

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

PROGRAMA DE PÓS-GRADUAÇÃO EM

METEOROLOGIA



DISSERTAÇÃO DE MESTRADO

Cleiza Cristiano Silva

**Avaliação de técnicas de Deep Learning para
prognósticos de energia solar**

Campina Grande, Fevereiro de 2024



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE - UFCG
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS - CTRN
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS – UACA
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA - PPGMET

DISSERTAÇÃO DE MESTRADO

AVALIAÇÃO DE TÉCNICAS DE DEEP LEARNING PARA
PROGNÓSTICOS DE ENERGIA SOLAR

CLEIZA CRISTIANO SILVA

CAMPINA GRANDE - PB
FEVEREIRO / 2024

DISSERTAÇÃO DE MESTRADO

**AVALIAÇÃO DE TÉCNICAS DE DEEP LEARNING PARA
PROGNÓSTICOS DE ENERGIA SOLAR**

CLEIZA CRISTIANO SILVA

ORIENTADORES:

Prof. Dr. Helber Barros Gomes

Prof. Dr. Malaquias Peña

**CAMPINA GRANDE - PB
FEVEREIRO / 2024**

CLEIZA CRISTIANO SILVA

**AVALIAÇÃO DE TÉCNICAS DE DEEP LEARNING PARA
PROGNÓSTICOS DE ENERGIA SOLAR**

Dissertação apresentada ao Curso de Mestrado em Meteorologia da Universidade Federal de Campina Grande em cumprimento às exigências para obtenção de título de Mestre em Meteorologia.

Área de concentração: Meteorologia de Meso e Grande Escalas

**CAMPINA GRANDE - PB
FEVEREIRO / 2024**

S586a

Silva, Cleiza Cristiano.

Avaliação de técnicas de Deep Learning para prognósticos de energia solar / Cleiza Cristiano Silva. – Campina Grande, 2024.

172 f. : il. color.

Dissertação (Mestrado em Meteorologia) - Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2024.

"Orientação: Prof. Dr. Helber Barros Gomes, Prof. Malaquias Peña Mendez".

Referências.

1. Radiação Solar. 2. Nordeste - Brasil. 3. Módulos Fotovoltaicos. 4. Métricas de Desempenho. I. Gomes, Helber Barros. II. Mendez, Malaquias Peña. III. Título.

CDU 551.521.37(043)

CLEIZA CRISTIANO SILVA

AVALIAÇÃO DE TÉCNICAS DE DEEP LEARNING
PARA PROGNÓSTICOS DE ENERGIA SOLAR

DISSERTAÇÃO APROVADA EM 20/02/2024

BANCA EXAMINADORA

Documento assinado digitalmente

 HELBER BARROS GOMES
Data: 27/02/2024 07:36:21-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. HELBER BARROS GOMES
Instituto de Ciências Atmosféricas
Universidade Federal de Alagoas



Prof. Dr. MALAQUIAS PEÑA MENDEZ
Department of Civil and Environmental Engineering
University of Connecticut



Prof. Dr. MADSON TAVARES SILVA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande

Samira de Azevedo
Santos Emiliavaca:
013.499.424-80

Assinado de forma digital por
Samira de Azevedo Santos
Emiliavaca: 013.499.424-80
Dados: 2024.02.27 08:47:08 -0300

Dra. SAMIRA DE AZEVEDO SANTOS EMILIAVACA
Instituto SENAI de Inovação
Energias Renováveis

Nunca duvidei de mim mesmo,
Comandante, e não vou começar agora!
(Buzz Lightyear)

DEDICATÓRIA

Aos meus pais,
Cleide Cristiano e Edielson Luis, que com toda humildade e simplicidade, ensinaram-me a ser uma pessoa decente, a respeitar e a buscar meus sonhos de forma honesta, mesmo que seja com muito trabalho. Agradeço por sempre apoiarem minhas decisões.

Aos meus irmãos,
Cleizi Gildina e Edicleidson Cristiano, pelo apoio, companheirismo e incentivo, sempre transmitindo forças para continuar.

AGRADECIMENTOS

Aos meus orientadores Prof. Dr. Helber Barros Gomes e Prof. Dr. Malaquias Peña, pelo apoio constante em cada etapa da pesquisa e por toda confiança. É com profunda gratidão e admiração que reconheço o papel fundamental que desempenharam em minha formação.

Ao Programa de Pós-Graduação em Meteorologia do Centro de Tecnologia e Recursos Naturais da Universidade Federal do Rio Grande do Norte, pela confiança depositada.

À banca examinadora, pela disposição e colaboração na melhoria deste trabalho.

À minha grande amiga Kivia Macêdo, que tem me acompanhado desde a graduação, sempre à disposição para me ouvir e oferecer conselhos valiosos.

Aos meus amigos do Jet Streams, Thayná Vila Nova e Matheus Maroja. Vocês foram essenciais durante essa trajetória; agradeço por cada momento compartilhado e por tornar tudo mais leve.

À "galera" de Maceió, por me acolher tão bem durante meu período em Campina Grande.

Ao Prof. Dr. Cláudio Moisés Santos e Silva, um grande profissional no qual admiro. Desde a graduação, confiou no meu potencial e continua sendo um grande incentivador durante minha formação acadêmica.

À querida Arilene, por toda disposição e proatividade.

A todos que, de forma direta ou indireta, colaboraram durante esse ciclo, deixo o meu mais sincero MUITO OBRIGADA!

LISTA DE FIGURAS

		Pág.
Figura 1	Evolução da fonte solar fotovoltaica no Brasil. Fonte: ANEEL/ABSOLAR, 2023. Elaboração: Autor (2024).	23
Figura 2	Espectro eletromagnético da radiação solar. Na área verde, temos a radiação solar ao nível médio do mar; a linha em roxo representa a radiação no topo da atmosfera, e, para comparação, é apresentada uma curva de emissão de um corpo negro a 6000 K (linha tracejada). Fonte: Pereira <i>et al.</i> (2017).	29
Figura 3	Distribuição latitudinal da insolação anual. Fonte: Ayoade (1996), conforme Sellers (1965).	30
Figura 4	Variação diária da radiação solar no topo da atmosfera em função da latitude, em langleys por dia. Fonte: Ayoade (1996), conforme Sellers (1965).	31
Figura 5	Modelo do balanço de radiação. Fonte: Ynoue <i>et al.</i> (2017), conforme Donald Ahrens e Henson (2015).	33
Figura 6	Variação da irradiância e irradiação solar em função das condições atmosféricas e movimentos da Terra. Fonte: Ferreira (2019).	34
Figura 7	Variação da irradiância solar durante o ano. Fonte: Duffie e Beckman (2013).	34
Figura 8	Média anual da irradiação global horizontal no Brasil. Fonte: Martins <i>et al.</i> (2017).	35
Figura 9	Radiação direta e difusa.	36
Figura 10	Parte da patente da primeira célula solar, registrada em março de 1954 por D.M. Chapin e colaboradores do <i>Bell Laboratories</i> .	38
Figura 11	Célula de silício monocristalino (a) e célula de silício policristalino (b). Fonte: Solar (2006).	39
Figura 12	a) Curva característica IV mostrando a corrente e a tensão. b) Curva típica de potência versus tensão. c) Parâmetro de potência máxima. Fonte: adaptado de Solar (2006).	40
Figura 13	Variação da corrente com a mudança de irradiância. Fonte: Solar (2006).	41

	Pág.
Figura 14	Varição da tensão com a mudança de temperatura. Fonte: Solar (2006). 41
Figura 15	Sistema fotovoltaico isolado. 42
Figura 16	Sistema fotovoltaico ligado à rede. 43
Figura 17	Classificação climática de acordo com os critérios de Köppen (1936). 44
Figura 18	Normal Climatológica Anual do Brasil 1961-1990 de precipitação e temperatura. Fonte: INMET, 2016. 45
Figura 19	Representação esquemática dos principais sistemas meteorológicos atuantes no território brasileiro nos períodos de primavera/verão (a) e outono/inverno (b). Fonte: Martins <i>et al.</i> (2017). 46
Figura 20	Evolução da participação das fontes na geração de energia elétrica do Subistema Nordeste - 2010-2020 (%). Fonte: Bezerra (2021), conforme ONS (2021), elaborado por BNB/Etene (2021). 48
Figura 21	Ranking estadual da geração de energia distribuída. Fonte: ANEEL/ABSOLAR, 2023. 49
Figura 22	Avanço dos preços de energia solar nos leilões promovidos pelo Governo Federal. Fonte: CCEE (2023). Elaboração: autor (2023). 50
Figura 23	Ranking estadual da geração de energia centralizada. Fonte: ANEEL/ABSOLAR, 2023. 51
Figura 24	Neurônio biológico e neurônio artificial. Fonte: Adaptado de NAGYFI (2018). 52
Figura 25	Exemplificação de uma rede neural profunda. 53
Figura 26	Exemplificação de clustering identificando padrões nos dados. 54
Figura 27	Funcionamento do aprendizado reforçado. 55
Figura 28	Localização do Nordeste no Brasil e área de estudo. 57
Figura 29	Localização das estações automáticas no Nordeste do Brasil. 59
Figura 30	Localização das usinas fotovoltaicas utilizadas no estudo 62
Figura 31	Q-Q Plot e p-valor das variáveis T2M, TCC, SSRD, GHI, Rg, TP. 74
Figura 32	Boxplot e média horária da irradiação global horizontal, para o período de 2009 a 2019, obtidos através dos dados observados do INMET. 76
Figura 33	Violinplot e média mensal da irradiação global horizontal, para o período de 2009 a 2019, obtidos através dos dados observados do INMET. 76

	Pág.
Figura 34 Boxplot e média horária da irradiação solar incidente no topo da atmosfera, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	77
Figura 35 Violinplot e média mensal da irradiação solar incidente no topo da atmosfera, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	78
Figura 36 Boxplot e média horária da irradiação global horizontal, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	79
Figura 37 Violinplot e média mensal da irradiação global horizontal, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	79
Figura 38 Boxplot e média horária da temperatura em 2 metros, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	80
Figura 39 Violinplot e média mensal da temperatura em 2 metros, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	81
Figura 40 Boxplot e média horária da precipitação total, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	82
Figura 41 Violinplot e média mensal da precipitação total, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	82
Figura 42 Boxplot e média horária da cobertura total de nuvens, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	83
Figura 43 Violinplot e média mensal da cobertura total de nuvens, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.	84
Figura 44 Correlação de Pearson aplicada as variáveis de Rg, SSRD, TCC, TP, T2M e GHI.	85
Figura 45 Q-Q Plot e p-valor da geração de energia verificada.	86
Figura 46 Boxplot e média horária da geração de energia verificada, para o período de 2017 a 2019, obtidos através dos dados observados do ONS.	88
Figura 47 Violinplot e média mensal da geração de energia verificada, para o período de 2017 a 2019, obtidos através dos dados observados do ONS.	88
Figura 48 Média horária da GHI, SSRD, T2M, TCC e TP, para o período de 2009 a 2019, obtidos através dos dados do ERA5.	90

	Pág.
Figura 49 Média horária da GHI para o período de 2009 a 2019 e a CI de energia para cada usina.	91
Figura 50 Média horária da GHI para o período de 2009 a 2019 e a CGE média horária para cada usina.	92
Figura 51 Média horária da GHI para o período de 2009 a 2019 e a GEV média horária para cada usina.	93
Figura 52 Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e LSTM+GRU (b), para o Conjunto Bom Jesus.	97
Figura 53 Dados observados e previsão para o período de validação referente aos métodos CNN (a) e LSTM+GRU (b), para o Conjunto Bom Jesus.	98
Figura 54 Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Horizonte.	102
Figura 55 Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Horizonte.	103
Figura 56 Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Nova Olinda.	107
Figura 57 Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Nova Olinda.	108
Figura 58 Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Rio Alto.	112
Figura 59 Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Rio Alto.	113
Figura 60 Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Sol do Futuro.	117
Figura 61 Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Sol do Futuro.	108

LISTA DE TABELAS

		Pág.
Tabela 1	Variável obtida através das estações do INMET.	59
Tabela 2	Variáveis utilizadas de acordo com os dados de análise do ERA.	60
Tabela 3	Variável obtida através dos dados da ONS.	61
Tabela 4	Usinas fotovoltaicas que tiveram seu funcionamento iniciado de 2017 a 2019.	63
Tabela 5	Hiperparâmetros aplicados durante o treinamento dos métodos de Deep Learning para prognóstico de Geração de Energia Verificada.	66
Tabela 6	Medidas de tendência central e dispersão dos dados da estação de Bom Jesus da Lapa.	73
Tabela 7	P-valor obtidos como resultado do teste de Kolmogorov-Smirnov.	75
Tabela 8	Medidas de tendência central e dispersão dos dados do Conjunto Bom Jesus.	86
Tabela 9	P-valor do GEV obtido como resultado do teste de Kolmogorov-Smirnov	87
Tabela 10	Métricas de avaliação de desempenho para tamanho de passos 6 para o Conjunto Bom Jesus.	94
Tabela 11	Métricas de avaliação de desempenho para tamanho de passos 12 para o Conjunto Bom Jesus.	95
Tabela 12	Métricas de avaliação de desempenho para tamanho de passos 24 para o Conjunto Bom Jesus.	96
Tabela 13	Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Horizonte.	99
Tabela 14	Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Horizonte.	100
Tabela 15	Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Horizonte.	100
Tabela 16	Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Nova Olinda.	104
Tabela 17	Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Nova Olinda.	105

		Pág.
Tabela 18	Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Nova Olinda.	105
Tabela 19	Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Rio Alto.	109
Tabela 20	Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Rio Alto.	110
Tabela 21	Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Rio Alto.	111
Tabela 22	Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Sol do Futuro.	114
Tabela 23	Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Sol do Futuro.	115
Tabela 24	Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Sol do Futuro.	115

LISTA DE SÍMBOLOS E SIGLAS

ABSOLAR	- Associação Brasileira de Energia Solar
ANEEL	- Agência Nacional de Energia Elétrica
CA	- Corrente Alternada
CC	- Corrente Contínua
CDS	- Climate Data Store
CGE	- Capacidade de Geração de Energia
CI	- Capacidade Instalada
CNN	- Convolutional Neural Network
COFINS	- Contribuição para o Financiamento da Seguridade Social
DL	- Deep Learning
DOL	- European Center for Medium-Range Weather Forecasts
ECMWF	- Distúrbios Ondulatórios de Leste
GEV	- Geração de Energia Verificada
GHI	- Irradiação Global Horizontal
GRU	- Gated Recurrent Unit
II	- Imposto de Importação
Imp	- Ponto Máximo de Potência
INMET	- Instituto Nacional de Meteorologia
IPI	- Imposto sobre Produtos Industrializados
Isc	- Corrente
JBN	- Jatos de Baixos Níveis
LEN	- Leilão de Energia Nova
LER	- Leilão de Energia Reserva
LSTM	- Long Short-Term Memory
MAE	- Mean Absolute Error
ML	- Machine Learning
NEB	- Nordeste do Brasil
ONS	- Operador Nacional de Sistemas Elétricos
PADIS	- Programa de Apoio ao Desenvolvimento Tecnológico da Indústria de Semicondutores
PASEP	- Programa de Formação do patrimônio do Servidor Público
PIS	- Programa de Integração Social
Pm	- Potência
Pmax	- Ponto de Potência Máxima
P&D	- Pesquisa e Desenvolvimento
Rg	- Irradiação global
RMSE	- Root Mean Squared Error
SCM	- Sistemas Convectivos de Mesoescala
SIGEL	- Sistema de Informações Geográficas do Setor de Energia
SIN	- Sistema Interligado Nacional
SSRD	- Irradiação Solar Incidente no Topo da Atmosfera
T2M	- Temperatura em 2 metros
TCC	- Cobertura Total de Nuvens
TP	- Precipitação Total
VCAN	- Vórtices Ciclônicos de Altos Níveis
Vmp	- Ponto de Máxima Potência

- Voc - Tensão de Saída
- ZCAS - Zona de Convergência do Atlântico Sul
- ZCIT - Zona de Convergência Intertropical

AVALIAÇÃO DE TÉCNICAS DE DEEP LEARNING PARA PROGNÓSTICOS DE ENERGIA SOLAR

RESUMO

Nos últimos anos, a energia solar tem conquistado significativa relevância devido à sua natureza renovável, considerada uma das fontes com impacto quase nulo sobre o meio ambiente e economicamente viável. Devido às condições geográficas do Nordeste do Brasil (NEB), a utilização de energia fotovoltaica se torna uma ótima opção para a diversificação das fontes energéticas. Nesse contexto, esta pesquisa tem como motivação a análise da aplicação de técnicas de Aprendizagem Profunda, conhecida como "*Deep Learning*" (DL), para o prognóstico de geração de energia solar no NEB, visando ampliar o conhecimento e facilitar aplicações de estudos na área. Para isso, utilizou-se dados de reanálise do ERA5 no período de 2009 a 2019, incluindo informações como Irradiação Solar Incidente no Topo da Atmosfera (SSRD), Irradiação Global Horizontal (GHI), Temperatura em 2 metros (T2M), Precipitação Total (TP) e Cobertura Total de Nuvens (TCC), além de dados do Instituto Nacional de Meteorologia (INMET) de Irradiação Global Horizontal (Rg). Dados de geração de energia, incluindo Geração de Energia Verificada (GEV), Capacidade de Geração de Energia (CGE) e Capacidade Instalada (CI), foram obtidos do Operador Nacional de Sistemas Elétricos (ONS). Ao analisar os dados meteorológicos, observou-se correlações entre T2M, Rg e outras variáveis meteorológicas. Com os dados de eficiência na geração de energia solar, identificou-se que as usinas com maiores potenciais de CI estão concentradas no Piauí e Bahia, regiões onde o GHI possui valores médios horários elevados, atingindo aproximadamente 200 Wh/m². Essas regiões também apresentam maiores valores de T2M e SSRD, e menores valores de TCC e TP. A eficiência dos modelos de previsão foi examinada com mais detalhes para os Conjuntos Bom Jesus, Horizonte, Nova Olinda, Rio Alto e Sol do Futuro, localizados na Bahia, Piauí, Paraíba e Ceará, destacando o método *Gated Recurrent Unit* (GRU) e combinações que o envolvem, como superiores em termos das métricas Erro Quadrático Médio (*Root Mean Squared Error* - RMSE) e Erro Médio Absoluto (*Mean Absolute Error* - MAE), mantendo consistência para diferentes tamanhos de passos. A validação, através da comparação do previsto com os dados observados, reforçou que o GRU, ou combinações que o envolvem, apresentam resultados mais eficazes na tarefa de prognóstico para os conjuntos de dados estudados.

Palavras-Chave: Radiação solar; Nordeste; Módulos fotovoltaicos; Métricas de desempenho.

EVALUATION OF DEEP LEARNING TECHNIQUES FOR SOLAR ENERGY PROGNOSIS

ABSTRACT

In recent years, solar energy has gained significant relevance due to its renewable nature, considered one of the sources with almost no impact on the environment and economically viable. Due to the geographic conditions of the NEB, the use of photovoltaic energy becomes a great option for the diversification of energy sources. In this context, this research is motivated by the analysis of the application of Deep Learning techniques, known as "Deep Learning" DL, for the prognosis of solar energy generation in the NEB, aiming to expand knowledge and facilitate study applications in the area. For this, ERA5 reanalysis data was used from 2009 to 2019, including information such as SSRD, GHI, T2M, TP and TCC, in addition to data from INMET of Rg. Power generation data, including GEV, CGE and CI, were obtained from ONS. When analyzing meteorological data, correlations were observed between T2M, Rg and other meteorological variables. With the efficiency data in solar energy generation, it was identified that the plants with the highest IC potential are concentrated in Piauí and Bahia, regions where the GHI has high hourly average values, reaching approximately 200 Wh/m². These regions also present higher T2M and SSRD values, and lower TCC and TP values. The efficiency of the forecast models was examined in more detail for the Bom Jesus, Horizonte, Nova Olinda, Rio Alto and Sol do Futuro Complexes, located in Bahia, Piauí, Paraíba and Ceará, highlighting the GRU method and combinations that involve it, such as superior in terms of RMSE and MAE metrics, maintaining consistency for different step sizes. Validation, through comparison of predicted with observed data, reinforced that the GRU, or combinations that involve it, present more effective results in the prediction task for the data sets studied.

Keywords: Solar radiation; Northeast; Photovoltaic modules; Performance metrics.

SUMÁRIO

	Pág.
1. INTRODUÇÃO.....	22
2. OBJETIVOS.....	27
2.1. OBJETIVO GERAL.....	27
2.2. OBJETIVO ESPECÍFICO.....	27
3. REVISÃO DA LITERATURA.....	28
3.1. Radiação solar.....	28
3.1.1. Origem da radiação.....	28
3.1.2. Variação da radiação.....	30
3.1.3. Balanço de radiação.....	32
3.1.4. Irradiância e irradiação.....	33
3.1.5. Radiação direta, difusa e global.....	36
3.1.6. Geometria solar.....	37
3.2. Energia solar fotovoltaica.....	37
3.2.1. Criação e efeito fotovoltaico.....	37
3.2.2. Funcionamento.....	38
3.2.3. Sistema fotovoltaico.....	42
3.2.4. Influência dos parâmetros climáticos no desempenho dos sistemas fotovoltaicos.....	43
3.2.4.1. Classificação climática.....	43
3.2.4.2. Elementos que influenciam os sistemas fotovoltaicos.....	46
3.2.5. Energia solar fotovoltaica no Nordeste do Brasil.....	47
3.3. Deep Learning.....	51
3.3.1. Tipos de aprendizado.....	53
3.3.1.1. Aprendizado de máquina supervisionado.....	53
3.3.1.2. Aprendizado de máquina não supervisionado.....	54
3.3.1.3. Aprendizado reforçado.....	55
3.3.2. Aplicação de Deep Learning em estufos de geração de energia solar.....	55
4. MATERIAL E MÉTODOS.....	57
4.1. Área de estudo.....	57
4.2. Dados.....	58
4.2.1. Observados.....	58
4.2.2. Reanálise do ERA5.....	59
4.2.3. Operador Nacional de Sistemas Elétricos.....	60
4.3. Análise estatística.....	63
4.3.1. Medidas de tendência central e dispersão.....	63
4.3.2. Teste de normalidade.....	64
4.3.3. Correlação.....	64
4.4. Aplicação de Deep Learning.....	65
4.4.1. Convolutional Neural Network.....	66
4.4.2. Long Short-term Memory.....	68
4.4.3. Gated Recurrent Unit.....	70
4.4.4. Métricas de desempenho.....	71
5. RESULTADOS.....	72
5.1. Dados da Estação de Bom Jesus da Lapa e Conjunto Bom Jesus.....	72
5.1.1. Estação de Bom Jesus da Lapa.....	72
5.1.1.1. Estatística descritiva e normalidade dos dados.....	72

	Pág.
5.1.1.2. Análise descritiva.....	75
5.1.1.3. Correlação entre as variáveis meteorológicas.....	84
5.1.2. Dados de energia do Conjunto Bom Jesus.....	85
5.1.2.1. Estatística descritiva e normalidade dos dados.....	85
5.1.2.2. Análise descritiva.....	87
5.2. Análise espacial das variáveis do ERA5.....	89
5.3. Dados de energia x GHI.....	91
5.4. Aplicação de Deep Learning.....	94
5.4.1. Conjunto Bom Jesus.....	94
5.4.1.1. Métrica de desempenho.....	94
5.4.1.2. Validação.....	96
5.4.2. Conjunto Horizonte.....	99
5.4.2.1. Métrica de desempenho.....	99
5.4.2.2. Validação.....	101
5.4.3. Conjunto Nova Olinda.....	104
5.4.3.1. Métrica de desempenho.....	104
5.4.3.2. Validação.....	106
5.4.4. Conjunto Rio Alto.....	109
5.4.4.1. Métrica de desempenho.....	109
5.4.4.2. Validação.....	111
5.4.5. Conjunto Sol do Futuro.....	114
5.4.5.1. Métrica de desempenho.....	114
5.4.5.2. Validação.....	116
6. CONCLUSÕES.....	119
REFERÊNCIAS BIBLIOGRÁFICAS.....	121
ANEXO A.....	131
ANEXO B.....	144
ANEXO C.....	169

1. INTRODUÇÃO

De acordo com Mantovani, Neumann e Edler (2017), as fontes energéticas podem ser divididas da seguinte forma:

- Não renováveis: encontram-se disponíveis de forma limitada na natureza, cujo ciclo de formação é de milhões de anos, e se extinguem após sua utilização, ou seja, uma vez esgotadas, não poderão ser regeneradas. São consideradas fontes de energias não renováveis os combustíveis fósseis como o petróleo, gás natural, carvão e o urânio como fonte de energia nuclear.
- Renováveis: são aquelas que utilizam recursos que possuem a capacidade de manter-se disponíveis por um longo prazo devido às características de renovação em ciclos contínuos, que se repetem em espaço de tempo relativamente curto, ou inesgotáveis do ponto de vista da longevidade humana, como a radiação solar, ventos, água, biomassa e outros.

O sol é uma fonte de energia primária que tem impacto direto em diversas atividades no planeta, assegurando a existência de vida na terra. A importância de sua presença vai desde a necessidade da sua luz para realização de fotossíntese dos vegetais até a de nós humanos para obtenção de vitamina D. Segundo Goldemberg (2015), a maioria das energias renováveis (energia eólica, solar térmica, eletricidade solar com células fotovoltaicas e energia de biomassa) tem origem na radiação solar que não vai se esgotar e que não é poluente, além de estar distribuída sobre o planeta de uma forma mais equitativa do que as fontes fósseis de energia.

Hémery, Debeir e Deléage (1993) estimam que os primeiros relatos referentes ao aproveitamento da energia solar para fins de iluminação deram-se no período Paleolítico. Souza (2005) alega que achados históricos de arqueólogos mostram que, já no século VII a.C., utilizavam-se simples lentes de vidro para concentrar a luz do sol e, desta forma, queimar pedaços de madeira para obter fogo. Os primeiros relatos da utilização de energia solar foram registrados em 4000 a.C. na Mesopotâmia, onde o calor do sol era utilizado para secar cereais e produzir tijolos (ROSA, 2016).

Com o aumento da população mundial e todas as questões ambientais dos últimos anos, a procura pela produção de uma energia limpa tem sido pauta para investimentos em pesquisas. Segundo Dos Reis e Santos (2006), a energia é um dos principais vetores influentes na questão ambiental e está no centro das discussões globais que originaram o conceito de desenvolvimento sustentável, cuja implementação tem sido um grande desafio para a humanidade.

Segundo dados da Agência Nacional de Energia Elétrica (ANEEL) (2022), a matriz elétrica

no Brasil divide-se da seguinte forma: 54,9% em usinas hidrelétricas, 24,6% em termelétricas, 12,3% em energia eólica, 3,7% em energia solar, 3,0% em pequenas hidrelétricas e, finalmente, uma quantidade muito pequena de usina nuclear. A predominância das usinas hidrelétricas no Brasil, consideradas fontes renováveis, acarreta em diversos prejuízos socioambientais, como é o caso do aumento da extinção na fauna e flora local (SOARES, 2009). Além disso, devido à falta de chuvas, erros de operação dos reservatórios e baixos investimentos no setor, o Brasil enfrentou um racionamento de energia que ficou conhecido popularmente como “crise do apagão” e colocou em dúvida a confiabilidade na fonte hidráulica, trazendo à tona a discussão da diversificação da matriz elétrica (TOLMASQUIM, 2000; MARENGO *et al.*, 2015).

Sabendo que a energia solar, a partir de painéis fotovoltaicos, é uma fonte que apresenta poucos impactos ambientais e sociais, esta torna-se uma alternativa sustentável para diversificar as fontes de energia elétrica do país (PINHO e GALDINO, 2014).

De acordo com os dados da ANEEL e da Associação Brasileira de Energia Solar (ABSOLAR), em 2023, a capacidade instalada de energia solar no Brasil alcançou um crescimento significativo, aumentando de 1194 MW em 2017 para 35.739 MW até novembro de 2023 (Figura 1). Esse grande impulso é resultado dos avanços no marco legal da geração distribuída e da queda no preço dos equipamentos fotovoltaicos (BEZERRA, 2021).

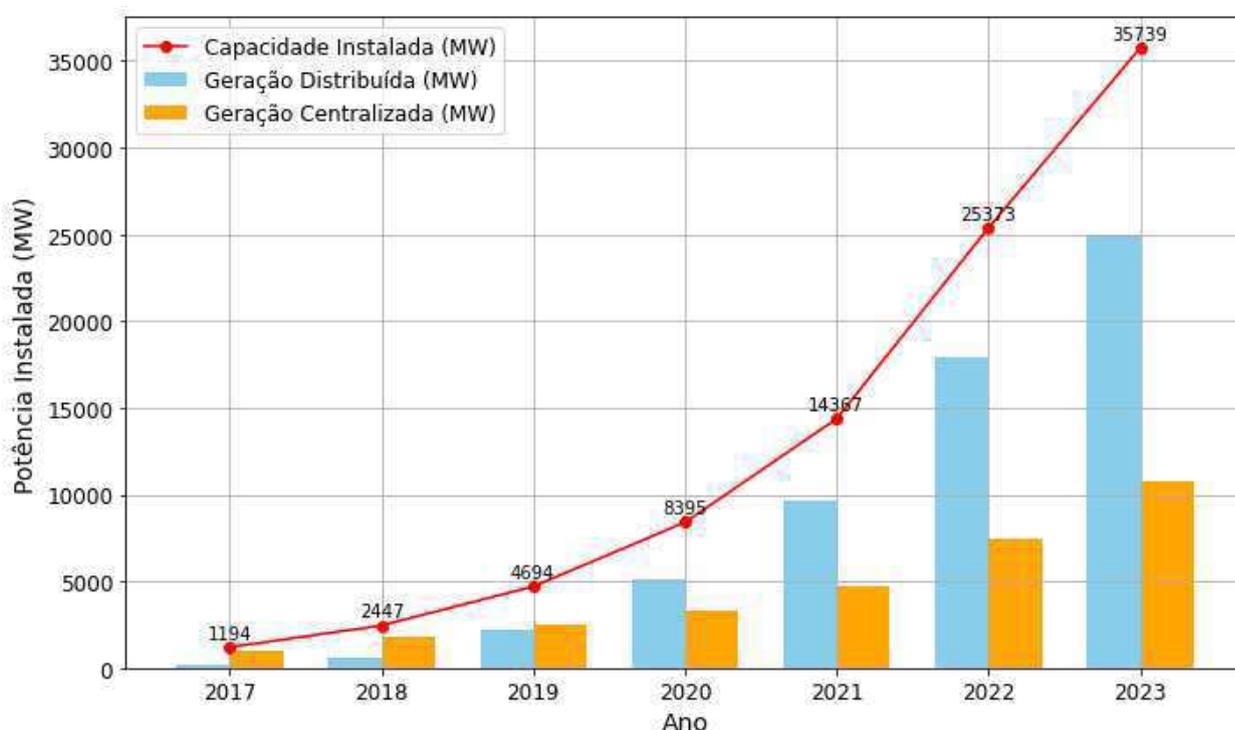


Figura 1. Evolução da fonte solar fotovoltaica no Brasil. Fonte: ANEEL/ABSOLAR, 2023. Elaboração: Autor (2024).

No Brasil, o marco regulatório que envolve a geração solar passou por modificações importantes nos últimos anos, eliminando obstáculos para a integração dessa alternativa energética na matriz elétrica nacional, seguindo a tendência de outros países (BEZERRA, 2018). Conforme Bezerra (2018), entre as leis e decretos federais criados, destacam-se:

- Lei nº 11.484, de 31 de maio de 2007:

“Art. 1º Fica instituído o Programa de Apoio ao Desenvolvimento Tecnológico da Indústria de Semicondutores (PADIS), nos termos e condições estabelecidos por esta Lei.” O PADIS é um conjunto de benefícios fiscais federais para atrair investimentos em semicondutores e displays, utilizados na fabricação de produtos eletrônicos. Ele se aplica também à cadeia de energia solar, incluindo células e módulos fotovoltaicos. Esses benefícios incluem a redução a 0% nas alíquotas de importação e impostos como Imposto de Importação (II), Imposto sobre Produtos Industrializados (IPI), Contribuições do Programa de Integração Social (PIS), e Financiamento da Seguridade Social (COFINS) na aquisição de equipamentos. Empresas que se beneficiam do PADIS recebem incentivos fiscais, como redução de IPI e PIS-COFINS. As reduções tributárias têm validade até 22/01/2022 ou por 12 ou 16 anos, dependendo do tributo e nível de investimento local. Como contrapartida, as empresas devem se comprometer com investimentos mínimos anuais em Pesquisa e Desenvolvimento (P&D);

- Lei nº 13.169/2015, de 6 de outubro de 2015:

“Art. 8º Ficam reduzidas a zero as alíquotas da Contribuição para o PIS, o Programa de Formação do Patrimônio do Servidor Público (PASEP) e do COFINS incidentes sobre a energia elétrica ativa fornecida pela distribuidora à unidade consumidora, na quantidade correspondente à soma da energia elétrica ativa injetada na rede de distribuição pela mesma unidade consumidora, com os créditos de energia ativa originados na própria unidade consumidora no mesmo mês, em meses anteriores ou em outra unidade consumidora do mesmo titular, nos termos do Sistema de Compensação de Energia Elétrica para microgeração e minigeração distribuída, conforme regulamentação da ANEEL.”

Esse crescimento, também é advindo da Resolução Normativa de nº 482 da ANEEL, publicada em 17 de abril de 2012, que diretrizes abrangentes, como créditos energéticos, encargos, potências normativas e responsabilidades relacionadas à microgeração distribuída nos sistemas de distribuição de energia elétrica, bem como ao sistema de compensação de energia elétrica (STEFANELLO, MARANGONI e ZEFERINO, 2018). Denomina-se microgeração distribuída a central geradora com potência instalada até 75 kW e segundo alteração introduzida pela Resolução Normativa nº 786, de 17 de outubro de 2017, "minigeração" é definida como central geradora de energia elétrica com potência instalada superior a 75 kW e inferior ou igual a 5 MW (sendo 3 MW

para fonte hídrica), conectadas à rede de distribuição por meio de instalações de unidades consumidoras (STEFANELLO, MARANGONI e ZEFERINO, 2018).

Outro importante motivo que contribuiu para o aumento expressivo da capacidade instalada de energia solar no Brasil são as condições climáticas favoráveis para a obtenção de radiação solar em algumas regiões do país. Mesmo com as variações climáticas, o território apresenta médias elevadas de irradiação solar e uma boa uniformidade, atingindo seu valor máximo na região Nordeste, mais especificamente no Norte do estado da Bahia, uma área que registra menor média anual de cobertura de nuvens (STEFANELLO, MARANGONI e ZEFERINO, 2018). No entanto, para análises diagnósticas e para produzir prognósticos do potencial desta energia, é necessário considerar outros aspectos, uma vez que temperatura, precipitação, duração do brilho solar (insolação), umidade relativa e vento influenciam diretamente na energia gerada (LUCAS, 2017).

Para determinar a viabilidade econômica do investimento em energia solar, é essencial recorrer a modelos de análise que considerem tanto os custos quanto os benefícios decorrentes do empreendimento (COSTA, COSTA e ECK, 2000; FADIGAS e REIS, 1993). Em média, no Brasil, o retorno financeiro ocorre entre 6 a 10 anos, o que não é necessariamente uma má notícia, dado que os módulos fotovoltaicos atualmente têm garantia de 25 anos (MACHADO e MIRANDA, 2015). Kruger, Zanella, Barichello (2023) afirmam que para painéis solares fotovoltaicos compostos por módulos de silício policristalino, inversor monofásico/trifásico, estruturas metálicas de fixação, minidisjuntor de corrente alternada, dispositivo de proteção contra surto SPW, pares de conectores MC4 e cabo solar especial, os painéis possuem garantia blindada para painéis solares de 25 anos com geração de 80% do nominal, 10 a 12 anos contra defeitos de fabricação, e para os inversores, a garantia é de 5 anos (até 20 kW) e 12 anos (50 kW) contra defeitos de fabricação.

A evolução tecnológica proporciona o acesso a uma grande quantidade de dados (*Big Data*). Nesse sentido, empresas têm utilizado esses dados para realizar previsões de tendências futuras, como a demanda por um produto (SUGAHARA, 2020). As técnicas de *Big Data* oferecem a oportunidade de alterar o modelo de negócios atual e as decisões do dia a dia por meio da análise de dados (WALLER e FAWCETT, 2013). Como indicado por Oliveira (2019), em 2013, o Aprendizado Profundo (*Deep Learning* - DL) foi reconhecido como uma das dez tecnologias inovadoras mais promissoras, mostrando uma tendência de crescimento acelerado na área de análise de *Big Data*. A estrutura do DL consiste em vários estágios, chamados de camadas, sendo a principal a camada de entrada e a última a camada de saída. Todas as camadas entre essas duas são denominadas camadas ocultas. O termo "*Deep*" (profundo) em DL deriva do fato de

geralmente envolver a presença de mais de duas camadas ocultas (ZHU *et al.*, 2017). Assim, o DL representa um ramo do Aprendizado de Máquina (*Machine Learning* – ML) que se concentra na criação de redes neurais profundas capazes de tomar decisões precisas com base em dados (KELLEHER, 2019).

Nesse contexto, a aplicação de DL para previsão de energia solar pode desempenhar um papel significativo no aprimoramento do planejamento de projetos fotovoltaicos, além de permitir o monitoramento da geração de energia em usinas solares, facilitando a tomada de decisões informadas.

2. OBJETIVOS

2.1. OBJETIVO GERAL

Esta pesquisa tem como objetivo analisar a aplicabilidade das técnicas de Deep Learning para a prognóstico de Geração de Energia Verificada no Nordeste do Brasil, bem como validar os resultados com dados observados. Buscando identificar quais métodos proporcionam previsões mais robustas e confiáveis, enquanto também se avaliar aqueles que apresentaram resultados menos satisfatórios.

2.2. OBJETIVOS ESPECÍFICOS

- Investigar a correlação entre variáveis meteorológicas e a Irradiação Global Horizontal, fatores cruciais que exercem influência direta na geração de energia solar;
- Realizar uma análise espacial da Geração de Energia Verificada e da Irradiância Global Horizontal com o intuito de identificar usinas solares com as produtividades mais elevadas e sua localização geográfica. Sendo possível determinar áreas mais promissoras para o desenvolvimento de parques solares, contribuindo para um planejamento mais eficiente;
- Avaliar a aplicabilidade de técnicas de Deep Learning no prognóstico da Geração de Energia Verificada no Nordeste do Brasil;
- Validar os prognósticos obtidos por meio de técnicas de Deep Learning com base em dados observados, garantindo a confiabilidade e a precisão das previsões na Geração de Energia Verificada no contexto do Nordeste do Brasil.

3. REVISÃO DA LITERATURA

3.1 Radiação solar

3.1.1 Origem da radiação

O sol é a principal fonte de energia que regula o tempo, o clima e a vida na Terra. Segundo Ayoade (1996), é uma esfera gasosa luminosa que apresenta em sua superfície uma temperatura de 6.000°C e emite energia em ondas eletromagnéticas, que se propagam à razão de aproximadamente 299.300 quilômetros por segundo. É o maior astro do sistema solar, com um diâmetro que corresponde a 109 vezes o diâmetro do planeta Terra. Apesar de estar a uma distância de aproximadamente 150 milhões de quilômetros, ele possui forte influência sobre a Terra, assegurando condições possíveis de vida no planeta.

Sua composição em porcentagem de massa é de 75,00% de hidrogênio, 24,25% de hélio, que se encontram quase que ionizados, além de 0,75% de outros elementos como ferro, níquel e oxigênio (COULSON, 1975). Em sua rotação, o equador leva cerca de 27 dias e as regiões polares 30 dias para cada giro. Não possui uma superfície sólida ou líquida como a Terra, porém, sua estrutura física pode ser dividida em seis camadas:

- Núcleo: o centro do sol, região mais intensa, onde devido à sua alta temperatura e forte pressão ocorrem as reações termonucleares da transformação de hidrogênio em hélio. Pode chegar a uma temperatura de 15 milhões de Kelvin;
- Zona radiativa: a energia produzida pelo núcleo é propagada por irradiação. Sua transferência de calor acontece através de ondas eletromagnéticas. Sua temperatura varia entre 2 e 7 milhões de Kelvin;
- Zona convectiva: com a presença de diferentes temperaturas, a transferência de calor acontece através de correntes circulares, ou seja, a energia nessa camada se propaga por convecção. Apresenta uma temperatura média de 2 milhões de Kelvin;
- Fotosfera: superfície do sol que pode ser observada da Terra, com temperatura de aproximadamente 5.800°C (5.778 kelvins). Local onde ocorre a formação das manchas solares, caracterizada por regiões mais frias e escuras (devido ao contraste com a superfície em si), com temperaturas de até 3.800°C;
- Cromosfera: camada irregular sobre a fotosfera, com sua temperatura variando de 6.000°C a 20.000°C e espessura de aproximadamente 10.000 km;

- Coroa: região rarefeita de formato variável que se estende por milhões de quilômetros, normalmente observada durante os eclipses totais do sol. Apresenta temperatura superior a 1.000.000°C (1 milhão) e é a camada onde saem os ventos solares.

Toda a sua energia é produzida através do processo de fusão nuclear devido à elevada temperatura do seu núcleo e a sua enorme pressão, liberando grandes quantidades de energia em forma de fótons. A radiação solar é formada no interior do sol por meio de um processo contínuo de conversão de hidrogênio em hélio, liberando grandes quantidades de calor que chegarão à Terra através da radiação solar (FOGAÇA e GOULART, 2018).

Toda essa energia é lançada em diferentes direções no espaço por meio das ondas eletromagnéticas. Todo o espectro de radiação, incluindo as ondas visíveis ao olho humano e as não visíveis, transporta energia que pode ser convertida na forma de calor ou em energia elétrica (CANTOR, 2017). A princípio, como é mostrado na Figura 2, assume-se o comportamento da irradiância do Sol como de um corpo negro à temperatura de 6000 K (linha pontilhada). Porém, com a presença de manchas solares e outros fatores, a emissão de radiação solar torna-se mais complexa do que o modelo adotado.

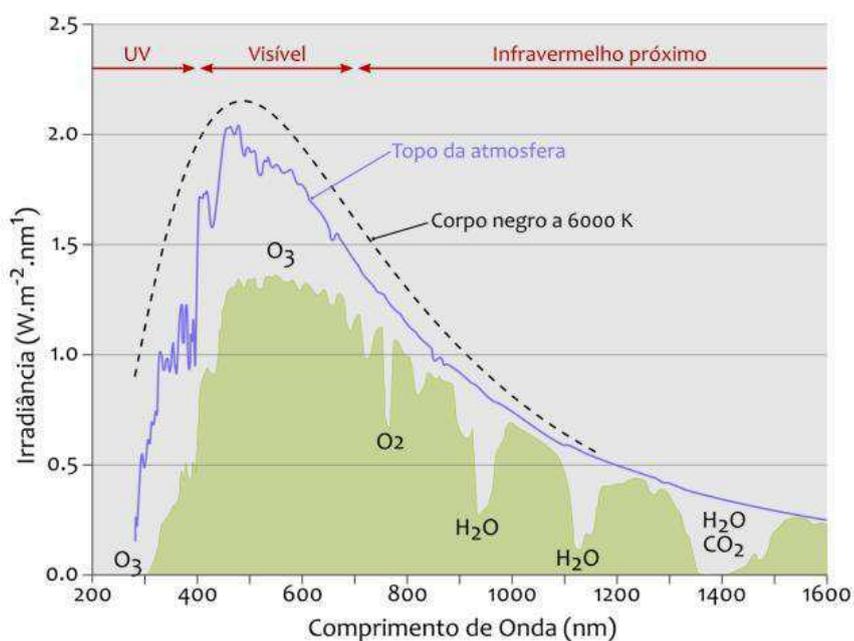


Figura 2. Espectro eletromagnético da radiação solar. Na área verde, temos a radiação solar ao nível médio do mar; a linha em roxo representa a radiação no topo da atmosfera, e, para comparação, é apresentada uma curva de emissão de um corpo negro a 6000 K (linha tracejada). Fonte: Pereira *et al.* (2017).

A radiação proveniente do Sol tem a maior parte de sua energia contida em comprimentos de onda entre 0,1 e 4 μm , correspondendo às bandas do ultravioleta, do visível e do infravermelho

próximo (BRUTSAERT, 2013). De acordo com Lemon (1966), dentro desse intervalo, cerca de 52% da radiação solar que chega à superfície da Terra está na faixa espectral do infravermelho, 44% no visível e 4% no ultravioleta. O máximo valor de radiação é observado no espectro visível (Figura 2), onde a radiação oriunda do sol é aproveitada para conversão fotovoltaica. Quanto maior a frequência (menor comprimento de onda), maior será a energia transmitida. Parte dessa radiação que chega à Terra alimenta todos os processos físicos, químicos e biológicos que ocorrem na superfície e na atmosfera.

3.1.2 Variação da radiação

Ayoade (1996) explica que a quantidade de radiação incidente sobre o topo da atmosfera da Terra depende de três fatores: ano, período do dia e latitude. A análise da variação anual de radiação solar que chega à superfície, considerando a latitude (Figura 3), sugere que a região do equador deveria apresentar a maior insolação, mas isso não é exatamente verdade. Na região do equador, encontra-se a Zona de Convergência Intertropical (ZCIT), que, devido à sua composição, tende a refletir parte dessa radiação, impedindo que atinja a superfície da Terra em quantidade elevada. Nos subtropicais, a radiação chega à superfície com mais facilidade, resultando em maior insolação. À medida que nos deslocamos em direção aos polos, a distribuição de insolação diminui devido à rotação da Terra em torno do sol, resultando na presença de radiação apenas durante metade do ano.

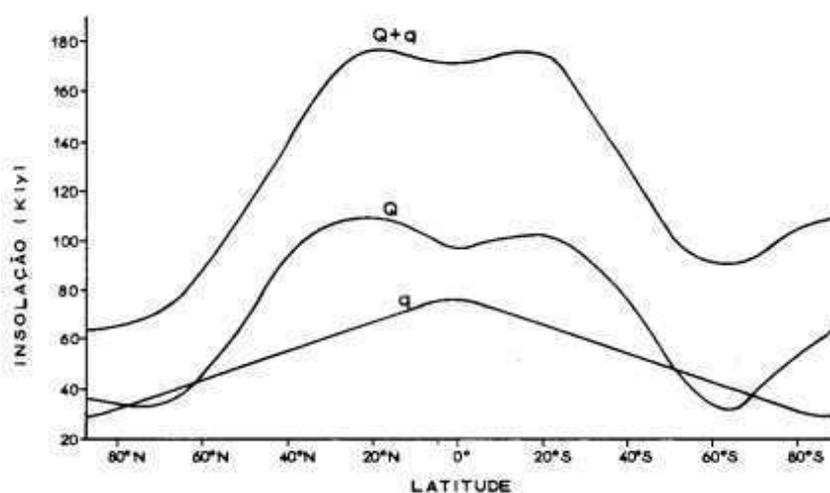


Figura 3. Distribuição latitudinal da insolação anual. Fonte: Ayoade (1996), conforme Sellers (1965).

Segundo Ayoade (1996), a radiação que atinge um determinado local também é afetada pela duração do dia, podendo sofrer variações com a latitude e estação do ano. A duração do dia

aumenta durante o verão e diminui durante o inverno de cada hemisfério, sendo essa diferença menor à medida que se aproxima do equador, onde não é observada tanta variação. Embora o Sol emita uma quantidade de radiação quase constante ao longo do ano, a energia que atinge a atmosfera terrestre pode variar devido à rotação do Sol e da Terra.

Esses fatores contribuem para criar um padrão de recebimento de energia solar (Figura 4). Duas vezes por ano, o Sol atinge uma posição mais afastada do Equador:

- 21 ou 23 de junho: solstício de inverno no hemisfério sul e de verão no hemisfério norte;
- 21 ou 23 de dezembro: solstício de verão no hemisfério sul e de inverno no hemisfério norte.

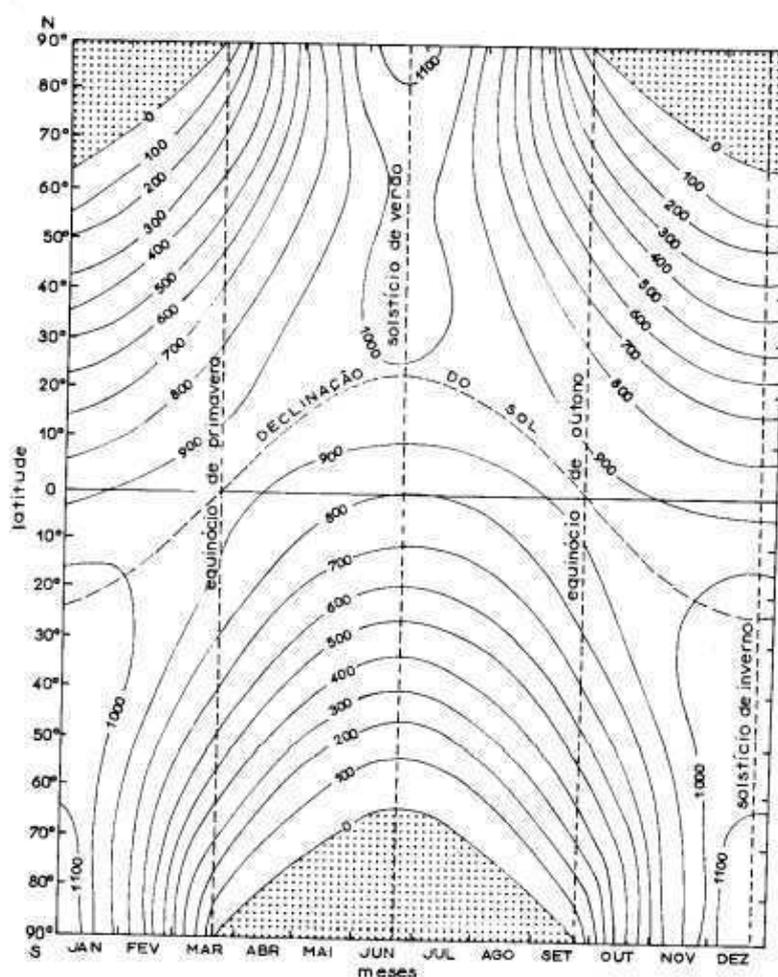


Figura 4. Variação diária da radiação solar no topo da atmosfera em função da latitude, em langleys por dia. Fonte: Ayoade (1996), conforme Sellers (1965).

Para o hemisfério sul, durante o solstício de inverno (verão), com o aumento (a diminuição) da distância Terra-Sol, observam-se menores (maiores) valores de radiação no topo da atmosfera. Com o deslocamento do equador em direção ao polo, os valores de radiação tendem a diminuir

entre os meses de fevereiro a novembro. A declinação do Sol é representada pela linha pontilhada, com variação na região próxima ao equador nos dois hemisférios.

3.1.3 Balanço de radiação

Nem toda a energia gerada e emitida pelo Sol chega à superfície terrestre; qualquer partícula em suspensão na atmosfera dificulta esse processo. A atmosfera é composta por diferentes gases estáveis. Segundo Barry e Chorley (1976), a composição média abaixo de 25 quilômetros é de 78,08% de nitrogênio (N₂), 20,94% de oxigênio (O₂), 0,93% de argônio (Ar), e o restante é composto por diferentes gases, como dióxido de carbono (CO₂), neônio (Ne), hélio (He) e ozônio (O₃).

Além disso, a atmosfera possui vários tipos de aerossóis cuja quantidade pode variar, dificultando ainda mais a chegada da radiação à superfície terrestre. Os aerossóis atmosféricos são definidos como partículas suspensas em um volume de gás, podendo ser sólidos, líquidos ou uma mistura de ambas as fases (KOLB e WORSNOP, 2012). A origem dessas partículas pode ser classificada como natural (poeira, sal marinho) ou antropogênica (produzida pelo homem, como fumaça).

Os aerossóis desempenham um papel fundamental no equilíbrio do fluxo de radiação terrestre, no controle do clima e do sistema hidrológico, e exercem funções importantes nos ecossistemas terrestres (ARTAXO *et al.*, 2013). Assim, todos os gases e aerossóis na atmosfera contribuem para absorver, refletir, difundir e reirradiar toda a energia emitida pelo Sol. No entanto, parte dessa radiação atinge diretamente a superfície (radiação solar direta), enquanto outra parte atinge a superfície após o processo de difusão (radiação solar difusa), representando o total de radiação solar que atinge a superfície terrestre, denominada radiação solar global (SILVA, 2008). Uma maneira de compreender melhor esse processo é através do balanço de radiação (Figura 5), que mostra a quantidade de radiação que entra, interage com as partículas e sai da atmosfera.

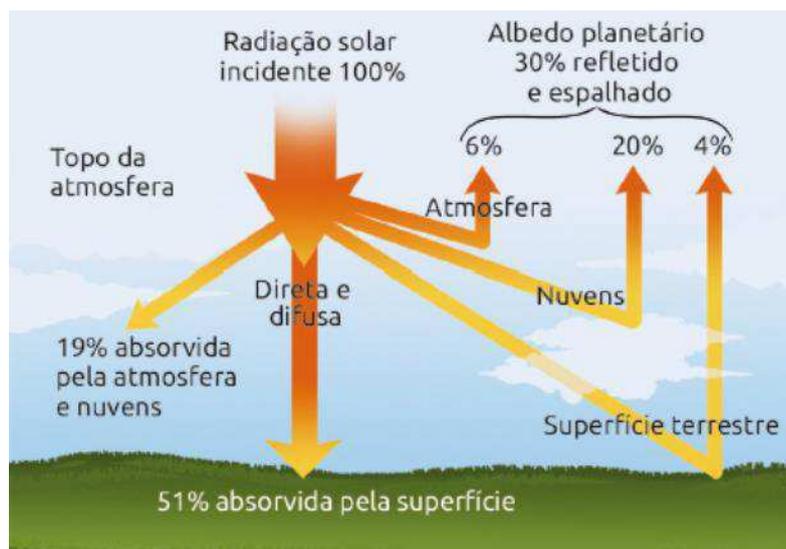


Figura 5. Modelo do balanço de radiação. Fonte: Ynoue *et al.* (2017), conforme Donald Ahrens e Henson (2015).

De acordo com Ynoue *et al.* (2017), o balanço de radiação pode ser compreendido da seguinte forma: se cem unidades de energia solar atingem o topo da atmosfera terrestre, aproximadamente 30% dessa radiação retorna para o espaço como radiação de onda curta (albedo planetário) – 6% é espalhado pela atmosfera, 20% é refletido pelas nuvens e 4% é refletido pela superfície da Terra. A atmosfera absorve 19% da radiação solar, restando 51% dessa radiação para ser absorvida pela superfície terrestre, ou seja, 51% da radiação solar é transmitida através da atmosfera, conseguindo atingir a superfície.

3.1.4 Irradiância e irradiação

Irradiância Solar é definida como a potência total da energia proveniente do Sol por unidade de área a 1 UA (distância entre o Sol e a Terra conhecida como Unidade Astronômica) (GÓMEZ *et al.*, 2018), ou seja, a quantidade de energia que é recebida em uma determinada superfície. No sistema internacional de unidades, é medida em W/m^2 . A irradiância pode variar dependendo das condições climáticas e dos movimentos da Terra (Figura 6). Em dias ensolarados, o comportamento da irradiância é mínimo no início e no final do dia, devido ao maior ângulo zenital. Durante o horário das 12h, quando o ângulo zenital é menor, é observado o valor máximo de irradiância. Em dias nublados e chuvosos, não é possível observar um comportamento bem definido, pois a presença de nuvens impede que a irradiância atinja a superfície da Terra com a mesma facilidade que em dias ensolarados.

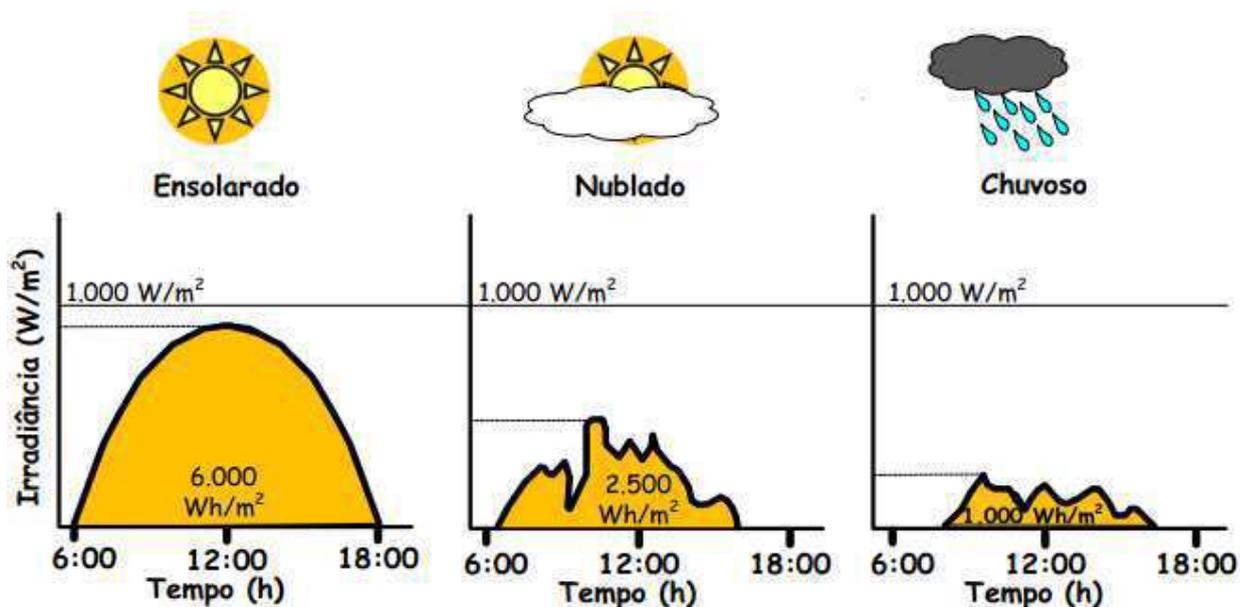


Figura 6. Variação da irradiância e irradiação solar em função das condições atmosféricas e movimentos da Terra. Fonte: Ferreira (2019).

Durante o ano, com a distância do Sol variando entre $1,47 \times 10^8$ km no inverno (21 de junho a 23 de setembro) e $1,52 \times 10^8$ km no verão (22 e dezembro a 20 de março), a irradiância tende a produzir uma variação na radiação de aproximadamente 3,3% (Figura 7), oscilando entre 1.325 W/m^2 e 1.412 W/m^2 , com uma média de $1.368,5$ W/m^2 .

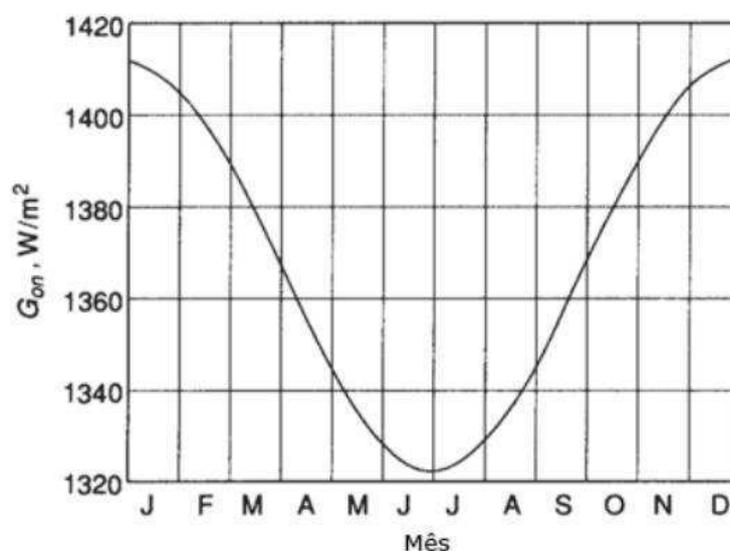


Figura 7. Variação da irradiância solar durante o ano. Fonte: Duffie e Beckman (2013).

A irradiância pode sofrer variações anuais em seu comportamento. Alguns estudos são elaborados com o objetivo de explicar a variação dessa energia, tendo em vista o impacto causado

na atmosfera e no clima da Terra em uma grande escala de tempo. Gómez *et al.* (2018) citam que a explicação mais aceita para justificar essa variação está relacionada aos fenômenos magnéticos que ocorrem na superfície solar. Solanki *et al.* (2013) afirmam que as mudanças na irradiância solar total no período de um ciclo solar de 11 anos estão ligadas à evolução das regiões ativas, redistribuição do campo magnético na superfície do sol ou modificação na temperatura do mesmo.

A integral da irradiância no tempo é definida como irradiação solar (Wh/m^2) ou energia radiante incidente acumulada em um intervalo de tempo. Algumas formas de observar a irradiação são utilizando mapas global horizontal, no plano inclinado na latitude e de forma direta normal.

Devido à sua grande extensão territorial, fatores e sistemas meteorológicos, para cada região do Brasil são observados valores variados na média de irradiação global horizontal (Figura 8). A região Norte possui uma grande atividade convectiva durante todo o ano, e com a elevada formação de nuvens, os valores de irradiação tendem a ser menores em quase toda a região. O Nordeste e uma pequena parte do Centro-Oeste destacam-se por apresentar elevados valores de irradiação, variando de aproximadamente 4750 Wh/m^2 a 6250 Wh/m^2 .

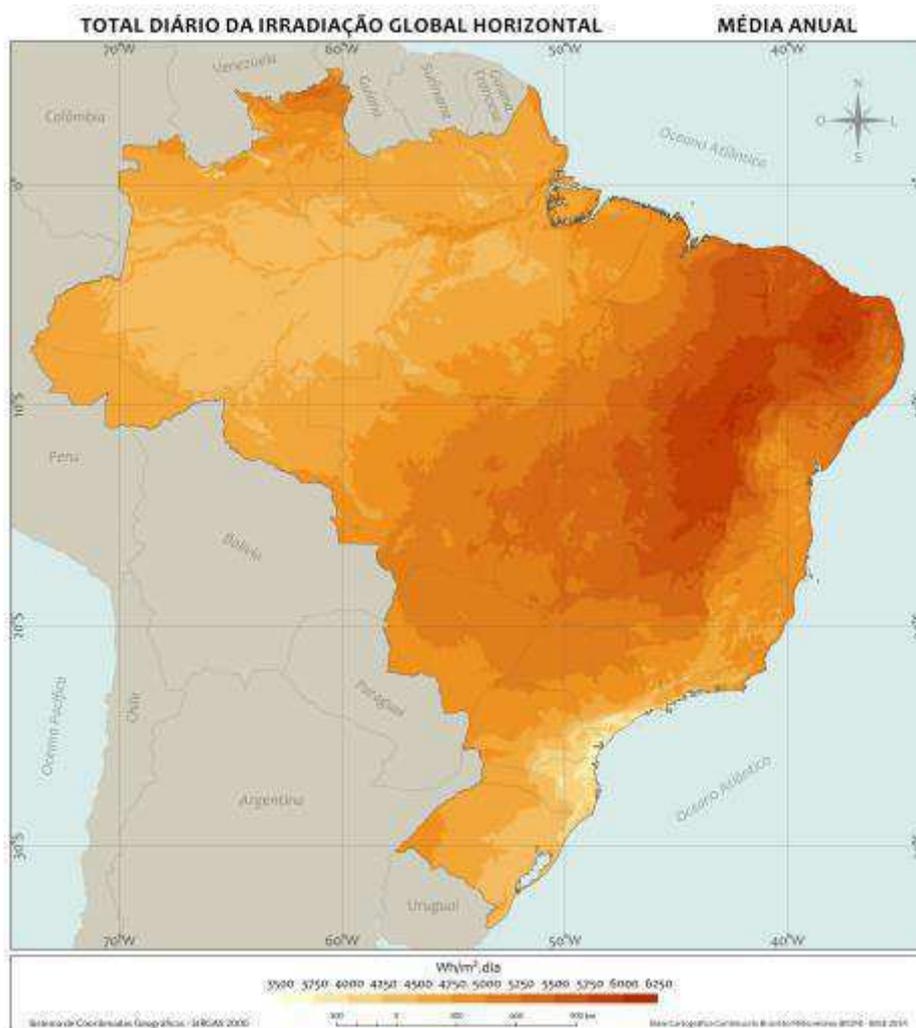


Figura 8. Média anual da irradiação global horizontal no Brasil. Fonte: Martins *et al.* (2017).

3.1.5 Radiação direta, difusa e global

Radiação direta é toda a radiação solar que chega à superfície da Terra e que, durante o seu trajeto, não foi espalhada, refletida ou absorvida por partículas em suspensão na atmosfera. A densidade de fluxo correspondente a essa radiação é determinada como irradiância solar direta, a qual pode ser medida por meio de piranômetros (VIANELLO e ALVES, 1991).

Radiação difusa engloba a radiação proveniente de todas as demais direções que decorrem dos processos de espalhamento pelos gases e particulados presentes na atmosfera (MARTINS *et al.*, 2017). A densidade do seu fluxo é denominada irradiância solar difusa. O fluxo da radiação difusa que chega à superfície da Terra varia com o ângulo zenital do Sol, sendo bastante difícil sua estimativa com grande exatidão, por envolver complexas teorias sobre o espalhamento (VIANELLO e ALVES, 1991).

Radiação Global é a soma da densidade do fluxo de radiação direta e radiação difusa que chegam à superfície.

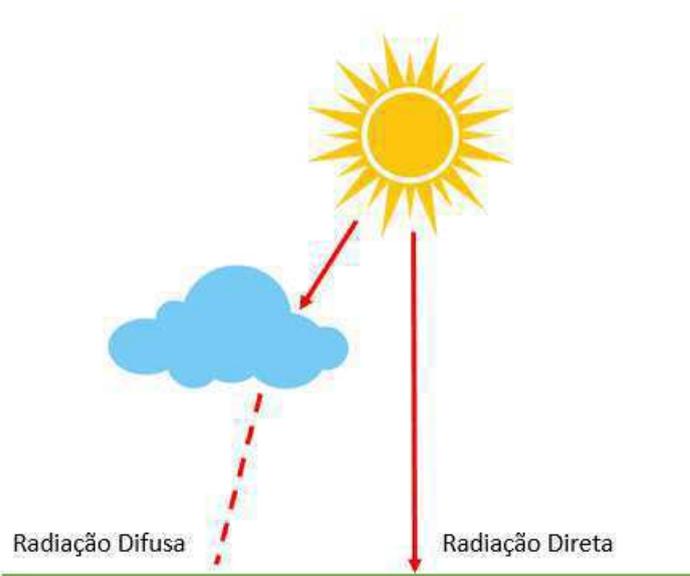


Figura 9. Radiação direta e difusa.

Em dias de céu claro (sem a presença de nuvens), a radiação direta prevalece durante toda a hora. A radiação difusa será observada, por exemplo, em dias com a presença de nuvens; seus raios tendem a chegar à superfície em um ângulo diferente do emitido pelo Sol (Figura 9). Essa diferença permite diferenciar os dois tipos de radiação e medi-los separadamente com diferentes instrumentos.

3.1.6 Geometria solar

Diversos métodos destinados ao cálculo da posição solar são observados na literatura, como, por exemplo, o modelo proposto por Michalsky (1988), que limita essa determinação para o período de 1950-2050, com uma incerteza aproximada de $\pm 0,01\%$. Para uma determinação precisa do posicionamento do Sol, são necessários alguns parâmetros locais, como data, hora, latitude, longitude, elevação, pressão, temperatura, inclinação e azimute. Segundo Oliveira (2018), Duffie e Beckman (2013) citam os principais aspectos geométricos a serem considerados na análise de um sistema de rastreamento solar:

- Ângulo zenital: formado entre os raios do Sol e a linha vertical local, ortogonal ao solo (zênite);
- Altura ou ângulo de elevação solar: ângulo formado entre o vetor Terra-Sol e o plano horizontal;
- Ângulo azimutal do Sol: conhecido como azimute solar, é o ângulo entre a projeção do vetor Terra-Sol no plano horizontal e a direção norte-sul, partindo do Norte (180°), positivo no sentido oeste e negativo no sentido leste;
- Ângulo azimutal da superfície: ângulo entre a projeção da normal à superfície no plano horizontal e a direção norte-sul, partindo do Norte (180°), negativo no sentido leste e positivo no sentido oeste;
- Inclinação do módulo, coletor ou do elemento de reflexão: ângulo entre o sistema a ser analisado e o plano horizontal;
- Ângulo de incidência: ângulo entre o vetor Terra-Sol e a normal da superfície do coletor.

3.2 Energia solar fotovoltaica

3.2.1 Criação e efeito fotovoltaico

O efeito fotovoltaico foi observado pela primeira vez por Becquerel (1839), que verificou, através de duas placas de latão imersas em um eletrólito líquido, a produção de eletricidade quando expostas à luz solar. Adams e Day (1877) construíram a primeira célula solar, que consiste em transformar a radiação solar em energia elétrica por meio do efeito fotovoltaico. Para a possível transformação, o equipamento foi baseado em dois eletrodos de selênio que produziam uma corrente elétrica quando expostos à radiação. No entanto, devido à sua baixa eficiência, o

desenvolvimento da célula solar não chamou tanta atenção, sendo necessária uma melhor compreensão dos materiais semicondutores.

Fritts (1883) desenvolveu a primeira bateria solar construída com folhas de selênio. Apesar de sua eficiência de conversão elétrica ser de apenas 1%, sua elaboração resultou em um grande avanço para a época. Apenas em 1954, Chapin e colaboradores, cientistas da *Bell Laboratory*, publicaram o primeiro artigo no *Journal of Applied Physics*, com os resultados de uma longa pesquisa sobre células solares à base de silício com eficiência de 6%, onde foi registrada uma patente (Figura 10).

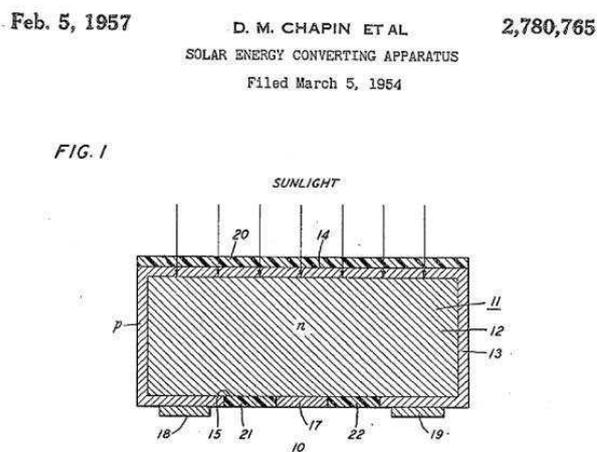


Figura 10. Parte da patente da primeira célula solar, registrada em março de 1954 por D.M. Chapin e colaboradores do *Bell Laboratories*.

3.2.2 Funcionamento

A energia solar fotovoltaica é obtida através da conversão da irradiância solar em eletricidade por intermédio de materiais semicondutores (KEMERICH *et al.*, 2016). Segundo Imhoff (2007), isso ocorre por meio de um dispositivo conhecido como célula fotovoltaica, que atua utilizando o princípio do efeito fotoelétrico ou fotovoltaico. Atualmente, essas células fotovoltaicas são fabricadas, na sua grande maioria, usando o silício e podem ser constituídas de cristais monocristalinos (Figura 11a), policristalinos (Figura 11b) ou de silício amorfo (SOLAR, 2006). As células de monocristalino são mais eficientes do que as de policristalino; no entanto, apresentam maiores custos de produção (EPE, 2012).

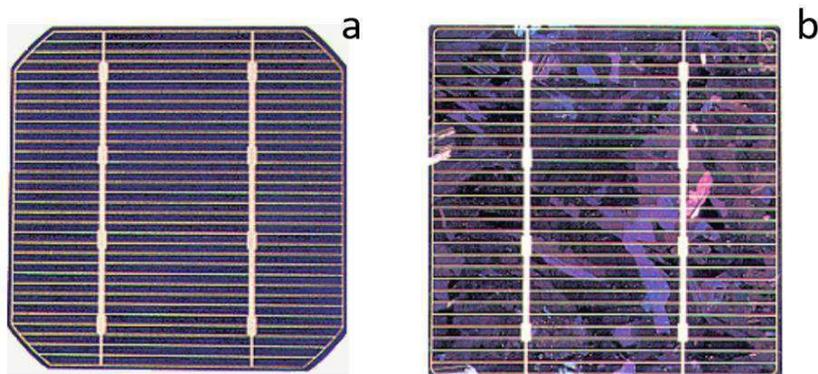


Figura 11. Célula de silício monocristalino (a) e célula de silício policristalino (b). Fonte: Solar (2006).

Uma célula fotovoltaica não armazena energia elétrica, apenas mantém um fluxo de elétrons num circuito elétrico enquanto houver incidência de luz sobre ela (DO NASCIMENTO, 2004). Essa corrente é recolhida por fios ligados à célula e transferida para os demais componentes do sistema. Assim, quanto mais células fotovoltaicas são ligadas em série ou em paralelo, maior a corrente e tensão produzidas (PEREIRA *et al.*, 2006).

As células fotovoltaicas são geralmente agrupadas, formando os módulos fotovoltaicos. O conjunto destes módulos é chamado de gerador fotovoltaico e constitui a primeira parte do sistema, ou seja, é responsável pelo processo de captação da irradiação solar e sua transformação em energia elétrica (PEREIRA e OLIVEIRA, 2011). Quando uma célula fotovoltaica dentro de um módulo, por algum motivo, estiver encoberta, a potência de saída do módulo cairá drasticamente, o que, por estar ligada em série, compromete todo o funcionamento das demais células no módulo (SOLAR, 2006).

A condição padrão para se obter as curvas características dos módulos é definida para irradiância de 1000W/m^2 (irradiância recebida na superfície da Terra em dia claro, ao meio-dia) e temperatura de 25°C na célula (a eficiência da célula é reduzida com o aumento da temperatura) (SOLAR, 2006). Na Figura 12a, observa-se a curva característica IV que relaciona a Corrente (I_{sc}) e a Tensão de Saída (V_{oc}) de um módulo fotovoltaico. O ponto I_{sc} (short circuit ou corrente de curto-circuito), no eixo x, é a máxima corrente elétrica que pode ser fornecida pelo módulo, e o ponto V_{oc} , no eixo y, é a máxima tensão que o módulo pode promover. A Figura 12b é referente à curva típica de Potência (P_m) e tensão. Unindo as duas linhas (Figura 12c), é possível observar o ponto de corrente que o módulo fornece quando opera no seu Ponto Máximo de Potência (I_{mp}) e a tensão que o módulo apresenta quando opera em seu Ponto de Máxima Potência (V_{mp}), resultando no ponto de potência máxima.

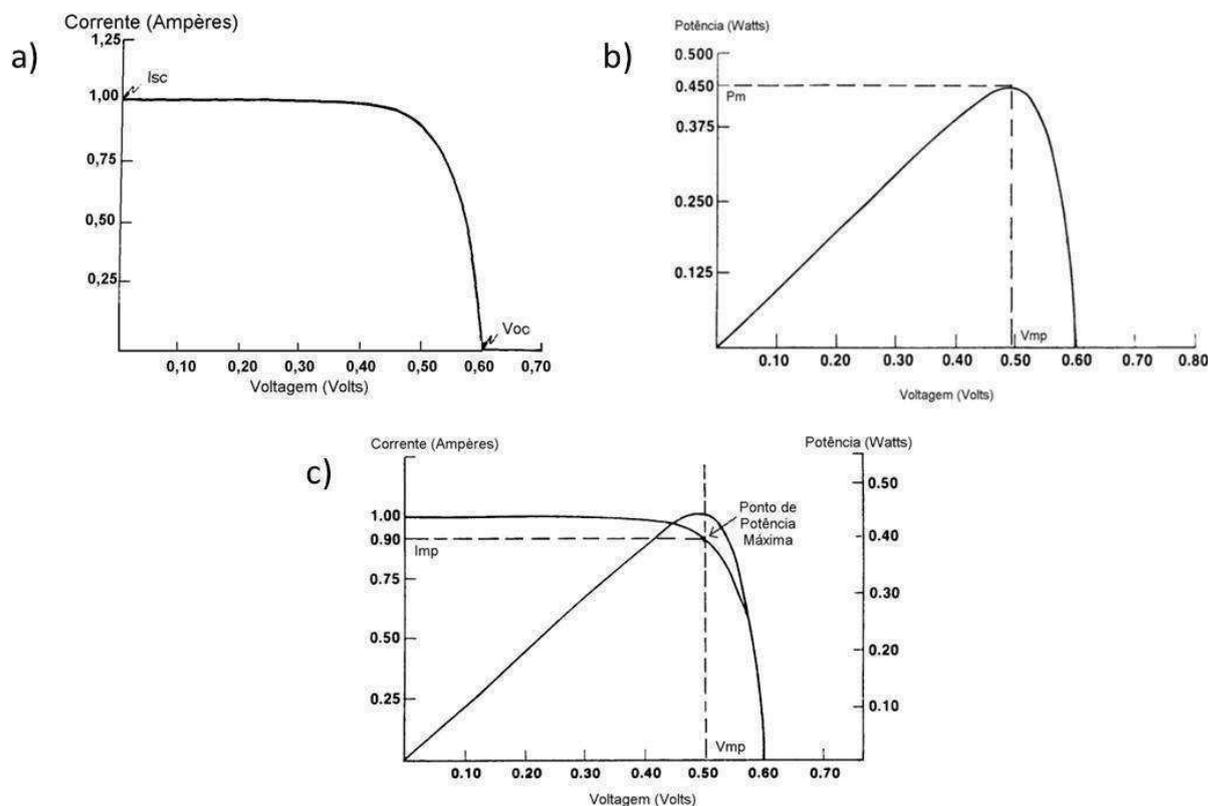


Figura 12. a) Curva característica IV mostrando a corrente e a tensão. b) Curva típica de potência versus tensão. c) Parâmetro de potência máxima. Fonte: adaptado de Solar (2006).

Fatores como as definições das condições padrões, medição da curva corrente-tensão, fonte de iluminação, medida de área e sensor de referência influenciam na determinação da eficiência das células (EBERHARDT, 2005). A corrente gerada nos módulos aumenta linearmente com o aumento da intensidade luminosa; por outro lado, o aumento da temperatura na célula faz com que a eficiência do módulo caia, reduzindo assim os pontos de operação para potência máxima gerada (SOLAR, 2006).

Uma mudança na intensidade da irradiância resulta em uma variação na corrente de saída para qualquer valor de tensão; a corrente varia com a irradiância de forma diretamente proporcional, e a tensão mantém-se praticamente constante (VALENTE, 2011), conforme a Figura 13. O valor da corrente diminui com a diminuição do valor da irradiância, e o mesmo acontece com o ponto de potência máxima, que também diminui com a diminuição da irradiância (XIAO *et al.*, 2006).

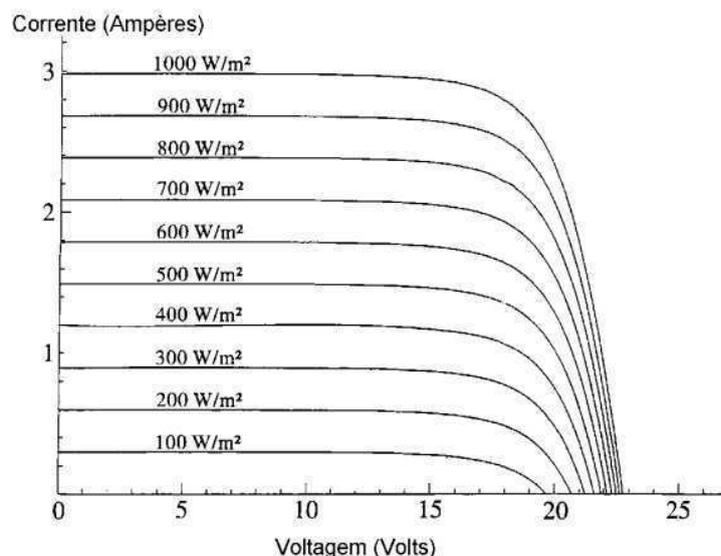


Figura 13. Variação da corrente com a mudança de irradiação. Fonte: Solar (2006).

Uma mudança na temperatura resulta em uma variação na tensão de saída para qualquer valor de corrente, e a tensão varia com a temperatura de forma diretamente proporcional (VALENTE, 2011), como observado na Figura 14. Além disso, Valente (2011) explica que o valor da tensão diminui com o aumento da temperatura, e o Ponto de Potência Máxima (Pmax) também se altera (diminui) com o aumento da temperatura. Desta forma, para garantir uma melhor eficiência do painel, é essencial manter o ponto de funcionamento o mais próximo possível do ponto de potência máxima.

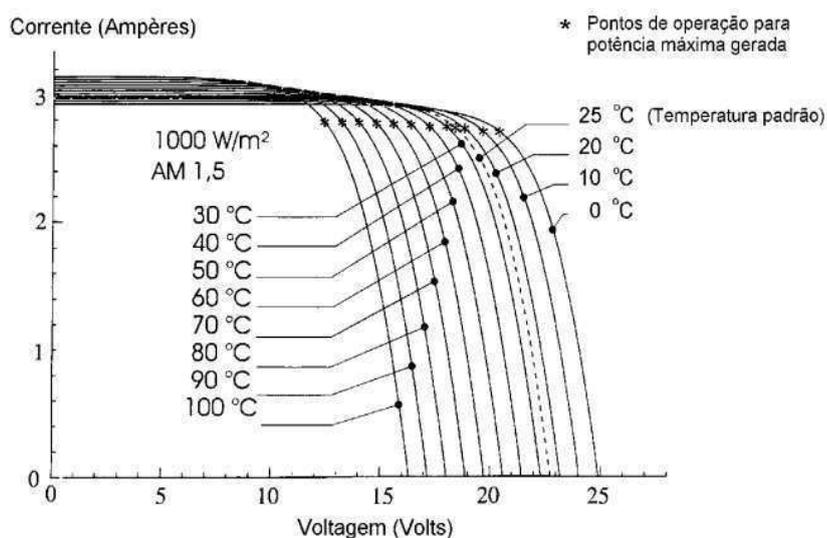


Figura 14. Variação da tensão com a mudança de temperatura. Fonte: Solar (2006).

3.2.3 Sistema fotovoltaico

Sistemas fotovoltaicos podem ser classificados como: isolados (off grid), ligados à rede (on grid) ou híbridos.

Os sistemas fotovoltaicos isolados (Figura 15) são responsáveis por fornecer energia elétrica para uma única unidade de consumo ou em mini-redes, quando a geração é compartilhada entre um pequeno grupo de unidades consumidoras geograficamente próximas umas das outras (GRAFF, 2017). Esse tipo de sistema pode ser dividido entre aqueles com armazenamento ou sem armazenamento. Segundo Solar (2006), para sistemas que necessitam de armazenamento de energia, utiliza-se o controlador de carga com o intuito de evitar danos na bateria por sobrecarga ou descarga profunda, sendo usados em sistemas pequenos onde os aparelhos utilizados são de baixa tensão e Corrente Contínua (CC). Ele ainda explica que, para alimentação de equipamentos de Corrente Alternada (CA), é necessário um inversor.

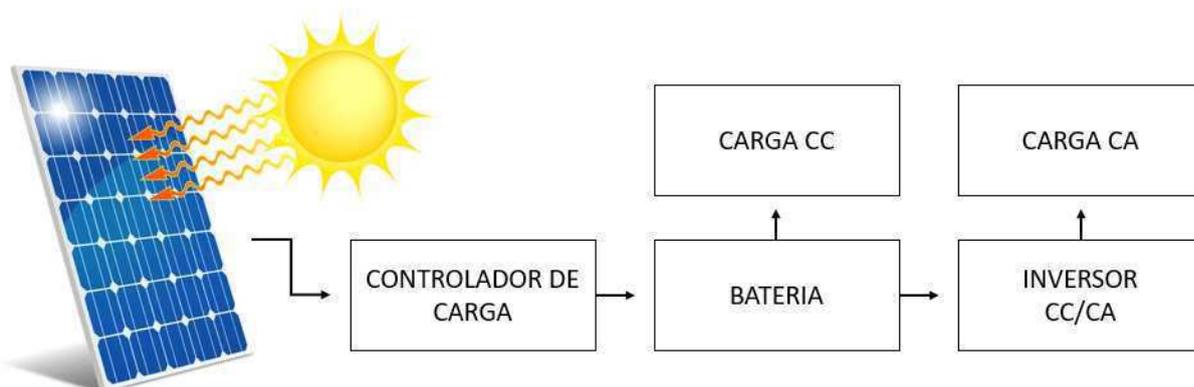


Figura 15. Sistema fotovoltaico isolado.

Os sistemas com armazenamento podem ser utilizados para carregamento de baterias de veículos elétricos, iluminação pública ou em pequenos aparelhos portáteis (VILLALVA e GAZOLI, 2012). Aqueles que não necessitam de armazenamento são geralmente utilizados em bombeamento de água, por apresentar maior viabilidade econômica, já que não requerem instrumentos para o armazenamento (PEREIRA e OLIVEIRA, 2011).

Os sistemas ligados à rede utilizam grandes números de painéis fotovoltaicos e não requerem armazenamento de energia, pois toda a geração é entregue diretamente na rede (SOLAR, 2006). De modo geral, o painel gera energia CC, o inversor a transforma em CA, que pode ser contabilizada através do medidor de energia e é direcionada para a rede de energia elétrica (Figura 16).

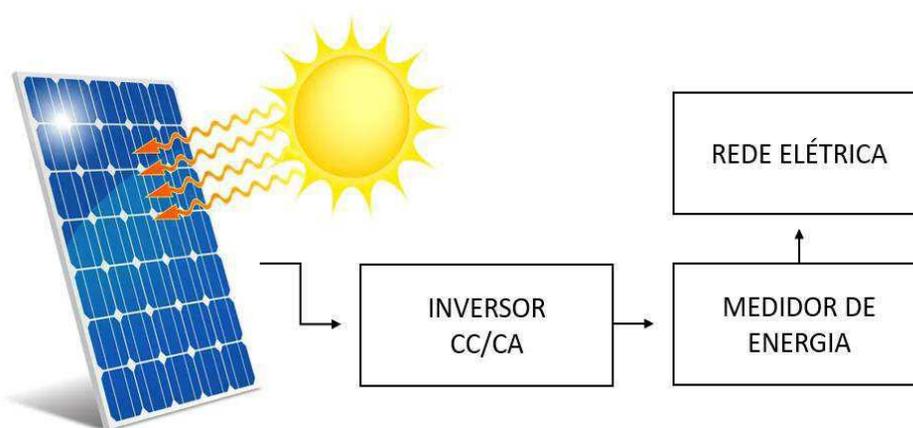


Figura 16. Sistema fotovoltaico ligado à rede.

Em sistemas híbridos, os sistemas fotovoltaicos são utilizados para alimentar as cargas em conjunto com outros sistemas que utilizam fontes de energias renováveis, como, por exemplo, sistemas eólicos, ou sistemas convencionais como o gerador diesel (FREITAS, 2008). Neste caso, torna-se necessário um controle de todas as fontes para que haja máxima eficiência na entrega da energia para o usuário (SOLAR, 2006).

3.2.4 Influência dos fatores climáticos no desempenho das células fotovoltaicas

3.2.4.1 Classificação climática

Köppen (1936) elaborou a classificação climática do Brasil, dividindo-a em 3 tipos: clima tropical, clima semiárido e clima subtropical-úmido (Figura 17). Grande parte do Brasil apresenta clima do tipo tropical e subtropical, com exceção de uma pequena parte no Nordeste, que é classificada como semiárido.

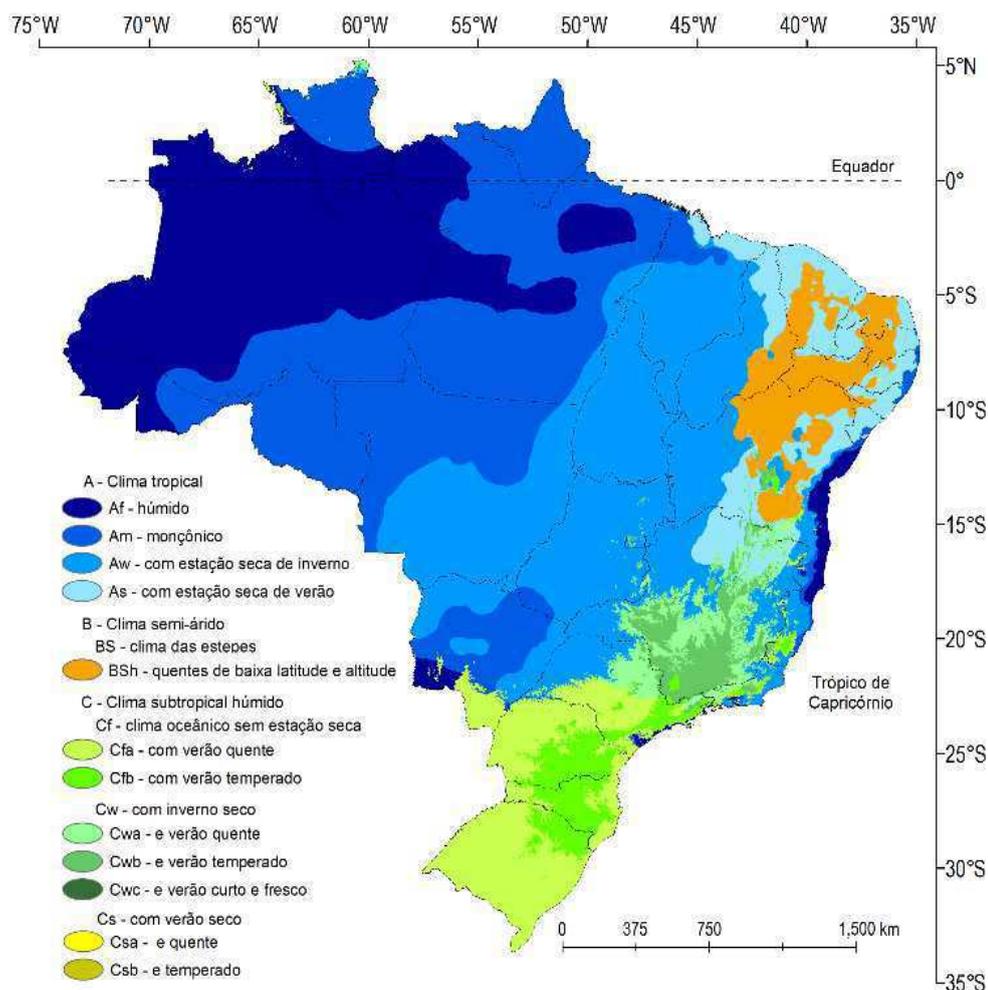


Figura 17. Classificação climática de acordo com os critérios de Köppen (1936).

A classificação climática do Brasil é moldada por diversos fatores, como a extensão territorial, relevo e sistemas sinóticos que atuam em diferentes áreas do país. Esses fatores, por sua vez, influenciam nos elementos meteorológicos, como temperatura, precipitação, umidade e vento.

A Figura 18 representa os valores de precipitação e temperatura das Normais Climatológicas Anuais do Brasil no período de 1961-1990, elaboradas pelo INMET. Para a precipitação acumulada anual, observam-se valores elevados na região da Amazônia e valores menores no semiárido do Nordeste. Na região equatorial, são observados os maiores valores de temperatura média acumulada. Por outro lado, a temperatura diminui à medida que se aproxima da região mais ao sul do Brasil.

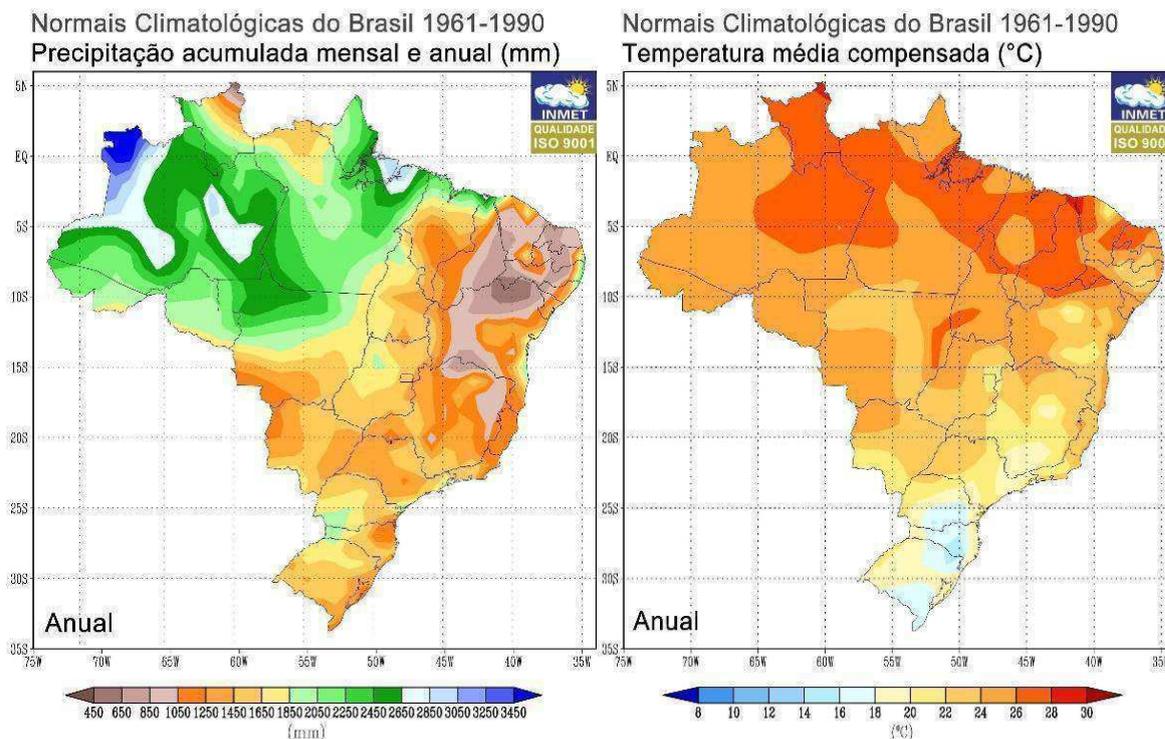


Figura 18. Normal Climatológica Anual do Brasil 1961-1990 de precipitação e temperatura. Fonte: INMET, 2016.

Com a amplitude da extensão territorial e dependendo da estação ou época do ano, diferentes sistemas meteorológicos podem atuar em cada região. Segundo Martins *et al.* (2017), com a mudança da circulação e maior disponibilidade de irradiância solar, o período entre a primavera e verão (Figura 19a) é caracterizado por uma maior quantidade de sistemas meteorológicos atuantes:

- Os Jatos de Baixos Níveis (JBN) passam a trazer a umidade da região Norte para o Sul do país, aumentando a quantidade de sistemas convectivos nesta região neste período;
- A Zona de Convergência do Atlântico Sul (ZCAS) passa a se configurar, aumentando os totais de precipitação na região Sudeste.

Ele ainda cita que, entre o outono e inverno (Figura 19b), tem-se:

- Um avanço maior dos sistemas frontais oriundos da região Sul no território brasileiro;
- A atuação da convergência dos alísios e dos Distúrbios Ondulatórios de Leste (DOL) na costa do Nordeste;
- A presença de sistemas convectivos na região Norte do país;
- Em grande parte do Centro-Oeste e Norte do país, a precipitação está relacionada com eventos de precipitação localizada.

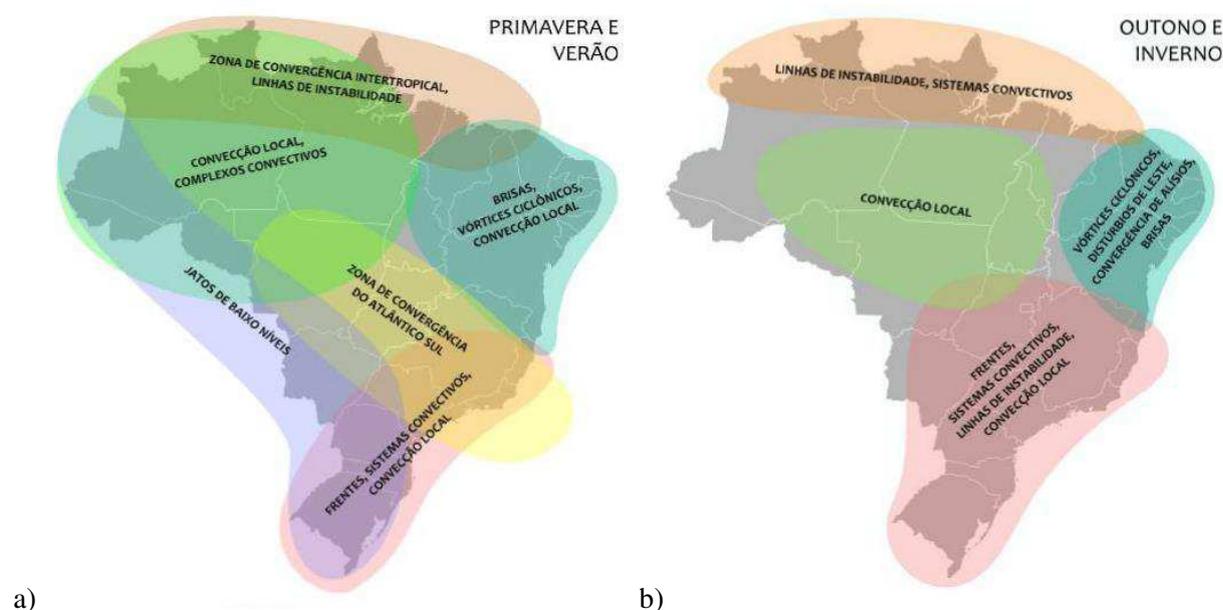


Figura 19. Representação esquemática dos principais sistemas meteorológicos atuantes no território brasileiro nos períodos de primavera/verão (a) e outono/inverno (b). Fonte: Martins *et al.* (2017).

3.2.4.2 Elementos que influenciam os sistemas fotovoltaicos

Quando falamos em energia solar e variáveis meteorológicas, logo é associada a irradiância solar e temperatura. Porém, outros elementos e fatores também influenciam de forma direta na produção de energia solar. Para essa identificação, alguns estudos são elaborados a fim de verificar e explicar a influência de parâmetros meteorológicos na geração de energia solar.

Sangrody *et al.* (2017), investigando a correlação entre a energia solar gerada pelos painéis fotovoltaicos no telhado dos edifícios de Engenharia e Ciência da Universidade de Binghamton e cinco variáveis meteorológicas, observaram que a temperatura do ponto de orvalho e a velocidade do vento têm correlação muito baixa com a energia. Por outro lado, a umidade relativa possui maior correlação com a energia, com um valor de -0,61, mostrando que quanto maior o valor de energia menor será a umidade relativa. Além disso, a temperatura e cobertura de nuvens apresentam boa correlação com energia, sendo, respectivamente, 0,44 e -0,42.

Francisco *et al.* (2019), analisando dados de uma estação meteorológica e dos painéis fotovoltaicos localizados no Centro Universitário UniFacens, em Sorocaba-SP, verificaram que entre as variáveis meteorológicas dependentes (temperatura, velocidade do vento e umidade) e a variável independente (energia) existe uma correlação significativa, com razão entre radiação e energia de 0,82 e entre temperatura e energia de 0,60. Ainda em seus resultados, observaram que a umidade e a energia apresentaram correlação de -0,49, logo, quanto maior a umidade, menor a

energia gerada. Já a velocidade do vento e a energia não apresentaram correlação significativa. Concluindo que quanto maior a radiação, maior a energia gerada, e altos valores de temperatura podem fazer com que os módulos percam eficiência, já o aumento da umidade pode ser indicativo de dia chuvoso ou cobertura de nuvem significativa.

Silva (2019) verificou alguns elementos climáticos visando entender a influência de cada um deles no desempenho do sistema fotovoltaico localizado sobre o telhado do Bloco B da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, e concluiu que o aumento da irradiação solar no plano do gerador melhora o desempenho do sistema. Além disso, o incremento na temperatura ambiente reduz a eficiência do módulo, a velocidade do vento reduz a temperatura de trabalho dos módulos, melhorando a sua eficiência. O efeito da umidade relativa do ar pode diminuir a eficiência fotovoltaica, pois provoca atenuação na irradiação solar, e a precipitação pluviométrica influencia diretamente na geração, pois reduz a irradiação incidente; no entanto, promove a limpeza dos módulos, melhorando sua eficiência em dias ensolarados.

3.2.5 Energia solar fotovoltaica no Nordeste do Brasil

No Nordeste, a energia solar vem ganhando espaço entre as fontes já existentes de energia elétrica, evoluindo de 0,02% em 2015 para 3,83% em 2020 (Figura 20). Se comparado às outras regiões brasileiras, o Nordeste ocupa lugar de notoriedade no cenário da geração de energia limpa, devido ao potencial de produção por meio da energia eólica e solar, sendo ainda responsável pelo maior potencial para geração de energia oriunda da irradiação solar no país (ARAÚJO, 2019).

A região possui os melhores parâmetros, apresentando o maior nível de irradiação no plano inclinado (média anual de 5,52 kWh/m².dia) e menor variabilidade interanual durante o ano (PEREIRA *et al.*, 2017). Além disso, a evolução dos leilões e atualizações de leis e normas contribuem para a expansão da energia solar, tanto na geração distribuída como na centralizada.

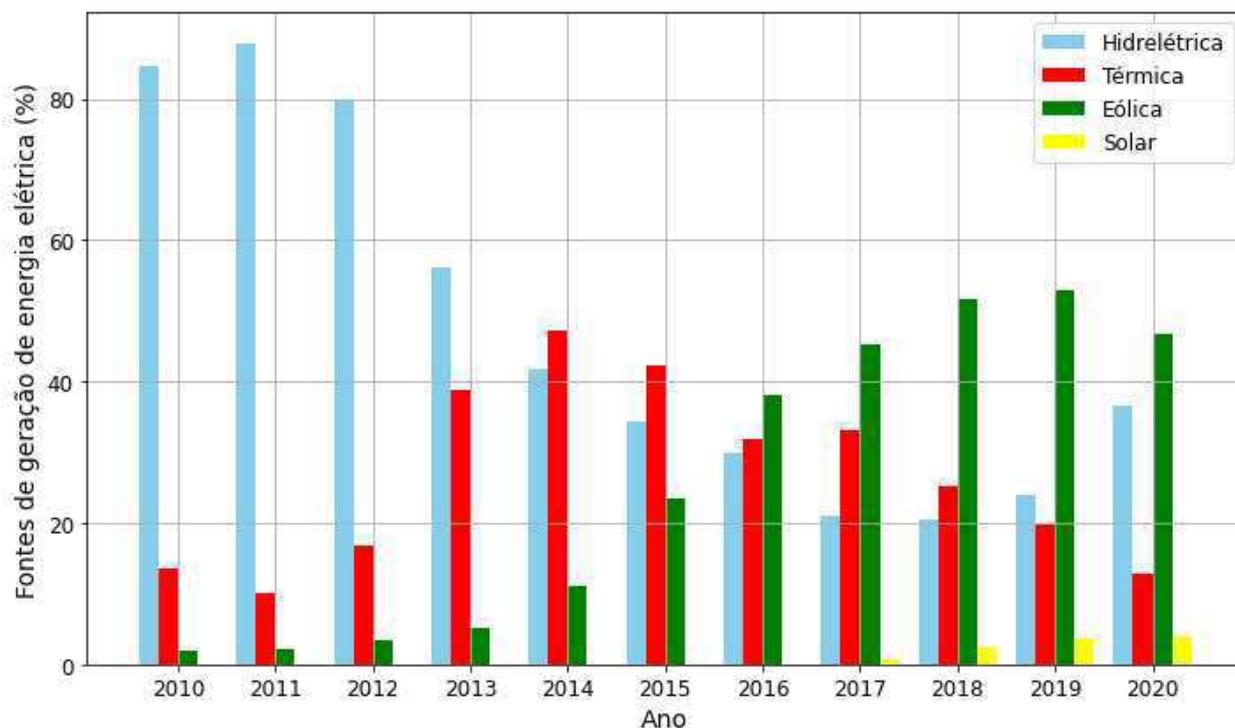


Figura 20. Evolução da participação das fontes na geração de energia elétrica do Subsystema Nordeste - 2010-2020 (%). Fonte: Bezerra (2021). Elaboração: Autor (2024).

A busca pela regularização de forma mais sólida para a geração distribuída teve início com a Nota Técnica nº 43 de 2010 da ANEEL, que propõe a abertura de uma Consulta Pública para o recebimento de contribuições visando a redução das barreiras para a instalação de geração distribuída de pequeno porte, a partir de fontes renováveis, conectada à rede de distribuição (BORSCHIVER, 2018). Em 17 de abril de 2012 entrou em vigor a Resolução Normativa ANEEL nº 482 de 2012, que define as condições para o acesso de sistemas de microgeração e minigeração distribuída de energia à rede de distribuição de energia elétrica, onde, a partir deste marco regulatório, o consumidor brasileiro passou a poder gerar sua própria energia a partir de fontes renováveis, fornecendo o excedente desta geração para a sua rede de distribuição local (BORSCHIVER, 2018).

A geração distribuída vem ganhando maiores proporções, pois com os custos para a instalação de sistemas em constante queda, por diversos motivos (aumento da capacidade produtiva de módulos, incentivos governamentais, além do aumento da demanda), produzir a sua própria energia vem sendo atrativo para muitos brasileiros que pagam altas tarifas de energia elétrica (SOUZA, 2020). Pensando nisso, e de acordo com os dados de geração distribuída divulgados pela ANEEL/ABSOLAR (2023) (Figura 21), é possível observar o ranking estadual do potencial de energia solar instalado, onde temos entre os quinze primeiros os estados da Bahia, Ceará, Pernambuco e Rio Grande do Norte representando a região Nordeste e ocupando,

respectivamente, as 8ª, 11ª, 12ª e 15ª posições.



Figura 21. Ranking estadual da geração de energia distribuída. Fonte: ANEEL/ABSOLAR, 2023.

Outro importante fator que contribuiu para a expansão da energia solar fotovoltaica no Brasil são os leilões promovidos pelo Governo Federal. A fonte solar teve sua primeira participação a partir do 6º Leilão de Energia Reserva (LER), que ocorreu em outubro de 2014, com preço consideravelmente elevado de 356,2 R\$/MWh. Com a aprovação de leis e normas, os preços do MWh despencaram. Após três anos da sua primeira participação, no 25º Leilão de Energia Nova (LEN), o preço chegou a 196,7 R\$/MWh, chamando atenção também o 29º LEN, com o preço de 85,5 R\$/MWh, que aconteceu em junho de 2019, como pode ser observado na Figura 22. A expressiva diminuição no valor do MWh oriundo da fonte solar deveu-se, sobretudo, à queda no preço do módulo nos últimos anos, principal item de custo dos sistemas fotovoltaicos (BEZERRA, 2021).

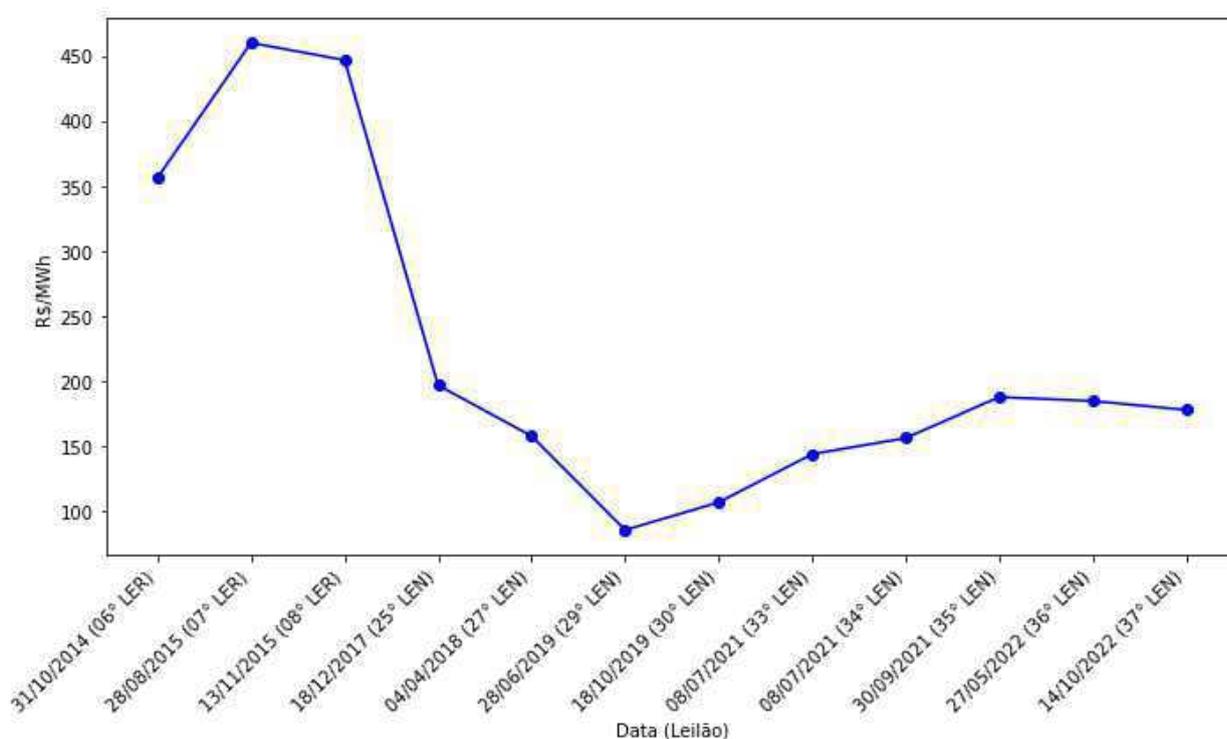


Figura 22. Avanço dos preços de energia solar nos leilões promovidos pelo Governo Federal. Fonte: CCEE (2023). Elaboração: Autor (2023).

A partir dos leilões foi possível começar a utilizar do potencial das regiões, com isso os estados que tiveram mais projetos contemplados são aqueles em que hoje têm maiores potências instaladas nas gerações de energia fotovoltaica (SOUZA, 2020). De acordo com os dados da ANEEL/ABSOLAR (2023), para a geração centralizada, temos uma presença marcante dos estados do Nordeste. A Bahia, Piauí, Ceará, Rio Grande do Norte, Pernambuco e Paraíba estão entre os 10 primeiros estados do Brasil com maior potencial de energia instalado, ocupando respectivamente a 2ª, 3ª, 4ª, 5ª, 7ª e 8ª posição (Figura 23).



Figura 23. Ranking estadual da geração de energia centralizada. Fonte: ANEEL/ABSOLAR, 2023.

Segundo estudos da Empresa de Pesquisa Energética (MME; EPE, 2017), a geração solar fotovoltaica centralizada, cujos projetos são oriundos principalmente de leilões promovidos pelo Governo Federal, crescerá, em média, expressivos 84,6% a.a. de 2016 até 2026, alcançando 9,7 GW, montante que corresponderá a 4,7% da capacidade instalada de geração do Brasil naquele ano (BEZERRA, 2018). Cabe ressaltar, contudo, que os preços dos leilões podem não refletir a realidade dos custos de geração, já que as empresas, em geral, reduzem preços com o intuito de assegurar algumas vantagens, prevendo negociar a maior parte da energia a ser gerada em seus projetos no Ambiente de Contratação Livre, com valores mais elevados (BEZERRA, 2021).

3.3 Deep Learning

Deep Learning é uma sub-área do Machine Learning, concentra-se na construção de redes neurais profundas que são capazes de tomar decisões precisas com base em dados (KELLEHER, 2019). Seus algoritmos que processam as informações são análogos ao processamento realizado

pelo cérebro humano. Tal como um neurônio biológicos são compostos por dendritos que recebem sinais, um corpo celular e núcleo para processá-los e axônio para transmitir-los a outros neurônios, o neurônio artificial dispõe de várias entradas, uma fase de processamento e uma saída que pode de conectar a vários outros neurônios artificiais, repetindo o processo (Figura 24). Conforme descrito por Conterato (2022), o funcionamento de uma rede neural envolve o cálculo do somatório das entradas multiplicadas por seus pesos correspondentes, seguido pela adição de um viés e pela aplicação de funções de ativação, gerando uma saída que pode ser direcionada para outros "n" neurônios, de modo que, nessa saída ocorre a comparação entre o valor previsto e o valor real. Conterato (2022) ainda afirma que, quando há discrepância entre o valor previsto e o real, os pesos associados a cada entrada juntamente com o viés, são ajustados de como a fazer com que os valores se aproximem. Sendo assim, as redes neurais se destacam por suas distintas arquiteturas e pela maneira como os pesos das conexões são adaptados ao longo do processo de aprendizado (FERNEDA, 2006).

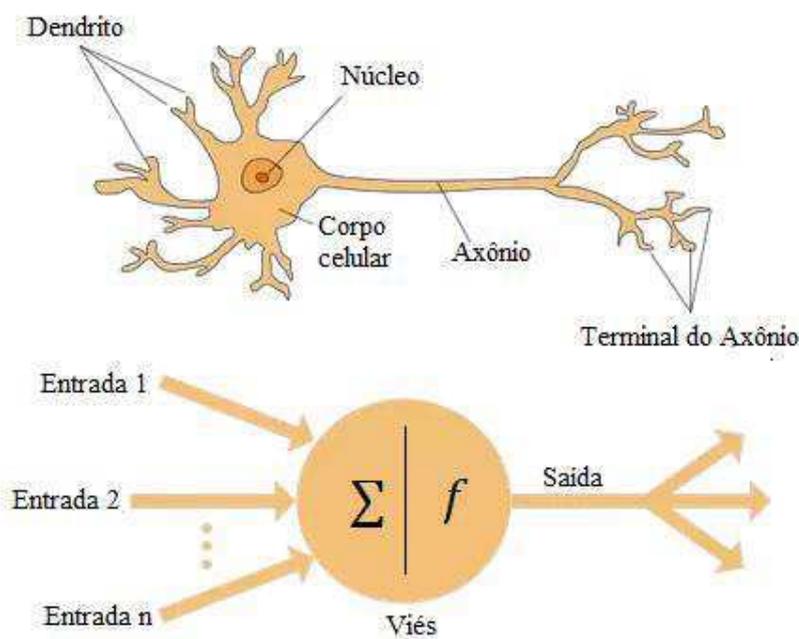


Figura 24. Neurônio biológico e neurônio artificial. Fonte: Adaptado de Nagyfi (2018).

A estrutura do Deep Learning é construída através de camadas. A utilização de múltiplas camadas pode levar a um aprendizado otimizado e consistente, mas também pode resultar em subutilizar a rede neural (CONTERATO, 2022). A organização de sua estrutura compreende uma

divisão em que a primeira camada é denominada de entrada, a última é a camada de saída, e todas as camadas intermediárias são conhecidas como camadas ocultas (Figura 25).

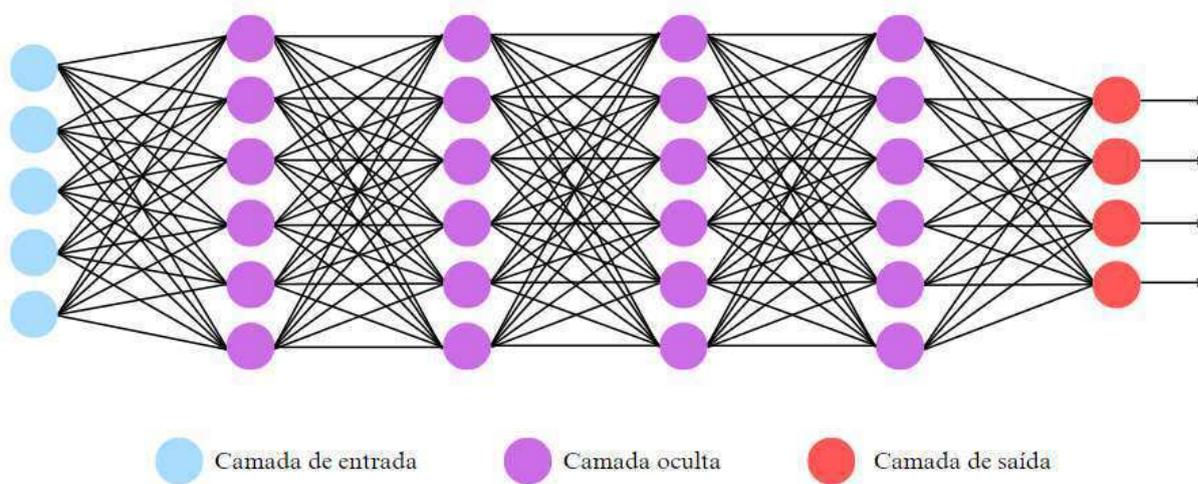


Figura 25. Exemplificação de uma rede neural profunda.

Biologicamente, a transferência de informações de um neurônio para outro ocorre nas áreas de conexões conhecidas como sinapses, frequentemente localizadas nas extremidades do anônimo de uma célula em relação aos dendritos de outra célula (LIMA, 2005). O mesmo ocorre em uma rede artificial durante o processo de transferência de informações. Após concluir o treinamento dos dados com “n” informações, a rede neural realiza a retropropagação da discrepância entre o valor observado e o valor previsto na última camada, resultando na atualização de todos os neurônios, camada por camada, processo conhecido como *feedforward backpropagation* (CONTERATO, 2022).

3.3.1 Tipos de aprendizado

3.3.1.1 Aprendizado supervisionado

O aprendizado de máquina supervisionado é o treinamento de um modelo que realiza previsões através de funções baseadas em dados reais de entrada e saída. Mahesh (2020) explica que o conjunto de dados de entrada é dividido entre dados de treinamento e teste, os algoritmos aprendem algum tipo de padrão do conjunto de dados de treinamento e os aplicam ao conjunto de dados de teste para a previsão ou classificação da variável de saída. Este tipo de aprendizado pode ser dividido em:

- Classificação: A distribuição de saída é tomada diretamente como discreta, descartando qualquer significado referente à ordenação dos diferentes valores possíveis. Mesmo com algumas limitações, tem sido aplicada com sucesso em redes neurais profundas para a contagem de objetos em imagens. Explica Stoter *et al.*, (2018).
- Regressão: Os modelos de regressão mapeiam o espaço de entrada em um domínio de valor real (NASTESKI, 2017), podendo ser utilizado, como por exemplo, para previsão de temperatura.

3.3.1.2 Aprendizado não supervisionado

No aprendizado não supervisionado utiliza apenas dados de entradas, dados de saída não são conhecidos. Os algoritmos são deixados por conta própria para descobrir e apresentar a estrutura interessante nos dados (MAHESH, 2018), para então prever os dados de saída. Como nesse tipo de aprendizado o algoritmo trabalha sozinho, dependendo do tamanho do conjunto de dados, ele pode se tornar um pouco mais demorado (RAVI, REBALA, CHURIWALA, 2019).

Quando novos dados são introduzidos, ele usa os recursos aprendidos anteriormente para reconhecer a classe dos dados e são usados principalmente para *clustering* e redução de recursos (MAHESH, 2018). Através das técnicas de *clustering* pode-se explorar dados e identificar os padrões, como observado na Figura 26.

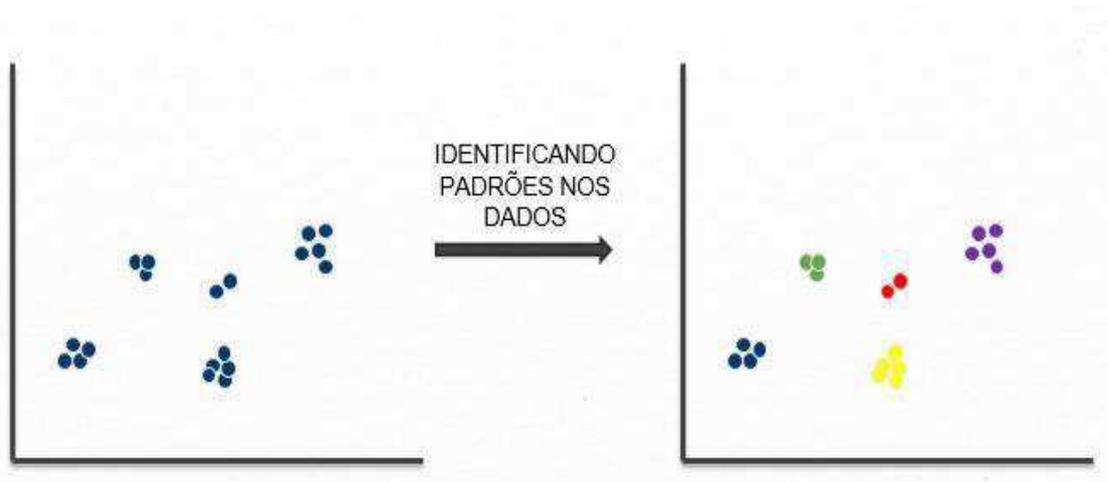


Figura 26. Exemplificação de clustering identificando padrões nos dados.

3.3.1.3 Aprendizado reforçado

O aprendizado reforçado toma decisões por conta própria com base em tentativas e erros de sua experiência, sendo recompensado quando o resultado é positivo. Essa técnica preocupa-se com a forma como os agentes de software devem realizar ações em um ambiente para maximizar alguma noção de recompensa cumulativa (MAHESH, 2018). Toda ação tem algum impacto no ambiente, e este fornece feedback que orienta o algoritmo de aprendizado (AYODELE, 2010). Um exemplo é quando o algoritmo recomenda um produto relacionado ao que o consumidor costuma pesquisar; caso o consumidor adquira o produto, o algoritmo entende que a sugestão foi eficiente (Figura 27).

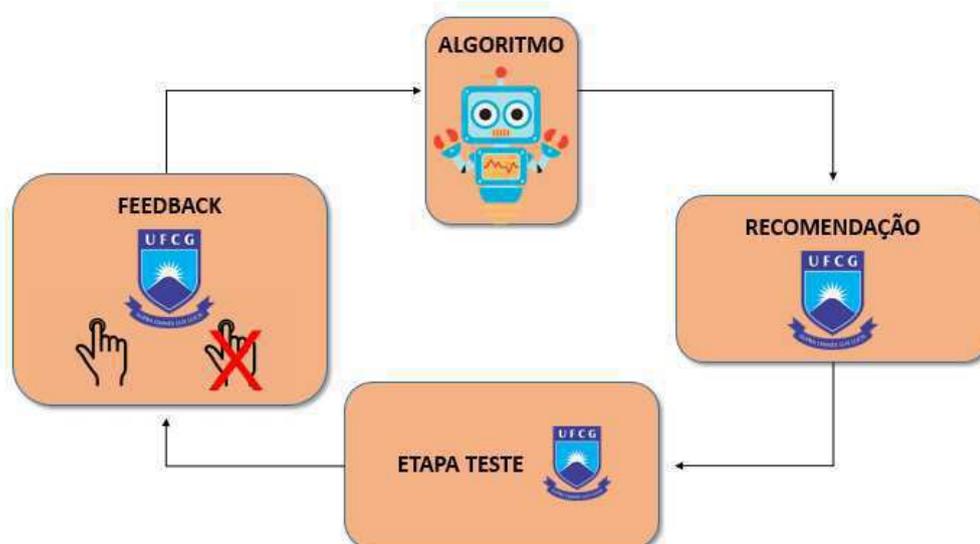


Figura 27. Funcionamento do aprendizado reforçado.

3.3.2 Aplicação de Deep Learning em estudos de geração de energia solar

Com o desenvolvimento da tecnologia e o avanço da necessidade de produção e utilização de energia de forma sustentável, métodos de Deep Learning são elaborados com o intuito de mitigar problemáticas na área de análise e previsão desses tipos de fontes. A previsão sempre foi um método crucial e econômico para integrar recursos variáveis de energia renovável, como eólica e solar, em sistemas de energia (MOHANTY *et al.*, 2017). A complexidade dessa variedade de energia depende da grande quantidade de dados e parâmetros, que devem ser investigados minuciosamente (ALBUALIGAR *et al.*, 2022).

Bastos (2020) conduziu um estudo com relação à aplicação de redes Memória de Longo Prazo (*Long Short-Term Memory* - LSTM) para previsão de dados de geração (potência) em

paineis fotovoltaicos empregando dados meteorológicos. Os dados em questão foram coletados por meio de uma estação solarimétrica de baixo custo situada nas proximidades de uma usina de produção de energia. As informações obtidas pela estação incluem: radiação solar, temperatura dos painéis, temperatura ambiente, umidade, velocidade do vento, quantidade de chuva, tensão e corrente. Bastos detalha que essas informações serviram como entrada para alimentar a rede neural, cuja função principal consistia em prever um vetor representando a potência a ser gerada pelos painéis solares da usina nos próximos segundos. Seus resultados destacaram o desempenho notável da rede *Long Short-Term Memory*, evidenciando valores de estimação com erros médios absolutos significativamente baixos.

Unlu, Peña, Wang (2022) elaboraram um estudo abordando as arquiteturas de *Deep Learning* no contexto da previsão de energia solar fotovoltaica. A pesquisa se concentrou no método de combinação de Rede neural Convolutiva (*Convolutional Neural Network - CNN*) e *Long Short-Term Memory*, para investigar a previsão de energia solar em um telhado fotovoltaico residencial de 4,9 kW, levando em consideração as condições climáticas para o estado de Connecticut. No decorrer do estudo, os pesquisadores também incorporaram técnicas de previsão solar multivariável. Alguns métodos de *Deep Learning*, como *Convolutional Neural Network*, *Long Short-Term Memory* e *Gated Recurrent Unit*, e o *Root Mean Squared Error* e *Mean Absolute Error* foram minuciosamente avaliados, e métricas de desempenho, como o *Root Mean Squared Error* e *Mean Absolute Error*, foram calculados para comparar o desempenho desses métodos em relação à previsão multivariável da energia solar. Os resultados da pesquisa revelaram que a combinação do modelo *Convolutional Neural Network + Long Short-Term Memory* superou os outros modelos nos conjuntos de dados de validação quando o tamanho do passo foi igual a seis horas. No entanto, com o tamanho de passos de doze e vinte e quatro horas, o modelo *Gated Recurrent Unit* apresentou um desempenho superior nos conjuntos de dados de validação. Além disso, notou-se que à medida que o tamanho do passo aumentava de seis para vinte e quatro horas, todos os modelos conseguiram reduzir seus erros *Root Mean Squared Error* e *Mean Absolute Error*. No que diz respeito à obtenção de resultados e à eficiência do modelo em termos de tempo de computação e recursos computacionais, observou-se que o modelo *Convolutional Neural Network* apresentou resultados rápidos, embora com uma precisão inferior em comparação com outros modelos. Em contrapartida, o modelo *Convolutional Neural Network + Long Short-Term Memory*, apesar de não ser eficiente em termos de tempo de computação, demonstrou um desempenho superior, fornecendo os melhores resultados nos conjuntos de dados de treinamento.

4. MATERIAL E MÉTODOS

4.1 Área de Estudo

O NEB localiza-se aproximadamente entre 1° e 18°30' de latitude Sul e 34°20' e 48°30' de longitude Oeste, com uma área de 1,6 milhões de km², sendo formado por 9 unidades da federação (Figura 28): Alagoas, Bahia, Ceará, Maranhão, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe.

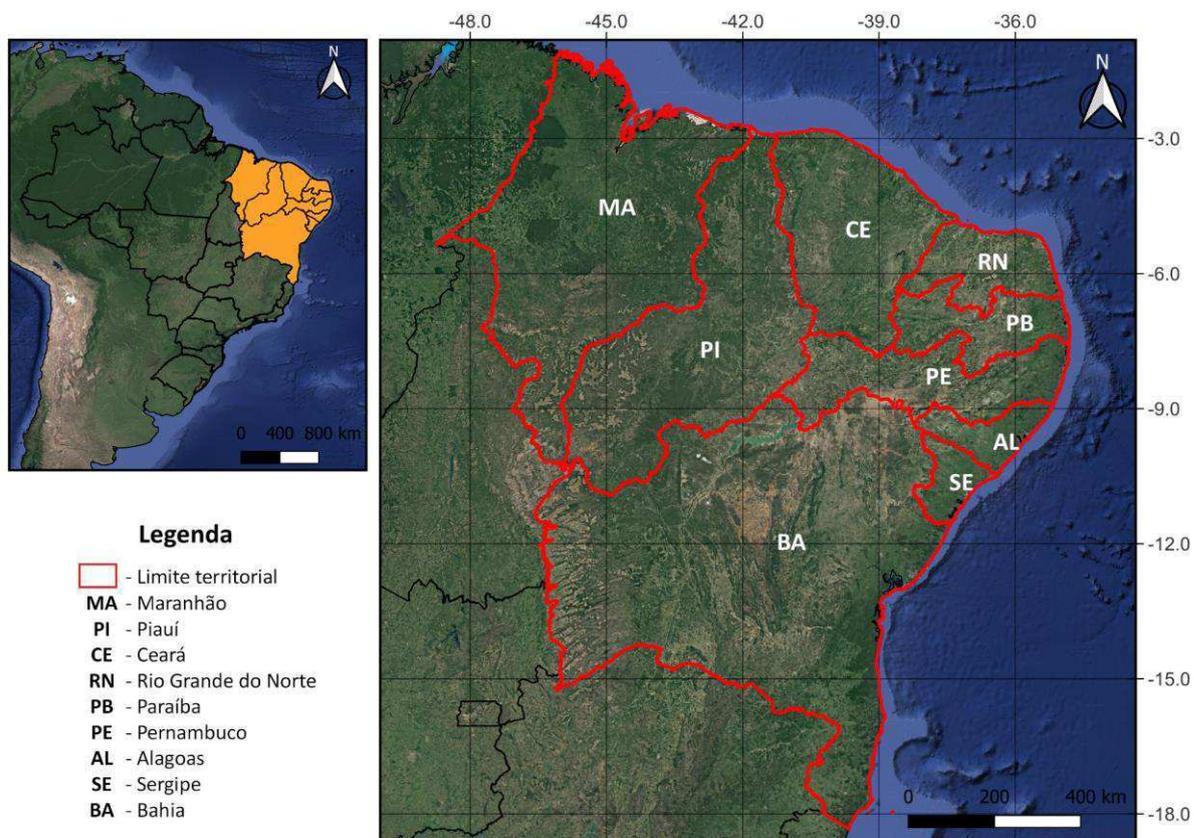


Figura 28. Localização do Nordeste no Brasil e área de estudo.

O clima na região é caracterizado pelas irregularidades das chuvas e pelas temperaturas relativamente elevadas. Isso ocorre pelo fato de estar localizado na região tropical, área definida por apresentar uma atmosfera úmida com grande e intensa atividade convectiva, devido à disponibilidade de energia solar durante todo o ano (BEZERRA e CAVALCANTI, 2008). Em função das diferentes características físicas apresentadas pelo clima da região, esta é afetada por períodos de secas severas (SANTIAGO, MOTA, NÓBREGA, 2010) e por eventos extremos de chuvas (OLIVEIRA, SANTOS E SILVA, LIMA, 2017; RODRIGUES *et al.*, 2020).

As variáveis de tempo e clima da região são modeladas por diversos sistemas atmosféricos de escalas espaciais, variando desde a micro à grande escala, como Vórtices Ciclônicos de Altos Níveis (VCAN) (SILVA, 2005; DE SOUZA FERREIRA, REBOITA, ROCHA, 2020; DE MORAIS, GAN, YOSHIDA, 2021), ZCIT (UVO, 1989; CARDOSO, 2019), ZCAS (DA SILVA e BRITO, 2008; BRAGA e AMBRIZZI, 2022), Sistemas Convectivos de Mesoescala (SCM) (SOUZA, ALVES, REPELLI, 1998; LYRA *et al.*, 2018; LYRA, FEDOROVA, LEVIT, 2022), DOL (GOMES *et al.*, 2015; GOMES *et al.*, 2019; SILVA *et al.*, 2021), efeitos de brisa marítima e terrestre (BARRETO, 2001; ANJOS e LOPES, 2019).

O relevo nordestino é caracterizado pela presença de extensos planaltos e algumas áreas altas e planas que formam as chapadas. O Planalto da Borborema ocupa a posição a leste do estado de Pernambuco e as áreas mais elevadas atingem entre 800 a 1000 metros de altitude (ROSS, 1985). A elevação desse planalto exerce forte interferência no regime pluviométrico na região, e conseqüentemente, em seus extremos (CORREIA FILHO, LUCIO, SPYRIDES, 2016). Na Bahia, localiza-se o Pico do Barbado com aproximadamente 2033 metros e é parte integrante da Chapada Diamantina. Outra importante chapada existente no Nordeste é a do Araripe, localizada entre os estados do Ceará, Piauí, Pernambuco e Paraíba. Essa chapada tem altitude variando de 700 m, no setor oeste, a 1.000 m, no setor leste (DNPM, 1996).

De acordo com dados do Sistema de Informações Geográficas do Setor de Energia (SIGEL), órgão que faz parte da ANEEL, atualmente o nordeste possui 3540 projetos de parques fotovoltaicos, porém, apenas 123 encontram-se em operação.

4.2 Dados

4.2.1 Observados

Para a realização da pesquisa, utilizou-se dados horários de Irradiação Global Horizontal, comumente chamada de Radiação Global, das estações automáticas situadas na área da região do NEB, no período de 2009 a 2019, obtidos por meio das estações do INMET (<https://bdmep.inmet.gov.br/>) (Tabela 1). O período de estudo foi escolhido devido à maior robustez na quantidade de dados para todas as estações. Inicialmente, foram consideradas 113 estações. No entanto, mesmo com essa quantidade, a série temporal passou por uma análise mais detalhada, verificando a porcentagem de dados faltantes com um limiar de 10%. Após a filtragem, restaram 87 estações, sendo 5 no estado de Alagoas, 30 na Bahia, 7 no Ceará, 9 no Maranhão, 5

na Paraíba, 11 em Pernambuco, 11 no Piauí, 4 no Rio Grande do Norte e 5 em Sergipe. A Figura 29 mostra os pontos de localização de cada estação automática utilizada no estudo.

Tabela 1. Variável obtida através das estações do INMET.

Variável	Fonte	Sigla	Unidade de medida
Irradiação Global Horizontal	INMET	Rg	Wh/m ²

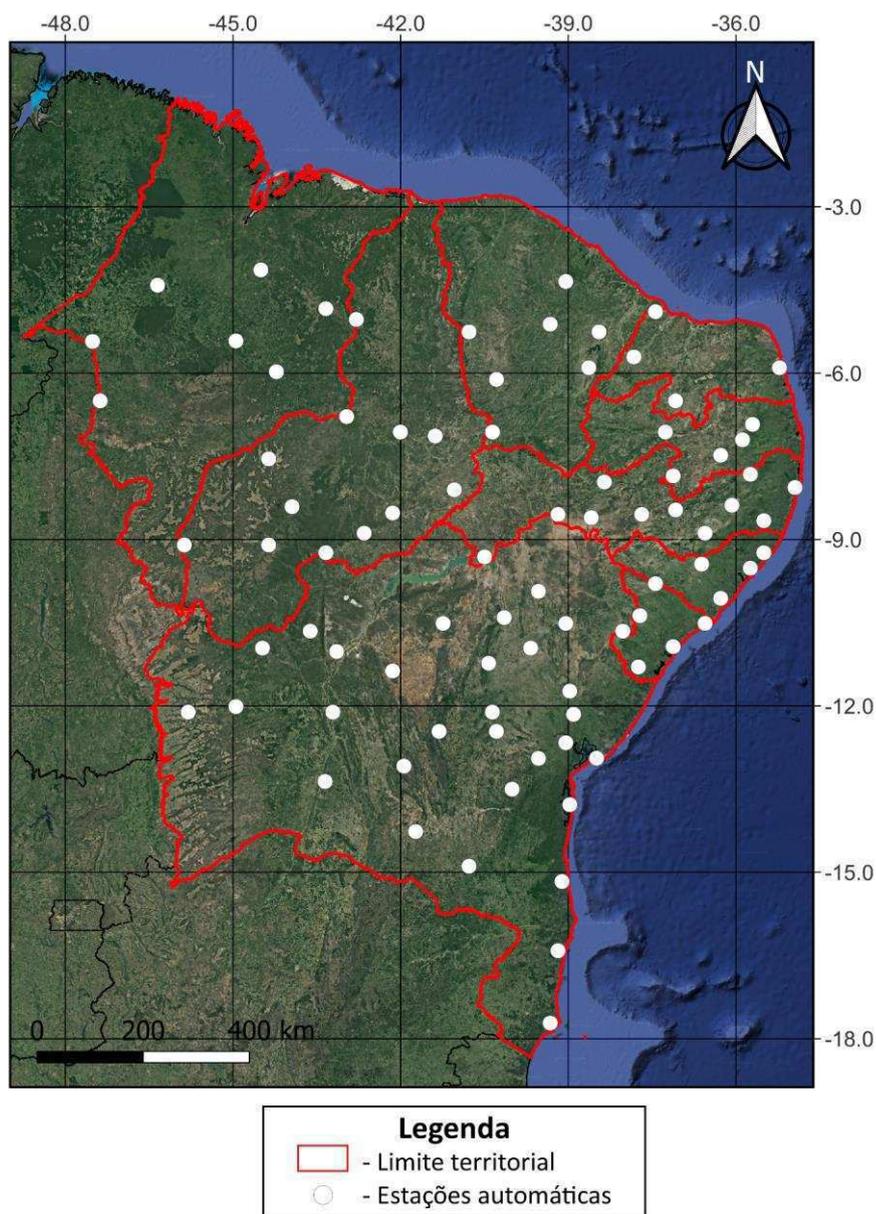


Figura 29. Localização das estações automáticas no Nordeste do Brasil.

4.2.2 Reanálise do ERA5

Sendo o ERA5 o produto ERA mais atualizado e a base de dados mais reconhecida em

produtos de reanálise (MARTINEZ e IGLESIAS, 2022), o conjunto de dados da 5ª geração de reanálise climática do *European Center for Medium-Range Weather Forecasts* (ECMWF), possui uma resolução espacial de aproximadamente 30 km, resolução temporal por hora e com 137 níveis verticais. O conjunto de dados de reanálise utilizado na presente pesquisa abrange o período de 1940 até o presente para níveis únicos e horários; no entanto, foram utilizados dados apenas de 2009 a 2019 para a região do NEB. Esses dados foram obtidos por meio do website do *Climate Data Store* (CDS). Como pode ser observado na Tabela 2, as variáveis utilizadas foram Irradiação Solar Incidente no Topo da Atmosfera (SSRD), Irradiação Global Horizontal (GHI), Temperatura em 2 metros (T2M), Precipitação Total (TP) e Cobertura Total de Nuvens (TCC).

Tabela 2. Variáveis utilizadas de acordo com os dados de análise do ERA.

Variável	Fonte	Sigla	Unidade de medida
Irradiação Solar Incidente no Topo da Atmosfera	ERA5	SSRD	Wh/m ²
Irradiação Global Horizontal	ERA5	GHI	Wh/m ²
Temperatura em 2 metros	ERA5	T2M	°C
Precipitação Total	ERA5	TP	mm
Cobertura total de nuvens	ERA5	TCC	0-1

4.2.3 Operador Nacional do Sistema Elétrico

Apesar da dificuldade, dados horários de GEV, CGE e CI (Tabela 3) de 14 usinas fotovoltaicas distribuídas no NEB foram obtidos através do Operador Nacional do Sistema Elétrico (ONS). A organização é responsável pela coordenação da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da ANEEL. Diante da disponibilidade dos dados, foi adquirido o período de 2009 a 2019; no entanto, após a manipulação do mesmo, verificou-se a presença de dados de usinas solares apenas a partir do ano de 2017 (Tabela 4). Apesar do curto período, existe uma grande relevância para utilização e aplicação na pesquisa.

Tabela 3. Variável obtida através dos dados da ONS.

Variável	Fonte	Sigla	Unidade de medida
Geração de energia verificada	ONS	GEV	MW
Capacidade de geração de energia	ONS	CGE	0-1
Capacidade instalada	ONS	CI	MW

A CI diz respeito à capacidade de energia que a usina pode chegar a gerar em MW. GEV são os valores de energia que a usina gerou; nesse caso, são valores horários em MW. Já a CGE é a variação de 0 a 1 da energia que a usina gerou, de acordo com sua capacidade. Em outras palavras, se a usina possui uma CI de 90 MW e às 13 horas ela gerou 90 MW, sua capacidade de geração de energia para o horário foi de 1.

Atualmente, para o NEB, a ONS disponibiliza dados provenientes de aproximadamente 50 usinas fotovoltaicas. Contudo, para os objetivos específicos deste estudo, optou-se por utilizar informações oriundas dessas usinas, as quais estão alinhadas com o período de 2009 a 2019, estabelecido para a condução da pesquisa. A distribuição espacial de cada usina fotovoltaica utilizada pode ser observada na Figura 30.

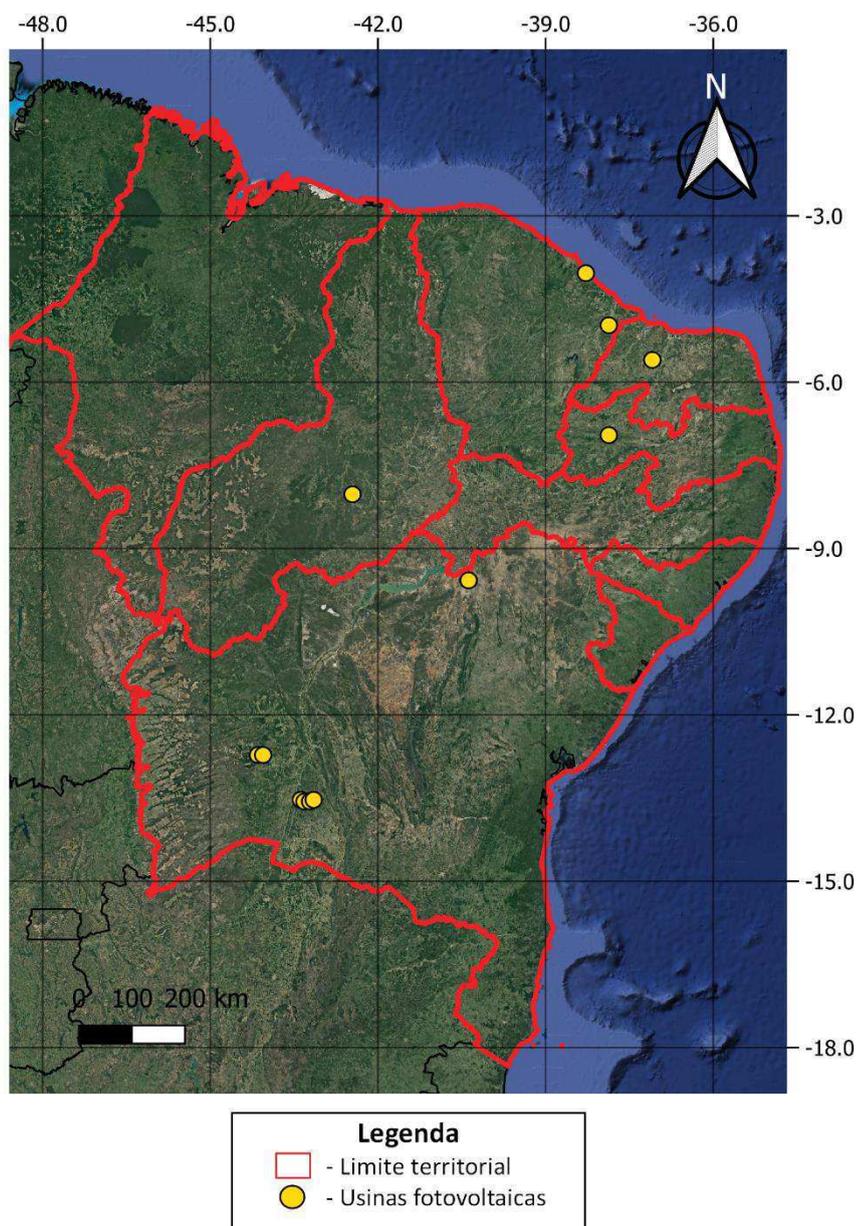


Figura 30. Localização das usinas fotovoltaicas utilizadas no estudo.

Essas usinas estão distribuídas geograficamente da seguinte maneira: uma no Rio Grande do Norte, duas no Ceará, uma na Paraíba, uma no Piauí e sete na Bahia, totalizando 12. Para uma compreensão mais detalhada, o início de funcionamento de cada usina, juntamente com seus respectivos nomes e localizações, pode ser observado na Tabela 4.

Tabela 4. Usinas fotovoltaicas que tiveram seu funcionamento iniciado de 2017 a 2019.

Usina	Estado	Início de funcionamento
Assú V	RN	13/12/2017
Conj. B JL	BA	12/01/2018
Conj. Bom Jesus	BA	17/05/2017
Conj. Calcário	CE	31/12/2018
Conj. Horizonte	BA	30/12/2018
Conj. Ituverava	BA	31/12/2018
Conj. Juazeiro Solar	BA	31/12/2018
Conj. Lapa	BA	30/12/2018
Conj. Nova Olinda	PI	11/09/2017
Conj. Rio Alto	PB	31/12/2018
Conj. São Pedro	BA	31/12/2018
Conj. Sol do Futuro	CE	11/12/2019

4.3 Análise estatística

4.3.1 Medidas de tendência central e dispersão

As medidas de tendência central são indicadores que proporcionam uma visão inicial ou um resumo da distribuição dos dados de uma experiência, oferecendo informações sobre o valor (ou valores) da variável aleatória (MORAIS, 2005). Denominam-se medidas de tendência central porque indicam um ponto ao redor do qual os dados se concentram, sendo esse ponto o centro da distribuição dos dados (GUEDES, *et al.*, 2005).

As medidas de dispersão auxiliam as medidas de tendência central a descrever adequadamente o conjunto de dados, indicando se os dados estão ou não próximos uns dos outros (GUEDES, *et al.*, 2005). Quanto maior (ou menor) for a dispersão, menor (ou maior) será a concentração, tornando a média observada uma medida central menos (ou mais) representativa.

Reconhecendo a importância da análise das medidas de tendência, e com o objetivo de realizar uma análise da estatística descritiva, foram examinadas as médias, medianas, variâncias e desvios padrões para os dados da estação de Bom Jesus da Lapa e do Conjunto Bom Jesus.

4.3.2 Teste de normalidade

Um dos métodos para verificar o formato da distribuição de uma variável contínua é a construção do histograma (LEOTTI, COSTER, RIBOLDI, 2012). O histograma é um tipo de gráfico de barras justapostas, no qual o eixo horizontal representa a variável de interesse dividida em classes, e o eixo vertical mostra a frequência da classe correspondente (SOARES e SIQUEIRA, 2002). Através do histograma, é possível observar a frequência dos dados, sua distribuição e o comportamento da curva normal, evidenciando simetria em forma de sino.

Outra forma de observar a normalidade de um conjunto de dados é através do gráfico Quantil-Quantil, ou Q-Q Plot. Neste gráfico, no eixo horizontal tem-se os valores observados da variável, e no eixo vertical, os valores esperados caso a variável tenha distribuição Normal, se há uma boa aderência dos dados à distribuição Normal os pontos estão próximos à reta de referência apresentada no gráfico (LEOTTI, COSTER, RIBOLDI, 2012). Em geral, análises de normalidade baseadas em diagramas Q-Q Plot são mais confiáveis para amostras de grande dimensão (> 5.000 unidades), pois os testes de normalidade podem apresentar sensibilidade reduzida (CHANTARANGSI, *et al.*, 2015).

4.3.3 Correlação

A aplicação de métodos estatísticos de correlação tem como objetivo identificar a possível conexão entre variáveis. Essas conexões, na natureza, podem ocorrer por questões químicas ou físicas. Através do coeficiente de correlação linear de Pearson (r), pode-se medir o nível de força, intensidade ou grau de relação linear entre duas variáveis aleatórias (FERREIRA, 2005). Figueiredo Filho e Silva Júnior (2009), com base em Moore e McCabe (2009), enfatizaram as propriedades do coeficiente e as condições que precisam ser satisfeitas para realizar a análise de correlação de Pearson:

- O coeficiente de correlação de Pearson não diferencia entre variáveis independentes e dependentes.
- O valor da correlação não muda ao se alterar a unidade de mensuração das variáveis.
- O coeficiente tem um caráter adimensional, ou seja, é desprovido de unidade física que o defina.
- A correlação exige que as variáveis sejam quantitativas.
- Os valores observados precisam estar normalmente distribuídos.

- É necessário realizar uma análise de outliers, pois o coeficiente de correlação é fortemente afetado por sua presença.
- É necessário a independência das observações, ou seja, a ocorrência de uma observação X_1 não influencia a ocorrência de outra observação X_2 .

Ainda de acordo com Figueiredo Filho e Silva Júnior (2009), o coeficiente de correlação de Pearson é uma medida de associação linear entre variáveis calculada através da seguinte fórmula:

$$r = \frac{1}{n-1} \Sigma \left(\frac{x_i - \bar{X}}{S_x} \right) \left(\frac{y_i - \bar{Y}}{S_y} \right) \quad (1)$$

de tal forma que:

- A variação de seu resultado vai de -1 a 1, indicando direção positiva ou negativa.
- Valores próximos de 1 indicam que as variáveis tendem a crescer ou diminuir proporcionalmente.
- Para valores próximos de -1, induzem que as variáveis são inversamente proporcionais, ou seja, quando uma aumenta (diminui) a outra tende a diminuir (aumentar).
- Para resultados igual ou muito próximo de 0 indica que não existe relação linear entre as variáveis analisadas.

Alguns estudos rotulam o nível de correlação com base nos resultados obtidos com a aplicação de Pearson, Dancey e Reidy (2018) classificaram que para $r = 0,10$ até $0,30$ possui correlação fraca; $r = 0,40$ até $0,6$ moderado; $r = 0,70$ até 1 forte.

Ciente das condições de aplicação do método de correlação de Pearson e de posse dos resultados de normalidade por meio do Q-Q Plot e o teste de Kolmogorov-Smirnov, identificou-se no estudo a relação entre as variáveis obtidas para o ponto de latitude e longitude da estação de Bom Jesus da Lapa.

4.4 Aplicação de Deep Learning

Neste estudo, realizamos análises utilizando os métodos CNN, LSTM e GRU, bem como suas combinações LSTM+CNN, CNN+GRU e LSTM+GRU. Isso resultou em seis modelos distintos testados para prognóstico de Geração de Energia Verificada. O acoplamento dos modelos é empregado com o objetivo de aprimorar a precisão dos resultados, assim como utilizada nos estudos de Huang e Kuo (2018) e Barzegar, Aalami e Adamowski (2021).

Os parâmetros desses métodos foram ajustados conforme detalhado na Tabela 5. Ademais, todo o processamento e os resultados posteriormente discutidos foram gerados por meio da

linguagem de programação Python.

Tabela 5. Hiperparâmetros aplicados durante o treinamento dos métodos de Deep Learning para prognóstico de Geração de Energia Verificada.

Tamanhos de passos	Épocas	Tamanho do lote	Otimizador
6	50	32	ADAM
12	50	32	ADAM
24	50	32	ADAM

Para o treinamento, foram utilizados três diferentes tamanhos de passo: seis, doze e vinte e quatro. Esses valores determinam a variação das atualizações feitas nos parâmetros do método a cada iteração durante o treinamento. Tamanhos de passo menores podem levar a um processamento mais lento, enquanto tamanhos maiores podem resultar em instabilidade durante o processo, levando a resultados insatisfatórios.

Para cada tamanho de passos foram aplicadas épocas (*epochs*) de 50, que está relacionado com a quantidade de vezes que o método em questão irá passar pelo conjunto de dados de treinamento durante o processo. Logo, para o caso da pesquisa em questão, o método treinará 50 vezes o conjunto de dados de treinamento.

Durante o treinamento, os dados são divididos em lotes, ou "batches", para serem processados. Cada lote é analisado individualmente, com cálculos e ajustes dos viés realizados em cada um. Um tamanho de lote maior pode acelerar o processo de treinamento, permitindo uma análise de uma maior quantidade de dados de uma só vez. No entanto, um tamanho de lote menor possibilita cálculos e ajustes mais precisos devido à maior frequência de ajustes.

A taxa de aprendizado foi otimizada utilizando o otimizador (*optimizer*) ADAM, que é popularmente utilizado devido à sua simplicidade e eficiência (KHAN *et al.* 2018), e possui a capacidade de ajuste automático durante o processo de treinamento.

4.4.1 Convolutional Neural Network

O *Convolutional Neural Network* (CNN) representa um tipo especializado de rede neural que emprega a operação de convolução de matrizes como um método essencial para extrair características significativas de dados (ALBAWI, MOHAMMED e AL-ZAWI, 2017). Feng *et al.* (2022), explica que isso ocorre devido à configuração da CNN, composta por camadas consecutivas de convolução e *pooling*, que atuam como filtros nos dados de entrada, extraindo informações significativas e mais complexas, além disso, identificam padrões e formas comuns

em cada mapa característicos gerado a cada camada do processo.

Para o caso de séries temporais, antes da aplicação do método CNN é necessário um pré-processamento dos dados, aplicando a normalização e garantindo que os referidos dados estejam padronizados na mesma escala de tempo, para então conseguir criar amostras para treinamento. Como exemplo, se temos uma série temporal T de n amostras, de forma que $T = \{t_1, t_2, \dots, t_n\}$, pode-se normalizar aplicando a seguinte equação:

$$t'_i = \frac{t_i - \text{média}(T)}{\text{desvio padrão}(T)} \quad (2)$$

Para o processo de convolução unidimensional com um filtro de tamanho k , é aplicado a operação matemática:

$$C(i) = \sum_{j=1}^k W_j * t_{i+j-1} + b \quad (3)$$

Desta forma, W_j representa a matriz de peso, t_{i+j-1} as entradas da série temporal e b_i o viés associado ao terminal de convolução.

Após a convolução é aplicado uma função não linear que resulta na transformação de valores negativos em zero e mantém os valores positivos. Por muitos anos, sigmoid e tanh foram as funções não lineares mais utilizadas, porém, a Unidade Linear Retificada (ReLU) tem sido usada com mais frequência por possuir definições mais simples tanto em função quanto em gradiente (ALBAWI, MOHAMMED e AL-ZAWI, 2017). Matematicamente, a função ReLU pode ser escrita da seguinte forma:

$$ReLU(x) = \max(0, x) \quad (4)$$

O pooling é aplicado com o intuito de reduzir a amostragem, reduzindo também a complexidade das camadas (ALBAWI, MOHAMMED e AL-ZAWI, 2017), ou seja, suas características são reduzidas. Max-pooling é um dos tipos mais comuns de métodos de pooling (ALBAWI, MOHAMMED e AL-ZAWI, 2017), definida matematicamente como:

$$P(i) = \max_j C(j) \quad (5)$$

Sendo $P(i)$ o valor máximo após o pooling na posição i .

Para o mapeamento das características reduzidas através do pooling, é aplicado a camada totalmente conectada, sendo possível, por exemplo, prever valores futuros e classificar padrões. Essas camadas estão conectadas pelos neurônios, uma ligada a outra formando uma grande rede. Esse processo pode ser calculado por:

$$Y = \text{ReLU}(W_F * F + b_F) \quad (6)$$

De modo que ReLU é a função de ativação não linear, W_F é a matriz de pesos associada as características F após a operação pooling e b_F o viés da camada totalmente conectada.

4.4.2 Long Short-Term Memory

Redes *Long Short-Term Memory* (LSTM) demonstram uma superioridade em relação às redes convencionais e as redes recorrentes simples, isto ocorre devido a sua habilidade em lembrar padrões ao longo de extensos períodos de tempo, permitindo que a previsão atual esteja contextualizada dentro de um âmbito temporal mais amplo (BASTOS, 2020).

De acordo com Yu *et al.* (2019), as células LSTM apresentam três componentes fundamentais: um terminal de entrada, um terminal de esquecimento e um terminal de saída, que determina quais informações serão extraídas da célula, baseando-se em seu estado interno. Desta forma, esses terminais controlam o fluxo de dados, permitindo que esse tipo de rede aprenda a lembrar e esquecer as informações conforme for necessário.

A função de ativação sigmoid (σ) é responsável por comprimir os valores em um intervalo (0,1), determinando a probabilidade ou as informações que devem ser lembradas, esquecidas ou transmitidas, sendo representada pela seguinte equação:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (7)$$

O exponencial negativo transforma o valor de x em um número positivo elevado a uma potência, que quando somado a 1 assegura que o denominador nunca seja zero. Aplicando a divisão, para valores maiores de x resultaram em frações menores e valores menores x resultaram em frações maiores. Logo o resultado final da aplicação da equação sigmoid será entre 0 e 1, onde valores maiores de x produzem valores de saídas mais próximos de 1 e valores menores de x produzem valores de saída mais próximos de 0.

A função de ativação tangente hiperbólica (\tanh) é aplicada no estado da célula de memória e na geração do estado oculto, que serão discutidas com mais detalhes no decorrer do tópico. A função é capaz de transformar os valores entre -1 e 1, onde é representada matematicamente por:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

A divisão da diferença pela soma das exponenciais faz com que os valores sejam normalizados em intervalos entre -1 e 1, de forma que, valores maiores de x resultam em valores de saída mais próximos de 1, valores menores de x resultam em valores de saída mais próximos de -1 e para x igual a 0 o valor de saída é 0. Desta forma, é possível captar padrões complexos e não lineares nos dados de entrada utilizados, melhorando o desempenho do modelo.

O terminal de esquecimento (Forget Gate) é responsável por decidir se as informações armazenadas persistiram ou serão descartadas (YU *et al.*, 2019), mantendo apenas as informações relevantes. Matematicamente é dado pela função:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

Os resultados para equação podem variar de 0 a 1, sendo 0 para esquecer totalmente 1 para manter. De forma que σ representa a função de ativação sigmoid, W_f a matriz de pesos associada ao terminal de esquecimento, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_f o viés associado ao terminal de esquecimento.

O terminal de entrada (Input Gate) é responsável por determinar quais informações são dignas de serem incorporadas ao estado da célula (YU *et al.*, 2019), sendo representada pela equação de ativação sigmoid aplicada à soma ponderada das entradas:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

Através da função sigmoid, a soma ponderada das entradas é transformada em valores que podem variar no intervalo de 0 a 1. Desta forma, W_i é a matriz de pesos associada ao terminal de entrada, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_i o viés associado ao terminal de entrada.

Ainda no terminal de entrada é aplicada a função gerada pela tangente hiperbólica aplicada à soma ponderada das entradas:

$$\hat{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (11)$$

Nesse caso, os valores são normalizados e podem variar no intervalo de -1 a 1. Logo, W_c é a matriz de pesos associada ao terminal de entrada, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_c o viés associado ao terminal de entrada.

O terminal de saída (Output Gate) é responsável por determinar quais informações serão extraídas da célula, baseando-se em seu estado interno (YU *et al.*, 2019). Matematicamente é dada pela equação:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (12)$$

Com a aplicação da função sigmoid, a soma ponderada das entradas é transformada em valores que podem variar no intervalo de 0 a 1. Desta forma, W_o é a matriz de pesos associada ao terminal de saída, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_o o viés associado ao terminal de entrada.

A atualização do estado da célula é calculada através da combinação de informações antigas e novas ponderadas pelas ativações dos terminal de esquecimento e entrada:

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (13)$$

Sendo f_t o terminal de esquecimento, C_{t-1} o estado anterior da célula e i_t a saída do terminal de entrada.

O estado oculto final (Block Output) é então obtido multiplicando o valor do terminal de

saída pelo estado atual da célula normalizado pela tangente hiperbólica:

$$h_t = o_t * \tanh(C_t) \quad (14)$$

Essa estrutura demonstrou ser promissora em aplicações de previsão de irradiância solar (KUMARI e TOSHNIWAL, 2021; ROCHA e SANTOS, 2022).

4.4.3 Gated Recurrent Unit

Gated Recurrent Unit (GRU) é uma variação do algoritmo LSTM e ambas geram resultados parecidos (GOMES, 2023), porém possui uma estrutura mais simplificada (VIEIRA, 2022). Devido a menor complexidade, as células GRU são treinadas mais rapidamente, porém podem apresentar resultados inferiores quando expostas a um grande volume de dados (VIEIRA, 2022).

No GRU, são introduzidos dois terminais incluindo um de reset (Reset Gate) que ajusta a incorporação de novas entradas com a memória anterior (ZHAO *et al.*, 2017), sendo calculada através da ativação da função sigmoid aplicada à soma ponderada das entradas:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (15)$$

Desta forma, σ representa a função de ativação sigmoid, W_r é a matriz de pesos associada ao terminal reset, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_r o viés associado ao terminal de reset.

O terminal de atualização (Update Gate) que controla a preservação da memória anterior (ZHAO *et al.*, 2017), calculada através da função de ativação sigmoid aplicada à soma ponderada das entradas:

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (16)$$

Onde, σ é a função de ativação sigmoid, W_z é a matriz de pesos associada ao terminal de atualização, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_z o viés associado ao terminal de atualização.

Após o terminal de atualização, é aplicado o novo estado oculto proposto levando em consideração a função de ativação tangente hiperbólica aplicada a uma combinação ponderada das entradas:

$$\hat{h}_t = \tanh(W_h[r_t * h_{t-1}, x_t] + b_c) \quad (17)$$

Logo, \tanh é a função de ativação tangente hiperbólica, W_h é a matriz de pesos associada ao estado oculto proposto, r_t é o vetor de reset, h_{t-1} o estado oculto anterior, x_t a entrada atual e b_c o viés associado ao novo estado oculto proposto.

A atualização do estado oculto é matematicamente calculado por:

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t \quad (18)$$

Sendo $(1 - z_t)$ a ponderação para manter o estado oculto anterior, z_t o terminal de atualização, h_{t-1} o estado anterior da célula e \hat{h}_t o novo estado oculto proposto.

4.4.4 Métrica de desempenho

Para avaliar o desempenho dos métodos de DL, foram aplicadas duas métricas quantitativas, o RMSE e o MAE, que são definidos da seguinte forma:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (20)$$

onde y_t e \hat{y}_t indicam a produção de energia observada e prevista no momento t . N são os conjuntos de dados do momento.

De acordo com Vieira (2022), o MAE apresenta a distância entre o valor previsto e o valor real, não diferenciando erros negativos e positivos, diferente do RMSE, que penaliza valores discrepantes. O uso de diferentes métricas se deve ao fato de que cada uma apresenta suas vantagens e desvantagens ao estabelecer uma avaliação qualitativa dos resultados obtidos, sendo que, em conjunto, poder-se-á avaliar com mais segurança (PRADA, 2021).

5. RESULTADOS

5.1 Dados da Estação de Bom Jesus da Lapa e Conjunto Bom Jesus

Buscando observar a correlação entre as variáveis meteorológicas, foram analisados os dados obtidos através da reanálise do ERA5 e os dados observados do INMET, para o ponto de latitude e longitude da estação de Bom Jesus da Lapa. Com os dados da usina solar Conjunto Bom Jesus, que localiza-se próximo a estação de Bom Jesus da Lapa, foram gerados resultados com o intuito de investigar as ligações da geração de energia com os dados supracitados.

A razão para o estudo detalhado desta estação é por estar localizada em na região Oeste da Bahia, caracterizada como uma das áreas proeminentes para obtenção de irradiação solar, conforme evidenciado anteriormente através da Figura 8 e corroborado por pesquisas desenvolvidas por Martins *et al.* (2007). Em estudos mais recentes, De Lima *et al.* (2019) enfatizam que a região Oeste da Bahia se destaca como uma área de máximo GHI, atribuída à sua característica de baixa precipitação e nebulosidade anual.

5.1.1 Estação de Bom Jesus da Lapa

5.1.1.1 Estatística descritiva e normalidade dos dados

R_g, SSRD e GHI apresentaram, respectivamente, médias de 458,89 Wh/m², 452,65 Wh/m² e 384,23 Wh/m², e variâncias de 104142,49 Wh/m², 100133,91 Wh/m² e 72242,66 Wh/m², indicando que possuem uma grande distância da variação em relação à média. No entanto, vale ressaltar que a variância é uma medida de dispersão que sofre influência direta de valores que estão distantes da média. Somado a isso, ela é calculada ao quadrado, resultando em camuflagem desses valores, dificultando ainda mais sua interpretação. Para mitigar esse problema, é calculado o desvio padrão, onde as variáveis R_g, SSRD e GHI, respectivamente, apresentaram valores de 322,71 Wh/m², 316,44 Wh/m² e 268,78 Wh/m².

A T2M possui média de 29,97°C, variância de 14,69°C e desvio padrão de 3,83°C. Os valores de TCC e TP possuem valores na distribuição dos dados muito pequenos, tornando a análise mais detalhada em relação às variáveis já mencionadas. Como respectivamente citadas, apresentam médias de 0,48 e 0,06, variância de 0,13 e 0,13 e desvio padrão de 0,37 e 0,35. Apresentando, também, uma distância consideravelmente grande da variação dos valores da distribuição dos dados em relação à média.

Tabela 6. Medidas de tendência central e dispersão dos dados da estação de Bom Jesus da Lapa.

Variáveis	Média	Mediana	Variância	Desvio Padrão
Rg (Wh/m ²)	456,21	458,89	104142,49	322,71
SSRD (Wh/m ²)	452,65	448,0	100133,91	316,44
GHI (Wh/m ²)	384,23	380,66	72242,66	268,78
T2M (°C)	29,97	29,78	14,69	3,83
TCC	0,48	0,43	0,13	0,37
TP (mm)	0,06	0,0	0,13	0,35

Após a análise descritiva das medidas de tendência central e de dispersão, foram realizados testes para identificar possíveis indicativos de normalidade para cada variável. Ao utilizar o gráfico Quantil-Quantil Plot ou Q-Q Plot, percebeu-se que, para a variável T2M, a maioria dos pontos está sensivelmente ao longo da reta, indicando graficamente uma distribuição normal, com apenas uma relação não-linear acentuada entre os valores dos dados e os quantis teóricos nas caudas da distribuição.

Por outro lado, as variáveis TCC, SSRD e GHI apresentam uma não-linearidade mais acentuada entre os valores dos dados e os quantis teóricos na região das suas caudas. A variável TP, devido à predominância de valores iguais ou muito próximos de zero em sua distribuição, torna a análise gráfica mais complexa.

Ao considerar o p-valor obtido a partir do Q-Q Plot, utilizado para testar a hipótese nula de que os dados seguem uma distribuição normal (Figura 31), observou-se que, para o nível de significância de 0,5, todas as variáveis apresentam distribuição normal. Entretanto, é crucial ressaltar que o Q-Q Plot não é considerado um teste formal de normalidade, mas sim uma ferramenta gráfica que permite visualizar se os dados se aproximam de uma distribuição normal, tornando a conclusão subjetiva ou tendenciosa.

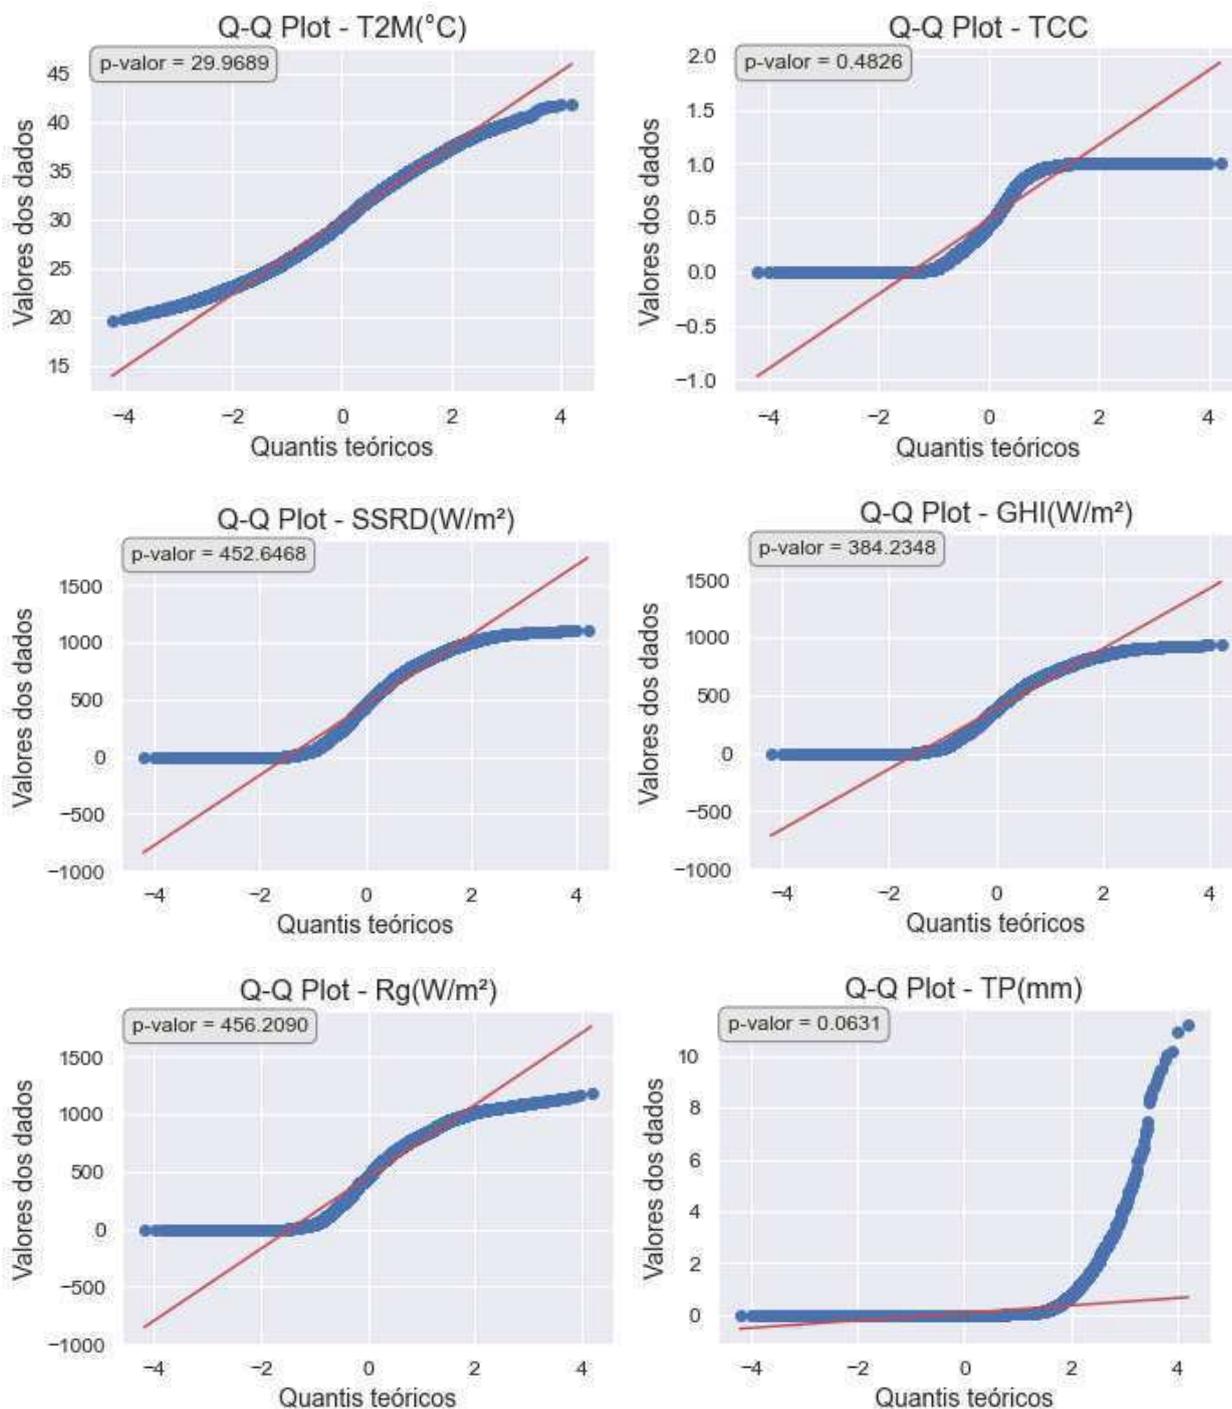


Figura 31. Q-Q Plot e p-valor das variáveis T2M, TCC, SSRD, GHI, Rg, TP.

Portanto, para uma análise mais quantitativa da normalidade de distribuição das variáveis discutidas, foi aplicado o teste de Kolmogorov-Smirnov. O teste visou identificar se os dados da Estação de Bom Jesus da Lapa seguem uma distribuição de Poisson com $\lambda = 10$, seguindo as hipóteses:

- H_0 : Segue a distribuição de Poisson com $\lambda = 10$.
- H_1 : Não segue a distribuição de Poisson com $\lambda = 10$.

Com base nos resultados do teste de Kolmogorov-Smirnov (Tabela 7), exceto para a variável TCC, que não apresentou valor em seus resultados, todas as outras variáveis analisadas para a localização da estação de Bom Jesus da Lapa possuem uma distribuição normal. Todos os p-valores são maiores que 0,05, indicando que a distribuição de Poisson com $\lambda = 10$ é uma boa representação dos dados.

Tabela 7. P-valor obtidos como resultado do teste de Kolmogorov-Smirnov.

Variáveis	P-valor
Rg (Wh/m ²)	0,33
SSRD (Wh/m ²)	0,33
T2M (°C)	0,27
TCC	NA
TP (mm)	0,27

5.1.1.2 Análise descritiva

No município de Bom Jesus da Lapa, devido à sua proximidade com a linha do equador, o nascer e pôr do sol ocorrem aproximadamente às 6 e 18 horas, respectivamente. A partir das 7 horas da manhã, a superfície começa a ser aquecida devido à exposição à irradiação solar emitida pelo sol. Ao longo do dia, a irradiação tende a atingir a superfície com mais facilidade e intensidade, resultando em um aumento observado que atinge seu pico médio por volta das 11 e 13 horas, alcançando aproximadamente 800 Wh/m². Após esse pico, a irradiação solar diminui, e com o pôr do sol, observam-se valores mais baixos de irradiação, como ilustrado na Figura 32.

As distribuições e médias mensais (Figura 33) da irradiação solar global apresentam um padrão sazonal, com valores mais elevados durante o verão e menores no período próximo ao inverno. Esse comportamento é observado devido à rotação e translação da Terra ao redor do Sol. Durante o inverno, os raios solares precisam percorrer um caminho mais extenso na atmosfera, levando a dias mais curtos e a uma redução no recebimento de irradiação solar. O mês de junho registrou a menor média, enquanto fevereiro apresentou a maior, com valores aproximados de 200 Wh/m² e 290 Wh/m², respectivamente.

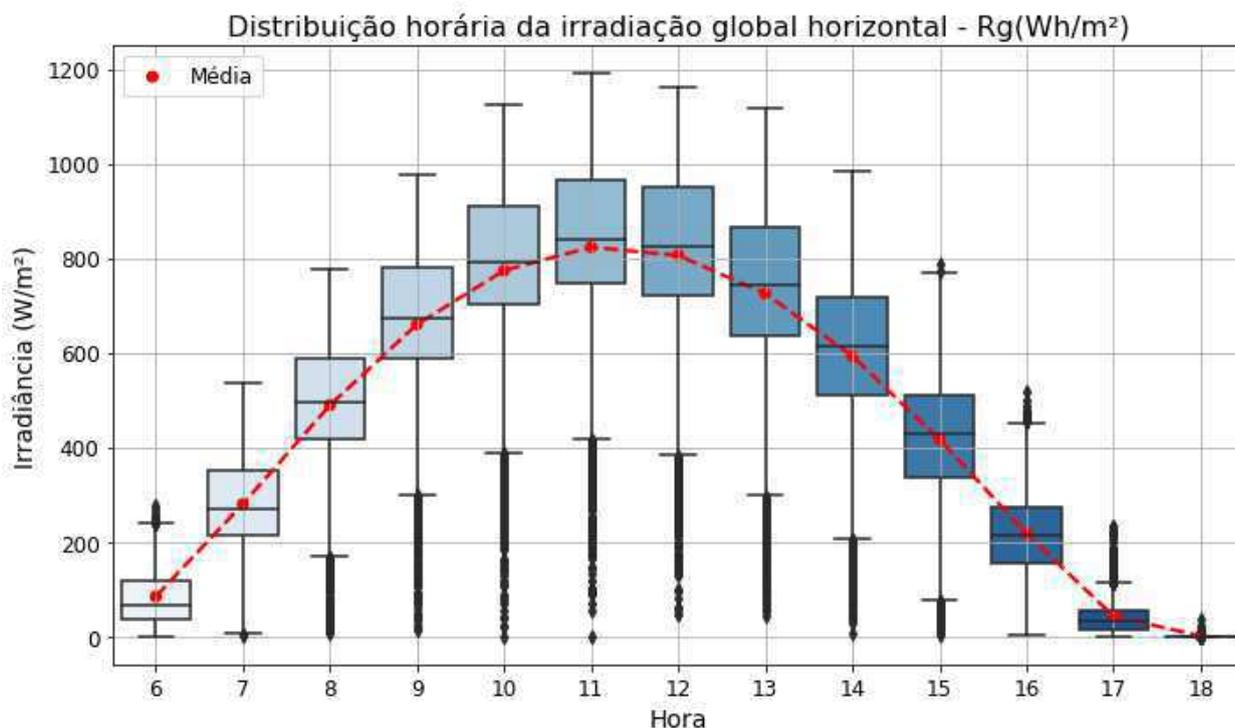


Figura 32. Boxplot e média horária da irradiação global horizontal, para o período de 2009 a 2019, obtidos através dos dados observados do INMET.

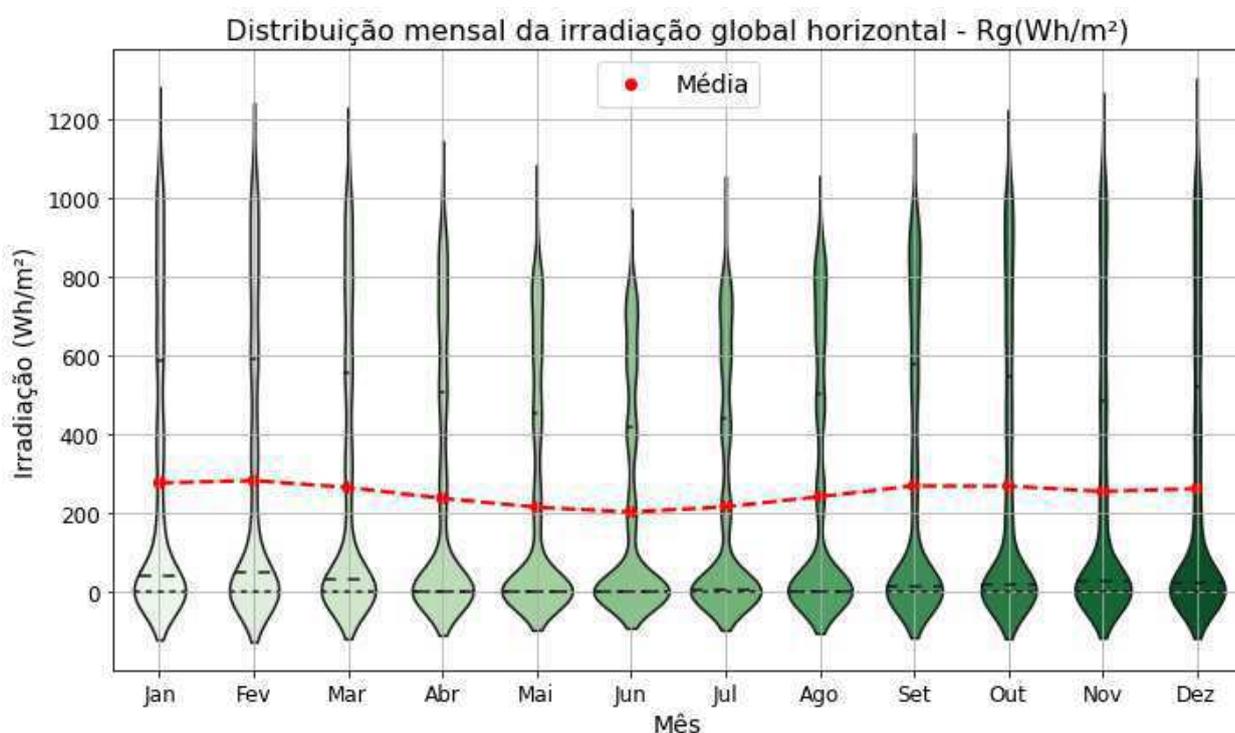


Figura 33. Violinplot e média mensal da irradiação global horizontal, para o período de 2009 a 2019, obtidos através dos dados observados do INMET.

A irradiação solar horária incidente no topo da atmosfera, obtida através dos dados de reanálise do ERA5 (Figura 34), possui comportamento análogo ao observado com os dados do

INMET. Apresenta valores que tendem a se elevar com o nascer do sol, intensificando-se ao longo do dia devido à irradiação solar sobre a região. O pico ocorre às 11 horas, com um valor aproximado de 800 Wh/m². Após o pico, como é esperado, os valores tendem a diminuir, cessando com o pôr do sol.

As distribuições e médias mensais (Figura 35) de SSRD, apresentam um padrão sazonal com valores mais elevados durante o verão e menores durante o período próximo do inverno. O mês de junho registrou a menor média, 196,63 Wh/m², enquanto janeiro apresentou a maior, com valor de 271,40 Wh/m².

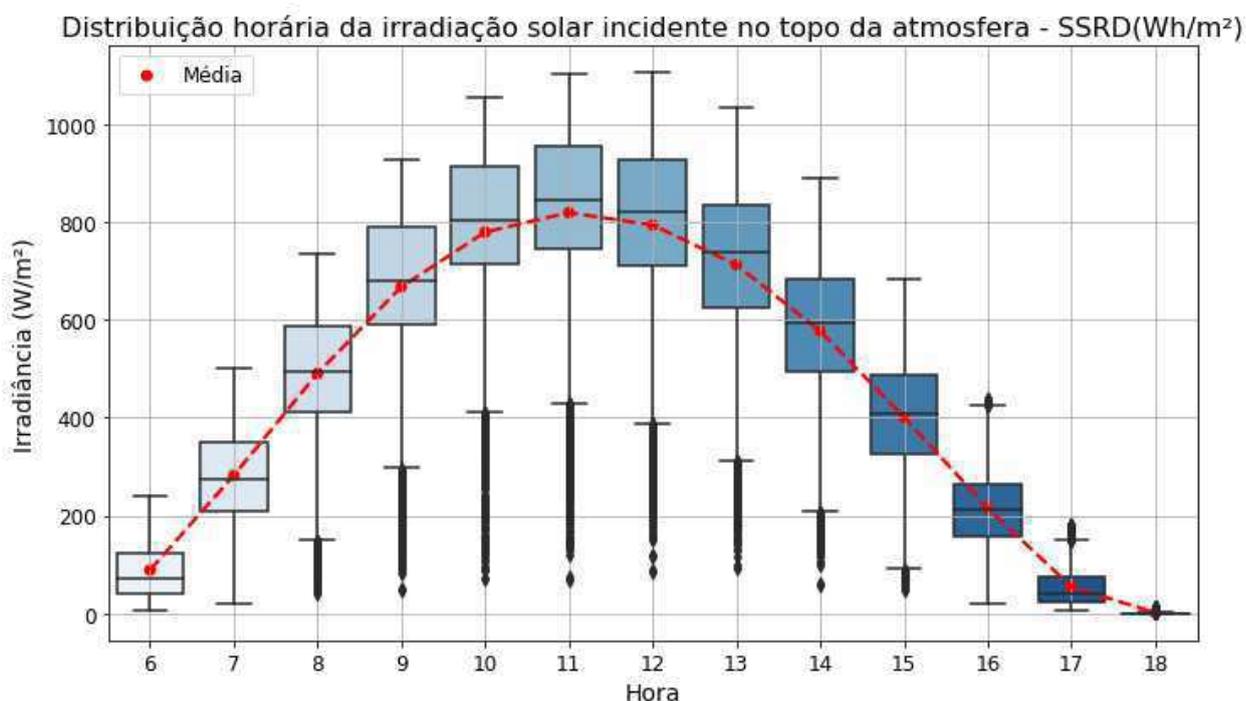


Figura 34. Boxplot e média horária da irradiação solar incidente no topo da atmosfera, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

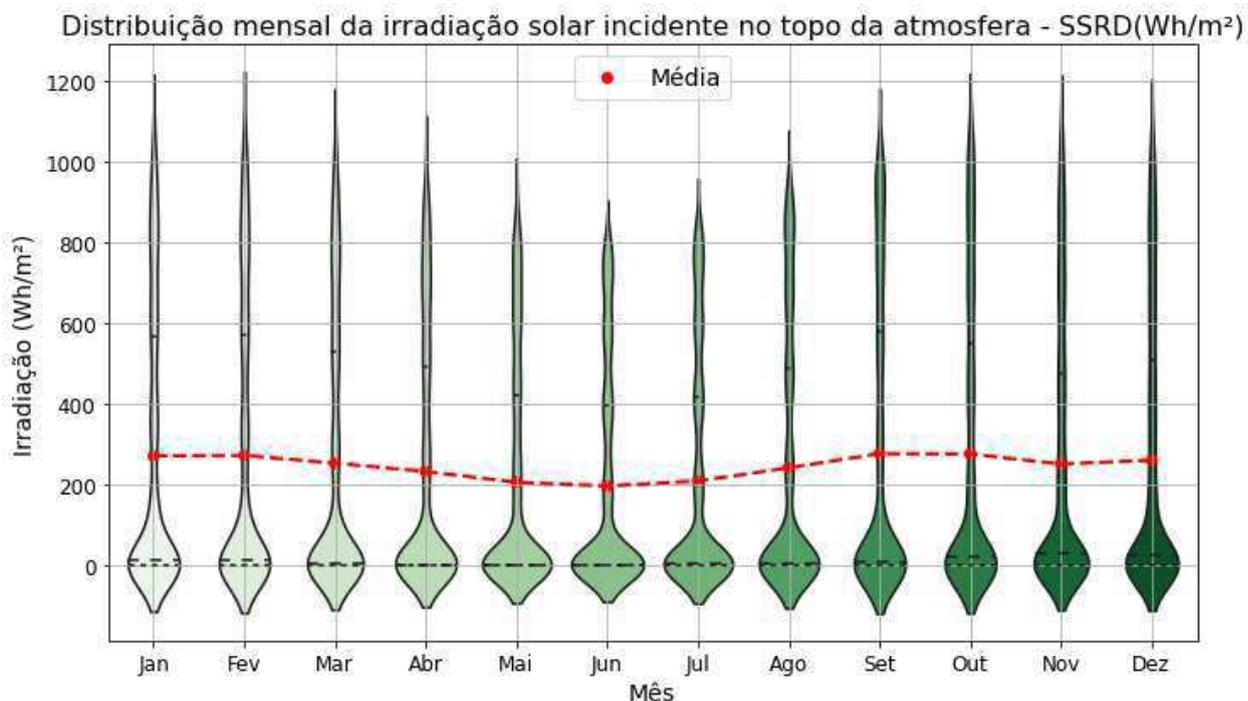


Figura 35. Violinplot e média mensal da irradiação solar incidente no topo da atmosfera, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

O GHI horário (Figura 36), obtido através dos dados de reanálise do ERA5, possui comportamento análogo à irradiação global e SSRD. Valores começam a ser observados com o nascer do sol e tendem a se elevar com o passar do dia devido à intensificação da irradiação solar sobre a região. O pico ocorreu às 11h, com valor de 696,97 Wh/m². Após o pico, como é esperado, os valores tendem a diminuir, cessando com o pôr do sol.

As distribuições e médias mensais (Figura 37) do GHI apresentam um padrão sazonal, com valores mais elevados durante o verão e menores durante o período próximo do inverno. O mês de junho registrou a menor média, 169,49 Wh/m², enquanto janeiro apresentou a maior, com um valor de 227,12 Wh/m².

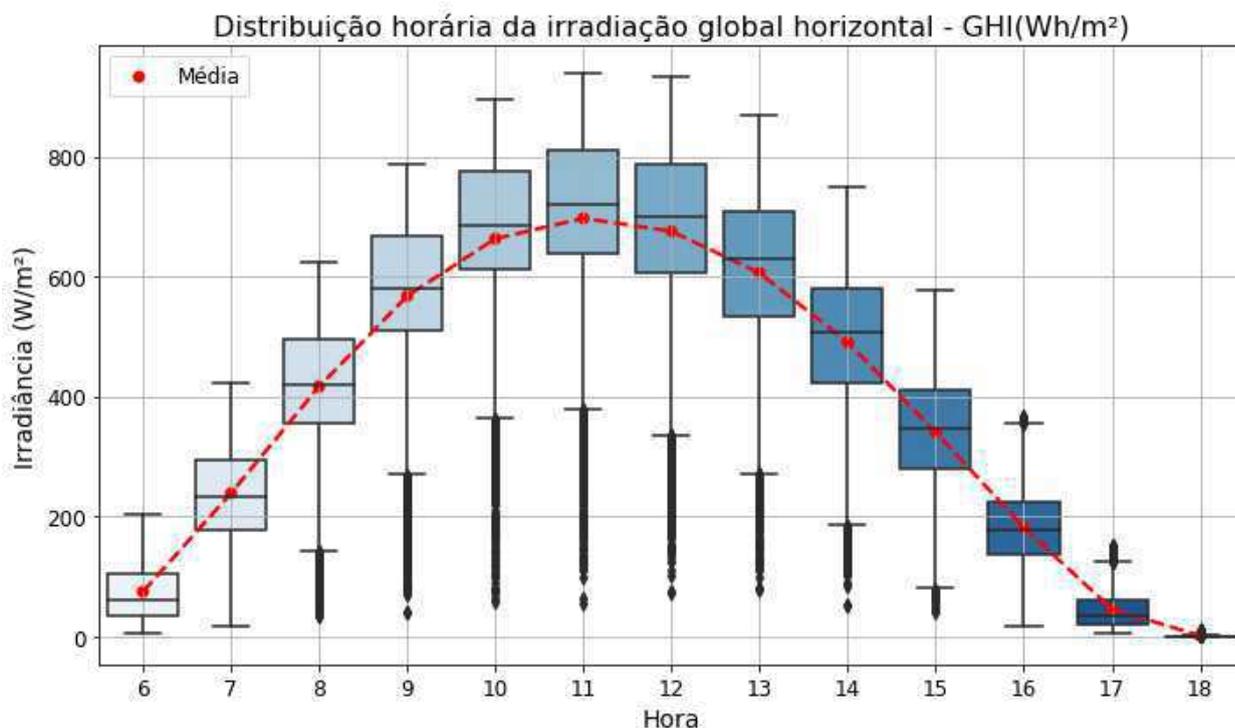


Figura 36. Boxplot e média horária da irradiação global horizontal, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

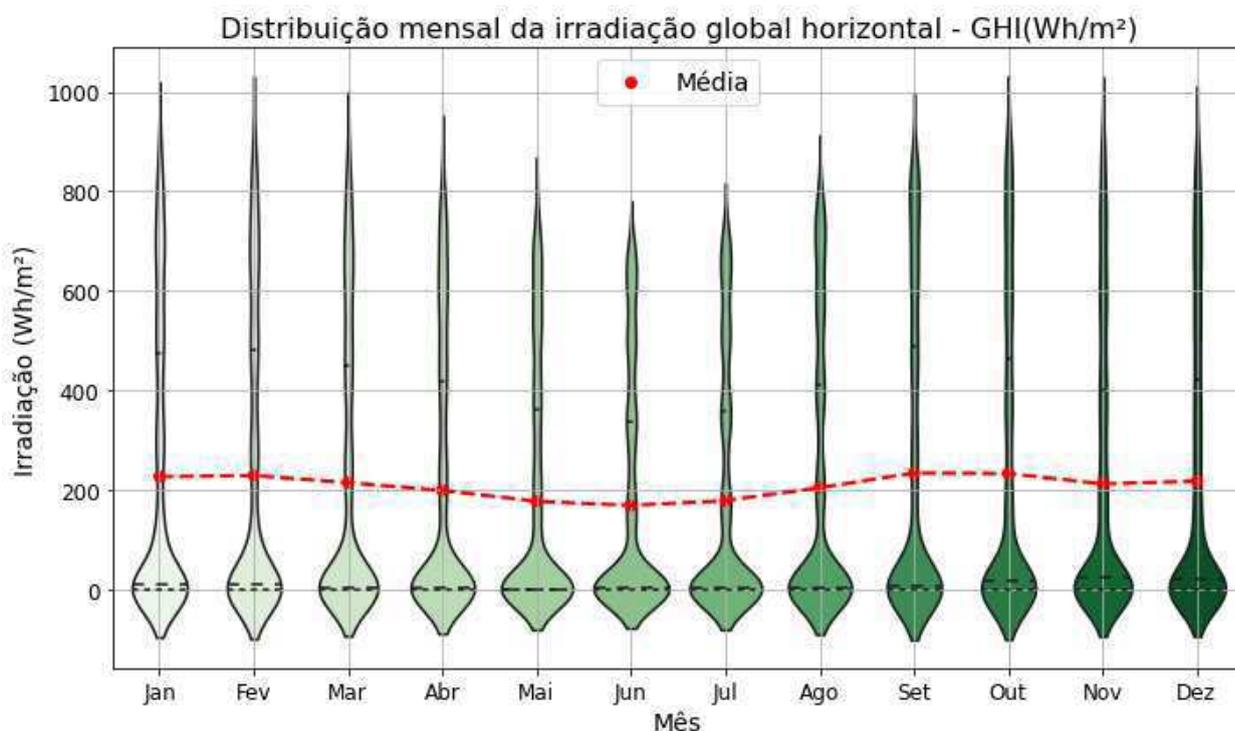


Figura 37. Violinplot e média mensal da irradiação global horizontal, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

Os valores de temperatura podem variar de acordo com os dias, pois sofrem influência direta de outras variáveis ou sistemas meteorológicos que podem estar atuando na região. Com o

nascer do sol, a temperatura tende a aumentar. A média horária da distribuição, apresentada na Figura 38, demonstra que os valores máximos ocorrem entre 11 e 17 horas, quando a superfície está em seu aquecimento máximo, com um valor máximo de 32,84 °C às 12 horas. Logo após as 17 horas, os valores de temperatura diminuem com a chegada da noite.

De acordo com as Figuras 39, o município de Bom Jesus da Lapa apresenta menores valores na distribuição e média mensal da temperatura durante o período de inverno, com a menor média em julho, chegando a 25,45 °C neste mês. Os maiores valores são observados durante a primavera e verão, com uma média máxima de 29,78 °C em outubro.

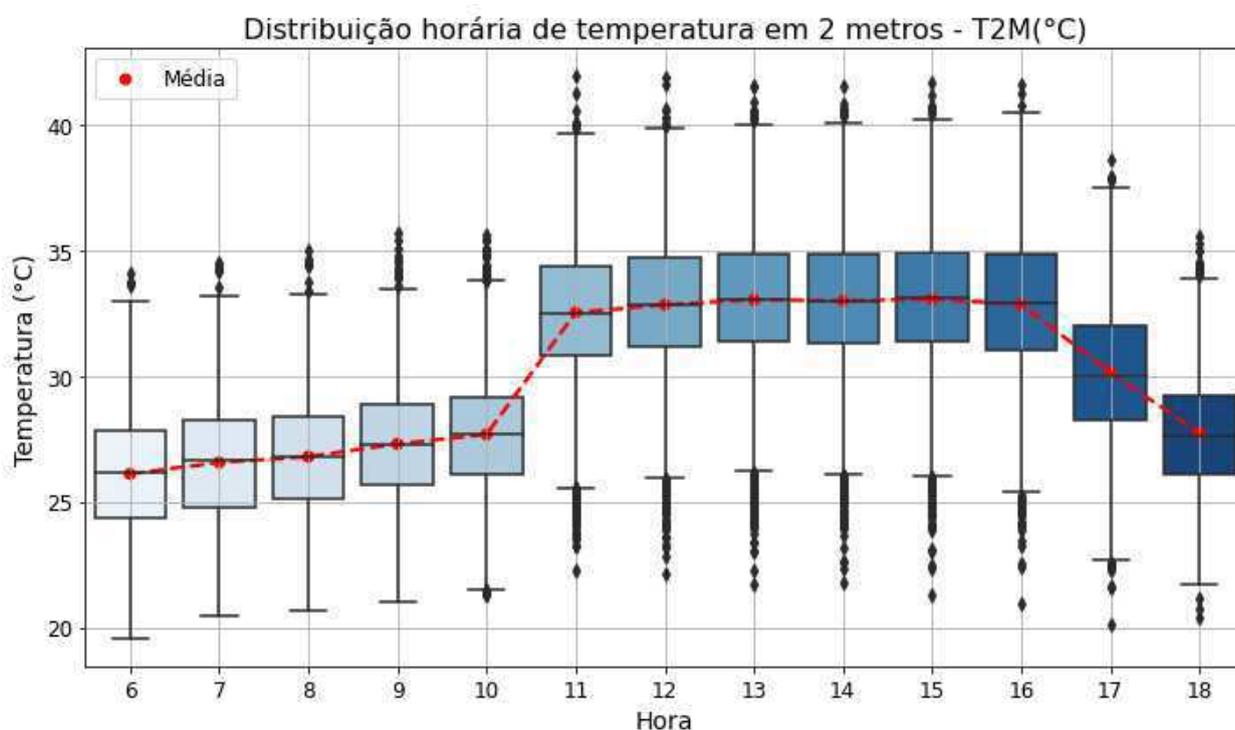


Figura 38. Boxplot e média horária da temperatura em 2 metros, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

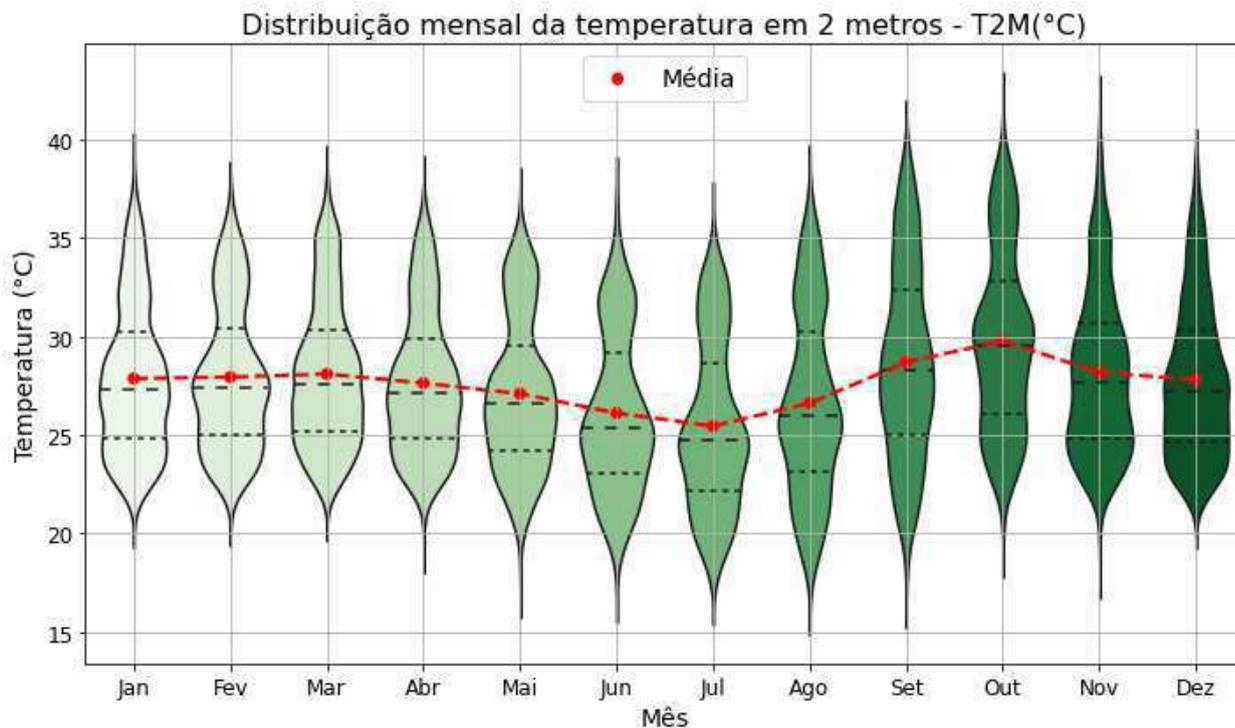


Figura 39. Violinplot e média mensal da temperatura em 2 metros, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

A precipitação total horária (Figura 40) apresenta uma distribuição quase homogênea, com valores médios próximos de zero e apenas alguns valores discrepantes. De acordo com o violinplot mensal (Figura 41), apesar das médias se aproximarem de zero, pelos valores discrepantes, é possível observar que o outono e inverno apresentam menores valores, ao contrário das estações da primavera e verão, que têm maiores valores.

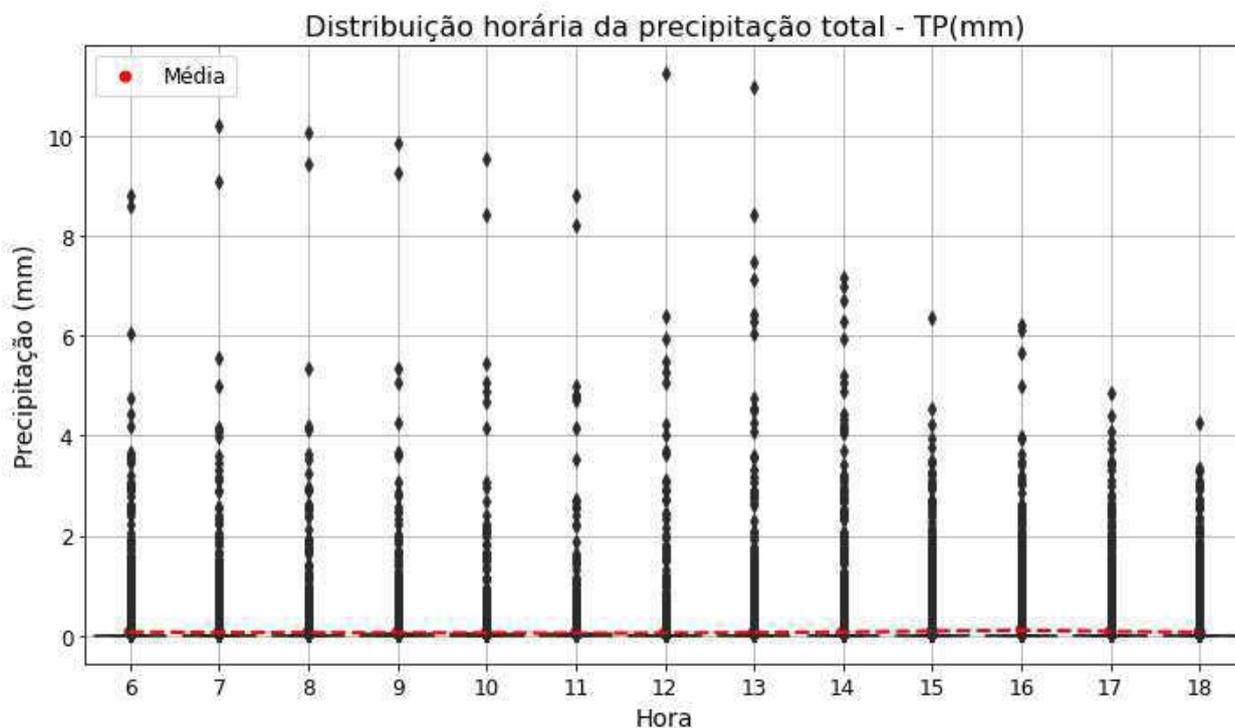


Figura 40. Boxplot e média horária da precipitação total, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

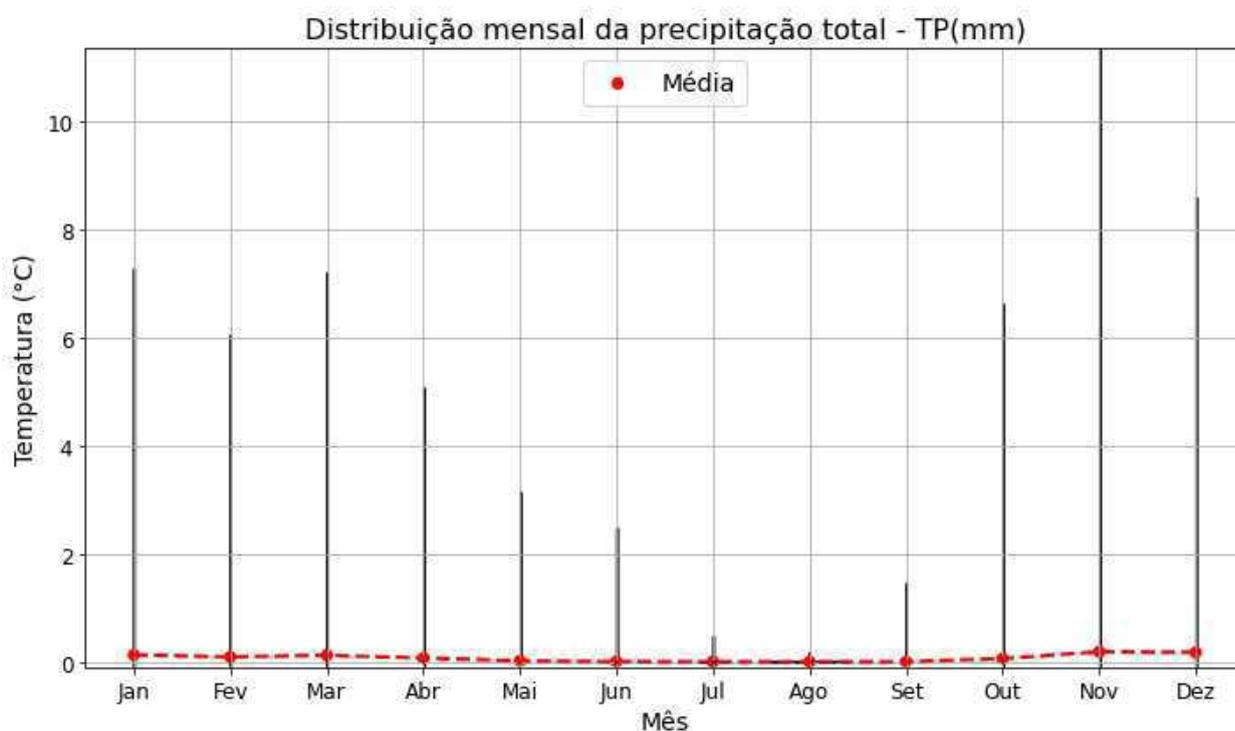


Figura 41. Violinplot e média mensal da precipitação total, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

Apesar da TCC média horária (Figura 42) não apresentar variação significativa, é possível identificar que o maior valor de cobertura inicia aproximadamente às 11 horas do dia e tende a

diminuir com a chegada da noite. De acordo com a média mensal (Figura 43), a porcentagem de céu encoberto por nuvens possui variação sazonal ao longo dos meses. O período de junho a outubro é a época de céu menos encoberto. A época mais encoberta inicia no final de outubro e termina em abril, tendo uma duração de aproximadamente 6 meses.

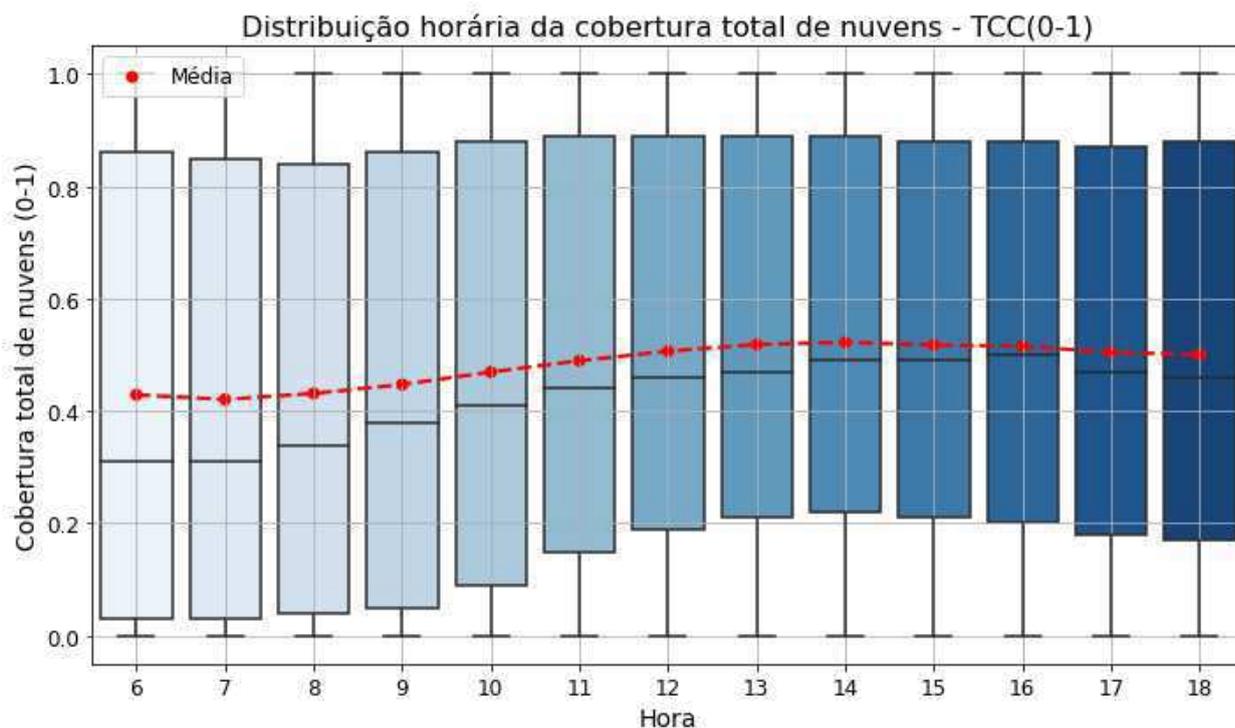


Figura 42. Boxplot e média horária da cobertura total de nuvens, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

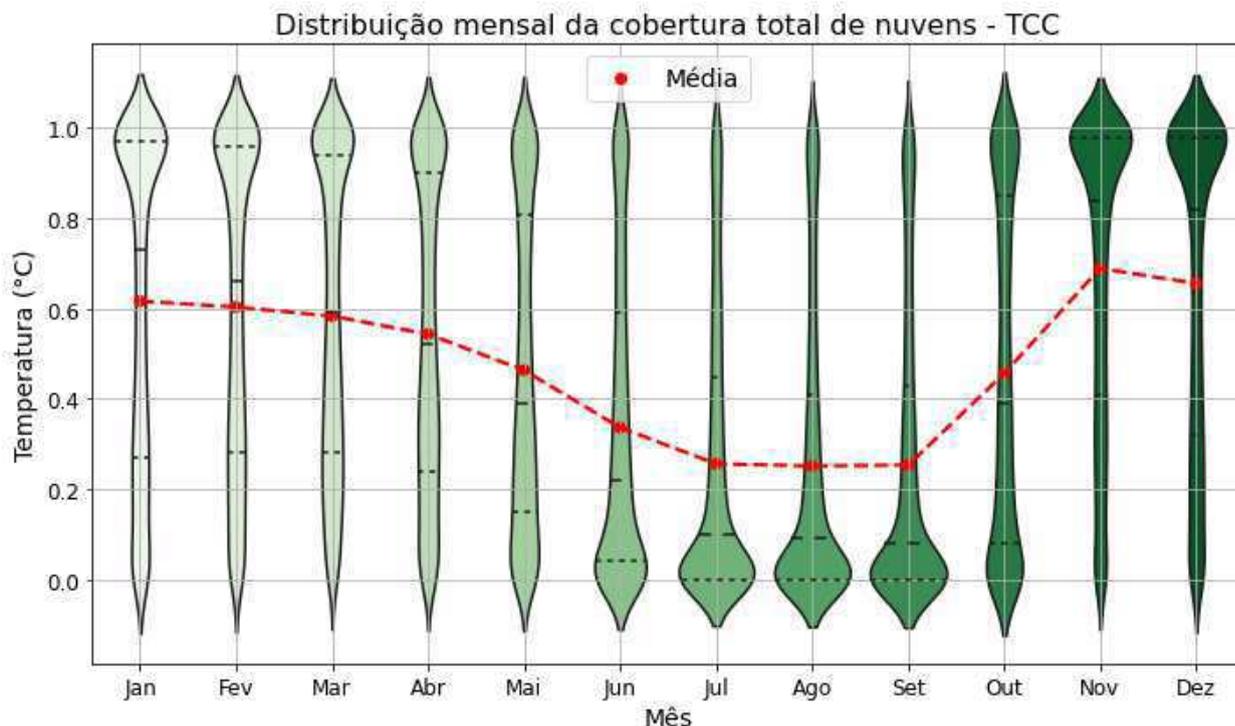


Figura 43. Violinplot e média mensal da cobertura total de nuvens, para o período de 2009 a 2019, obtidos através da reanálise do ERA5.

5.1.1.3 Correlação entre as variáveis meteorológicas

Através da análise das relações entre as variáveis independentes (SSRD, GHI, TCC, TP e T2M) e a variável dependente (Rg) utilizando o método de Pearson, observamos uma correlação significativa entre elas (Figura 44). A razão entre SSRD e Rg foi de 0,96, enquanto entre T2M e Rg foi de 0,61. Isso sugere que à medida que a SSRD aumenta, também aumenta a Rg, e que a temperatura está correlacionada com a quantidade de irradiação solar global que alcança a superfície, corroborando com estudos anteriores, como o de El Alani et al. (2021).

A razão entre Rg e GHI também foi de 0,96, o que sugere uma relação direta entre essas variáveis. A proximidade dos valores pode ser atribuída ao fato de ambas serem medidas que representam a mesma grandeza, a qual chamamos de irradiação global horizontal, sendo uma obtida por observação em estações meteorológicas e a outra derivada de modelagem atmosférica.

Por outro lado, as razões entre TCC e Rg, e entre TP e Rg foram de -0,03 e -0,07, respectivamente, indicando uma correlação baixa entre essas variáveis nos conjuntos de dados analisados.

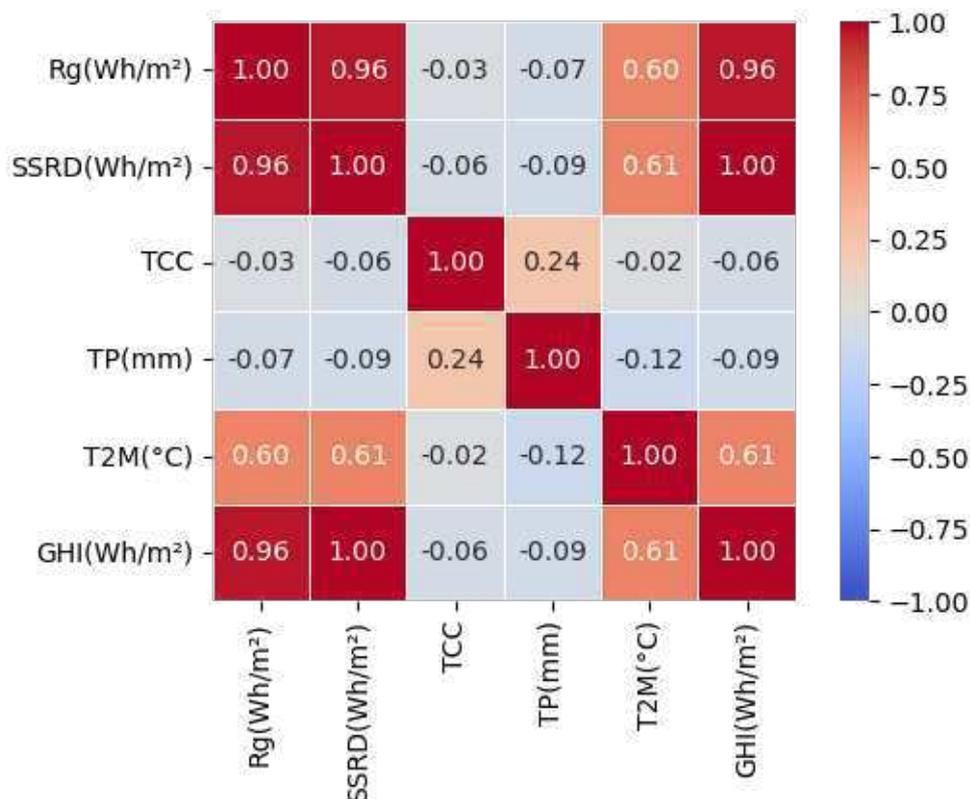


Figura 44. Correlação de Pearson aplicada as variáveis de Rg, SSRD, TCC, TP, T2M e GHI.

Comparando as médias mensais, a temperatura depende diretamente da quantidade de irradiação solar que chega à superfície. O período com menores valores de temperatura coincide com o mesmo período em que a irradiação chega à superfície com maior dificuldade. O mesmo é observado para o período de maiores valores de temperatura, quando também são apresentados maiores valores de irradiação global.

5.1.2 Dados de energia do Conjunto Bom Jesus

5.1.2.1 Estatística descritiva e normalidade dos dados

O CI do Conjunto Bom Jesus é de 60 MW. Sabendo disso, na Tabela 8, podemos observar a estatística descritiva da GEV e CGE apenas para os horários de funcionamento do Conjunto, ou seja, das 6 horas até as 18 horas. A GEV possui média de 30,58 MW, variância de 397,74 e desvio padrão de 19,94, indicando uma distância considerável da variação dos dados com relação à média. Variando de 0 a 1, a CGE possui média de 0,51, variância de 0,11 e desvio padrão de 0,33. Pelo valor da média da CGE, é possível concluir que o Conjunto opera aproximadamente em 50% do seu valor de CI, o que pode ser um bom valor, já que existe uma variação de GEV durante o dia,

com o passar das horas.

Tabela 8. Medidas de tendência central e dispersão dos dados do Conjunto Bom Jesus.

Variáveis	Média	Mediana	Variância	Desvio Padrão
GEV (MW)	30,58	34,41	397,74	19,94
CGE (0-1)	0,51	0,57	0,11	0,33

Através da observação gráfica do Q-Q Plot (Figura 45), é notório que alguns pontos da GEV estão sobre a linha ou muito próximos, havendo também pontos não tão próximos da reta, indicando uma relação não-linear acentuada entre os quantis dos dados e quantis teóricos nas caudas da distribuição. O seu p-valor é de 17,8651, indicando que apresenta distribuição normal para o nível de significância igual a 0,5.



Figura 45. Q-Q Plot e p-valor da geração de energia verificada.

Quando aplicado o teste de Kolmogorov-Smirnov para identificar se os dados de GEV do Conjunto Bom Jesus seguem uma distribuição de Poisson com $\lambda = 10.0$, as seguintes hipóteses foram consideradas:

- H_0 : Segue a distribuição de Poisson com $\lambda = 10.0$;
- H_1 : Não segue a distribuição de Poisson com $\lambda = 10.0$.

A hipótese nula (H_0) não foi rejeitada (Tabela 9), ou seja, possui uma distribuição normal, indicando que a distribuição de Poisson com $\lambda = 10.0$ é uma boa representação dos dados analisados.

Tabela 9. P-valor do GEV obtido como resultado do teste de Kolmogorov-Smirnov.

Variável	P-valor
GEV	0,6042

5.1.2.2 Análise descritiva

O Conjunto Bom Jesus, inaugurado em 2017 com CI de 60 MW, está localizado no município baiano de Bom Jesus da Lapa. Devido à região onde está instalado, o conjunto inicia seu funcionamento por volta das 6 horas da manhã, quando são verificados os primeiros registros de irradiação solar (Figura 46). Com o passar do dia, sua produtividade aumenta, atingindo um pico médio aproximadamente às 10 horas da manhã, com valor médio de 48,66 MW. Após este horário, a geração média verificada diminui lentamente até as 14 horas; com a chegada das 15 horas, a diminuição é mais expressiva. A distribuição horária pode variar de acordo com as condições do tempo, como, por exemplo, a presença de nuvens que causam sombreamento sobre as placas e influenciam diretamente em seu funcionamento.

A distribuição e média mensal (Figura 47) apresentam baixos valores médios entre os meses de fevereiro a junho, chegando a 15,13 MW em maio e valores médios mais altos durante o período de julho a janeiro, com pico de 21,05 MW no mês de setembro. Sazonalmente, de acordo com a distribuição, a primavera e o verão apresentam maiores valores, enquanto o outono e o inverno têm os menores. Pelas médias das estações, a primavera apresenta o maior valor (19,69 MW) e o inverno o menor valor (15,76 MW).

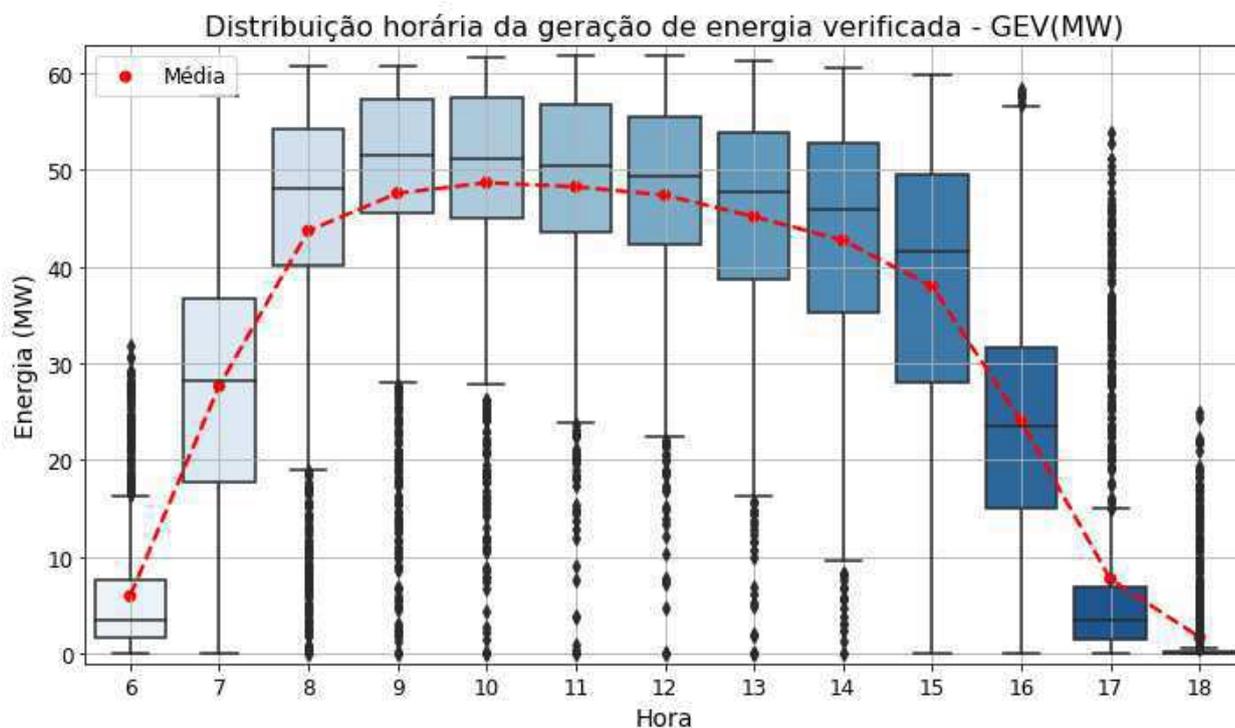


Figura 46. Boxplot e média horária da geração de energia verificada, para o período de 2017 a 2019, obtidos através dos dados observados do ONS.

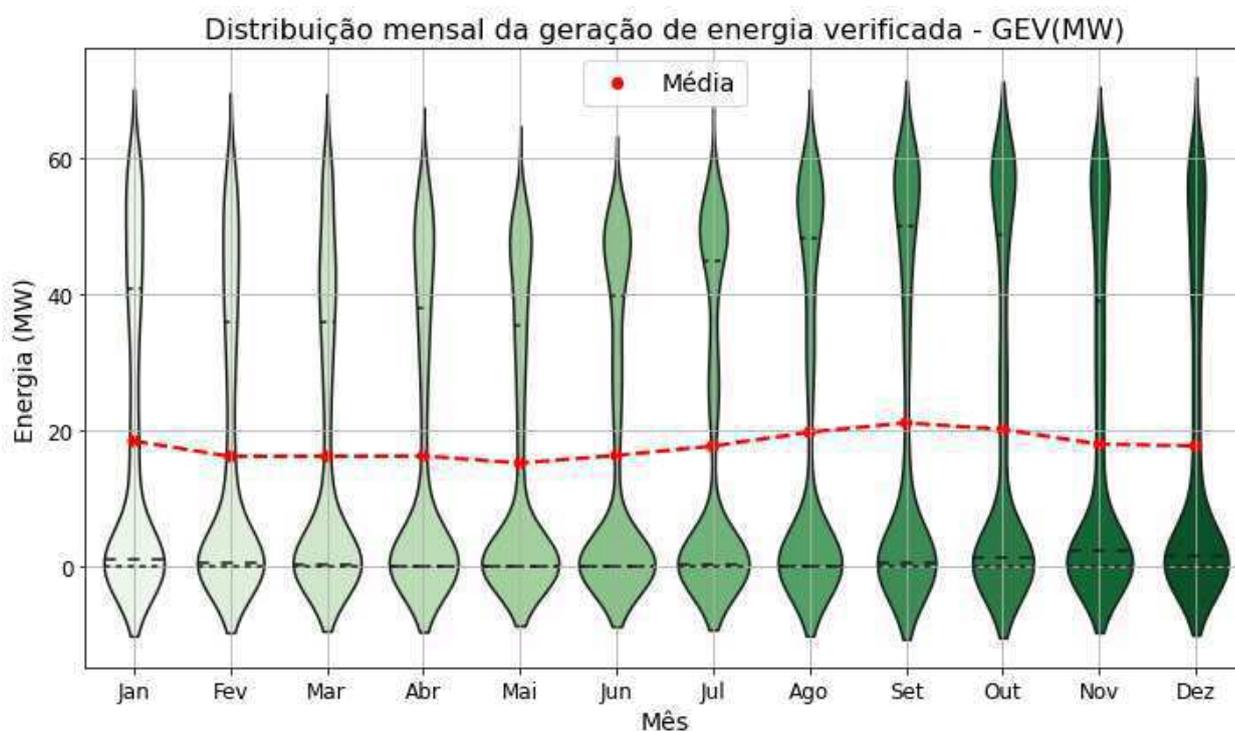


Figura 47. Violinplot e média mensal da geração de energia verificada, para o período de 2017 a 2019, obtidos através dos dados observados do ONS.

Diante dos resultados estatísticos, é evidente que a GEV do Conjunto Bom Jesus possui uma relação e dependência das variáveis SSRD, GHI, T2M, TP e TCC. O período mensal médio

de maior (menor) GEV é observado quando há maiores (menores) registros de SSRD e GHI, maiores (menores) valores de T2M, menores (menores) médias de TP e menor (maior) porcentagem de TCC, aproximadamente entre os meses de julho a dezembro (fevereiro a junho).

Entretanto, é importante destacar que valores de temperatura em um nível muito elevado podem prejudicar o funcionamento ótimo (ponto de potência máxima) dos módulos fotovoltaicos, como mencionado por Valente (2011). Logo, altos valores de temperatura nem sempre são indicativos de uma ótima geração de energia. Portanto, para um prognóstico preciso da geração de energia solar, torna-se necessário uma análise detalhada das variáveis apresentadas.

5.2 Análise espacial das variáveis do ERA5

Através da Figura 48, é possível realizar uma análise espacial da correlação entre as variáveis do ERA5. De acordo com a média horária das variáveis, observa-se que boa parte das regiões que possuem maiores valores de SSRD, como partes do Rio Grande do Norte, Paraíba, Pernambuco, Maranhão, Piauí e Bahia, também apresentam maiores valores de GHI e T2M, e menores valores de TCC e TP. Regiões mais litorâneas, como partes da Paraíba, Pernambuco, Alagoas, Sergipe e Bahia, apresentam menores valores de SSRD, GHI e T2M, e maiores valores de TCC. Essas observações indicam que, quanto menor (maior) for a TCC, a irradiação tende a chegar com facilidade (dificuldade) até a superfície, e apresenta maiores (menores) temperaturas.

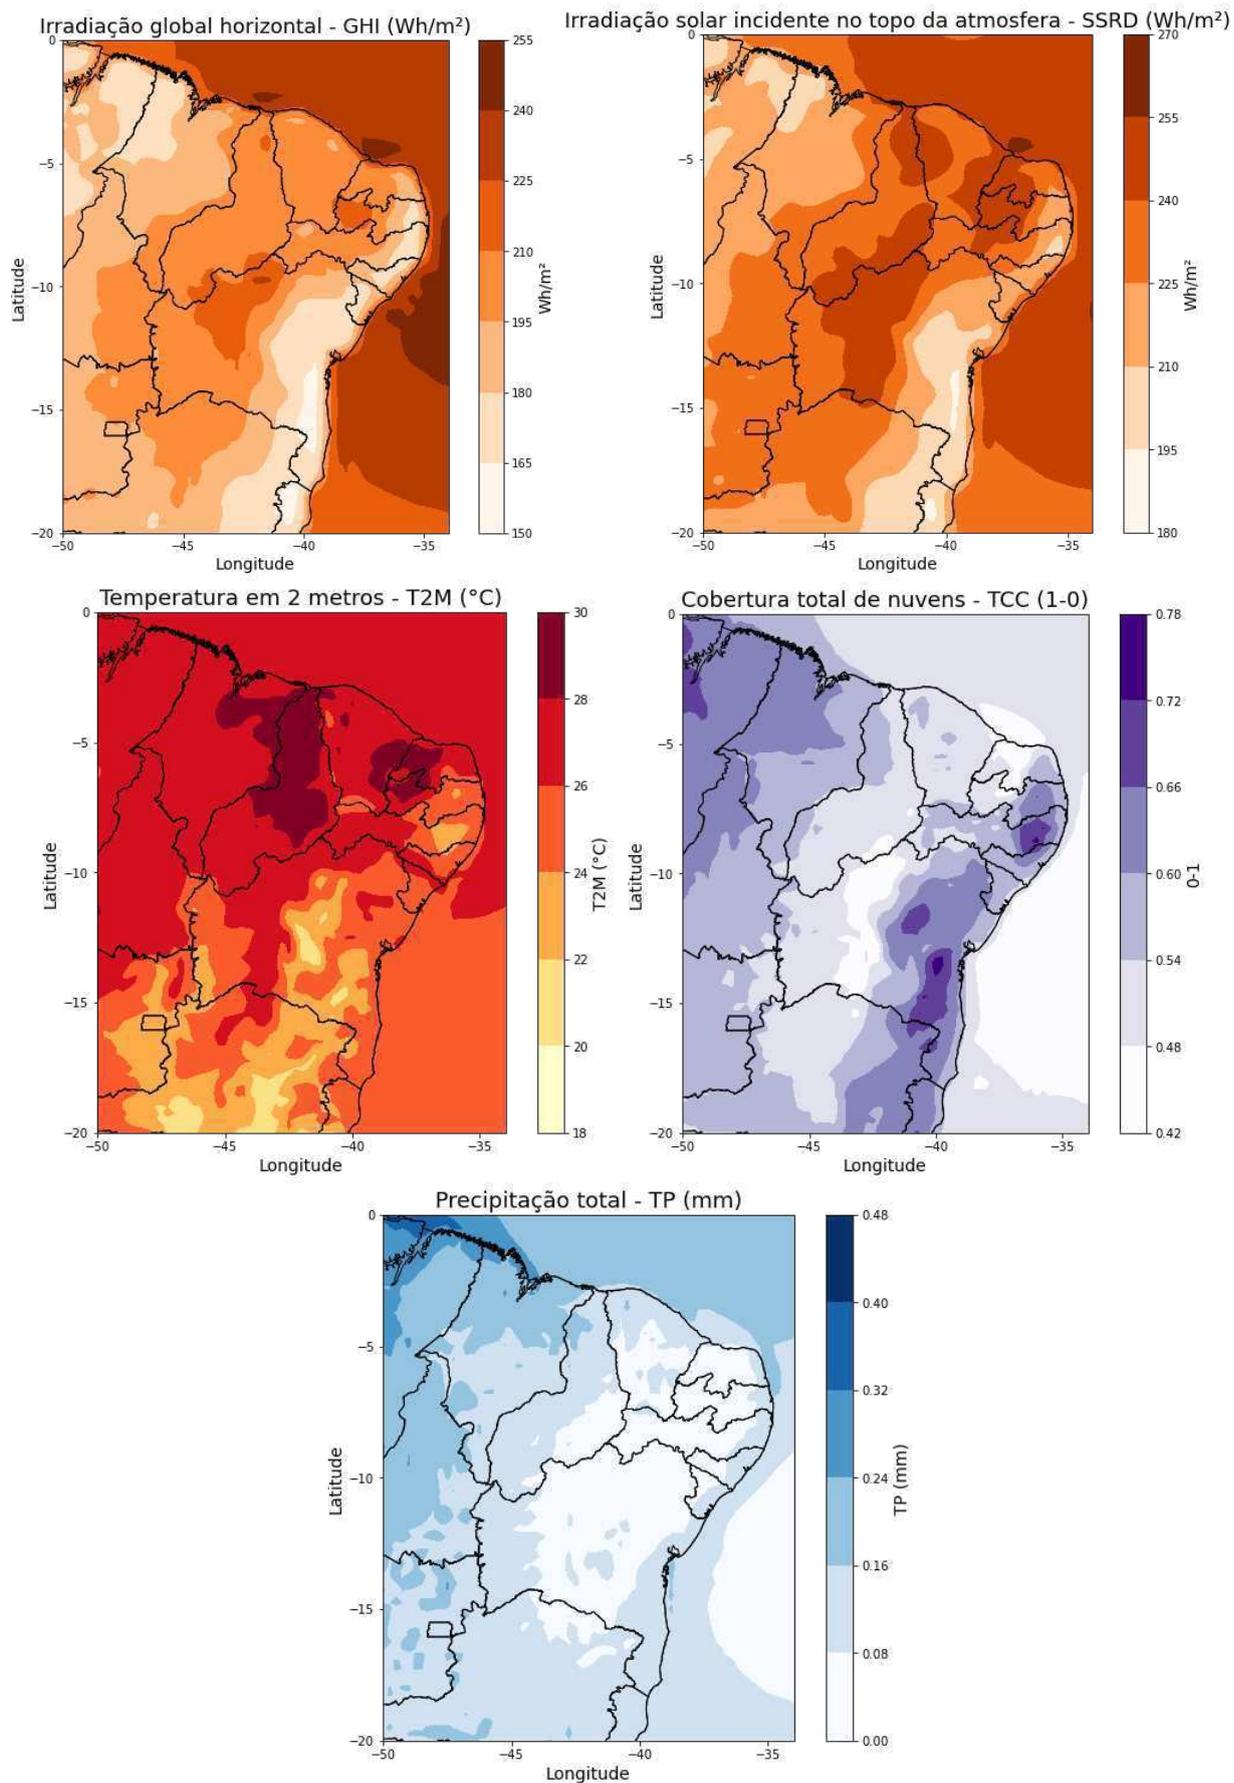


Figura 48. Média horária da GHI, SSRD, T2M, TCC e TP, para o período de 2009 a 2019, obtidos através dos dados do ERA5.

5.3 Dados de energia x GHI

Como já mencionado, a CI diz respeito à capacidade de energia que a usina pode chegar a gerar em MW, ou seja, o seu limite máximo de energia. Na Figura 49, em laranja temos a média horária do GHI, e os pontos verdes representam a CI de cada usina. Logo, podemos observar que as usinas com maiores potenciais de CI estão localizadas no Piauí e Bahia, com valores respectivos de 210 e 196 MW. Apesar da variação da CI de cada usina ser de 20 a 210 MW, todas estão localizadas na região onde o GHI possui um valor médio horário elevado, chegando a aproximadamente 200 Wh/m².

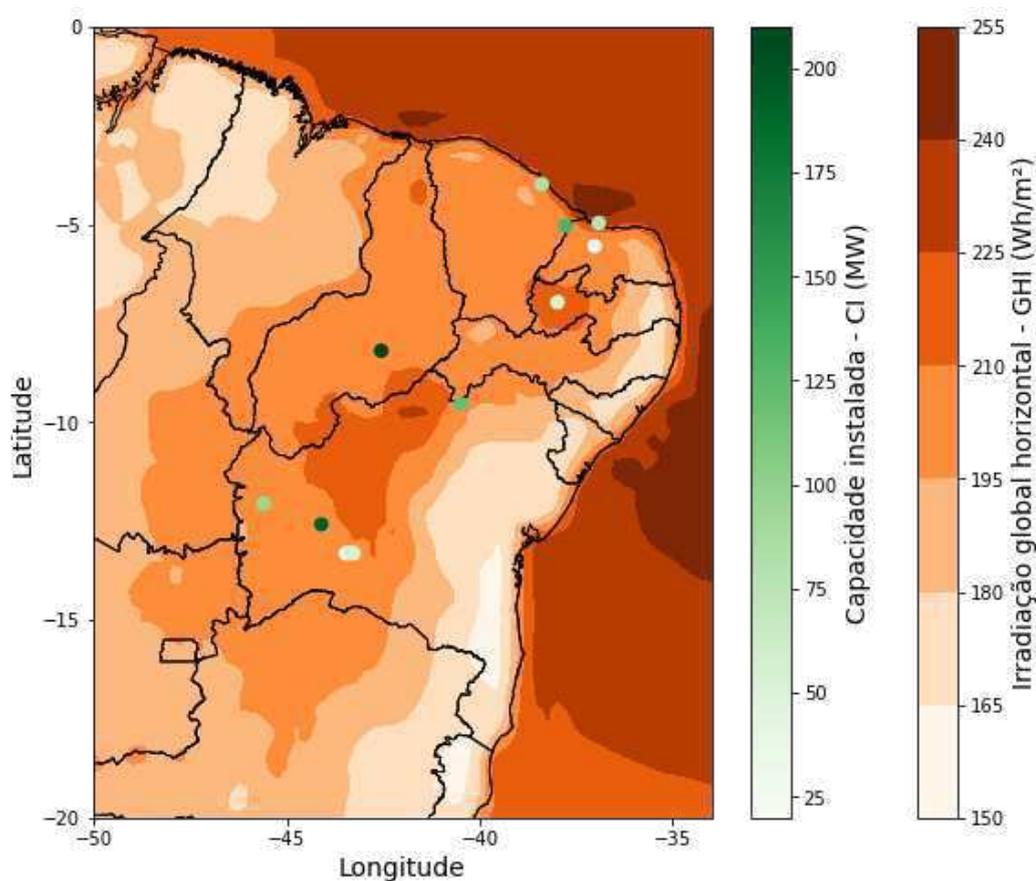


Figura 49. Média horária da GHI para o período de 2009 a 2019 e a CI de energia para cada usina.

Na Figura 50, temos a relação entre a média horária do GHI em Wh/m² e a média de CGE em horários de funcionamento de cada usina, variando entre 0 e 1. Apesar de todas as usinas estarem localizadas em regiões onde o GHI possui um valor médio horário elevado, as que apresentam uma maior produtividade com maiores valores de CGE estão localizadas a Oeste e

Norte da Bahia e no Piauí, próximo de uma região com o GHI chegando a aproximadamente 220 Wh/m². Além disso, são regiões que possuem maiores valores de T2M e SSRD, e menores valores de TCC e TP, como pode ser observado em conjunto com a Figura 55.

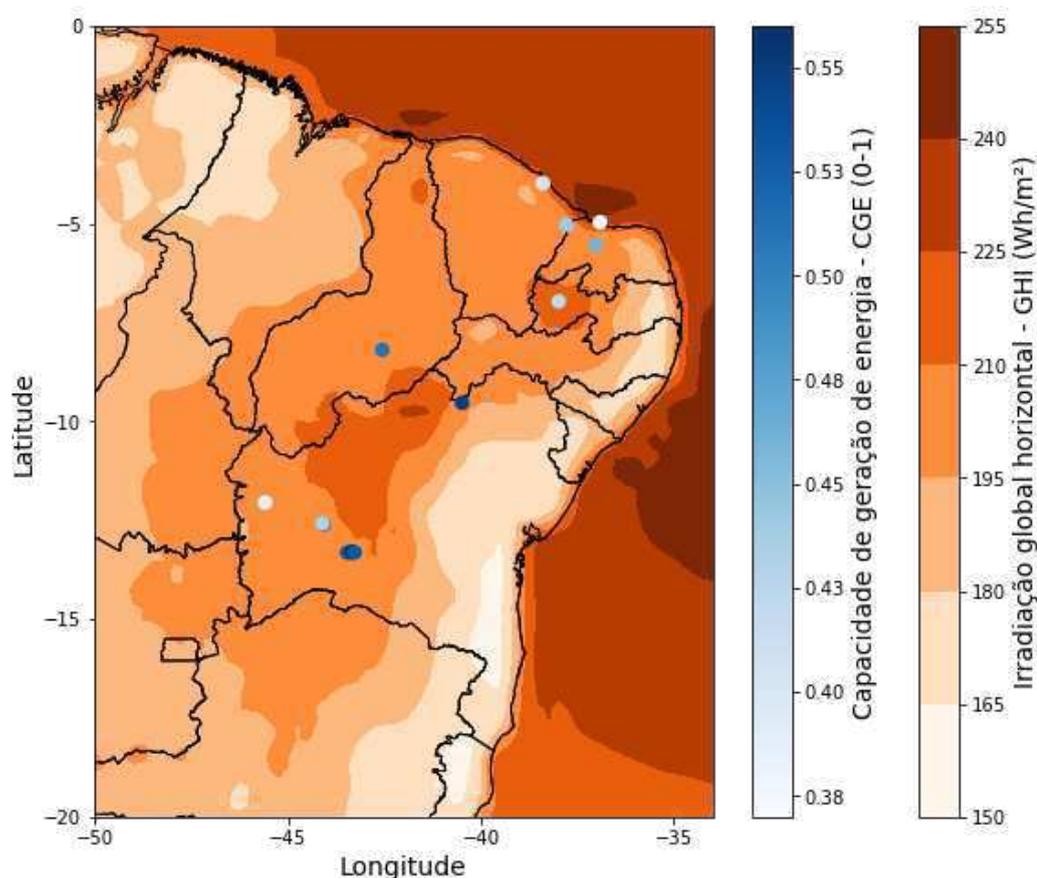


Figura 50. Média horária da GHI para o período de 2009 a 2019 e a CGE média horária para cada usina.

De acordo com a GEV e a média horária do GHI em Wh/m² (Figura 51), as usinas com maior produtividade estão situadas ao Oeste e Norte da Bahia, assim como no estado do Piauí, onde os valores de GHI alcançam cerca de 220 Wh/m². Reforçando esses resultados, um estudo conduzido por Bergamo e Ramos (2022) identificou que os dados de geração de energia do parque solar Bom Jesus da Lapa são diretamente influenciados pela radiação global, a qual chamamos de GHI para os dados do ERA5. Estudos anteriores, como o de Whitaker et al. (1991), também corroboram esse padrão de comportamento.

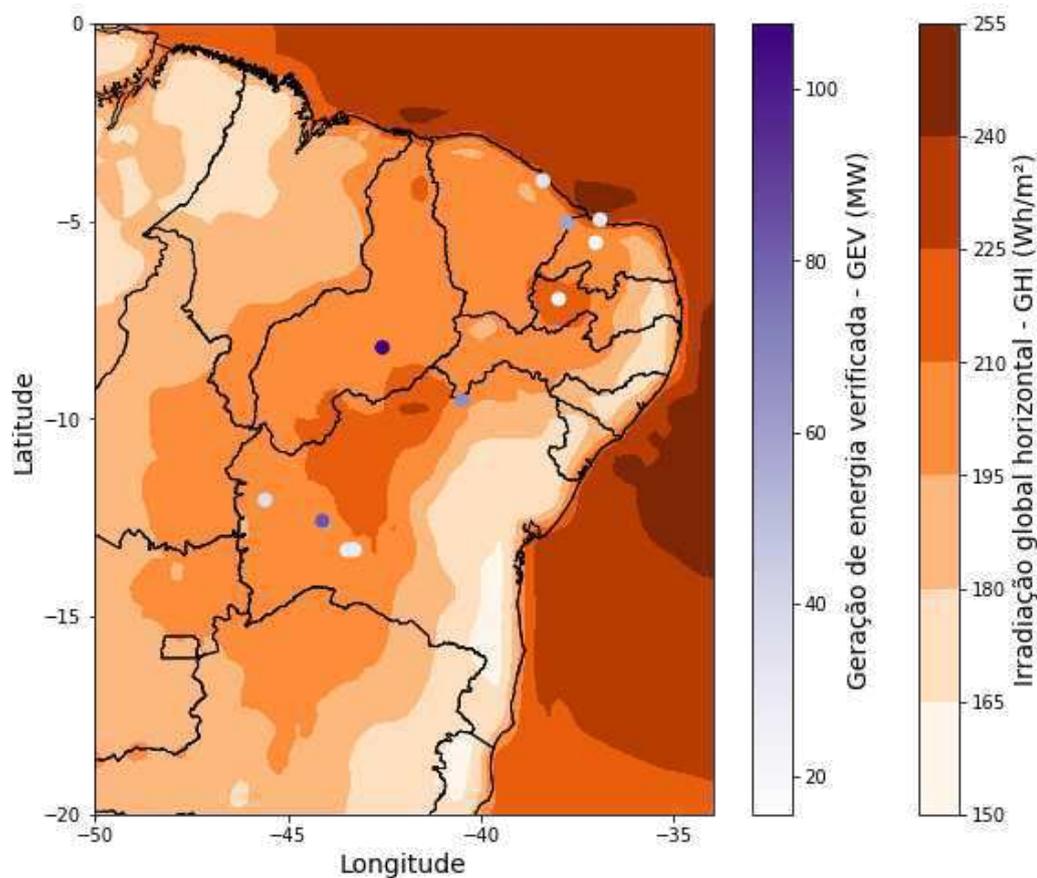


Figura 51. Média horária da GHI para o período de 2009 a 2019 e a GEV média horária para cada usina.

Comparando as variáveis de GEV, CGE e a CI de cada usina, apesar dos maiores valores de CI serem dos Conjuntos Nova Olinda e Ituverava, localizadas respectivamente no Piauí e na Bahia, com valores de 210 e 196 MW, as usinas com maiores médias de GEV e CGE são as do Conjunto Bom Jesus e Lapa, ambas localizadas na Bahia, apresentando, respectivamente, valores médio horário de GEV de 33,54 e 33,85 MW, e valores médio horário de CGE de 0,56 para ambas.

As usinas com menor CI são as do Conjunto BJL e Assú V, localizadas na Bahia e no Rio Grande do Norte. Apesar dos baixos valores, o Conjunto BJL possui valor médio de CGE muito bom, ficando entre as cinco usinas com melhor produtividade em relação à sua CI.

5.4 Aplicação de Deep Learning

5.4.1 Conjunto Bom Jesus

5.4.1.1 Métricas de desempenho

Na Tabela 10, apresentam-se os resultados dos erros RMSE e MAE para o período de treinamento e validação, considerando um tamanho de passo igual a seis. O método LSTM+GRU demonstrou superioridade em relação a todos os outros métodos de DL no conjunto de dados, tanto no treinamento quanto na validação. Em termos quantitativos, os resultados do método para o treinamento incluíram um RMSE de 14.44 e um MAE de 9.61. Para o período de validação, o modelo alcançou um RMSE de 14.29 e um MAE de 9.53.

No entanto, o método CNN exibiu um desempenho menos robusto para o RMSE e MAE, tanto no treinamento quanto na validação. Quantitativamente, para o RMSE, foram de 14.77 para o treinamento e 14.53 para a validação. Para o MAE, os valores quantitativos indicam 10.01 para o treinamento e 9.88 para validação.

Tabela 10. Métricas de avaliação de desempenho para tamanho de passos 6 para o Conjunto Bom Jesus.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	14.77	10.01	14.53	9.88	6
LSTM	14.72	9.97	14.50	9.83	6
GRU	14.70	9.78	14.50	9.72	6
CNN + LSTM	14.69	9.96	14.48	9.83	6
LSTM + GRU	14.44	9.61	14.29	9.53	6
CNN + GRU	14.58	9.80	14.44	9.70	6

Na Tabela 11, são exibidos resultados dos erros RMSE e MAE durante os períodos de treinamento e validação, considerando o tamanho de passos igual a 12. O método GRU destacou-se pela sua superioridade em comparação com todos os outros métodos de DL no conjunto de dados, tanto no treinamento quanto na validação. Em termos quantitativos, os resultados do método para o treinamento registraram um RMSE de 12.67 e um MAE de 8.01. Para o período de validação, o modelo apresentou um RMSE de 12.72 e um MAE de 8.09.

Todavia, o método CNN demonstrou um desempenho menos robusto em termos de RMSE e MAE, tanto no treinamento quanto na validação. Quantitativamente, os resultados para o CNN foram de 13.03 para o RMSE no treinamento e 13.19 para o RMSE na validação; já para o MAE, indicaram valores de 8.79 no treinamento e 8.94 na validação.

Tabela 11. Métricas de avaliação de desempenho para tamanho de passos 12 para o Conjunto Bom Jesus.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	13.03	8.79	13.19	8.94	12
LSTM	12.92	8.38	13.04	8.50	12
GRU	12.67	8.01	12.72	8.09	12
LSTM + CNN	12.90	8.40	13.03	8.51	12
LSTM + GRU	12.76	8.10	12.82	8.20	12
CNN + GRU	12.83	8.33	12.95	8.43	12

Na Tabela 12, temos os resultados dos erros RMSE e MAE durante os períodos de treinamento e validação, considerando o tamanho de passos 24. A combinação dos métodos LSTM+GRU destacou-se como superior a todos os outros métodos de DL no conjunto de dados, para o RMSE. Em termos quantitativos, para o treinamento e validação, apresentou valores respectivos de 11.13 e 11.51. Já para o MAE, durante o treinamento e validação mostrou mais eficiência através da combinação CNN+GRU, com valores respectivos de 6.82 e 7.03.

Contudo, o método CNN apresentou um desempenho menos robusto para o RMSE e MAE no período de treinamento e validação. Quantitativamente, os resultados para o RMSE foram de 11.78 no treinamento e 12.21 na validação. Para o MAE, indicam valores de 8.03 no treinamento e 8.35 na validação.

Tabela 12. Métricas de avaliação de desempenho para tamanho de passos 24 para o Conjunto Bom Jesus.

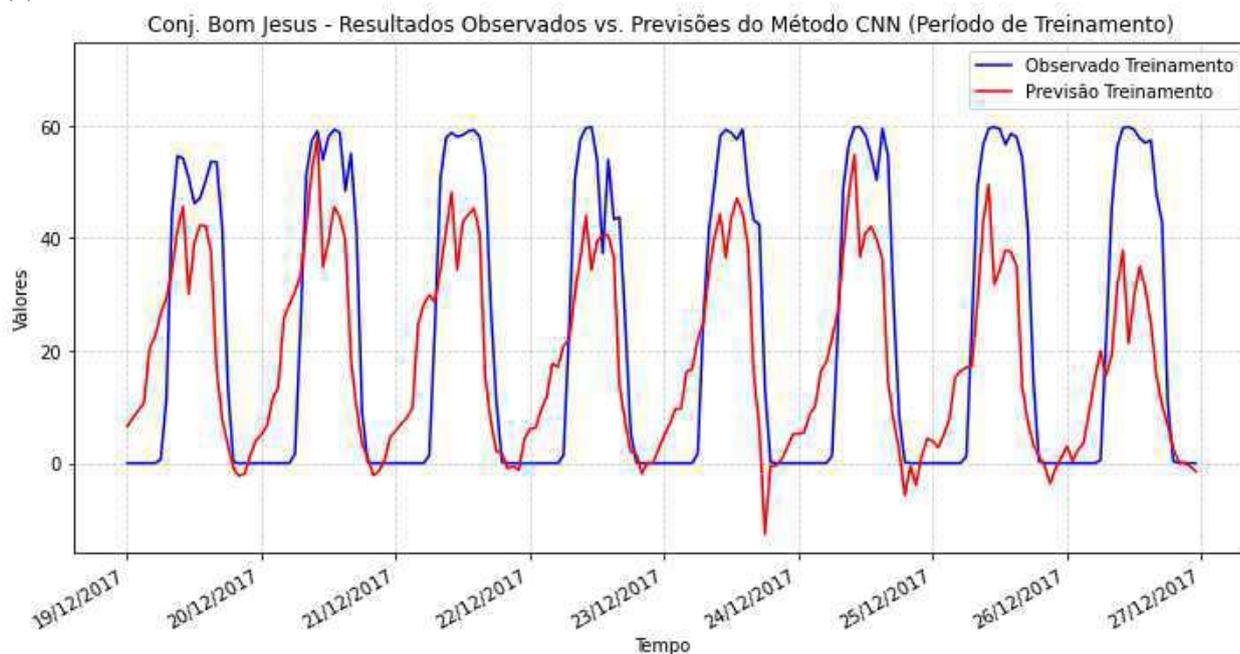
Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	11.78	8.03	12.21	8.35	24
LSTM	11.51	7.51	11.83	7.73	24
GRU	11.20	7.00	11.60	7.26	24
LSTM + CNN	11.54	7.39	11.86	7.62	24
LSTM + GRU	11.13	7.10	11.51	7.35	24
CNN + GRU	11.28	6.82	11.63	7.03	24

5.4.1.2 Validação

Uma análise visual do desempenho das previsões geradas pelos modelos CNN e LSTM+GRU ao longo do treinamento e validação pode ser realizada através das Figuras 52 e 53. Ao comparar minuciosamente os método CNN com LSTM+GRU para o período de treinamento (Figura 52), observa-se que o LSTM+GRU (Figura 52b) se ajusta de maneira mais eficaz ao comportamento dos dados observados se comparados com o CNN (Figura 52a). Essa tendência também é evidente durante o período de validação (Figura 53). Essas observações sugerem que o modelo LSTM+GRU é capaz de realizar prognósticos com uma confiabilidade consideravelmente superior em comparação com o modelo CNN.

Essas observações visuais estão em concordância com os resultados quantitativos obtidos a partir das métricas de desempenho, como RMSE e MAE, que foram calculadas e discutidas anteriormente. A análise visual reforça a conclusão de que o modelo LSTM+GRU supera o modelo CNN em termos de precisão e consistência na tarefa de prognóstico para o conjunto de dados em questão.

(a)



(b)

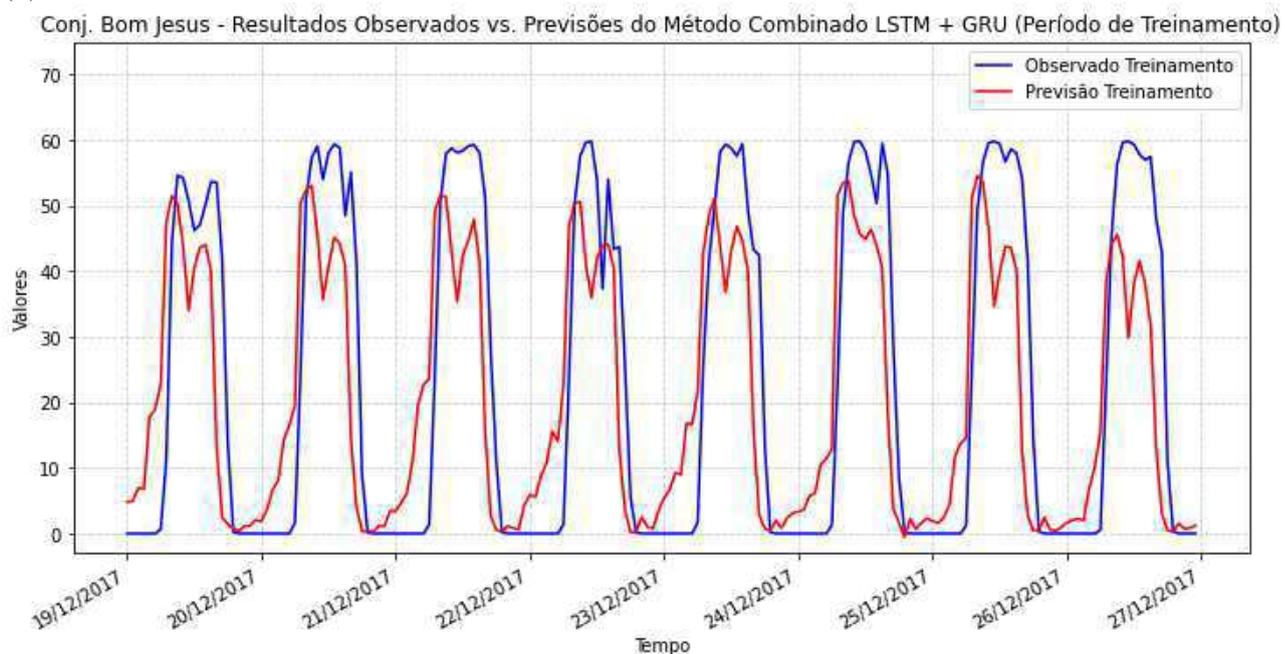
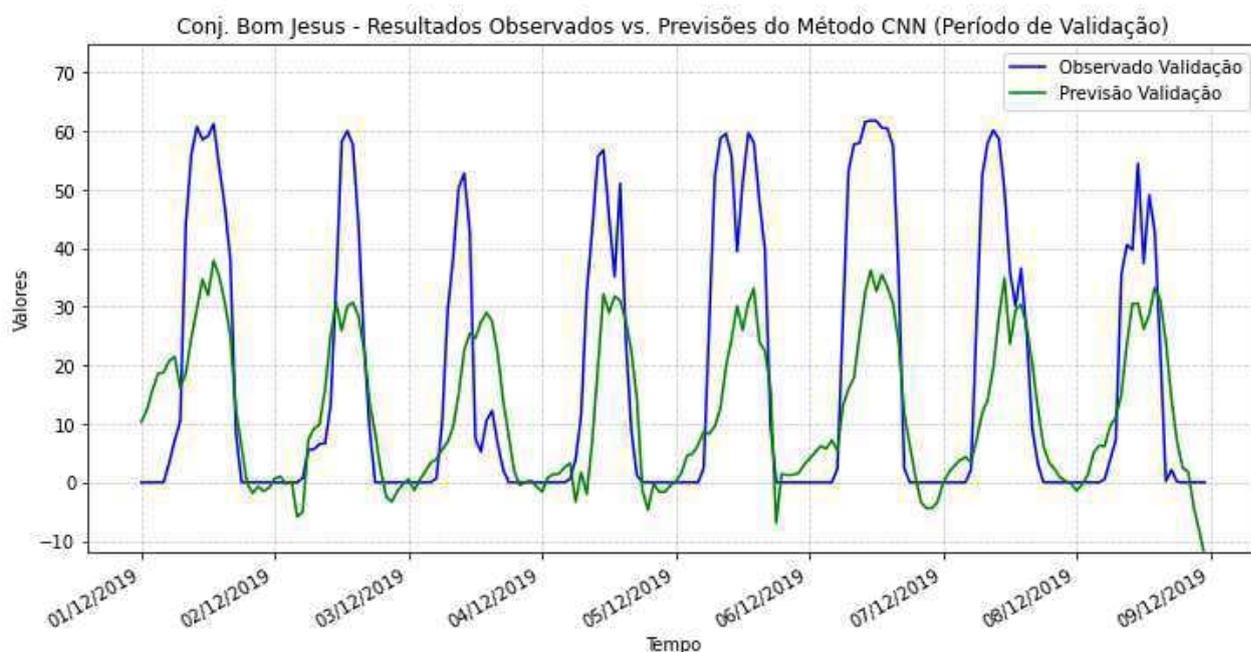


Figura 52. Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e LSTM+GRU (b), para o Conjunto Bom Jesus.

(a)



(b)

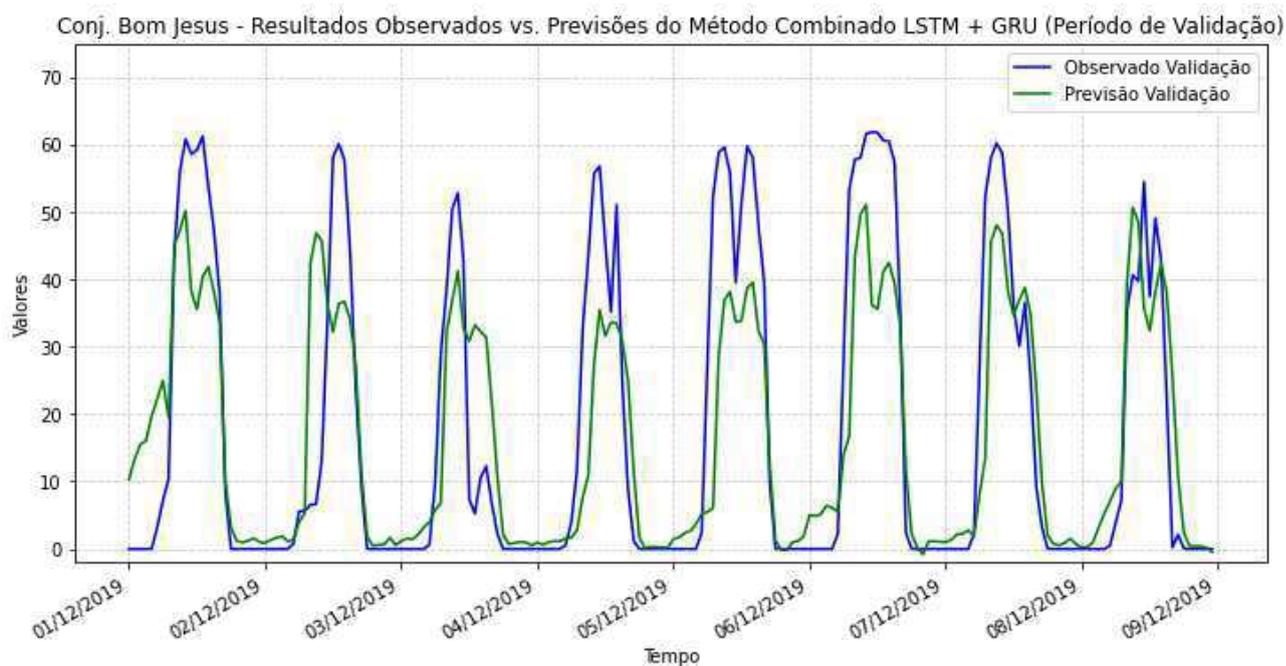


Figura 53. Dados observados e previsão para o período de validação referente aos métodos CNN (a) e LSTM+GRU (b), para o Conjunto Bom Jesus.

Conterato (2022), em uma de suas pesquisas, analisando métricas de desempenho de MAE e RMSE para variáveis meteorológicas como irradiação solar e temperatura para uma estação localizada na Bahia, através de seus resultados quantitativos observou que se comparado alguns métodos de DL, o LSTM e GRU apresentam uma maior eficiência em comparação com o CNN.

5.4.2 Conjunto Horizonte

5.4.2.1 Métricas de desempenho

Para o Conjunto Horizonte, com um tamanho de passo seis (Tabela 13), observa-se que o método CNN se mostra menos eficaz, evidenciado pelos valores mais elevados de 19.30 no treinamento e 19.69 na validação, ambos para o RMSE. No que se refere ao MAE, foram registrados valores de 13.93 no treinamento e 14.38 na validação.

Em contrapartida, os métodos GRU e a combinação CNN+GRU destacam-se como mais satisfatórios. No caso do RMSE, o método combinado CNN+GRU exibe valores de 16.32 no treinamento e 16.33 na validação. Quanto ao MAE, o método GRU demonstra desempenho notável, alcançando valores de 13.29 no treinamento e 13.73 na validação.

Tabela 13. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Horizonte.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	19.30	13.93	19.69	14.38	6
LSTM	18.99	13.75	19.35	14.16	6
GRU	18.96	13.29	19.35	13.73	6
LSTM + CNN	18.97	13.76	19.33	14.14	6
LSTM + GRU	18.87	13.54	19.27	13.97	6
CNN + GRU	18.71	13.48	19.16	13.90	6

Para tamanho de passos doze (Tabela 14), o desempenho do método CNN revelou-se menos robusto em ambas as métricas de desempenho. Em termos de RMSE, registrou-se valores de 16.68 no treinamento e 16.64 na validação, enquanto o MAE apresentou-se com valores de 11.65 no treinamento e 11.69 na validação.

Contrastando com isso, os métodos GRU e a combinação CNN+GRU demonstraram um desempenho superior em comparação com os demais. No que tange ao RMSE, o método combinado CNN+GRU exibiu valores de 16.32 no treinamento e 16.33 na validação. No caso do MAE, o método GRU destacou-se com valores de 10.58 no treinamento e 10.72 na validação.

Tabela 14. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Horizonte.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	16.68	11.65	16.64	11.69	12
LSTM	16.60	10.94	16.51	10.94	12
GRU	16.38	10.58	16.40	10.72	12
LSTM + CNN	16.55	11.06	16.50	11.10	12
LSTM + GRU	16.46	10.99	16.43	11.06	12
CNN + GRU	16.32	10.72	16.33	10.83	12

Com o tamanho de passo de vinte e quatro (Tabela 15), novamente observa-se que o método CNN proporcionou resultados menos eficientes, apresentando valores de RMSE de 14.68 e 14.72 para treinamento e validação, respectivamente. No que diz respeito ao MAE, os valores foram de 10.48 no treinamento e 10.46 na validação.

Por outro lado, os métodos GRU e a combinação LSTM+GRU destacaram-se com resultados mais robustos. Para o RMSE, o método GRU sobressaiu-se com valores de 13.86 no treinamento e 13.98 na validação. Já em relação ao MAE, o método LSTM+GRU demonstrou desempenho notável, alcançando valores de 8.49 tanto no treinamento quanto na validação.

Tabela 15. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Horizonte.

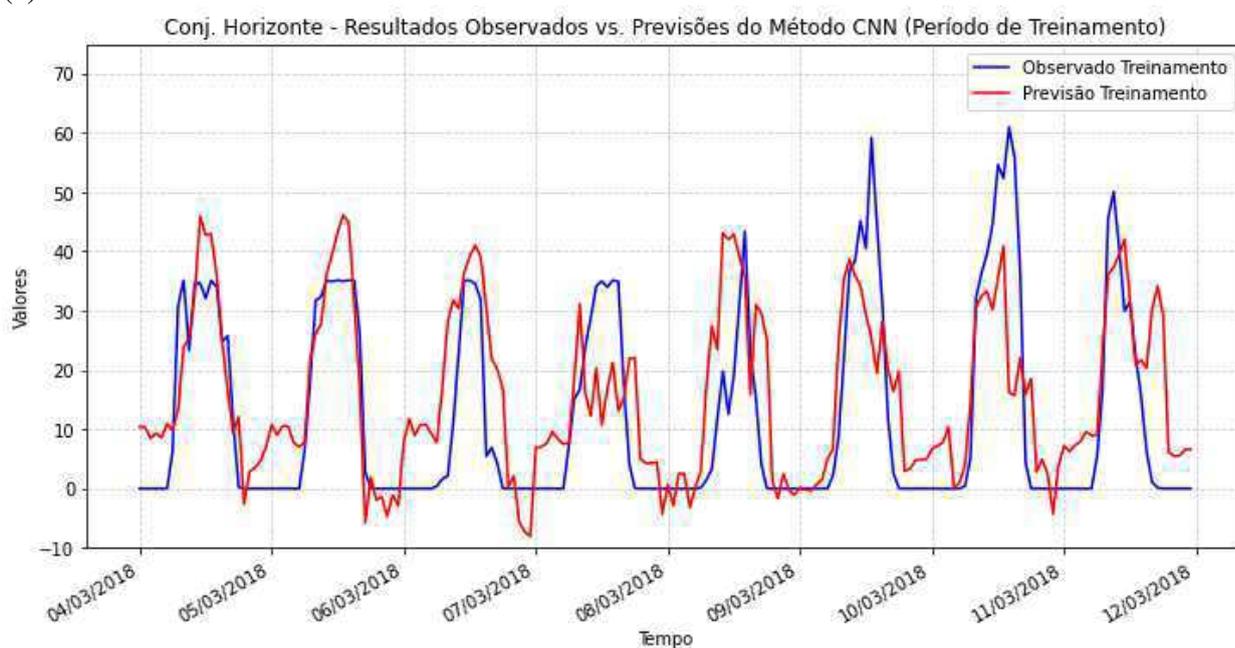
Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	14.68	10.48	14.72	10.46	24
LSTM	14.13	9.06	14.14	9.01	24
GRU	13.86	8.51	13.98	8.50	24
LSTM + CNN	14.12	9.06	14.13	9.01	24
LSTM + GRU	13.87	8.49	13.99	8.49	24
CNN + GRU	14.01	8.94	14.12	8.93	24

5.4.2.2 Validação

Nas Figuras 54 e 55, é possível realizar uma análise visual do desempenho das previsões dos métodos CNN e GRU, tanto para o período de treinamento quanto para a validação. Ao realizar a comparação, nota-se que, durante o período de treinamento (Figura 54), o método GRU (Figura 54b) exibe um comportamento mais próximo dos dados observados, ajustando-se de maneira mais eficaz do que o método CNN (Figura 54a). Essa mesma tendência é evidenciada na Figura 55, onde o método GRU (Figura 55b) novamente se adapta de forma mais precisa aos dados observados do que o CNN (Figura 55a).

Portanto, as observações sugerem que o método GRU realiza previsões mais robustas, adequando-se de maneira mais eficiente aos dados observados. Além disso, as análises visuais estão em concordância com os resultados quantitativos das métricas de desempenho RMSE e MAE, fortalecendo a conclusão de que o método GRU é mais eficiente do que o CNN para o Conjunto Horizonte.

(a)



(b)

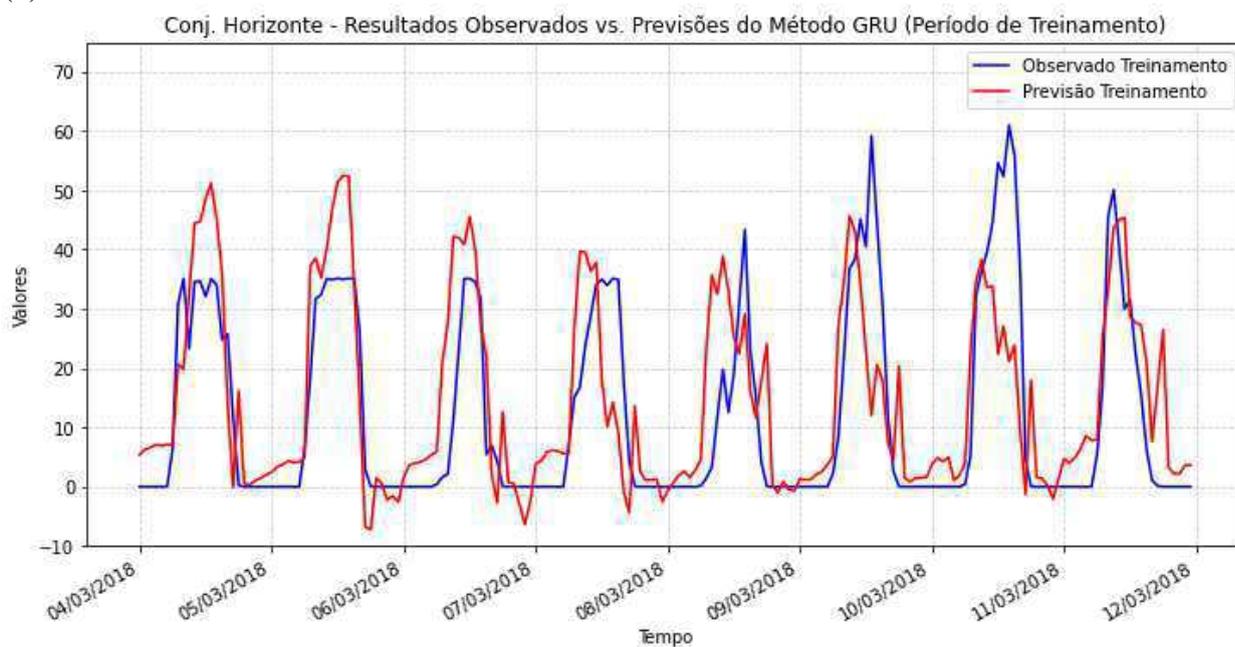
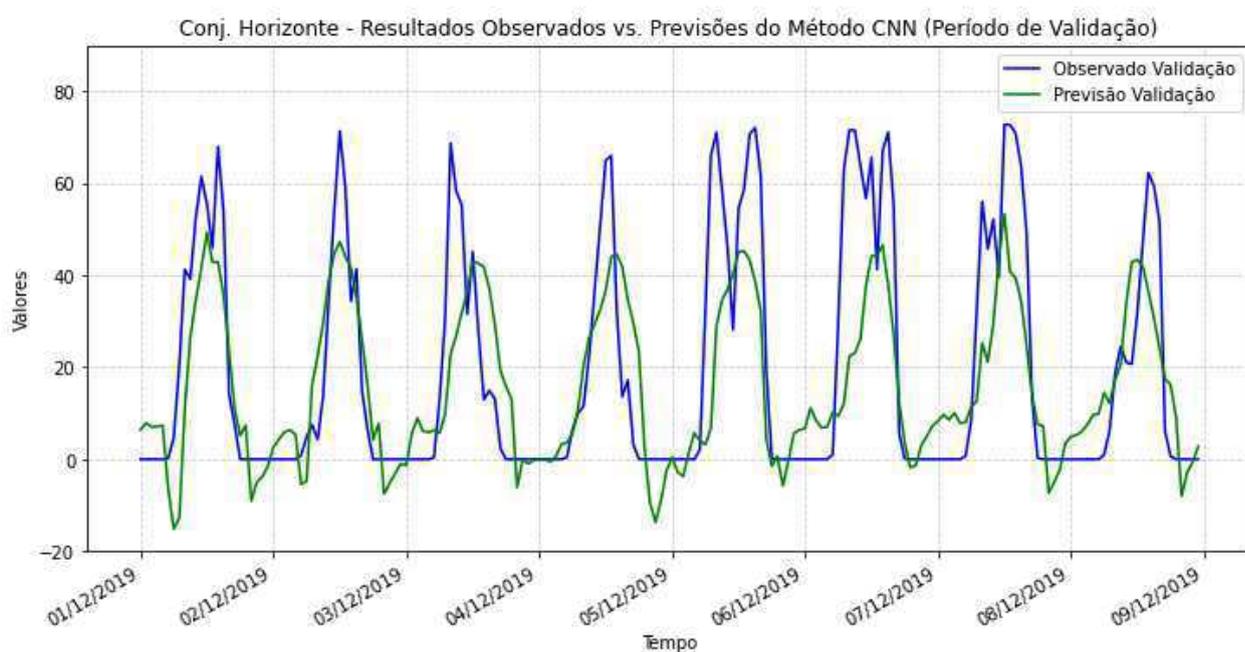


Figura 54. Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Horizonte.

(a)



(b)

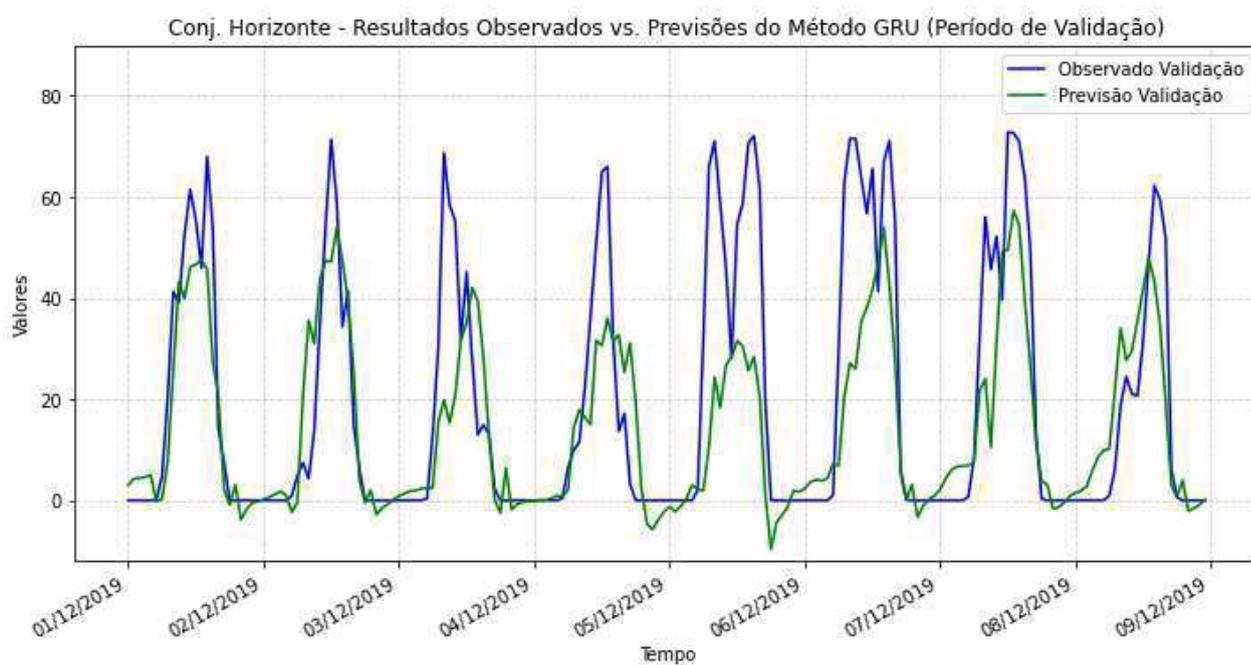


Figura 55. Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Horizonte.

5.4.3 Conjunto Nova Olinda

5.4.3.1 Métricas de desempenho

Para o Conjunto Nova Olinda, considerando um tamanho de passo seis (Tabela 16), percebe-se que o método CNN revela-se menos eficiente, como evidenciado pelos valores mais elevados de 50.74 no treinamento e 50.21 na validação para o RMSE. Em relação ao MAE, foram registrados valores de 36.91 no treinamento e 36.53 na validação.

Por outro lado, os métodos combinados LSTM+GRU e CNN+GRU sobressaem como opções mais satisfatórias. No que diz respeito ao RMSE, o método combinado CNN+GRU apresenta valores de 48.73 no treinamento e 48.47 na validação. Quanto ao MAE, o método LSTM+GRU demonstra um desempenho notável, alcançando valores de 33.70 no treinamento e 33.66 na validação.

Tabela 16. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	50.74	36.91	50.21	36.53	6
LSTM	49.61	35.29	48.94	34.88	6
GRU	48.90	34.08	48.58	34.00	6
LSTM + CNN	49.89	36.49	49.30	36.04	6
LSTM + GRU	48.83	33.70	48.50	33.66	6
CNN + GRU	48.73	34.23	48.47	34.06	6

Para tamanho de passos doze (Tabela 17), o desempenho do método CNN revela-se menos robusto em ambas as métricas de desempenho. No que diz respeito ao RMSE, foram registrados valores de 43.49 no treinamento e 44.02 na validação, enquanto o MAE apresentou-se com valores de 29.32 no treinamento e 30.07 na validação.

Em contraste, os métodos GRU e a combinação CNN+GRU demonstraram desempenho superior. No caso do RMSE, o método combinado CNN+GRU exibiu valores de 42.27 no treinamento e 42.70 na validação. Para o MAE, o método GRU destacou-se com valores de 27.16 no treinamento e 27.82 na validação.

Tabela 17. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	43.49	29.32	44.02	30.07	12
LSTM	43.29	28.02	43.59	28.58	12
GRU	42.64	27.16	42.93	27.82	12
LSTM + CNN	43.35	28.62	43.64	29.23	12
LSTM + GRU	42.84	27.22	43.19	27.89	12
CNN + GRU	42.57	27.46	42.70	28.02	12

Com o tamanho de passo de vinte e quatro (Tabela 18), novamente constatamos que o método CNN exibiu resultados menos eficientes, apresentando valores de RMSE de 34.89 e 34.95 para treinamento e validação, respectivamente. No que concerne ao MAE, registrou-se 22.47 no treinamento e 22.75 na validação.

Por outro lado, o método GRU destacou-se com resultados mais eficientes em comparação com os demais. Em relação ao RMSE, o método GRU sobressaiu-se com valores de 32.74 no treinamento e 32.59 na validação. Quanto ao MAE, o método alcançou valores de 19.15 no treinamento e 19.35 na validação.

Tabela 18. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	34.89	22.47	34.95	22.75	24
LSTM	33.98	21.94	33.89	22.10	24
GRU	32.74	19.15	32.59	19.35	24
LSTM + CNN	34.14	21.71	34.09	21.90	24
LSTM + GRU	32.82	19.94	33.04	20.34	24
CNN + GRU	33.32	21.17	33.31	21.34	24

5.4.3.2 Validação

É possível realizar uma análise visual do desempenho das previsões geradas pelos modelos CNN e GRU ao longo das fases de treinamento e validação, utilizando as Figuras 56 e 57. Ao analisar detalhadamente os métodos CNN e GRU durante o período de treinamento (Figura 56), percebe-se que o GRU (Figura 56b) se adapta de maneira mais eficiente ao comportamento dos dados observados em comparação com o CNN (Figura 56a). Essa tendência se mantém durante o período de validação (Figura 57). Essas observações sugerem que o modelo GRU é capaz de realizar previsões com uma confiabilidade consideravelmente superior em comparação com o modelo CNN. Essas conclusões visuais coincidem com os resultados quantitativos obtidos por meio das métricas de desempenho, que foram previamente calculadas e discutidas.

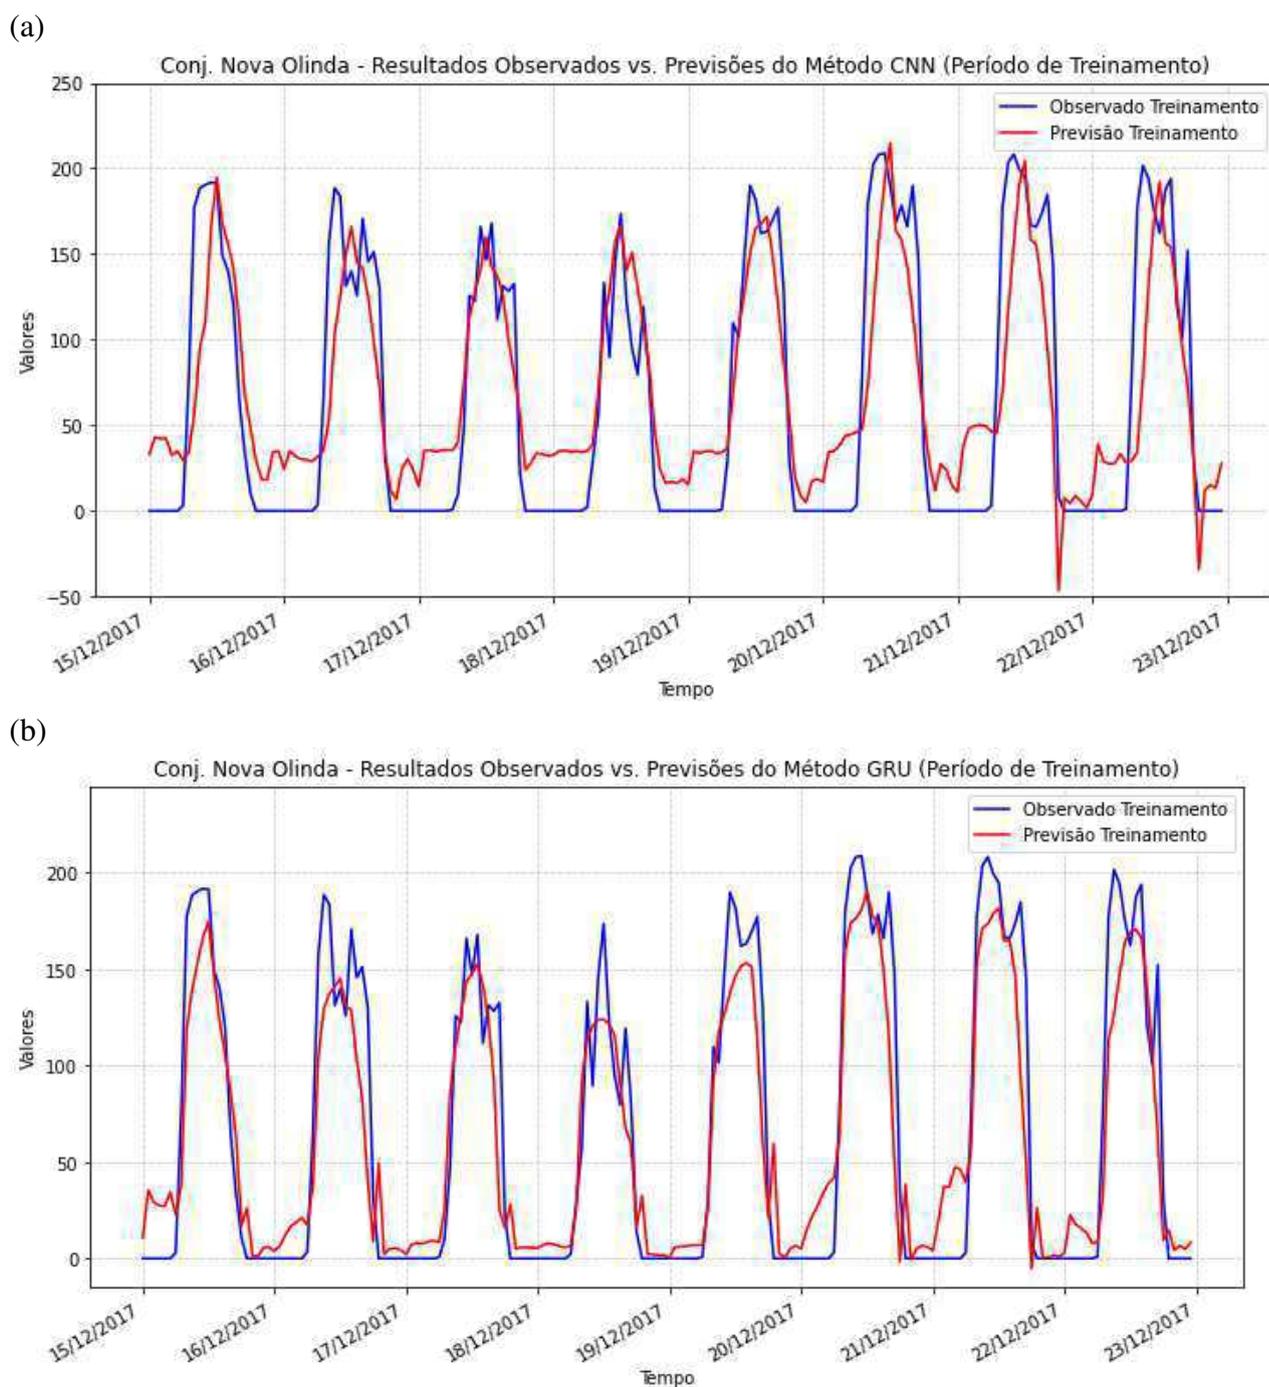
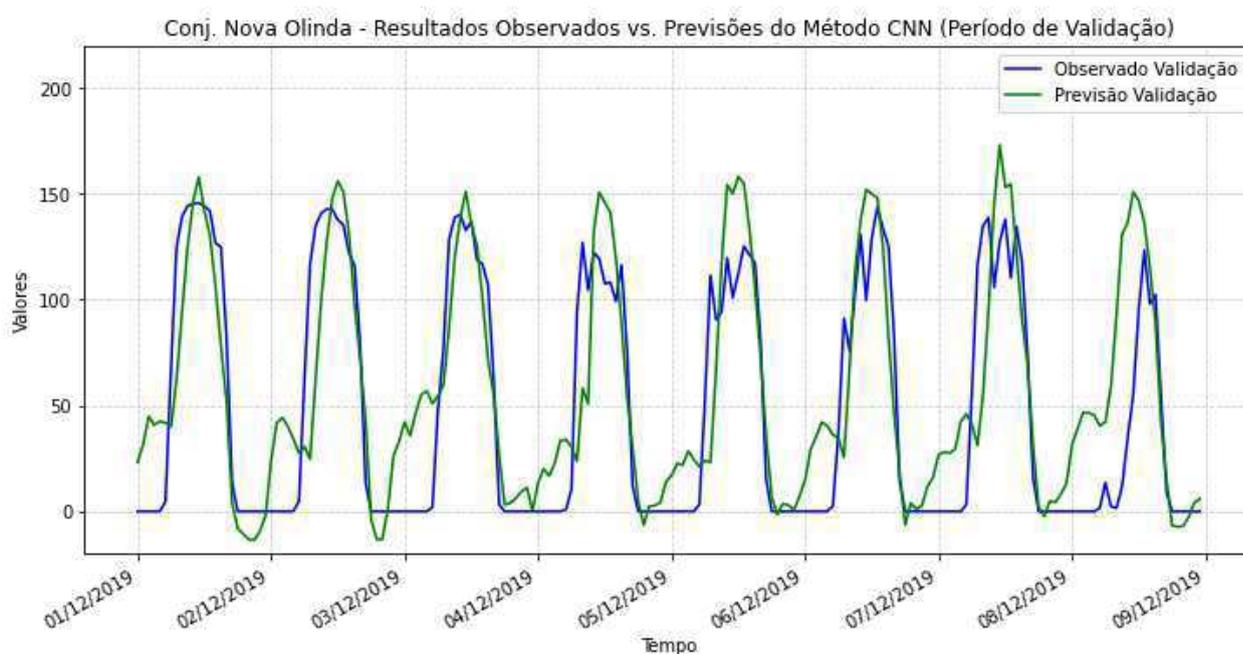


Figura 56. Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Nova Olinda.

(a)



(b)

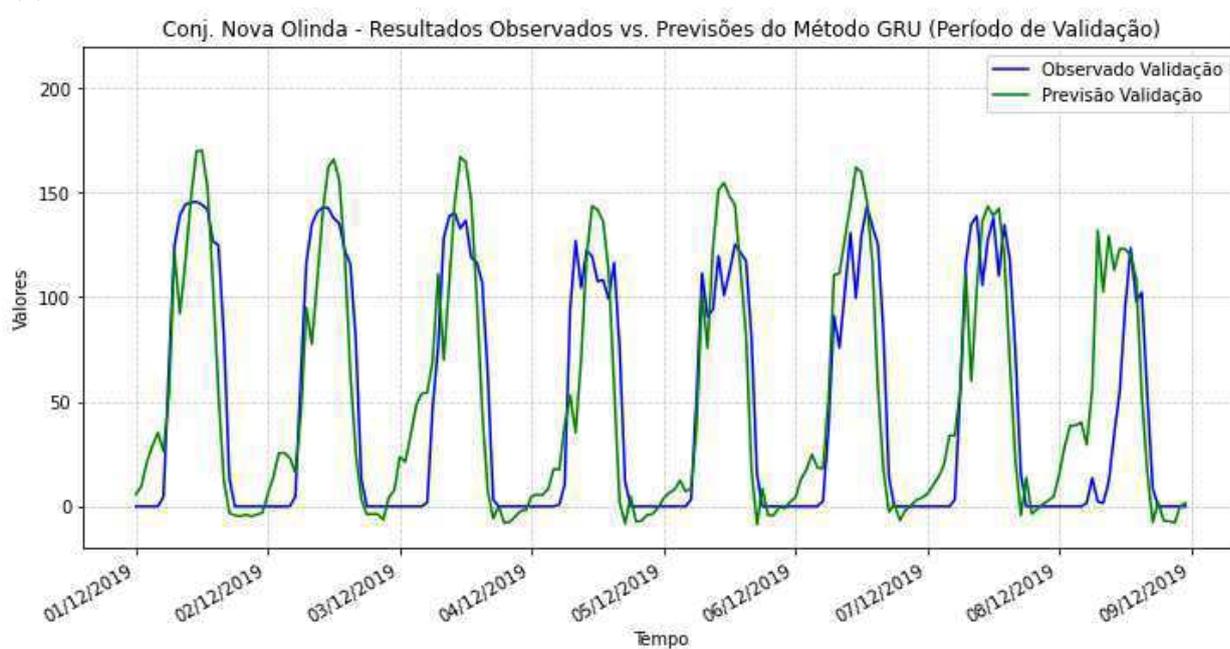


Figura 57. Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Nova Olinda.

5.4.4 Conjunto Rio Alto

5.4.4.1 Métricas de desempenho

Os resultados dos erros RMSE e MAE para o Conjunto Rio Alto durante o período de treinamento e validação, considerando um tamanho de passo igual a seis, são apresentados na Tabela 19. O método GRU demonstra superioridade em relação a todos os outros métodos de DL no conjunto de dados, tanto durante o treinamento quanto na validação. Em termos quantitativos, os resultados do método para o treinamento incluem um RMSE de 10.05 e um MAE de 6.47. Durante o período de validação, o modelo atinge um RMSE de 10.14 e um MAE de 6.59. Além disso, o método combinado LSTM+GRU também mostra superioridade para o MAE, com um valor de 6.59 durante o período de validação.

No entanto, o método CNN exibe um desempenho menos robusto tanto para o RMSE quanto para o MAE. Em termos quantitativos, os valores para o RMSE são de 14.77 no treinamento e 14.53 na validação. Para o MAE, os valores indicam 10.01 no treinamento e 9.88 na validação.

Tabela 19. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	10.48	7.17	10.82	7.36	6
LSTM	10.30	7.02	10.39	7.09	6
GRU	10.05	6.47	10.14	6.59	6
LSTM + CNN	10.25	6.92	10.36	7.00	6
LSTM + GRU	10.09	6.48	10.18	6.59	6
CNN + GRU	10.16	6.64	10.25	6.76	6

Na Tabela 20, são apresentados os resultados dos erros RMSE e MAE durante os períodos de treinamento e validação, considerando tamanho de passos igual a 12. Os métodos GRU e a combinação LSTM+GRU destacaram-se pela sua superioridade. Em termos quantitativos, no que diz respeito ao RMSE, o método LSTM+GRU sobressaiu-se com valores de 9.48 para o período de treinamento e 9.53 para a validação. Quanto ao MAE, foi o método GRU que demonstrou superioridade, registrando valores de 5.92 no treinamento e 5.96 na validação.

Por outro lado, o método CNN+LSTM apresentou desempenho menos robusto em termos de RMSE, com valores de 9.78 no treinamento e 9.81 na validação. Para o MAE, o método CNN evidenciou um desempenho menos robusto, tanto no treinamento quanto na validação, com valores respectivos de 6.51 e 6.53.

Tabela 20. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.72	6.51	9.77	6.53	12
LSTM	9.77	6.28	9.82	6.31	12
GRU	9.49	5.92	9.59	5.96	12
LSTM + CNN	9.78	6.45	9.81	6.45	12
LSTM + GRU	9.48	6.06	9.53	6.07	12
CNN + GRU	9.70	6.19	9.80	6.26	12

Na Tabela 21, são apresentados os resultados dos erros RMSE e MAE durante os períodos de treinamento e validação, considerando o tamanho de passo igual a 24. O método GRU destacou-se como superior a todos os outros métodos, tanto para o RMSE quanto para o MAE. Em termos quantitativos, os valores de RMSE foram de 7.05 e 7.06 para treinamento e validação, respectivamente. No que diz respeito ao MAE, durante o treinamento e a validação, foram registrados valores respectivos de 4.36 e 4.40.

Entretanto, o método CNN apresentou um desempenho menos robusto em termos de RMSE e MAE durante o período de treinamento e validação. Em termos quantitativos, os resultados para o RMSE foram de 7.98 no treinamento e 8.09 na validação. Quanto ao MAE, indicaram-se valores de 5.43 no treinamento e 5.61 na validação.

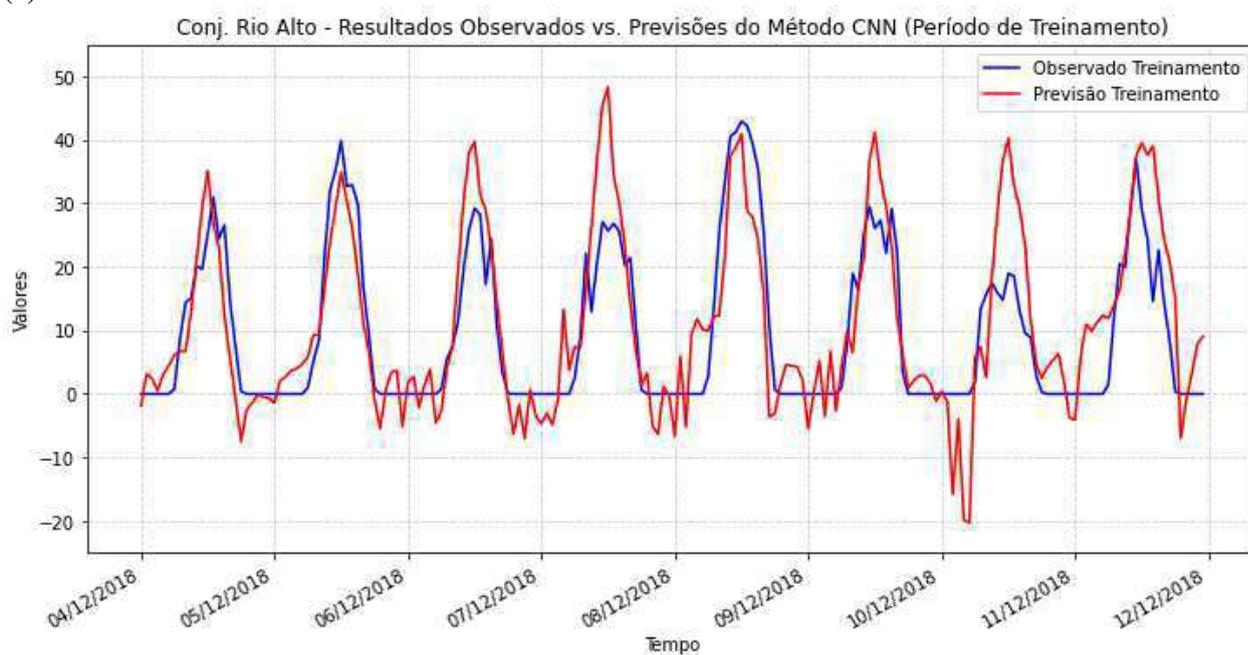
Tabela 21. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	7.98	5.43	8.09	5.61	24
LSTM	7.82	5.15	7.86	5.26	24
GRU	7.05	4.36	7.06	4.40	24
LSTM + CNN	7.75	5.05	7.79	5.16	24
LSTM + GRU	7.24	4.86	7.33	4.97	24
CNN + GRU	7.52	4.57	7.63	4.65	24

5.4.4.2 Validação

Realizando uma análise visual do desempenho das previsões geradas pelos modelos CNN e GRU ao longo do treinamento e validação pode ser realizada através das Figuras 58 e 59, é perceptível que o GRU (Figura 58b) se ajusta de maneira mais eficaz ao comportamento dos dados observados em comparação com o CNN (Figura 58a). Essa tendência também se manifesta durante o período de validação (Figura 59). Essas observações indicam que o modelo GRU é capaz de realizar previsões com uma confiabilidade consideravelmente superior em comparação com o modelo CNN. Essas conclusões visuais alinham-se com os resultados quantitativos obtidos a partir das métricas de desempenho, como RMSE e MAE, que foram previamente calculadas e discutidas.

(a)



(b)

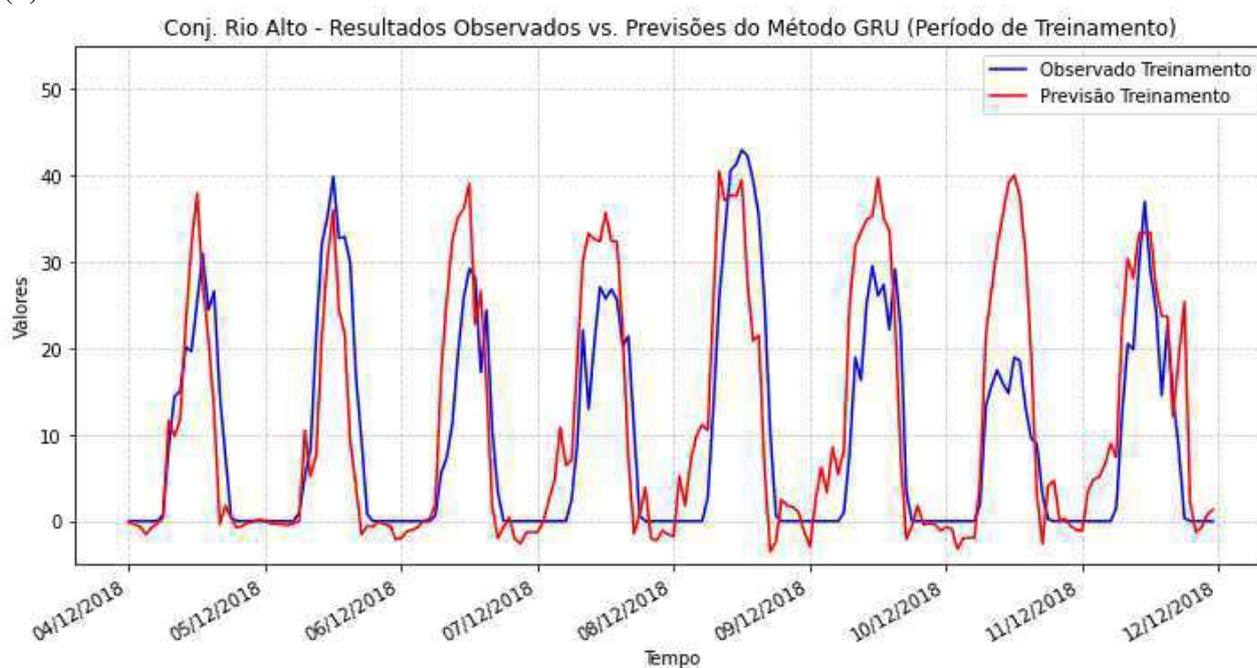


Figura 58. Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Rio Alto.

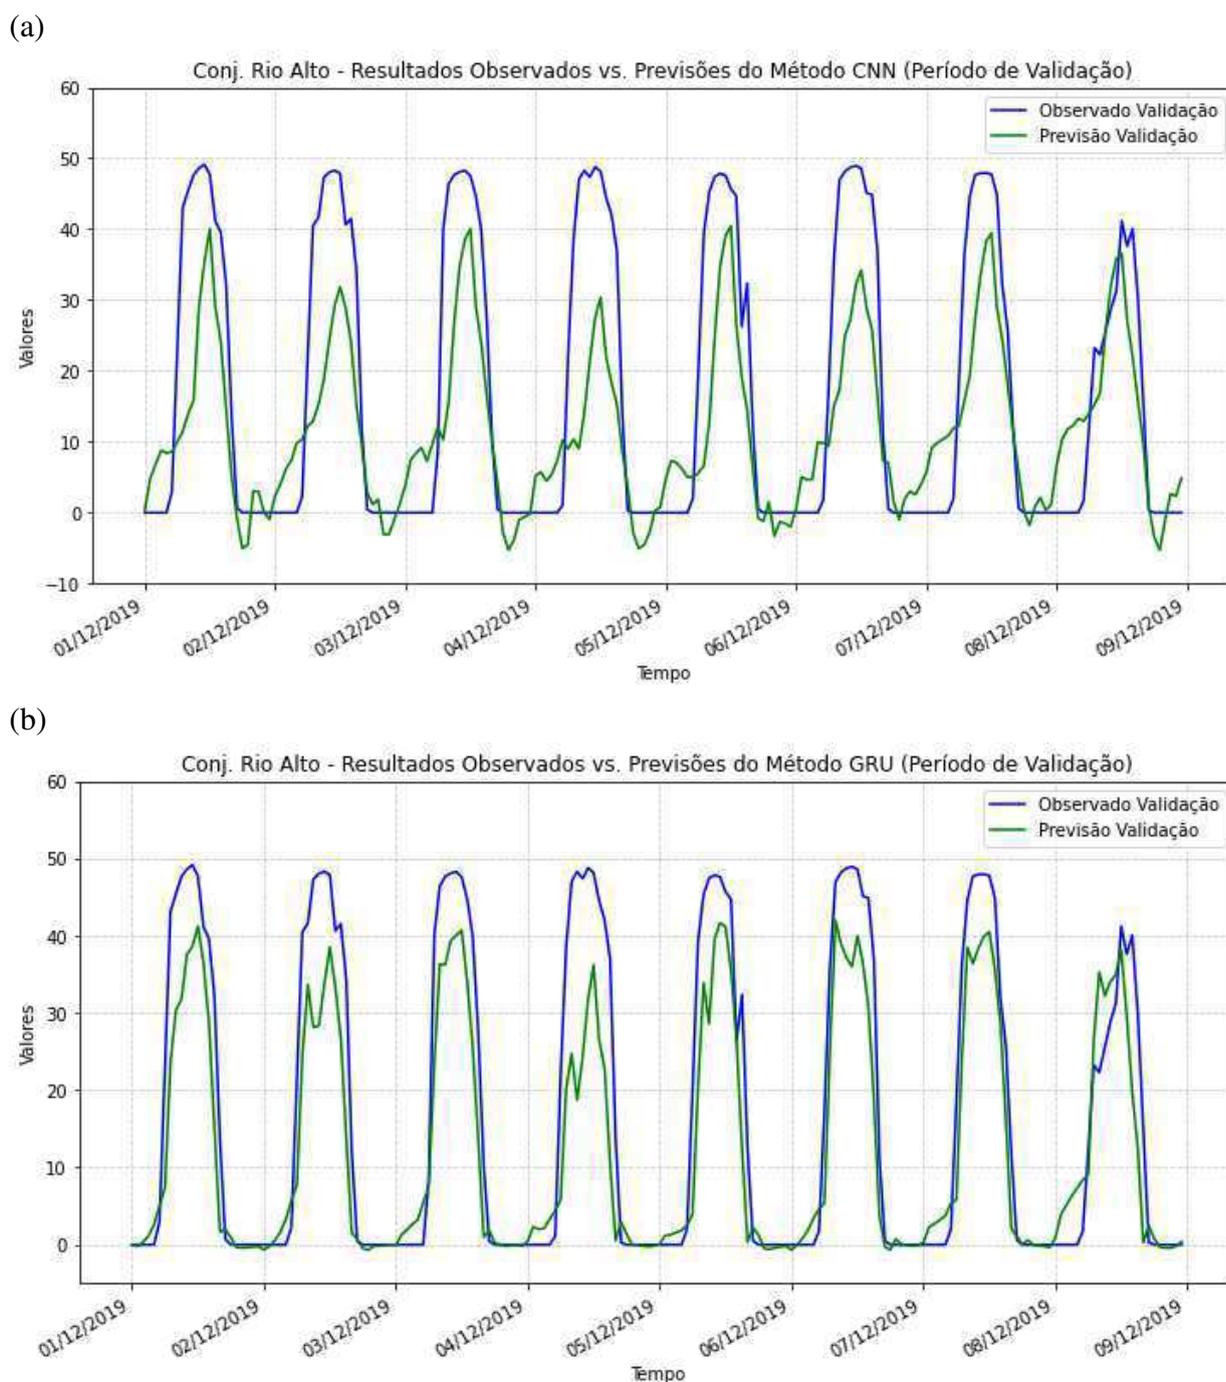


Figura 59. Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Rio Alto.

5.4.5 Conjunto Sol do Futuro

5.4.5.1 Métricas de desempenho

No Conjunto Sol do Futuro, considerando o tamanho de passo seis (Tabela 22), evidencia-se que o método CNN demonstra eficiência inferior. No que se refere ao RMSE, destaca-se com valores de 17.11 no treinamento e 17.31 na validação. Em relação ao MAE, apresenta valores de 13.61 no treinamento e 13.64 na validação.

Em contrapartida, o método GRU se destaca como uma opção mais satisfatória. Quanto ao RMSE, o método apresenta valores de 15.40 no treinamento e 15.39 na validação. No que diz respeito ao MAE, demonstra um desempenho sólido, alcançando valores de 10.72 no treinamento e 10.61 na validação.

Tabela 22. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	17.11	13.61	17.31	13.64	6
LSTM	16.71	13.24	16.52	12.98	6
GRU	15.40	10.72	15.39	10.61	6
LSTM + CNN	16.45	12.79	16.33	12.54	6
LSTM + GRU	15.52	11.13	15.61	11.13	6
CNN + GRU	15.72	11.01	15.86	10.96	6

Considerando um intervalo de passo doze (Tabela 23), observa-se que os métodos LSTM e a combinação LSTM+CNN revelam-se menos eficazes. Em relação ao RMSE, o LSTM destaca-se com valores de 13.07 no treinamento e 13.23 na validação. No que diz respeito ao MAE, a combinação LSTM+CNN apresenta valores de 8.35 no treinamento e 8.44 na validação.

Por outro lado, os métodos GRU e LSTM+GRU destacam-se como opções mais satisfatórias. No que tange ao RMSE, o método combinado LSTM+GRU exibe valores de 11.95 no treinamento e 11.92 na validação. Quanto ao MAE, o método GRU demonstra um desempenho sólido, alcançando valores de 7.01 no treinamento e 6.95 na validação. Vale destacar que o método LSTM+GRU também se sobressai no MAE durante o período de treinamento, registrando um valor de 7.01.

Tabela 23. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	12.73	8.15	13.02	8.29	12
LSTM	13.07	8.33	13.23	8.40	12
GRU	12.15	7.01	12.04	6.95	12
LSTM + CNN	13.01	8.35	13.16	8.44	12
LSTM + GRU	11.95	7.01	11.92	6.98	12
CNN + GRU	12.90	7.36	12.82	7.30	12

Com um tamanho de passo vinte e quatro (Tabela 24), o método CNN apresentou resultados menos eficientes, registrando valores de RMSE de 9.04 e 9.12 para treinamento e validação, respectivamente. No que diz respeito ao MAE, foram registrados 5.61 no treinamento e 5.64 na validação.

Por outro lado, o método CNN+GRU destacou-se com resultados mais eficientes em comparação com os demais. Em relação ao RMSE, o método sobressaiu-se com valores de 8.26 no treinamento e 8.24 na validação. Quanto ao MAE, o método alcançou valores de 4.78 no treinamento e 4.71 na validação.

Tabela 24. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.04	5.61	9.12	5.64	24
LSTM	8.45	5.02	8.44	4.95	24
GRU	8.31	5.10	8.30	5.07	24
LSTM + CNN	8.43	4.99	8.42	4.93	24
LSTM + GRU	8.37	4.98	8.39	4.96	24
CNN + GRU	8.26	4.78	8.24	4.71	24

5.4.5.2 Validação

Ao analisar visualmente o desempenho das previsões geradas pelos modelos CNN e GRU ao longo das fases de treinamento e validação (Figuras 60 e 61), observa-se uma diferença notável. Durante o período de treinamento (Figura 60), o GRU (Figura 60b) demonstra uma previsão mais próxima dos valores observados em comparação com o CNN (Figura 60a). Essa tendência persiste durante o período de validação (Figura 61). As observações visuais estão alinhadas com os resultados quantitativos obtidos por meio das métricas de desempenho.

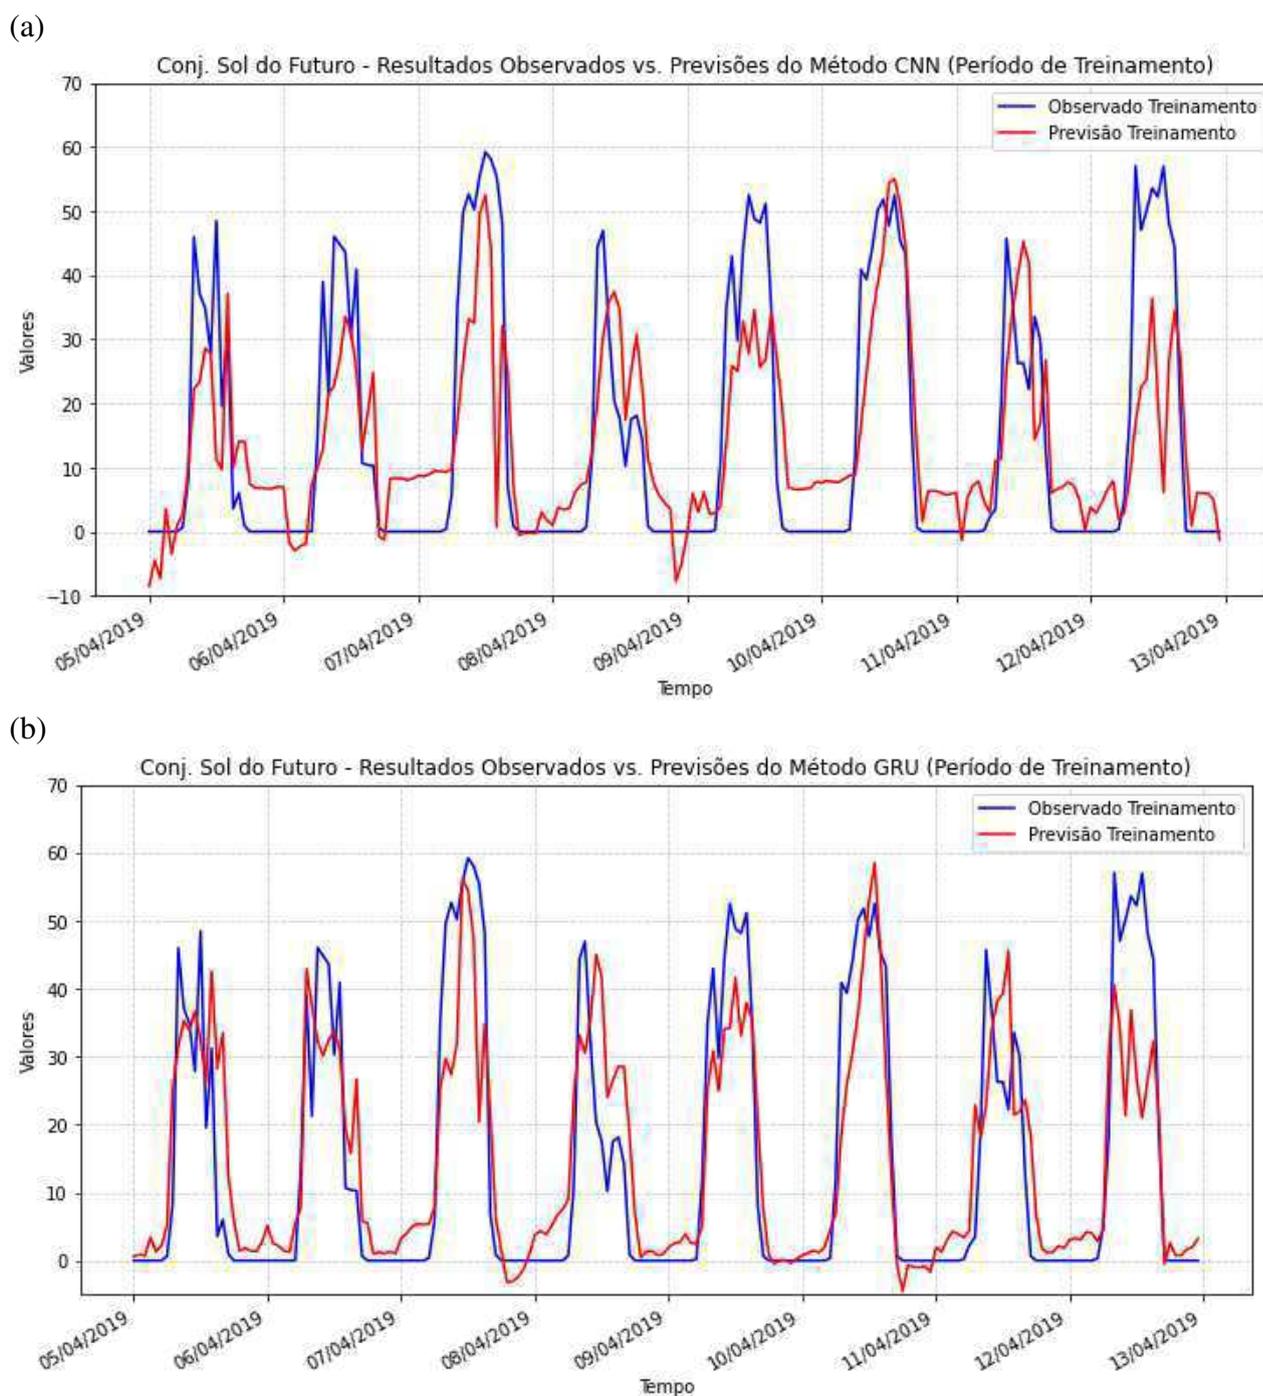
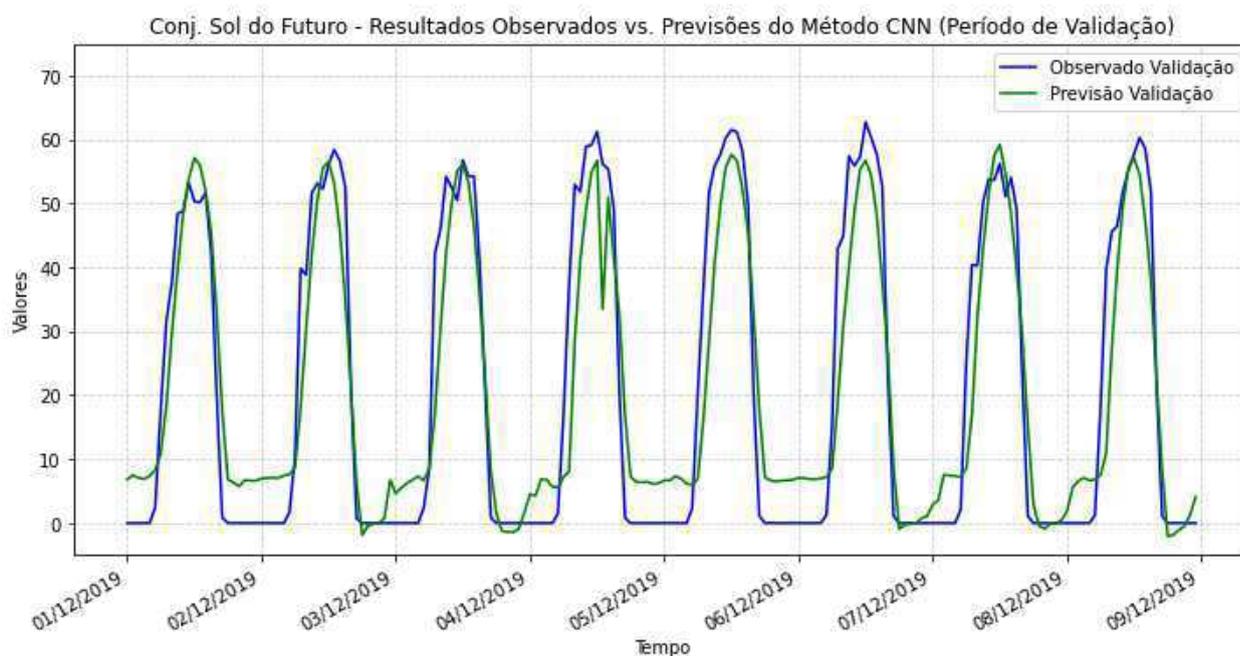


Figura 60. Dados observados e previsão para o período de treinamento referente aos métodos CNN (a) e GRU (b), para o Conjunto Sol do Futuro.

(a)



(b)

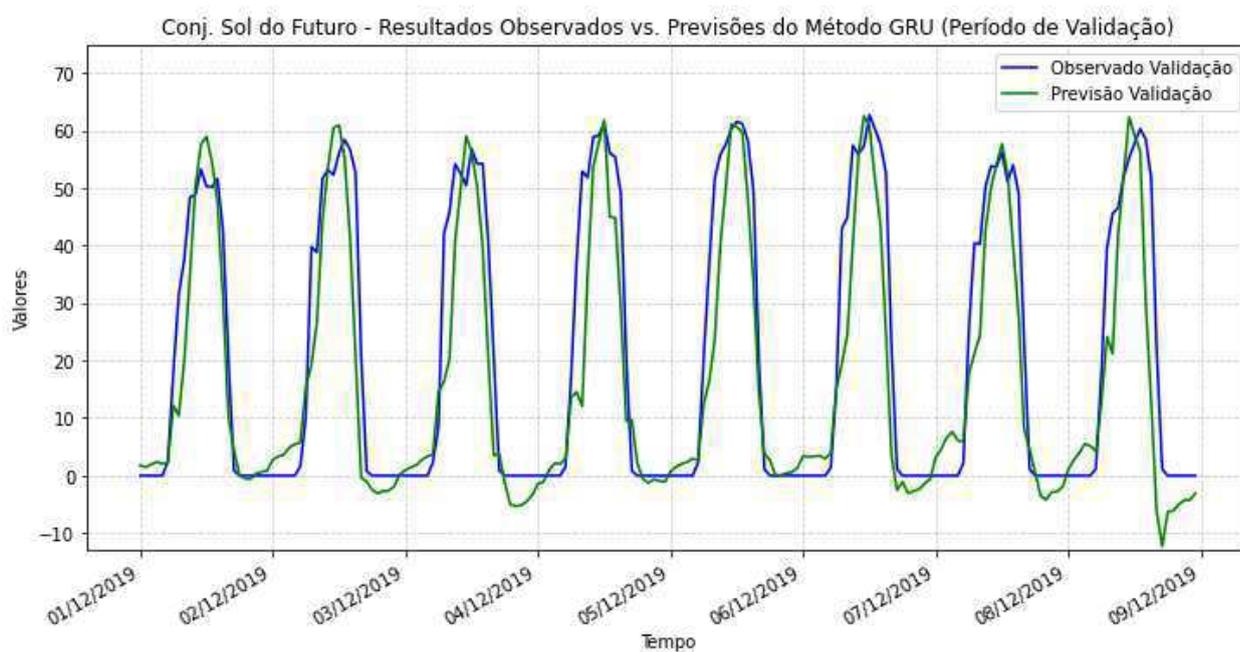


Figura 61. Dados observados e previsão para o período de validação referente aos métodos CNN (a) e GRU (b), para o Conjunto Sol do Futuro.

6. CONCLUSÕES

De acordo com os objetivos propostos, esta pesquisa apresenta as seguintes conclusões:

- Para os dados provenientes da estação de Bom Jesus da lapa, a alta correlação entre as variáveis SSRD e GHI com Rg era esperada, tendo em vista que, apesar de serem oriunda de fontes distintas (dados observados e dados modelados), elas representam a mesma variável. Além disso, a forte correlação entre Rg e T2M também era esperada. No entanto, as relações entre TCC e Rg, assim como TP e Rg, revelaram-se baixas, indicando correlações menos marcantes;
- A análise espacial revelou que regiões com maiores (ou menores) valores de SSRD tendem a apresentar maiores (ou menores) valores de GHI e T2M, além de menores (ou maiores) valores de TCC e TP, em toda a região do NEB;
- A correlação entre GHI e os dados de GEV, CI e CGE em diferentes regiões do NEB foi destacada pela análise espacial. As usinas com maior potencial de CI concentram-se no Piauí e Bahia, áreas com elevados valores médios horários de GHI, em torno de 200 Wh/m². As usinas mais produtivas (com maiores valores de CGE) estão principalmente na Bahia e Piauí, onde o GHI atinge aproximadamente 220 Wh/m². Mesmo usinas com CI mais baixas, como o Conjunto BJL e Assu, podem ser eficientes em termos de CGE, indicando que a produtividade não é determinada apenas pela CI, mas também pelas condições climáticas locais;
- Neste estudo, métodos de DL e suas combinações foram aplicados para prognóstico de GEV aocomplado com dados meteorológicos, como T2M, GHI, TP, TCC e SSRD, para usinas fotovoltaicas distribuídas no NEB. Os dados foram divididos em duas partes: dados de treinamento e validação. Para os dados de treinamento foram aplicados hiperparâmetros, entre eles, diferentes tamanhos de passos, como mencionado anteriormente, além de uma análise em suas métricas de desempenho. Para os dados de teste, que não são utilizados durante a validação, também foram aplicados cálculos das métricas de desempenho. Os resultados mostraram que o método GRU e combinações que o envolvem mostraram-se mais eficientes na maioria dos conjuntos de dados analisados, apresentando resultados mais satisfatórios. Em contrapartida, o método CNN emerge como o menos vantajoso para para a maioria dos tamanhos de passos, destacando-se como a opção menos eficaz no prognóstico do GEV;

- Ao comparar as métricas de desempenho entre os métodos e para diferentes tamanhos de passos, constatou-se uma consistência nos resultados entre os dados observados e os de prognóstico gerados. Métodos com desempenho superior no treinamento também demonstraram superioridade na validação;
- Logo, como esperando, o acoplamento entre os métodos revelou-se mais eficiente na grande maioria dos conjuntos de dados fotovoltaicos analisados.

REFERÊNCIAS BIBLIOGRÁFICAS

ABUALIGAH, L.; ZITAR, R. A.; ALMOTAIRI, K. H.; HUSSEIN, A. M.; ABD ELAZIZ, M.; NIKOO, M. R.; GANDOMI, A. H. Wind, solar, and photovoltaic renewable energy systems with and without energy storage optimization: A survey of advanced machine learning and deep learning techniques. **Energies**, v. 15, n. 2, p. 578, 2022.

ADAMS, W. G.; DAY, R. E. V. The action of light on selenium. **Proceedings of the Royal Society of London**, v. 25, n. 171-178, p. 113-117, 1877.

ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: **2017 international conference on engineering and technology (ICET)**. Ieee, 2017. p. 1-6. 2017.

ANEEL – AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. SIGA: Sistema de Informações da Geração da ANEEL. 2022. Disponível em: <<https://bit.ly/2IGf4Q0>> . Acesso em: 22 nov. 2022.

ANJOS, M.; LOPES, A. Sea breeze front identification on the northeastern coast of Brazil and its implications for meteorological conditions in the Sergipe region. **Theoretical and Applied Climatology**, v. 137, p. 2151-2165, 2019.

ARAÚJO, J. R. B. D. Potencial para instalação de sistemas fotovoltaicos residenciais na região nordeste. Trabalho de Conclusão de Curso (graduação) - Universidade Federal Rural do Semiárido. 2019.

ARTAXO, P.; RIZZO, L. V.; BRITO, J. F.; BARBOSA, H. M.; ARANA, A.; SENA, E. T.; CIRINO, G. G.; BASTOS, W.; MARTIN, S. T.; ANDREAE, M. O. Atmospheric aerosols in Amazonia and land use change: from natural biogenic to biomass burning conditions. **Faraday discussions**, v. 165, p. 203-235, 2013.

AYOADE, J. O. Introdução à climatologia para os trópicos. *Tradução de Maria Juraci dos Santos; revisão de Suely Bastos; coordenação editorial de Antonio Christofolletti, 4, Rio de Janeiro, Bertrand Brasil*, 1996.

AYODELE, T. O. Types of machine learning algorithms. **New advances in machine learning**, v. 3, p. 19-48, 2010.

BARRETO, A. B. Estudo do ciclo diário do vento à superfície no Nordeste do Brasil. *Dissertação (Mestrado) - Universidade Federal da Paraíba. Campina Grande - PB*, 2001.

BARRY, R. A.; CHORLEY, R. J. Atmosphere, Weather and Climate. *Methuen, London*, 3, 1976.

BASTOS, Í. G. P. Previsão de geração fotovoltaica a partir de dados meteorológicos utilizando rede LSTM. Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Alagoas. Maceió - AL, 2020.

BARZEGAR, R.; AALAMI, M. T.; ADAMOWSKI, J. Coupling a hybrid CNN-LSTM deep learning model with a boundary corrected maximal overlap discrete wavelet transform for multiscale lake water level forecasting. **Journal of Hydrology**, v. 598, p. 126196, 2021.

BECQUEREL, M. E. Mémoire sur les effets électriques produits sous l'influence des rayons solaires. **Comptes rendus hebdomadaires des séances de l'Académie des sciences**, v. 9, p. 561-567, 1839.

BERGAMO, H. P.; RAMOS, L. G. D. Análise preditiva da geração fotovoltaica via algoritmos de inteligência computacional: modelagem e estudo de caso da Usina Solar Bom Jesus da Lapa-BA. 2022.

BEZERRA, A. C. N.; CAVALCANTI, E. P. Energia estática sobre o norte e Nordeste do Brasil relacionada com a temperatura da superfície do mar. **Revista Brasileira de Meteorologia**, v. 23, p. 239-263, 2008.

BEZERRA, F. D. Nordeste: futuro promissor para energia solar. 2018.

BEZERRA, F. D. Oportunidades para o Nordeste em Energia Eólica. 2021.

BORSCHIVER, F. Análise das motivações e impactos da regulação de geração distribuída de energia solar no Brasil. *Dissertação (Mestrado) - Universidade Federal do Rio de Janeiro . Rio de Janeiro – RJ*, 2018.

BRAGA, H. A.; AMBRIZZI, T. A variabilidade intrassazonal e interanual do acoplamento entre a zona de convergência do Atlântico Sul e o vórtice ciclônico de altos níveis. **Revista Brasileira de Meteorologia**, v. 37, p. 305-311, 2022.

BRUTSAERT, W. **Evaporation into the atmosphere: theory, history and applications**. Springer Science & Business Media, 2013.

CANTOR, G. A. R. Influência dos fatores climáticos no desempenho de módulos fotovoltaicos em regiões de clima tropical. *Dissertação (Mestrado) – Universidade Federal da Paraíba. João Pessoa – PB*, 2017.

CARDOSO, L. K. D. S. Aspectos climáticos das posições da zona de convergência intertropical e dos anticiclones semipermanentes do Atlântico Sul e do Pacífico Sul: relações com regimes de chuva no nordeste do Brasil. *Dissertação (Mestrado) – Universidade Federal de Campina Grande. Campina Grande – PB*, 2019.

CCEE - CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. Resultados de leilões. Disponível em: Acesso: 16 abr. 2023.

CHANTARANGSI, W.; LIU, W.; BRETZ, F.; KIATSUPAIBUL, S.; HAYTER, A. J.; WAN, F. Normal probability plots with confidence. **Biometrical Journal**, v. 57, n. 1, p. 52-63, 2015.

CHAPIN, D. M.; FULLER, C. S.; PEARSON, G. L. A new silicon p-n junction photocell for converting solar radiation into electrical power. **Journal of applied physics**, v. 25, n. 5, p. 676-677, 1954.

CONTERATO, F. S. Um estudo comparativo entre redes neurais profundas e o modelo numérico WRF-ARW para previsão de energia solar a curto prazo. *Dissertação (Mestrado) - Centro Universitário SENAI CIMATEC. Salvador – BA*, 2022.

CORREIA FILHO, W. L. F.; LUCIO, P. S.; SPYRIDES, M. H. C. Caracterização dos extremos de precipitação diária no nordeste do Brasil. **Boletim Goiano de Geografia**, v. 36, n. 3, p. 539-

554, 2016.

COSTA, H. S.; COSTA, R.; ECK, M. Análise econômica comparativa da eletrificação rural comercial e fotovoltaica. **Encontro de energia no meio rural**, v. 3, 2000.

COULSON, K. L. Solar and Terrestrial Radiation. *Academic, San Fran-cisco*, 1975.

DA SILVA, D. F.; BRITO, J. I. B. Variabilidade do vento na bacia hidrográfica do rio São Francisco durante a ocorrência da ZCAS. **Ambiência**, v. 4, n. 2, p. 221-235, 2008.

DANCEY, C.; REIDY, J. **Estatística Sem Matemática para Psicologia-7**. Penso Editora, 2018.

DE LIMA, F. J. L.; MARTINS, F. R.; COSTA, R. S.; GONÇALVES, A. R.; DOS SANTOS, A. P. P.; PEREIRA, E. B. The seasonal variability and trends for the surface solar irradiation in northeastern region of Brazil. **Sustainable Energy Technologies and Assessments**, v. 35, p. 335-346, 2019.

DE MORAIS, M. D. C.; GAN, M. A.; YOSHIDA, M. C. Features of the upper tropospheric cyclonic vortices of Northeast Brazil in life cycle stages. **International Journal of Climatology**, v. 41, p. E39-E58, 2021.

DE SOUZA FERREIRA G. W.; REBOITA, M. S.; ROCHA, R. P. Vórtices ciclônicos de altos níveis nas cercanias do Nordeste do Brasil: climatologia e análise da vorticidade potencial isentrópica. **Anuário do Instituto de Geociências**, v. 42, n. 3, p. 568-585, 2020.

DNPM – Departamento Nacional de Produção Mineral. Projeto avaliação hidrogeológica da bacia sedimentar do Araripe. *Recife: DNPM, 103*, 1996.

DO NASCIMENTO, C. A. Princípio de funcionamento da célula fotovoltaica. *Dissertação (Mestrado) - Universidade Federal de Lavras. Lavras – MG, 23*, 2004.

DONALD AHRENS, C.; HENSON, R. *Meteorology Today: An introduction to weather, climate and the environment*. 2015.

DOS REIS, L. B.; SANTOS, E. C. **Energia elétrica e sustentabilidade: aspectos tecnológicos, socioambientais e legais**. Editora Manole, 2006.

DUFFIE, J. A.; BECKMAN, W. A.. **Solar engineering of thermal processes**. John Wiley & Sons, 2013.

EBERHARDT, D. Desenvolvimento de um Sistema Completo para Caracterização de Células Solares. *Dissertação (Mestrado) - Universidade Católica do Rio Grande do Sul. Porto Alegre – RS, 104*, 2005.

EL ALANI, O.; ABRAIM, M.; GHENNIQUI, H.; GHENNIQUI, A.; IKENBI, I.; DAHR, F. E. Short term solar irradiance forecasting using sky images based on a hybrid CNN–MLP model. **Energy Reports**, v. 7, p. 888-900, 2021.

EMPRESA DE PESQUISA ENERGÉTICA - EPE. *Balanco Energético Nacional: ano base 20011*, 2012. Disponível em: <<https://www.epe.gov.br/pt>>

ENERGIA SOLAR NO BRASIL. Associação Brasileira de Energia Solar Fotovoltaica, São

Paulo, 02 de maio de 2023. Disponível em: <<https://www.absolar.org.br/mercado/infografico/>>. Acesso em: 05 de maio de 2023.

FADIGAS, E. A. F. A.; REIS, L. B. D. Dimensionamento de fontes fotovoltaicas e eólicas com base no índice de perda de suprimento e sua aplicação para atendimento a localidades isoladas. *Dissertação (Mestrado em Planejamento Energético) - Escola Politécnica, Universidade de São Paulo. São Paulo – SP, 1993.*

FENG, C.; ZHANG, J.; ZHANG, W.; HODGE, B.-M. Convolutional neural networks for intra-hour solar forecasting based on sky image sequences. **Applied Energy**, v. 310, p. 118438, 2022.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, p. 25-30, 2006.

FERREIRA, D. F. Estatística. **Básica. Lavras. Editora UFLA, 2005.**

FERREIRA, J. P. J. A energia solar e o conceito de horas de sol pleno. *CEFET-RJ. Escola Técnica. Curso de Eletrotécnica, 2019.*

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115-146, 2009.

FOGAÇA, T. K.; GOULART, A. A. Introdução à climatologia: Conceitos, pesquisas e ensino. **Curitiba: Intersaberes, 2018.**

FRANCISCO, A. C. C.; VIEIRA, H. E. D. M.; ROMANO, R. R.; ROVEDA, S. R. M. M. Influência de parâmetros meteorológicos na geração de energia em painéis fotovoltaicos: um caso de estudo do Smart Campus Facens, SP, Brasil. **urbe. Revista Brasileira de Gestão Urbana**, v. 11, 2019.

FREITAS, S. S. A. Dimensionamento de sistemas fotovoltaicos. *Tese (Doutorado) - Instituto Politecnico de Braganca (Portugal), 2008.*

FRITTS, C. E. On a new form of selenium cell, and some electrical discoveries made by its use. **American Journal of Science**, v. 3, n. 156, p. 465-472, 1883.

GOLDEMBERG, J. Energia e sustentabilidade. **Revista de Cultura e Extensão USP**, v. 14, p. 33-43, 2015. Disponível em: <<https://doi.org/10.11606/issn.2316-9060.v14i0p33-43>>.

GOMES, H. B.; AMBRIZZI, T.; HERDIES, D. L.; HODGES, K.; PONTES DA SILVA, B. F. Easterly wave disturbances over Northeast Brazil: an observational analysis. **Advances in Meteorology**, v. 2015, p. 1-20, 2015.

GOMES, H. B.; AMBRIZZI, T.; PONTES DASILVA, B. F.; HODGES, K.; SILVA DIAS, P. L.; SILVA, M. C. L.; GOMES, H. B. Climatology of easterly wave disturbances over the tropical South Atlantic. **Climate Dynamics**, v. 53, p. 1393-1411, 2019.

GOMES, L. P. P. Previsibilidade de geração solar no contexto de hibridização de fontes para análise de complementaridade. Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Uberlândia. Uberlândia - MG, 2023.

- GÓMEZ, J. M.; CARLESSO, F.; VIEIRA, L. E.; DA SILVA, L.. A irradiância solar: conceitos básicos. **Revista Brasileira de Ensino de Física**, v. 40, 2018.
- GRAFF, M. R. Comparativo de custos da alteração do sistema fotovoltaico isolado para sistema fotovoltaico interligado à rede da concessionária-estudo de caso. *Dissertação (Mestrado) – Universidade Federal do Paraná. Palotina – PR*, 2017.
- GUEDES, T. A.; MARTINS, A. B. T.; ACORSI, C. R. L.; JANEIRO, V. Estatística descritiva. **Projeto de ensino aprender fazendo estatística**, p. 1-49, 2005.
- HÉMERY, D.; DEBEIR, J. C.; DELÉAGE, J. P. Uma História da Energia. trad. e atual. **Sérgio de Salvo Brito. Editora Universidade de Brasília, Brasília**, 1993.
- HUANG, C. J.; KUO, P. H. A deep CNN-LSTM model for particulate matter (PM_{2.5}) forecasting in smart cities. **Sensors**, v. 18, n. 7, p. 2220, 2018.
- IMHOFF, J. Desenvolvimento de conversores estáticos para sistemas fotovoltaicos autônomos. *Dissertação (Mestrado) - Escola de Engenharia Elétrica da Universidade Federal de Santa Maria. Santa Maria – RS, 146*, 2007.
- INMET. Normais Climatológicas do Brasil 1961-1990. 2016.
- KEMERICH, P. D. C.; FLORES, C. E. B.; DE BORBA, W. F.; DA SILVEIRA, R. B.; FRANÇA, J. R.; LEVANDOSKI, N. Paradigmas da energia solar no Brasil e no mundo. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, p. 241-247, 2016.
- KELLEHER, J. D. **Deep learning**. MIT press, 2019.
- KHAN, M.; NIELSEN, D.; TANGKARATT, V.; LIN, W.; GAL, Y.; SRIVASTAVA, A. Fast and scalable bayesian deep learning by weight-perturbation in adam. In: **International conference on machine learning**. PMLR, 2018. p. 2611-2620.
- KOLB, C. E.; WORSNOP, D. R. Chemistry and composition of atmospheric aerosol particles. **Annual review of physical chemistry**, v. 63, p. 471-491, 2012.
- KOPPEN, W. Das geographische System de Klimate. **Handbuch der klimatologie**, 1936.
- KRUGER, S. D.; ZANELLA, C.; BARICHELLO, R. Análise da viabilidade econômico-financeira para implantação de projeto de produção de energia solar fotovoltaica em uma propriedade rural. **Revista de Gestão e Secretariado (Management and Administrative Professional Review)**, v. 14, n. 1, p. 428-445, 2023.
- KUMARI, P.; TOSHNIWAL, D. Deep learning models for solar irradiance forecasting: A comprehensive review. **Journal of Cleaner Production**, v. 318, p. 128566, 2021.
- LEMON, E. R. Energy conversion and water use efficiency in plants. **Plant Environment and Efficient Water Use**, p. 28-48, 1966.
- LEOTTI, V. B.; COSTER, R.; RIBOLDI, J. Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação. **Revista HCPA. Porto Alegre. Vol. 32, no. 2 (2012), p. 227-234**, 2012.

- LIMA, I. V. M. Uma abordagem simplificada de detecção de intrusão baseada em redes neurais artificiais. Dissertação (mestrado) Universidade Federal de Santa Catarina. Florianópolis, Santa Catarina, 2005.
- LUCAS, A. F. Estimativa de irradiação solar via modelos empíricos com base na temperatura do ar para o Nordeste brasileiro. *Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Norte. Natal – RN*, 2017.
- LYRA, M. J. A.; CAVALCANTE, L. C. V.; LEVIT, V.; FEDOROVA, N. Complexos Convectivos de Mesoescala sobre o Nordeste do Brasil e fenômenos adversos associados. **Revista Ibero-Americana de Ciências Ambientais**, v. 9, n. 3, p. 95-103, 2018.
- LYRA, M. J.; FEDOROVA, N.; LEVIT, V. Mesoscale convective complexes over northeastern Brazil. **Journal of South American Earth Sciences**, v. 118, p. 103911, 2022.
- MACHADO, C. T.; MIRANDA, F. S. Energia Solar Fotovoltaica: uma breve revisão. **Revista virtual de química**, v. 7, n. 1, p. 126-143, 2015.
- MAHESH, B. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**. v. 9, n. 1, p. 381-386, 2020.
- MAHESH, V. G.; RAJ, A. N. J. Zernike moments and machine learning based gender classification using facial images. In: **Proceedings of the Eighth International Conference on Soft Computing and Pattern Recognition (SoCPaR 2016)**. Springer International Publishing, 2018. p. 398-408.
- MANTOVANI, P. R. A.; NEUMANN, P. N.; EDLER, M. A. R. Matriz Energética Brasileira: Em busca de uma nova alternativa. **Revista Interdisciplinar De Ensino, Pesquisa E Extensão-RevInt**, v. 4, n. 1, 2017.
- MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista Usp**, n. 106, p. 31-44, 2015.
- MARTINEZ, A; IGLESIAS, G. Climate changer impacts on wind energy resources in North America based on the CMIP6 projections. **Science of The Total Environment**, v. 806, p. 150580, 2022.
- MARTINS, F. R.; PEREIRA, E. B.; ABREU, S. L. Satellite-derived solar resource maps for Brazil under SWERA project. **Solar Energy**, v. 81, n. 4, p. 517-528, 2007.
- MARTINS, F. R.; PEREIRA, E. B.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L. D.; RÜTHER, R.; ABREU, S. L.; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. D. Atlas brasileiro de energia solar 2, 2017.
- MICHALSKY, J. J. The astronomical almanac's algorithm for approximate solar position (1950–2050). **Solar energy**, v. 40, n. 3, p. 227-235, 1988.
- MOHANTY, S.; PATRA, PK; SAHOO, SS; MOHANTY, A. Previsão de energia solar com aplicação para uma economia em crescimento como a Índia: Pesquisa e implicação. *Renovar. Sustentar. Energy Rev.* V. 78 , P. 539–553, 2017.

MOORE, D. S.; McCABE, G. **Introduction to the Practice of Statistics**. WH Freeman and company, 2009.

MORAIS, C. Escalas de medida, estatística descritiva e inferência estatística. 2005.

NAGYFI, R. The differences between artificial and biological neural networks. **Towards Data Science [online]. Sep**, v. 4, 2018.

NASTESKI, V. An overview of the supervised machine learning methods. **Horizons. b**, v. 4, p. 51-62, 2017.

OLIVEIRA, Á. D. D. Sistema de rastreamento solar automático baseado em algoritmo de posição solar aplicado a um refletor fresnel linear. *Dissertação (Mestrado) - Universidade do Vale do Rio dos Sinos. São Leopoldo - RS*, 2018.

OLIVEIRA, P. D. S. Uso de aprendizagem de máquina e redes neurais convolucionais profundas para a classificação de áreas queimadas em imagens de alta resolução espacial. Dissertação de Mestrado, Universidade de Brasília, 2019.

OLIVEIRA, P. T.; SANTOS E SILVA, C. M.; LIMA, K. C. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. **Theoretical and Applied Climatology**, v. 130, p. 77-90, 2017.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO - ONS. Histórico da operação. *Geração de energia*. 2021.

Panorama da solar fotovoltaica no Brasil e no mundo. ABSOLAR, 2023 .Disponível em:< <https://www.absolar.org.br/mercado/infografico/>>. Acesso em: 11 de jan. de 2024.

PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L. de; RÜTHER, R.; ABREU, S. L. de; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. *Atlas brasileiro de energia solar. São José dos Campos: Inpe*, v. 1, 2017.

PEREIRA, F.; OLIVEIRA, M. Curso técnico instalador de energia solar fotovoltaica. **Porto: Publindústria**, 2011.

PINHO, J. T.; GALDINO, M. A. **Manual de engenharia para sistemas fotovoltaicos. Grupo de trabalho de energia solar-GTES**. CEPEL-DTE-CRESESB, 2014.

PRADA, R. B. Modelo de previsão de carga elétrica considerando a influência da mini e microgeração distribuída no perfil da curva de carga. Tese (Doutorado) - Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro - RJ, 2021.

RAVI, A.; REBALA, G.; CHURIWALA, S. **An introduction to machine learning**. Springer, 2019.

ROCHA, P. A., & SANTOS, V. O. Global horizontal and direct normal solar irradiance modeling by the machine learning methods XGBoost and deep neural networks with CNN-LSTM layers: A case study using the GOES-16 satellite imagery. **International Journal of Energy and Environmental Engineering**, v. 13, n. 4, p. 1271-1286, 2022.

RODRIGUES, D. T.; GONÇALVES, W. A.; SPYRIDES, M. H. C.; SANTOS E SILVA, C. M.

Spatial and temporal assessment of the extreme and daily precipitation of the Tropical Rainfall Measuring Mission satellite in Northeast Brazil. **International Journal of Remote Sensing**, v. 41, n. 2, p. 549-572, 2020.

ROSA, A. **Processos de Energia Renováveis**. Elsevier Brasil, 2016.

ROSS, J. L. S. Relevo brasileiro: uma nova proposta de classificação. **Revista do Departamento de Geografia**, v. 4, p. 25-39, 1985.

SANGRODY, H.; SARAILOO, M.; ZHOU, N., TRAN, N.; MOTALLEB, M.; FORUZAN, E. Weather forecasting error in solar energy forecasting. **IET Renewable Power Generation**, v. 11, n. 10, p. 1274-1280, 2017.

SANTIAGO, G. A. C. F.; MOTA, C. L.; NÓBREGA, R. S. Secas severas no Nordeste do Brasil e a temperatura da superfície do mar: uma revisão. In *A Conferência da Terra*, v. 1, p. 127-132, 2010.

SELLERS, W. D. *Physical Climatology*. Chicago, University of Chicago Press, 1965.

SILVA, A. S. D.; SILVA, E. M. D.; LEAL JUNIOR, J. B. V.; SALES, D. C.; MOURA, I. J. M.; ALVES, J. M. B. Distúrbios Ondulatórios de Leste no Nordeste Brasileiro: Um Estudo de Caso Utilizando Modelagem Numérica de Mesoescala. **Revista Brasileira de Meteorologia**, v. 36, p. 637-649, 2021.

SILVA, J. A. A. D. Tratamento de dados meteorológicos e análise de desempenho do sistema fotovoltaico da EMC/UFG. *Dissertação (mestrado) - Universidade Federal de Goiás. Goiás – GO*, 2019.

SILVA, L. A. A influência do vórtice ciclônico de altos níveis (VCAN) sobre a precipitação do nordeste do Brasil (NEB) e as características associadas. *Dissertação (Mestrado) - Instituto Nacional de Pesquisas Espaciais. São José dos Campos - SP, 131*, 2005.

SILVA, R. A. Variabilidade da radiação solar no Nordeste do Brasil com base em dados observados e do NCEP/NCAR. *Dissertação (mestrado) - Universidade Federal de Campina Grande. Campina Grande - PB*, 2008.

SOARES, J. F.; SIQUEIRA, A. L. Introdução à estatística médica. In: **Introdução à estatística médica**. p. 300-300. 2002.

SOARES, V. R. Impactos sociais causados pela construção de hidrelétricas em populações ribeirinhas na zona da mata mineira. *Trabalho de conclusão de curso (Graduação em Ciências Sociais) - Universidade Federal de Juiz de Fora. Juiz de Fora - MG*, 2009.

SOLANKI, H. K.; PAWAR, D. D.; SHAH, D. A.; PRAJAPATI, V. D.; JANI, G. K.; MULLA, A. M.; THAKAR, P. M. Development of microencapsulation delivery system for long-term preservation of probiotics as biotherapeutics agent. **BioMed research international**, v. 2013, 2013.

SOLAR, E. Princípios e aplicações. **Centro de Referencia para Energia Solar e Eólica Sergio de Salvo Brito–CRESESB, Rio de Janeiro**, v. 4, 2006.

SOUZA, E. D.; ALVES, J. M. B.; REPELLI, C. A. Um complexo convectivo de mesoescala

associado à precipitação intensa sobre Fortaleza-CE. **Revista Brasileira de Meteorologia**, v. 13, n. 2, p. 1-14, 1998.

SOUZA, R. A. B. Energia solar: vantagens do investimento desta fonte de energia alternativa na região do Nordeste. *Dissertação (Especialização em Fontes Alternativas de Energia) - Universidade Federal de Lavras, Minas Gerais - MG*, 2005.

SOUZA, V. L. O. Crescimento da geração de energia fotovoltaica na região nordeste do Brasil. Trabalho de Conclusão de Curso (graduação) - Universidade Federal Rural do Semiárido. 2020.

STEFANELLO, C.; MARANGONI, F.; ZEFERINO, C. L. A importância das políticas públicas para o fomento da energia solar fotovoltaica no Brasil. In: **Congresso Brasileiro de Energia Solar-CBENS**. 2018.

STÖTER, F. R.; CHAKRABARTY, S.; EDLER, B.; HABETS, E. A. Classification vs. regression in supervised learning for single channel speaker count estimation. In: **2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. IEEE, p. 436-440, 2018.

SUGAHARA, J. A. S. Machine learning e data science na indústria: aplicações e desafios. 2020.

TOLMASQUIM, M. As origens da crise energética brasileira. 2000.

UNLU, A.; PEÑA, M.; WANG, Z. Deep Learning Architectures for Solar PV Forecasting. In: **2022 North American Power Symposium (NAPS)**. IEEE, 2022. p. 1-6, 2022.

UVO, C.R.B. A Zona de Convergência Intertropical (ZCIT) e sua relação com a Precipitação da Região Norte do Nordeste Brasileiro. *Dissertação (Mestrado) - Instituto Nacional de Pesquisas Espaciais. São José dos Campos – SP*, 1989.

VALENTE, M. Â. S. Caracterização automática de um painel fotovoltaico. *Dissertação (Mestrado) - Universidade Nova de Lisboa. Lisboa, Portugal*, 2011.

VIANELLO, R. L.; ALVES, A. R. Meteorologia básica e aplicações. *Viçosa, MG: UFV*, 1991.

VIEIRA, J. P. Redes neurais recorrentes para previsão de radiação solar global. Trabalho de Conclusão de Curso (graduação) - Instituto Federal de Educação, Ciências e Tecnologia de Goiás. Itumbiara - GO, 2022.

VILLALVA, M. G.; GAZOLI, J. R. Energia solar fotovoltaica: conceitos e aplicações. **São Paulo: Érica**, v. 2, 2012.

WALLER, M. A.; FAWCETT, S. E. Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management. **Journal of Business Logistics**, v. 34, n. 2, p. 77-84, 2013.

WHITAKER, C. M.; TOWNSEND, T. U.; WENGER, H. J.; ILICETO, A.; CHIMENTO, G.; PALETTA, F. Effects of irradiance and other factors on PV temperature coefficients. In: **The Conference Record of the Twenty-Second IEEE Photovoltaic Specialists Conference-1991**. IEEE, 1991. p. 608-613.

XIAO, W.; LIND, M. G.; DUNFORD, W. G.; CAPEL, A. Real-time identification of optimal

operating points in photovoltaic power systems. **IEEE Transactions on industrial Electronics**, v. 53, n. 4, p. 1017-1026, 2006.

YNOUE, R. Y.; REBOITA, M. S.; AMBRIZZI, T.; DA SILVA, G. A. *Meteorologia: noções básicas. Oficina de Textos*, 2017.

YU, Y.; SI, X.; HU, C.; ZHANG, J. A review of recurrent neural networks: LSTM cells and network architectures. **Neural computation**, v. 31, n. 7, p. 1235-1270, 2019.

ZHAO, R.; WANG, D.; YAN, R.; MAO, K.; SHEN, F.; WANG, J. Machine health monitoring using local feature-based gated recurrent unit networks. **IEEE Transactions on Industrial Electronics**, v. 65, n. 2, p. 1539-1548, 2017.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G. S.; ZHANG, L.; XU, F.; FRAUNDORFER, F. Deep learning in remote sensing: A comprehensive review and list of resources. **IEEE geoscience and remote sensing magazine**, v. 5, n. 4, p. 8-36, 2017.

ANEXO A

Anexo A1. Métricas de avaliação de desempenho com tamanho de passos 6 para Assú V.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	5.91	4.03	6.02	4.13	6
LSTM	5.87	3.98	5.95	4.08	6
GRU	5.78	3.83	5.88	3.96	6
LSTM + CNN	5.75	4.07	5.96	4.17	6
LSTM + GRU	5.75	3.86	5.86	3.96	6
CNN + GRU	5.78	3.83	5.89	3.95	6

Anexo A2. Métricas de avaliação de desempenho com tamanho de passos 12 para Assú V.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	5.73	3.80	5.89	3.91	12
LSTM	5.82	3.74	5.95	3.84	12
GRU	5.65	3.57	5.79	3.68	12
LSTM + CNN	5.78	3.74	5.93	3.84	12
LSTM + GRU	5.72	3.54	5.81	3.63	12
CNN + GRU	5.61	3.54	5.74	3.64	12

Anexo A3. Métricas de avaliação de desempenho com tamanho de passos 24 para Assú V.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	4.83	3.12	5.05	3.22	24
LSTM	4.76	3.08	4.91	3.14	24
GRU	4.66	2.80	4.92	2.93	24
LSTM + CNN	4.75	3.05	4.93	3.13	24
LSTM + GRU	4.57	2.86	4.82	3.00	24
CNN + GRU	4.60	2.87	4.80	2.99	24

Anexo A4. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto BJJ.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.81	6.84	10.00	6.91	6
LSTM	9.61	6.85	9.80	6.93	6
GRU	9.48	6.69	9.70	6.79	6
LSTM + CNN	9.56	6.85	9.75	6.93	6
LSTM + GRU	9.52	6.71	9.76	6.83	6
CNN + GRU	9.60	6.86	9.81	6.97	6

Anexo A5. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto BJJ.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	8.59	5.90	8.61	5.93	12
LSTM	8.66	5.86	8.61	5.82	12
GRU	8.65	5.94	8.50	5.82	12
LSTM + CNN	8.65	5.94	8.60	5.92	12
LSTM + GRU	8.68	5.72	8.65	5.72	12
CNN + GRU	8.61	5.78	8.52	5.75	12

Anexo A6. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto BJJ.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	7.49	4.99	7.45	5.00	24
LSTM	7.58	5.20	7.53	5.20	24
GRU	7.12	4.74	7.16	4.79	24
LSTM + CNN	7.52	5.18	7.49	5.21	24
LSTM + GRU	7.16	4.72	7.21	4.78	24
CNN + GRU	7.18	4.74	7.28	4.82	24

Anexo A7. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Bom Jesus.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	14.77	10.01	14.53	9.88	6
LSTM	14.72	9.97	14.50	9.83	6
GRU	14.70	9.78	14.50	9.72	6
LSTM + CNN	14.69	9.96	14.48	9.83	6
LSTM + GRU	14.44	9.61	14.29	9.53	6
CNN + GRU	14.58	9.80	14.44	9.70	6

Anexo A8. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Bom Jesus.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	13.03	8.79	13.19	8.94	12
LSTM	12.92	8.38	13.04	8.50	12
GRU	12.67	8.01	12.72	8.09	12
LSTM + CNN	12.90	8.40	13.03	8.51	12
LSTM + GRU	12.76	8.10	12.82	8.20	12
CNN + GRU	12.83	8.33	12.95	8.43	12

Anexo A9. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Bom Jesus.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	11.78	8.03	12.21	8.35	24
LSTM	11.51	7.51	11.83	7.73	24
GRU	11.20	7.00	11.60	7.26	24
LSTM + CNN	11.54	7.39	11.86	7.62	24
LSTM + GRU	11.13	7.10	11.51	7.35	24
CNN + GRU	11.28	6.82	11.63	7.03	24

Anexo A10. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Calcário.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	25.60	18.66	25.14	18.28	6
LSTM	25.39	18.85	24.97	18.44	6
GRU	24.90	17.30	24.85	17.14	6
LSTM + CNN	25.56	19.11	25.12	18.71	6
LSTM + GRU	24.24	17.07	24.04	16.82	6
CNN + GRU	24.45	17.27	24.32	17.01	6

Anexo A11. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Calcário.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	22.38	14.68	22.49	15.01	12
LSTM	22.64	14.27	22.52	14.56	12
GRU	21.59	13.12	21.62	13.42	12
LSTM + CNN	22.58	14.31	22.45	14.58	12
LSTM + GRU	21.49	13.00	21.47	13.27	12
CNN + GRU	21.47	13.18	21.53	13.57	12

Anexo A12. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Calcário.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	15.01	11.53	18.83	12.62	24
LSTM	16.59	10.23	18.05	11.25	24
GRU	16.01	9.48	17.45	10.41	24
LSTM + CNN	16.70	10.47	18.15	11.49	24
LSTM + GRU	15.86	9.51	16.99	10.29	24
CNN + GRU	15.81	9.44	16.94	10.18	24

Anexo A13. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Horizonte.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	19.30	13.93	19.69	14.38	6
LSTM	18.99	13.75	19.35	14.16	6
GRU	18.96	13.29	19.35	13.73	6
LSTM + CNN	18.97	13.76	19.33	14.14	6
LSTM + GRU	18.87	13.54	19.27	13.97	6
CNN + GRU	18.71	13.48	19.16	13.90	6

Anexo A14. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Horizonte.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	16.68	11.65	16.64	11.69	12
LSTM	16.60	10.94	16.51	10.94	12
GRU	16.38	10.58	16.40	10.72	12
LSTM + CNN	16.55	11.06	16.50	11.10	12
LSTM + GRU	16.46	10.99	16.43	11.06	12
CNN + GRU	16.32	10.72	16.33	10.83	12

Anexo A15. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Horizonte.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	14.68	10.48	14.72	10.46	24
LSTM	14.13	9.06	14.14	9.01	24
GRU	13.86	8.51	13.98	8.50	24
LSTM + CNN	14.12	9.06	14.13	9.01	24
LSTM + GRU	13.87	8.49	13.99	8.49	24
CNN + GRU	14.01	8.94	14.12	8.93	24

Anexo A16. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Ituverava.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	45.65	34.81	46.10	35.43	6
LSTM	44.86	33.09	45.18	33.51	6
GRU	43.80	30.74	44.36	31.27	6
LSTM + CNN	44.84	33.04	45.14	33.47	6
LSTM + GRU	44.01	31.09	44.49	31.59	6
CNN + GRU	43.78	30.85	44.16	31.33	6

Anexo A17. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Ituverava.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	38.36	25.35	39.10	26.18	12
LSTM	38.64	25.01	39.21	25.70	12
GRU	37.37	23.07	37.67	23.50	12
LSTM + CNN	38.55	25.47	39.12	26.14	12
LSTM + GRU	37.29	23.50	37.82	24.11	12
CNN + GRU	37.61	23.32	37.95	23.74	12

Anexo A18. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Ituverava.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	30.88	20.38	30.19	19.98	24
LSTM	30.13	18.69	29.46	18.27	24
GRU	30.45	18.52	29.97	18.22	24
LSTM + CNN	30.14	18.54	29.51	18.14	24
LSTM + GRU	29.87	18.55	29.38	18.27	24
CNN + GRU	29.87	18.44	29.38	18.24	24

Anexo A19. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Juazeiro Solar.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	31.91	24.30	32.35	24.81	6
LSTM	30.23	22.08	30.34	22.17	6
GRU	29.34	20.25	29.80	20.56	6
LSTM + CNN	30.39	22.66	30.45	22.78	6
LSTM + GRU	29.61	20.76	30.33	21.33	6
CNN + GRU	29.53	20.32	30.32	20.99	6

Anexo A20. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Juazeiro Solar.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	27.94	18.49	28.01	18.31	12
LSTM	26.67	17.19	25.99	16.55	12
GRU	25.68	15.85	24.83	15.12	12
LSTM + CNN	26.62	17.78	25.85	17.11	12
LSTM + GRU	26.66	17.25	25.74	16.45	12
CNN + GRU	25.64	15.57	24.97	14.98	12

Anexo A21. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Juazeiro Solar.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	19.15	12.32	19.57	12.86	24
LSTM	17.82	11.06	18.10	11.55	24
GRU	17.42	10.55	17.87	11.25	24
LSTM + CNN	17.92	11.12	18.24	11.62	24
LSTM + GRU	17.57	11.01	17.92	11.64	24
CNN + GRU	17.40	10.46	17.66	11.06	24

Anexo A22. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Lapa.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	15.02	10.80	14.88	10.68	6
LSTM	14.91	10.63	14.74	10.49	6
GRU	14.69	9.89	14.51	9.78	6
LSTM + CNN	14.87	10.54	14.67	10.37	6
LSTM + GRU	14.90	10.34	14.75	10.21	6
CNN + GRU	14.77	10.29	14.69	10.22	6

Anexo A23. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Lapa.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	12.33	8.16	12.71	8.53	12
LSTM	12.35	7.78	12.66	8.13	12
GRU	12.13	7.16	12.37	7.46	12
LSTM + CNN	12.31	7.92	12.63	8.27	12
LSTM + GRU	11.92	7.37	12.19	7.66	12
CNN + GRU	12.24	7.95	12.55	8.21	12

Anexo A24. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Lapa.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.95	6.52	10.02	6.52	24
LSTM	9.63	5.95	9.72	5.98	24
GRU	9.45	5.67	9.48	5.67	24
LSTM + CNN	9.68	6.00	9.76	6.03	24
LSTM + GRU	9.39	5.58	9.43	5.59	24
CNN + GRU	9.46	5.55	9.57	5.57	24

Anexo A25. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	50.74	36.91	50.21	36.53	6
LSTM	49.61	35.29	48.94	34.88	6
GRU	48.90	34.08	48.58	34.00	6
LSTM + CNN	49.89	36.49	49.30	36.04	6
LSTM + GRU	48.83	33.70	48.50	33.66	6
CNN + GRU	48.73	34.23	48.47	34.06	6

Anexo A26. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	43.49	29.32	44.02	30.07	12
LSTM	43.29	28.02	43.59	28.58	12
GRU	42.64	27.16	42.93	27.82	12
LSTM + CNN	43.35	28.62	43.64	29.23	12
LSTM + GRU	42.84	27.22	43.19	27.89	12
CNN + GRU	42.57	27.46	42.70	28.02	12

Anexo A27. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Nova Olinda.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	34.89	22.47	34.95	22.75	24
LSTM	33.98	21.94	33.89	22.10	24
GRU	32.74	19.15	32.59	19.35	24
LSTM + CNN	34.14	21.71	34.09	21.90	24
LSTM + GRU	32.82	19.94	33.04	20.34	24
CNN + GRU	33.32	21.17	33.31	21.34	24

Anexo A28. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	10.48	7.17	10.82	7.36	6
LSTM	10.30	7.02	10.39	7.09	6
GRU	10.05	6.47	10.14	6.59	6
LSTM + CNN	10.25	6.92	10.36	7.00	6
LSTM + GRU	10.09	6.48	10.18	6.59	6
CNN + GRU	10.16	6.64	10.25	6.76	6

Anexo A29. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.72	6.51	9.77	6.53	12
LSTM	9.77	6.28	9.82	6.31	12
GRU	9.49	5.92	9.59	5.96	12
LSTM + CNN	9.78	6.45	9.81	6.45	12
LSTM + GRU	9.48	6.06	9.53	6.07	12
CNN + GRU	9.70	6.19	9.80	6.26	12

Anexo A30. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Rio Alto.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	7.98	5.43	8.09	5.61	24
LSTM	7.82	5.15	7.86	5.26	24
GRU	7.05	4.36	7.06	4.40	24
LSTM + CNN	7.75	5.05	7.79	5.16	24
LSTM + GRU	7.24	4.86	7.33	4.97	24
CNN + GRU	7.52	4.57	7.63	4.65	24

Anexo A31. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto São Pedro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	14.42	10.64	14.34	10.44	6
LSTM	14.48	10.85	14.32	10.61	6
GRU	14.16	9.90	14.01	9.74	6
LSTM + CNN	14.39	10.70	14.23	10.47	6
LSTM + GRU	14.08	10.01	13.86	9.77	6
CNN + GRU	14.18	10.08	14.02	9.85	6

Anexo A32. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto São Pedro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	11.82	7.68	12.19	7.99	12
LSTM	12.08	7.97	12.40	8.35	12
GRU	11.66	6.85	12.01	7.22	12
LSTM + CNN	12.06	8.16	12.39	8.54	12
LSTM + GRU	11.28	7.02	11.63	7.41	12
CNN + GRU	11.46	7.19	11.79	7.54	12

Anexo A33. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto São Pedro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.17	5.54	8.93	5.35	24
LSTM	9.05	5.62	8.86	5.50	24
GRU	8.94	4.95	8.77	4.87	24
LSTM + CNN	9.06	5.54	8.92	5.46	24
LSTM + GRU	9.08	5.20	8.86	5.11	24
CNN + GRU	8.93	5.38	8.70	5.25	24

Anexo A34. Métricas de avaliação de desempenho com tamanho de passos 6 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	17.11	13.61	17.31	13.64	6
LSTM	16.71	13.24	16.52	12.98	6
GRU	15.40	10.72	15.39	10.61	6
LSTM + CNN	16.45	12.79	16.33	12.54	6
LSTM + GRU	15.52	11.13	15.61	11.13	6
CNN + GRU	15.72	11.01	15.86	10.96	6

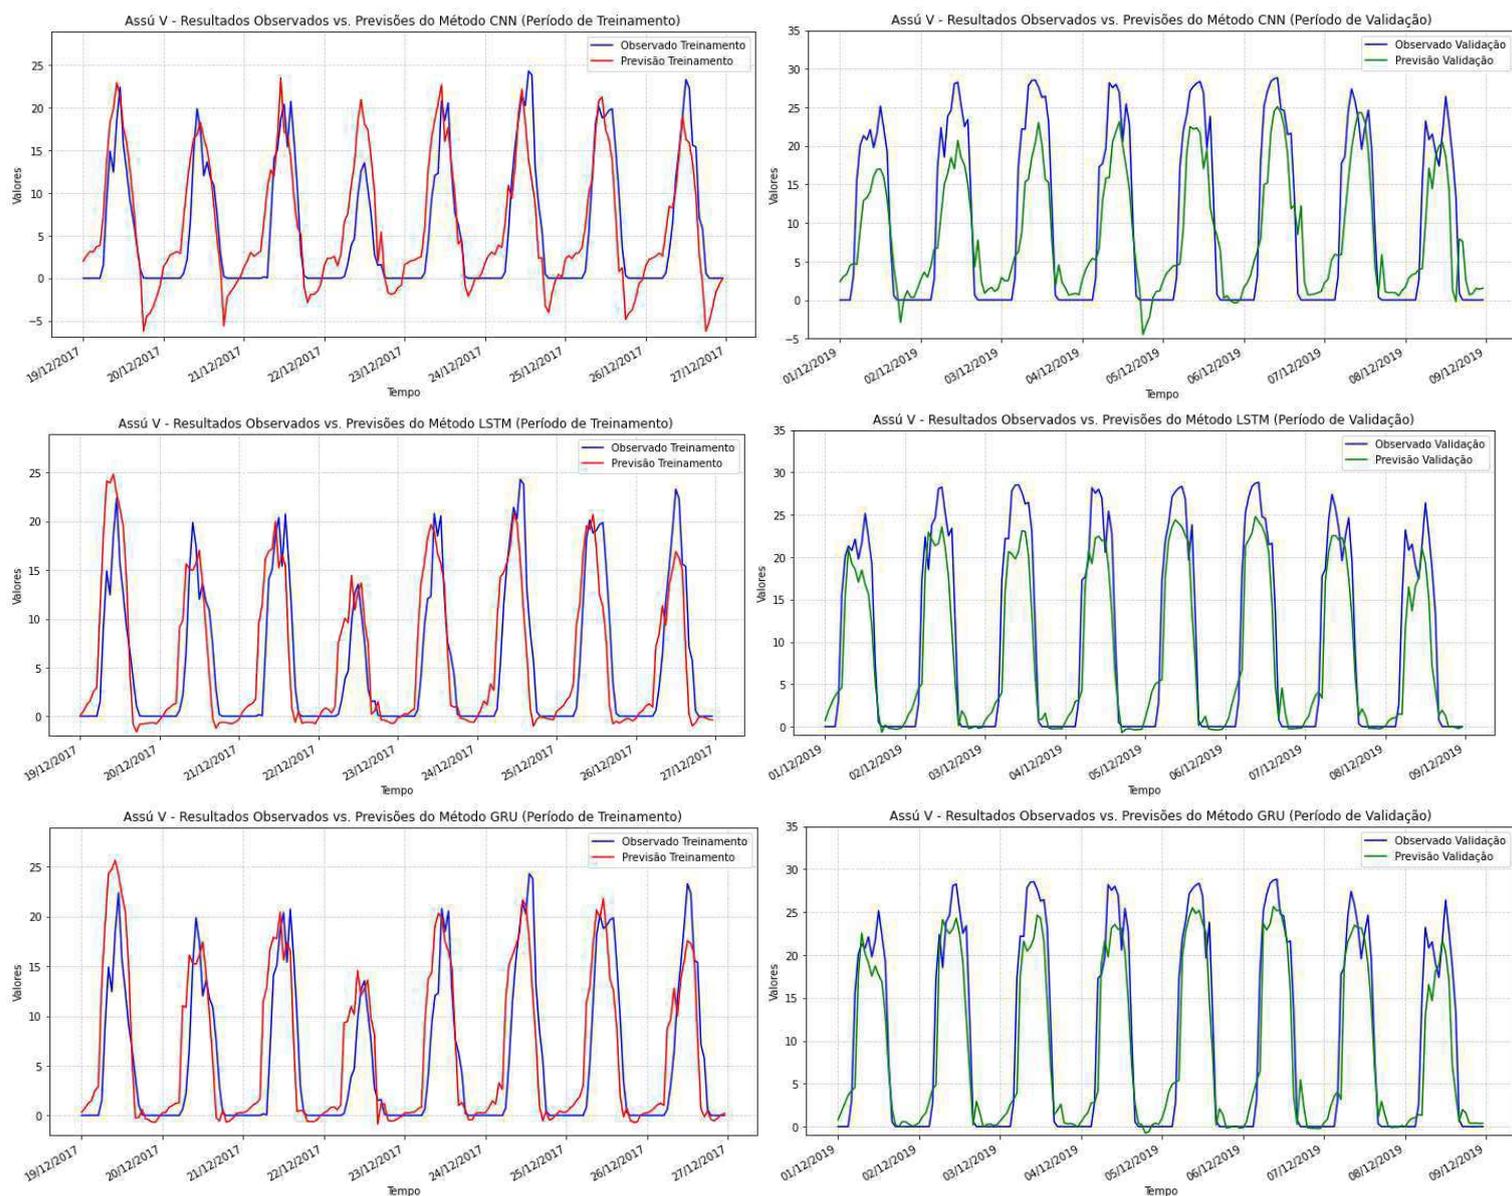
Anexo A35. Métricas de avaliação de desempenho com tamanho de passos 12 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	12.73	8.15	13.02	8.29	12
LSTM	13.07	8.33	13.23	8.40	12
GRU	12.15	7.01	12.04	6.95	12
LSTM + CNN	13.01	8.35	13.16	8.44	12
LSTM + GRU	11.95	7.01	11.92	6.98	12
CNN + GRU	12.90	7.36	12.82	7.30	12

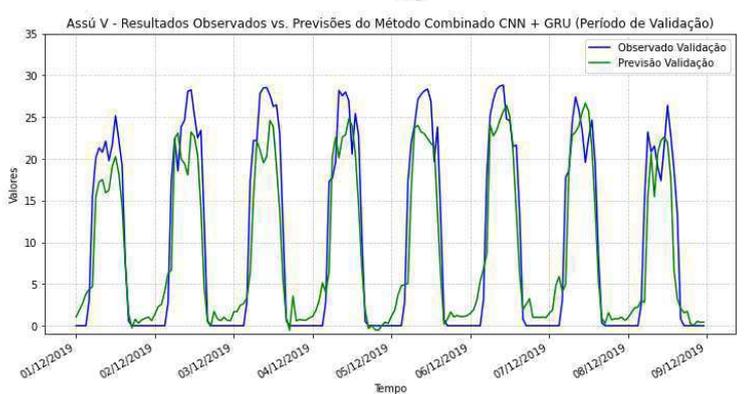
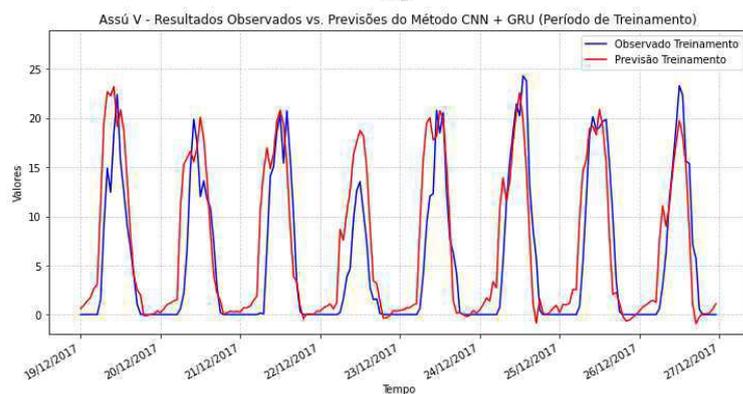
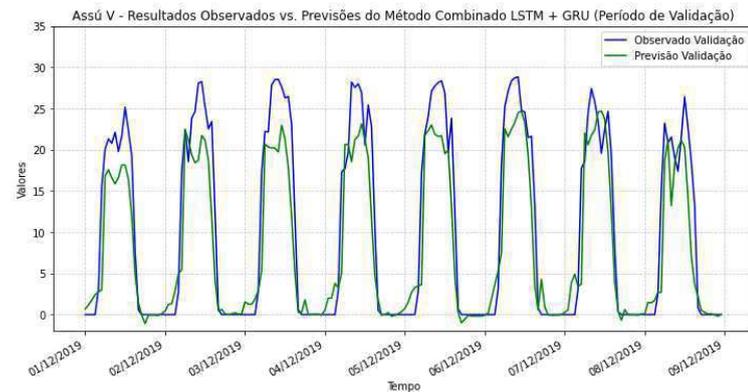
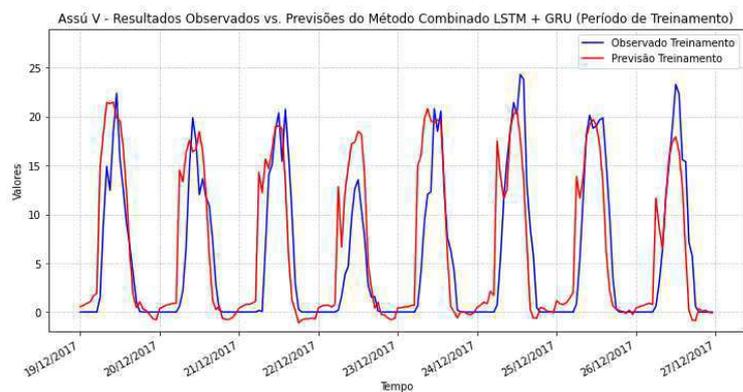
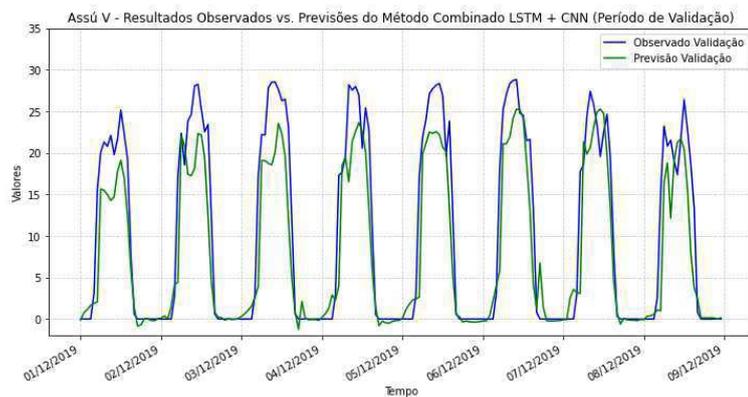
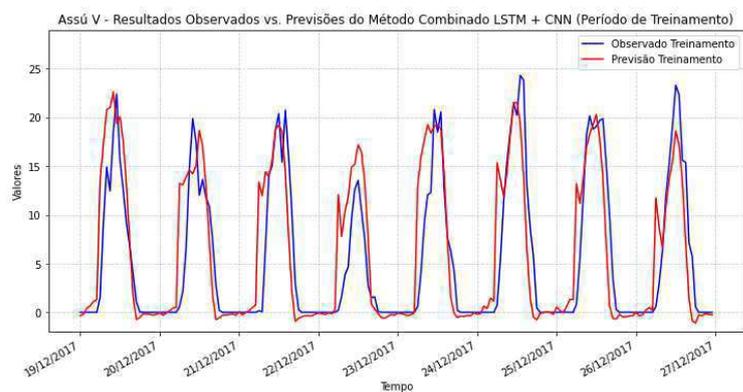
Anexo A36. Métricas de avaliação de desempenho com tamanho de passos 24 para o Conjunto Sol do Futuro.

Comparação de previsão multivariável de métricas de desempenho					
Método DL	Treinamento RMSE	Treinamento MAE	Validação RMSE	Validação MAE	Tamanho do passo
CNN	9.04	5.61	9.12	5.64	24
LSTM	8.45	5.02	8.44	4.95	24
GRU	8.31	5.10	8.30	5.07	24
LSTM + CNN	8.43	4.99	8.42	4.93	24
LSTM + GRU	8.37	4.98	8.39	4.96	24
CNN + GRU	8.26	4.78	8.24	4.71	24

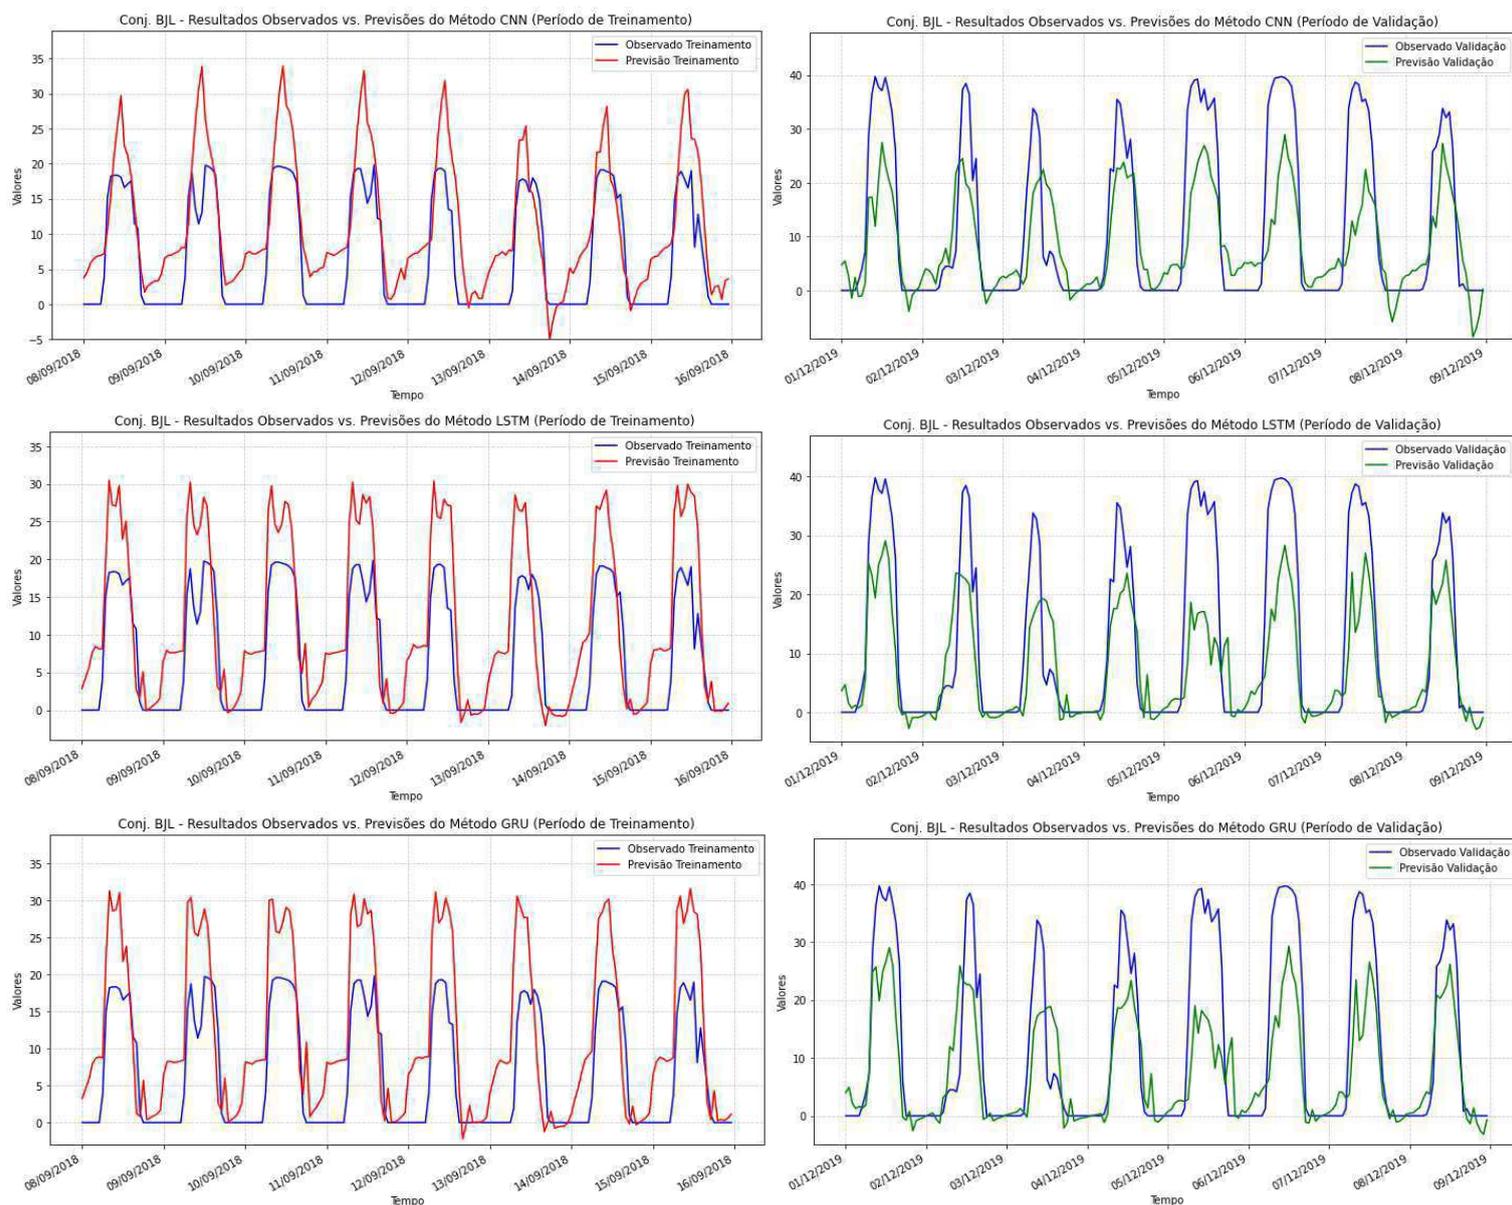
ANEXO B



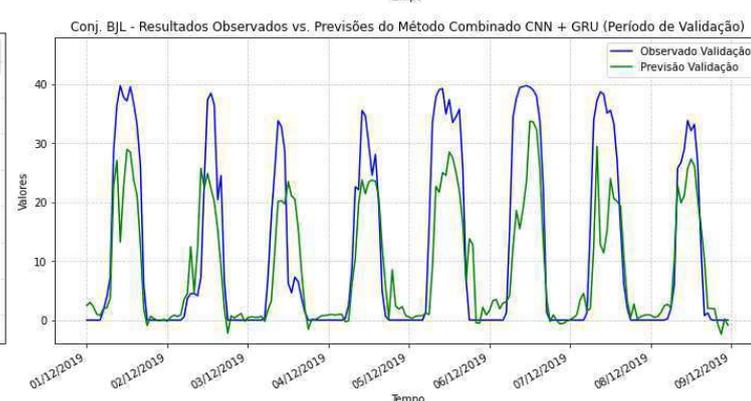
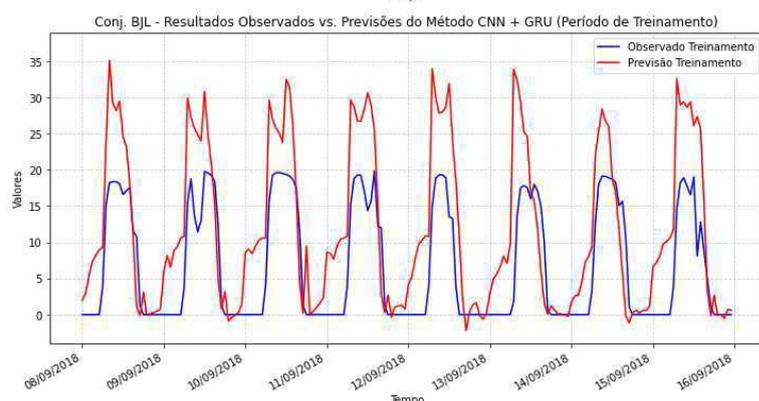
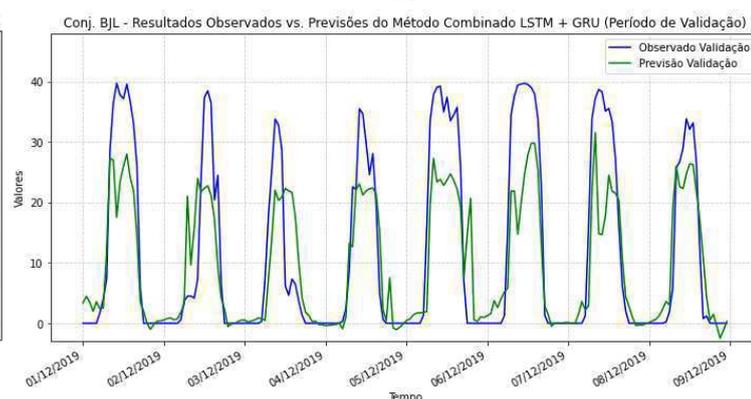
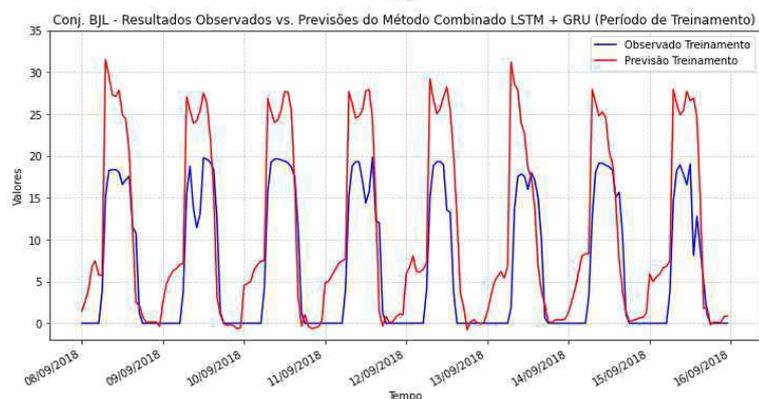
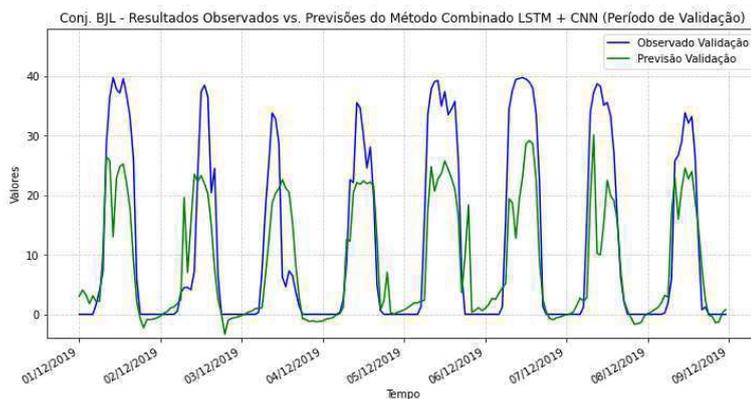
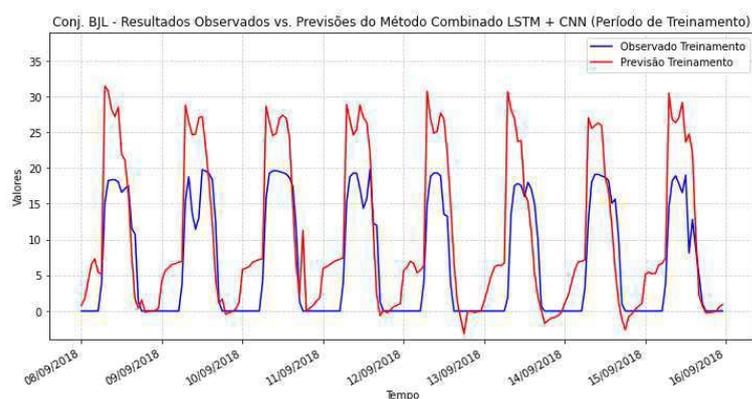
Anexo B1. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU para os períodos de treinamento e validação do conjunto de dados de Assú V.



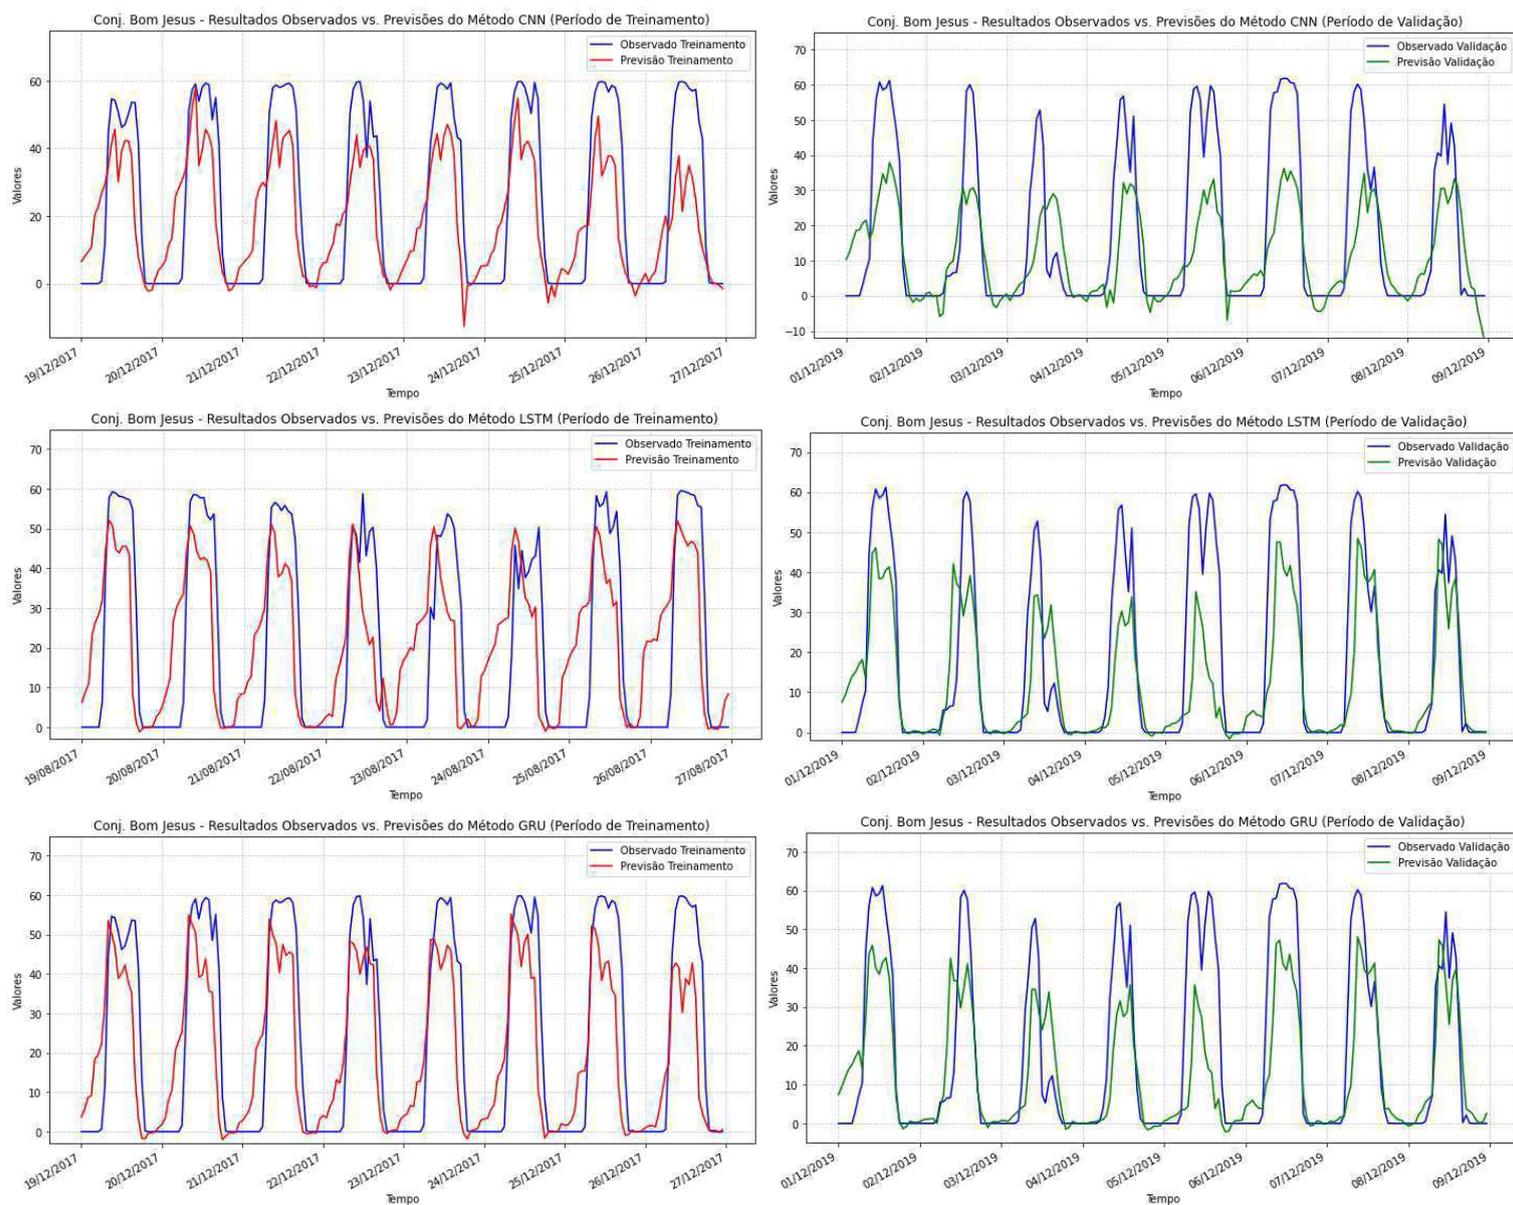
Anexo B2. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU para os períodos de treinamento e validação do conjunto de dados de Assú V.



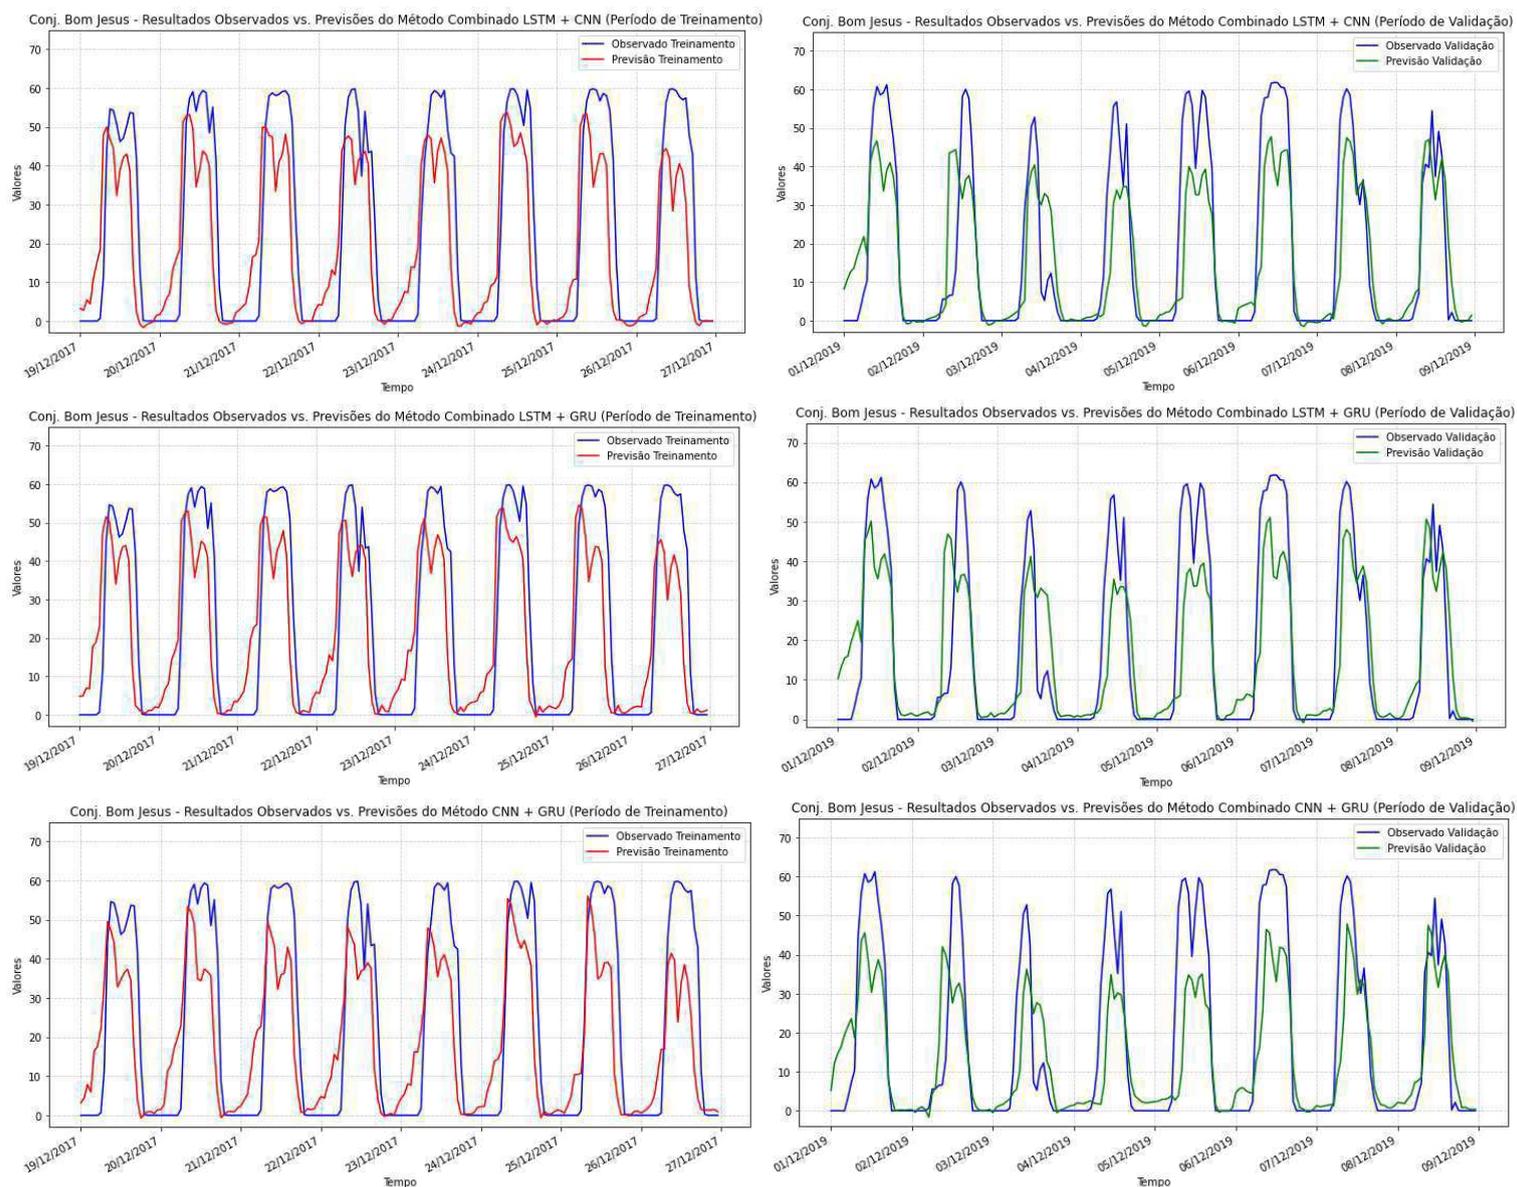
Anexo B3. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto BJJ.



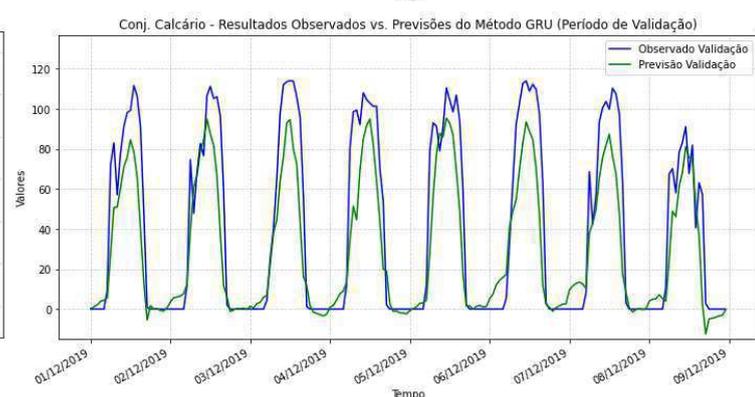
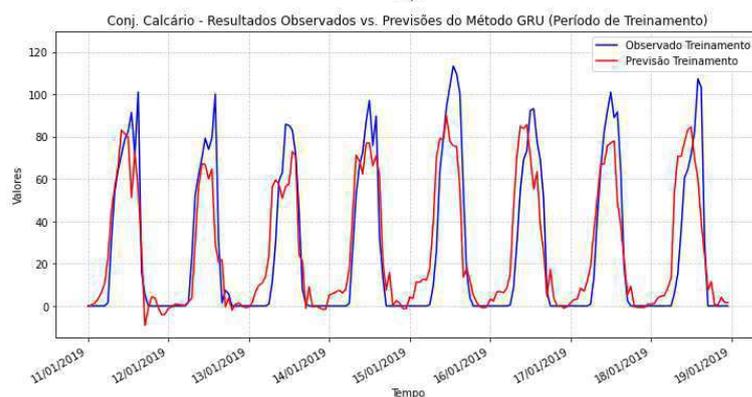
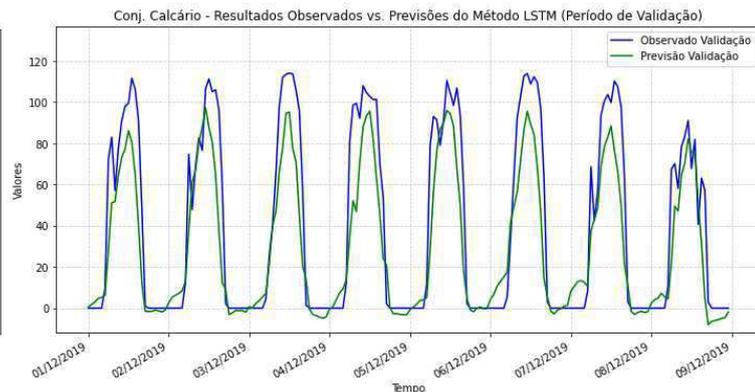
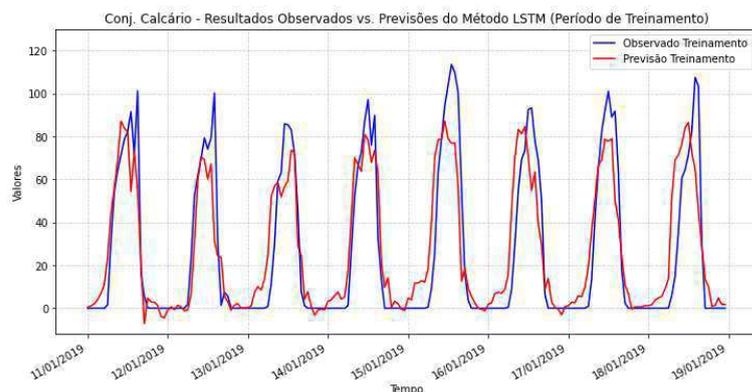
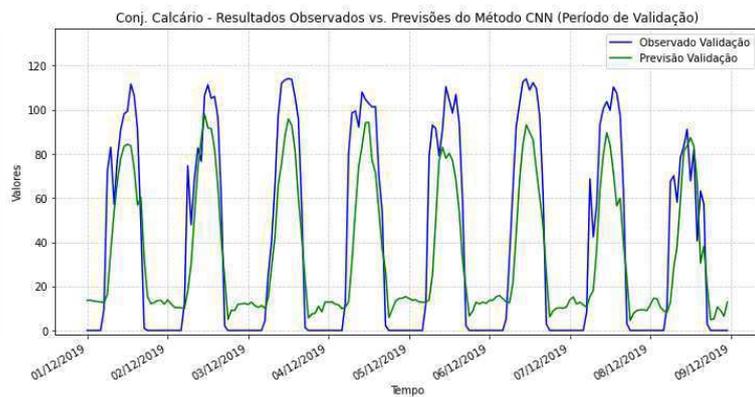
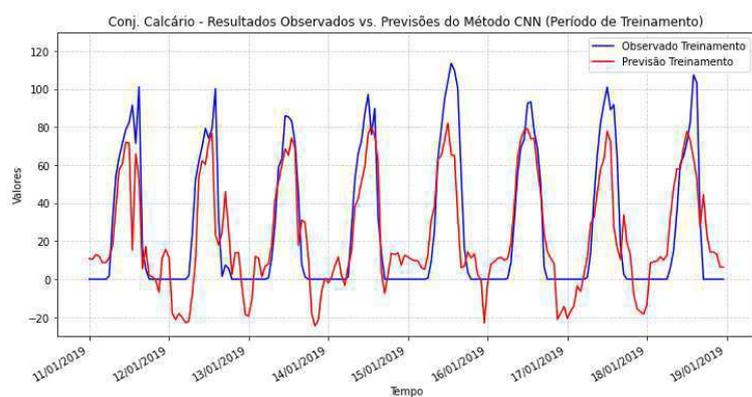
Anexo B4. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto B.JL.



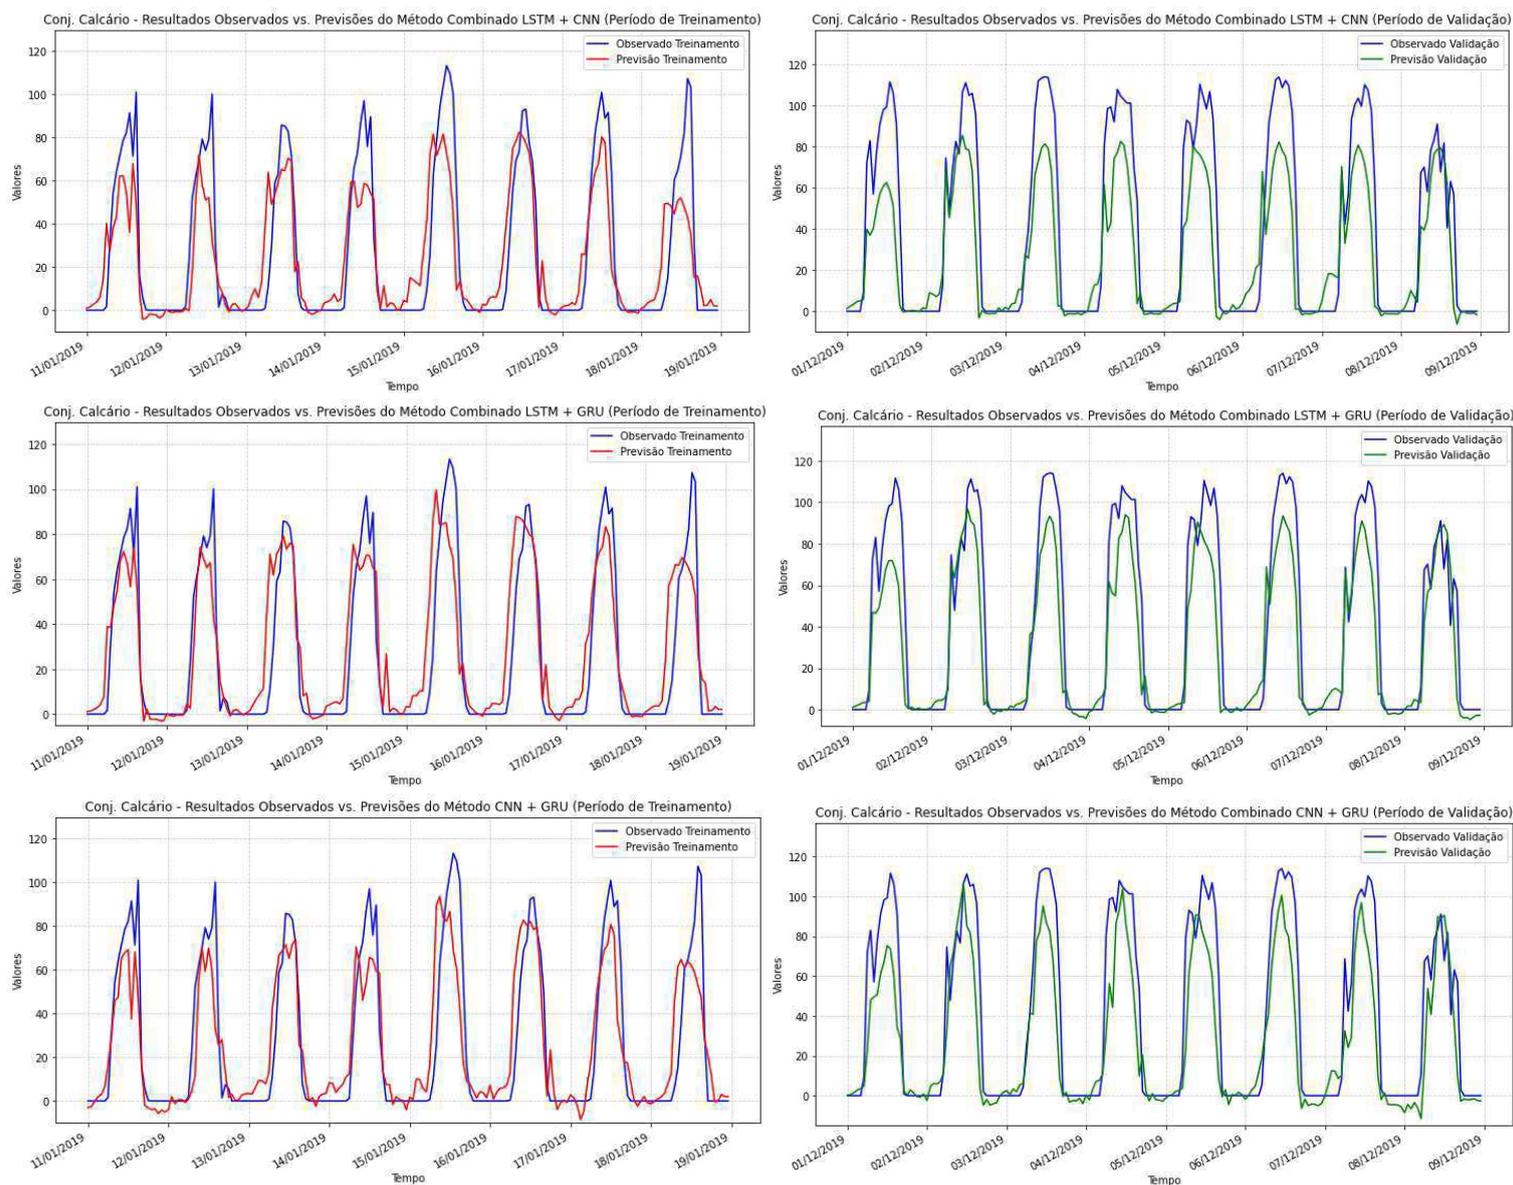
Anexo B5. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Bom Jesus.



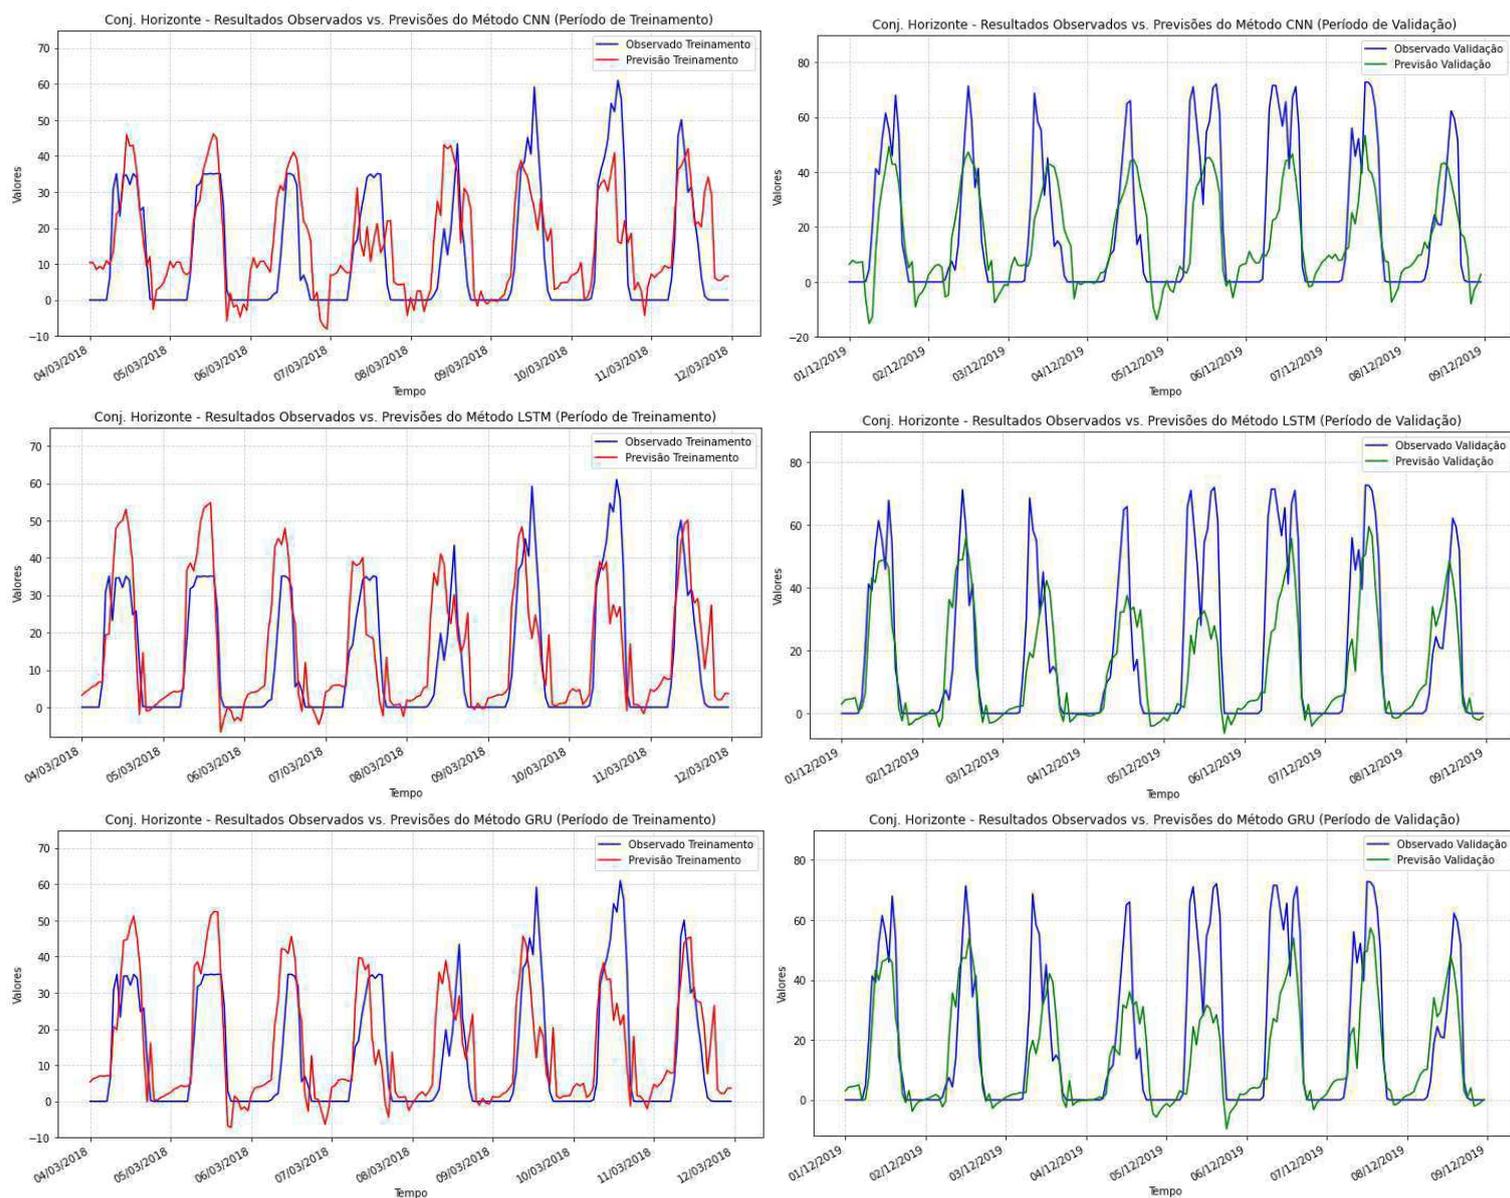
Anexo B6. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Bom Jesus.



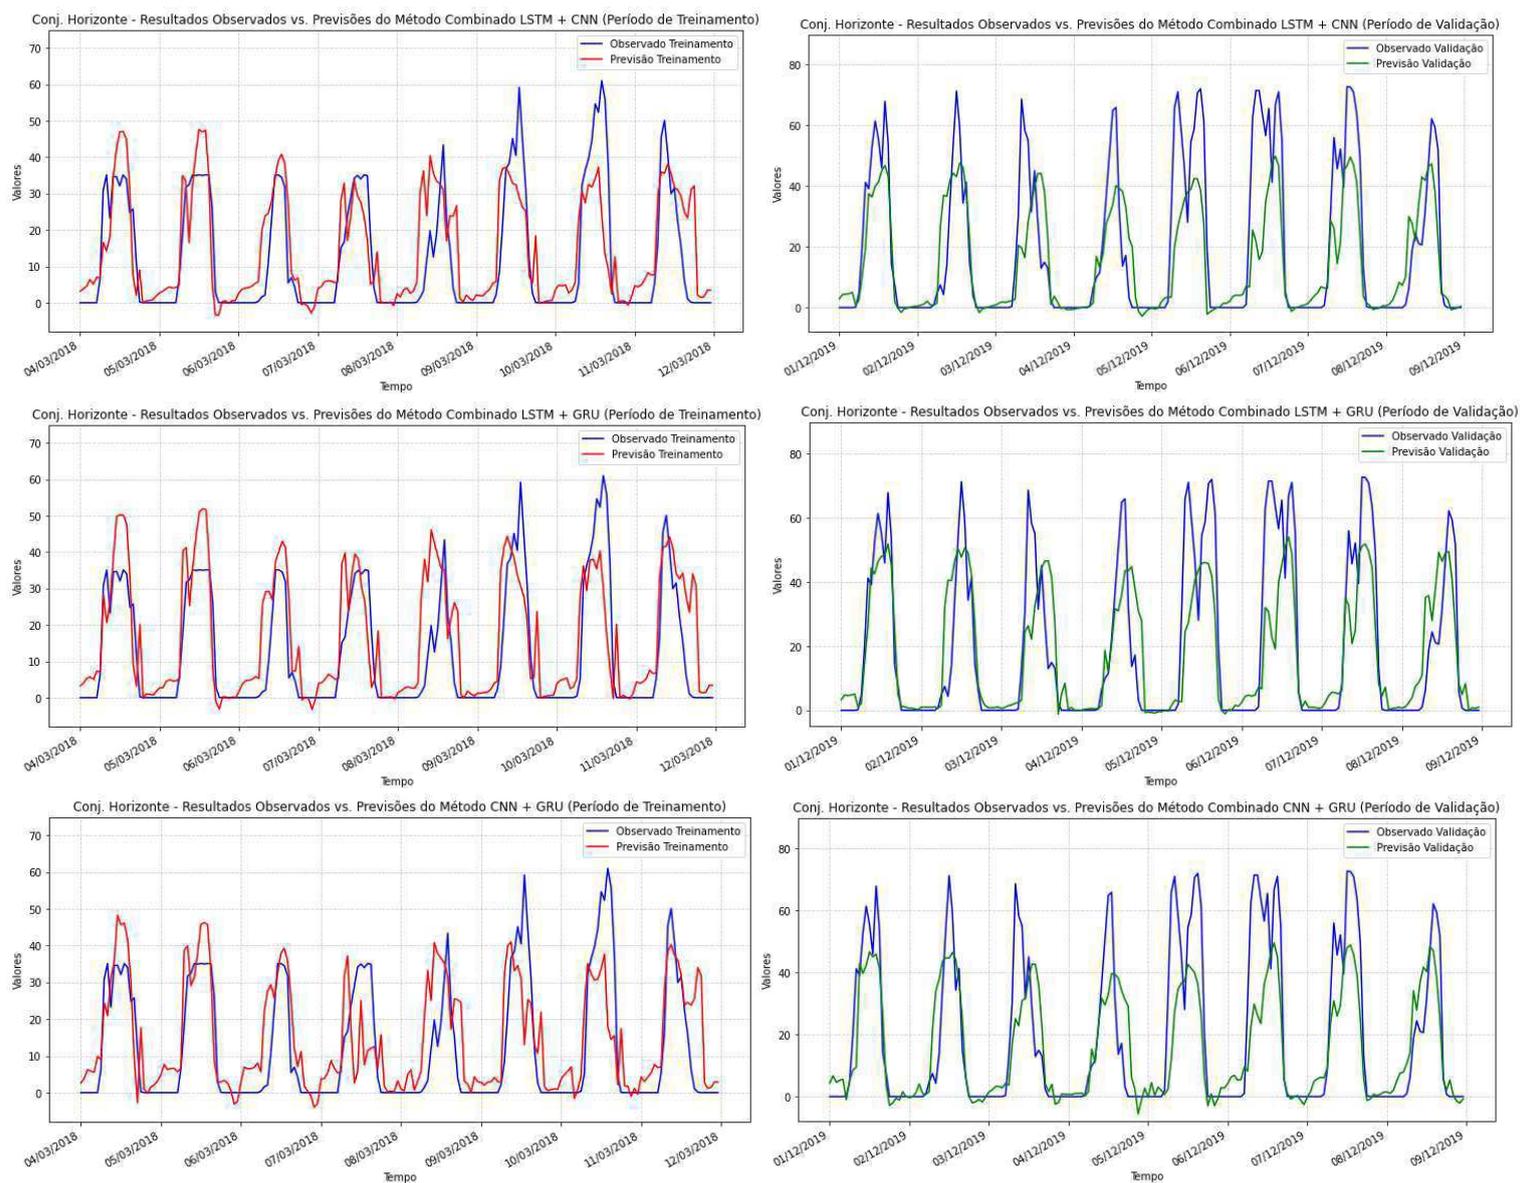
Anexo B7. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Calcário.



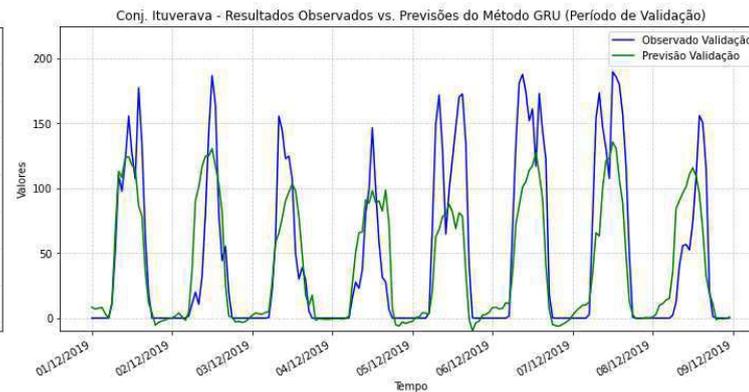
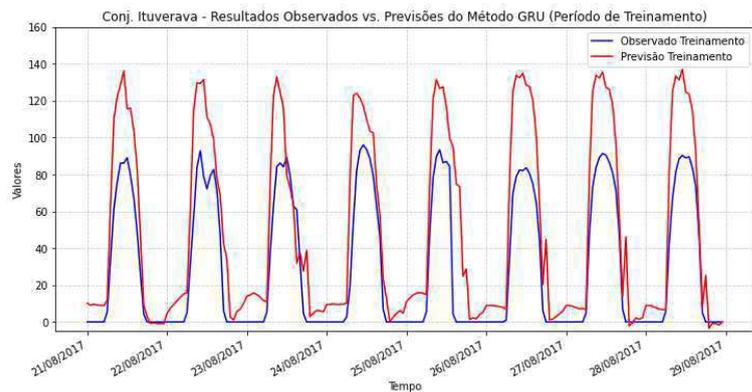
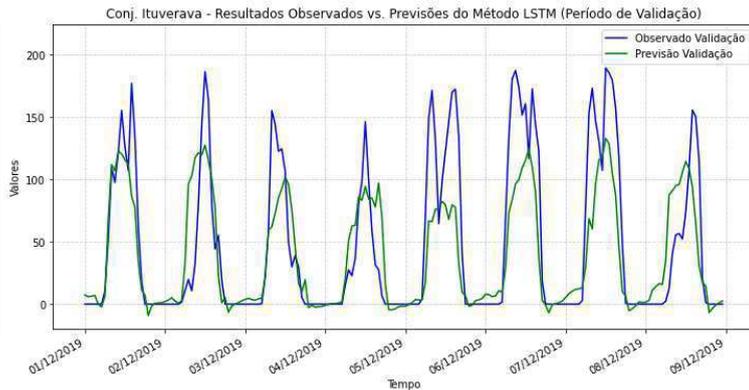
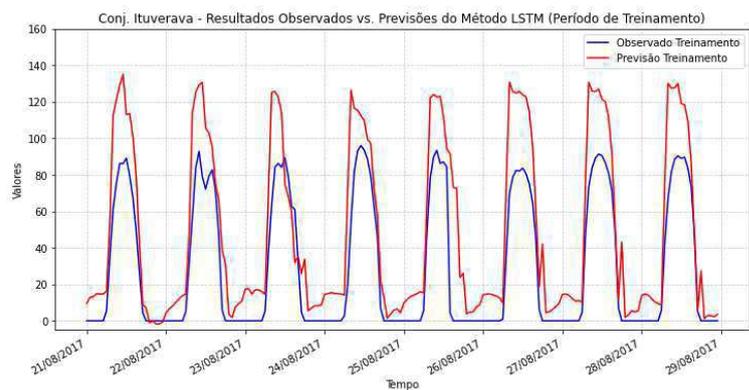
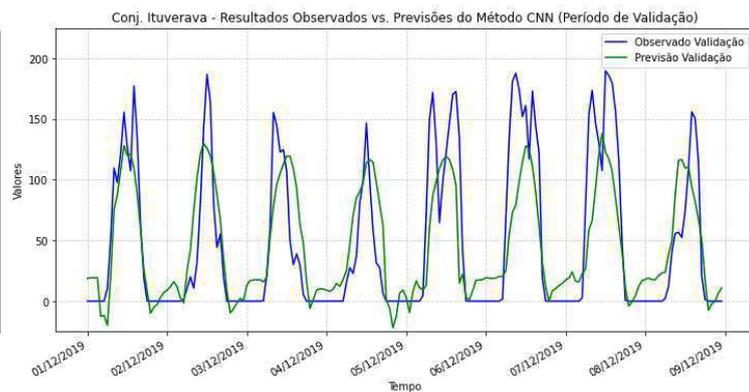
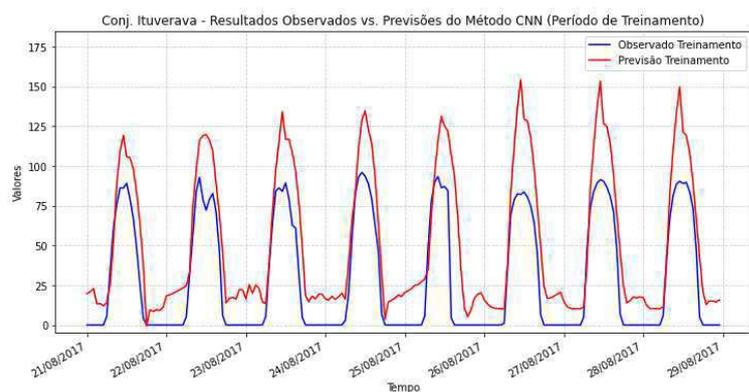
Anexo B8. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Calcário.



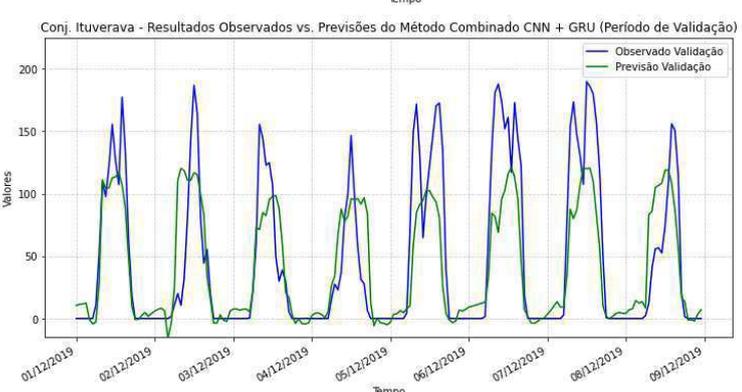
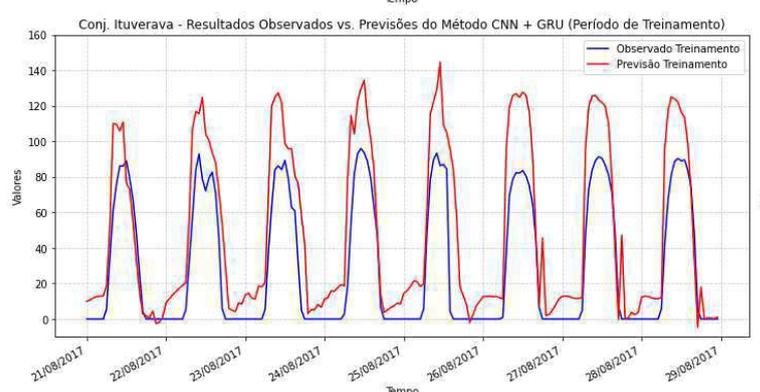
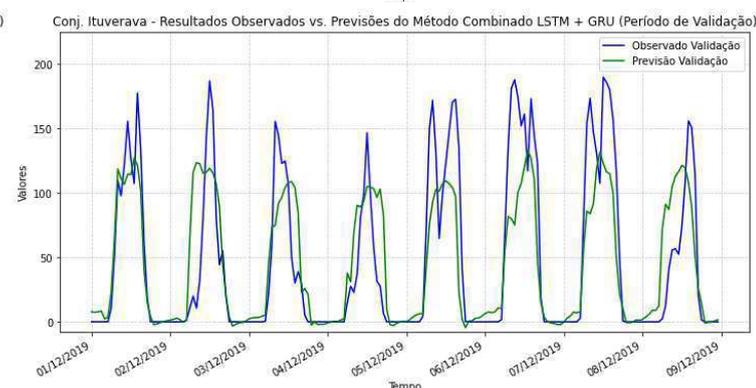
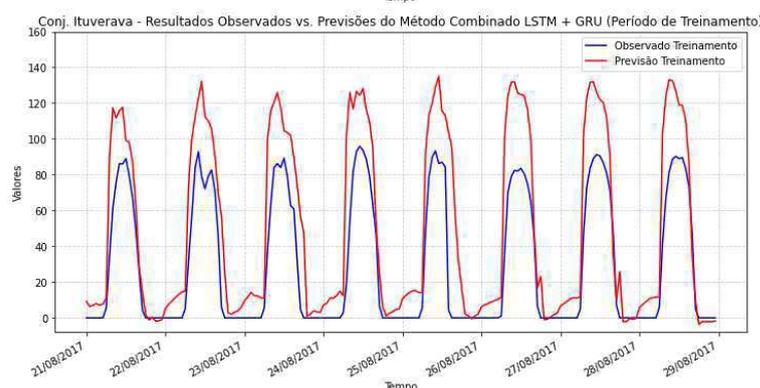
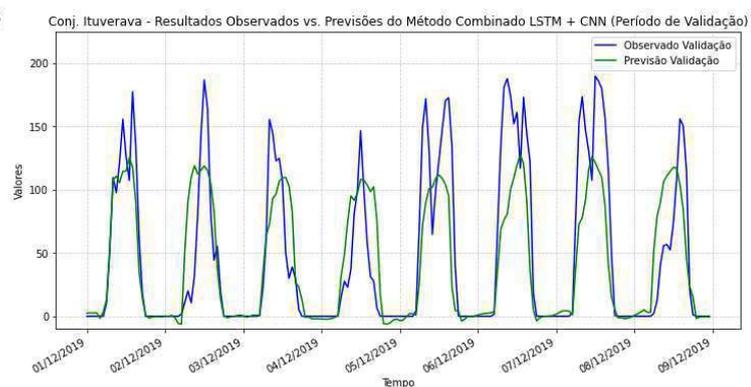
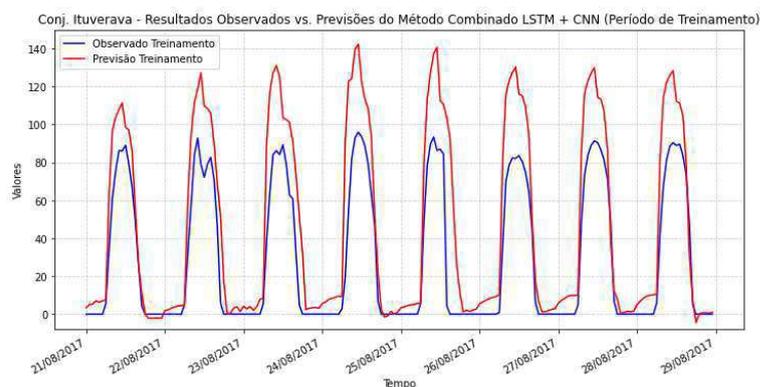
Anexo B9. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Horizonte.



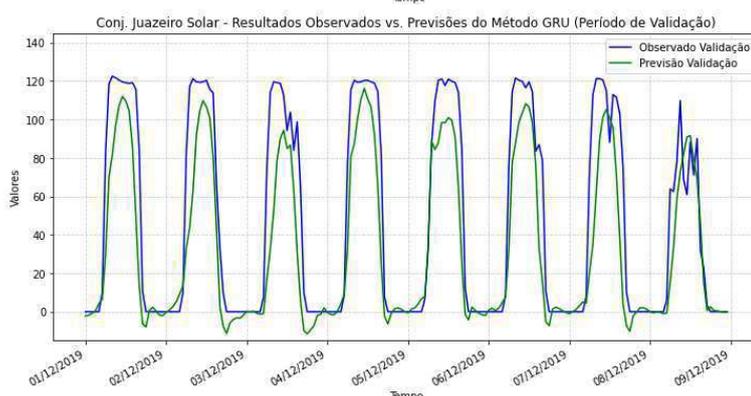
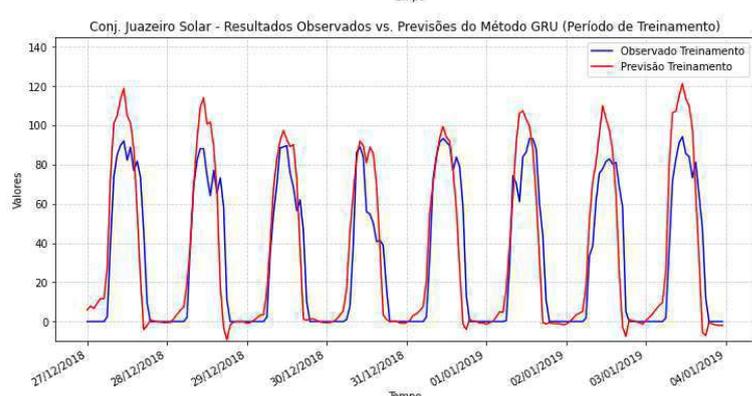
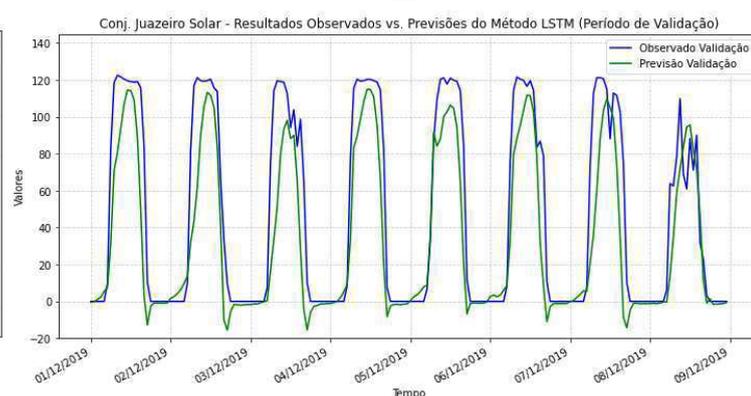
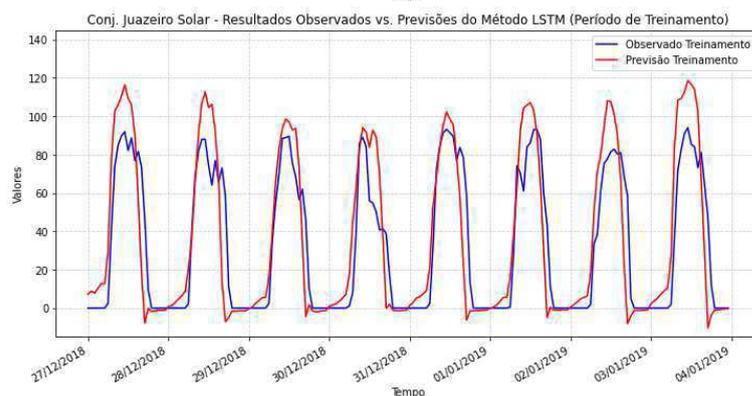
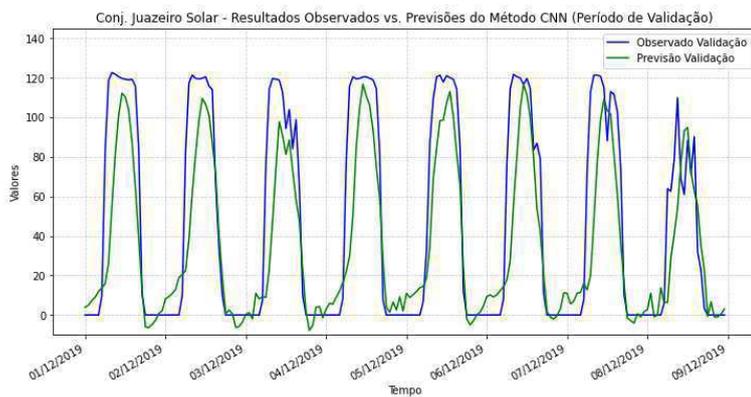
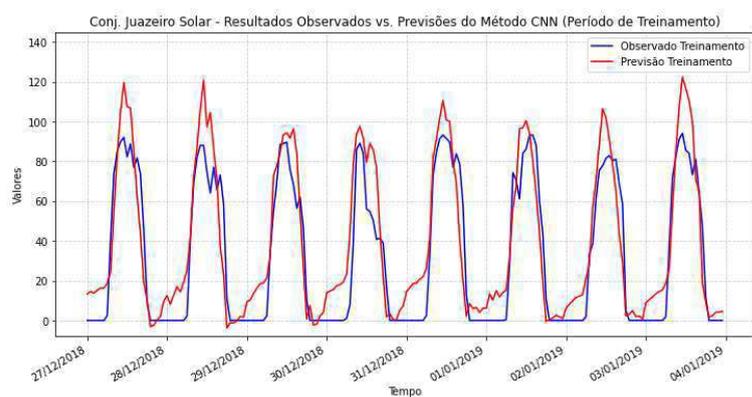
Anexo B10. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Horizonte.



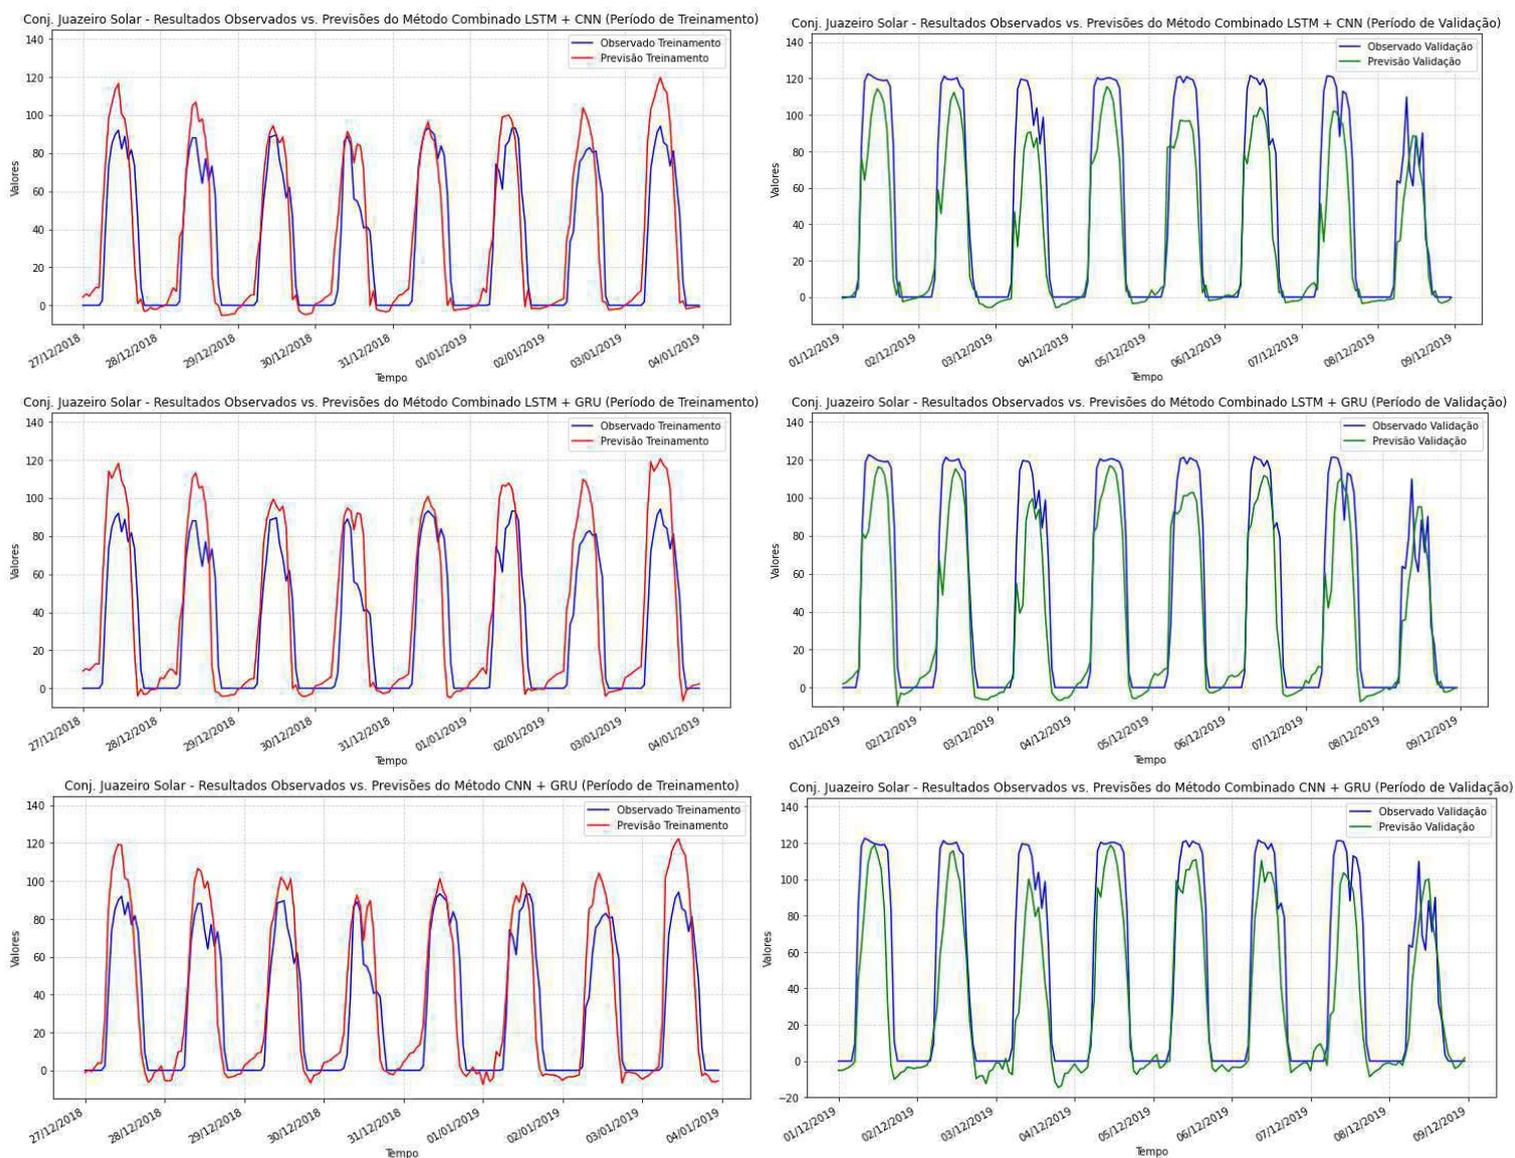
Anexo B11. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Ituverava.



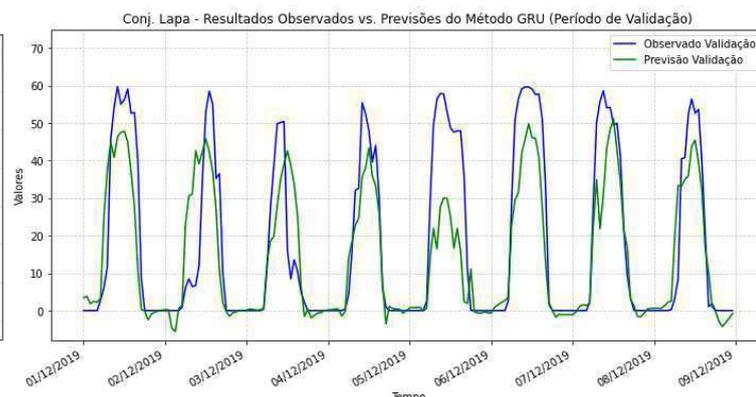
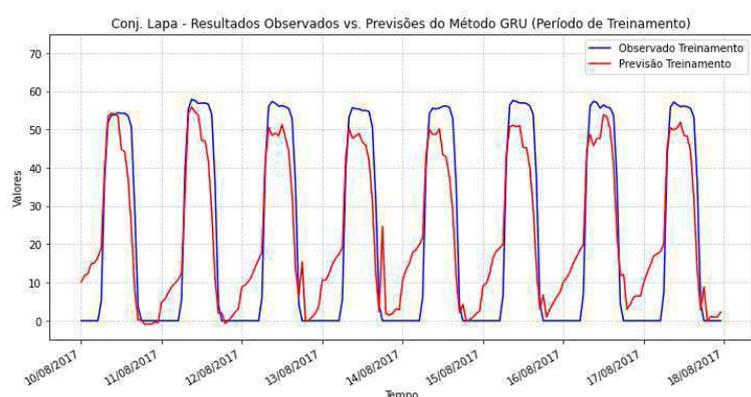
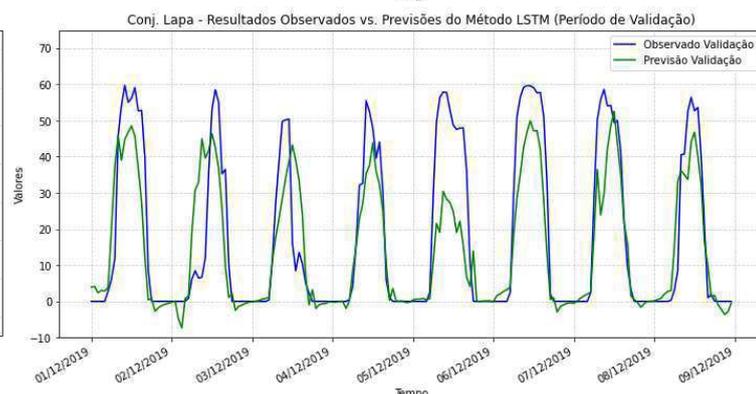
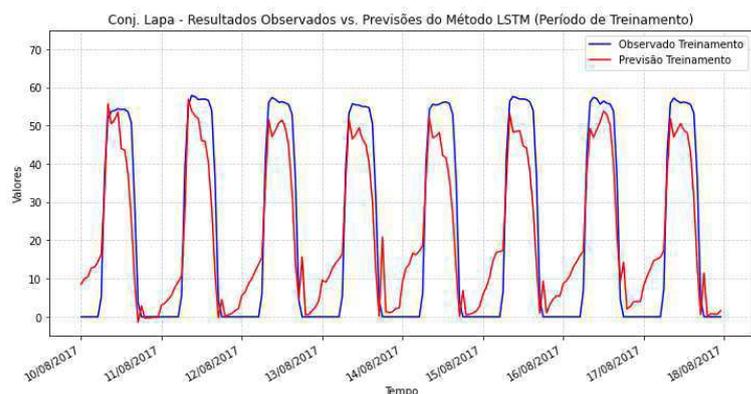
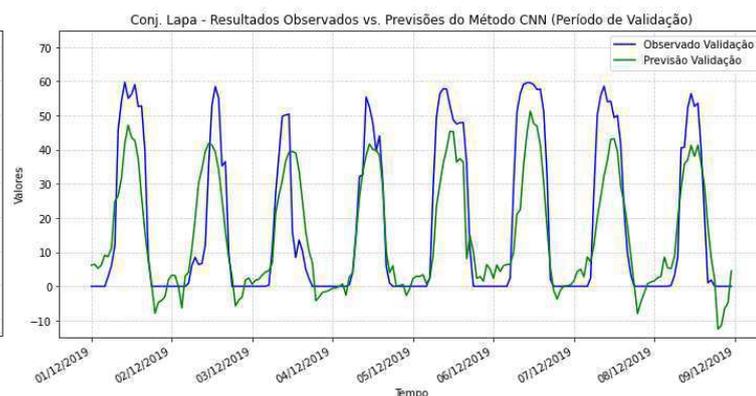
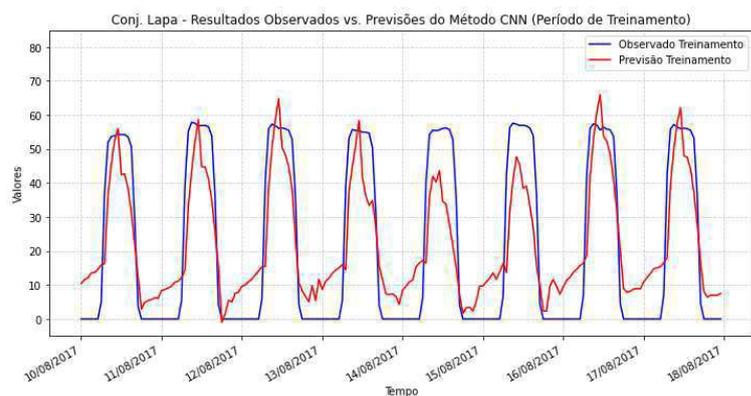
Anexo B12. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Ituverava.



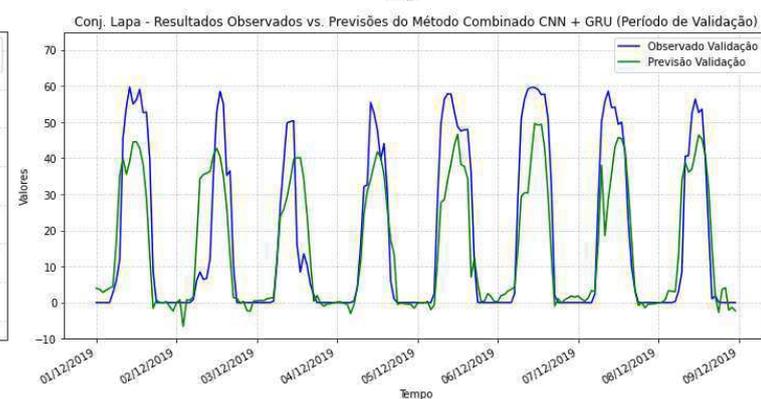
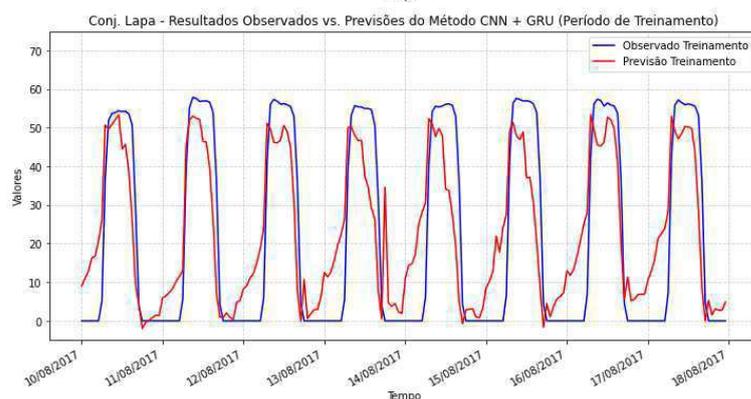
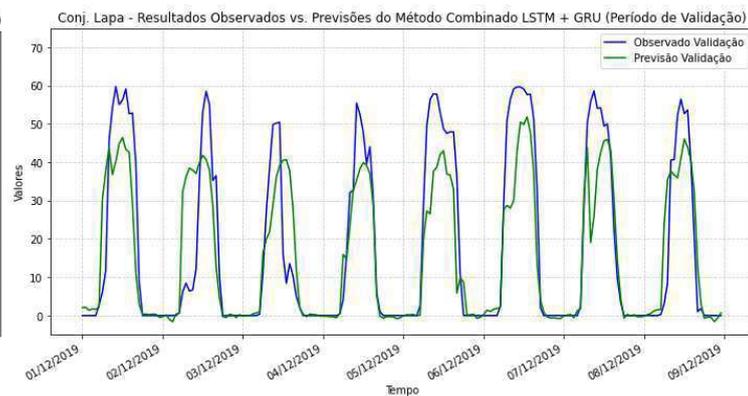
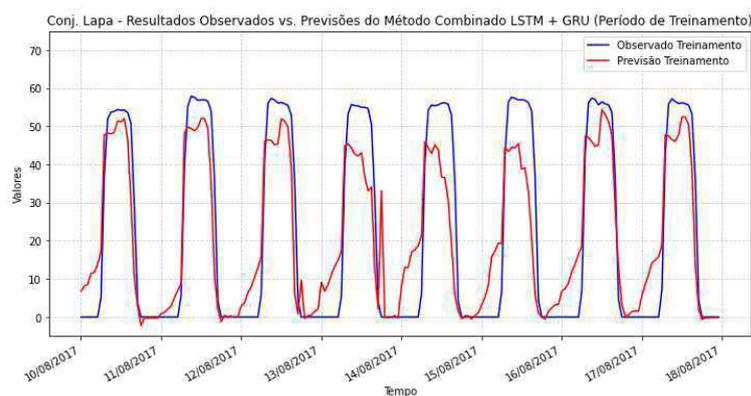
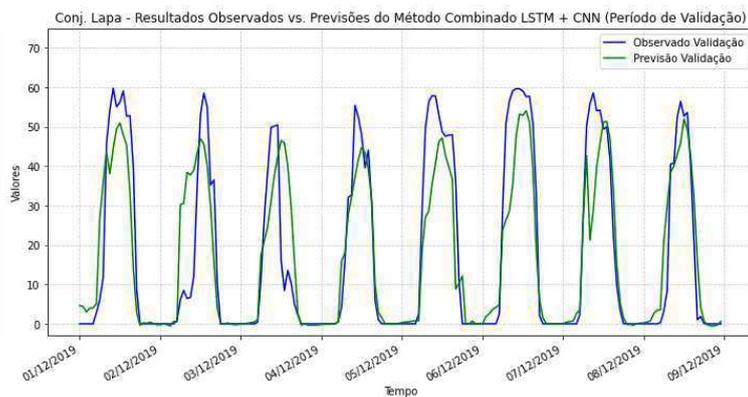
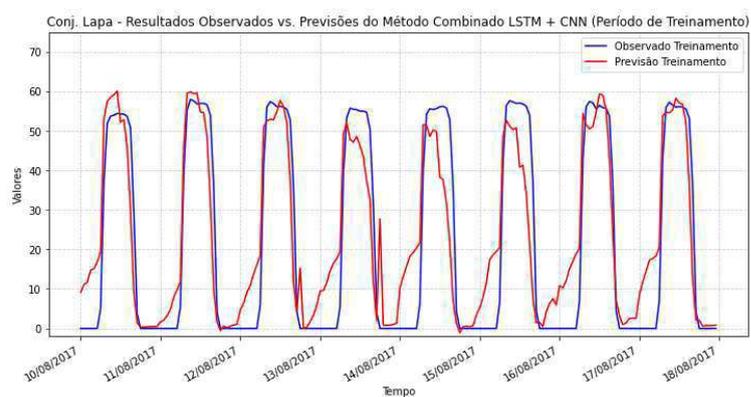
Anexo B13. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Juazeiro Solar.



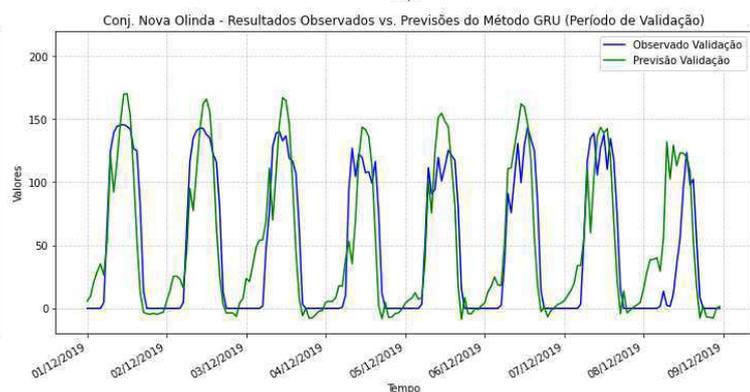
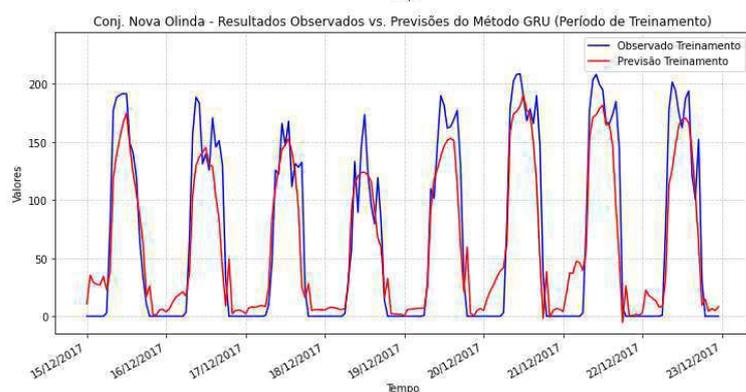
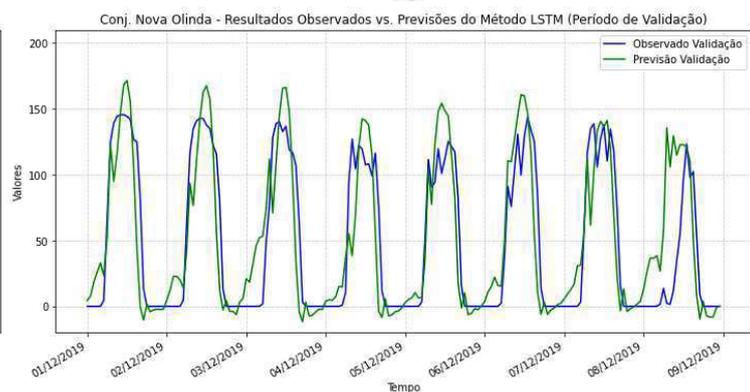
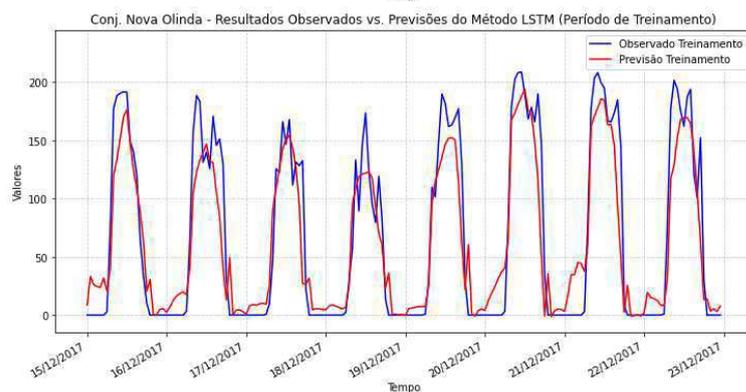
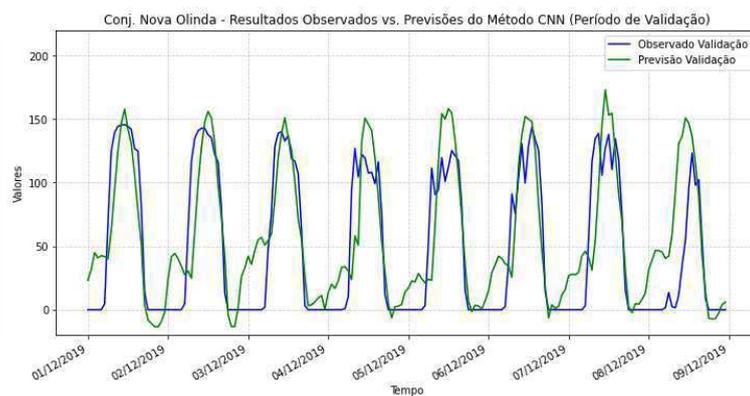
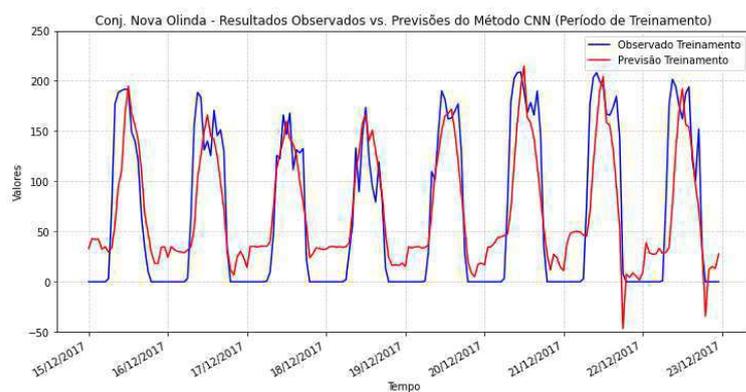
Anexo B14. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Juazeiro Solar.



Anexo B15. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Lapa.

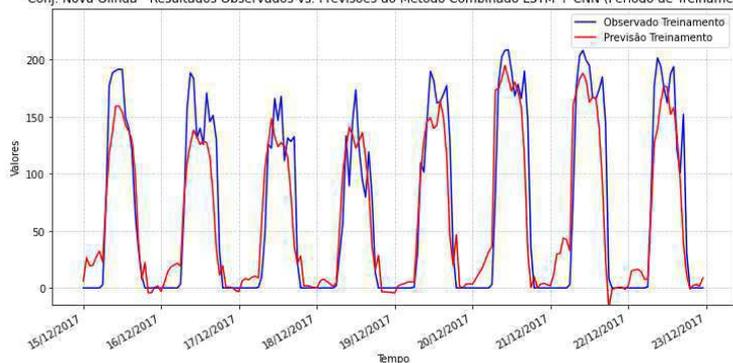


Anexo B16. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Lapa.

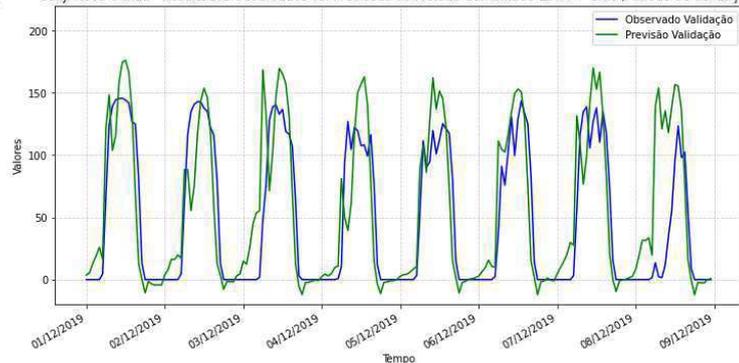


Anexo B17. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Nova Olinda.

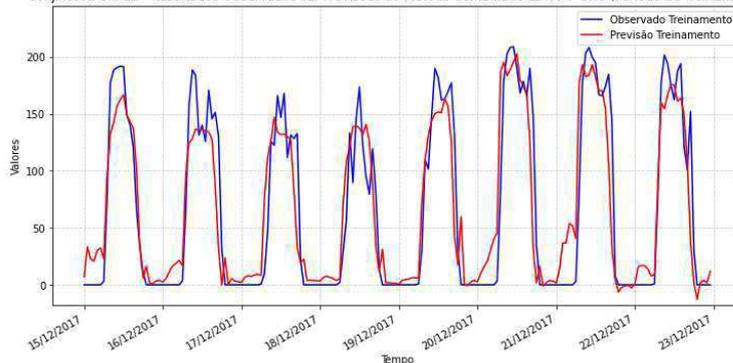
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método Combinado LSTM + CNN (Período de Treinamento)



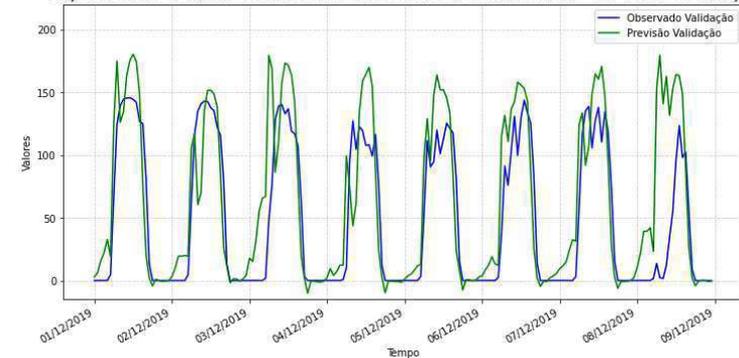
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método Combinado LSTM + CNN (Período de Validação)



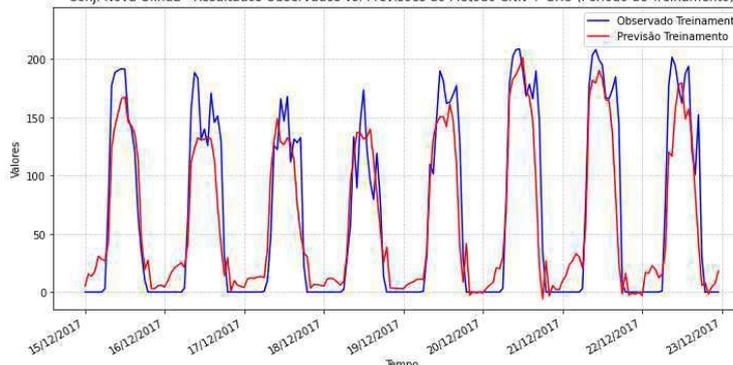
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método Combinado LSTM + GRU (Período de Treinamento)



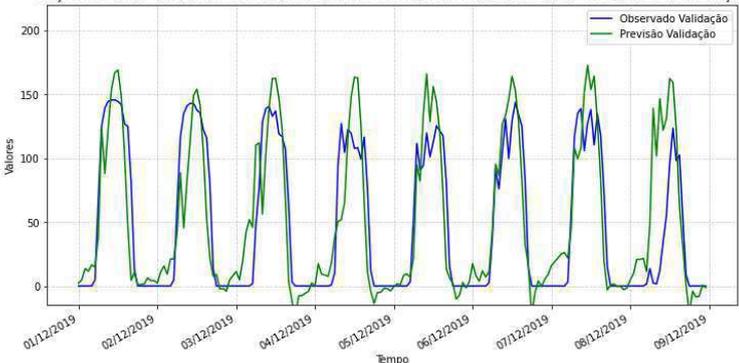
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método Combinado LSTM + GRU (Período de Validação)



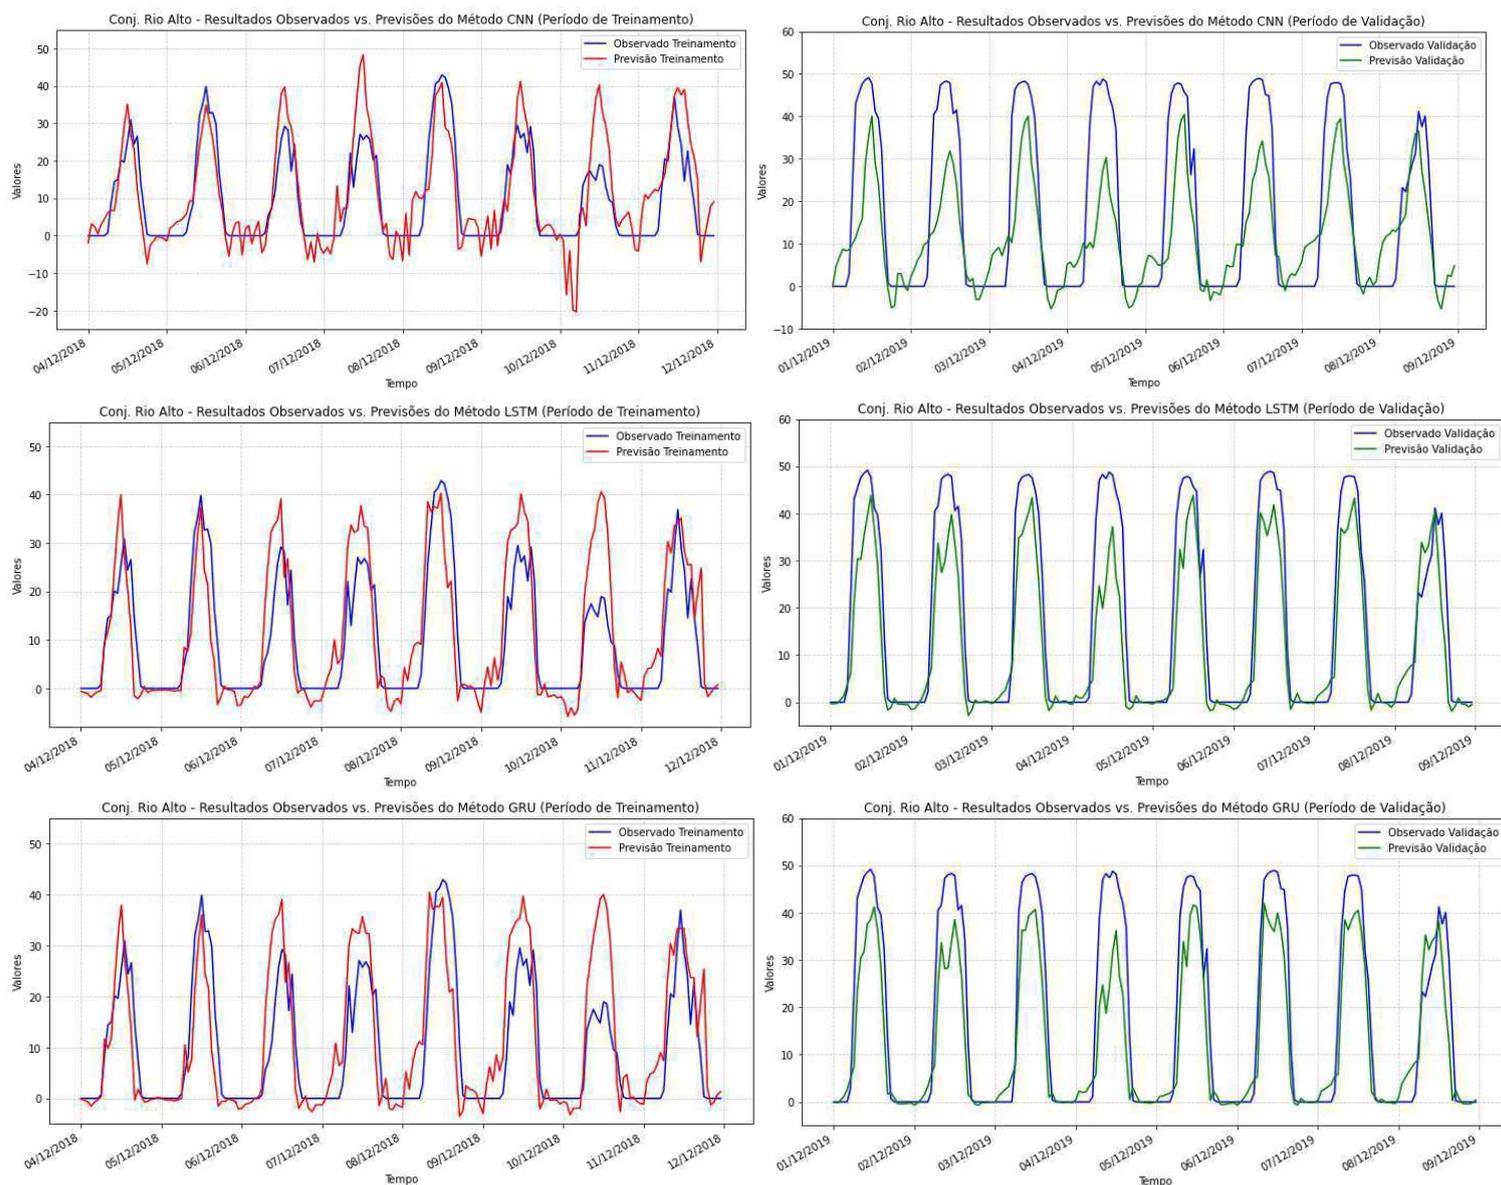
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método CNN + GRU (Período de Treinamento)



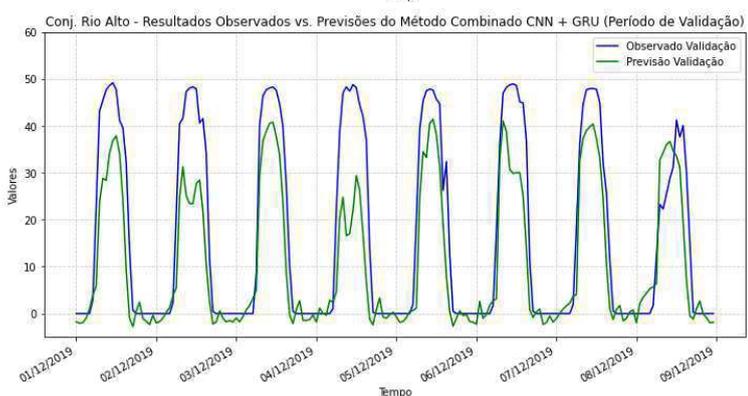
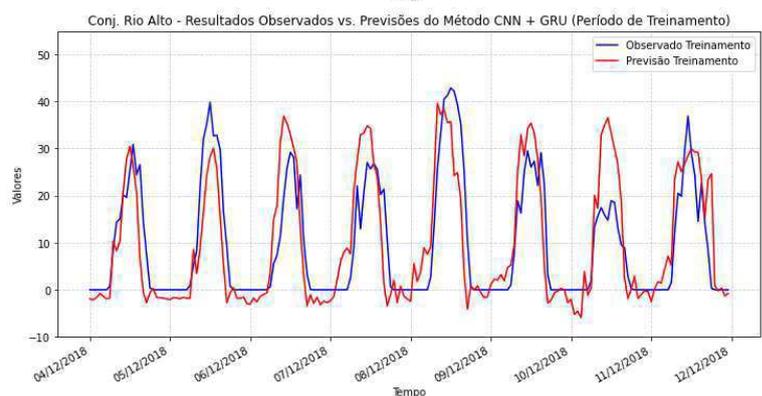
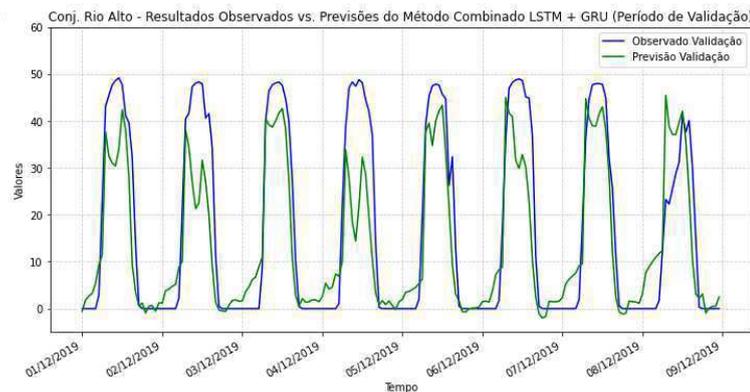
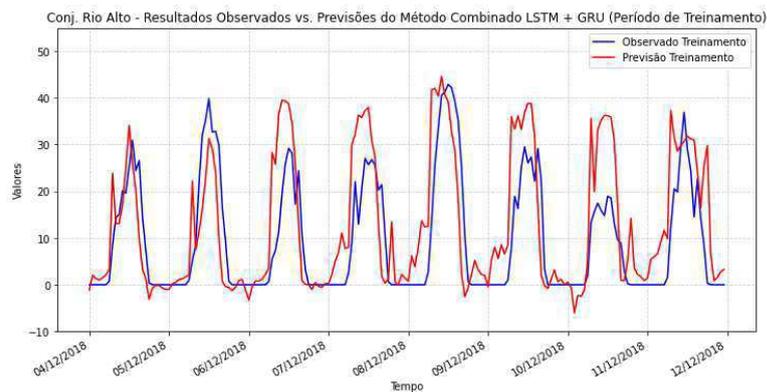
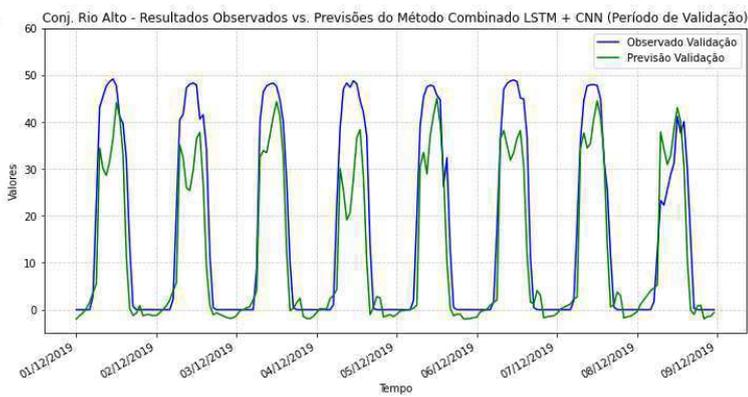
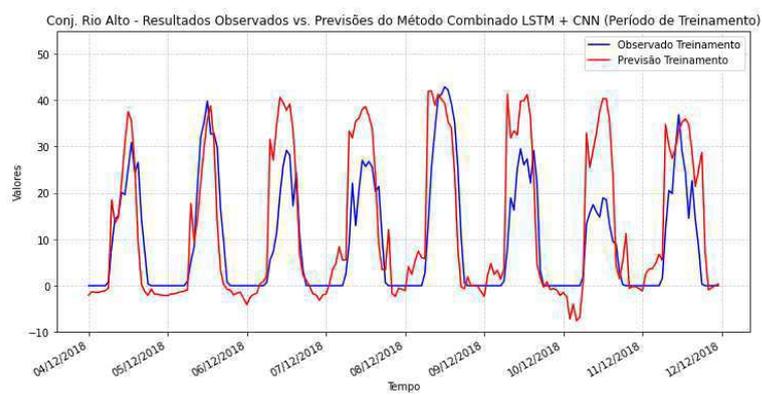
Conj. Nova Olinda - Resultados Observados vs. Previsões do Método Combinado CNN + GRU (Período de Validação)



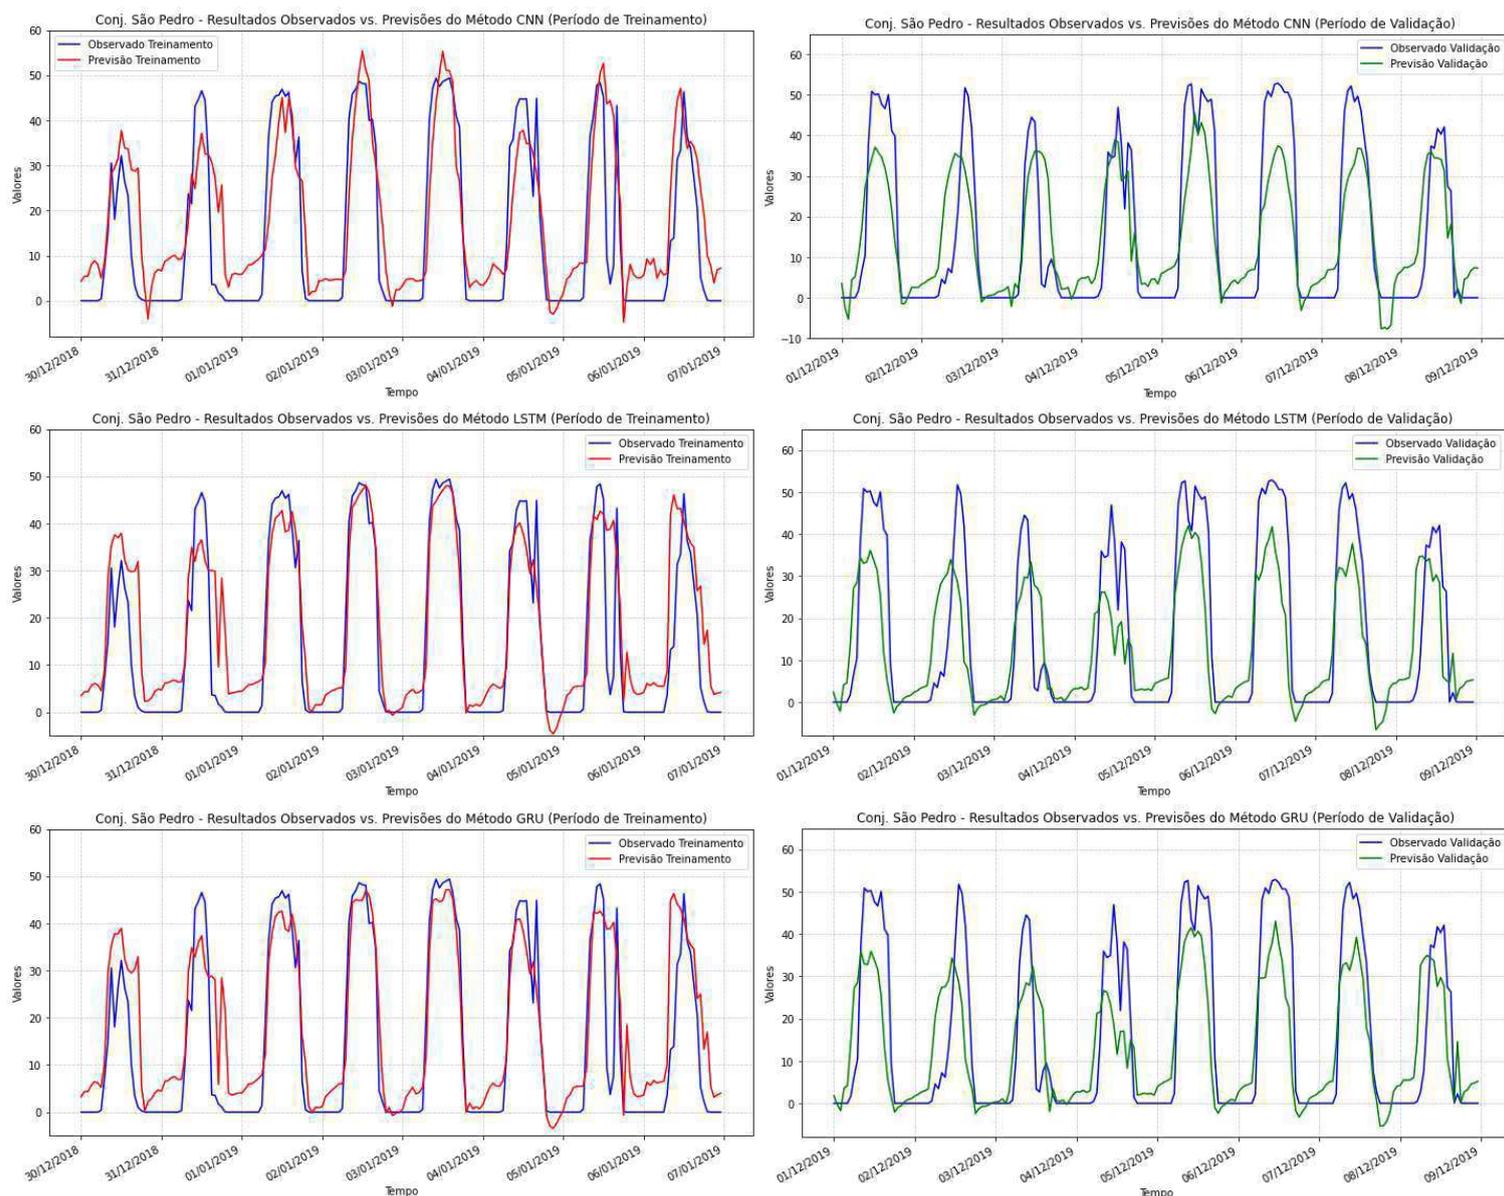
Anexo B18. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Nova Olinda.



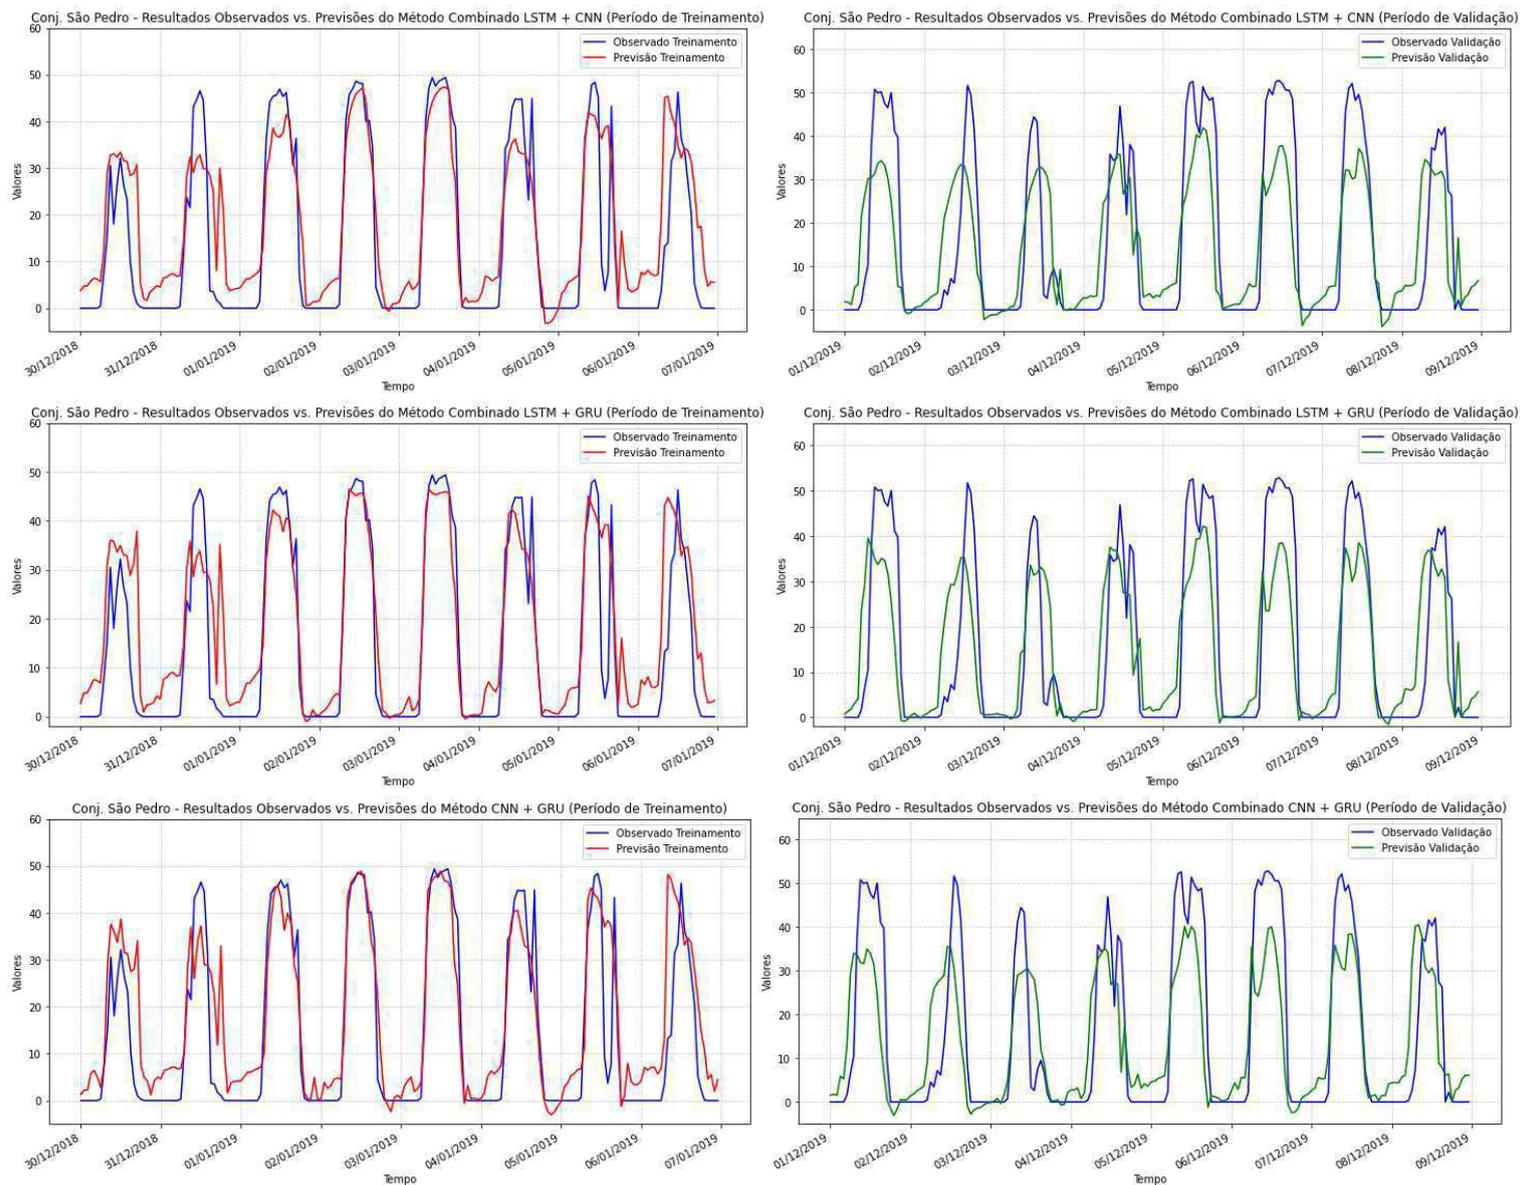
Anexo B19. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Rio Alto.



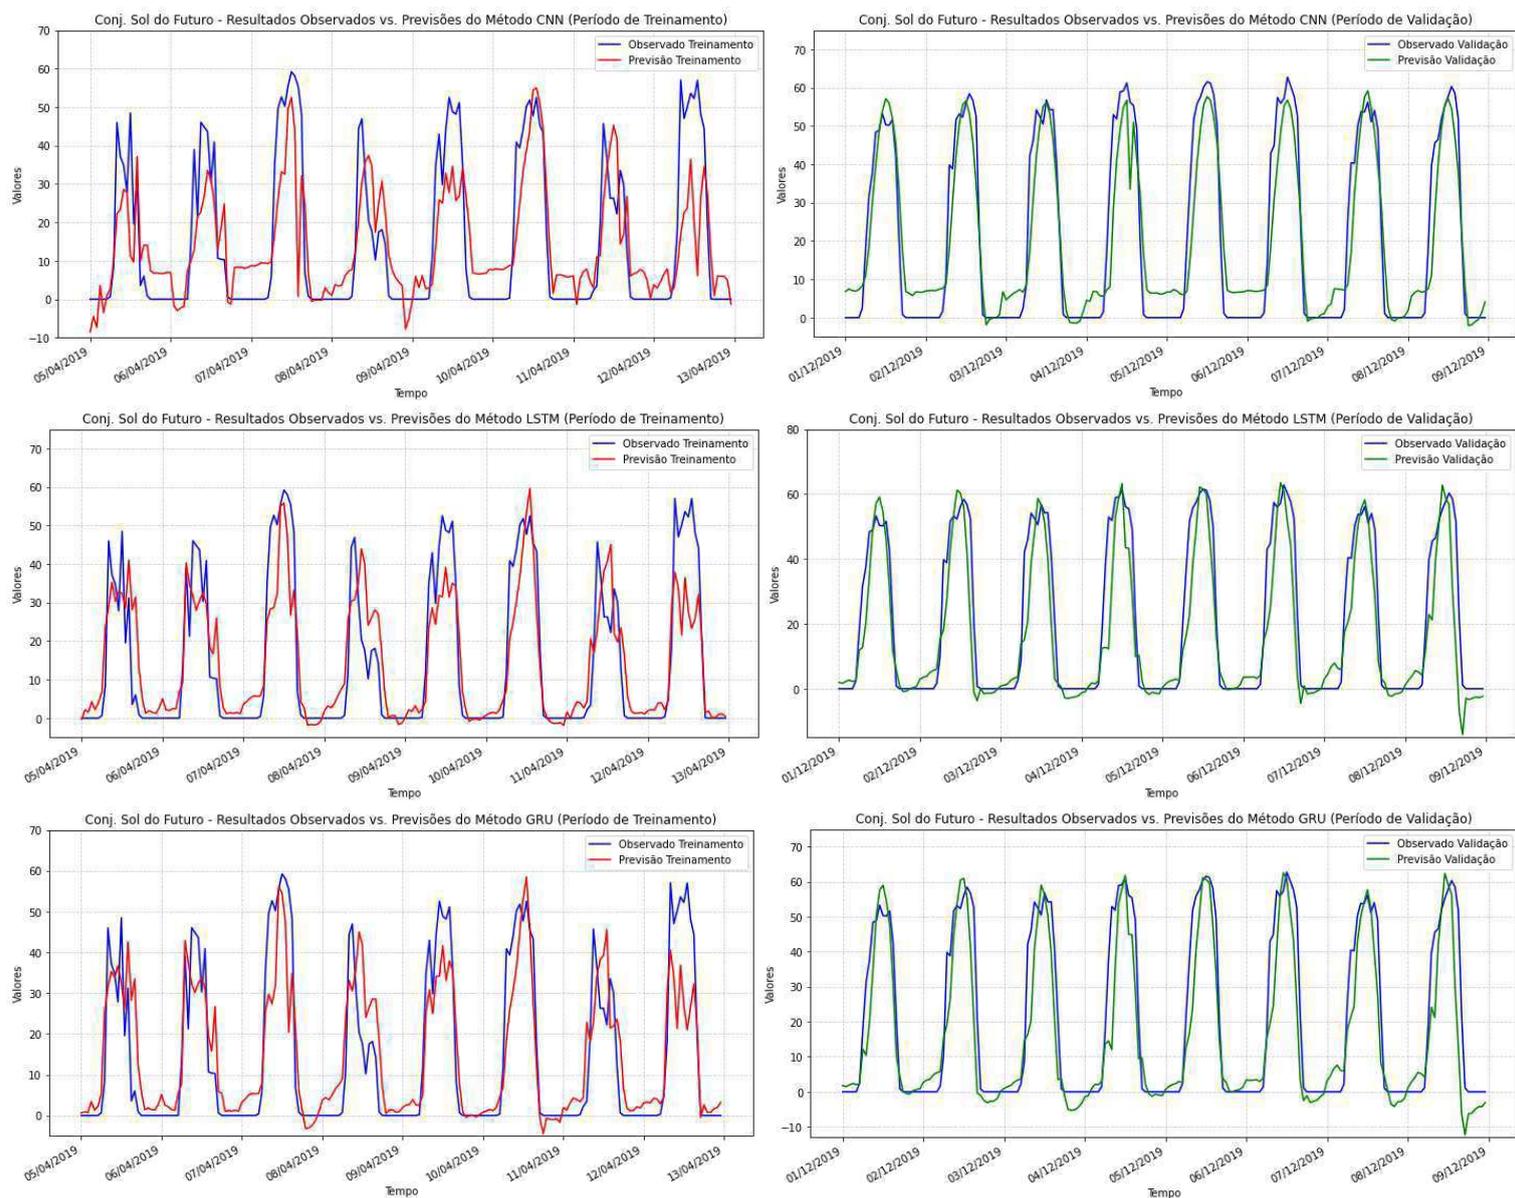
Anexo B20. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Rio Alto.



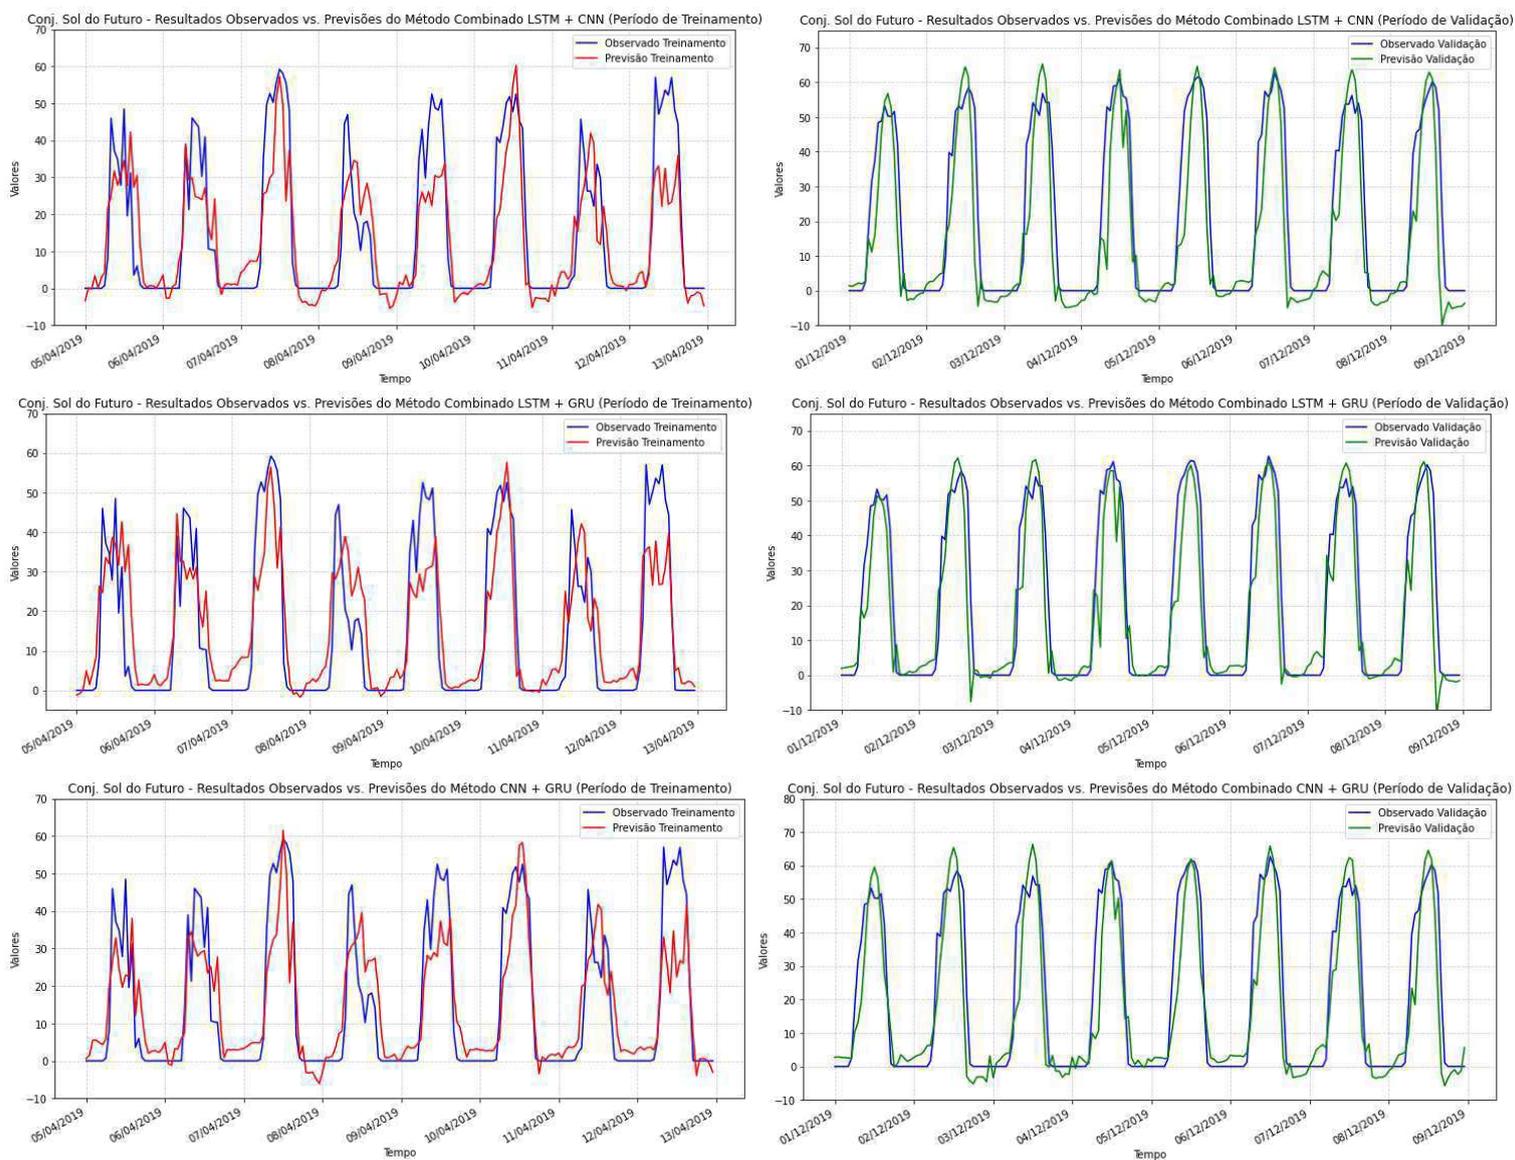
Anexo B21. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto São Pedro.



Anexo B22. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto São Pedro.



Anexo B23. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos CNN, LSTM e GRU durante os períodos de treinamento e validação para os dados do Conjunto Sol do Futuro.



Anexo B24. Dados observados e previsão com tamanhos de passos 6, 12 e 24, referente aos métodos combinados LSTM+CNN, LSTM+GRU e CNN+GRU durante os períodos de treinamento e validação para os dados do Conjunto Sol do Futuro.

ANEXO C

Anexo C1. Resultados de eficiência de treinamento e validação para Assú V.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	181.43	2745.85
LSTM	11251	271.52	2570.11
GRU	8001	307.82	2894.95
LSTM + CNN	11571	229.31	3004.25
LSTM + GRU	19251	358.76	3203.32
CNN + GRU	8321	343.06	3132.81

Anexo C2. Resultados de eficiência de treinamento e validação para o Conjunto BJJ.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	134.25	1807.44
LSTM	11251	172.98	1511.68
GRU	8001	234.80	2066.64
LSTM + CNN	11571	174.74	2382.31
LSTM + GRU	19251	282.36	2782.48
CNN + GRU	8321	329.37	2775.66

Anexo C3. Resultados de eficiência de treinamento e validação para o Conjunto Bom Jesus.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	270.49	2176.19
LSTM	11251	304.69	2155.34
GRU	8001	492.39	2252.18
LSTM + CNN	11571	494.51	2414.80
LSTM + GRU	19251	753.51	2410.45
CNN + GRU	8321	502.75	1769.22

Anexo C4. Resultados de eficiência de treinamento e validação para o Conjunto Calcário.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	98.32	2604.61
LSTM	11251	250.25	1473.18
GRU	8001	159.36	2500.11
LSTM + CNN	11571	130.45	3104.92
LSTM + GRU	19251	214.40	2982.35
CNN + GRU	8321	221.29	3074.82

Anexo C5. Resultados de eficiência de treinamento e validação para o Conjunto Horizonte.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	330.48	2440.45
LSTM	11251	443.17	1646.30
GRU	8001	573.92	2489.19
LSTM + CNN	11571	632.29	2647.13
LSTM + GRU	19251	639.68	2974.28
CNN + GRU	8321	584.20	3292.19

Anexo C6. Resultados de eficiência de treinamento e validação para o Conjunto Ituverava.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	204.67	2131.91
LSTM	11251	229.56	1540.48
GRU	8001	374.12	2210.40
LSTM + CNN	11571	337.35	2503.90
LSTM + GRU	19251	560.94	2646.05
CNN + GRU	8321	528.43	2440.59

Anexo C7. Resultados de eficiência de treinamento e validação para o Conjunto Juazeiro Solar.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	110.47	1925.11
LSTM	11251	108.46	1488.86
GRU	8001	213.18	2099.98
LSTM + CNN	11571	172.31	2372.96
LSTM + GRU	19251	254.28	2521.62
CNN + GRU	8321	236.84	2698.83

Anexo C8. Resultados de eficiência de treinamento e validação para o Conjunto Lapa.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	309.93	2137.13
LSTM	11251	362.24	1542.43
GRU	8001	420.41	2160.26
LSTM + CNN	11571	361.66	2438.49
LSTM + GRU	19251	538.31	2574.27
CNN + GRU	8321	491.98	2424.14

Anexo C9. Resultados de eficiência de treinamento e validação para o Conjunto Nova Olinda.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	248.78	1881.39
LSTM	11251	262.69	1547.71
GRU	8001	447.55	2158.38
LSTM + CNN	11571	348.03	2288.16
LSTM + GRU	19251	498.14	2417.25
CNN + GRU	8321	399.61	2547.93

Anexo C10. Resultados de eficiência de treinamento e validação para o Conjunto Rio Alto.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	137.80	1781.00
LSTM	11251	159.56	1483.20
GRU	8001	246.05	1986.35
LSTM + CNN	11571	189.01	2280.53
LSTM + GRU	19251	275.43	2538.80
CNN + GRU	8321	284.42	2586.65

Anexo C11. Resultados de eficiência de treinamento e validação para o Conjunto São Pedro.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	122.49	1734.35
LSTM	11251	155.99	1487.71
GRU	8001	185.42	1853.38
LSTM + CNN	11571	132.49	2117.14
LSTM + GRU	19251	218.02	2450.54
CNN + GRU	8321	215.43	2644.38

Anexo C12. Resultados de eficiência de treinamento e validação para o Conjunto Sol do Futuro.

Método DL	Parâmetros totais treináveis	Tempo de execução (s)	Ram (MB)
CNN	3557	136.74	1546.34
LSTM	11251	121.79	1472.28
GRU	8001	230.51	1749.92
LSTM + CNN	11571	139.33	2017.81
LSTM + GRU	19251	231.69	2215.11
CNN + GRU	8321	214.67	2364.24