI nos períodos nublados (≅10h às 13h) e ensolarados do dia. Isto demonstra que as métricas de PI, desenvolvidas neste estudo, forneceram condições para que os modelos de AM realizassem as predições.

Figura 34 – Predições da irradiância solar do MHP nos três dias de referência.

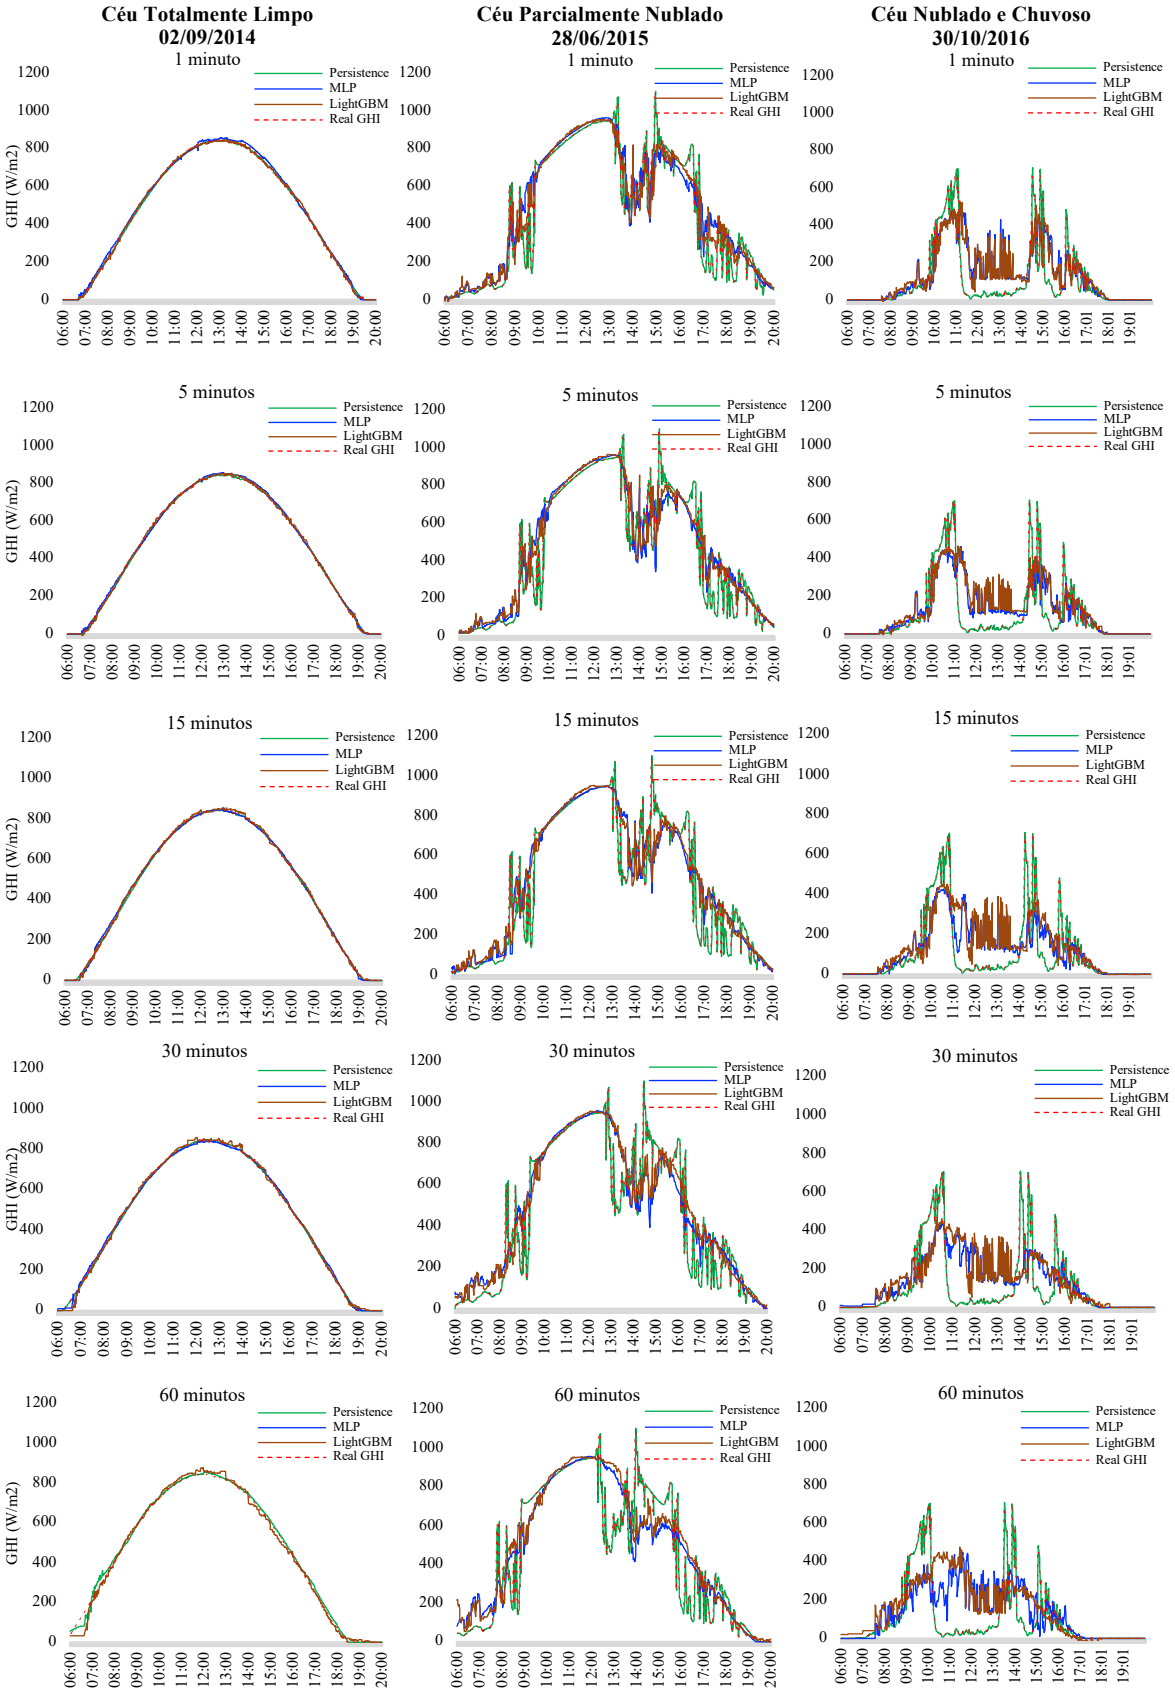

Fonte: O autor, (2022).

Por fim, as predições no dia com céu nublado e chuvoso (30/10/2016) demonstram uma das limitações do MHP e daqueles baseados estritamente em imagens do céu (*all-sky*). Neste dia, entre os horários de ≅10h às 13h choveu e tornou a acurácia das predições mais limitadas, conforme observa-se para o dia 30/10/2016. As gotas de chuva causam rápidas mudanças na imagem capturadas pela lente da câmera *all-sky*, gerando assim ruídos indesejados em todas as métricas de PI e, portanto, aumentando os erros das predições no MHP.

4.2. COMPARAÇÃO COM A LITERATURA CIENTÍFICA

Com o intuito de verificar o desempenho das predições do MHP proposto, buscou-se na literatura científica da PGESF (seção 2.1), propostas similares para se realizar uma análise comparativa empírica das acurácias de predição. A Tabela 17 exibe as acurácias do MHP e dos principais estudos da literatura científica da PGESF de curto prazo, cuja seleção se baseou nos seguintes critérios:

i) O uso de imagens totais do céu (*all-sky*) como entrada (*input*);

ii) Compatibilidade total ou parcial dos horizontes de predição considerados (1, 5, 10, 15, 30 ou 60 minutos);

iii) Compatibilidade com as métricas de acurácia utilizadas na análise das predições (MAE, RMSE, nRMSE ou R^2) e da variável predita (GHI);

iv) Acurácia geral das predições considerando diferentes condições meteorológicas.

Essas características estão detalhadas para cada estudo da literatura e devem ser consideradas conjuntamente nas possíveis comparações de acurácia entre o modelo MHP e os demais da literatura.

É importante ressaltar que a seleção destes estudos para a comparação de suas acurácias de predição é uma tarefa complexa (AHMED et al., 2020), pois, envolve distintas e relevantes variáveis que devem ser consideradas e, principalmente, padronizadas para possibilitar uma análise adequada e justa. Dentre estas variáveis tem-se a padronização do *datasets*, a qualidade e período de informações, a quantidade de dados dos conjuntos de treinamento, validação e teste, os tipos e quantidade de variáveis de entrada (*input*) utilizadas, a classe de algoritmos de predição, os horizontes e as métricas de acurácias consideradas, dentre outras.

Tabela 17 – Acurácia de predição do MHP e estudos similares da literatura científica.

Modelo	Descrição das Características	Horizonte	MAE[1] (W/m²)	RMSE[1] (W/m²)
MHP-MLP (Proposto)	**Classe**: Modelo Híbrido **Modelos**: Processamento de Imagens + RNA **Parâmetros treináveis**: ≅ 38.803 **Entrada**: Imagem *all-sky* **Teste**: 3 anos (Anos de 2014 a 2016) **Saída**: Irradiância GHI (W/m²)	1	18,52	48,84
		5	18,76	49,97
		10	19,87	52,13
		15	20,10	53,38
		30	22,06	56,83
		60	25,16	61,29
(ZHEN et al., 2022)	**Classe**: Aprendizado Profundo **Modelos**: CNN + LSTM-FUSION **Parâmetros treináveis**[2]: ≫100.000 **Entradas**: Imagem *all-sky* **Teste**: 6 meses (julho a dezembro/2014) **Saída**: Irradiância GHI (W/m²)	1	-	-
		5	-	-
		10	76,08	131,85
		15	-	-
		30	104,36	163,93
		60	120,77	179,72
(RAJAGUKGUK; KAMIL; LEE, 2021)	**Classe**: Modelo Híbrido **Modelos**: Processamento de Imagens + LSTM **Parâmetros treináveis**[2]: ≫100.000 **Entradas**: Imagem *all-sky* + *Clear Sky Index* **Teste**: 30 dias **Saída**: Irradiância GHI (W/m²)	1	-	58,44
		5	-	77,13
		10	-	86,97
		15	-	-
		30	-	-
		60	-	-
(PALETTA; ARBOD; LASENBY, 2021)	**Classe**: Aprendizado Profundo **Modelos**: CNN + LSTM + RNA **Parâmetros treináveis**[2]: ≅ 4,4 milhões **Entradas**: Imagem *all-sky* + *Exposure Time* + Irradiância GHI (passado) **Teste**: 363 dias (janeiro a novembro/2019) **Saída**: Irradiância GHI (W/m²)	1	-	-
		5	-	-
		10	6,20	20,40
		15	-	-
		30	-	-
		60	-	-
(WEN et al., 2021)	**Classe**: Aprendizado Profundo **Modelo**: CNN ResNet-18 **Parâmetros treináveis**[2]: ≅ 31,7 milhões **Entrada**: Imagem *all-sky* **Teste**: 30 dias (Abril/2016) **Saída**: Irradiância GHI (W/m²)	1	-	-
		5	56,40	105,50
		10	54,10	104,30
		15	-	-
		30	-	-
		60	-	-
(DISSAWA et al., 2021a)	**Classe**: Processamento de Imagens **Modelo**: Processamento de Imagens **Entrada**: Imagens *all-sky* (duas câmeras) **Parâmetros treináveis**: não aplicável **Teste**: 21 dias **Saída**: Irradiância GHI (W/m²)	1	77,25	120,33
		5	82,50	131,25
		10	-	-
		15	95,67	139,42
		30	-	-
		60	-	-
(YANG et al., 2021)	**Classe**: Aprendizado Profundo **Modelos**: 3D-CNN Resnet 34/50 + RNA **Parâmetros treináveis**[2]: ≅ 63,6/46,4 milhões **Entradas**: Imagem *all-sky* + *Clear Sky Index* **Teste**: 365 dias (Ano de 2016) **Saída**: Irradiância GHI (W/m²)	1	-	-
		5	-	46,30
		10	-	57,60
		15	-	65,30
		30	-	72,70
		60	-	-

[1] Valores com (-) estão indisponíveis ou não foram avaliados nas publicações.
[2] Parâmetros dos modelos de Aprendizado Profundo relatados por (LEONG et al., 2020).

Fonte: O autor, (2022).

A Figura 35 exibe graficamente todos os dados de RMSE descritos na Tabela 17, pois, essa é a medida de acurácia mais comum observada nos estudos da PGESF (JUNCKLAUS MARTINS et al., 2022). A seguir, cada um destes estudos literatura têm suas

características e medidas de acurácia analisadas e comparadas, empiricamente, com o MHP proposto.

Figura 35 – Acurácia do MHP (MLP e LightGBM) e de estudos da literatura científica.

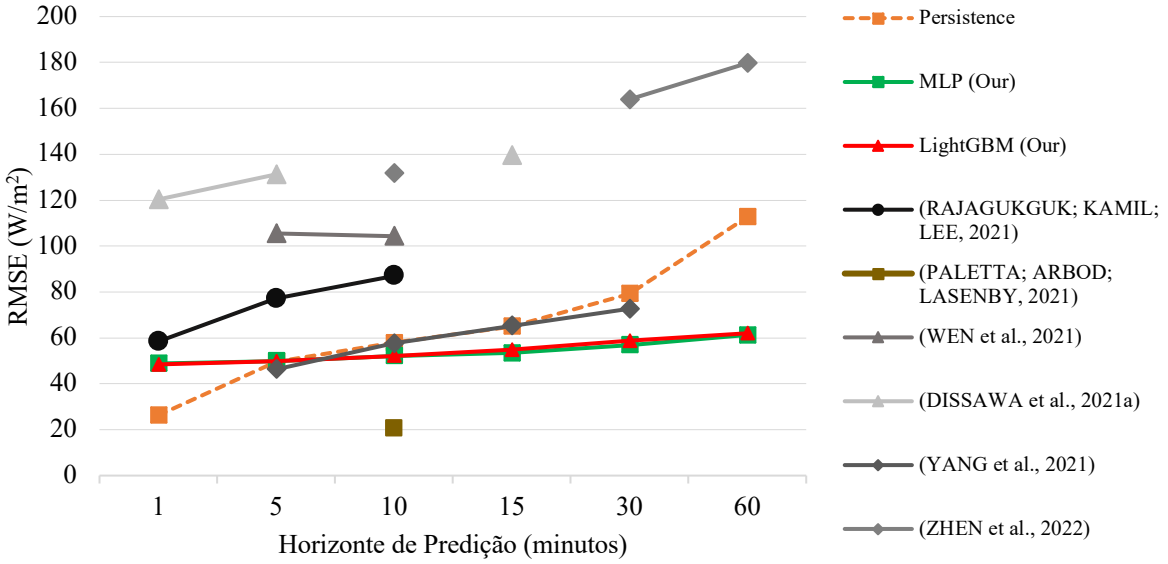

Fonte: O autor, (2022).

A proposta similar e mais recente foi publicada por (ZHEN et al., 2022) e avalia quatro modelos de predição, sendo considerados os melhores resultados correspondentes ao modelo de Aprendizado Profundo composto por redes CNN+LSTM-FUSION, onde somente imagens do céu (*all-sky*) são fornecidas para as predições da GHI. Este modelo usa a abordagem caixa-preta (*black-box*), onde as características são extraídas pela CNN e as predições são feitas pela LSTM. O período de testes considerado em (ZHEN et al., 2022) é de 6 meses e inferior aos 3 anos de avaliação do MHP proposto. Já a precisão do modelo de predição CNN+LSTM-FUSION é inferior ao MHP, proposto neste estudo, em todos os horizontes de 10, 30 e 60 minutos que foram avaliados.

De modo similar, outra interessante proposta selecionada e publicada (RAJAGUKGUK; KAMIL; LEE, 2021) emprega um modelo híbrido composto por processamento de imagens e uma rede LSTM para executar as predições de curto prazo. Assim como o MHP proposto, o modelo híbrido de extrai diversas características das nuvens por meio de técnicas de processamento de imagens. No entanto, além das imagens totais do céu, (RAJAGUKGUK; KAMIL; LEE, 2021) utilizam um Índice de Céu Limpo (*Clear Sky Index)* como entrada adicional para o modelo de Aprendizado Profundo, baseado em LSTM, distinguindo-se do MHP proposto neste estudo. Considerando que o período é de um mês

(30 dias), o MHP proposto demonstrou acurácia superior para os horizontes de 1, 5 e 10 minutos.

Por outro lado, conforme a Figura 35, o estudo de (PALETTA; ARBOD; LASENBY, 2021) apresenta melhor precisão na predição para o horizonte de 10 minutos em relação ao MHP proposto neste estudo. Todavia, é necessário considerar que os autores utilizam diversas informações adicionais a imagem do céu, tais como valores de irradiância prévios, tempo de exposição da câmera fotográfica e localização do sol fornecidos pelo *dataset*. No MHP proposto, estas informações não são utilizadas e, o uso dos valores históricos prévio e atual da variável a ser predita (GHI), requer a necessidade de dispositivos adicionais para captura destas informações, além de possibilitam o aumento da acurácia dos modelos de predição da irradiância solar.

O estudo desenvolvido por (ZHANG et al., 2018b) é um dos pioneiros na PGESF utilizando Aprendizado Profundo por agrupamento (*Ensemble Model*) com imagens *all-sky*. Tal pesquisa inspirou a proposta desenvolvida por (WEN et al., 2021) que, por sua vez, é o estudo pioneiro em aplicar Aprendizado Profundo com Rede Neural Convolucional (CNN) na PGESF de curto prazo utilizando somente imagens *all-sky*. Neste estudo, a CNN adotada é do tipo ResNet-18 pré-treinada e utiliza imagens empilhadas para gerar predições nos horizontes de 5 a 10 minutos. Embora este modelo caixa-preta seja bem mais complexo do que o MHP proposto, em termos de quantidade de parâmetros treináveis e por utilizar uma CNN pré-treinada, a acurácia do MHP proposto foi superior com a MLP e o LightGBM utilizando as Métricas e PI como entrada. Ou seja, mesmo os modelos de Aprendizado de Máquina, teoricamente mais simples, demonstraram acurácia superior ao modelo de Aprendizado Profundo com CNN de arquitetura ResNet-18. Provavelmente, este resultado sugere que a etapa de extração de características do MHP, cujo desenvolvimento proposto neste estudo é baseado em Métricas de Processamento de Imagens, forneceu melhores condições para que os modelos MLP e LightGBM capturassem as intermitências da GHI com maior acurácia em relação ao uso de imagens da CNN-ResNet-18.

Outra abordagem que aplicou somente técnicas de processamento de imagens foi proposta em (DISSAWA et al., 2021a) e incluída nas comparações das predições de 1, 5 e 15 minutos. O modelo que utiliza duas câmeras *all-sky* para identificar, classificar e rastrear as nuvens, demonstrou acurácia inferior, em todos os horizontes, ao MHP proposto neste estudo. Além disso, somente um período de 21 dias de testes, pré-selecionados com

diferentes condições climáticas, foi considerado no estudo. Portanto, esse fator prejudica a comparação adequada com o MHP que se baseia em um período de teste mais amplo de 3 anos.

Por fim, outro interessante e recente método para melhorar as predições de curto prazo é descrito por (YANG et al., 2021) e utiliza o mesmo *dataset* (seção 3.5) empregado na avaliação do MHP proposto. Na proposta mencionada, os autores utilizaram o Aprendizado Profundo com um modelo de Rede Neural Convolucional de três dimensões (3D-CNN) para a predição da GHI. No entanto, além das imagens *all-sky* os autores utilizaram de um Índice de Céu Limpo (*Clear Sky Index*) fornecido pelo *dataset*, diferindo-se, portanto, do uso exclusivo de imagens do MHP proposto. Além disso, foram utilizadas CNNs com arquitetura ResNet 34 e 50, que são caixa-preta, previamente treinadas e mais complexas do que as usadas no MHP. Considerando os horizontes de 5, 10, 15 e 30 minutos avaliados, o modelo 3D-CNN supera em 7,2% o MHP proposto no horizonte de 5 minutos, apresentando RMSE=46,30 W/m^2 em relação RMSE=49,90 W/m^2, respectivamente. Nos outros três horizontes, o MHP proposto demonstrou acurácia de predição superior em 9%, 18%, e 21% para 10, 15 e 30 minutos, respectivamente. Este estudo é uma comparação importante por empregar o mesmo *dataset* utilizado no MHP proposto, porém, o período de testes em (YANG et al., 2021) contempla somente 1 ano completo, ao passo que são 3 anos completos considerados no teste do MHP proposto neste estudo.

Diante destes resultados torna-se relevante destacar que o MHP proposto é o menos complexo computacionalmente, por possuir a menor quantidade de parâmetros treináveis (38.803), dentre todos os outros modelos de predição da literatura exibidos na Tabela 17. Além disso, muitos estudos focam suas melhorias em horizontes únicos e específicos, ou então faixas mais curtas de horizontes e, geralmente, de menor amplitude do que a faixa de 1 a 60 minutos avaliada com o MHP proposto.

Por fim, cabe ressaltar que o MHP foi proposto e desenvolvido com um processo de extração de características das imagens (Métricas de PI) generalista e, portanto, independente e sem otimização para um horizonte de predição específico. Portanto, a abordagem do MHP pode ainda ser, posteriormente, otimizada para um horizonte de predição específico, ou mesmo uma faixa menos ampla de horizontes de predição.

4.3. ANÁLISE DOS TIPOS DE ENTRADA

O MHP proposto neste estudo difere-se das demais propostas da literatura científica por ter um método de processamento híbrido para predições de curto prazo que calcula e utiliza um conjunto de medidas ou características das imagens *all-sky*, denominadas de Métricas de Processamento de Imagens (PI), e as utiliza como entrada para os modelos de AM executarem as predições de curto prazo.

Este conjunto específico de 8 (oito) métricas de PI foi projetado para representar diferentes as características do céu relevantes a predição da irradiância de curto prazo. Portanto, para cada imagem do céu (*all-sky*) são computadas as seguintes métricas de PI: *Clouds Movement*, *Clouds Coverage, Clouds Around Sun*, *Clear Sky GHI*, *Sun Luminance*, *Sun Luminance Adjusted*, *Sun Located* e *White Pixels Rate*, descritas na seção 0.

É importante destacar que métricas de *Clouds Movement*, *Clouds Around Sun* e *Sun Luminance Adjusted* foram desenvolvidas de modo exclusivo para o MHP, com base na premissa de simplicidade de execução computacional e significado para a PGESF. As demais métricas de PI já têm sido empregadas na PGESF, geralmente, de modo isolado. No entanto, as métricas *Clouds Coverage*, *Sun Luminance*, *Sun Located* e *White Pixels Rate* foram modificadas e empregadas no MHP, de modo que o uso conjunto de todas estas métricas diferencia a abordagem do MHP em relação aos demais métodos da literatura.

Exemplificando a simplicidade das métricas exclusivas do MHP, tem-se que a *Clouds Movement* calcula uma simples diferença (subtração) entre duas imagens distintas, capturadas com base no horizonte de predição. No entanto, seu significado para a PGESF é relevante, pois permite identificar a existência de nuvens e, ao mesmo tempo, de movimento destas no céu (Figura 16). Por sua vez, a métrica *Clouds Around Sun* identificar a existência de nuvens próximas ao sol, enquanto a métrica de *Sun Luminance Adjusted* utiliza a luminância, previamente calculada, ajustada aos valores de irradiância esperados em dias de céu totalmente limpo (Figura 26).

Convém ressaltar que a estratégia de se extrair, previamente, este conjunto de métricas de PI (características do céu e nuvens) das imagens *all-sky*, no MHP proposto, foi desenvolvida e motivada pela necessidade de se calcular e prover, de modo mais compreensível e assertivo, informações importantes, distintas, complementares e relevantes, para o processamento das predições de curto prazo. Historicamente, a maioria dos estudos da PGESF de curto prazo utiliza informações meteorológicas e/ou, mais recentemente,

imagens do céu a partir de modelos complexos de AP (caixa-preta), tais como as CNNs conhecidas por lidarem bem com problemas de classificação.

Nesse contexto, a Tabela 18 exibe a acurácia de predição do MHP utilizando o conjunto de entrada relativo as Informações Meteorológicas. Conforme detalhado na Figura 32 (página 88), além do mês, hora e minuto, estas informações contemplam as oito diferentes variáveis meteorológicas de estação do ano, temperatura do ar, umidade do ar, pressão atmosférica, velocidade do vento, velocidade máxima do vento, direção do vento e precipitação (chuva). Complementarmente, os valores do modelo de Persistência são novamente exibidos para o cálculo da métrica de *Skill Score* (SS).

Os resultados demonstram a acurácia de ambos os modelos simples de AM utilizando MLP-Weather e LightGBM-Weather são inferiores àquelas obtidas com o MHP proposto (Tabela 16) e que usa como entrada as Métricas de PI, considerando todos os horizontes de predição analisados. Além da acurácia diminuir conforme o horizonte de predição aumenta, as acurácias de predição da MLP-Weather e LightGBM-Weather, que usam informações meteorológicas, são superiores aos modelos de referência (*Persistence*). Comparando entre si os modelos MLP-Weather e LightGBM-Weather, observa-se que o modelo LightGBM-Weather (RMSE=76,5) demonstrou melhor capacidade de predição e acurácia média superior ao MLP-Weather (RMSE = 96,0) em ≅ 20%.

Tabela 18 – Acurácia de predição do MHP com Informações Meteorológicas.

		***fold*-1**					***fold*-2**					***fold*-3**					***Acurácia Geral do Modelo***				
	Horizonte (minuto)	MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS (%)	MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS (%)	MAE (W/m^2)	RMSE (W/m^2)	nRMSE	R^2	SS	**MAE (W/m^2)**	**RMSE (W/m^2)**	**nRMSE**	**R^2**	**SS (%)**
Persistence	1	5,48	26,36	0,019	0,992	-	5,50	26,44	0,018	0,992	-	5,71	26,02	0,021	0,992	-	**5,56**	**26,27**	**0,019**	**0,992**	**-**
	5	14,37	50,04	0,039	0,971	-	14,94	49,86	0,039	0,971	-	14,44	49,12	0,039	0,972	-	**14,58**	**49,67**	**0,039**	**0,971**	**-**
	10	20,21	57,93	0,046	0,960	-	20,21	57,93	0,046	0,960	-	21,30	58,70	0,049	0,960	-	**20,57**	**58,19**	**0,047**	**0,960**	**-**
	15	25,42	65,05	0,051	0,950	-	25,42	65,05	0,051	0,950	-	26,72	66,73	0,056	0,948	-	**25,85**	**65,61**	**0,053**	**0,949**	**-**
	30	38,10	78,23	0,062	0,928	-	38,10	78,23	0,062	0,928	-	39,17	78,11	0,068	0,929	-	**38,46**	**78,19**	**0,064**	**0,928**	**-**
	60	63,28	111,34	0,094	0,854	-	66,36	113,74	0,095	0,849	-	65,30	112,92	0,099	0,851	-	**64,98**	**112,67**	**0,096**	**0,851**	**-**
	$\bar{x}$	*27,81*	*64,83*	*0,052*	*0,943*	*-*	*28,42*	*65,21*	*0,052*	*0,942*	*-*	*28,77*	*65,27*	*0,055*	*0,942*	*-*	***28,34***	***65,10***	***0,053***	***0,942***	***-***
	σ	*20,53*	*28,60*	*0,025*	*0,048*	*-*	*21,52*	*29,38*	*0,026*	*0,050*	*-*	*21,17*	*29,26*	*0,027*	*0,049*	*-*	***21,07***	***29,08***	***0,026***	***0,049***	***-***
MLP-Weather	1	50,40	91,94	0,067	0,905	248,79	51,38	97,03	0,077	0,891	266,97	45,66	86,47	0,059	0,913	232,33	**49,14**	**91,81**	**0,068**	**0,903**	**249,45**
	5	50,16	91,72	0,067	0,906	-83,30	52,92	98,85	0,078	0,886	-98,26	47,19	88,81	0,061	0,909	-80,80	**50,09**	**93,13**	**0,069**	**0,900**	**-87,48**
	10	52,35	95,04	0,070	0,899	-64,06	53,98	100,03	0,079	0,884	-72,68	48,25	90,60	0,062	0,905	-54,34	**51,53**	**95,22**	**0,070**	**0,896**	**-63,65**
	15	53,73	96,37	0,071	0,896	-48,14	54,30	100,04	0,079	0,884	-53,79	46,86	88,50	0,060	0,909	-32,62	**51,63**	**94,97**	**0,070**	**0,896**	**-44,75**
	30	54,75	99,56	0,073	0,889	-27,27	55,18	101,82	0,080	0,880	-30,16	52,45	95,34	0,065	0,895	-22,05	**54,13**	**98,91**	**0,073**	**0,888**	**-26,50**
	60	54,75	99,65	0,073	0,889	10,50	56,88	106,64	0,084	0,868	6,24	56,24	101,10	0,069	0,882	10,47	**55,96**	**102,46**	**0,075**	**0,879**	**9,05**
	$\bar{x}$	*52,69*	*95,71*	*0,070*	*0,897*	*-47,65*	*54,11*	*100,74*	*0,080*	*0,882*	*-54,48*	*49,44*	*91,80*	*0,063*	*0,902*	*-40,66*	***52,08***	***96,08***	***0,071***	***0,894***	***-47,59***
	σ	*2,06*	*3,50*	*0,003*	*0,008*	*-*	*1,89*	*3,30*	*0,003*	*0,008*	*-*	*4,07*	*5,45*	*0,004*	*0,012*	*-*	***2,54***	***3,94***	***0,003***	***0,009***	***-***
LightGBM -Weather	1	38,38	67,76	0,050	0,949	*157,04*	42,57	75,56	0,060	0,934	*185,77*	44,98	76,20	0,052	0,933	*192,85*	**41,97**	**73,17**	**0,054**	**0,938**	178,50
	5	39,07	68,67	0,050	0,947	*-37,24*	43,85	76,67	0,061	0,932	*-53,77*	46,26	77,56	0,053	0,930	*-57,90*	**43,06**	**74,30**	**0,055**	**0,936**	-49,58
	10	38,50	71,23	0,052	0,942	*-22,96*	45,13	76,39	0,060	0,932	*-31,86*	45,89	78,31	0,053	0,931	*-33,41*	**43,17**	**75,31**	**0,055**	**0,935**	-29,43
	15	42,00	71,43	0,052	0,943	*-9,80*	46,29	79,20	0,063	0,927	*-21,75*	48,32	79,95	0,055	0,926	*-19,81*	**45,54**	**76,86**	**0,056**	**0,932**	-17,14
	30	42,83	73,51	0,054	0,939	*6,03*	46,81	80,25	0,063	0,925	*-2,58*	48,76	81,20	0,055	0,924	*-3,96*	**46,13**	**78,32**	**0,058**	**0,929**	-0,17
	60	44,25	75,99	0,056	0,935	*31,75*	48,55	82,48	0,065	0,921	*27,49*	50,85	84,53	0,058	0,917	*25,14*	**47,88**	**81,00**	**0,059**	**0,925**	28,11
	$\bar{x}$	*40,84*	*71,43*	*0,052*	*0,943*	*-10,19*	*45,53*	*78,42*	*0,062*	*0,928*	*-20,27*	*47,51*	*79,63*	*0,054*	*0,927*	*-22,00*	***44,63***	***76,49***	***0,056***	***0,933***	***-17,50***
	σ	*2,51*	*3,04*	*0,002*	*0,005*	*-*	*2,15*	*2,67*	*0,002*	*0,005*	*-*	*2,19*	*2,98*	*0,002*	*0,006*	*-*	***2,25***	***2,86***	***0,002***	***0,005***	***-***

Fonte: O autor, (2022).

A Figura 36 exibe graficamente as acurácias de predição para todos os horizontes entre o MHP proposto e os modelos MLP-Weather e LightGBM-Weather utilizando informações meteorológicas. Conforme pode se observar, o uso conjunto das Métricas de PI no MHP proposto possibilitou a realização de predições com maior acurácia em relação ao uso conjunto de informações de meteorológicas.

Figura 36 – Acurácia do MHP com Métricas de PI e Informações Meteorológicas.

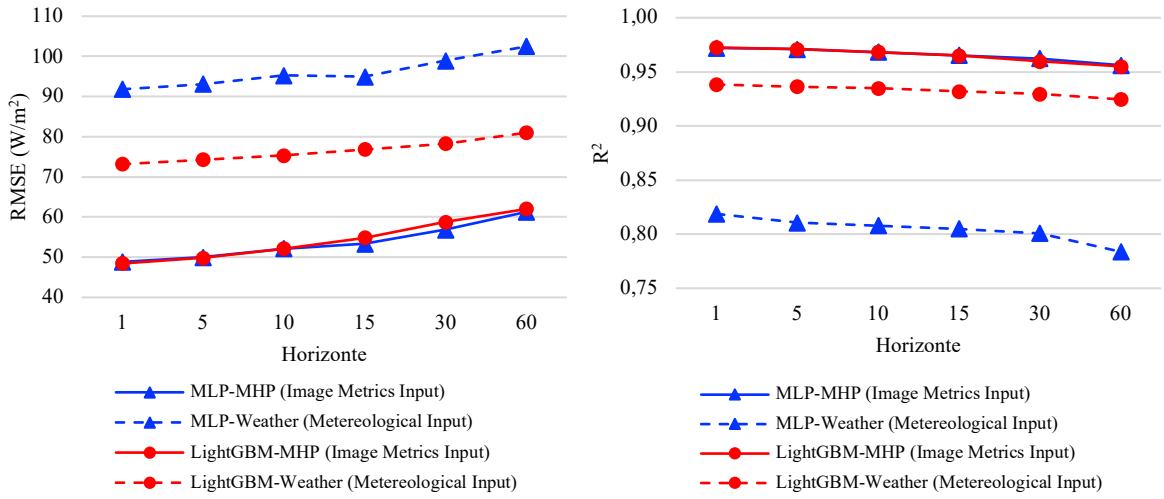

Fonte: O autor, (2022).

Em termos gerais, a comparação do modelo MLP no MHP proposto (MLP-MHP) e no modelo com informações meteorológicas (MLP-Weather) demonstrou que o uso das Métricas de PI no MHP proposto aumentou a acurácia de RMSE em ≅ 44%, ou seja, com RMSE = 53,74 para o MHP-MLP e RMSE = 96,08 para modelo MHP-Weather, que usa informações meteorológicas. Considerando o LightGBM, constata-se um aumento da acurácia de RMSE em ≅ 28%, com RMSE = 54,35 para o LightGBM-MHP e RMSE = 76,49 para o LightGBM-Weather.

Os exemplos das predições com o MHP proposto (MLP-MHP), que emprega as métricas de PI, e o uso de informações meteorológicas (MLP-Weather) são exibidos na Figura 37 para os algoritmos baseados em MLP. De modo geral, as predições do MHP proposto exibem maior precisão e acurácia em relação ao modelo MLP-Weather. No dia parcialmente nublado (28/06/2015) constata-se que o modelo MLP-Weather falhou em capturar o padrão da variabilidade da GHI a partir do uso de informações meteorológicas. Possivelmente, as MLPs sejam modelos simples demais para capturar essa variabilidade em função dos dados meteorológicos que foram considerados. É importante destacar que esta análise buscou avaliar a qualidade de predição dos modelos, neste caso MLP, em função dos

distintos tipos conjuntos de dados de entrada, ou seja, as métrica de PI e as informações meteorológicas.

Figura 37 – Predição da irradiância solar com MLP e informação meteorológica.

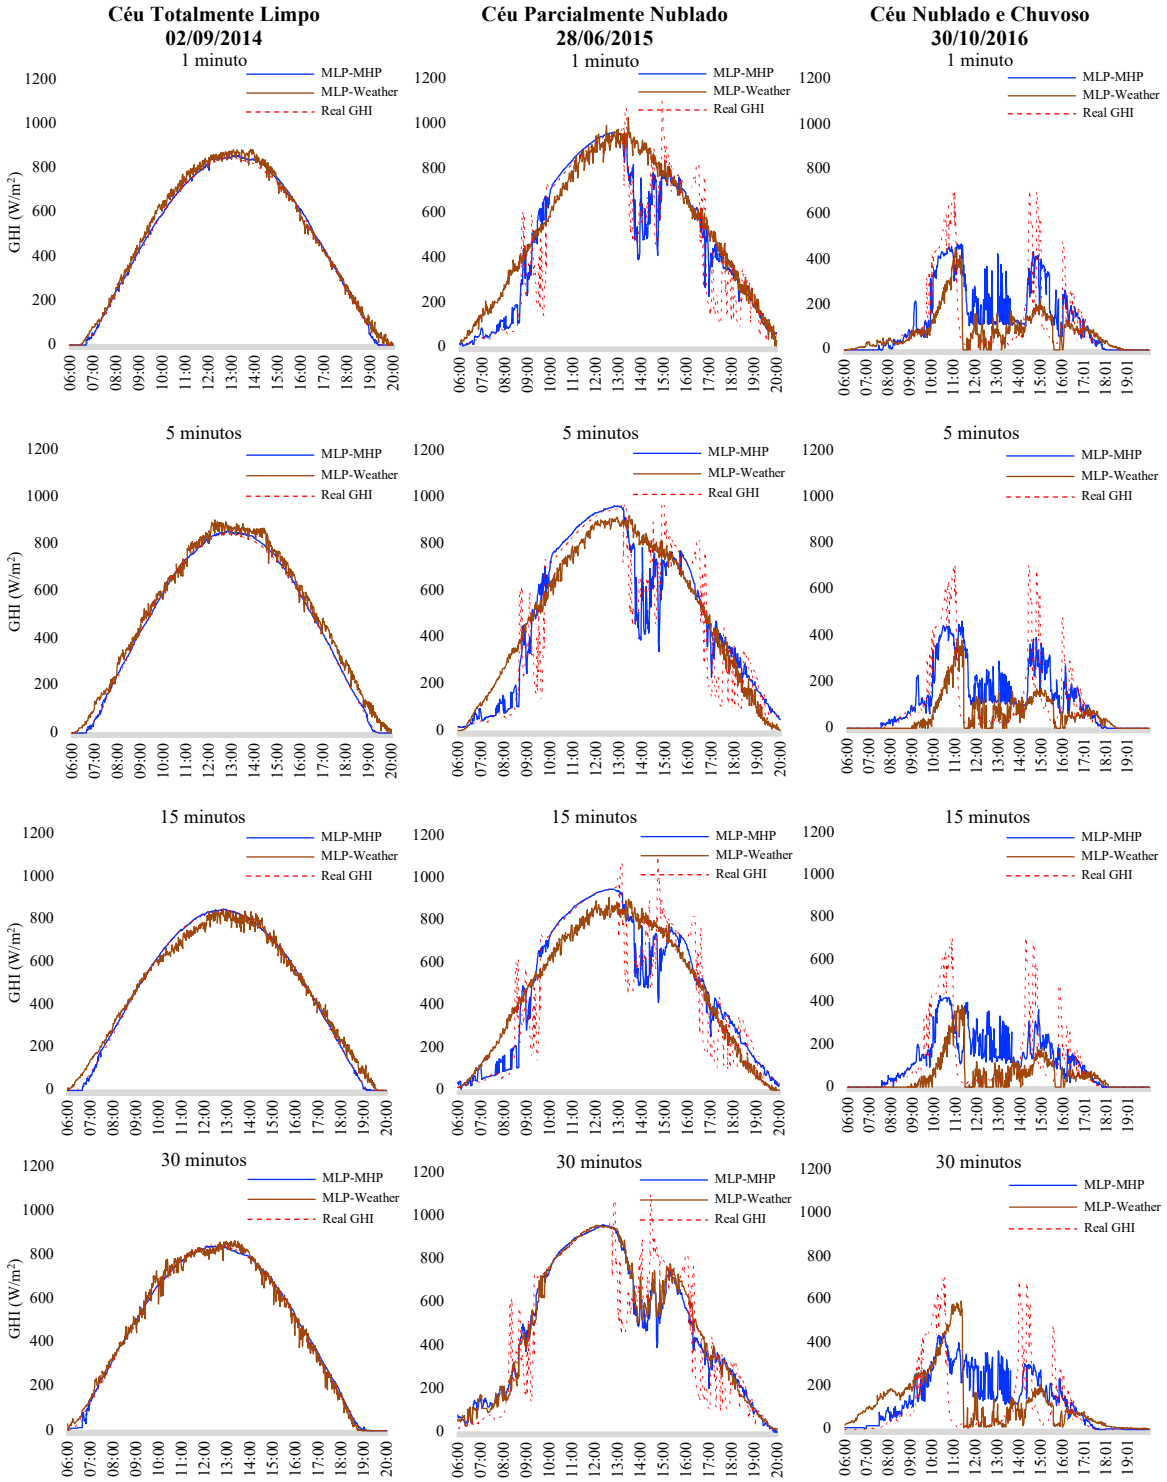

Fonte: O autor, (2022).

De modo complementar, na Figura 38 são exibidos alguns exemplos das predições com o algoritmo LightGBM a partir do MHP proposto (LightGBM-MHP) e do uso de

informações meteorológicas (LightGBM-Weather). Assim como observado para os modelos MLP, o MHP proposto também apresentou melhores índices gerais de acurácia e precisão.

Figura 38 – Predição da irradiância solar com LightGBM e informação meteorológica.

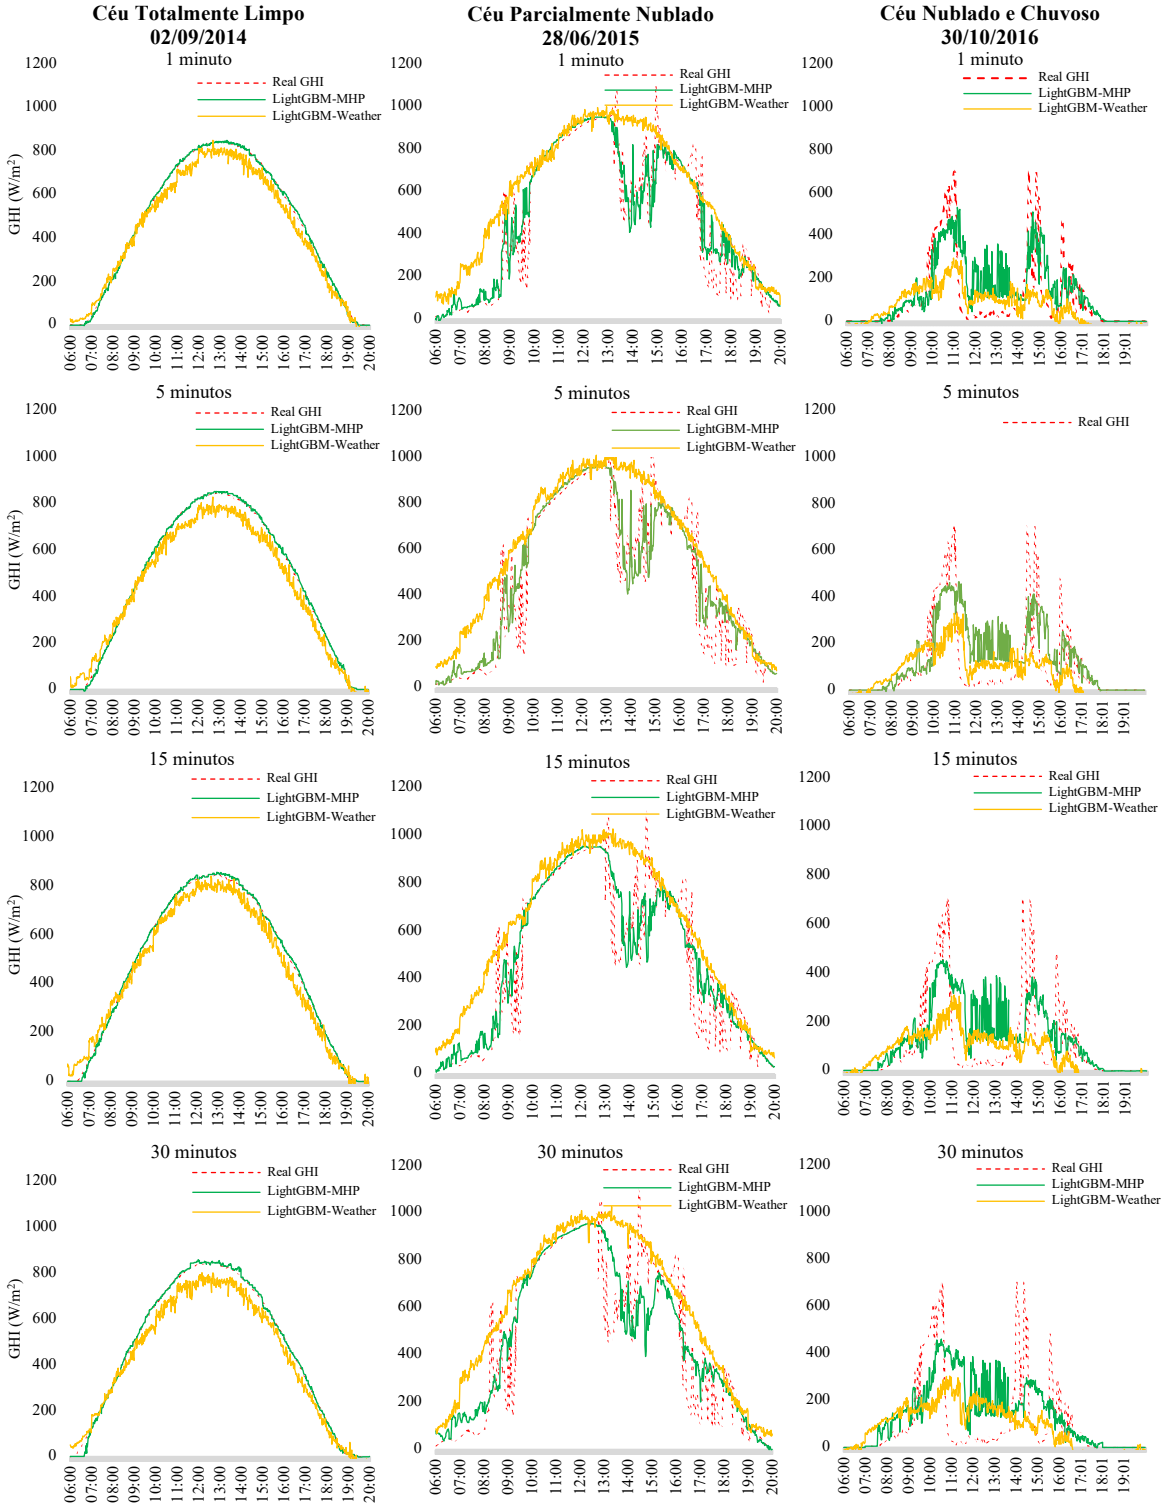

Fonte: O autor, (2022).

Os exemplos das predições exibidas na Figura 37 e Figura 38 são apresentadas para os três dias de referência adotados neste estudo. É importante destacar que o dia com céu nublado e chuvoso (30/10/2016) foi selecionado e exibido, especificamente, para representar o comportamento do MHP em condições adversas e que limitam seu funcionamento, pois, conforme mencionado na seção 0, o gotejamento das chuvas é uma condição que limita e interfere negativamente nas predições do MHP, conforme pode ser observado no período entre 12:00 e 14:00 horas.

Portanto, de modo geral os resultados possibilitam constatar que as métricas de PI extraídas das imagens *all-sky*, proposta neste estudo e adotadas no MHP, proporcionaram melhores índices de acurácia e precisão nas predições de curto prazo, quando comparadas ao uso de informações meteorológicas. Desse modo, as imagens *all-sky* contém e podem fornecer informações relevantes para a captura e predição da GHI nos horizontes de predição avaliados, apresentando ainda precisão e acurácia iguais ou superiores ao uso de informações meteorológicas.

4.4. VALIDAÇÃO DAS HIPÓTESES

O presente estudo definiu duas hipóteses (seção 1.1) a serem interpretadas a partir do desenvolvimento e da avaliação do MHP proposto para a PGESF de curto prazo (1, 5, 10, 15, 30, e 60 minutos) com o uso de imagens totais do céu (*all-sky*).

A primeira hipótese (a) descreve que o MHP proposto com uso de imagens *all-sky* e com uma abordagem de execução híbrida composta pelas etapas de Processamento de Imagens (extração explícita de características) e Aprendizado de Máquina (execução das predições), pode ser aplicado à PGESF e gerar predições de curto prazo com acurácia igual ou superior aos métodos existentes na literatura científica, incluindo aqueles baseados em Aprendizado Profundo.

Nesse sentido, os resultados da avaliação experimental do MHP demonstraram que sua acurácia é similar ou superior ao modelo de referência (*Persistence*) nos horizontes acima de 1 minuto (seção 4.1), sendo ainda superior a diversas propostas da literatura que empregam imagens *all-sky* e os horizontes avaliados, especialmente a partir de 10 minutos (seção 4.2). Portanto, com base nestes resultados a hipótese (a) pôde ser analisada e parcialmente aceita levando-se em conta o horizonte de predição avaliado. É importante salientar que o MHP proposto utiliza um algoritmo de predição mais simples e baseado em

AM, diferindo-se da maioria das propostas da literatura (Tabela 17) que, em geral, utilizam algoritmos mais complexos de Aprendizado Profundo.

A segunda hipótese (b) se refere comparação do desempenho de predição dos modelos de AM do MHP em relação ao uso de informações meteorológicas tradicionalmente utilizadas na PGESF. Os resultados descritos na seção 4.3 demonstram que o uso das métricas de PI, ou seja, as características extraídas das imagens *all-sky*, permitiram a realização de predições com melhor acurácia e diferença significativa quando comparada ao uso de informações meteorológicas. Portanto, a hipótese (b) pode ser comprovada e aceita, pois, as métricas de PI utilizadas permitiram comprovar que as imagens *all-sky* contêm informações implícitas que possibilitam a realização de predições de curto prazo com acurácia igual ou superior ao uso de informações meteorológicas.

Vale destacar que os resultados destas hipóteses são particularmente interessantes, pois, sugerem que o desenvolvimento de novos métodos híbridos de predição de curto prazo, utilizando um conjunto determinado de características distintas e complementares das imagens *all-sky*, tal como o proposto no MHP, constituem uma nova abordagem e caminho a ser estudado na área da PGESF.

Um aspecto fundamental considerado neste estudo é o fato de que embora as métricas de PI tenham limitações de funcionamento conhecidas e estudadas na literatura da PGESF, o projeto da abordagem híbrida de execução do MHP foi construído para possibilitar a transferência de reconhecimento e captura destas limitações para o modelo de AM realizar as predições. Essa estratégia foi adotada devido ao fato de que os modelos de AM e/ou AP, da Inteligência Artificial, são robustos em capturar e aprender os padrões e utilizar esse conhecimento para fazer predições ou tomada de decisões, principalmente quando não existem dependência linear entre as entradas e saídas (RUSSELL; NORVIG, 2016).

Nesse sentido, destaca-se que os algoritmos MLP e LightGBM, avaliados no MHP, além de possuírem complexidade computacional inferior e maior interpretabilidade, demonstraram acurácia similar ou superior em relação aos estudos comparados da literatura científica da PGESF, os quais em geral empregam modelos mais complexos baseados em Aprendizado Profundo, principalmente as CNNs e variações.

4.5. CONSIDERAÇÕES FINAIS

Nesta seção foram descritos os resultados da avaliação experimental do MHP proposto. Além da discussão destes resultados, foi apresentada a análise comparativa de desempenho de predição do MHP, que utiliza imagens *all-sky*, em relação ao uso de informações meteorológicas tradicionais. Ao final foi apresentada a discussão e a validação das hipóteses de pesquisa do presente estudo (seção 1.1). A próxima seção apresenta a conclusão do presente estudo, destacando suas principais características de originalidade, resultados e contribuições.

5. CONCLUSÃO

Um dos principais objetivos dos modelos de predição consiste em prover a redução das incertezas futuras que ocorrem devido a volatilidade de fenômenos naturais existentes em diversas áreas do conhecimento, tal como as intermitências na geração de energia solar fotovoltaica. Partindo do conceito de que a Predição da Geração de Energia Solar Fotovoltaica (PGESF) é um problema de regressão com crescente relevância no cenário energético e científico atual, a presente tese apresentou a criação e a avaliação de um Método Híbrido de Predição (MHP) da irradiância GHI do tipo caixa-cinza (*gray-box*), a partir do *insight* de estudos científicos recentes que apontaram a importância da otimização dos parâmetros de entrada (AHMED et al., 2020) e os melhores resultados de acurácia dos modelos de predição híbridos (KUMARI; TOSHNIWAL, 2021).

Diante desse contexto, o MHP desenvolvido e avaliado utiliza como entrada somente imagens totais do céu (*all-sky*) com uma abordagem de processamento híbrida, composta de duas etapas: (i) a extração de um conjunto de características (métricas) com processamento de imagens, e; (ii) a execução das predições a partir das características das imagens com modelos simples de Aprendizado de Máquina (AM), especificamente com MLP e LightGBM. Os horizontes de predição de curto prazo avaliados contemplaram 1, 5, 10, 15, 30 e 60 minutos.

A acurácia de predição da GHI do MHP proposto superou a do modelo de referência nos horizontes de 10, 15, 30 e 60 minutos, apresentando valor similar para 5 minutos e inferior para 1 minuto. Esta é uma limitação do MHP que poder ser melhorada, principalmente para os horizontes de 1 e 5 minutos, embora a diferença para este último seja pequena (0,6%). No entanto, a acurácia geral (RMSE) das predições do MHP, utilizando MLP, foi 17,45% superior ao modelo de referência (*Persistence*), enquanto que o LightGBM exibiu acurácia média 16,52% superior ao modelo de referência. Entre si, as predições dos algoritmos MLP e LightGBM demonstraram certa similaridade com pequena vantagem de acurácia média geral para o modelo MLP (MAE ≅ 9%), considerando todos os horizontes.

Por outro lado, a comparação empírica de acurácia do MHP com os estudos da literatura demonstrou que a abordagem híbrida do MHP, principalmente a extração do conjunto de características das imagens, propiciou predições com acurácia igual ou superior a diversos modelos da literatura científica da PGESF, quando considerado o uso de imagens do céu (*all-sky*) nos horizontes avaliados. Além disso, é importante ressaltar que os estudos

considerados nas comparações, em geral, empregam modelos mais complexos de Aprendizado Profundo em suas abordagens, enquanto o MHP proposto foi avaliado com modelos mais simples de Aprendizado de Máquina.

Ressalta-se que o MHP possui a vantagem de necessitar somente de imagens *all-sky* como entrada, sem calibração de câmera, dispensando instrumentos de medições adicionais (meteorológicos e/ou irradiância solar) e, assim, diminuindo os custos de aquisição e operação do sistema de predição. Além de dispensar a necessidade de *hardware* robusto para a execução, o MHP é um modelo híbrido caixa-cinza que possui maior interpretabilidade de execução quando comparado aos tradicionais algoritmos de Aprendizado Profundo (AP), tal como as CNNs.

Por outro lado, o MHP também possui limitações que devem ser consideradas e exploradas. A primeira é o fato de o MHP ter seu funcionamento completamente dependente da captura de imagens *all-sky* (180°), onde problemas de captura ou ruídos como as chuvas e sujeiras podem prejudicar seu funcionamento. Adicionalmente, o conjunto de métricas de PI empregadas no MHP possuem limitações e problemas conhecidos na literatura da PGESF, tais como o *Otsu Threshold* (OTSU, 1979) e o *Red-Blue-Ratio* (RBR) (EŞLIK; AKARSLAN; HOCAOĞLU, 2022). No entanto, os modelos de AM utilizados demonstraram capacidade de captura e se adaptar as limitações das métricas de PI, possibilitando predizer de maneira satisfatória a variabilidade da irradiância nos horizontes avaliados.

É importante destacar que a principal etapa que agrega inteligência e ineditismo ao MHP proposto, consiste na extração de um conjunto de características simples (métricas de PI) das imagens por meio de técnicas de Processamento de Imagens (PI). Os resultados demonstraram que o uso destas métricas de PI propiciaram uma acurácia média geral superior para o MHP de 28% (MLP) a 44% (LightGBM). A abordagem de uso conjunto das métricas de PI no MHP proposto, abre um caminho para novas pesquisas na PGESF. Em estudos futuros, acredita-se que tal abordagem de processamento híbrido do MHP pode ser explorada e otimizada a partir de três aspectos principais:

i) Otimização do MHP para realizar predições em uma amplitude horizonte menor ou específico, principalmente entre 1 e 5 minutos;

ii) Estudos para proposição de novas métricas de PI ou otimizações das existentes e seleção daquelas mais relevantes, tal como, por exemplo, a aplicação do

método de *Principal Component Analysis* (PCA) (JOLLIFFE; CADIMA, 2016);

iii) Avaliação do MHP utilizando algoritmos mais robustos de Aprendizado Profundo (AP) para realizar as predições, tais como CNNs, 3D-CNNs, RNNs, LSTMs, BiLSTMs, entre outros.

iv) Avaliação do MHP em outros distintos *datasets*, inclusive com dados relativos à geração direta da energia solar fotovoltaica, ou ainda, testá-lo com um dispositivo dedicado real de processamento e captura de imagens *all-sky*;

REFERÊNCIAS

ABDEL-NASSER, Mohamed; MAHMOUD, Karar. Accurate photovoltaic power forecasting models using deep LSTM-RNN. **Neural Computing and Applications**, *[S. l.]*, v. 31, n. 7, p. 1–14, 2017. DOI: 10.1007/s00521-017-3225-z.

ABDULLAH, Nor Azliana; RAHIM, Nasrudin Abd; GAN, Chin Kim; ADZMAN, Noriah Nor. Forecasting solar power using hybrid firefly and particle swarm optimization (HFPSO) for optimizing the parameters in a wavelet transform-adaptive neuro fuzzy inference system (WT-ANFIS). **Applied Sciences (Switzerland)**, *[S. l.]*, v. 9, n. 16, p. 3214, 2019. DOI: 10.3390/app9163214.

ABEDINI, Mani; RAHIL GARNAVI, TIMOTHY M. LYNAR, Kew; CHRISTOPHER I. E. MESIKU; WAGNER, John M. **Solar irradiation modeling and forecasting using community based terrestrial sky imaging**, Patent US 20170351970-A1, 2017.

ABSOLAR. **Energia Solar Fotovoltaica no Brasil - Infográfico ABSOLAR**. 2022. Disponível em: https://www.absolar.org.br/mercado/infografico. Acesso em: 19 jul. 2022.

ABUELLA, Mohamed. Improving Combined Solar Power Forecasts Using Estimated Ramp Rates. **Transactions, IEEE PES Energy, Sustainable**, *[S. l.]*, p. 1–9, 2015.

ABUELLA, Mohamed; CHOWDHURY, Badrul. Random forest ensemble of support vector regression models for solar power forecasting. *Em*: 2017 IEEE POWER & ENERGY SOCIETY INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE (ISGT) 2017a: IEEE, 2017. p. 1–5. DOI: 10.1109/ISGT.2017.8086027.

ABUELLA, Mohamed; CHOWDHURY, Badrul. Hourly probabilistic forecasting of solar power. *Em*: 2017 NORTH AMERICAN POWER SYMPOSIUM (NAPS) 2017b: IEEE, 2017. p. 1–5. DOI: 10.1109/NAPS.2017.8107270.

ABUELLA, Mohamed; CHOWDHURY, Badrul. Improving combined solar power forecasts using estimated ramp rates: data-driven post-processing approach. **IET Renewable Power Generation**, Department of Electrical and Computer Engineering, Energy Production and Infrastructure Center, University of North Carolina, Charlotte, NC 28223, United States, v. 12, n. 10, p. 1127–1135, 2018. DOI: 10.1049/iet-rpg.2017.0447.

AGUIAR, L. M.; PEREIRA, B.; DAVID, M.; DÍAZ, F.; LAURET, P. Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks. **Solar Energy**, *[S. l.]*, 2015. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X15005927.

AGUIAR, L. M.; PEREIRA, B.; LAURET, P.; DÍAZ, F.; DAVID, M. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. **Renewable Energy**, *[S. l.]*, 2016. a. Disponível em: https://www.sciencedirect.com/science/article/pii/S0960148116305390.

AGUIAR, L. Mazorra; PEREIRA, B.; LAURET, P.; DÍAZ, F.; DAVID, M. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. **Renewable Energy**, University Institute for Intelligent Systems and Numerical Applications in Engineering, University of Las Palmas de Gran Canaria, Edificio Central del Parque Tecnológico, Campus de Tafira, 35017, Spain, v. 97, p. 599–610, 2016. b. DOI: 10.1016/j.renene.2016.06.018.

AHMED, R.; SREERAM, V.; MISHRA, Y.; ARIF, M. D. **A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization**. **Renewable and Sustainable Energy Reviews**Elsevier Ltd, , 2020. DOI: 10.1016/j.rser.2020.109792.

AI, Yiyang; PENG, Yonggang; WEI, Wei. A model of very short-term solar irradiance forecasting based on low-cost sky images. *Em*: (You, Z and Xiao, J and Tan, Z, Org.) AIP CONFERENCE PROCEEDINGS 2017. [s.l: s.n.] DOI: 10.1063/1.4982387.

AKHTER, Muhammad Naveed; MEKHILEF, Saad; MOKHLIS, Hazlie; SHAH, Noraisyah Mohamed. Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. **IET Renewable Power Generation**, *[S. l.]*, v. 13, n. 7, p. 1009–1023, 2019. DOI: 10.1049/iet-rpg.2018.5649.

AKIBA, Takuya; SANO, Shotaro; YANASE, Toshihiko; OHTA, Takeru; KOYAMA, Masanori. Optuna: A Next-generation Hyperparameter Optimization Framework. *Em*: PROCEEDINGS OF THE 25TH ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING 2019, New York, NY, USA. New York, NY, USA: ACM, 2019. p. 2623–2631. DOI: 10.1145/3292500.3330701. Disponível em: https://dl.acm.org/doi/10.1145/3292500.3330701.

AL-DAHIDI, Sameer; AYADI, Osama; ALRBAI, Mohammed; ADEEB, Jihad. Ensemble approach of optimized artificial neural networks for solar photovoltaic power prediction. **IEEE Access**, *[S. l.]*, v. 7, p. 81741–81758, 2019. DOI: 10.1109/ACCESS.2019.2923905.

ALI, Moez. **PyCaret: An open source, low-code machine learning library in Python**. , 2020. Disponível em: https://www.pycaret.org.

ALMEIDA, Marcelo Pinho; MUÑOZ, Mikel; DE LA PARRA, Iñigo; PERPIÑÁN, Oscar. Comparative study of PV power forecast using parametric and nonparametric PV models. **Solar Energy**, Instituto de Energia e Ambiente, Universidade de São Paulo, São Paulo, Brazil, v. 155, p. 854–866, 2017. DOI: 10.1016/j.solener.2017.07.032.

ALMEIDA, Marcelo Pinho; PERPIÑÁN, Oscar; NARVARTE, Luis. PV power forecast using a nonparametric PV model. **Solar Energy**, *[S. l.]*, v. 115, p. 354–368, 2015. DOI: 10.1016/j.solener.2015.03.006.

ANEEL. **Matriz de Energia Brasileira**. 2016. Disponível em: http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm. Acesso em: 18 out. 2019.

ANEEL. **Matriz de Energia Elétrica do Brasil**. 2019. Disponível em https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica. Acesso em: 10 out. 2020.

ANEEL. 2020. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - Módulo 8: Qualidade da Energia Elétrica**. Brasília-DF. Disponível em https://www.aneel.gov.br/modulo-8. Acesso em: 10 nov. 2022.

ANEEL. **Sistema de Informações de Geração da ANEEL - SIGA**. 2022. Disponível em: https://bit.ly/2IGf4Q0. Acesso em: 19 jul. 2022.

ANTONANZAS, J.; OSORIO, N.; ESCOBAR, R.; URRACA, R.; MARTINEZ-DE-PISON, F. J.; ANTONANZAS-TORRES, F. Review of photovoltaic power forecasting. **Solar Energy**, EDMANS Group, Department of Mechanical Engineering, University of La Rioja, Logroño, Spain, v. 136, p. 78–111, 2016. DOI: 10.1016/j.solener.2016.06.069.

ANTONANZAS-TORRES, F.; URRACA, R.; POLO, J.; PERPIÑÁN-LAMIGUEIRO, O.; ESCOBAR, R. Clear sky solar irradiance models: A review of seventy models. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 107, p. 374–387, 2019. DOI: 10.1016/j.rser.2019.02.032.

ARORA, Isha; GAMBHIR, Jaimala; KAUR, Tarlochan. Solar Irradiance Forecasting using Decision Tree and Ensemble Models. *Em*: 2020 SECOND INTERNATIONAL CONFERENCE ON INVENTIVE RESEARCH IN COMPUTING APPLICATIONS (ICIRCA) 2020. IEEE, 2020. p. 675–681. DOI: 10.1109/ICIRCA48905.2020.9182876.

ASRARI, Arash; WU, Thomas X.; RAMOS, Benito. A Hybrid Algorithm for Short-Term Solar Power Prediction - Sunshine State Case Study. **IEEE Transactions on Sustainable Energy**, *[S. l.]*, v. 8, n. 2, p. 582–591, 2017. DOI: 10.1109/TSTE.2016.2613962.

AYET, A.; TANDEO, P. Nowcasting solar irradiance using an analog method and geostationary satellite images. **Solar Energy**, *[S. l.]*, v. 164, p. 301–315, 2018. DOI: 10.1016/j.solener.2018.02.068.

BARBIERI, Florian; RAJAKARUNA, Sumedha; GHOSH, Arindam. Very short-term photovoltaic power forecasting with cloud modeling: A review. **Renewable and Sustainable Energy Reviews**, Curtin University, Department of Electrical and Computer Engineering, Kent Street, Bentley, WA 6102, Australia, v. 75, n. August 2015, p. 242–263, 2017. DOI: 10.1016/j.rser.2016.10.068.

BASSOUS, Guilherme Fonseca; CALILI, Rodrigo Flora; BARBOSA, Carlos Hall. Development of a Low-Cost Data Acquisition System for Very Short-Term Photovoltaic Power Forecasting. **Energies**, *[S. l.]*, v. 14, n. 19, p. 6075, 2021. DOI: 10.3390/en14196075. Disponível em: https://www.mdpi.com/1996-1073/14/19/6075.

BING, James M. **Method and apparatus for forecasting solar radiation and solar power production using synthetic irradiance imaging**, Patente US 2015177415-A1, 2015.

BISONG, Ekaba. Google Colaboratory. *Em*: **Building Machine Learning and Deep Learning Models on Google Cloud Platform**. Berkeley, CA: Apress, 2019. p. 59–64. DOI: 10.1007/978-1-4842-4470-8_7.

BIXEL, Paul S. **Method for predicting and mitigating power fluctuations at a photovoltaic power plant due to cloud cover**, Patent US 10133245-B2, 2018.

BLAGA, Robert; SABADUS, Andreea; STEFU, Nicoleta; DUGHIR, Ciprian; PAULESCU, Marius; BADESCU, Viorel. A current perspective on the accuracy of incoming solar energy forecasting. **Progress in Energy and Combustion Science**, Faculty of Physics, West University of Timisoara, V Parvan 4, Timisoara, 300223, Romania, v. 70, p. 119–144, 2019. DOI: 10.1016/j.pecs.2018.10.003.

BLUM, Niklas Benedikt et al. Measurement of diffuse and plane of array irradiance by a combination of a pyranometer and an all-sky imager. **Solar Energy**, *[S. l.]*, v. 232, n. January, p. 232–247, 2022. DOI: 10.1016/j.solener.2021.11.064.

BONE, Viv; PIDGEON, John; KEARNEY, Michael; VEERARAGAVAN, Ananthanarayanan. Intra-hour direct normal irradiance forecasting through adaptive clear-sky modelling and cloud tracking. **Solar Energy**, *[S. l.]*, v. 159, p. 852–867, 2018. DOI: 10.1016/j.solener.2017.10.037.

BRIGHT, Jamie M.; KILLINGER, Sven; LINGFORS, David; ENGERER, Nicholas A. Improved satellite-derived PV power nowcasting using real-time power data from reference PV systems. **Solar Energy**, *[S. l.]*, v. 168, p. 118–139, 2018. DOI: 10.1016/j.solener.2017.10.091.

CARNEIRO, Tatiane C.; ROCHA, Paulo A. C.; CARVALHO, Paulo C. M.; FERNÁNDEZ-RAMÍREZ, Luis M. Ridge regression ensemble of machine learning models applied to solar and wind forecasting in Brazil and Spain. **Applied Energy**, *[S. l.]*, v. 314, p. 118936, 2022. a. DOI: 10.1016/j.apenergy.2022.118936.

CARNEIRO, Tatiane Carolyne; DE CARVALHO, Paulo Cesar Marques; ALVES DOS SANTOS, Heron; LIMA, Marcello Anderson Ferreira Batista; BRAGA, Arthur Plinio de Souza. Review on Photovoltaic Power and Solar Resource Forecasting: Current Status and Trends. **Journal of Solar Energy Engineering**, *[S. l.]*, v. 144, n. 1, 2022. b. DOI: 10.1115/1.4051652.

CECI, Michelangelo; CORIZZO, Roberto; FUMAROLA, Fabio; MALERBA, Donato; RASHKOVSKA, Aleksandra. Predictive Modeling of PV Energy Production: How to Set Up the Learning Task for a Better Prediction? **IEEE Transactions on Industrial Informatics**, *[S. l.]*, v. 13, n. 3, p. 956–966, 2017. DOI: 10.1109/TII.2016.2604758.

CERVONE, Guido; CLEMENTE-HARDING, Laura; ALESSANDRINI, Stefano; DELLE MONACHE, Luca. Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble. **Renewable Energy**, *[S. l.]*, v. 108, p. 274–286, 2017. DOI: 10.1016/j.renene.2017.02.052.

CHANG, Ti-Chiun; ERNST, Jan; WILES, Jeremy Ralph; BAMBERGER, Joachim; SZABO, Andrei. **Short term cloud forecast, improved cloud recognition and prediction and uncertainty index estimation**, Patent WO 2018151782-A1, 2018.

CHAUVIN, R.; NOU, J.; THIL, S.; TRAORÉ, A.; GRIEU, S. Cloud Detection Methodology Based on a Sky-imaging System. **Energy Procedia**, *[S. l.]*, v. 69, p. 1970–1980, 2015. DOI: 10.1016/j.egypro.2015.03.198.

CHAUVIN, Rémi; NOU, Julien; EYNARD, Julien; THIL, Stéphane; GRIEU, Stéphane. A new approach to the real-time assessment and intraday forecasting of clear-sky direct

normal irradiance. **Solar Energy**, PROMES-CNRS (UPR 8521), Rambla de la thermodynamique, Tecnosud, Perpignan, 66100, France, v. 167, p. 35–51, 2018. a. DOI: 10.1016/j.solener.2018.02.027.

CHAUVIN, Rémi; NOU, Julien; EYNARD, Julien; THIL, Stéphane; GRIEU, Stéphane. A new approach to the real-time assessment and intraday forecasting of clear-sky direct normal irradiance. **Solar Energy**, PROMES-CNRS (UPR 8521), Rambla de la thermodynamique, Tecnosud, Perpignan, 66100, France, v. 167, p. 35–51, 2018. b. DOI: 10.1016/j.solener.2018.02.027.

CHENG, Hsu Yung; YU, Chih Chang; LIN, Sian Jing. Bi-model short-term solar irradiance prediction using support vector regressors. **Energy**, Department of Computer Science and Information Engineering, National Central University, No. 300 Jhongda Rd., Jhongli City, Taoyuan County, Taiwan, v. 70, p. 121–127, 2014. DOI: 10.1016/j.energy.2014.03.096.

CHOW, C. W.; BELONGIE, S.; KLEISSL, J. Cloud motion and stability estimation for intra-hour solar forecasting. **Solar Energy**, *[S. l.]*, 2015. a. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X15001565.

CHOW, C. W.; URQUHART, B.; LAVE, M.; DOMINGUEZ, A.; KLEISSL, J. Intra-hour forecasting with a total sky imager at the UC San Diego solar energy testbed. **Solar Energy**, *[S. l.]*, 2011. a. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X11002982.

CHOW, Chi Wai; BELONGIE, Serge; KLEISSL, Jan. Cloud motion and stability estimation for intra-hour solar forecasting. **Solar Energy**, *[S. l.]*, v. 115, p. 645–655, 2015. b. DOI: 10.1016/j.solener.2015.03.030.

CHOW, Chi Wai; URQUHART, Bryan; LAVE, Matt; KLEISSL, Jan. Intra-hour forecasting with a total sky imager at the UC san Diego solar energy testbed. *Em*: 40TH ASES NATIONAL SOLAR CONFERENCE 2011, SOLAR 2011 2011b, University of California, 9500 Gilman Drive, San Diego, CA, United States. University of California, 9500 Gilman Drive, San Diego, CA, United States: Elsevier Ltd, 2011. p. 248–256. DOI: 10.1016/j.solener.2011.08.025.

CHOW, Chi Wai; URQUHART, Bryan; LAVE, Matthew; DOMINGUEZ, Anthony; KLEISSL, Jan; SHIELDS, Janet; WASHOM, Byron. Intra-hour forecasting with a total sky imager at the UC San Diego solar energy testbed. *Em*: SOLAR ENERGY 2011c, University of California, 9500 Gilman Drive, San Diego, CA, United States. University of California, 9500 Gilman Drive, San Diego, CA, United States: Elsevier Ltd, 2011. p. 2881–2893. DOI: 10.1016/j.solener.2011.08.025.

CHU, Yinghao; URQUHART, Bryan; GOHARI, Seyyed M. I.; PEDRO, Hugo T. C.; KLEISSL, Jan; COIMBRA, Carlos F. M. Short-term reforecasting of power output from a 48 MWe solar PV plant. **Solar Energy**, Department of Mechanical and Aerospace Engineering, Jacobs School of Engineering, Center for Renewable Resource Integration, University of California, San Diego, 9500 Gilman Drive, La Jolla, CA 92093, United States, v. 112, p. 68–77, 2015. DOI: 10.1016/j.solener.2014.11.017.

COCOCCIONI, Marco; D'ANDREA, Eleonora; LAZZERINI, Beatrice. 24-hour-ahead forecasting of energy production in solar PV systems. *Em*: 2011 11TH INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS 2011, Dipartimento di Ingegneria dell'Informazione: Elettronica, Informatica, Telecomunicazioni, University of Pisa, Largo Lucio Lazzarino, 1, 56122 Pisa, Italy: IEEE, 2011. p. 1276–1281. DOI: 10.1109/ISDA.2011.6121835.

COCOCCIONI, Marco; D'ANDREA, Eleonora; LAZZERINI, Beatrice. One day-ahead forecasting of energy production in solar photovoltaic installations: An empirical study. **Intelligent Decision Technologies**, Dipartimento di Ingegneria dell'Informazione: Elettronica, Informatica, Telecomunicazioni, University of Pisa, Largo Lucio Lazzarino 1, 56122 Pisa, Italy, v. 6, n. 3, p. 197–210, 2012. DOI: 10.3233/IDT-2012-0136.

CORNEJO-BUENO, L.; CASANOVA-MATEO, C.; SANZ-JUSTO, J.; SALCEDO-SANZ, S. Machine learning regressors for solar radiation estimation from satellite data. **Solar Energy**, Department of Signal Processing and Communications, Universidad de Alcalá, Alcalá de Henares, Spain, v. 183, p. 768–775, 2019. DOI: 10.1016/j.solener.2019.03.079. Disponível em:

DA SILVA FONSECA, Joao Gari; OOZEKI, Takashi; OHTAKE, Hideaki; SHIMOSE, Ken Ichi; TAKASHIMA, Takumi; OGIMOTO, Kazuhiko. Forecasting regional photovoltaic power generation - A comparison of strategies to obtain one-day-ahead data. **Energy Procedia**, *[S. l.]*, v. 57, p. 1337–1345, 2014. DOI: 10.1016/j.egypro.2014.10.124.

DAS, Utpal Kumar; TEY, Kok Soon; SEYEDMAHMOUDIAN, Mehdi; MEKHILEF, Saad; IDRIS, Moh Yamani Idna; VAN DEVENTER, Willem; HORAN, Bend; STOJCEVSKI, Alex. Forecasting of photovoltaic power generation and model optimization: A review. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 81, n. August 2017, p. 912–928, 2018. DOI: 10.1016/j.rser.2017.08.017.

DAZHI, Yang; PANIDA, Jirutitijaroen; M., Walsh Wilfred. Hourly solar irradiance time series forecasting using cloud cover index. **Solar Energy**, Department of Electrical and Computer Engineering, National University of Singapore, Singapore, v. 86, n. 12, p. 3531–3543, 2012. DOI: 10.1016/j.solener.2012.07.029.

DE FREITAS VISCONDI, Gabriel; ALVES-SOUZA, Solange N. A Systematic Literature Review on big data for solar photovoltaic electricity generation forecasting. **Sustainable Energy Technologies and Assessments**, *[S. l.]*, v. 31, p. 54–63, 2019. DOI: 10.1016/j.seta.2018.11.008.

DEFRAIGNE, Jean Christophe. **Sustainable growth in China and the EU: Competition or cooperation?** Université libre de Bruxelles - ULB, Belgium: Taylor and Francis, 2017. DOI: 10.4324/9781315173733.

DEGTYAREV, Alexander S.; KOSENKO, Viktor I.; ENGEL, Ekaterina A.; ENGEL, Nikita N.; SAVELYEVA, Marina V. Power forecasting for a photovoltaic system based on the multi-agent adaptive fuzzy neuronet. *Em*: IOP CONFERENCE SERIES: MATERIALS SCIENCE AND ENGINEERING 2018, [s.l: s.n.] DOI: 10.1088/1757-899X/450/7/072012.

DENIS, Yvan; SUARD, Frédéric; LOMET, Aurore; CHÈZE, David. Saving energy by anticipating hot water production: Identification of key points for an efficient statistical model integration. **Artificial Intelligence for Engineering Design, Analysis and Manufacturing: AIEDAM**, LIANES, CEA, Technopôle Savoie Technolac, INES 50 avenue du lac Léman, Le Bourget du Lac Cedex, 73375, France, v. 33, n. 2, p. 138–147, 2019. DOI: 10.1017/S0890060419000143.

DEO, Ravinesh C.; ŞAHIN, Mehmet. Forecasting long-term global solar radiation with an ANN algorithm coupled with satellite-derived (MODIS) land surface temperature (LST) for regional locations in Queensland. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 72, p. 828–848, 2017. DOI: 10.1016/j.rser.2017.01.114.

DEO, Ravinesh C.; ŞAHIN, Mehmet; ADAMOWSKI, Jan F.; MI, Jianchun. Universally deployable extreme learning machines integrated with remotely sensed MODIS satellite predictors over Australia to forecast global solar radiation: A new approach. **Renewable and Sustainable Energy Reviews**, School of Agricultural Computational and Environmental Sciences, Centre for Sustainable Agricultural Systems & Centre for Applied Climate Sciences, Institute of Life Sciences and the Environment, University of Southern QueenslandQLD 4300, Australia, v. 104, p. 235–261, 2019. DOI: 10.1016/j.rser.2019.01.009.

DEV, Soumyabrata; SAVOY, Florian M.; LEE, Yee Hui; WINKLER, Stefan. Estimation of solar irradiance using ground-based whole sky imagers. *[S. l.]*, 2016. Disponível em: http://arxiv.org/abs/1606.02546.

DEV, Soumyabrata; SAVOY, Florian M.; LEE, Yee Hui; WINKLER, Stefan. Estimating Solar Irradiance Using Sky Imagers. *[S. l.]*, 2019. Disponível em: http://arxiv.org/abs/1910.04981.

DIAGNE, Maimouna; DAVID, Mathieu; LAURET, Philippe; BOLAND, John; SCHMUTZ, Nicolas. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 27, p. 65–76, 2013. DOI: 10.1016/j.rser.2013.06.042.

DIAZ, Valentin Silvera. **Avaliação de desempenho das estratégias de controle para suavização da potência ativa de sistemas fotovoltaicos com armazenamento de energia**. 2019. Dissertação de Mestrado. Universidade Estadual do Oeste do Paraná (UNIOESTE), *[S. l.]*, 2019.

DING, Ming; WANG, Lei; BI, Rui. An ANN-based approach for forecasting the power output of photovoltaic system. *Em*: PROCEDIA ENVIRONMENTAL SCIENCES 2011. [s.l: s.n.] p. 1308–1315. DOI: 10.1016/j.proenv.2011.12.196.

DISSAWA, Lasanthika H.; GODALIYADDA, Roshan I.; EKANAYAKE, Parakrama B.; AGALGAONKAR, Ashish P.; ROBINSON, Duane; EKANAYAKE, Janaka B.; PERERA, Sarath. Sky Image-Based Localized, Short-Term Solar Irradiance Forecasting for Multiple PV Sites via Cloud Motion Tracking. **International Journal of Photoenergy**, *[S. l.]*, v. 2021, p. 1–27, 2021. a. DOI: 10.1155/2021/9973010. Disponível em: https://www.hindawi.com/journals/ijp/2021/9973010/.

DISSAWA, Lasanthika; ROBINSON, Duane; AGALGAONKAR, Ashish; GODALIYADDA, Roshan; EKANAYAKE, Parakrama; PERERA, Sarath; EKANAYAKE, Janaka. **Sky Images and PV Power Measurements for Irradiance Forecasting**. **Mendeley Data**, 2021. b. DOI: 10.17632/cb8t8np9z3.2. Disponível em: http://10.17632/cb8t8np9z3.2. Acesso em: 25 mar. 2022.

DOMINGUEZ, Luis; MERCANGOEZ, Mehmet; CORTINOVIS, Andrea; ZEYDAN, Burak. **Solar irradiance forecasting**, Patent WO 2015104281-A1, 2015.

DOU, Chunxia; QI, Hang; LUO, Wei; ZHANG, Yamin. Elman neural network based short-term photovoltaic power forecasting using association rules and kernel principal component analysis. **Journal of Renewable and Sustainable Energy**, *[S. l.]*, v. 10, n. 4, 2018. DOI: 10.1063/1.5022393.

DREES, Kirk H. **Photovoltaic energy system with solar intensity prediction**, Patent US 2017104449-A1, 2017.

DU, Juan; MIN, Qilong; ZHANG, Penglin; GUO, Jinhui; YANG, Jun; YIN, Bangsheng. Short-term solar irradiance forecasts using sky images and radiative transfer model. **Energies**, *[S. l.]*, v. 11, n. 5, 2018. DOI: 10.3390/en11051107.

DU, Peidong; ZHANG, Gang; LI, Pingli; LI, Meng; LIU, Hongchi; HOU, Jinwang. The Photovoltaic Output Prediction Based on Variational Mode Decomposition and Maximum Relevance Minimum Redundancy. **Applied Sciences**, State Key Laboratory of Eco-Hydraulics in Northwest Arid Region, Xi'an University of Technology, Xi'an, 710048, China, v. 9, n. 17, p. 3593, 2019. DOI: 10.3390/app9173593.

DU, Pengwei; LU, Ning. **Energy Storage for Smart Grids: Planning and Operation for Renewable and Variable Energy Resources (VERs)**. [s.l.] : Elsevier, 2014.

DÜRR, Oliver; SICK, Beate; MURINA, Elvis. **Probabilistic Deep Learning: with Python, Keras and Tensorflow Probability**. [s.l.] : Manning Publications, 2020.

EL-KENAWY, E. S. M.; MIRJALILI, S.; GHONEIM, S. S. M. Advanced Ensemble Model for Solar Radiation Forecasting Using Sine Cosine Algorithm and Newton's Laws. **IEEE …**, *[S. l.]*, 2021. Disponível em: https://ieeexplore.ieee.org/abstract/document/9519711/.

ELLIS, Abraham; SCHOENWALD, David; HAWKINS, Jon; WILLARD, Steve; ARELLANO, Brian. PV output smoothing with energy storage. **Conference Record of the IEEE Photovoltaic Specialists Conference**, *[S. l.]*, p. 1523–1528, 2012. DOI: 10.1109/PVSC.2012.6317885.

ELSEVIER. **Mendeley**. Elsevier, 2019. Disponível em: https://www.mendeley.com.

ELSINGA, Boudewijn; VAN SARK, Wilfried G. J. H. M. Short-term peer-to-peer solar forecasting in a network of photovoltaic systems. **Applied Energy**, Utrecht University, Copernicus Institute of Sustainable Development, PO Box 80.115, TC Utrecht, 3508, Netherlands, v. 206, p. 1464–1483, 2017. DOI: 10.1016/j.apenergy.2017.09.115.

ENSSLIN, L.; ENSSLIN, S. R.; LACERDA, R. T. O.; TASCA, J. E. **Processo de Análise Sistêmica. Processo técnico com patente de registro pendente junto ao INPI.** 2010.

ENSSLIN, Sandra Rolim; ENSSLIN, Leonardo; YAMAKAWA, Eduardo Kazumi; NAGAOKA, Marilda da Penha Teixeira; AOKI, Alexandre Rasi; SIEBERT, Luciano Cavalcante. Processo Estruturado de Revisão da Literatura e Análise Bibliométrica Sobre Avaliação de Desempenho de Processos de Implementação de Eficiência Energética. **Revista Brasileira de Energia**, *[S. l.]*, v. 20 n.1, p. 21–50, 2014.

ESCRIG, H.; BATLLES, F. J.; ALONSO, J.; BAENA, F. M.; BOSCH, J. L.; SALBIDEGOITIA, I. B.; BURGALETA, J. I. Cloud detection, classification and motion estimation using geostationary satellite imagery for cloud cover forecast. **Energy**, *[S. l.]*, v. 55, p. 853–859, 2013. DOI: 10.1016/j.energy.2013.01.054.

EŞLIK, Ardan Hüseyin; AKARSLAN, Emre; HOCAOĞLU, Fatih Onur. Short-term solar radiation forecasting with a novel image processing-based deep learning approach. **Renewable Energy**, *[S. l.]*, v. 200, p. 1490–1505, 2022. DOI: 10.1016/j.renene.2022.10.063.

F. HOLMGREN, William; W. HANSEN, Clifford; A. MIKOFSKI, Mark. pvlib python: a python package for modeling solar energy systems. **Journal of Open Source Software**, *[S. l.]*, v. 3, n. 29, p. 884, 2018. DOI: 10.5281/zenodo.593284.

FENG, Minwei; KHABIBRAKHMANOV, Idar; KUMAR, Tarun; LAVIN, Mark A.; WARREN, Kevin W.; ZHANG, Rui; ZHANG, Wei. **Forecasting solar power output**, Patent US 2019064392-A1, 2019.

FERNANDEZ-JIMENEZ, L. Alfredo; MUÑOZ-JIMENEZ, Andrés; FALCES, Alberto; MENDOZA-VILLENA, Montserrat; GARCIA-GARRIDO, Eduardo; LARA-SANTILLAN, Pedro M.; ZORZANO-ALBA, Enrique; ZORZANO-SANTAMARIA, Pedro J. Short-term power forecasting system for photovoltaic plants. **Renewable Energy**, *[S. l.]*, v. 44, p. 311–317, 2012. DOI: 10.1016/j.renene.2012.01.108.

FOUILLOY, Alexis; VOYANT, Cyril; NOTTON, Gilles; MOTTE, Fabrice; PAOLI, Christophe; NIVET, Marie Laure M. L.; GUILLOT, Emmanuel; DUCHAUD, Jean Laurent J. L. Solar irradiation prediction with machine learning: Forecasting models selection method depending on weather variability. **Energy**, University of Corsica, Centre Georges Péri, Route des Sanguinaires, CNRS UMR SPE 6134, Ajaccio, 20000, France, v. 165, p. 620–629, 2018. a. DOI: 10.1016/j.energy.2018.09.116.

FOUILLOY, Alexis; VOYANT, Cyril; NOTTON, Gilles; MOTTE, Fabrice; PAOLI, Christophe; NIVET, Marie Laure M. L.; GUILLOT, Emmanuel; DUCHAUD, Jean Laurent J. L. Solar irradiation prediction with machine learning: Forecasting models selection method depending on weather variability. **Energy**, University of Corsica, Centre Georges Péri, Route des Sanguinaires, CNRS UMR SPE 6134, Ajaccio, 20000, France, v. 165, p. 620–629, 2018. b. DOI: 10.1016/j.energy.2018.09.116.

FU, Chia Lin; CHENG, Hsu Yung. Predicting solar irradiance with all-sky image features via regression. **Solar Energy**, *[S. l.]*, v. 97, p. 537–550, 2013. DOI: 10.1016/j.solener.2013.09.016.

GAO, Bixuan; HUANG, Xiaoqiao; SHI, Junsheng; TAI, Yonghang; XIAO, Rui. Predicting day-ahead solar irradiance through gated recurrent unit using weather forecasting data. **Journal of Renewable and Sustainable Energy**, *[S. l.]*, v. 11, n. 4, p. 043705, 2019. a. DOI: 10.1063/1.5110223.

GAO; LI; HONG; LONG. Short-Term Forecasting of Power Production in a Large-Scale Photovoltaic Plant Based on LSTM. **Applied Sciences**, *[S. l.]*, v. 9, n. 15, p. 3192, 2019. b. DOI: 10.3390/app9153192.

GAY, Warren. **Raspberry Pi Hardware Reference**. 1st. ed. USA: Apress, 2014.

GENSLER, Andre; HENZE, Janosch; SICK, Bernhard; RAABE, Nils. Deep Learning for solar power forecasting - An approach using AutoEncoder and LSTM Neural Networks. *Em*: 2016 IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, SMC 2016 - CONFERENCE PROCEEDINGS 2017, [s.l: s.n.] p. 2858–2865. DOI: 10.1109/SMC.2016.7844673.

GENSLER, Andre; SICK, Bernhard; PANKRAZ, Vitali. An analog ensemble-based similarity search technique for solar power forecasting. *Em*: 2016 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2016 - Conference Proceedings 2017, [s.l: s.n.] p. 2850–2857. DOI: 10.1109/SMC.2016.7844672.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 6ª Edição ed. São Paulo.: Atlas, 2017.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital image processing**. 2nd. ed. [s.l: s.n.]. v. 1

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge, MA, USA: MIT Press, 2016. DOI: 10.1016/b978-0-12-814761-0.00010-1. Disponível em: www.deeplearningbook.org.

GUARISO, Giorgio; NUNNARI, Giuseppe; SANGIORGIO, Matteo. Multi-step solar irradiance forecasting and domain adaptation of deep neural networks. **Energies**, *[S. l.]*, v. 13, n. 15, p. 3987, 2020. DOI: 10.3390/en13153987. Disponível em: https://www.mdpi.com/1996-1073/13/15/3987.

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**, *[S. l.]*, v. 39, p. 1024–1034, 2014. DOI: 10.1016/j.rser.2014.07.117. Disponível em: http://dx.doi.org/10.1016/j.rser.2014.07.117.

GUTIERREZ-COREA, F. V; MANSO-CALLEJO, M. A.Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations. **Solar Energy**, *[S. l.]*, 2016. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X16300536.

HAMMER, A.; HEINEMANN, D.; LUCKEHE, B. Short-Term Forecasting of Solar Radiation : a Statistical Approach Using Satellite Data. **Solar Energy**, *[S. l.]*, v. 67, n. 1992, p. 139–150, 2000.

HARTUNG, Schmidt Michael; ANTON, Heller Christian Maria; GERHARD, Mayer Oliver; MARCUS, Zettl; STERN, Gonzalez Omar Ivan; MENDEZ, Hernandez Yaru Nagem; RONALD, Lynass Mark; BERNAL, Serra Eva. **Method and system for predicting cloud movement**, Patent EP 2645135-A1, 2013.

HENSEL, Stefan; MARINOV, Marin B.; SCHWARZ, Raphael; GANEV, Borislav. Algorithms for Cloud Segmentation with Ground-based Camera Images. *Em*: 2018 7TH BALKAN CONFERENCE ON LIGHTING, BALKANLIGHT 2018 - PROCEEDINGS 2018, Department for Electrical Engineering, University of Applied Sciences Offenburg, Badstraße 24, Offenburg, D-77652, Germany: Institute of Electrical and Electronics Engineers Inc., 2018. DOI: 10.1109/BalkanLight.2018.8546948.

HOFF, Thomas E. **Computer-implemented system and method for generating a probabilistic forecast of photovoltaic fleet power generation**, Patent US 8437959-B2, 2013.

HOFF, Thomas E. **System and method for correlating point-to-point sky clearness for use in photovoltaic fleet output estimation with the aid of a digital computer**, Patent US 10436942, 2019. a.

HOFF, Thomas E. **System and Method for Irradiance - Based Estimation of Photovoltaic Fleet Power Generation With the Aid of a Digital**, Patent US 20190170901-A1, 2019. b.

HOFF, Thomas E. **System And Method For Estimating Photovoltaic Energy Through Linearly Interpolated Clearness Indexes With The Aid Of A Digital Computer** 2020.

HOSSAIN, Mohammad Safayet; MAHMOOD, Hisham. Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast. **IEEE Access**, *[S. l.]*, v. 8, p. 172524–172533, 2020. DOI: 10.1109/ACCESS.2020.3024901. Disponível em: https://ieeexplore.ieee.org/document/9200614/.

HU, Keyong; CAO, Shihua; WANG, Lidong; LI, Wenjuan; LV, Mingqi. A new ultra-short-term photovoltaic power prediction model based on ground-based cloud images. **Journal of Cleaner Production**, *[S. l.]*, v. 200, p. 731–745, 2018. a. DOI: 10.1016/j.jclepro.2018.07.311.

HU, Yang; LIAN, Weiwei; HAN, Yutong; DAI, Songyuan; ZHU, Honglu. A seasonal model using optimized multi-layer neural networks to forecast power output of pv plants. **Energies**, *[S. l.]*, v. 11, n. 2, 2018. b. DOI: 10.3390/en11020326.

HUANG, Chiou Jye; KUO, Ping Huan. Multiple-Input Deep Convolutional Neural Network Model for Short-Term Photovoltaic Power Forecasting. **IEEE Access**, *[S. l.]*, v. 7, p. 74822–74834, 2019. DOI: 10.1109/ACCESS.2019.2921238.

HUANG, Hao; XU, Jin; PENG, Zhenzhou; YOO, Shinjae; YU, Dantong; HUANG, Dong; QIN, Hong. **Cloud motion estimation for short term solar irradiation prediction**. **2013 IEEE International Conference on Smart Grid Communications, SmartGridComm,** Vancouver, CANADA, 2013. DOI: 10.1109/SmartGridComm.2013.6688040.

HUSEIN, Munir; CHUNG, Il Yop. Day-ahead solar irradiance forecasting for microgrids using a long short-term memory recurrent neural network: A deep learning approach. **Energies**, School of Electrical Engineering, Kookmin University, 77 Jeongneung-ro, Seongbuk-gu, Seoul, 02707, South Korea, v. 12, n. 10, 2019. DOI: 10.3390/en12101856.

INACIO, Cleber Onofre; BORGES, Carmen Lucia Tancredo. Stochastic Model for Generation of High-Resolution Irradiance Data and Estimation of Power Output of Photovoltaic Plants. **IEEE Transactions on Sustainable Energy**, *[S. l.]*, v. 9, n. 2, p. 952–960, 2018. DOI: 10.1109/TSTE.2017.2767780.

INEICHEN, Pierre; PEREZ, Richard. A new airmass independent formulation for the Linke turbidity coefficient. **Solar Energy**, *[S. l.]*, v. 73, n. 3, p. 151–157, 2002. DOI: 10.1016/S0038-092X(02)00045-2. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0038092X02000452.

INMAN, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. Solar forecasting methods for renewable energy integration. **Progress in Energy and Combustion Science**, Department of Mechanical and Aerospace Engineering, Jacobs School of Engineering, University of California, 9500 Gilman Drive, San Diego, CA 92093, United States, v. 39, n. 6, p. 535–576, 2013. DOI: 10.1016/j.pecs.2013.06.002.

INPE. **Instituto Nacional de Pesquisas Espaciais**. 2020. Disponível em: http://www.inpe.br. Acesso em: 19 out. 2020.

IRENA. **Renewable Capacity Statistics**. 2020. Abu Dhabi. DOI: ISBN 978-92-9260-239-0.

ITU. **Parameter values for the HDTV standards for production and international programme exchange**. Geneva. Disponível em: https://www.itu.int/dms_pubrec/itu-r/rec/bt/R-REC-BT.709-6-201506-I!!PDF-E.pdf. Acesso em: 1 ago. 2022.

JAMALY, Mohammad; KLEISSL, Jan. Spatiotemporal interpolation and forecast of irradiance data using Kriging. **Solar Energy**, *[S. l.]*, v. 158, n. October, p. 407–423, 2017. DOI: 10.1016/j.solener.2017.09.057.

JAMALY, Mohammad; KLEISSL, Jan. Robust cloud motion estimation by spatio-temporal correlation analysis of irradiance data. **Solar Energy**, *[S. l.]*, v. 159, n. October 2017, p. 306–317, 2018. DOI: 10.1016/j.solener.2017.10.075. Disponível em: https://doi.org/10.1016/j.solener.2017.10.075.

JAYADEVAN, Vijai Thottathil; RODRIGUEZ, Jeffrey J.; LONIJ, Vincent P. A.; CRONIN, Alexander D. Forecasting solar power intermittency using ground-based cloud imaging. *Em*: World Renewable Energy Forum, WREF 2012, Including World Renewable Energy Congress XII and Colorado Renewable Energy Society (Cres) Annual Conferen 2012, Department of Electrical and Computer Engineering, University of Arizona, Tucson, AZ 85721, United States. Department of Electrical and Computer Engineering, University of Arizona, Tucson, AZ 85721, United States p. 2100–2106.

JING, Bo; QIAN, Zheng; PEI, Yan; WANG, Jingyi. Ultra short-term PV power forecasting based on ELM segmentation model. **The Journal of Engineering**, *[S. l.]*, v. 2017, n. 13, p. 2564–2568, 2017. DOI: 10.1049/joe.2017.0790.

JOLLIFFE, Ian T.; CADIMA, Jorge. Principal component analysis: a review and recent developments. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, *[S. l.]*, v. 374, n. 2065, p. 20150202, 2016. DOI: 10.1098/rsta.2015.0202.

JUNCKLAUS MARTINS, Bruno; CERENTINI, Allan; MANTELLI, Sylvio Luiz; LOUREIRO CHAVES, Thiago Zimmermann; MOREIRA BRANCO, Nicolas; VON WANGENHEIM, Aldo; RÜTHER, Ricardo; MARIAN ARRAIS, Juliana. Systematic review of nowcasting approaches for solar energy production based upon ground-based cloud imaging. **Solar Energy Advances**, *[S. l.]*, v. 2, p. 100019, 2022. DOI: 10.1016/j.seja.2022.100019.

KANG, Byung O.; TAM, Kwa Sur. A new characterization and classification method for daily sky conditions based on ground-based solar irradiance measurement data. **Solar Energy**, Department of Electrical and Computer Engineering, Virginia Tech, Blacksburg, VA, United States, v. 94, p. 102–118, 2013. DOI: 10.1016/j.solener.2013.04.007.

KAZANTZIDIS, A.; TZOUMANIKAS, P.; BAIS, A. F.; FOTOPOULOS, S.; ECONOMOU, G. Cloud detection and classification with the use of whole-sky ground-based images. **Atmospheric Research**, *[S. l.]*, v. 113, p. 80–88, 2012. DOI: 10.1016/j.atmosres.2012.05.005.

KAZANTZIDIS, Andreas; TZOUMANIKAS, Panagiotis; BLANC, Philippe; MASSIP, Pierre; WILBERT, Stefan; RAMIREZ-SANTIGOSA, Lourdes. Short-term forecasting based on all-sky cameras. *Em*: **Renewable Energy Forecasting: From Models to Applications**. [s.l.] : Elsevier, 2017. p. 153–178. DOI: 10.1016/B978-0-08-100504-0.00005-6. Disponível em: http://dx.doi.org/10.1016/B978-0-08-100504-0.00005-6.

KE, Guolin; MENG, Qi; FINLEY, Thomas; WANG, Taifeng; CHEN, Wei; MA, Weidong; YE, Qiwei; LIU, Tie-Yan. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Em*: 31ST CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS (NIPS 2017), LONG BEACH, CA, USA. 2017. [s.l: s.n.] p. 1–9. Disponível em: https://github.com/Microsoft/LightGBM.

KERKER, Milton. Blue skies and the Tyndall effect. **Journal of Chemical Education**, *[S. l.]*, v. 48, n. 6, p. 389, 1971. DOI: 10.1021/ed048p389.1.

KHANDAKAR, Amith; E. H. CHOWDHURY, Muhammad; KHODA KAZI, Monzure-; BENHMED, Kamel; TOUATI, Farid; AL-HITMI, Mohammed; JR S. P. GONZALES, Antonio. Machine Learning Based Photovoltaics (PV) Power Prediction Using Different Environmental Parameters of Qatar. **Energies**, *[S. l.]*, v. 12, n. 14, p. 2782, 2019. DOI: 10.3390/en12142782.

KHATIB, Tamer; MOHAMED, Azah; SOPIAN, K. A review of solar energy modeling techniques. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 16, n. 5, p. 2864–2869, 2012. DOI: 10.1016/j.rser.2012.01.064.

KHUMMA, Kriangkamon; CHAIWONG, Khomyuth; TAMEE, Kreangsak. Very short-term photovoltaic power forecasting considering the stochastic factors. *Em*: ECTI DAMT-NCON 2019 - 4TH International Conference on Digital Arts, Media and Technology and

2nd ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering 2019, [s.l: s.n.] p. 21–24. DOI: 10.1109/ECTI-NCON.2019.8692258.

KONSTANTINOU, Maria; PERATIKOU, Stefani; CHARALAMBIDES, Alexandros G. Solar Photovoltaic Forecasting of Power Output Using LSTM Networks. **Atmosphere**, *[S. l.]*, v. 12, n. 1, p. 124, 2021. DOI: 10.3390/atmos12010124. Disponível em: https://www.mdpi.com/2073-4433/12/1/124.

KUMAR, Dhivya Sampath; YAGLI, Gokhan Mert; KASHYAP, Monika; SRINIVASAN, Dipti. Solar irradiance resource and forecasting: a comprehensive review. **IET Renewable Power Generation**, *[S. l.]*, v. 14, n. 10, p. 1641–1656, 2020. DOI: 10.1049/iet-rpg.2019.1227.

KUMARI, Pratima; TOSHNIWAL, Durga. Deep learning models for solar irradiance forecasting: A comprehensive review. **Journal of Cleaner Production**, *[S. l.]*, v. 318, n. May, p. 128566, 2021. DOI: 10.1016/j.jclepro.2021.128566. Disponível em: https://doi.org/10.1016/j.jclepro.2021.128566.

LAGO, Jesus; DE BRABANDERE, Karel; DE RIDDER, Fjo; DE SCHUTTER, Bart. Short-term forecasting of solar irradiance without local telemetry: A generalized model using satellite data. **Solar Energy**, *[S. l.]*, v. 173, p. 566–577, 2018. DOI: 10.1016/j.solener.2018.07.050.

LAGO, Jesus; DE BRABANDERE, Karel; DE RIDDER, Fjo; DE SCHUTTER, Bart. A generalized model for short-term forecasting of solar irradiance. *Em*: PROCEEDINGS OF THE IEEE CONFERENCE ON DECISION AND CONTROL 2019, Delft Center for Systems and Control, Delft University of Technology, Delft, Netherlands: Institute of Electrical and Electronics Engineers Inc., 2019. p. 3165–3170. DOI: 10.1109/CDC.2018.8618693.

LAPPALAINEN, Kari; VALKEALAHTI, Seppo. Photovoltaic mismatch losses caused by moving clouds. **Solar Energy**, *[S. l.]*, v. 158, n. October, p. 455–461, 2017. DOI: 10.1016/j.solener.2017.10.001.

LARSON, David P.; NONNENMACHER, Lukas; COIMBRA, Carlos F. M. Day-ahead forecasting of solar power output from photovoltaic plants in the American Southwest. **Renewable Energy**, Department of Mechanical and Aerospace Engineering, Jacobs School of Eng., Center of Excellence in Renewable Energy Integration, Center for Energy Res., University of California San Diego, La Jolla, CA 92093, United States, v. 91, p. 11–20, 2016. DOI: 10.1016/j.renene.2016.01.039.

LEE, Donghun; KIM, Kwanho. Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information. **Energies**, *[S. l.]*, v. 12, n. 2, 2019. DOI: 10.3390/en12020215.

LEONG, Mei Chee; PRASAD, Dilip K.; LEE, Yong Tsui; LIN, Feng. Semi-CNN Architecture for Effective Spatio-Temporal Learning in Action Recognition. **Applied Sciences**, *[S. l.]*, v. 10, n. 2, p. 557, 2020. DOI: 10.3390/app10020557. Disponível em: https://www.mdpi.com/2076-3417/10/2/557.

LI, Danny H. W.; CHEN, Wenqiang; LI, Shuyang; LOU, Siwei. Estimation of hourly global solar radiation using Multivariate Adaptive Regression Spline (MARS) – A case study of Hong Kong. **Energy**, *[S. l.]*, v. 186, p. 115857, 2019. a. DOI: 10.1016/j.energy.2019.115857.

LI, Gangqiang; WANG, Huaizhi; ZHANG, Shengli; XIN, Jiantao; LIU, Huichuan. Recurrent neural networks based photovoltaic power forecasting approach. **Energies**, *[S. l.]*, v. 12, n. 13, 2019. b. DOI: 10.3390/en12132538.

LI, Gangqiang; WANG, Huaizhi; ZHANG, Shengli; XIN, Jiantao; LIU, Huichuan. Recurrent neural networks based photovoltaic power forecasting approach. **Energies**, *[S. l.]*, v. 12, n. 13, p. 1–17, 2019. c. DOI: 10.3390/en12132538.

LI, Ling Ling; CHENG, Peng; LIN, Hsiung Cheng; DONG, Hao. Short-term output power forecasting of photovoltaic systems based on the deep belief net. **Advances in Mechanical Engineering**, *[S. l.]*, v. 9, n. 9, p. 1–13, 2017. DOI: 10.1177/1687814017715983.

LI, Pengtao; ZHOU, Kaile; LU, Xinhui; YANG, Shanlin. A hybrid deep learning model for short-term PV power forecasting. **Applied Energy**, *[S. l.]*, v. 259, n. November 2019, p. 114216, 2020. DOI: 10.1016/j.apenergy.2019.114216. Disponível em: https://doi.org/10.1016/j.apenergy.2019.114216.

LI, Pengtao; ZHOU, Kaile; YANG, Shanlin. Photovoltaic Power Forecasting: Models and Methods. *Em*: 2ND IEEE CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION, EI2 2018 - PROCEEDINGS 2018: IEEE, 2018. p. 1–6. DOI: 10.1109/EI2.2018.8582674.

LI, Qingyong; LU, Weitao; YANG, Jun. A hybrid thresholding algorithm for cloud detection on ground-based color images. **Journal of Atmospheric and Oceanic Technology**, *[S. l.]*, v. 28, n. 10, p. 1286–1296, 2011. DOI: 10.1175/JTECH-D-11-00009.1. Disponível em: http://journals.ametsoc.org/doi/10.1175/JTECH-D-11-00009.1.

LI, Xin; LU, Zhiying; ZHOU, Qingxia; XU, Zhengyang. A Cloud Detection Algorithm with Reduction of Sunlight Interference in Ground-Based Sky Images. **Atmosphere**, *[S. l.]*, v. 10, n. 11, p. 640, 2019. d. DOI: 10.3390/atmos10110640. Disponível em: https://www.mdpi.com/2073-4433/10/11/640.

LI, Yanting; HE, Yong; SU, Yan; SHU, Lianjie. Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines. **Applied Energy**, *[S. l.]*, v. 180, p. 392–401, 2016. DOI: 10.1016/j.apenergy.2016.07.052.

LI, Yanting; SU, Yan; SHU, Lianjie. An ARMAX model for forecasting the power output of a grid connected photovoltaic system. **Renewable Energy**, *[S. l.]*, v. 66, p. 78–89, 2014. DOI: 10.1016/j.renene.2013.11.067.

LIMA, F.; COSTA, R.; GONCALVES, A.; PES, M.; PEREIRA, E.; MARTINS, F. Comparing solar data from NWP models for Brazilian territory. **IEEE Latin America Transactions**, *[S. l.]*, v. 18, n. 05, p. 899–906, 2020. DOI: 10.1109/TLA.2020.9082918.

LIMA, Francisco J. L.; MARTINS, Fernando R.; PEREIRA, Enio B.; LORENZ, Elke; HEINEMANN, Detlev. Forecast for surface solar irradiance at the Brazilian Northeastern

region using NWP model and artificial neural networks. **Renewable Energy**, CPTEC - Center for Weather Forecasting and Climate Research, INPE - Brazilian National Institute for Space Research, São José dos Campos, Brazil, v. 87, p. 807–818, 2016. DOI: 10.1016/j.renene.2015.11.005.

LIMA, Marcello Anderson F. B.; CARVALHO, Paulo C. M.; DE S. BRAGA, Arthur P.; FERNÁNDEZ RAMÍREZ, Luis M.; LEITE, Josileudo R. MLP Back Propagation Artificial Neural Network for Solar Resource Forecasting in Equatorial Areas. **Renewable Energy and Power Quality Journal**, *[S. l.]*, v. 1, n. 16, p. 175–180, 2018. DOI: 10.24084/repqj16.253.

LIN, Fan; ZHANG, Yao; WANG, Jianxue. Recent advances in intra-hour solar forecasting: A review of ground-based sky image methods. **International Journal of Forecasting**, *[S. l.]*, 2022. DOI: 10.1016/j.ijforecast.2021.11.002. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S016920702100176X.

LIU, Fang; LI, Ranran; LI, Yong; YAN, Ruifeng; SAHA, Tapan. Takagi-Sugeno fuzzy model-based approach considering multiple weather factors for the photovoltaic power short-term forecasting. **IET Renewable Power Generation**, *[S. l.]*, v. 11, n. 10, p. 1281–1287, 2017. DOI: 10.1049/iet-rpg.2016.1036.

LO BRANO, Valerio; CIULLA, Giuseppina; DI FALCO, Mariavittoria. Artificial neural networks to predict the power output of a PV panel. **International Journal of Photoenergy**, *[S. l.]*, v. 2014, 2014. DOI: 10.1155/2014/193083.

LORENZ, E.; HAMMER, A.; HEINEMANN, D. **Short term forecasting of solar radiation based on satellite data**. **… (ISES Europe Solar …**academia.edu, , 2004. Disponível em: https://www.academia.edu/download/49998767/Short_term_forecasting_of_solar_radiatio20161031-11795-7wi9q3.pdf.

LOYOLA-GONZALEZ, Octavio. Black-Box vs. White-Box: Understanding Their Advantages and Weaknesses From a Practical Point of View. **IEEE Access**, *[S. l.]*, v. 7, p. 154096–154113, 2019. DOI: 10.1109/ACCESS.2019.2949286. Disponível em: https://ieeexplore.ieee.org/document/8882211/.

LUCCHESE, Felipe Cirolini; ANSELMINI, Felipe; MARTINS, Criciéle Castro; SPERANDIO, Mauricio. Análise do Impacto da Geração Distribuida Fotovoltaica na Rede Elétrica da Universidade Federal de Santa Maria. *Em*: VII CONGRESSO BRASILEIRO DE ENERGIA SOLAR 2018, Gramado-RS. Gramado-RS p. 1–10.

LUIZ, Eduardo Weide; MARTINS, Fernando Ramos; GONÇALVES, André Rodrigues; PEREIRA, Enio Bueno. Analysis of intra-day solar irradiance variability in different Brazilian climate zones. **Solar Energy**, Center for Earth System Science, National Institute for Space Research, Av. dos Astronautas, 1758, São José dos Campos, SP 12227-010, Brazil, v. 167, p. 210–219, 2018. DOI: 10.1016/j.solener.2018.04.005.

LUIZ, Gabriel; ALMEIDA, Silva; ROMEIRO, Patrícia. Estudo da elevação de tensão em redes de distribuição de energia elétrica com alta concentração de geradores. *Em*: VII

CONGRESSO BRASILEIRO DE ENERGIA SOLAR 2018, Gramado-RS. Gramado-RS p. 1–10.

MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. **Método, Dispositivo e Sistema Híbrido de Predição do Potencial de Geração de Energia Solar Fotovoltaica**, BR 1020200153331, 2020.

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**, *[S. l.]*, v. 19, n. 4, p. 612–624, 2021. DOI: 10.1109/TLA.2021.9448544. Disponível em: https://ieeexplore.ieee.org/document/9448544/.

MACIEL, Joylan Nunes; WENTZ, Victor Hugo; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. Analysis of Artificial Neural Networks for Forecasting Photovoltaic Energy Generation with Solar Irradiance. **Brazilian Archives of Biology and Technology**, *[S. l.]*, v. 64, n. spe, 2021. DOI: 10.1590/1678-4324-75years-2021210131. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1516-89132021000200212&tlng=en.

MARCOS, J.; STORKËL, O.; MARROYO, L.; GARCIA, M.; LORENZO, E. Storage requirements for PV power ramp-rate control. **Solar Energy**, *[S. l.]*, v. 99, p. 28–35, 2014. DOI: 10.1016/j.solener.2013.10.037.

MARQUEZ, R.; PEDRO, H. T. C.; COIMBRA, C. F. M. Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to ANNs. **Solar Energy**, *[S. l.]*, 2013. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X13000881.

MARQUEZ, Ricardo; COIMBRA, Carlos F. M. Intra-hour DNI forecasting based on cloud tracking image analysis. **Solar Energy**, *[S. l.]*, v. 91, p. 327–336, 2013. DOI: 10.1016/j.solener.2012.09.018.

MARTINEZ, Antonio Lopo; DUMER, Miguel Carlos Ramos. Adoption of IFRS and the Properties of Analysts' Forecasts: The Brazilian Case. **SSRN Electronic Journal**, *[S. l.]*, 2012. DOI: 10.2139/ssrn.2153173. Disponível em: http://www.ssrn.com/abstract=2153173.

MARZOUQ, M.; BOUNOUA, Z.; EL FADILI, Hakim; MECHAQRANE, A.; ZENKOUAR, K.; LAKHLIAI, Z. New daily global solar irradiation estimation model based on automatic selection of input parameters using evolutionary artificial neural networks. **Journal of Cleaner Production**, *[S. l.]*, v. 209, p. 1105–1118, 2019. DOI: 10.1016/j.jclepro.2018.10.254.

MASSAOUDI, Mohamed; CHIHI, Ines; ABU-RUB, Haitham; REFAAT, Shady S.; OUESLATI, Fakhreddine S. **Convergence of Photovoltaic Power Forecasting and Deep Learning: State-of-Art Review**. **IEEE Access**Institute of Electrical and Electronics Engineers Inc., , 2021. DOI: 10.1109/ACCESS.2021.3117004.

MASSUCCO, Stefano; MOSAICO, Gabriele; SAVIOZZI, Matteo; SILVESTRO, Federico. A hybrid technique for day-ahead pv generation forecasting using clear-sky

models or ensemble of artificial neural networks according to a decision tree approach. **Energies**, *[S. l.]*, v. 12, n. 7, 2019. DOI: 10.3390/en12071298.

MELZI, Fateh Nassim; TOUATI, Taieb; SAME, Allou; OUKHELLOU, Latifa. Hourly solar irradiance forecasting based on machine learning models. *Em*: PROCEEDINGS - 2016 15TH IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS, ICMLA 2016 2017, IRT SystemX, Palaiseau, 92400, France. **Anais** [...]. IRT SystemX, Palaiseau, 92400, France: Institute of Electrical and Electronics Engineers Inc., 2017. p. 441–446. DOI: 10.1109/ICMLA.2016.186.

MILLER, S. D.; ROGERS, M. A.; HAYNES, J. M.; SENGUPTA, M. Short-term solar irradiance forecasting via satellite/model coupling. **Solar Energy**, *[S. l.]*, 2018. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X17310435.

MINING, E. **Python Machine Learning: Understand Python Libraries (Keras, NumPy, Scikit-Lear, TensorFlow) for Implementing Machine Learning Models in Order to Build Intelligent Systems**. [s.l.] : Amazon Digital Services LLC - KDP Print US, 2019. Disponível em: https://books.google.com.br/books?id=qqQdzAEACAAJ.

MME. **Plano Decenal de Expansão de Energia 2026 (versão para consulta pública)**. Brasília, 2017.

MO, Han; ZHANG, Yu; XIAN, Zhaokun; WANG, Hangping. Photovoltaic (PV) Power Prediction Based on ABC - SVM. *Em*: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE 2018, [s.l: s.n.] DOI: 10.1088/1755-1315/199/5/052031.

MONTEIRO, Raul V. A.; GUIMARÃES, Geraldo C.; MOURA, Fabricio A. M.; ALBERTINI, Madeleine R. M. C.; ALBERTINI, Marcelo K. Estimating photovoltaic power generation: Performance analysis of artificial neural networks, Support Vector Machine and Kalman filter. **Electric Power Systems Research**, Núcleo de Dinâmica de Sistemas Elétricos, Faculdade de Engenharia Elétrica, Uberlândia, MG, Brazil, v. 143, p. 643–656, 2017. DOI: 10.1016/j.epsr.2016.10.050.

MOSAVI, Amir; SALIMI, Mohsen; ARDABILI, Sina Faizollahzadeh; RABCZUK, Timon; SHAMSHIRBAND, Shahaboddin; VARKONYI-KOCZY, Annamaria R. State of the Art of Machine Learning Models in Energy Systems, a Systematic Review. **Energies 2019, Vol. 12, Page 1301**, *[S. l.]*, v. 12, n. 7, p. 1301, 2019. DOI: 10.3390/EN12071301. Disponível em: https://www.mdpi.com/1996-1073/12/7/1301/htm. Acesso em: 13 abr. 2022.

MOUSSA, Adel Abdul Karim; ZALEWSKI, Willian; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo; MACIEL, Joylan Nunes. Predição da Geração de Energia Solar Fotovoltaica Utilizando Algoritmos de Inteligência Artificial. *Em*: Anais do XI Encontro Anual de Iniciação Científica e VII Encontro de Iniciação em Desenvolvimento Tecnológico (EICTI) da UNILA 2022, [s.l: s.n.]. 2022.

NAAMANDADIN, Nurul Akman; MING, Chew Jian; AZANI MUSTAFA, Wan Azani. Relationship between Solar Irradiance and Power Generated by Photovoltaic Panel: Case Study at UniCITI Alam Campus. **Journal of Advanced Research in Engineering**

Knowledge, *[S. l.]*, v. 5, p. 16–20, 2018. Disponível em: www.akademiabaru.com/arek.html.

NASCIMENTO, Lucas Rafael Do; BRAGA, Marília; CAMPOS, Rafael Antunes; NASPOLINI, Helena Flavia; RÜTHER, Ricardo. Performance assessment of solar photovoltaic technologies under different climatic conditions in Brazil. **Renewable Energy**, *[S. l.]*, v. 146, p. 1070–1082, 2020. DOI: 10.1016/j.renene.2019.06.160.

NI, Qiang; ZHUANG, Shengxian; SHENG, Hanming; KANG, Gaoqiang; XIAO, Jian. An ensemble prediction intervals approach for short-term PV power forecasting. **Solar Energy**, *[S. l.]*, v. 155, n. 10, p. 1072–1083, 2017. DOI: 10.1016/j.solener.2017.07.052.

NICCOLAI, Alessandro; NESPOLI, Alfredo. Sun Position Identification in Sky Images for Nowcasting Application. **Forecasting**, *[S. l.]*, v. 2, n. 4, p. 488–504, 2020. DOI: 10.3390/forecast2040026. Disponível em: https://www.mdpi.com/2571-9394/2/4/26.

NIE, Yuhao; LI, Xiatong; SCOTT, Andea; SUN, Yuchi; VENUGOPAL, Vignesh; BRANDT, Adam. SKIPP'D: a SKy Images and Photovoltaic Power Generation Dataset for Short-term Solar Forecasting. *[S. l.]*, 2022. Disponível em: http://arxiv.org/abs/2207.00913.

NOBRE, André M.; SEVERIANO, Carlos A.; KARTHIK, Shravan; KUBIS, Marek; ZHAO, Lu; MARTINS, Fernando R.; PEREIRA, Enio B.; RÜTHER, Ricardo; REINDL, Thomas. PV power conversion and short-term forecasting in a tropical, densely-built environment in Singapore. **Renewable Energy**, Solar Energy Research Institute of Singapore, National University of Singapore, 7 Engineering Drive 1, Singapore, 117574, Singapore, v. 94, p. 496–509, 2016. DOI: 10.1016/j.renene.2016.03.075.

NOU, Julien; CHAUVIN, Rémi; EYNARD, Julien; THIL, Stéphane; GRIEU, Stéphane. Towards the intrahour forecasting of direct normal irradiance using sky-imaging data. **Heliyon**, *[S. l.]*, v. 4, n. 4, 2018. DOI: 10.1016/j.heliyon.2018.e00598.

OBANDO, E. D.; CARVAJAL, S. X.; PINEDA, J. Solar Radiation Prediction Using Machine Learning Techniques: A Review. **IEEE Latin America Transactions**, *[S. l.]*, v. 17, n. 4, p. 684–697, 2019.

OBANDO, Edgar Dario; CARVAJAL, Sandra Ximena; PINEDA AGUDELO, Jairo. Solar Radiation Prediction Using Machine Learning Techniques: A Review. **IEEE Latin America Transactions**, *[S. l.]*, v. 17, n. 04, p. 684–697, 2019. DOI: 10.1109/TLA.2019.8891934. Disponível em: https://ieeexplore.ieee.org/document/8891934/.

OGAWA, Shota; MORI, Hiroyuki. Application of evolutionary deep neural netwok to photovoltaic generation forecasting. *Em*: PROCEEDINGS - IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS 2019, [s.l: s.n.] DOI: 10.1109/ISCAS.2019.8702210.

OLATOMIWA, Lanre; MEKHILEF, Saad; SHAMSHIRBAND, Shahaboddin; MOHAMMADI, Kasra; PETKOVIĆ, Dalibor; SUDHEER, Ch. A support vector machine-firefly algorithm-based model for global solar radiation prediction. **Solar Energy**, *[S. l.]*, v. 115, p. 632–644, 2015. DOI: 10.1016/j.solener.2015.03.015.

ORANG, O.; SILVA, R.; SILVA, P. C. L. Solar energy forecasting with fuzzy time series using high-order fuzzy cognitive maps. **2020 IEEE International …**, *[S. l.]*, 2020. Disponível em: https://ieeexplore.ieee.org/abstract/document/9177767/.

OSPINA, Juan; NEWAZ, Alvi; OMAR FARUQUE, M. Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model. **IET Renewable Power Generation**, *[S. l.]*, v. 13, n. 7, p. 1087–1095, 2019. DOI: 10.1049/iet-rpg.2018.5779.

OTSU, Nobuyuki. A Threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, *[S. l.]*, v. 9, n. 1, p. 62–66, 1979. DOI: 10.1109/TSMC.1979.4310076. Disponível em: http://ieeexplore.ieee.org/document/4310076/.

PALETTA, Quentin; ARBOD, Guillaume; LASENBY, Joan. Benchmarking of deep learning irradiance forecasting models from sky images – An in-depth analysis. **Solar Energy**, *[S. l.]*, v. 224, n. January, p. 855–867, 2021. DOI: 10.1016/j.solener.2021.05.056. Disponível em: https://doi.org/10.1016/j.solener.2021.05.056.

PASION, Christil; WAGNER, Torrey; KOSCHNICK, Clay; SCHULDT, Steven; WILLIAMS, Jada; HALLINAN, Kevin. Machine Learning Modeling of Horizontal Photovoltaics Using Weather and Location Data. **Energies**, *[S. l.]*, v. 13, n. 10, p. 2570, 2020. DOI: 10.3390/en13102570.

PAVLOVSKI, Alexander; ANICHKOV, Dimitriy; KOSTYLEV, Vladimit. **Method and system for solar power forecasting**, Patent US 20180275314-A1, 2018.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, *[S. l.]*, v. 12, p. 2825–2830, 2011.

PEDRO, Hugo T. C.; LARSON, David P.; COIMBRA, Carlos F. M. A comprehensive dataset for the accelerated development and benchmarking of solar forecasting methods. **Journal of Renewable and Sustainable Energy**, Department of Mechanical and Aerospace Engineering, Center for Energy Research University of California San Diego, San Diego, CA 92093, United States, v. 11, n. 3, p. 036102, 2019. DOI: 10.1063/1.5094494. Disponível em: http://aip.scitation.org/doi/10.1063/1.5094494.

PEREIRA, Eduardo dos Santos. **Defisheye**. 2019. Disponível em: https://github.com/duducosmos/defisheye. Acesso em: 29 jul. 2022.

PERVEEN, G.; RIZWAN, M.; GOEL, N. An ANFIS-based model for solar energy forecasting and its smart grid application. **Engineering Reports**, *[S. l.]*, 2019. DOI: 10.1002/eng2.12070. Disponível em: https://onlinelibrary.wiley.com/doi/abs/10.1002/eng2.12070.

PESSANHA, J. F. M.; MELO, A. C. G.; CALDAS, R. P.; FALCÃO, D. M. An Approach for Data Treatment of Solar Photovoltaic Generation. **IEEE Latin America Transactions**, *[S. l.]*, n. No. 1e (2020): Early Access, 2020.

PINTO, Tiago; MARQUES, Luis; SOUSA, Tiago M.; PRAÇA, Isabel; VALE, Zita; ABREU, Samuel L. Data-Mining-based filtering to support Solar Forecasting

Methodologies. **ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal**, *[S. l.]*, v. 6, n. 3, p. 85, 2017. DOI: 10.14201/adcaij20176385102.

POMBO, Daniel Vázquez; BINDNER, Henrik W.; SPATARU, Sergiu Viorel; SØRENSEN, Poul Ejnar; BACHER, Peder. Increasing the Accuracy of Hourly Multi-Output Solar Power Forecast with Physics-Informed Machine Learning. **Sensors**, *[S. l.]*, v. 22, n. 3, p. 749, 2022. DOI: 10.3390/s22030749. Disponível em: https://www.mdpi.com/1424-8220/22/3/749.

PRETTENHOFER, Peter; LOUPPE, Gilles. **Gradient Boosted Regression Trees**. 2016. Disponível em: https://orbi.uliege.be/bitstream/2268/163521/1/slides.pdf. Acesso em: 20 nov. 2022.

PULIPAKA, Subrahmanyam; KUMAR, Rajneesh. Performance enhancement of neural network training using hybrid data division technique for photovoltaic power prediction. *Em*: CONFERENCE PROCEEDINGS - 2017 17TH IEEE INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING AND 2017 1ST IEEE INDUSTRIAL AND COMMERCIAL POWER SYSTEMS EUROPE, EEEIC / I AND CPS EUROPE 2017 2017, [s.l: s.n.] DOI: 10.1109/EEEIC.2017.7977473.

QING, Xiangyun; NIU, Yugang. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. **Energy**, *[S. l.]*, v. 148, p. 461–468, 2018. DOI: 10.1016/j.energy.2018.01.177.

QUESADA-RUIZ, S.; LINARES-RODRÍGUEZ, A.; RUIZ-ARIAS, J. A.; POZO-VÁZQUEZ, D.; TOVAR-PESCADOR, J. An advanced ANN-based method to estimate hourly solar radiation from multi-spectral MSG imagery. **Solar Energy**, Solar Radiation and Atmospheric Modeling Research Group (MATRAS), University of Jaén, Campus Las Lagunillas, Jaén, 23071, Spain, v. 115, p. 494–504, 2015. DOI: 10.1016/j.solener.2015.03.014.

RAHUL; GUPTA, Aakash; BANSAL, Ankur; ROY, Kshitij. Solar Energy Prediction using Decision Tree Regressor. *Em*: 2021 5TH INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING AND CONTROL SYSTEMS (ICICCS) 2021,: IEEE, 2021. p. 489–495. DOI: 10.1109/ICICCS51141.2021.9432322. Disponível em: https://ieeexplore.ieee.org/document/9432322/.

RAJAGUKGUK, Rial A.; KAMIL, Raihan; LEE, Hyun-Jin. A Deep Learning Model to Forecast Solar Irradiance Using a Sky Camera. **Applied Sciences**, *[S. l.]*, v. 11, n. 11, p. 5049, 2021. DOI: 10.3390/app11115049. Disponível em: https://www.mdpi.com/2076-3417/11/11/5049.

RAJAGUKGUK, Rial A.; RAMADHAN, Raden A. A.; LEE, Hyun-Jin. A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power. **Energies**, *[S. l.]*, v. 13, n. 24, p. 6623, 2020. DOI: 10.3390/en13246623. Disponível em: https://www.mdpi.com/1996-1073/13/24/6623.

RAMSAMI, Pamela; OREE, Vishwamitra. A hybrid method for forecasting the energy output of photovoltaic systems. **Energy Conversion and Management**, *[S. l.]*, v. 95, p. 406–413, 2015. DOI: 10.1016/j.enconman.2015.02.052.

RANA, Mashud; KOPRINSKA, Irena; AGELIDIS, Vassilios G. Forecasting solar power generated by grid connected PV systems using ensembles of neural networks. *Em*: PROCEEDINGS OF THE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS 2015, [s.l: s.n.] DOI: 10.1109/IJCNN.2015.7280574.

RETTGER, Philip; KESHNER, Marvin; KATRINA PLIGAVKO, Alexandra; JACKSON MOORE; LITTMANN, Bodo W. **Dynamic power prediction system for distributed photovoltaic power generation system**, Patent US 20100198420, 2010.

REZENDE, Solange Oliveira. **Sistemas Inteligentes**. 1. ed. São Paulo: Manole, 2003. v. 2013

RICHARDSON, Walter; KRISHNASWAMI, Hariharan; VEGA, Rolando; CERVANTES, Michael. A low cost, edge computing, all-sky imager for cloud tracking and intra-hour irradiance forecasting. **Sustainability (Switzerland)**, *[S. l.]*, v. 9, n. 4, p. 482, 2017. DOI: 10.3390/su9040482. Disponível em: http://www.mdpi.com/2071-1050/9/4/482.

ROCHA, P. A. Costa; FERNANDES, J. L.; MODOLO, A. B.; LIMA, R. J. Pontes; DA SILVA, M. E. Vieira; BEZERRA, C. A. Dias. Estimation of daily, weekly and monthly global solar radiation using ANNs and a long data set: a case study of Fortaleza, in Brazilian Northeast region. **International Journal of Energy and Environmental Engineering**, *[S. l.]*, v. 10, n. 3, p. 319–334, 2019. DOI: 10.1007/s40095-019-0313-0.

ROPP, Michael; HUMMEL, Steven G. **Systems and Methods for Forecasting Solar Power**, Patent US 20110282514-A1, 2011.

ROSSUM, Guido Van. **Python 3.9.0 documentation**. 2020. Disponível em: https://docs.python.org/3/.

RUSSELL, Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 3rd edition ed. United Kingdom: Pearson Education, 2016.

RYU, Anto; ITO, Masakazu; ISHII, Hideo; HAYASHI, Yasuhiro. Preliminary Analysis of Short-term Solar Irradiance Forecasting by using Total-sky Imager and Convolutional Neural Network. *Em*: 2019 IEEE PES GTD GRAND INTERNATIONAL CONFERENCE AND EXPOSITION ASIA, GTD ASIA 2019 2019, [s.l: s.n.] p. 627–631. DOI: 10.1109/GTDAsia.2019.8715984.

SABERIAN, Aminmohammad; HIZAM, H.; RADZI, M. A. M.; AB KADIR, M. Z. A.; MIRZAEI, Maryam. Modelling and prediction of photovoltaic power output using artificial neural networks. **International Journal of Photoenergy**, *[S. l.]*, v. 2014, 2014. DOI: 10.1155/2014/469701.

SABRI, Mohammed; EL HASSOUNI, Mohammed. A Novel Deep Learning Approach for Short Term Photovoltaic Power Forecasting Based on GRU-CNN Model. **E3S Web of Conferences**, *[S. l.]*, v. 336, p. 00064, 2022. DOI: 10.1051/e3sconf/202233600064. Disponível em: https://www.e3s-conferences.org/10.1051/e3sconf/202233600064.

SAHIN, Furkan E. Fisheye lens design for sun tracking cameras and photovoltaic energy systems. **Journal of Photonics for Energy**, Light Co., Palo Alto, CA, United States, v. 8, n. 03, p. 1, 2018. DOI: 10.1117/1.jpe.8.035501.

SAJJAD, Muhammad; KHAN, Zulfiqar Ahmad; ULLAH, Amin; HUSSAIN, Tanveer; ULLAH, Waseem; LEE, Mi Young; BAIK, Sung Wook. A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting. **IEEE Access**, *[S. l.]*, v. 8, p. 143759–143768, 2020. DOI: 10.1109/ACCESS.2020.3009537. Disponível em: https://ieeexplore.ieee.org/document/9141253/.

SANDERS, Sam; BARRICK, Chris; MAIER, Frederick; RASHEED, Khaled. Solar radiation prediction improvement using weather forecasts. *Em*: (Chen, X and Luo, B and Luo, F and Palade, V and Wani, MA, Org.)PROCEEDINGS - 16TH IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS, ICMLA 2017 2018, [s.l: s.n.] p. 499–504. DOI: 10.1109/ICMLA.2017.0-112.

SARA, Umme; AKTER, Morium; UDDIN, Mohammad Shorif. Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study. **Journal of Computer and Communications**, *[S. l.]*, v. 07, n. 03, p. 8–18, 2019. DOI: 10.4236/jcc.2019.73002.

SAVOY, Florian M.; DEV, Soumyabrata; LEE, Yee Hui; WINKLER, Stefan. Geo-referencing and stereo calibration of ground-based Whole Sky Imagers using the sun trajectory. *Em*: 2016 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS) 2016: IEEE, 2016. p. 7473–7476. DOI: 10.1109/IGARSS.2016.7730949. Disponível em: http://ieeexplore.ieee.org/document/7730949/.

SCHMIDT, Thomas; KALISCH, John; LORENZ, Elke; HEINEMANN, Detlev. Evaluating the spatio-temporal performance of sky-imager-based solar irradiance analysis and forecasts. *[S. l.]*, p. 3399–3412, 2016. a. DOI: 10.5194/acp-16-3399-2016.

SCHMIDT, Thomas; KALISCH, John; LORENZ, Elke; HEINEMANN, Detlev. Evaluating the spatio-temporal performance of sky-imager-based solar irradiance analysis and forecasts. *[S. l.]*, p. 3399–3412, 2016. b. DOI: 10.5194/acp-16-3399-2016.

SEMERO, Yordanos Kassa; ZHANG, Jianhua; ZHENG, Dehua. PV power forecasting using an integrated GA-PSO-ANFIS approach and Gaussian process regression based feature selection strategy. **CSEE Journal of Power and Energy Systems**, *[S. l.]*, v. 4, n. 2, p. 210–218, 2018. DOI: 10.17775/cseejpes.2016.01920.

SERRANO ARDILA, Vanessa María; MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; ANDO JUNIOR, Oswaldo Hideo. Fuzzy Time Series Methods Applied to (In)Direct Short-Term Photovoltaic Power Forecasting. **Energies**, *[S. l.]*, v. 15, n. 3, p. 845, 2022. DOI: 10.3390/en15030845. Disponível em: https://www.mdpi.com/1996-1073/15/3/845.

SHAO, Xiaoyan; LU, Siyuan; HAMANN, Hendrik F. Solar radiation forecast with machine learning. *Em*: PROCEEDINGS OF AM-FPD 2016 - 23RD INTERNATIONAL WORKSHOP ON ACTIVE-MATRIX FLATPANEL DISPLAYS AND DEVICES: TFT TECHNOLOGIES AND FPD MATERIALS 2016, [s.l: s.n.] p. 19–22. DOI: 10.1109/AM-FPD.2016.7543604.

SHIELDS, J. E.; JOHNSON, R. W.; KOEHLER, T. L. Automated Whole Sky Imaging Systems for Cloud Field Assessment. *Em*: FOURTH SYMPOSIUM ON GLOBAL CHANGE STUDIES OF THE AMERICAN METEOROLOGICAL SOCIETY, 17-22 1993, Boston, MA, USA. Boston, MA, USA

SHIVASHANKAR, S.; MEKHILEF, Saad; MOKHLIS, Hazlie; KARIMI, M. Mitigating methods of power fluctuation of photovoltaic (PV) sources - A review. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 59, p. 1170–1184, 2016. DOI: 10.1016/j.rser.2016.01.059.

SIDDIQUI, Talha A.; BHARADWAJ, Samarth; KALYANARAMAN, Shivkumar. A deep learning approach to solar-irradiance forecasting in sky-videos. *Em*: PROCEEDINGS - 2019 IEEE WINTER CONFERENCE ON APPLICATIONS OF COMPUTER VISION, WACV 2019 2019, [s.l: s.n.] p. 2166–2174. DOI: 10.1109/WACV.2019.00234.

SILVA, Eder Andrade Da; URZAGASTI, Carlos Alejandro; MACIEL, Joylan Nunes; LEDESMA, Jorge Javier Gimenez; CAVALLARI, Marco Roberto; ANDO JUNIOR, Oswaldo Hideo. Development of a Self-Calibrated Embedded System for Energy Management in Low Voltage. **Energies**, *[S. l.]*, v. 15, n. 22, p. 8707, 2022. DOI: 10.3390/en15228707. Disponível em: https://www.mdpi.com/1996-1073/15/22/8707.

SINGH DOORGA, Jay Rovisham; DHURMEA, Kumar Ram; RUGHOOPUTH, Soonil; BOOJHAWON, Ravindra. Forecasting mesoscale distribution of surface solar irradiation using a proposed hybrid approach combining satellite remote sensing and time series models. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 104, p. 69–85, 2019. DOI: 10.1016/j.rser.2018.12.055.

SIVANEASAN, B.; YU, C. Y.; GOH, K. P. Solar Forecasting using ANN with Fuzzy Logic Pre-processing. *Em*: (Yan, J and Chou, SK and Li, H and Nian, V, Org.)ENERGY PROCEDIA 2017, [s.l: s.n.] p. 727–732. DOI: 10.1016/j.egypro.2017.12.753.

SOARES, Thaiane G.; LIMA, Francisco J. L.; MARTINS, Fernando R. Generating solar irradiance data series with 1-minute time resolution based on hourly observational data. **IEEE Latin America Transactions**, *[S. l.]*, v. X, n. X, p. 1–8, 2019.

SOBRI, Sobrina; KOOHI-KAMALI, Sam; RAHIM, Nasrudin Abd. Solar photovoltaic generation forecasting methods: A review. **Energy Conversion and Management**, *[S. l.]*, v. 156, n. December 2017, p. 459–497, 2018. DOI: 10.1016/j.enconman.2017.11.019. Disponível em: https://doi.org/10.1016/j.enconman.2017.11.019.

SREEKUMAR, Sreenu; GUPTA, Ayushi; SUSHILA; AGARWAL, Varun; BHAKAR, Rohit. Matrix based univariate and multivariate linear similar day approach towards short term solar radiation forecasting. *Em*: 2016 NATIONAL POWER SYSTEMS CONFERENCE, NPSC 2016 2017, Electrical Engineering Department, Malaviya National Institute of Technology, Jaipur, 302017, India. Electrical Engineering Department, Malaviya National Institute of Technology, Jaipur, 302017, India: Institute of Electrical and Electronics Engineers Inc., 2017. DOI: 10.1109/NPSC.2016.7858914.

SRIVASTAVA, Rachit; TIWARI, A. N.; GIRI, V. K. Forecasting of Solar Radiation in India Using Various ANN Models. *Em*: 2018 5TH IEEE UTTAR PRADESH SECTION

INTERNATIONAL CONFERENCE ON ELECTRICAL, ELECTRONICS AND COMPUTER ENGINEERING, UPCON 2018 2018, [s.l: s.n.] DOI: 10.1109/UPCON.2018.8597170.

SRIVASTAVA, Shikhar; LESSMANN, Stefan. A comparative study of LSTM neural networks in forecasting day-ahead global horizontal irradiance with satellite data. **Solar Energy**, School of Business and Economics, Humboldt-Universität zu Berlin, Unter den Linden 6, Berlin, 10099, Germany, v. 162, p. 232–247, 2018. DOI: 10.1016/j.solener.2018.01.005.

SU, H. Y.; LIU, T. Y.; HONG, H. H. Adaptive residual compensation ensemble models for improving solar energy generation forecasting. **… Transactions on Sustainable Energy**, *[S. l.]*, 2019. Disponível em: https://ieeexplore.ieee.org/abstract/document/8772128/.

SUN, Yuchi; SZUCS, Gergely; BRANDT, Adam R. Solar PV output prediction from video streams using convolutional neural networks. **Energy and Environmental Science**, *[S. l.]*, v. 11, n. 7, p. 1811–1818, 2018. DOI: 10.1039/c7ee03420b.

SUN, Yuchi; VENUGOPAL, Vignesh; BRANDT, Adam R. Convolutional Neural Network for Short-term Solar Panel Output Prediction. *Em*: 2018 IEEE 7TH WORLD CONFERENCE ON PHOTOVOLTAIC ENERGY CONVERSION, WCPEC 2018 - A JOINT CONFERENCE OF 45TH IEEE PVSC, 28TH PVSEC AND 34TH EU PVSEC 2018, [s.l: s.n.] p. 2357–2361. DOI: 10.1109/PVSC.2018.8547400.

SZELISKI, Richard. **Computer Vision: Algorithms and Applications**. [s.l.] : Springer, 2011. DOI: 10.1007/978-1-84882-935-0_1. Disponível em: http://szeliski.org/Book/drafts/SzeliskiBook_20100903_draft.pdf.

TANG, Jiacheng; LV, Zeyan; ZHANG, Yong; YU, Miao; WEI, Wei. An improved cloud recognition and classification method for photovoltaic power prediction based on total-sky-images. *Em*: THE JOURNAL OF ENGINEERING 2019, College of Electrical Engineering, Zhejiang University, Hangzhou, Zhejiang Province; 310007, China. College of Electrical Engineering, Zhejiang University, Hangzhou, Zhejiang Province; 310007, China: Institution of Engineering and Technology, 2019. p. 4922–4926. DOI: 10.1049/joe.2018.9249.

TIDD, Joe. Innovation management in context: environment, organization and performance. **International Journal of Management Reviews**, *[S. l.]*, v. 3, n. 3, p. 169–183, 2001. DOI: 10.1111/1468-2370.00062.

TINA, Giuseppe Marco; VENTURA, Cristina; FERLITO, Sergio; DE VITO, Saverio. A State-of-Art-Review on Machine-Learning Based Methods for PV. **Applied Sciences**, *[S. l.]*, v. 11, n. 16, p. 7550, 2021. DOI: 10.3390/app11167550. Disponível em: https://www.mdpi.com/2076-3417/11/16/7550.

TIWARI, Soumya; SABZEHGAR, Reza; RASOULI, Mohammad. Short term solar irradiance forecast based on image processing and cloud motion detection. *Em*: 2019 IEEE TEXAS POWER AND ENERGY CONFERENCE, TPEC 2019 2019, **Anais** [...]. [s.l: s.n.] DOI: 10.1109/TPEC.2019.8662134.

TOVAR, Mario; ROBLES, Miguel; RASHID, Felipe. PV Power Prediction, Using CNN-LSTM Hybrid Neural Network Model. Case of Study: Temixco-Morelos, México. **Energies**, *[S. l.]*, v. 13, n. 24, p. 6512, 2020. DOI: 10.3390/en13246512.

URQUHART, Bryan; GHONIMA, Mohamed; NGUYEN, Dung (Andu); KURTZ, Ben; CHOW, Chi Wai; KLEISSL, Jan. Sky-Imaging Systems for Short-Term Forecasting. *Em*: **Solar Energy Forecasting and Resource Assessment**. Solar Energy Forecasting and Resource AssessmentCenter for Renewable Resources and Integration, Department of Mechanical and Aerospace Engineering, University of California, San Diego, United States: Elsevier Inc., 2013. p. 195–232. DOI: 10.1016/B978-0-12-397177-7.00009-7. Disponível em: http://dx.doi.org/10.1016/B978-0-12-397177-7.00009-7.

URRACA, R.; ANTONANZAS, J.; ALIA-MARTINEZ, M.; MARTINEZ-DE-PISON, F. J.; ANTONANZAS-TORRES, F. Smart baseline models for solar irradiation forecasting. **Energy Conversion and Management**, *[S. l.]*, v. 108, p. 539–548, 2016. DOI: 10.1016/j.enconman.2015.11.033.

VAN DER MEER, D. W.; WIDÉN, J.; MUNKHAMMAR, J. Review on probabilistic forecasting of photovoltaic power production and electricity consumption. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 81, n. December 2016, p. 1484–1512, 2018. DOI: 10.1016/j.rser.2017.05.212.

VILLALVA, Marcelo Gradella. **Energia Solar Fotovoltaica: Conceitos e aplicações**. 2ed. ed. São Paulo: Érica, 2015.

VISWAVANDYA, M.; SARANGI, B.; MOHANTY, S.; . Short term solar energy forecasting by using fuzzy logic and ANFIS. **Advances in Intelligent Systems and Computing**, vol 990. Springer, Singapore, *[S. l.],* 2020. DOI: 10.1007/978-981-13-8676-3_63. Disponível em: https://link.springer.com/chapter/10.1007/978-981-13-8676-3_63.

VOYANT, Cyril; DE GOOIJER, Jan G.; NOTTON, Gilles. Periodic autoregressive forecasting of global solar irradiation without knowledge-based model implementation. **Solar Energy**, University of Reunion Island – PIMENT Laboratory, 15, Avenue René Cassin, BP, Saint-Denis Cedex, 97715, France, v. 174, p. 121–129, 2018. DOI: 10.1016/j.solener.2018.08.076.

VOYANT, Cyril; MOTTE, Fabrice; NOTTON, Gilles; FOUILLOY, Alexis; NIVET, Marie Laure; DUCHAUD, Jean Laurent. Prediction intervals for global solar irradiation forecasting using regression trees methods. **Renewable Energy**, University of Corsica, CNRS UMR SPE 6134, Corte, 20250, France, v. 126, p. 332–340, 2018. DOI: 10.1016/j.renene.2018.03.055.

VOYANT, Cyril; NOTTON, Gilles. Solar irradiation nowcasting by stochastic persistence: A new parsimonious, simple and efficient forecasting tool. **Renewable and Sustainable Energy Reviews**, *[S. l.]*, v. 92, p. 343–352, 2018. DOI: 10.1016/j.rser.2018.04.116.

VOYANT, Cyril; NOTTON, Gilles; KALOGIROU, Soteris; NIVET, Marie Laure; PAOLI, Christophe; MOTTE, Fabrice; FOUILLOY, Alexis. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, University of Corsica/CNRS

UMR SPE 6134, Campus Grimaldi, Corte, 20250, France, v. 105, p. 569–582, 2017. DOI: 10.1016/j.renene.2016.12.095.

VOYANT, Cyril; RANDIMBIVOLOLONA, Prisca; NIVET, Marie Laure; PAOLI, Christophe; MUSELLI, Marc. Twenty four hours ahead global irradiation forecasting using multi-layer perceptron. **Meteorological Applications**, CH Castelluccio, Ajaccio, France, v. 21, n. 3, p. 644–655, 2014. DOI: 10.1002/met.1387.

WANG, Fei et al. A satellite image data based ultra-short-term solar PV power forecasting method considering cloud information from neighboring plant. **Energy**, *[S. l.]*, v. 238, p. 121946, 2022. DOI: 10.1016/j.energy.2021.121946. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0360544221021940.

WANG, Fei; XUAN, Zhiming; ZHEN, Zhao; LI, Yu; LI, Kangping; ZHAO, Liqiang; SHAFIE-KHAH, Miadreza; CATALÃO, João P. S. A minutely solar irradiance forecasting method based on real-time sky image-irradiance mapping model. **Energy Conversion and Management**, *[S. l.]*, v. 220, p. 113075, 2020. DOI: 10.1016/j.enconman.2020.113075. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0196890420306191.

WANG, Fei; ZHEN, Zhao; WANG, Bo; MI, Zengqiang. Comparative study on KNN and SVM based weather classification models for day ahead short term solar PV power forecasting. **Applied Sciences (Switzerland)**, *[S. l.]*, v. 8, n. 1, 2017. DOI: 10.3390/app8010028.

WANG, Huaizhi; LEI, Zhenxing; ZHANG, Xian; ZHOU, Bin; PENG, Jianchun. A review of deep learning for renewable energy forecasting. **Energy Conversion and Management**, *[S. l.]*, v. 198, p. 111799, 2019. DOI: 10.1016/j.enconman.2019.111799. Disponível em: https://www.sciencedirect.com/science/article/pii/S0196890419307812.

WANG, Jidong; LI, Peng; RAN, Ran; CHE, Yanbo; ZHOU, Yue. A short-term photovoltaic power prediction model based on the Gradient Boost Decision Tree. **Applied Sciences (Switzerland)**, *[S. l.]*, v. 8, n. 5, 2018. a. DOI: 10.3390/app8050689.

WANG, Ying; FENG, Bo; HUA, Qing Song; SUN, Lai. Short-term solar power forecasting: A combined long short-term memory and gaussian process regression method. **Sustainability (Switzerland)**, *[S. l.]*, v. 13, n. 7, 2021. DOI: 10.3390/su13073665.

WANG, Yusen; LIAO, Wenlong; CHANG, Yuqing. Gated recurrent unit network-based short-term photovoltaic forecasting. **Energies**, *[S. l.]*, v. 11, n. 8, 2018. DOI: 10.3390/en11082163.

WANG, Zheng; KOPRINSKA, Irena; TRONCOSO, Alicia; MARTÍNEZ-ÁLVAREZ, Francisco. Static and Dynamic Ensembles of Neural Networks for Solar Power Forecasting. *Em*: PROCEEDINGS OF THE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS 2018b, **Anais** [...]. [s.l: s.n.] DOI: 10.1109/IJCNN.2018.8489231.

WATANABE, Takeshi; NOHARA, Daisuke. Prediction of time series for several hours of surface solar irradiance using one-granule cloud property data from satellite observations.

Solar Energy, *[S. l.]*, v. 186, n. March, p. 113–125, 2019. DOI: 10.1016/j.solener.2019.05.004.

WEI, Li; BING, Wang; HONGFENG, Deng. Short-term photovoltaic power prediction based on similar days with meteorological factors. *Em*: PROCEEDINGS - 2018 33RD YOUTH ACADEMIC ANNUAL CONFERENCE OF CHINESE ASSOCIATION OF AUTOMATION, YAC 2018 2018, [s.l: s.n.] p. 648–653. DOI: 10.1109/YAC.2018.8406453.

WEN, Haoran; DU, Yang; CHEN, Xiaoyang; LIM, Enggee; WEN, Huiqing; JIANG, Lin; XIANG, Wei. Deep Learning Based Multistep Solar Forecasting for PV Ramp-Rate Control Using Sky Images. **IEEE Transactions on Industrial Informatics**, *[S. l.]*, v. 17, n. 2, p. 1397–1406, 2021. DOI: 10.1109/TII.2020.2987916. Disponível em: https://ieeexplore.ieee.org/document/9072298/.

WENTZ, Victor H.; MACIEL, Joylan N.; KAPP, Marcelo N.; LEDESMA, Jorge J. G.; ANDO JUNIOR, Oswaldo Hideo; JUNIOR, Oswaldo H. Ando. Comparação de Modelos de Redes Neurais Artificiais para a Predição da Irradiância Solar na Geração de Energia Fotovoltaica. *Em*: ANAIS DO I CONGRESSO BRASILEIRO INTERDISCIPLINAR EM CIÊNCIA E TECNOLOGIA 2020, Evento Online: Even3 Publicações, 2020. p. 8. Disponível em: https://www.even3.com.br/anais/icobicet2020/265096-comparacao-de-modelos-de-redes-neurais-artificias-para-a-predicao-de-irradiancia-solar-na-geracao-de-energia-foto/.

WENTZ, Victor Hugo; MACIEL, Joylan Nunes; GIMENEZ LEDESMA, Jorge Javier; ANDO JUNIOR, Oswaldo Hideo. Solar Irradiance Forecasting to Short-Term PV Power: Accuracy Comparison of ANN and LSTM Models. **Energies**, *[S. l.]*, v. 15, n. 7, p. 2457, 2022. DOI: 10.3390/en15072457. Disponível em: https://www.mdpi.com/1996-1073/15/7/2457.

WOIWODE, Wolfgang et al. Mesoscale fine structure of a tropopause fold over mountains. **Atmospheric Chemistry and Physics**, *[S. l.]*, v. 18, n. 21, p. 15643–15667, 2018. DOI: 10.5194/acp-18-15643-2018.

WOJTKIEWICZ, Jessica; HOSSEINI, Matin; GOTTUMUKKALA, Raju; CHAMBERS, Terrence Lynn. Hour-Ahead Solar Irradiance Forecasting Using Multivariate Gated Recurrent Units. **Energies**, *[S. l.]*, v. 12, n. 21, p. 4055, 2019. DOI: 10.3390/en12214055. Disponível em: https://www.mdpi.com/1996-1073/12/21/4055.

WU, Ji; CHAN, Chee Keong; ZHANG, Yu; XIONG, Bin Yu; ZHANG, Qing Hai. Prediction of solar radiation with genetic approach combing multi-model framework. **Renewable Energy**, Nanyang Technological University, School of Electrical and Electronics Engineering, Singapore, v. 66, p. 132–139, 2014. DOI: 10.1016/j.renene.2013.11.064.

XIAO, Cao; ZHI-BAO, Chen; YUYU, Ding; HAI, Zhou; JIE, Ding. Study on Very Short-term Solar Irradiance Forecasting Methods using Ground based Cloud Image. *Em*: DENG, W. (org.). **AASRI Procedia**. AASRI Procedia [s.l: s.n.]. v. 2p. 174–179. DOI: 10.1016/j.aasri.2012.09.031.

XIE, Tuo; ZHANG, Gang; LIU, Hongchi; LIU, Fuchao; DU, Peidong. A hybrid forecasting method for solar output power based on variational mode decomposition, deep belief networks and auto-regressive moving average. **Applied Sciences (Switzerland)**, Institute of Water Resources and Hydro-Electric Engineering, Xi'an University of Technology, Xi'an, 710048, China, v. 8, n. 10, 2018. DOI: 10.3390/app8101901.

XU, Gaowei; LIU, Min. Photovoltaic power prediction model based on parallel neural network and genetic algorithms. *Em*: (Cao, J and Liu, J, Org.) COMMUNICATIONS IN COMPUTER AND INFORMATION SCIENCE 2017, [s.l: s.n.] p. 99–110. DOI: 10.1007/978-981-10-3996-6_8.

YADAV, Harendra Kumar; PAL, Yash; TRIPATHI, M. M. Short-Term PV Power Forecasting Using Adaptive Neuro-Fuzzy Inference System. *Em*: 8TH IEEE POWER INDIA INTERNATIONAL CONFERENCE, PIICON 2018 2019, Ph.D Research Scholar, School of Renewable Energy and Efficiency, NIT KurukshetraHaryana, India. **Anais** [...]. Ph.D Research Scholar, School of Renewable Energy and Efficiency, NIT KurukshetraHaryana, India: Institute of Electrical and Electronics Engineers Inc., 2019. DOI: 10.1109/POWERI.2018.8704445.

YADAV, V.; NATH, S. Novel hybrid model for daily prediction of PM 10 using principal component analysis and artificial neural network. **International Journal of Environmental Science and Technology**, Department of Environmental Sciences and NRM, College of Forestry, Sam Higginbottom University of Agriculture, Technology and Sciences, Uttar Pradesh, Allahabad, 211007, India, v. 16, n. 6, p. 2839–2848, 2019. DOI: 10.1007/s13762-018-1999-x.

YANG, Dazhi. Kriging for NSRDB PSM version 3 satellite-derived solar irradiance. **Solar Energy**, Singapore Institute of Manufacturing Technology, Agency for Science, Technology and Research (A*STAR), Singapore, v. 171, p. 876–883, 2018. DOI: 10.1016/j.solener.2018.06.055.

YANG, Dazhi. Post-processing of NWP forecasts using ground or satellite-derived data through kernel conditional density estimation. **Journal of Renewable and Sustainable Energy**, Singapore Institute of Manufacturing Technology, Agency for Science, Technology and Research (ASTAR), Singapore, Singapore, v. 11, n. 2, 2019. DOI: 10.1063/1.5088721.

YANG, Dazhi. Ensemble model output statistics as a probabilistic site-adaptation tool for satellite-derived and reanalysis solar irradiance. **Journal of Renewable and Sustainable Energy**, *[S. l.]*, v. 12, n. 1, 2020. DOI: 10.1063/1.5134731.

YANG, Dazhi; KLEISSL, Jan; GUEYMARD, Christian A.; PEDRO, Hugo T. C.; COIMBRA, Carlos F. M. History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. **Solar Energy**, Singapore Institute of Manufacturing Technology, Agency for Science, Technology and Research (A*STAR), Singapore, v. 168, p. 60–101, 2018. DOI: 10.1016/j.solener.2017.11.023.

YANG; GAO; LI; JIA; JIANG. Nowcasting of Surface Solar Irradiance Using FengYun-4 Satellite Observations over China. **Remote Sensing**, *[S. l.]*, v. 11, n. 17, p. 1984, 2019. DOI: 10.3390/rs11171984.

YANG, Handa; KURTZ, Ben; NGUYEN, Dung; URQUHART, Bryan; CHOW, Chi Wai; GHONIMA, Mohamed; KLEISSL, Jan. Solar irradiance forecasting using a ground-based sky imager developed at UC San Diego. **Solar Energy**, *[S. l.]*, v. 103, p. 502–524, 2014. DOI: 10.1016/j.solener.2014.02.044. Disponível em: http://dx.doi.org/10.1016/j.solener.2014.02.044.

YANG, Hao; WANG, Long; HUANG, Chao; LUO, Xiong. 3d-cnn-based sky image feature extraction for short-term global horizontal irradiance forecasting. **Water (Switzerland)**, *[S. l.]*, v. 13, n. 13, 2021. DOI: 10.3390/w13131773.

YANG, Jun; MIN, Qilong; LU, Weitao; MA, Ying; YAO, Wen; LU, Tianshu; DU, Juan; LIU, Guangyi. A total sky cloud detection method using real clear sky background. **Atmospheric Measurement Techniques**, *[S. l.]*, v. 9, n. 2, p. 587–597, 2016. DOI: 10.5194/amt-9-587-2016.

YI, Haiyan; WANG, Huaizhi; ZHANG, Rongquan; PENG, Jianchun. Forecasting Photovoltaic Power using a Convolutional Neural Network and the Wavelet Transformation. *Em*: DESTECH TRANSACTIONS ON COMPUTER SCIENCE AND ENGINEERING 2018, [s.l: s.n.] p. 350–357. DOI: 10.12783/dtcse/csae2017/17503.

ZAFAR, Rehman; VU, Ba Hau; HUSEIN, Munir; CHUNG, Il-Yop. Day-Ahead Solar Irradiance Forecasting Using Hybrid Recurrent Neural Network with Weather Classification for Power System Scheduling. **Applied Sciences**, *[S. l.]*, v. 11, n. 15, p. 6738, 2021. DOI: 10.3390/app11156738. Disponível em: https://www.mdpi.com/2076-3417/11/15/6738.

ZANG, Haixiang; LIU, Ling; SUN, Li; CHENG, Lilin; WEI, Zhinong; SUN, Guoqiang. Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations. **Renewable Energy**, *[S. l.]*, v. 160, p. 26–41, 2020. DOI: 10.1016/j.renene.2020.05.150. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0960148120308557.

ZENG, Jianwu; QIAO, Wei. Short-term solar power prediction using a support vector machine. **Renewable Energy**, *[S. l.]*, v. 52, p. 118–127, 2013. DOI: 10.1016/j.renene.2012.10.009.

ZHANG, Can; DU, Yang; CHEN, Xiaoyang; LIM, Eng Gee. Cloud Motion Forecasting and Cloud Base Height Estimation Using Two Low-Cost Sky Cameras. *Em*: 2ND IEEE CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION, EI2 2018 - PROCEEDINGS 2018a,: IEEE, 2018. p. 1–6. DOI: 10.1109/EI2.2018.8582657. Disponível em: https://ieeexplore.ieee.org/document/8582657/.

ZHANG, Jinsong; VERSCHAE, Rodrigo; NOBUHARA, Shohei; LALONDE, Jean François. Deep photovoltaic nowcasting. **Solar Energy**, *[S. l.]*, v. 176, n. October, p. 267–276, 2018. b. DOI: 10.1016/j.solener.2018.10.024. Disponível em: https://doi.org/10.1016/j.solener.2018.10.024.

ZHANG, Jinxia; CHI, Yuanying; XIAO, Linpeng. Solar Power Generation Forecast Based on LSTM. *Em*: (Li, W and Babu, MSP, Org.)PROCEEDINGS OF THE IEEE

INTERNATIONAL CONFERENCE ON SOFTWARE ENGINEERING AND SERVICE SCIENCES, ICSESS 2019, [s.l: s.n.] p. 869–872. DOI: 10.1109/ICSESS.2018.8663788.

ZHANG, Rui; FENG, Minwei; ZHANG, Wei; LU, Siyuan; WANG, Fei. Forecast of Solar Energy Production - A Deep Learning Approach. *Em*: 2018 IEEE INTERNATIONAL CONFERENCE ON BIG KNOWLEDGE (ICBK) 2018c: IEEE, 2018. p. 73–82. DOI: 10.1109/ICBK.2018.00018. Disponível em: https://ieeexplore.ieee.org/document/8588777/.

ZHANG, Xinmin; LI, Yuan; LU, Siyuan; HAMANN, Hendrik F.; HODGE, Bri Mathias; LEHMAN, Brad. A Solar Time Based Analog Ensemble Method for Regional Solar Power Forecasting. **IEEE Transactions on Sustainable Energy**, *[S. l.]*, v. 10, n. 1, p. 268–279, 2019. DOI: 10.1109/TSTE.2018.2832634.

ZHANG, Yue; BEAUDIN, Marc; ZAREIPOUR, Hamidreza; WOOD, David. Forecasting Solar Photovoltaic power production at the aggregated system level. *Em*: 2014 NORTH AMERICAN POWER SYMPOSIUM, NAPS 2014 2014, [s.l: s.n.] DOI: 10.1109/NAPS.2014.6965389.

ZHEN, Zhao; PANG, Shuaijie; WANG, Fei; LI, Kangping; LI, Zhigang; REN, Hui; SHAFIE-KHAH, Miadreza; CATALAO, Joao P. S. Pattern Classification and PSO Optimal Weights Based Sky Images Cloud Motion Speed Calculation Method for Solar PV Power Forecasting. **IEEE Transactions on Industry Applications**, *[S. l.]*, v. 55, n. 4, p. 3331–3342, 2019. DOI: 10.1109/TIA.2019.2904927.

ZHEN, Zhao; WANG, Fei; SUN, Yujing; MI, Zengqiang; LIU, Chun; WANG, Bo; LU, Jing. SVM based cloud classification model using total sky images for PV power forecasting. *Em*: 2015 IEEE POWER AND ENERGY SOCIETY INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE, ISGT 2015 2015, [s.l: s.n.] DOI: 10.1109/ISGT.2015.7131784.

ZHEN, Zhao; ZHANG, Xuemin; MEI, Shengwei; CHANG, Xiqiang; CHAI, Hua; YIN, Rui; WANG, Fei. Ultra-short-term irradiance forecasting model based on ground-based cloud image and deep learning algorithm. **IET Renewable Power Generation**, *[S. l.]*, v. 16, n. 12, p. 2604–2616, 2022. DOI: 10.1049/rpg2.12280. Disponível em: https://onlinelibrary.wiley.com/doi/10.1049/rpg2.12280.

ZHOU, Hangxia; ZHANG, Yujin; YANG, Lingfan; LIU, Qian. Short-Term Photovoltaic Power Forecasting Based on Stacking-SVM. *Em*: PROCEEDINGS - 9TH INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY IN MEDICINE AND EDUCATION, ITME 2018 2018, [s.l: s.n.] p. 994–998. DOI: 10.1109/ITME.2018.00221.

ZHOU, Hangxia; ZHANG, Yujin; YANG, Lingfan; LIU, Qian; YAN, Ke; DU, Yang. Short-Term photovoltaic power forecasting based on long short term memory neural network and attention mechanism. **IEEE Access**, *[S. l.]*, v. 7, p. 78063–78074, 2019. DOI: 10.1109/ACCESS.2019.2923006.

ZHU, Honglu; LI, Xu; SUN, Qiao; NIE, Ling; YAO, Jianxi; ZHAO, Gang. A power prediction method for photovoltaic power plant based on wavelet decomposition and artificial neural networks. **Energies**, *[S. l.]*, v. 9, n. 1, 2016. DOI: 10.3390/en9010011.