

MINISTÉRIO DA EDUCAÇÃO

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS

Escola de Engenharia

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e Materiais -
PPGE3M

**DESENVOLVIMENTO DE METODOLOGIA DE PREDIÇÃO DE GERAÇÃO
FOTOVOLTAICA EM CURTO E MÉDIO PRAZO A PARTIR DE ANÁLISE DE
SISTEMAS FOTOVOLTAICOS E DE PLATAFORMAS DE PREVISÃO
METEOROLÓGICA**

M.Sc. Eng. André Possamai Rosso

Tese para a obtenção do título de Doutor em Engenharia

Porto Alegre

Setembro de 2024

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Escola de Engenharia

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais -
PPGE3M

Desenvolvimento de metodologia de predição de geração fotovoltaica em curto e médio
prazo a partir de análise de sistemas fotovoltaicos e de plataformas de previsão
meteorológica

M.Sc. André Possamai Rosso

Engenheiro de Energia

Proposta submetida à banca examinadora do Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais, PPGE3M, da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como Tese para posterior obtenção do título de Doutor em Engenharia.

Área de concentração: Processos de Fabricação

Orientador: Prof. Ing. Lirio Schaeffer, Dr.

Coorientador: Prof. Giuliano Arns Rampinelli, Dr.

Banca Examinadora:

Prof. Alexandre José Bühler, Dr. - Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul, IFRS

Prof. Fabiano Perin Gasparin, Dr. - Universidade Federal do Rio Grande do Sul, UFRGS

Prof. Roberto Zilles, Dr. - Universidade de São Paulo, USP

Prof. Rodrigo de Lemos Peroni, Dr.

Coordenador do PPGE3M – UFRGS

Dedico aos meus pais,
Amilto Rosso (*in memoriam*) e
Dilma Possamai Rosso (*in memoriam*),
e à minha esposa, Juliana Loch Locatelli.

AGRADECIMENTOS

Esta dedicação vai para todos aqueles que de alguma forma contribuíram para eu estar aqui.

Agradeço a Deus, por todos os momentos que eu vivenciei até aqui, por me dar forças nos momentos mais difíceis que presenciei, por colocar pessoas incríveis em minha vida e que de alguma forma me ajudaram a chegar até aqui.

À minha família, pelo exemplo de força, confiança, sabedoria e persistência na caminhada. Aos meus pais, Amilto (*in memoriam*) e Dilma (*in memoriam*), e à minha irmã, Karoline. Em especial, à minha esposa, Juliana, por toda paciência e apoio em todos os momentos e por compartilhar comigo todas as minhas conquistas.

Ao meu orientador, Prof. Dr. Ing. Lirio Schaeffer, e ao meu coorientador, Prof. Dr. Giuliano Arns Rampinelli, por sempre me receberem de portas abertas, por me apoiarem em todas as ideias e decisões e por todo incentivo que me deram na busca do conhecimento.

À Universidade Federal do Rio Grande do Sul (UFRGS) e à Universidade Federal de Santa Catarina (UFSC), pelo espaço físico fornecido. Ao Prof. M.Sc. Geovio Kroth do Instituto Federal de Santa Catarina (IFSC), pelos dados de geração dos subsistemas fotovoltaicos do Instituto Federal de Criciúma - SC. Aos funcionários da UFRGS, pela disponibilidade e gentileza prestada.

Ao Programa de Pós-Graduação em Minas, Metalúrgica e Materiais (PPGE3M), por todo o apoio prestado. À Fundação de Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro.

A todos os professores do Programa de Pós-Graduação em Minas, Metalúrgica e Materiais da UFRGS.

*“Se, a princípio, a ideia não é absurda,
então não há esperança para ela”.*

Albert Einstein

SUMÁRIO

LISTA DE ILUSTRAÇÕES	X
LISTA DE TABELAS	XIV
LISTA DE SIGLAS	XVII
LISTA DE SÍMBOLOS	XIX
RESUMO	XX
ABSTRACT	XXI
PUBLICAÇÕES RELACIONADAS À TESE	XXII
1 INTRODUÇÃO.....	26
1.1 HIPÓTESES	28
1.2 OBJETIVOS	28
1.2.1 Objetivo Geral	28
1.2.2 Objetivos Específicos	28
1.3 JUSTIFICATIVA E RELEVÂNCIA.....	29
2 REFERENCIAL TEÓRICO	31
2.1 RADIAÇÃO SOLAR NA SUPERFÍCIE TERRESTRE.....	31
2.2 ENERGIA SOLAR FOTOVOLTAICA.....	33
2.3 MÓDULOS FOTOVOLTAICOS.....	33
2.4 ARRANJO FOTOVOLTAICO	35
2.5 SISTEMAS FOTOVOLTAICOS CONECTADOS À REDE ELÉTRICA.....	36
2.5.1 Sistemas Fotovoltaicos Centralizados	36
2.5.2 Sistemas Fotovoltaicos de Geração Distribuída	37
2.6 METODOLOGIA RRRa	40
2.7 PREDIÇÕES DE GERAÇÃO FOTOVOLTAICA	41
2.7.1 Horizontes de Resolução Temporal de Predição	42
2.7.2 Classes e Modelos dos Métodos de Predição	43
2.7.2.1 Método da Persistência	45
2.7.2.2 Métodos Estatísticos Clássicos	45
2.7.2.3 Modelos Numéricos do Tempo	46
2.7.2.4 Modelos com Processamento de Imagens	46
2.8 DESEMPENHO DE SISTEMAS FOTOVOLTAICOS	48
2.8.1 Índices de desempenho de sistemas fotovoltaicos	48

3	ESTADO DA ARTE	50
3.1	PREDIÇÕES DE GERAÇÃO FOTOVOLTAICA	50
3.2	ÍNDICES DE DESEMPENHO FOTOVOLTAICO	60
4	METODOLOGIA	69
4.1	SISTEMAS FOTOVOLTAICOS DE GERAÇÃO DISTRIBUÍDA ..	69
4.1.1	SFGD da Universidade Federal de Santa Catarina – UFSC, Araranguá – SC	69
4.1.2	SFGD do Instituto Federal de Santa Catarina – IFSC, Criciúma- SC	70
4.2	MÉTODO RRRa DE PREDIÇÃO DE GERAÇÃO FOTOVOLTAICA	72
4.2.1	Metodologia RRRa da predição de geração fotovoltaica	72
4.2.1.1	Plataformas de busca das previsões do tempo	73
4.2.1.1.1	Plataforma <i>Ventusky</i>	73
4.2.1.1.2	Plataforma <i>Open Weather</i>	74
4.2.1.2	Obtenção do valor padrão final de predição para diferentes previsões do tempo utilizando a plataforma <i>Ventusky</i>	75
4.2.1.3	Levantamento dos perfis utilizados para realizar a predição de geração RRRa utilizando as plataformas <i>Ventusky</i> e <i>OpenWeather</i>	77
4.2.2	Horizonte de Resolução Temporal	79
4.2.3	Métricas estatísticas para avaliação do desempenho do método proposto	79
4.3	ANÁLISE DO DESEMPENHO ENERGÉTICO DO SFCR DO IFSC	80
5	RESULTADOS E DISCUSSÃO	82
5.1	PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV _r) UTILIZANDO A PLATAFORMA <i>VENTUSKY</i> NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2023	82
5.1.1	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h	82

5.1.2	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h	87
5.1.3	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h	89
5.1.4	Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h	93
5.1.5	Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h	95
5.2	PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV _r) UTILIZANDO A PLATAFORMA <i>OPEN WEATHER</i> NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2023	98
5.2.1	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h	99
5.2.2	Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h	104
5.2.3	Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h	105
5.3	PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV _r) UTILIZANDO A PLATAFORMA <i>VENTUSKY</i> NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2024	107
5.3.1	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h	107
5.3.2	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h	110
5.3.3	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h	112
5.3.4	Análise de predição de geração fotovoltaica anual por meio dos erros médios diários	116

5.3.5	Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h	118
5.4	PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV _r) UTILIZANDO A PLATAFORMA <i>OPEN WEATHER</i> NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2024	121
5.4.1	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h	121
5.4.2	Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h	124
5.4.3	Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h	126
5.5	ANÁLISE DE PRODUTIVIDADE DO SISTEMA (Y _F) DOS SUBSISTEMAS e SFV _T DO IFSC	129
5.5.1	Índice de mérito de desempenho Y _F do Sub 1 e do Sub 2 do IFSC.....	129
5.5.2	Índice de mérito de desempenho Y _F do Sub 3 e do Sub 5 do IFSC.....	133
5.5.3	Índice de mérito de desempenho Y _F do Sub 4 e do SFV _T do IFSC	136
5.6	VALIDAÇÃO DO MÉTODO NOS Sub 1 E Sub 5 DO IFSC.....	139
5.6.1	Análise da predição de geração fotovoltaica horária para o Sub 1 e o Sub 5 utilizando os perfis desenvolvidos com o HRT = 1h até 10h.....	140
5.6.2	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h	142
5.6.3	Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h	143
5.6.4	Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h	144
6	CONCLUSÕES DA TESE	151

6.1 Sugestões para trabalhos futuros	157
REFERÊNCIAS BIBLIOGRÁFICAS	158

LISTA DE ILUSTRAÇÕES

Figura 1	Componentes da radiação solar.....	31
Figura 2	Esquema de ligação para as duas tecnologias de módulos fotovoltaicos de c-Si, sendo (a) módulo de 60 células inteiras e (b) módulos com 120 meias-células (<i>half-cell module</i>)	34
Figura 3	Estrutura típica de um módulo fotovoltaico	34
Figura 4	Exemplo de um arranjo fotovoltaico que contém 4 módulos em série e 6 <i>strings</i> em paralelo.....	36
Figura 5	Esquema de um SFCR com um inversor e transformador.....	37
Figura 6	Esquema de um SFCR com vários inversores e transformadores.....	37
Figura 7	Esquema de um SFGD.....	39
Figura 8	Potência de uma usina de energia fotovoltaica durante as estações típicas e sob condições climáticas típicas. (a) Potência gerada diária em dias claros durante as estações típicas, (b) potência gerada diária em dias nublados durante as estações típicas, (c) potência gerada diária em dias muito nublados durante as estações típicas e (d) potência gerada diária em dias chuvosos durante as estações típicas.	57
Figura 9	Comparação dos resultados projetados	58
Figura 10	Erro em relação aos horizontes de treinamento	59
Figura 11	Vista aérea do Laboratório Fotovoltaica/UFSC, com 111 kWp de sistemas fotovoltaicos conectados à rede	60
Figura 12	Variação mensal do rendimento energético de cada sistema fotovoltaico em análise e irradiação horizontal global mensal no mesmo local	61
Figura 13	Vista da planta piloto fotovoltaica em Ghardaïa, Argélia. (a) Silício amorfo, (b) telureto de cádmio, (c) silício monocristalino e (d) silício multicristalino.	62
Figura 14	Esquema da planta piloto de 400 kWp, localizada em Ghardaïa, Argélia.....	63
Figura 15	Ptprodutividade dos subsistemas Y_F em comparação com o rendimento de referência Y_R	64

Figura 16	P_R médio mensal dos diferentes subsistemas fotovoltaicos de 100 kWp.....	65
Figura 17	F_C médio mensal dos diferentes subsistemas fotovoltaicos de 100 kWp utilizando a potência c.c. do gerador.....	66
Figura 18	SFVr da UFSC – Campus Araranguá – SC	70
Figura 19	Sistema de geração no telhado dos 3 blocos	71
Figura 20	Legenda da plataforma <i>Ventusky</i>	74
Figura 21	Legenda da plataforma <i>Open Weather</i>	75
Figura 22	Curvas de Potência Fotovoltaica do Sistema Fotovoltaico da UFSC, Araranguá	76
Figura 23	Fluxograma para obtenção do valor padrão final de predição para cada mês do ano e para cada previsão do tempo.....	77
Figura 24	Gráfico de predições RRRa e MP com a GR de 7 dias para as quatro estações do ano utilizando a plataforma <i>Ventusky</i>	85
Figura 25	Box Plot da geração e predições utilizando a plataforma <i>Ventusky</i> dos meses de março de 2022 até fevereiro de 2023 para um HRT = 1h até 10h	86
Figura 26	Box Plot da geração e predições utilizando a plataforma <i>Ventusky</i> para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2023 para um HRT = 24h	88
Figura 27	Box Plot da geração e predições utilizando a plataforma <i>Ventusky</i> para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2023 para um HRT = 72h	90
Figura 28	RMSE, MAE e MAPE para os três perfis utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h	92
Figura 29	Comparação do método RRRa com RNA e DW + RNA de Zhu <i>et al.</i> (2015) utilizando o período de predição de março de 2022 até fevereiro de 2023.....	94
Figura 30	Comparativo do método RRRa com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan <i>et al.</i> , (2020) por meio do horizonte de predição para o dia seguinte (HRT = 24h) utilizando o período de predição de 2022 até 2023.....	98

Figura 31	Gráfico de previsões RRRa e MP com a GR de 7 dias para as quatro estações do ano utilizando a plataforma <i>Open Weather</i>	101
Figura 32	Box Plot da geração e previsões utilizando a plataforma <i>Open Weather</i> para os perfis nos intervalos horários para HRT = 1h até 10h no primeiro ano de previsão.....	103
Figura 33	Comparação de desempenho das plataformas <i>Ventusky</i> e <i>Open Weather</i> no primeiro ano de previsões utilizando os erros médios diários anuais.....	104
Figura 34	Comparação de desempenho das plataformas <i>Ventusky</i> e <i>Open Weather</i> no primeiro ano de previsões utilizando os erros médios diários mensais.....	106
Figura 35	Box Plot da geração e previsões utilizando a plataforma <i>Ventusky</i> para os perfis nos intervalos horários para os dois anos de previsões com HRT = 1h até 10h.....	109
Figura 36	Box Plot da geração e previsões utilizando a plataforma <i>Ventusky</i> para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2024 para um HRT = 24h.....	112
Figura 37	Box Plot da geração e previsões utilizando a plataforma <i>Ventusky</i> para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2024 para um HRT = 72h.....	114
Figura 38	Comparativo do RMSE, MAE e MAPE para os três perfis utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h entre 2022 até 2023 e 2022 até 2024.....	116
Figura 39	Comparação do método RRRa utilizando a plataforma <i>Ventusky</i> do período de 2022-2023 e 2022-2024 com RNA e DW + RNA de Zhu <i>et al.</i> , (2015)	117
Figura 40	Comparativo do método RRRa com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan <i>et al.</i> , (2020) por meio do horizonte de previsão para o dia seguinte utilizando o período de previsão de 2022 até 2024.....	120
Figura 41	Box Plot da geração e previsões utilizando a plataforma <i>Open Weather</i> para os perfis nos intervalos horários para os dois anos de previsões com HRT = 1h até 10h.....	123

Figura 42	Comparação do método RRRa utilizando a plataforma <i>Open Weather</i> do período de 2022-2023 e 2022-2024 com RNA e DW + RNA de Zhu <i>et al.</i> , (2015)	125
Figura 43	Comparação de desempenho das plataformas <i>Ventusky</i> e <i>Open Weather</i> no segundo ano de predições utilizando os erros médios diários anuais.....	126
Figura 44	Comparação de desempenho das plataformas <i>Ventusky</i> e <i>Open Weather</i> no período de março de 2023 até fevereiro de 2024 utilizando os erros médios diários mensal	128
Figura 45	Índice de Y_F mensais do Sub 1 nos anos de 2018 até 2023.....	130
Figura 46	Índice de Y_F mensais do Sub 2 nos anos de 2018 até 2023.....	130
Figura 47	Y_F em base mensal para os dois subsistemas nos anos de 2018 até 2023.....	131
Figura 48	Índice de Y_F mensais do Sub 3 nos anos de 2018 até 2023.....	134
Figura 49	Índice de Y_F mensais do Sub 5 nos anos de 2018 até 2023.....	134
Figura 50	Y_F em base mensal para os dois subsistemas nos anos de 2018 até 2023.....	135
Figura 51	Índice de Y_F mensais do Sub 4 nos anos de 2018 até 2023.....	137
Figura 52	Índice de Y_F mensais do SFV_T nos anos de 2018 até 2023.....	137
Figura 53	Comparativo da validação do método RRRa por meio dos Sub 1 e Sub 5 com o SFV_r na análise de predição mensal (HRT = 1h até 10h).	145
Figura 54	Comparativo da validação do método RRRa por meio dos Sub 1 e Sub 5 com o SFV_r na análise de predição mensal (HRT = 24h)	146
Figura 55	Comparativo das predições dos Sub 1 e Sub 5 com a metodologia de El-Baz <i>et al.</i> , (2018)	147
Figura 56	Comparativo das predições dos Sub 1 e Sub 5 com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan <i>et al.</i> , (2020)	148
Figura 57	Comparativo da validação do método RRRa por meio dos Sub 1 e do Sub 5 com o SFV_r na análise de predição mensal (HRT = 72h)	149

LISTA DE TABELAS

Tabela 1	Horizontes de resolução temporal para métodos de predição da radiação solar	43
Tabela 2	Métodos e modelos utilizados para predição da Irradiância Global Horizontal (GHI)	44
Tabela 3	Comparação de desempenho RMSE de modelos de predição básicos e combinados para o primeiro mês	52
Tabela 4	Comparação de desempenho RMSE de modelos de predição básicos e combinados para o segundo mês	53
Tabela 5	Comparação de desempenho RMSE de modelos de predição básicos e combinados para o terceiro mês	54
Tabela 6	Comparação de desempenho RMSE de modelos de predição básicos e combinados para o quarto mês	55
Tabela 7	Comparação do desempenho de predição com os modelos RNA e DW + RNA em diferentes tipos de dia	58
Tabela 8	Características técnicas dos módulos fotovoltaicos e dos inversores...	63
Tabela 9	Comparação dos rendimentos finais dos subsistemas fotovoltaicos de 100 kWp	64
Tabela 10	Parâmetros de desempenho de SFVs em locais áridos e semiáridos ...	67
Tabela 11	Especificações do Sistema Fotovoltaico da UFSC – Campus Araranguá – SC.....	69
Tabela 12	Especificações dos inversores.....	71
Tabela 13	Parâmetros elétricos do módulo fotovoltaico CS6K nas condições STC.....	71
Tabela 14	Distribuição das <i>strings</i> nos inversores.....	72
Tabela 15	Perfis de previsões do tempo obtidos das plataformas <i>Ventusky</i> e <i>OpenWeather</i>	78
Tabela 16	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h, utilizando os métodos RRRa e MP para o primeiro ano de predição.....	83

Tabela 17	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h utilizando os métodos RRRa e MP para o primeiro ano de predição.....	87
Tabela 18	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h utilizando os métodos RRRa e MP para o primeiro ano de predição.....	89
Tabela 19	Erro médio diário anual RSME, MAE e MAPE para os três perfis utilizando a plataforma <i>Ventusky</i> no primeiro ano de predição.....	93
Tabela 20	RMSE, MAE e MAPE médio diário mensal para os métodos RRRa e MP com HRT = 1h até 10h, HRT = 24h e HRT = 72h utilizando a plataforma <i>Ventusky</i> para o primeiro ano de predição.....	96
Tabela 21	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h utilizando os métodos RRRa e MP para o primeiro ano de predição	99
Tabela 22	Erro médio diário anual RSME, MAE e MAPE para os três perfis utilizando a plataforma <i>Open Weather</i> para o primeiro ano de predição.....	104
Tabela 23	RMSE, MAE e MAPE médio diário mensal para os métodos RRRa e MP com HRT = 1h até 10h utilizando a plataforma <i>Open Weather</i> para o primeiro ano de predição.....	105
Tabela 24	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h utilizando os métodos RRRa e MP para os dois anos de predição.....	108
Tabela 25	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h utilizando os métodos RRRa e MP para os dois anos de predição.....	111
Tabela 26	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h utilizando os métodos RRRa e MP para os dois anos de predição.....	113
Tabela 27	Erro médio diário anual RSME, MAE e MAPE para os três perfis.....	117
Tabela 28	RMSE, MAE e MAPE médio diário mensal para os métodos RRRa e MP com HRT = 1h até 10h, HRT = 24h e HRT = 72h.....	119

Tabela 29	Erros nos 3 perfis em intervalos horários para os meses de março de 2022 até fevereiro de 2024 utilizando os métodos RRRa e MP.....	122
Tabela 30	Erro médio diário anual RSME, MAE e MAPE para os três perfis....	124
Tabela 31	RMSE, MAE e MAPE médios diários mensais para os dois anos com os métodos RRRa e MP utilizando a plataforma <i>Open Weather</i>	127
Tabela 32	Y_F do sistema em base mensal do Sub 1.....	132
Tabela 33	Y_F do sistema em base mensal do Sub 2	133
Tabela 34	Y_F do sistema em base mensal do Sub 3	136
Tabela 35	Y_F do sistema em base mensal do Sub 5	136
Tabela 36	Y_F do sistema em base mensal do Sub 4	138
Tabela 37	Y_F do sistema em base mensal do SFV _T	138
Tabela 38	Y_F do SFV _r nos anos de 2021 e 2022	139
Tabela 39	Erros em intervalos horários para os meses de maio de 2022, fevereiro de 2023, agosto de 2023 e novembro de 2023 utilizando os métodos RRRa e MP para os Sub 1 e Sub 5.....	141
Tabela 40	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h utilizando os métodos RRRa e MP para os Sub 1 e Sub 5.....	142
Tabela 41	RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h utilizando os métodos RRRa e MP para os Sub 1 e Sub 5.	143
Tabela 42	RMSE, MAE e MAPE médio diário mensal para os métodos RRRa e MP com HRT = 1h até 10h, HRT = 24h e HRT = 72h.....	144

LISTA DE SIGLAS

AG	Algoritmos genéticos
ANEEL	Agência Nacional de Energia Elétrica
AR	Método auto regressivo
ARIMA	Método de média móvel integrada auto regressiva
ARMA	Método de média móvel auto regressiva
a-Si	Silício amorfo
BAPV	Sistemas fotovoltaicos aplicados em envoltórios de edifícios
BAPV_A	Sistema fotovoltaico aplicado no envoltório do edifício A com telhado curvo
BAPV_A1	Subsistema 1 aplicado no envoltório do edifício A
BAPV_A2	Subsistema 2 aplicado no envoltório do edifício A
BAPV_A3	Subsistema 3 aplicado no envoltório do edifício A
BAPV_B	Sistema fotovoltaico aplicado no envoltório do edifício B com telhado plano
BAPV_D	Sistema fotovoltaico no abrigo de ponto de ônibus
BAPV_E	Sistema fotovoltaico aplicado na fachada do edifício B
BAPV_E1	Subsistema 1 na fachada do edifício B
BAPV_E2	Subsistema 2 na fachada do edifício B
BIPV	Sistemas fotovoltaicos integrados em envoltórios de edifícios
BIPV_C	Garagem solar
BYD	<i>Build your dreams</i>
CdTe	Célula de telureto de cádmio
CEE	Comunidade econômica europeia
c-Si	Silício cristalino
CTS	Centro de Ciências, Tecnologia e Saúde da Universidade Federal de Santa Catarina
DW	Decomposição Wavelet
eBus	Ônibus elétrico
EVA	Etileno Acetato de Vinila
FDI	Fator de dimensionamento do inversor
GBSI	<i>Ground Based Sky Imagens</i>

GM	Sistemas fotovoltaicos montados no solo
GM_F	Sistemas fotovoltaicos montados no solo fixo
GM_F1	Subsistema fotovoltaico 1 no solo fixo
GM_F2	Subsistema fotovoltaico 2 no solo fixo
GM_G	Sistemas fotovoltaicos montados no solo fixo
GM_H	Sistema fotovoltaico montado no solo fixo com rastreador solar
GM_H1	Subsistema 1 montado no solo com rastreador solar
GM_H2	Subsistema 2 montado no solo com rastreador solar
HRT	Horizontes de resolução temporal de predição
IA	Inteligência artificial
IEA	<i>International Energy Agency</i>
IEA-PVPS	<i>International Energy Agency Photovoltaic Power Systems Programme</i>
IFSC	Instituto Federal de Santa Catarina
kNN	<i>k</i> vizinho mais próximo
MAe	Máquina de aprendizagem extrema
mc-Si	Silício multicristalino
MEC	Métodos estatísticos clássicos
ML	<i>Machine learning</i>
MP	Método da persistência
m-Si	Silício monocristalino
MVS	Máquina vetorial de suporte
PNT	Predição numérica do tempo
RAc	Regressão de árvores de conjunto
RL	Regressão linear
RLI	Regressão linear interativa
RNa	Rede neural de avanço
RNA	Método de rede neural artificial
RNFHA	Redes neurais físicas, híbridas e artificiais
RNN	Método de rede neural
RNPM	Redes neurais profundas com memória de longo prazo
RRR	Regressão de classificação reduzida adaptada
RRRa	Metodologia desenvolvida de predição de geração fotovoltaica

RVS	Regressão de vetor de suporte
RVSG	Regressão de vetor de suporte com kernel gaussiano
RVSL	Regressão de vetor de suporte com kernel linear
RVSQ	Regressão de vetor de suporte com kernel quadrático
S	Desvio-padrão
SBSI	<i>Satellite Based Sky Images</i>
SFC	Sistema fotovoltaico de geração centralizada
SFCR	Sistema fotovoltaico conectado à rede
SFGD	Sistema fotovoltaico de geração distribuída
SFV	Sistemas fotovoltaicos
SFV _r	Sistema fotovoltaico de referência da Universidade Federal de Santa Catarina
SFV _T	Sistema fotovoltaico total do Instituto Federal de Santa Catarina
SPMP	Seguidor de ponto de máxima potência
Sub 1	Subsistema do inversor 1 do Instituto Federal de Santa Catarina
Sub 2	Subsistema do inversor 2 do Instituto Federal de Santa Catarina
Sub 3	Subsistema do inversor 3 do Instituto Federal de Santa Catarina
Sub 4	Subsistema do inversor 4 do Instituto Federal de Santa Catarina
Sub 5	Subsistema do inversor 5 do Instituto Federal de Santa Catarina
STC	Condições <i>standard</i>
T	Período de integração
UFSC	Universidade Federal de Santa Catarina
\bar{x}	Média aritmética

LISTA DE SÍMBOLOS

a	<i>Coeficiente de temperatura na potência máxima, [W/°C]</i>
c.a.	<i>Corrente alternada, [A]</i>
c.c.	<i>Corrente contínua, [A]</i>
F_C	<i>Fator de capacidade, [%]</i>
FV	<i>Geração fotovoltaica, [W.h]</i>
GHI	<i>Irradiância Global Horizontal, [W/m²]</i>
GP	<i>Geração Predita Fotovoltaica, [W.h]</i>
GR	<i>Geração Real Fotovoltaica, [W.h]</i>
\overline{GR}	<i>Geração Real Média Fotovoltaica, [W.h]</i>
G_{STD}	<i>Irradiância de referência, [W/m²]</i>
H	<i>Irradiação média, [Wh/m²]</i>
I_{MP}	<i>Corrente de máxima potência, [A]</i>
I_{SC}	<i>Corrente de curto-circuito, [A]</i>
MAE	<i>Erro médio absoluto, [%]</i>
MAPE	<i>Erro percentual médio absoluto, [%]</i>
MBE	<i>Erro médio de polarização, [%]</i>
η	<i>Eficiência, [%]</i>
nRMSE	<i>Erro médio quadrático normalizado, [%]</i>
P_{CA}	<i>Potência elétrica entregue à rede no instante t, [kW]</i>
PF	<i>Padrão final de previsão fotovoltaica para cada tipo de previsão do tempo, [W.h]</i>
$\overline{PF\overline{P}}$	<i>Padrão final de perfil de previsão fotovoltaica para cada perfil, [W.h]</i>
$\overline{PF\overline{P}}_{PVS}$	<i>Padrão final de perfil no sistema em que será determinada a previsão, [W.h]</i>
$\overline{PF\overline{P}}_{PSD}$	<i>Padrão final de perfil de onde o sistema foi implementado, [W.h]</i>
PFV	<i>Predição de Geração Fotovoltaica, [W.h]</i>
$P_{MÁX}$	<i>Potência máxima, [W]</i>
P_{MP}	<i>Ponto de máxima potência, [W]</i>
P_R	<i>Performance ratio, [%]</i>

P_{STD}	<i>Potência do sistema na condição padrão, [kWp]</i>
$RMSE$	<i>Raiz do erro médio quadrático, [%]</i>
$rRMSE$	<i>Erro médio quadrático relativo, [%]</i>
TC_{PMP}	<i>Coeficiente de temperatura de ponto de máxima potência, (%/°C)</i>
TC_{VOC}	<i>Coeficiente de temperatura de tensão de circuito aberto, (%/°C)</i>
TC_{ISC}	<i>Coeficiente de temperatura de corrente de curto circuito (%/°C)</i>
V_{MP}	<i>Tensão de máxima potência, [V]</i>
V_{OC}	<i>Tensão de circuito aberto, [V]</i>
Y_F	<i>Produtividade do sistema fotovoltaico, [kWh/kWp]</i>
Y_R	<i>Rendimento de referência, [kWh/m²/kW/m²]</i>

RESUMO

A inserção da energia solar fotovoltaica na matriz elétrica apresenta alguns desafios, que estão relacionados, principalmente, à natureza intermitente da geração de energia elétrica a partir de sistemas fotovoltaicos. Embora o armazenamento da geração fotovoltaica resolva esse problema, uma previsão da geração fotovoltaica é necessária para controlar a energia injetada na rede. Analisando a importância das previsões de geração fotovoltaica, a presente Tese tem como objetivo desenvolver uma metodologia de regressão de classificação reduzida adaptada (RRRa) para a previsão da geração fotovoltaica em curto e médio prazos. O modelo RRRa proposto é simples, de fácil acesso e aplicação, e não utiliza dados de irradiância. A aplicação da metodologia RRRa requer duas pesquisas/entradas. A primeira entrada são dos dados de previsão meteorológica obtidos a partir das plataformas de previsão meteorológica *Ventusky* e *Open Weather* e a segunda são dados históricos reais de produção fotovoltaica no local onde o método foi desenvolvido. O método foi desenvolvido por meio do sistema fotovoltaico de referência (SFVr) conectado à rede da Universidade Federal de Santa Catarina – UFSC. A plataforma *Ventusky* foi a principal plataforma utilizada de previsão do tempo para a aplicação da metodologia. As previsões de geração fotovoltaica foram realizadas no período de março de 2022 até fevereiro de 2024. As métricas estatísticas utilizadas para avaliar o desempenho do método proposto foram a *raiz do erro quadrático médio* (RMSE), do *erro absoluto médio* (MAE) e do *erro percentual absoluto médio* (MAPE). O método proposto foi comparado com o método de persistência. Utilizando a plataforma *Ventusky* com o horizonte de curto prazo, o RMSE médio mensal para o RRRa variou de 7,3% a 77,5%. Para o método da persistência, variou de 15,1% a 65,0%. Utilizando o horizonte de médio prazo (24h), o RMSE médio mensal para o RRRa variou entre 4,5% e 62,5%. Para o método da persistência, variou de 11,5% a 75,0%. A validação do método foi realizada para o Sub 1 e o Sub 5 do sistema fotovoltaico do Instituto Federal de Santa Catarina – IFSC no período de quatro meses. Utilizando o horizonte de curto prazo, o Sub 1 obteve RMSE médio mensal de 0,7% a 4,1% de diferença quando comparado com o SFVr. O Sub 5 obteve RMSE médio mensal de 0,1% a 3,6% de diferença do SFVr. A presente Tese apresentou experimentalmente que o RRRa é competitivo com o estado da arte em termos de previsões de geração fotovoltaica sem utilizar dados de radiação solar.

Palavras-chave: Previsão de energia, Fotovoltaica, Dados de produção, Dados de previsão meteorológica.

ABSTRACT

The insertion of photovoltaic solar energy into the electricity matrix presents some challenges, which are mainly related to the intermittent nature of electricity generation from photovoltaic systems. Although the storage of photovoltaic generation solves this problem, a prediction of photovoltaic generation is necessary to control the energy injected into the grid. Considering the importance of photovoltaic generation predictions, this thesis aims to develop an adapted reduced rank regression (RRRa) methodology for predicting photovoltaic generation in the short and medium term. The proposed RRRa model is simple, easy to access and apply, and does not use irradiance data. Applying the RRRa methodology requires two searches/inputs. The first input is weather forecast data obtained from the Ventusky and Open Weather forecasting platforms and the second is actual historical photovoltaic production data at the site where the method was developed. The method was developed using the photovoltaic system (SFVr) connected to the grid at the Federal University of Santa Catarina (UFSC). The Ventusky platform was the main weather forecasting platform used to apply the methodology. Predictions of photovoltaic generation were made from March 2022 to February 2024. The statistical metrics used to evaluate the performance of the proposed method were root mean square error (RMSE), mean absolute error (MAE) and mean absolute percentage error (MAPE). The proposed method was compared with the persistence method. Using the Ventusky platform with a short-term horizon, the average monthly RMSE for RRRa ranged from 7.3% to 77.5%. For the persistence method, it ranged from 15.1% to 65.0%. Using the medium-term horizon (24h), the average monthly RMSE for RRRa ranged from 4.5% to 62.5%. For the persistence method, it ranged from 11.5% to 75.0%. The method was validated for Sub 1 and Sub 5 of the photovoltaic system at the Federal Institute of Santa Catarina (IFSC) over a four-month period. Using the short-term horizon, Sub 1 obtained an average monthly RMSE of between 0.7% and 4.1% when compared to the SFVr. Sub 5 obtained an average monthly RMSE of 0.1% to 3.6% different from the SFVr. This thesis has shown experimentally that RRRa is competitive with the state of the art in terms of predicting photovoltaic generation without using solar radiation data.

Keywords: Energy prediction, Photovoltaic, Production data, Weather forecast data.

PUBLICAÇÕES RELACIONADAS À TESE

ROSSO, A. P.; RAMPINELLI, G. A.; SCHAEFFER, L. Experimental development of a method of short and medium-term photovoltaic generation forecasting using multivariate statistics and mathematical modeling. **Energy Reports**, v. 12, pp. 1710-1722, 2024.
<https://doi.org/10.1016/j.egy.2024.07.058>

ROSSO, A. P.; RAMPINELLI, G. A.; SCHAEFFER, L. Metodologia de predição de geração de energia elétrica a partir de dados históricos reais de geração de um sistema fotovoltaico conectado à rede. In: 12ª Conferência Internacional de Materiais e Processos para Energias Renováveis, 2023, Porto Alegre. 12º Conferência Internacional de Materiais e Processos para Energias Renováveis, 2023.

ROSSO, A. P.; RAMPINELLI, G. A.; SCHAEFFER, L. Estudo preliminar de previsão de curto prazo da geração de energia elétrica de um sistema fotovoltaico conectado à rede na região Sul de Santa Catarina. In: 11º Conferência Internacional de Materiais e Processos para Energias Renováveis, 2022, Porto Alegre. 11ª Conferência Internacional de Materiais e Processos para Energias Renováveis, 2022.

ROSSO, A. P.; KROTH, G.; RAMPINELLI, G. A.; SCHAEFFER, L. Influência do fator de dimensionamento de inversor no desempenho de sistemas fotovoltaicos conectados à rede em operação no sul do Brasil. In: IX Congresso Brasileiro de Energia Solar - CBENS 2022, 2022, Florianópolis. IX Congresso Brasileiro de Energia Solar - CBENS 2022, 2022.

ROSSO, A. P.; KROTH, G.; RAMPINELLI, G. A.; SCHAEFFER, L. Influência das perdas por associação de módulos fotovoltaicos em sistemas fotovoltaicos conectados à rede em operação no sul do Brasil. In: XIII Congresso Brasileiro de Planejamento Energético, 2022, Itajubá.

1 INTRODUÇÃO

Os sistemas fotovoltaicos (SFV) convertem diretamente a radiação solar em eletricidade e podem ser usados em uma ampla área de aplicações. Os SFVs utilizados vão desde pequenos sistemas que alimentam cargas até grandes sistemas que estão conectados diretamente à rede elétrica. O componente principal dos SFVs são os arranjos fotovoltaicos. Esses são um conjunto de módulos interligados em série e em paralelo que totalizam a potência do sistema fotovoltaico (Pearsall, 2017).

A integração dos sistemas fotovoltaicos exige cuidados na gestão e no controle da energia produzida. A variabilidade da geração fotovoltaica (FV) acarreta uma variação de tensão na entrada da rede de transmissão ou distribuição. As variações de tensão podem danificar equipamentos de proteção e a própria qualidade da energia, podendo haver um aumento no custo da energia (Barbieri *et al.*, 2017; Böök e Lindfors, 2020).

Devido à radiação solar ser intermitente e possuir variabilidade durante um curto período de tempo, a produção dos sistemas fotovoltaicos pode sofrer flutuações na geração de energia. As incertezas na FV dificultam o despacho da energia produzida na rede elétrica. Embora o armazenamento da energia elétrica proveniente dos SFV seja uma solução para esse problema, é necessária uma previsão da geração fotovoltaica (PFV) para o controle de energia injetada na rede elétrica (Barbieri, 2017; Böök e Lindfors, 2020).

A previsão fotovoltaica é a aplicação de várias etapas com bancos de dados grandes, medições não confiáveis e múltiplas observações de entrada-saída. Por outro lado, previsões confiáveis permitem oferecer confiabilidade aos gerentes/diretores de usinas. Por meio das previsões, consegue-se minimizar os desvios entre a energia programada e a energia produzida (Antonanzas *et al.*, 2016)

As previsões da radiação solar fornecem informações relacionadas às incertezas na geração de eletricidade de uma usina solar fotovoltaica. Por meio do conhecimento dessas incertezas, pode-se gerenciar a entrada de energia elétrica na rede elétrica de maneira que não haja distúrbios e flutuações de energia (Bakker *et al.*, 2019).

Com o aumento do emprego de SFV para a geração de eletricidade, tem-se a importância de realizar estudos da previsão de geração fotovoltaica no local onde os sistemas fotovoltaicos serão instalados. A partir do conhecimento do perfil/comportamento da irradiância solar, pode-se viabilizar a instalação de SFVs em uma determinada região, garantindo o máximo aproveitamento do recurso ao longo de

todo o ano, onde as variações da intensidade da radiação solar sofrem significativas alterações (Lorenzo, 2006; Pinho e Galdino, 2014; Pereira *et al.*, 2017).

A integração fotovoltaica na matriz elétrica ainda apresenta alguns desafios que precisam ser superados. Esses estão relacionados, principalmente, à natureza intermitente da produção de eletricidade a partir da conversão fotovoltaica da energia solar. A partir do momento que a geração fotovoltaica atinge uma parcela significativa na matriz elétrica, o desenvolvimento de PFVs em grande escala se tornará indispensável (Böök e Lindfors, 2020; Wirth, 2020).

Outro estudo importante é a análise de desempenho dos sistemas fotovoltaicos. O desempenho dos SFVs, que diz respeito, principalmente, à produção de energia, depende das condições de operação e da configuração detalhada do sistema. Por sua vez, as condições de operação dependem da localização do sistema, levando em conta a irradiação solar recebida, a temperatura ambiente e outros aspectos climáticos que influenciam o desempenho do sistema (Pearsall, 2017).

O desempenho energético do sistema fotovoltaico também pode ser afetado por outros fatores, como distribuição espectral da radiação solar, tecnologia dos módulos fotovoltaicos, temperatura de operação do módulo fotovoltaico, perdas por incompatibilidade entre os módulos fotovoltaicos (*mismatch*), sujeiras e degradação dos módulos fotovoltaicos. As perdas por incompatibilidade entre os módulos fotovoltaicos têm origem do fato de que as curvas I-V dos módulos que compõem o arranjo não são idênticas (Gasparin *et al.*, 2016).

Levando em conta a importância de uma análise de desempenho e de um estudo das PFVs, a presente tese tem como finalidade desenvolver, apresentar e validar uma metodologia de previsão de geração fotovoltaica através da regressão de classificação reduzida adaptada (RRRa) por meio dos próprios dados de geração de um sistema fotovoltaico conectado à rede (SFCR) que está localizado na Região Sul de Santa Catarina. O SFCR utilizado no desenvolvimento da metodologia está localizado na UFSC, Campus Araranguá – SC (SFV_R). O SFCR, por meio do qual se realizou a validação do método através de uma correlação da metodologia com o índice de desempenho, está localizado no IFSC, Campus Criciúma – SC (SFV_T). A aplicação da metodologia RRRa precisa de duas buscas/entradas. A primeira entrada é dos dados de previsão do tempo, que se obtêm por meio de uma plataforma de previsão do tempo, e a segunda entrada é dos dados históricos reais de geração fotovoltaica no local em que se deseja efetuar a PFV.

1.1 HIPÓTESES

1. Um método de predição de geração fotovoltaica pode ser desenvolvido utilizando como entrada dois blocos de dados de natureza diferente, sendo eles a previsão do tempo e um histórico de geração real de um sistema fotovoltaico no local da predição.
2. É possível realizar uma predição de geração fotovoltaica sem a utilização de dados de radiação solar com um grau aceitável de assertividade.
3. É possível realizar a predição de geração fotovoltaica para diferentes orientações e configurações de sistemas fotovoltaicos utilizando uma correlação do método proposto com os índices de desempenho do sistema.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Desenvolver, aplicar e validar uma metodologia de predição de geração fotovoltaica no Sul do estado de Santa Catarina, por meio de horizontes de curto e médio prazos, e realizar um estudo de índices de desempenho para esses sistemas.

1.2.2 Objetivos Específicos

- Desenvolver uma metodologia de predição de geração fotovoltaica por meio de dados históricos de geração e das redes meteorológicas.
- Desenvolver o método utilizando um horizonte na faixa de 1h até 10h, 24h e 72h futuras.
- Desenvolver a metodologia a partir dos dados de um sistema fotovoltaico de referência (SFVr) de 0,99 kWp, localizado na UFSC, Campus Araranguá.
- Desenvolver e aplicar a metodologia utilizando as plataformas de previsões do tempo: *Ventusky* e *OpenWeather*.

- Analisar as incertezas do método desenvolvido utilizando os diferentes horizontes propostos e diferentes métricas estatísticas.
- Comparar o método proposto com o método da persistência.
- Avaliar o impacto das diferentes plataformas de previsão do tempo no método desenvolvido.
- Validar a metodologia correlacionando a previsão da geração com um índice de desempenho de dois subsistemas (Sub 1 e Sub 5) localizados no IFSC, Campus Criciúma.
- Avaliar a influência dos ângulos de inclinação e de azimute do SFVr e dos Sub 1 e Sub 5 na PFV.

1.3 JUSTIFICATIVA E RELEVÂNCIA

O Brasil apresenta um crescimento exponencial nas instalações de SFCR de distribuição. Ele também possui um aumento significativo nas instalações de Sistemas Fotovoltaicos Centralizados (SFC). Atualmente, com o aumento nas instalações de SFCRs e SFCs no Brasil, a capacidade de geração solar fotovoltaica instalada chegou a 19,0% da matriz elétrica nacional para o mês de agosto de 2024 (Absolar, 2024).

Uma análise sobre o desempenho de SFV é importante para acompanhar a produção de energia de um SFCR e para analisar parâmetros que podem afetar diretamente a produção de energia elétrica. Os índices de desempenho são relacionados à eficiência do sistema, à produtividade, a perdas do sistema e à energia elétrica produzida. Uma alternativa para avaliar um SFCR é por meio dos índices de desempenho que relacionam a produtividade e o desempenho dos sistemas (Chikh *et al.*, 2021).

A integração dos sistemas fotovoltaicos exige cuidados na gestão e no controle da energia produzida. A variabilidade de geração fotovoltaica acarreta uma variação de tensão na entrada da rede de transmissão ou distribuição e essas variações podem danificar equipamentos de proteção e a própria qualidade da energia, podendo haver um aumento no custo da energia (Barbieri, 2017; Böök e Lindfors, 2020).

Para manter a confiabilidade da rede elétrica de distribuição, requer-se um entendimento e um planejamento tanto de incertezas quanto da variabilidade inerente ao sistema. Os geradores de energia e as linhas de transmissão e distribuição possuem alguma probabilidade de falha devido à demanda por energia elétrica variar ao longo do

dia. Com a adição de fontes de geração, como a energia solar fotovoltaica, a variabilidade da geração também se torna um fator. O sistema de transmissão e distribuição deve estar preparado e ser fisicamente capaz de responder a essa variabilidade de geração de energia (Dyreson, 2014).

As previsões precisas da radiação solar podem fornecer informações relacionadas às incertezas na geração de eletricidade de uma usina solar fotovoltaica. Por meio do conhecimento dessas incertezas, pode-se gerenciar a entrada de energia elétrica na rede elétrica de maneira que não haja distúrbios e flutuações de energia na rede (Bakker *et al.*, 2019).

Algumas pesquisas que tratam das previsões de geração fotovoltaica foram desenvolvidas nos últimos anos. Os países mais desenvolvidos economicamente são os que mais realizaram estudos nessa área, tais como Alemanha, Estados Unidos, China, entre outros (Mosavi *et al.*, 2019; Blaga *et al.*, 2019). Muitos estudos utilizam dados de dispositivos e sensores que capturam informações para realizar a previsão de geração fotovoltaica, como informações meteorológicas e de irradiância solar (Maciel, 2021; Yang, 2018).

Devido à situação de investimentos e crescimento exponencial da energia solar fotovoltaica no Brasil, tem-se a necessidade de desenvolvimento e aplicações de metodologias para a previsão da geração de energia solar fotovoltaica no país. Desse modo, a proposta apresentada neste estudo é desenvolvida, aplicada e validada em SFCRs que se encontram no Sul do estado de Santa Catarina, Brasil. O método proposto pode ser aplicado em qualquer localização geográfica do planeta e com diferentes configurações, orientações e tecnologias de sistemas fotovoltaicos.

2 REFERENCIAL TEÓRICO

Neste capítulo serão abordados os conceitos relevantes para a fundamentação do presente trabalho.

2.1 RADIAÇÃO SOLAR NA SUPERFÍCIE TERRESTRE

A radiação solar incidente sobre uma superfície receptora horizontal à superfície terrestre é constituída por uma componente direta e por uma componente difusa (Figura 1). A componente direta é aquela que atravessa diretamente a atmosfera terrestre sem sofrer espalhamento e produz sombras nítidas, enquanto a componente difusa é aquela proveniente de todas as direções e que atinge a superfície após sofrer espalhamento ao entrar na atmosfera terrestre (Duffie e Beckman, 2013).

Em um dia de céu totalmente claro, aproximadamente 20% da radiação solar que atinge a superfície é da componente difusa. Em um dia totalmente nublado, 100% são da componente difusa. Se a superfície estiver inclinada em relação ao solo, uma terceira componente é notada, isto é, a componente refletida pelo entorno da superfície (vegetação, solo, obstáculos, etc.) conforme indicado na Figura 1. O coeficiente de reflexão dessas superfícies é denominado albedo (Pinho e Galdino, 2014).




Figura 1 - Componentes da radiação solar (Rosso, 2019).

Esses processos de absorção e os espalhamentos alteram o espectro eletromagnético da radiação solar ao longo de seu percurso pela atmosfera terrestre (Haag e Krenzinger, 2010).

Valores de irradiância maiores por curtos períodos do tempo podem ser observados em condições de nebulosidade parcial como consequência do espalhamento por bordas de nuvens, ou por efeito lente causado pela geometria sol/nuvens/terra. Durante curtos períodos do dia, a diferença de irradiação não é causada apenas pelo movimento das nuvens, mas também pelo efeito lente, podendo elevar drasticamente o valor da irradiância (Tiba e Leal, 2017). Zomer e Rüther (2017) presenciaram em algumas pesquisas no território brasileiro valores de irradiância global horizontal (GHI) de até 1822 W/m^2 . Almeida e Zilles (2014) presenciaram, na cidade de São Paulo, irradiâncias de até 1590 W/m^2 .

O percentual de perda do fluxo de potência entre o espectro da irradiância incidente no topo da atmosfera e o espectro da irradiância global que alcança uma superfície inclinada é de aproximadamente 27%, resultando em aproximadamente 1000 W/m^2 incidente sobre a superfície terrestre. Esse nível de irradiância é considerado valor padrão para a especificação da potência nominal de uma célula ou de um módulo fotovoltaico (Pinho e Galdino, 2014; Kalogirou, 2014).

No entanto a energia produzida por sistemas fotovoltaicos depende de alguns fatores variáveis, como irradiância solar, temperatura ambiente, temperatura do módulo, distribuição espectral da radiação solar, direção do vento e umidade. A potência de saída de um sistema fotovoltaico muda dinamicamente com o tempo devido à variabilidade destes fatores. Portanto, a predição com alto grau de precisão da geração fotovoltaica é consideravelmente difícil. A entrada de energia elétrica da geração fotovoltaica na rede pode afetar negativamente a estabilidade, a confiabilidade e a programação da operação do sistema de energia quando não se obtém a predição da geração fotovoltaica. A predição confiável da geração a partir de SFV pode reduzir os impactos que a intermitência provoca na rede elétrica, melhorar a confiabilidade do sistema, manter a qualidade da energia e aumentar o nível de penetração dos SFVs. Portanto, a predição da geração fotovoltaica é um grande desafio (Das *et al.*, 2018) e vale destacar que ela é a variável a ser prevista pelo RRRa.

2.2 ENERGIA SOLAR FOTOVOLTAICA

A energia solar fotovoltaica é a energia proveniente da conversão direta da energia solar em energia elétrica e se dá por meio de um fenômeno físico chamado de efeito fotovoltaico. O dispositivo fundamental unitário que é responsável pela conversão de energia é chamado de célula fotovoltaica. A conversão fotovoltaica acontece por meio de materiais semicondutores. Desde o início da tecnologia até os dias de hoje, a maioria das células solares fotovoltaicas são produzidas com a tecnologia de silício. Com o objetivo de gerar eletricidade, o módulo fotovoltaico foi desenvolvido com as células fotovoltaicas conectadas em série, obtendo uma tensão elétrica maior e, com o aumento da tensão, uma potência elétrica maior. O módulo fotovoltaico é a unidade básica de um sistema de FV (Luque e Hegedus, 2011; Pinho e Galdino, 2014; Lorenzo, 2006).

2.3 MÓDULOS FOTOVOLTAICOS

O módulo fotovoltaico é obtido por meio da associação das células fotovoltaicas, formando uma associação de células inserida em alguma estrutura. Os módulos fotovoltaicos eram obtidos por meio de células fotovoltaicas utilizam a associação em série das células para aumentar a tensão de circuito aberto (V_{OC}) do módulo (Luque e Hegedus, 2011; Lorenzo, 2006). Antigamente, os módulos mais utilizados e disponíveis no mercado fotovoltaico eram os módulos de 60 e 72 células em série (Luque e Hegedus, 2011).

No momento atual, uma nova tecnologia que está disponível no mercado são os módulos que apresentam configurações de meia-célula (*half-cell module*). Esses módulos de meia-célula são constituídos de 120 e 144 células e apresentam os parâmetros elétricos parecidos do módulo com célula inteira (*full-cell module*). As células se associam em série e paralelo (Oliveira, 2020). A Figura 2 apresenta o esquema de ligação elétrica para as duas tecnologias de módulos.

A estrutura de um módulo fotovoltaico convencional possui alguns componentes além das células fotovoltaicas. Eles protegem o módulo fotovoltaico quando exposto a intempéries ou submetido a alguma força mecânica. As células do módulo são isoladas eletricamente dos outros componentes do módulo (Ndiaye, *et al.*, 2013; Luque e Hegedus, 2011).

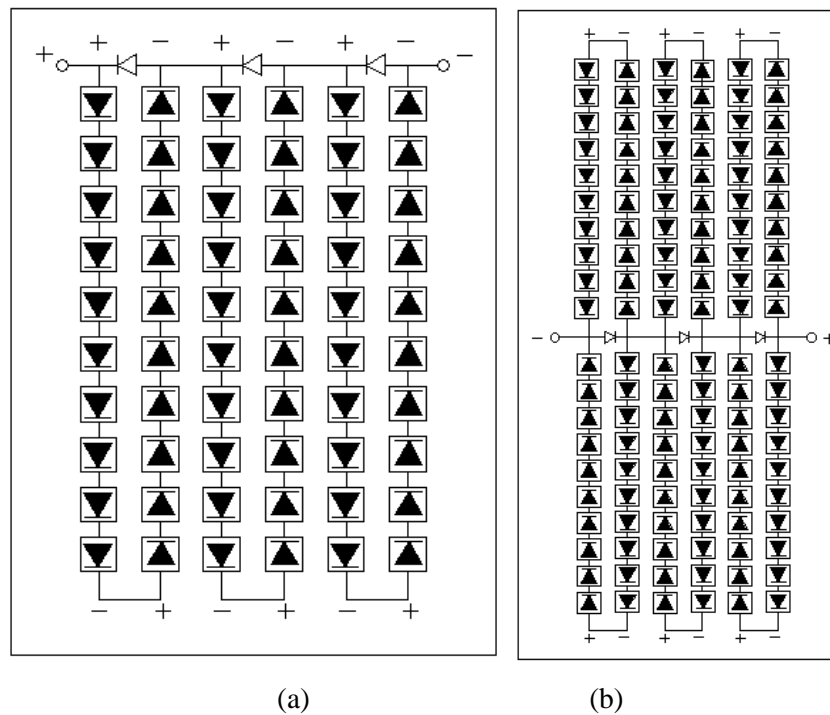


Figura 2 – Esquema de ligação para as duas tecnologias de módulos fotovoltaicos de c-Si, sendo (a) módulo de 60 células inteiras e (b) módulos com 120 meias-células (*half-cell module*).

A Figura 3 apresenta a estrutura de um módulo fotovoltaico convencional.




Figura 3 – Estrutura típica de um módulo fotovoltaico (Aryan *et al.*, 2018).

O módulo fotovoltaico convencional, apresentado na Figura 3, é formado pelos seguintes componentes: material de cobertura posterior (*Tedlar*); arranjo de células fotovoltaicas; material encapsulante (EVA), que garante o isolamento elétrico das células; vidro e estrutura de alumínio para garantir proteção mecânica e isolamento; e caixa de junção, que é utilizada para realizar as conexões elétricas e abrigar os diodos de *by-pass*, que são utilizados para proteger o módulo caso uma célula ou um conjunto de células sejam sombreados ou apresentem algum defeito (Lorenzo, 2006; Luque e Hegedus, 2011).

Os módulos fotovoltaicos formam *strings* quando são ligados em séries. Elas são formadas nos sistemas fotovoltaicos com o intuito de aumentar o valor de tensão de operação do sistema. Por meio da associação dos módulos em série, a tensão estabelecida é a soma da tensão de cada módulo ligado na *string*. A corrente elétrica da *string* permanece a mesma de um módulo fotovoltaico individual devido à ligação ser em série. Em sistemas fotovoltaicos de geração distribuída de menor porte, é comum o uso de apenas uma *string* para se chegar ao valor adequado de tensão e, conseqüentemente, chegar ao valor de potência necessária para o sistema. Em sistemas maiores de geração distribuída ou geração centralizada, é comum se obter um arranjo fotovoltaico. Nos arranjos fotovoltaicos, há normalmente a conexão de mais de uma *string* em paralelo para se obter, além de um aumento de tensão, um aumento de corrente elétrica no sistema (Luque e Hegedus, 2011; Pinho e Galdino, 2014; Oliveira, 2020).

2.4 ARRANJO FOTOVOLTAICO

O arranjo fotovoltaico se dá por meio de ligações em paralelo de módulos fotovoltaicos que estão ligados em série (*strings*). Através desse tipo de ligação, aumenta-se o valor de corrente elétrica e consegue-se obter o valor de potência de geração desejada. Quando se faz a ligação em paralelo, cada série de módulos tem que ser protegida por meio de dispositivos de proteção (fusível ou diodo), evitando que uma *string* de módulos injete corrente elétrica em outra *string* quando a irradiância não for uniforme em todo o arranjo (Duffie e Beckman, 2013; Pinho e Galdino, 2014; Oliveira, 2020; Elasser *et al.*, 2010). A Figura 4 apresenta um esquema de um arranjo fotovoltaico e a aplicação dos fusíveis em cada série fotovoltaica.

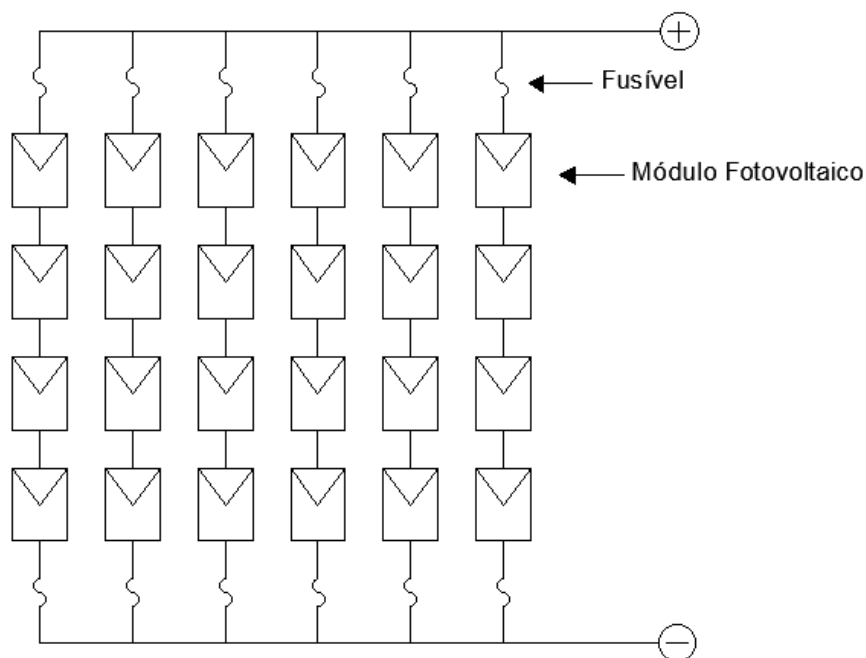


Figura 4 – Exemplo de um arranjo fotovoltaico que contém 4 módulos em série e 6 *strings* em paralelo.

2.5 SISTEMAS FOTOVOLTAICOS CONECTADOS À REDE ELÉTRICA

Existem dois tipos de Sistemas Fotovoltaicos Conectados à Rede (SFCR), que serão apresentados nesta seção: as grandes Centrais Fotovoltaicas (SFC) e os Sistemas Fotovoltaicos de Geração Distribuída (SFGD), que, na maioria dos casos, estão instalados em unidades localizadas no próprio ponto de consumo. Os SFGD estão conectados diretamente na rede de distribuição por meio de unidades consumidoras, que podem ser residencial ou comercial dentre as demais modalidades existentes.

2.5.1 Sistemas Fotovoltaicos Centralizados

A geração fotovoltaica centralizada (SFC), cujos geradores são conhecidos como usinas fotovoltaicas, também fornece a potência instantaneamente para a rede elétrica através de um ou mais inversores e transformadores. Os sistemas centralizados utilizam inversores comutados pela rede para evitar a operação isolada (Pinho e Galdino, 2014). A Figura 5 apresenta um esquema de um SFCR centralizado com apenas um inversor e transformador. A Figura 6 apresenta um esquema de um SFCR centralizado com vários inversores e transformadores.

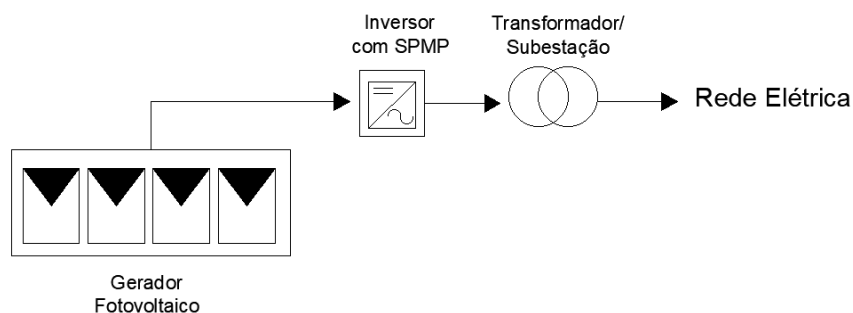


Figura 5 – Esquema de um SFCR com um inversor e transformador.

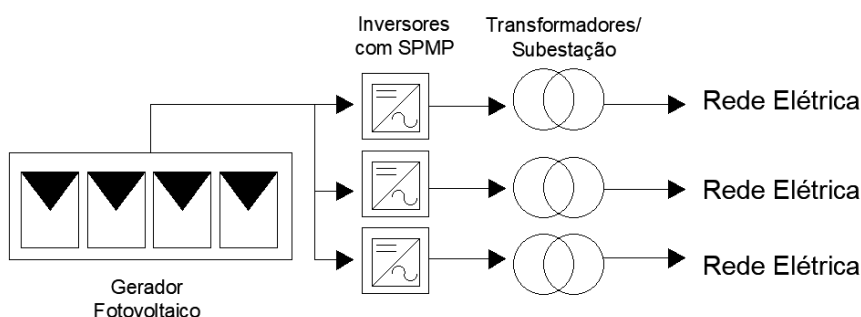


Figura 6 – Esquema de um SFCR com vários inversores e transformadores.

Os SFCs possuem uma desvantagem quando comparados com os SFGDs: as usinas ocupam grandes áreas e geralmente estão instaladas em locais afastados da área de consumo e, com isso, há a necessidade de linhas de transmissão e distribuição de energia até o centro de consumo.

2.5.2 Sistemas Fotovoltaicos de Geração Distribuída

Os Sistemas Fotovoltaicos de Geração Distribuída (SFGD) são sistemas de FV que estão alocados dentro dos limites da área de uma determinada concessionária de distribuição e, normalmente, junto à principal unidade consumidora associada ao sistema. Eles permitem que o consumidor gere sua própria energia elétrica a partir de fontes renováveis, como a energia solar fotovoltaica, ou cogeração qualificada. A geração distribuída pode ser dividida em microgeração e em minigeração (Pinho e Galdino, 2014).

No Brasil o início da regulamentação da micro e da minigeração distribuída ocorreu com a publicação da Resolução Normativa nº 482, de 17 de abril de 2012, regulamentada pela Agência Nacional de Energia Elétrica - ANEEL, sendo assim a energia elétrica pode ser gerada e consumida no local de instalação do sistema gerador,

por meio de fontes renováveis ou cogeração qualificada, além de tornar possível a compensação de energia elétrica (Aneel, 2012).

Em 2015, a Resolução Normativa n° 482 foi atualizada pela RN n° 687 e caracterizou a microgeração distribuída como uma geradora de energia elétrica com a potência instalada menor ou igual a 75 kW, utilizando fontes renováveis ou cogeração qualificada que esteja conectada à rede de distribuição por meio de instalações de unidades consumidoras. A minigeração se caracterizou como uma geradora de energia elétrica que possui uma potência instalada superior a 75 kW e menor ou igual a 3 MW para as fontes hídricas ou menor ou igual a 5 MW para as demais fontes de geração (Aneel, 2015).

Em 2022, a Lei n° 14.300 instituiu o marco legal da micro e da minigeração distribuída, o Sistema de Compensação de Energia Elétrica e o Programa de Energia Renovável Social. A microgeração distribuída é definida como uma geradora de energia elétrica, com potência instalada, em corrente alternada, menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da Agência Nacional de Energia Elétrica - ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição de energia elétrica por meio de instalações de unidades consumidoras. A minigeração distribuída se caracterizou como uma central geradora de energia elétrica renovável ou de cogeração qualificada que não se classifica como microgeração distribuída e que possua potência instalada, em corrente alternada, maior que 75 kW, menor ou igual a 5 MW para fontes despacháveis e menor ou igual a 3 MW para fontes não despacháveis, conforme regulamentação da Aneel, conectada na rede de distribuição de energia elétrica por meio de instalações de unidades consumidoras (Brasil, 2022).

Outras vantagens para a geração de energia elétrica por meio de SFGD são a não ocorrência de perdas nas linhas de transmissão através do transporte de energia gerada (Chiradeja, 2005), baixo impacto ambiental (Qianet *et al.*, 2008), baixo tempo de instalação do sistema de geração, redução do carregamento da rede de transmissão e distribuição, diversificação da matriz energética, entre outros (Costa *et al.*, 2023).

O SFGD, conforme apresentado na Figura 7, compreende-se pelos seguintes componentes:

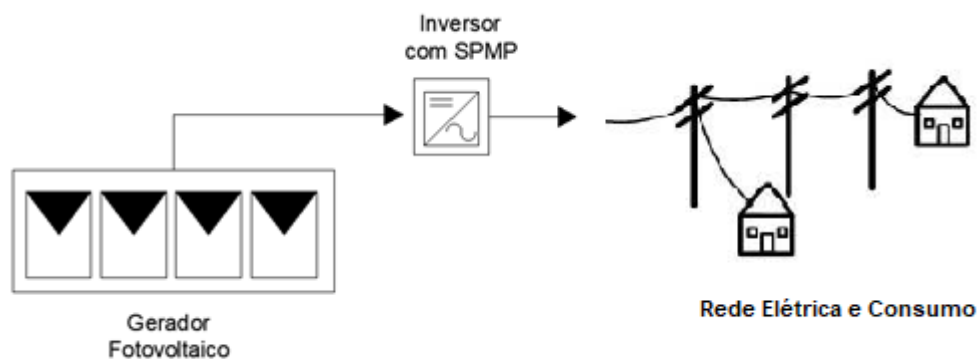


Figura 7 – Esquema de um SFGD (Adaptado de Pinho e Galdino, 2014).

Alguns parâmetros podem afetar a geração de um arranjo de módulos fotovoltaicos. A radiação solar é o parâmetro principal, que depende da localização geográfica da instalação do sistema, do clima no local da instalação, bem como de seus ângulos de inclinação e azimute, além da possibilidade de sombreamentos. Outros parâmetros, como temperatura dos módulos, sombreamento parcial, descasamento entre os módulos ou painéis de uma mesma *string* (*module mismatch losses*), resistências dos condutores e limpeza dos módulos, também influenciam o desempenho de geração de um SFV (Rüther, 2004; Lorente *et al.*, 2014).

Entretanto, devido à variação da irradiância solar na superfície terrestre criada pela passagem das nuvens, os sistemas fotovoltaicos distribuídos podem afetar a qualidade da energia e a operação do sistema. Políticas de interconexão que considerem os benefícios tanto dos proprietários/operadores de geração distribuída quanto das empresas de distribuição são necessárias para tratar os principais problemas, como comunicação, controle, proteção contra curto-circuito, isolamento elétrico e proteção contra surtos (Lai *et al.*, 2017).

Estudos que incluem as características que variam no tempo de geração, carga e dispositivos de controle de tensão nos alimentadores podem ser usados para fornecer controle parcial da estabilidade do sistema elétrico. A localização do sistema fotovoltaico, o nível de penetração da energia solar fotovoltaica e as características elétricas do sistema de distribuição podem ter uma influência significativa na estabilidade do sistema elétrico. A energia pode ser injetada de volta ao sistema de transmissão a partir dos circuitos alimentados pelos sistemas fotovoltaicos. Os perfis de tensão, a proteção contra sobrecorrente e a operação do banco de capacitores podem ser afetados pela condição de alta penetração da energia fotovoltaica. A motivação para estudar os impactos para níveis

diferentes de penetração fotovoltaica e a investigação dos efeitos sob diferentes condições de carregamento do alimentador se deve à natureza variável da carga do alimentador e da saída da energia fotovoltaica (Lai *et al.*, 2017).

Os principais problemas em redes de distribuição com alta penetração fotovoltaica são os seguintes (Von Appen *et al.*, 2013):

- 1) Fluxos de potência reversa no sistema de distribuição: em sistemas de distribuição em que a geração fotovoltaica local excede a demanda de carga local, os fluxos de potência reversa ocorrem em direção aos níveis de tensão maiores. Isso geralmente é acompanhado por aumentos de tensão e causa um fluxo de energia adicional no sistema.
- 2) Fluxos de potência adicionais no sistema de transmissão: fluxos de potência reversos podem causar fluxos de potência adicionais do sistema de distribuição para o sistema de transmissão.
- 3) Estabilidade da rede (frequência e tensão): hoje, as usinas despacháveis devem garantir a estabilidade do sistema.

2.6 METODOLOGIA RRRa

O método desenvolvido (RRRa) utiliza a técnica de análise estatística multivariada. Esta geralmente envolve explorar as variações em um conjunto de variáveis inter-relacionadas ou investigar as relações simultâneas entre dois ou mais conjuntos de variáveis (Reinsel e Velu, 1998). Ao analisar a previsão do tempo, a plataforma meteorológica analisa dados, como pressão atmosférica, precipitação pluviométrica, umidade do ar, temperatura, entre outros. Nos dados reais de geração do sistema fotovoltaico, estão inseridas variáveis, como radiação solar, temperatura, sombreamento, descasamento espectral, sujeira, perdas por descasamento, perdas de cabeamento, entre outras.

O modelo clássico de regressão multivariada não faz uso direto do fato com que as variáveis de resposta são provavelmente correlacionadas. Uma preocupação prática mais séria é que, mesmo para um número moderado de variáveis cujas inter-relações devem ser investigadas, o número de parâmetros na matriz de regressão pode ser grande.

Assim, em muitas situações práticas, há uma necessidade de reduzir o número de parâmetros no modelo e esse problema pode ser abordado por meio da suposição de classificação reduzida da matriz (Reinsel e Velu, 1998). O modelo desenvolvido no artigo possui algumas características e adaptações da Regressão de Classificação Reduzida (RRR).

Na regressão linear múltipla, a matriz de projeto X possui mais de uma característica, $X \in \mathbb{R}^{n \times p}$, e assim se busca um vetor de coeficientes $\beta \in \mathbb{R}^p$ para aproximar $Y \in \mathbb{R}^n$, novamente $Y \approx X\beta$. Na regressão multivariada múltipla, ambos $X \in \mathbb{R}^{n \times p}$ e $Y \in \mathbb{R}^{n \times q}$ são multidimensionais e se busca uma matriz de coeficientes $B \in \mathbb{R}^{p \times q}$ para aproximar o mapa linear entre X e Y , novamente $Y = XB + \epsilon$ (Reinsel e Velu, 1998).

A regressão de classificação reduzida (RRR) é uma variante da regressão múltipla, com uma restrição adicional: em vez de estimar β como uma matriz de coeficientes $p \times q$, o RRR impõe que a classificação (β) = r , em que $r < \text{mínimo}(p, q)$. Intuitivamente, essa restrição reforça a suposição de que X e Y estão relacionados por meio de um pequeno número de fatores latentes em vez de uma relação completa e de alta dimensão de coeficientes pq (Reinsel e Velu, 1998).

A metodologia RRRa apresentada na tese é fundamentada na técnica de regressão de classificação reduzida. A RRRa é uma inspiração do modelo RRR, no qual, por exemplo, os perfis utilizados para realizar as previsões fotovoltaicas são reduzidos. A RRRa é uma adaptação e foram utilizados os fundamentos da metodologia RRR.

2.7 PREDIÇÕES DE GERAÇÃO FOTOVOLTAICA

A produção de energia em um sistema fotovoltaico pode variar durante curtos intervalos de tempo devido à mudança das condições meteorológicas, podendo resultar em variação e alteração da saída dessa potência produzida. Como resultado, a incerteza dos valores de geração fotovoltaica dificulta a integração na rede elétrica quando se tem um alto nível da penetração dessa energia na rede (Barbieri *et al.*, 2017).

A previsão da energia elétrica de saída dos geradores fotovoltaicos é um desafio. Em particular, é uma aplicação de várias etapas, bancos de dados grandes, medições não confiáveis e múltiplas observações de entrada-saída. Por outro lado, previsões confiáveis permitem oferecer confiabilidade aos gerentes/diretores de usinas. Por meio delas, consegue-se minimizar os desvios entre a energia programada e a energia produzida (Antonanzas *et al.*, 2016).

Apesar da participação cada vez maior de SFV com geração variável, a integração junto à rede elétrica ainda apresenta muitos desafios. Esses estão relacionados principalmente à natureza intermitente da produção fotovoltaica, variando entre otimizar o uso local e equilibrar a demanda de eletricidade na rede elétrica (Böök e Lindfors, 2020).

Por meio de um controle adequado de potência fotovoltaica gerada, pode-se oferecer para o sistema da rede elétrica e seus operadores uma operação estável, confiável e eficaz. Além disso, para se gerenciar a geração fotovoltaica intermitente, os operadores da rede elétrica precisam de métodos de previsão precisa de curto prazo e também de algum suporte de recursos energéticos que são controláveis, compensatórios e alternativos. De fato, o rápido avanço da previsão de geração fotovoltaica de curto prazo garante uma continuidade de sistemas eficientes e confiáveis na operação da rede elétrica (Barbieri e Rajakaruna, 2017). A previsão é geralmente melhorada por um pré-processamento e um pós-processamento de potência fotovoltaica de saída, a histórica e a prevista (Raza *et al.*, 2016).

A abordagem de previsões mais adequada é determinada, principalmente, por alguns fatores: horizonte de tempo utilizado e resolução, condições climáticas prevalentes, localização geográfica, disponibilidade e qualidade dos dados, classes e modelos de algoritmos de previsões e métricas de análise de erros utilizadas (Mellit *et al.*, 2020).

2.7.1 Horizontes de Resolução Temporal de Previsão

A principal maneira por meio da qual as previsões podem ser classificadas é de acordo com o horizonte de resolução temporal de previsão (HRT). As previsões realizadas para os diversos horizontes de tempo são importantes para diferentes aspectos da operação da rede, como manutenção da estabilidade da rede, agendamento de reservas rotativas, acompanhamento de carga ou comprometimento da unidade (Antonanzas *et al.*, 2016). O objetivo e a precisão de um modelo de previsão de energia fotovoltaica dependem do horizonte de previsão (Das *et al.*, 2018).

Em referência ao horizonte de previsão, essa pode ser dividida em quatro tipos, conforme apresentado na Tabela 1. Previsão de prazo muito curto com um horizonte de tempo que varia de milissegundos até aproximadamente 1 minuto; previsão de curto

prazo que varia de 1 minuto até 24 horas; predição de médio prazo que varia de 1 dia até 1 semana e predição de longo prazo que varia de 1 semana para mais (Mellit *et al.*, 2020).

Tabela 1 – Horizontes de resolução temporal para métodos de predição da radiação solar.

HRT	TERMOS RELACIONADOS	HORIZONTE DE PREDIÇÃO
Predição de prazo muito curto	<i>real time, nowcasting, ultra short-term</i>	de milissegundos até 59 segundos
Predição de prazo curto*	<i>intra-hour, short-term, intra-day</i>	de 1 minuto até 24 horas
Predição de prazo médio*	<i>medium-term, day ahead</i>	de 24 horas até 1 semana
Predição de prazo longo	<i>Long term</i>	de 1 semana ou mais

* Horizontes de predição alvo considerados no presente estudo.

Cada horizonte de predição tem sua aplicação específica para que, por exemplo, predições de prazo muito curto sejam utilizadas para o controle e a gestão de sistemas fotovoltaicos no mercado de eletricidade para o controle da rede. Horizontes de curto prazo são adotados para o controle das operações do sistema de energia, despacho econômico e comprometimento unitário. Horizontes de médio e longo prazos são geralmente utilizados para a manutenção e o planejamento de usinas fotovoltaicas (Mellit *et al.*, 2020). Portanto, adotaram-se nesta pesquisa as definições de HRT de predição de prazo médio apresentadas na Tabela 1.

2.7.2 Classes e Modelos dos Métodos de Predição

Na literatura, inúmeros métodos de predição de energia solar fotovoltaica por meio da predição da radiação solar foram desenvolvidos (Tabela 2). De acordo com Diagne *et al.* (2013), os métodos e modelos existentes de predição da GHI podem ser classificados por meio dos dados de entrada, que também determinam o horizonte de predição. Os métodos utilizados são método da persistência, método por meio de dados/imagens de satélite, método de predição numérica do tempo, método por meio de imagem do céu e métodos estatísticos. Uma visão geral dos métodos está apresentada na Tabela 2.

Tabela 2 – Métodos e modelos utilizados para predição da Irradiância Global Horizontal (GHI).

MÉTODO	SUBCLASSE	MODELO	ESCALA DE TEMPO
Persistência		Irradiância global no tempo $t+1$ é melhor prevista pelo seu valor no tempo t ($Z_{t+1} = Z_t$)	Precisa para curto prazo
Estatístico	Modelo de Série Temporal	Autorregressivo (AR)	Preciso para curto prazo
		Autorregressivo de média móvel (ARMA)	Preciso para curto prazo
Estatístico	Rede Neural	Rede neural artificial (RNAs)	Preciso para curto prazo
Baseado em dados/imagens de satélite	Imagem de satélite geoestacionário	Processamento de imagens	Bom desempenho em intervalos de 30min até 6h
Baseado em imagens de céu	Imagens do céu total	Processamento de imagens	Bom desempenho em interval de sub-horas
Baseado em modelos numéricosdo tempo	Predição numérica do tempo (PNT)	Sistema Global de previsão do tempo	Preciso para previsões mais longas

Os principais fatores que afetam o desempenho dos prognósticos utilizados na predição da energia produzida pelas usinas fotovoltaicas são o horizonte de tempo e a resolução de tempo, as condições climáticas, a localização geográfica e a disponibilidade e a qualidade dos dados (Nespoli *et al.*, 2019).

Em relação a esses parâmetros, diferentes prognósticos podem ser escolhidos para uma necessidade particular: métodos físicos (Wolff *et al.*, 2016; Dolara *et al.*, 2015), que se baseiam principalmente no uso de modelos numéricos de predição do tempo (PNT) (Larson *et al.*, 2016; Zhang *et al.*, 2019), ou imagens de satélite (Jang *et al.*, 2016), que podem ser usadas para o desenvolvimento de modelos regionais. Nesse caso, dados meteorológicos de imagens de satélite são frequentemente usados para predição de longo prazo (Pelland *et al.*, 2013). Os modelos de predição numérica do tempo são amplamente utilizados para prever o estado da atmosfera para os próximos 15 dias (Pelland *et al.*, 2013) e não precisam de dados históricos.

Esses métodos podem proporcionar uma boa precisão, mas dependem principalmente da estabilidade das condições climáticas. No entanto a implementação de modelos físicos é em geral relativamente difícil, pois exige uma série de parâmetros e equipamentos caros que nem sempre estão disponíveis em muitas áreas do mundo. Além disso, para a maioria dos modelos de predição numérica do tempo disponíveis, as

primeiras horas de predições não são particularmente úteis para a predição solar (Tuohy *et al.*, 2015).

2.7.2.1 Método da Persistência

Os métodos da persistência (MP) são métodos mais simples de elaborar predições e usados como referência para modelos mais desenvolvidos. O MP clássico assume que as condições (irradiância solar, geração, índice de céu claro etc.) permaneçam as mesmas entre o tempo atual t e $t + f_h$. O modelo da persistência é recomendado quando as séries temporais são estacionárias (Antonanzas *et al.*, 2016). A predição de geração em um instante t é dada pela Equação (2.1):

$$P_p(t + f_h) = P(t) \quad (2.1)$$

Os MPs possuem algumas características que são desejáveis, entre elas: (i) simplicidade, método que não requer nenhum treinamento ou inteligência; (ii) rapidez, método computacional rápido de implementar e fácil de operar; e (iii) repetitividade, método que sempre produz um resultado esperado para uma mesma entrada (Maciel, 2022).

2.7.2.2 Métodos Estatísticos Clássicos

Os métodos estatísticos clássicos (MEC) não precisam de nenhuma informação interna do sistema para modelá-los. É uma abordagem baseada em dados que é capaz de extrair relações em dados passados para prever o comportamento futuro da planta. Assim, a qualidade dos dados históricos é essencial para uma predição precisa (Graditi *et al.*, 2016).

Ao contrário da abordagem paramétrica, para a abordagem MEC é normalmente necessário um grande conjunto de dados históricos (medições meteorológicas e de energia, por exemplo), com os quais a usina já deve estar trabalhando há algum tempo. Esse método beneficia a capacidade de corrigir erros sistemáticos associados à medição de entradas (Antonanzas *et al.*, 2016).

Outra opção são abordagens estatísticas e probabilísticas. Esse método inclui modelos de regressão (Wanget *al.*, 2016), suavização exponencial, modelos

autorregressivos (AR), modelo autorregressivo de média móvel integrada (ARIMA), (Nobre *et al.*, 2016), conjunto de séries temporâneas (Yang e Dong, 2018) e abordagens probabilísticas (Agoua *et al.*, 2019; Bracale e Carpinelli, 2017; Sanjari e Gooi, 2016). Abordagens estatísticas são mais adequadas para previsões de curto prazo até um dia antes. Para lidar com o problema da não linearidade, várias tentativas foram feitas, por exemplo, Yang e Dong (2018) realizaram uma aplicação estendida do conjunto de séries de tempos sazonais para previsão fotovoltaica.

2.7.2.3 Modelos Numéricos do Tempo

O modelo de previsão numérica do tempo (PNT) é utilizado para estimar previsões climáticas do tempo. Ele emprega variáveis climáticas como entrada. Por meio de modelos matemáticos, consegue descrever os processos que ocorrem na atmosfera e realizar as previsões, considerando HRT superiores a 6 h. O PNT possui um desempenho melhor em escalas de tempo entre 48 h e 172 h futuras (Barbieri *et al.*, 2017). Esse modelo possui precisão menor para previsões de curto prazo quando comparado com outros modelos (Blaga *et al.*, 2019). A precisão do PNT geralmente depende da estabilidade das condições climáticas. Os modelos PNTs não requerem nenhum dado histórico de geração fotovoltaica, no entanto as desvantagens são as disponibilidades geográficas deles e o fato de que as primeiras horas de previsões não são particularmente úteis para previsões de energia solar fotovoltaica (Böök e Lindfors, 2020).

2.7.2.4 Modelos com Processamento de Imagens

Esses modelos utilizam câmeras fotográficas para realizar a captura de imagens que, posteriormente, são utilizadas em modelos de previsões. Após capturar as imagens, algumas técnicas de processamento de imagens são utilizadas para melhorar a qualidade das imagens.

Os modelos de processamento de imagens podem ser divididos em dois grupos, conforme a câmera utilizada ou a imagem capturada:

1. *Ground Based Sky Images* (GBSI): captura a imagem do céu, do sol, das nuvens e de seus movimentos por câmeras apontadas para o céu no próprio local. As câmeras utilizadas possuem lentes grandes angulares de 180°, denominadas olho

de peixe. Por meio dessas lentes, a câmera captura uma imagem de todo o céu. O objetivo destes modelos é prever a irradiância solar ou energia gerada por meio de técnicas que envolvem o processamento das nuvens em imagens digitais do céu.

2. *Satellite Based Sky Images* (SBSI): utiliza imagens da Terra que são obtidas por meio de satélites. Consegue-se extrair o vetor de movimentos das nuvens e informações meteorológicas para efetuar as previsões da irradiância direta, difusa ou global. A cobertura das nuvens é considerada o principal fator de modulação da transmitância atmosférica e as demais propriedades óticas são parametrizadas a partir das variáveis meteorológicas de temperatura da superfície, umidade relativa do ar, visibilidade atmosférica e albedo de superfície (Pereira *et al.*, 2017).

Métodos avançados baseados em técnicas de inteligência artificial (IA) e *machine learning* (ML) (Russel e Norvig, 2009) incluem redes neurais artificiais (RNAs), k vizinho mais próximo (kNN), máquina de aprendizagem extrema (MAE), máquina vetorial de suporte (MVS) etc. Esses métodos, que não necessitam de qualquer informação sobre os sistemas fotovoltaicos, têm algumas vantagens típicas das abordagens estatísticas: são usados quando as medidas do campo estão disponíveis e, basicamente, usados para aplicações de curto prazo (Mellit e Kalogirou, 2008).

Abordagens híbridas combinam um dos métodos avançados acima mencionados com uma abordagem física ou estatística. Esse tipo de técnica apresenta uma precisão de previsão muito boa, pois se beneficia da combinação de duas técnicas de bom desempenho (Dolara *et al.*, 2015; Bouzercoum *et al.*, 2013).

Na literatura, há modelos baseados no uso de medições no local, modelos que dependem de dados de previsão do tempo e modelos que combinam medições históricas no local com previsões meteorológicas (Nespoli *et al.*, 2019). Estes últimos são cada vez mais utilizados e pertencem à categoria híbrida.

Após a previsão fotovoltaica em um determinado local ser concluída, poderemos utilizar correlações com os índices de desempenho e aplicar a metodologia para realizar a previsão em qualquer localização do planeta para qualquer configuração de sistemas fotovoltaicos.

2.8 DESEMPENHO DE SISTEMAS FOTOVOLTAICOS

O sombreamento parcial ou total de um gerador fotovoltaico pode reduzir acentuadamente o rendimento de todo o sistema de geração. Devido à característica construtiva dos módulos fotovoltaicos de silício cristalino (c-Si), em que as células fotovoltaicas individuais são conectadas em série, uma pequena sombra sobre uma célula pode reduzir drasticamente o rendimento de todo o sistema. Esse fato ocorre devido à célula sombreada determinar a corrente elétrica de todo o conjunto que está conectado em série com essa célula. Os diodos de by-pass são utilizados nos módulos fotovoltaicos para minimizar esse efeito. A célula fotovoltaica parcialmente sombreada pode atuar como uma carga e parte da energia produzida se dissipa na forma de calor nessa célula, o que pode levar a um aquecimento excessivo dela e a uma possível destruição do módulo (Rüther, 2004).

Outro fator que pode influenciar o rendimento de um sistema fotovoltaico é o tipo e a potência do inversor. O inversor é um equipamento eletrônico que converte a energia gerada pelo sistema fotovoltaico, que é em corrente contínua (c.c.), em corrente alternada (c.a.). Por meio do carregamento, que é a relação entre a potência instantânea sendo convertida e a potência nominal do inversor, a eficiência de conversão do inversor pode variar. O superdimensionamento dos geradores fotovoltaicos em relação à capacidade dos inversores pode levar o inversor em certos casos a um tempo de vida de operação menor.

A análise de desempenho de diferentes SFVs pode ser realizada por meio de análises de um grupo de índices, denominados índices de mérito técnico de SFVs. A análise de desempenho do SFV baseia-se nos índices de mérito utilizados pelo programa de avaliação energética da Comunidade Econômica Europeia em seu programa de avaliação de SFCR [CEE – Joint Research Centre, 1993 apud Oliveira, 2002]. Essa metodologia de análise necessita que a instalação fotovoltaica seja monitorada por um período mínimo de um ano para que sejam conhecidos os índices de méritos mensais e, por consequência, o desempenho energético do SFCR (Rampinelli, 2010).

2.8.1 Índices de desempenho de sistemas fotovoltaicos

Os índices de desempenho são referências para diagnosticar a qualidade do sistema fotovoltaico para identificar necessidades futuras de melhoramento e definir

expectativas do retorno financeiro atribuído ao sistema. O desempenho de sistemas fotovoltaicos é determinado por meio de indicadores ou índices de mérito, que são parâmetros que caracterizam equipamentos, sistemas ou tecnologias de acordo com a sua performance de conversão de energia (Rampinelli, 2010).

Para o caso específico de sistemas fotovoltaicos, os índices de desempenho foram propostos pela *International Energy Agency Photovoltaic Power Systems Programme* (IEA-PVPS). Eles padronizam a prática de monitoramento de sistemas fotovoltaicos e são ferramentas de análise que permitem avaliar o desempenho de sistemas fotovoltaicos. A partir desse monitoramento, é possível determinar e entender as perdas do sistema fotovoltaico que não podem ser caracterizadas por uma avaliação direta do equipamento. Os métodos propostos pela IEA-PVPS são aplicáveis em todas as tecnologias de sistemas fotovoltaicos (Woyte *et al.*, 2014).

Os principais índices de desempenho utilizados para avaliar a qualidade e o desempenho de um sistema fotovoltaico são: eficiência global, produtividade do sistema (*Yield*), taxa de desempenho do sistema (*Performance Ratio*), fator de capacidade, eficiências e perdas, entre outros (Malvoniet *al.*, 2017; Markovic e Ciric, 2017). Os índices permitem analisar o funcionamento de um SFCR com base na produção de energia, recurso solar, perdas e custos (Macêdo, 2006).

Outra análise que pode ser realizada de desempenho e de características elétricas de sistemas fotovoltaicos é por meio do traçado da curva característica I-V. Essa apresenta o ponto de máxima potência de uma célula, módulo ou arranjo fotovoltaico. Além da potência máxima, ela apresenta outros parâmetros elétricos. Por meio dela, pode-se observar defeitos relacionados às células ou a módulos que estão associados no sistema de geração. Além dos defeitos, pode-se observar sombreamentos parciais ou totais nos módulos fotovoltaicos do sistema de geração (Gasparin *et al.*, 2016; Lorente *et al.*, 2014).

3 ESTADO DA ARTE

Esta seção descreve a revisão científica e tecnológica sobre a predição de geração fotovoltaica incluindo a predição de curto e médio prazo e sobre os índices de desempenho de sistemas fotovoltaicos. Foram abordados trabalhos de revisão e aplicação dos métodos existentes de predição fotovoltaica.

3.1 PREDIÇÕES DE GERAÇÃO FOTOVOLTAICA

Alguns trabalhos propuseram a realizar um estudo de revisão da literatura dos métodos de predição da geração fotovoltaica. Mellit e Kalogirou (2008) realizaram uma revisão sobre uma série de técnicas, utilizando RNAs para a predição da potência produzida por sistemas fotovoltaicos. Mostraram que as técnicas baseadas em inteligência artificial têm um grande potencial na estimativa de potência fotovoltaica e predições baseadas em redes neurais (RNN) foram reconhecidas como as mais precisas. Os autores concluíram com a literatura publicada que a inteligência artificial possui um potencial nos projetos fotovoltaicos que utilizam predições fotovoltaicas.

Outro trabalho de revisão da literatura foi proposto por Antonanzas *et al.* (2016). Os autores tiveram como objetivo de compilar uma grande parte do conhecimento sobre a predição da geração fotovoltaica, centrando-se nos últimos avanços e futuras tendências. Os autores incluíram técnicas de regressão e métodos baseados em inteligência artificial. Eles descobriram que as abordagens estatísticas têm um desempenho melhor do que as abordagens paramétricas. Mencionaram também que as técnicas mais recentes se baseiam no uso de métodos de ML, incluindo MVS, MAe e etc. Essas técnicas possuem a facilidade de modelagem sem a necessidade de conhecer as características do sistema fotovoltaico.

Raza *et al.* (2016) também forneceram uma revisão completa da literatura, incluindo séries temporais, RNAs e algumas abordagens híbridas. Uma comparação entre modelos baseados em RNA e modelos clássicos de séries temporais também foi apresentada. As conclusões foram que a predição e a precisão podem ser aprimoradas pelo pré e pelo pós-processamento dos dados históricos. As RNAs apresentaram melhores desempenhos do que outras abordagens clássicas de séries temporais. Ogloari *et al.* (2017) apresentam um extenso estudo comparativo entre métodos físicos e híbridos. A

conclusão foi que as redes neurais físicas, híbridas e artificiais (RNFHA) sempre mostram a mais alta precisão.

Das *et al.* (2018) realizaram uma revisão geral da literatura de estudos recentes sobre os métodos de predição direta. Os autores apontaram que os modelos de predição baseados em RNA e MVS funcionam particularmente bem sob condições ambientais rápidas e variadas. O algoritmo otimizado pode aumentar significativamente a precisão da predição e os algoritmos genéticos (AG) representam uma das técnicas de otimização mais práticas para a predição fotovoltaica.

Sobri *et al.* (2018) concluíram que os métodos baseados em RNA e MVS são amplamente utilizados devido à sua capacidade de resolver problemas de predição complexos e não lineares. Métodos de conjunto capazes de melhorar a precisão de predição foram encontrados, eles são capazes de mesclar métodos lineares e não lineares.

A predição de médio prazo é importante para o controle de armazenamentos de energia (usinas de geração centralizada) e de despachos da energia elétrica gerada pelas concessionárias de energia. Para os casos de erros de predição do dia seguinte, que são os mais relevantes para realizar o planejamento de estratégias do despacho, Dewangan *et al.* (2020) exploraram diferentes métodos combinados de predição de energia solar para três usinas fotovoltaicas localizadas na Austrália. Os autores utilizaram doze variáveis PNT e séries temporais de energia, registradas de 1º de abril de 2012 a 30 de junho de 2014, para as três usinas fotovoltaicas. A predição da geração fotovoltaica para o dia seguinte é uma função não linear das variáveis de previsão do tempo, como irradiância, temperatura e cobertura de nuvens. O modelo de regressão fornece a predição média para a entrada fornecida aprendendo os padrões de treinamento e diminui o efeito da incerteza presente nas variáveis de entrada, fornecidas pelo PNT.

Dewangan *et al.* (2020) destacam que as predições combinadas são utilizadas quando é difícil determinar o melhor modelo de predição entre vários modelos. Diferentes modelos de predição têm diferentes métodos de aprendizagem. Assim, as saídas de predição possuem informações diferentes, que podem ser combinadas para se obter um modelo preciso. Modelos de predição candidatos devem ter precisão satisfatória para participar de predições combinadas, e modelos de predição com baixo desempenho não devem ser considerados ao formar o modelo de predição combinada. Os métodos de predição combinada incluem média simples com pesos iguais, mediana, regressão linear e regressão não linear.

Os modelos de predições utilizados no trabalho de Dewangan *et al.* (2020) foram: RNa (Rede neural de avanço), RPG (Regressão do processo gaussiano), RPGMa (Regressão de processo gaussiano com kernel matern), RL (Regressão linear), RLI (Regressão linear interativa), RLG (Regressão linear de gaussiana), MP (Método da Persistência), RVSG (Regressão de vetor de suporte com kernel gaussiano), RVSL (Regressão de vetor de suporte com kernel linear), RVSQ (Regressão de vetor de suporte kernel quadrático), RNPM (Redes neurais profundas com memória de longo prazo) e RAc (Regressão de árvores de conjunto). A lista de abreviações usadas na Tabela 3 utiliza as siglas para os modelos básicos. O sufixo 'C' foi adicionado ao nome do algoritmo combinado para diferenciar os modelos básicos e os modelos combinados. As métricas estatísticas utilizadas para analisar as precisões da predição dos modelos são avaliadas em termos de erro percentual médio absoluto (MAPE) e raiz do erro médio quadrático (RMSE).

Tabela 3 - Comparação de desempenho RMSE de modelos de predição básicos e combinados para o primeiro mês (adaptado de Dewangan *et al.*, 2020).

Classificação	Usina 1		Usina 2		Usina 3	
	Modelos	RMSE [%]	Modelos	RMSE [%]	Modelos	RMSE [%]
1	MédiaC	7,79	RLIC	15,36	RLC	8,71
2	RNPMC	7,83	RLC	15,37	MédiaC	8,75
3	RVSGC	7,87	RNPMC	15,37	RNPMC	8,76
4	RLC	7,89	RPGMaC	15,40	RLIC	8,80
5	RVSLC	7,92	MédiaC	15,44	RVSLC	8,85
6	MedianaC	7,94	MedianaC	15,50	MedianaC	8,85
7	RPGMaC	7,95	RPGMa	15,58	RVSGC	8,86
8	RLIC	8,04	RVSGC	15,72	RPGMaC	8,87
9	RVSG	8,64	RVSLC	15,79	RNPM	9,64
10	RNa	8,77	RVSG	15,95	RVSG	9,92
11	RPGMa	8,91	RAc	16,58	RVSQ	9,95
12	RVSQ	9,06	RNPM	16,70	RAc	9,96
13	RLI	9,21	RVSQ	17,16	RNa	10,22
14	RAc	9,37	RLI	17,79	RLI	10,62
15	RNPM	9,78	RNa	17,97	RPGMa	10,84
16	MP	18,43	MP	20,23	MP	21,12

Legenda:

MédiaC: média combinada; MedianaC: mediana combinada; RNPMC: redes neurais profundas vom memória de longo prazo combinada; RVSGC: regressão de vetor de suporte com kernel gaussiano combinada; RLC: regressão linear combinada; RVSLC: regressão de vetor de suporte com kernel linear combinada; RLIC: regressão linear interativa combinada; RPGMaC: regressão do processo gaussiano com kernel matern combinada; RAc: regressão de árvores de conjunto; RNPM: redes neurais profundas com memória de longo prazo; RVSQ: regressão de vetor de suporte com kernel quadrático; RNa: rede neural de avanço; RVSG: regressão de vetor de suporte com kernel gaussiano; RPGMa: regressão do processo gaussiano com kernel matern; RLI: regressão linear interativa; MP: método da persistência.

A Tabela 3 apresenta a comparação de desempenho (RMSE) dos modelos de predição básicos e combinados das usinas 1, 2 e 3 para o primeiro mês. Os autores alcançaram para o modelo da persistência um RMSE de 18,43%, 20,23% e 21,12% para as usinas 1, 2 e 3, respectivamente.

Para o modelo combinado RVSGC (Regressão de Vetor de Suporte com Kernel Gaussiano), alcançaram um valor de 7,87%, 15,72% e 8,86% para as usinas 1, 2 e 3, respectivamente. O RMSE para método RVSG, sem a combinação, foi de 8,64%, 15,95% e 9,92% para as usinas 1, 2 e 3.

As tabelas 4, 5 e 6 também apresentam as comparações de desempenho (RMSE) dos modelos de predição básicos e combinados das três usinas para o segundo, o terceiro e o quarto mês, respectivamente.

Tabela 4 - Comparação de desempenho RMSE de modelos de predição básicos e combinados para o segundo mês (adaptado de Dewangan *et al.*, 2020).

Classificação	Usina 1		Usina 2		Usina 3	
	Modelos	RMSE [%]	Modelos	RMSE [%]	Modelos	RMSE [%]
1	MédiaC	9,80	RVSLC	7,37	RNPMC	9,19
2	MedianaC	9,81	RVSGC	7,41	RLIC	9,25
3	RNPMC	9,85	MedianaC	7,41	RLC	9,31
4	RVSGC	9,95	MédiaC	7,53	RPGMaC	9,33
5	RLC	9,98	RNPMC	7,54	MédiaC	9,38
6	RVSLC	9,99	RPGMaC	7,54	MedianaC	9,41
7	RLIC	10,06	RLIC	7,55	RVSGC	9,56
8	RPGMaC	10,10	RLC	7,56	RVSLC	9,62
9	RAc	10,22	RAc	8,07	RPGMa	10,14
10	RNPM	10,67	RNPM	8,68	RAc	10,28
11	RVSQ	10,76	RVSQ	8,75	RNPM	10,41
12	RNa	10,84	RVSG	8,98	RVSG	10,65
13	RVSG	11,11	RPGMa	9,10	RLI	10,71
14	RPGMa	11,18	RLI	9,38	RNa	10,86
15	RLI	11,24	RNa	9,51	RVSQ	10,91
16	MP	18,71	MP	21,04	MP	19,95

Legenda:

MédiaC: média combinada; MedianaC: mediana combinada; RNPMC: redes neurais profundas vom memória de longo prazo combinada; RVSGC: regressão de vetor de suporte com kernel gaussiano combinada; RLC: regressão linear combinada; RVSLC: regressão de vetor de suporte com kernel linear combinada; RLIC: regressão linear interativa combinada; RPGMaC: regressão do processo gaussiano com kernel matern combinada; RAc: regressão de árvores de conjunto; RNPM: redes neurais profundas com memória de longo prazo; RVSQ: regressão de vetor de suporte com kernel quadrático; RNa: rede neural de avanço; RVSG: regressão de vetor de suporte com kernel gaussiano; RPGMa: regressão do processo gaussiano com kernel matern; RLI: regressão linear interativa; MP: método da persistência.

Os autores alcançaram para o modelo da persistência no segundo mês um RMSE de 18,71%, 21,04% e 19,75% para as usinas 1, 2 e 3, respectivamente. Os melhores RMSE para a Usina 1 no segundo mês foi por meio dos métodos MédiaC e MedianaC com valores de 9,80% e 9,81%. Para a Usina 2, no segundo mês, foram os métodos RVSLC e RVSGC com valores de 7,37% e 7,41%. A Usina 3 apresentou os métodos RNPMC e RLIC como os melhores, com valores de 9,19% e 9,25%.

Tabela 5 - Comparação de desempenho RMSE de modelos de predição básicos e combinados para o terceiro mês (adaptado de Dewangan *et al.*, 2020).

Classificação	Usina 1		Usina 2		Usina 3	
	Modelos	RMSE [%]	Modelos	RMSE [%]	Modelos	RMSE [%]
1	RVSGC	12,11	RVSLC	12,23	RNPMC	10,72
2	RNPMC	12,11	RVSGC	12,28	RLIC	10,76
3	RLIC	12,13	RNPMC	12,38	MédiaC	10,76
4	RPGMaC	12,14	RLIC	12,39	RLC	10,79
5	MédiaC	12,17	RLC	12,44	RPGMaC	10,84
6	RVSLC	12,18	MédiaC	12,45	RVSGC	10,88
7	RLC	12,24	RPGMaC	12,45	RVSLC	10,88
8	MedianaC	12,26	MedianaC	12,55	MedianaC	10,93
9	RVSQ	12,86	RAc	12,73	RNa	11,66
10	RNPM	12,93	RNPM	12,96	RLI	11,70
11	RVSG	13,13	RVSQ	13,21	RAc	11,71
12	RAc	13,14	RNa	13,29	RVSQ	11,78
13	RLI	13,16	RLI	13,66	RNPM	12,10
14	RNa	13,32	RVSG	14,03	RVSG	12,12
15	RPGMa	13,78	RPGMa	14,43	RPGMa	12,48
16	MP	20,63	MP	19,47	MP	19,57

Legenda:

MédiaC: média combinada; MedianaC: mediana combinada; RNPMC: redes neurais profundas vom memória de longo prazo combinada; RVSGC: regressão de vetor de suporte com kernel gaussiano combinada; RLC: regressão linear combinada; RVSLC: regressão de vetor de suporte com kernel linear combinada; RLIC: regressão linear interativa combinada; RPGMaC: regressão do processo gaussiano com kernel matern combinada; RAc: regressão de árvores de conjunto; RNPM: redes neurais profundas com memória de longo prazo; RVSQ: regressão de vetor de suporte com kernel quadrático; RNa: rede neural de avanço; RVSG: regressão de vetor de suporte com kernel gaussiano; RPGMa: regressão do processo gaussiano com kernel matern; RLI: regressão linear interativa; MP: método da persistência.

Os autores alcançaram para o modelo da persistência no terceiro mês um RMSE de 20,63%, 19,47% e 19,57% para as usinas 1, 2 e 3, respectivamente. Os melhores RMSE para a Usina 1 no terceiro mês foi por meio dos métodos RVSGC e RNPMC, ambos com valores de 12,11%. Para a Usina 2, no terceiro mês, os dois melhores métodos usados no segundo mês foram repetidos, RVSLC e RVSGC, com valores de 12,23% e

12,28%. A Usina 3 também repetiu os métodos RNPMC e RLIC, usados no segundo mês. Os valores de RMSE foram de 10,72% e 10,76%, respectivamente.

Tabela 6 - Comparação de desempenho RMSE de modelos de predição básicos e combinados para o quarto mês (adaptado de Dewangan *et al.*, 2020).

Classificação	Usina 1		Usina 2		Usina 3	
	Modelos	RMSE [%]	Modelos	RMSE [%]	Modelos	RMSE [%]
1	RVSGC	9,97	MedianaC	8,77	RPGMaC	9,11
2	RNPMC	10,11	MédiaC	8,88	RVSGC	9,14
3	RVSLC	10,14	RVSGC	8,90	RLIC	9,18
4	MédiaC	10,15	RVSLC	8,90	RVSLC	9,22
5	MedianaC	10,19	RNPMC	8,93	MédiaC	9,25
6	RLIC	10,22	RLC	9,09	RLC	9,27
7	RPGMaC	10,25	RLIC	9,16	RNPMC	9,37
8	RLC	10,28	RPGMaC	9,16	MedianaC	9,41
9	RNPM	10,64	RVSQ	9,75	RNPM	9,93
10	RVSQ	10,69	RNPM	9,97	RVSQ	10,09
11	RVSG	11,28	RVSG	10,01	RNa	10,26
12	RNa	11,35	RPGMa	10,10	RVSG	10,28
13	RLI	11,43	RAc	10,13	RLI	10,32
14	RAc	11,45	RLI	10,26	RAc	10,48
15	RPGMa	12,66	RNa	10,29	RPGMa	10,71
16	MP	20,24	MP	20,78	MP	19,41

Legenda:

MédiaC: média combinada; MedianaC: mediana combinada; RNPMC: redes neurais profundas vom memória de longo prazo combinada; RVSGC: regressão de vetor de suporte com kernel gaussiano combinada; RLC: regressão linear combinada; RVSLC: regressão de vetor de suporte com kernel linear combinada; RLIC: regressão linear interativa combinada; RPGMaC: regressão do processo gaussiano com kernel matern combinada; RAc: regressão de árvores de conjunto; RNPM: redes neurais profundas com memória de longo prazo; RVSQ: regressão de vetor de suporte com kernel quadrático; RNa: rede neural de avanço; RVSG: regressão de vetor de suporte com kernel gaussiano; RPGMa: regressão do processo gaussiano com kernel matern; RLI: regressão linear interativa; MP: método da persistência.

Para o quarto mês, os autores obtiveram para o método da persistência um RMSE de 20,24%, 20,78% e 19,41% para as usinas 1, 2 e 3, respectivamente. Os melhores RMSE para a Usina 1 no quarto mês se repetiram, usados no terceiro mês, RVSGC e RNPMC, com valores de 9,97% e 10,11%, respectivamente. Para a Usina 2, no quarto mês, os dois melhores métodos foram os MedianaC e MédiaC, com valores de 8,77% e 8,88%. Para a Usina 3, os dois melhores métodos foram os RPGMaC e RVSGC, com valores de 9,11% e 9,14%, respectivamente (Dewangan *et al.*, 2020).

Segundo Dewangan *et al.* (2020), o desempenho médio dos modelos básicos de predição baseados em RVS com função kernel quadrática e gaussiana, RAc e redes

profundas com camadas RNPM foi melhor do que os outros modelos básicos de predição. Isso sugere que qualquer um dos quatro modelos básicos deve ser preferido quando um único modelo de predição é viável. O desempenho médio das predições combinadas foi considerado melhor do que o dos modelos básicos. O benefício da predição combinada é o RMSE reduzido em até 2% (da potência nominal da usina) dos modelos básicos de predição. O desempenho médio dos modelos de predição combinados baseados em RVS com função de kernel gaussiano, redes profundas com camadas RNPM e média simples foi melhor do que o dos outros modelos de predição combinados.

Zhu *et al.* (2015) apresentaram um método híbrido de predição e geração fotovoltaica que combinou as vantagens da decomposição wavelet (DW) e da rede neural artificial (RNA). Os autores utilizaram a irradiância solar teórica e as variáveis meteorológicas como entrada do modelo híbrido baseado em DW e RNA. A potência de saída da planta fotovoltaica foi decomposta usando DW para separar as informações úteis das perturbações. As RNAs são usadas para construir os modelos da potência de saída fotovoltaica decomposta. Finalmente, as saídas dos modelos RNAs são reconstruídas na potência prevista da usina fotovoltaica. O método apresentado é comparado com o método tradicional de previsão baseado em RNA. Os resultados mostram que o método descrito neste trabalho requer menos tempo de cálculo e tem melhor precisão de predição. Os dados utilizados no artigo foram registrados com um intervalo de amostragem de 1 minuto.

A Figura 8 apresenta as curvas de potência de saída da usina fotovoltaica em quatro condições climáticas típicas: dia claro, dia nublado, dia muito nublado e dia chuvoso. A linha sólida é a saída medida da usina fotovoltaica, a linha pontilhada é a saída teórica da usina fotovoltaica e as quatro cores correspondem às quatro estações. A Figura 8a, correspondente a um dia claro, mostra que a saída medida da usina fotovoltaica é semelhante à saída teórica; na Figura 8b, percebe-se que, em um dia nublado, a curva de saída medida da usina fotovoltaica flutua frequentemente devido ao movimento das nuvens no céu; na Figura 8c, vê-se que, em um dia muito nublado, a saída medida da usina de energia fotovoltaica diminui significativamente e a flutuação é menor do que em tempo nublado; na Figura 8d, nota-se que, em um dia chuvoso, a produção medida da usina fotovoltaica pode mostrar um grande declínio. Influenciada por fatores sazonais, a curva de irradiância solar global tem diferenças óbvias de quantidade, é maior no verão, seguida por primavera, outono e inverno (Zhu *et al.*, 2015).

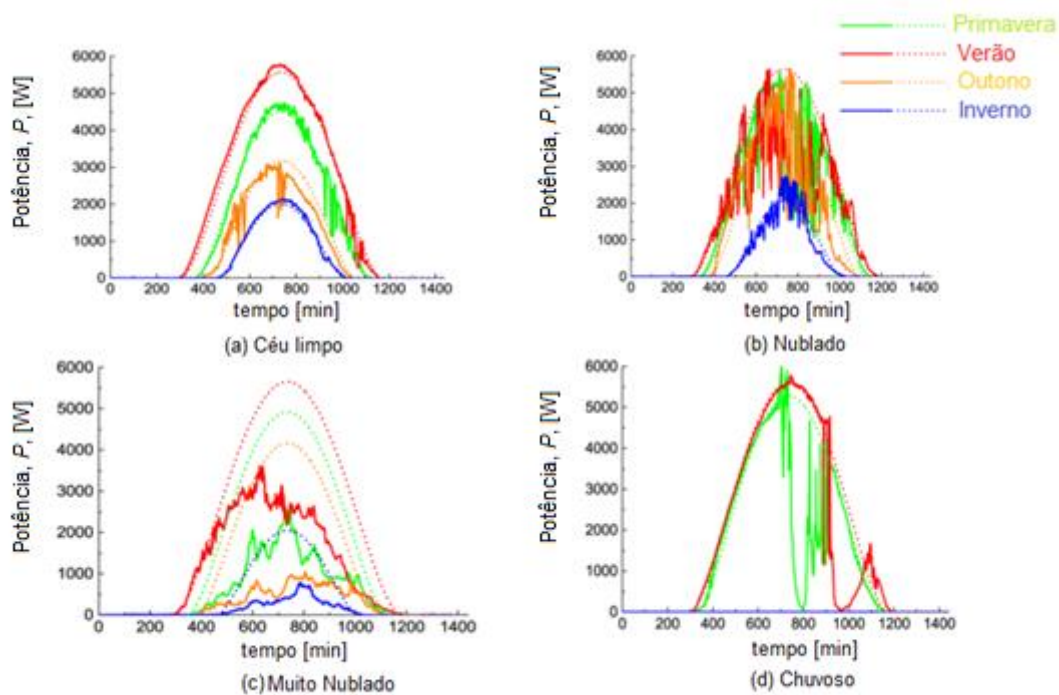


Figura 8 - Potência de uma usina de energia fotovoltaica durante as estações típicas e sob condições climáticas típicas. (a) potência gerada diária em dias claros durante as estações típicas, (b) potência gerada diária em dias nublados durante as estações típicas, (c) potência gerada diária em dias muito nublados durante as estações típicas e (d) potência gerada diária em dias chuvosos durante as estações típicas (adaptado de Zhu *et al.*, 2015).

Resumindo, a potência de saída diária da usina fotovoltaica apresenta características não lineares do dia para a noite, enquanto a produção da usina fotovoltaica tem diferenças óbvias na quantidade total durante diferentes estações em um período de 1 ano. Pode-se observar que os métodos convencionais de previsão de potência baseados em séries temporais não são aplicáveis à potência de saída de uma usina fotovoltaica (Zhu *et al.*, 2015).

Para avaliar a eficácia desse método, ele é comparado com o método de previsão baseado em RNA. A Figura 9 apresenta o contraste de desempenho de previsão entre o método RNA e o método DW + RNA. A linha sólida mostra a saída de energia medida da usina de energia fotovoltaica, enquanto a linha pontilhada mostra a saída prevista pelos dois métodos. Ao comparar os resultados da previsão, em um dia claro, DW + RNA tem boa precisão de previsão. Em dias nublados ou chuvosos, DW + RNA pode fornecer diferentes quantidades totais de potência de saída. No entanto, em dias nublados ou chuvosos, devido a mudanças abruptas na camada de nuvens e outros fatores ambientais,

a potência medida flutua muito e os resultados da previsão apresentam um certo desvio (Zhu *et al.*, 2015).

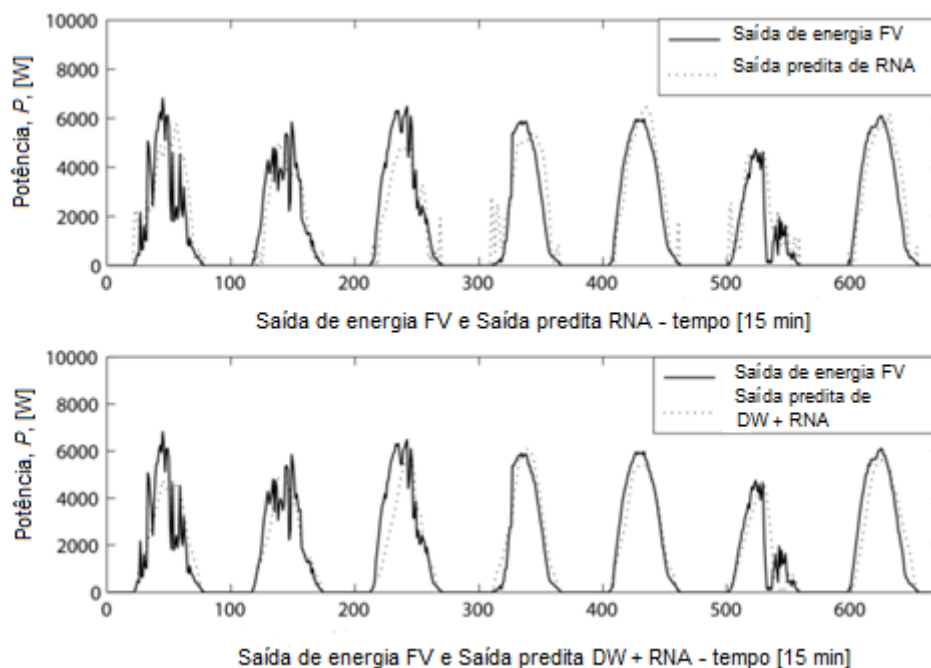


Figura 9 - Comparação dos resultados projetados (adaptado de Zhu *et al.*, 2015).

Zhu *et al.* (2015) utilizaram os índices RMSE, MAE e MAPE para avaliarem os resultados da previsão com base em DW + RNA e RNA. A Tabela 7 apresenta os resultados da avaliação de diferentes métodos para entender melhor o efeito do uso de DW + RNA e RNA sob várias condições climáticas diferentes.

Tabela 7 – Comparação do desempenho de previsão com os modelos RNA e DW + RNA em diferentes tipos de dia (adaptado de Zhu *et al.*, 2015).

Modelo	Clima	RMSE (%)	Erro	
			MAE [%]	MAPE [%]
RNA	Céu claro	9,313	4,978	13,858
	Nublado	18,472	10,259	21,550
	Muito Nublado	18,511	10,220	35,226
	Chuvoso	22,948	13,062	30,926
DW + RNA	Céu claro	7,193	3,639	9,240
	Nublado	16,817	9,578	21,294
	Muito Nublado	17,607	10,544	26,767
	Chuvoso	19,663	10,349	25,373

Percebe-se, por meio da Tabela 7, que o método DW + RNA tem uma melhor precisão de predição do que o método RNA em diferentes condições climáticas.

El-Baz *et al.* (2018) apresentaram uma nova abordagem de previsão probabilística de geração fotovoltaica para um dia à frente para sistemas de gerenciamento de energia em edifícios. O modelo consiste em vários módulos para desenvolver a predição probabilística. Inicialmente, um modelo de céu limpo é ajustado para incorporar as perdas do sistema, temperatura e sombreamento parcial. O modelo foi desenvolvido com base nos dados disponíveis em edifícios, como as medições históricas da geração fotovoltaica e as previsões meteorológicas. A previsão probabilística foi validada em um conjunto de dados de um ano completo de um sistema fotovoltaico de 3 kWp localizado no telhado na cidade de Munique, Alemanha. Os resultados mostraram sua capacidade de fornecer uma predição precisa e confiável para aplicações nos sistemas de gerenciamento de energia em edifícios.

A Figura 10 apresenta o erro médio diário para diferentes períodos de treinamento cumulativos de uma resolução temporal horária. O erro foi normalizado para o valor nominal do sistema fotovoltaico.




Figura 10 - Erro em relação aos horizontes de treinamento (El-Baz *et al.*, 2018).

Percebe-se, por meio da Figura 10, que o RMSE e o MAE diminuem após quatro meses de treinamento e depois se estabilizam. O valor inicial começa em junho após um mês de treinamento, representando o valor mais alto, 17,3% para o RMSE, 9,3% para o

MAE e -1,5% para o MBE. Após quatro meses de treinamento, o RMSE caiu para 15,3%. Por outro lado, o MAE e o MBE foram 8,5% e 1,53%, respectivamente.

3.2 ÍNDICES DE DESEMPENHO FOTOVOLTAICO

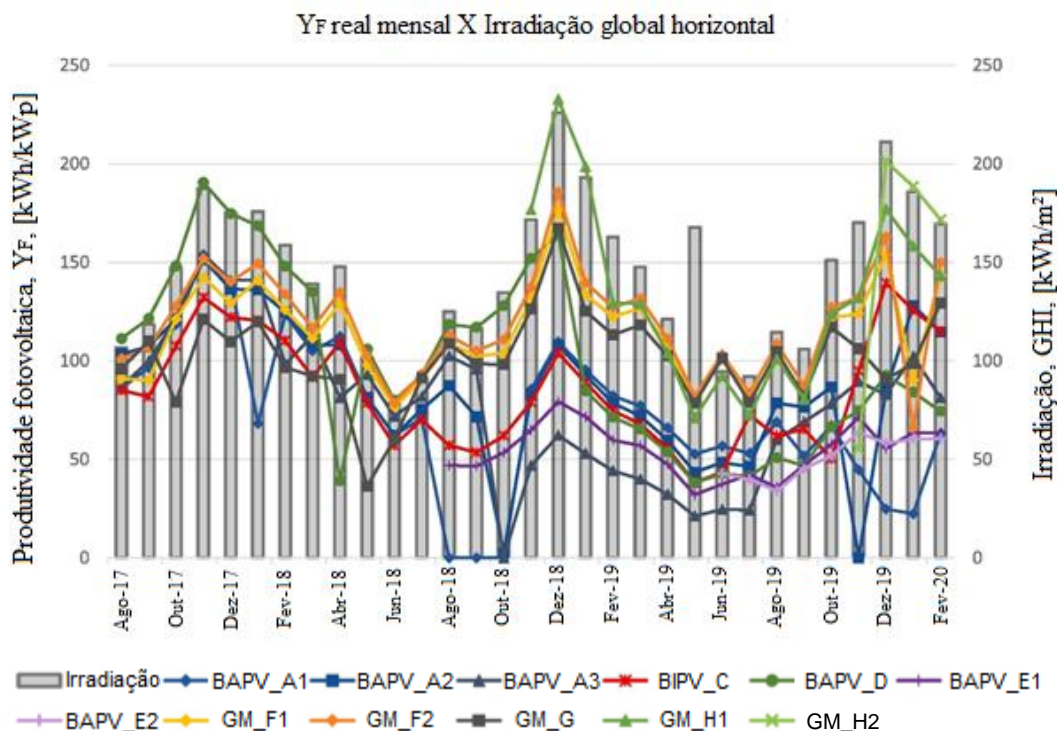
Zomer *et al.* (2020) avaliaram a evolução do balanço energético e o desempenho energético dos sistemas fotovoltaicos instalados no laboratório Fotovoltaica – UFSC (Figura 11) de agosto de 2017 a fevereiro de 2020. As análises foram realizadas monitorando a disponibilidade de irradiação solar no local, mudanças no número de ocupantes do edifício, upgrades na capacidade instalada dos sistemas fotovoltaicos, perfil de uso do ônibus elétrico (eBus), requisitos ocasionais de experimentos de pesquisa e desenvolvimento para paradas de alguns sistemas fotovoltaicos, geração mensal de energia e consumo e gases de efeito estufa evitados. Zomer *et al.* (2020) avaliaram o desempenho energético utilizando o índice Y_F (kWh/kWp) dos sistemas instalados (Figura 12). Primeiro, os rendimentos mensais foram calculados usando os dados de geração de energia e a capacidade instalada de cada sistema fotovoltaico.



Legenda:

BAPV_A: Sistema solar fotovoltaico aplicado no envoltório do edifício A com telhado curvo; BAPV_B: Sistema solar fotovoltaico aplicado no envoltório do edifício B com telhado plano inclinado; BIPV_C: Garagem solar; BAPV_D: Abrigo de ponto de ônibus coberto com sistema fotovoltaico; BAPV_E: Sistema fotovoltaico aplicado na fachada do edifício B; GM_F, GM_G: Sistemas fotovoltaicos montados no solo fixos e GM_H: Sistema fotovoltaico montado no solo com rastreador solar.

Figura 11 - Vista aérea do Laboratório Fotovoltaica / UFSC, com 111 kWp de sistemas fotovoltaicos conectados à rede (Zomer *et al.*, 2020).



Legenda:

BAPV_A1: Subsistema 1; BAPV_A2: Subsistema 2; BAPV_A3: Subsistema 3; BIPV_C: Garagem solar; BAPV_D: Abrigo de ponto de ônibus coberto com sistema fotovoltaico; BAPV_E1: Subsistema 1 na fachada do edifício B; BAPV_E2: Subsistema 2 na fachada do edifício B; GM_F1: Subsistema 1 no solo fixo; GM_F2: Subsistema 2 no solo fixo; GM_G: Sistema fotovoltaico montado no solo fixo e GM_H1: Subsistema 1 montado no solo com rastreador solar; GM_H2: Subsistema 2 montado no solo com rastreador solar.

Figura 12 - Variação mensal do rendimento energético de cada sistema fotovoltaico em análise e irradiação horizontal global mensal no mesmo local (adaptado de Zomer *et al.*, 2020).

Em seguida, foram calculadas as médias mensais de todas as produções de energia, a fim de se obter um valor de produção de energia final que represente a capacidade total instalada de sistemas fotovoltaicos no Laboratório Fotovoltaica - UFSC. Ambas as análises de rendimento de energia foram demonstradas por meio de gráficos, que também mostram a irradiação horizontal global no local, a fim de se observar a relação entre elas.

Zomer *et al.* (2020) perceberam que a maioria dos valores de rendimento segue a curva de irradiação, com alguns sistemas fotovoltaicos com desempenho melhor do que o de outros. Durante o primeiro ano analisado, todos os sistemas fotovoltaicos apresentaram desempenhos energéticos semelhantes. Então, de junho de 2019 a fevereiro de 2020, as curvas demonstram mais diferenças entre si. Além disso, dois sistemas fotovoltaicos de fachada foram adicionados, com rendimentos mais baixos, conforme esperado de sua inclinação vertical e orientação leste. Considerando os anos com dados

adquiridos para todos os meses, em 2018 as produções energéticas médias anuais foram de 1114 kWh/kWp e, em 2019, de 931 kWh/kWp e as médias do fator de capacidade foram de 13,2% e 11,2%, respectivamente. Se todos os geradores fotovoltaicos estivessem conectados à rede e alimentando energia sempre que o sol brilhava, os rendimentos de energia de 2018 e 2019 teriam sido de 1.315 kWh/kWp e 1.247 kWh/kWp, respectivamente, 18% e 34% maior. Quando os SFVs GM são comparados com os sistemas BIPV, com todos os sistemas funcionando em uma situação ideal, o rendimento energético esperado dos sistemas BIPV seria apenas 11% menor do que o dos sistemas GM.

Chikh *et al.* (2021) avaliaram o desempenho de uma planta piloto fotovoltaica conectada à rede com módulos fotovoltaicos de diferentes tecnologias. As tecnologias dos módulos fotovoltaicos utilizadas são silício monocristalino, silício multicristalino, silício amorfo e telureto de cádmio. A planta piloto possui uma potência nominal de 400 kWp e está localizada em Ghardaia, deserto do Saara, centro-norte da Argélia (Figura 13). Os autores utilizaram alguns índices de mérito técnico para avaliarem os desempenhos energéticos dos subsistemas. Alguns dos índices utilizados são performance ratio (P_R), fator de capacidade (F_C), produtividade dos sistemas (Y_F) e rendimento de referência (Y_R).



Figura 13 – Vista da planta piloto fotovoltaica em Ghardaia, Argélia. (a) Silício amorfo, (b) telureto de cádmio, (c) silício monocristalino e (d) silício multicristalino (adaptado de Chikh *et al.*, 2021).

O esquema da planta piloto é apresentado na Figura 14. Cada um dos subsistemas é composto por um arranjo fotovoltaico de 100 kWp e um inversor c.c./c.a.

de 96 kW de potência. As características técnicas das diferentes tecnologias dos módulos fotovoltaicos e as características do inversor estão apresentadas na Tabela 8.

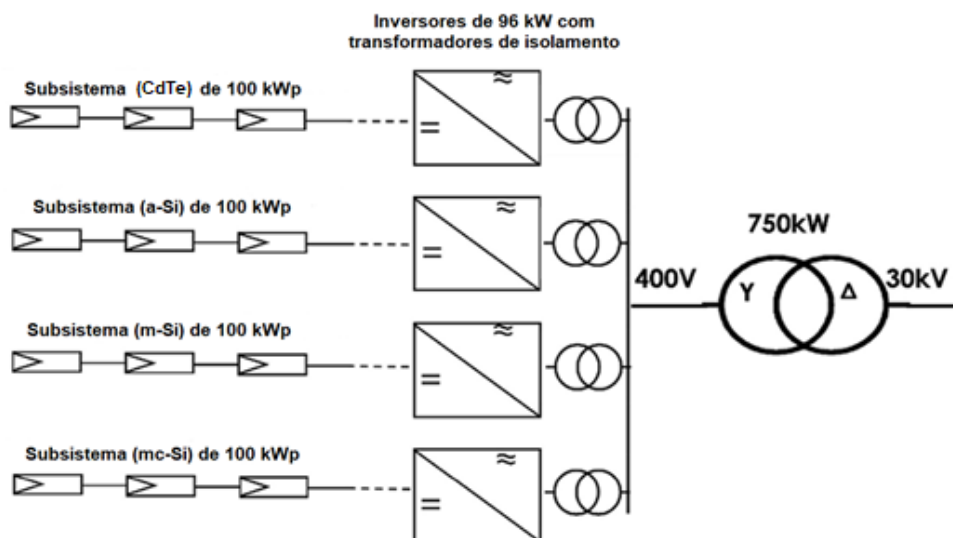


Figura 14 - Esquema da planta piloto de 400 kWp, localizada em Ghardaïa, Argélia
(adaptado: Chikh *et al.*, 2021).

Tabela 8 – Características técnicas dos módulos fotovoltaicos e dos inversores
(adaptado de Chikh *et al.*, 2021).

Valores Nominais		CdTe	a-Si	m-Si	mc-Si
Potência nominal (+/-5%)	P_{MP} (W)	80	103	250	240
Tensão de máxima potência	V_{MP} (V)	71.2	17.4	30.35	29.21
Corrente de máxima potência	I_{MP} (A)	1.12	5.57	8.24	8.21
Tensão de circuito aberto	V_{OC} (V)	91,5	23.7	37,62	37.16
Corrente de curto-circuito	I_{SC} (A)	1.22	6.72	8.79	8.73
Coefficiente de temperatura de P_{MP}	$T_c (P_{MP})$ (%/°C)	-0,25	-0,2	-0,43	-0,43
Coefficiente de temperatura de V_{OC} , alta temperatura (>25°C)	$T_c (V_{OC}$, alta temperatura) (%/°C)	-0,25	-0,33	-0,34	-0,32
Coefficiente de temperatura de V_{OC} , baixa temperatura (-40°C a +25°C)	$T_c (V_{OC}$, baixa temperatura) (%/°C)	-0,20	-0,33	-0,34	-0,32
Coefficiente de temperatura de I_{SC}	$T_c (I_{SC})$ (%/°C)	+0,04	+0,08	+0,03	+0,04
Eficiência do Módulo (STC)	η (%)	11.11	6.9	15.35	14.74
Inversor (CC/CA)	Potência nominal: 96 kW, eficiência europeia: 97,17%				

O período de monitoramento dos subsistemas foi de maio de 2015 a abril de 2016. Os indicadores de desempenho foram utilizados para realizar análises comparativas de desempenho dos subsistemas fotovoltaicos que constituem a usina fotovoltaica de 400 kWp. Os resultados de desempenho obtidos dos subsistemas foram comparados com o desempenho energético de sistemas fotovoltaicos instalados em outras localidades caracterizadas por climas áridos e semiáridos semelhantes (Chikh *et al.*, 2021).

O estudo dos parâmetros de desempenho normalizados estão apresentados na Figura 15. Os valores apresentados na Figura 15 e na Tabela 9 são das médias diárias mensais. O rendimento de referência Y_R atingiu seu máximo durante os meses de maio, junho e julho com um valor de 7,04 kWh/kWp de insolação, equivalente a 1000 W/m². O mínimo foi registrado nos meses de dezembro, janeiro e fevereiro, atingindo em torno de 5,60 h de insolação, equivalente a 1000 W/m². Além disso, o Y_F dos subsistemas fotovoltaicos possui valores diferentes dependendo da tecnologia do arranjo fotovoltaico, conforme ilustrado na Tabela 9.




Figura 15 - Produtividade dos subsistemas Y_F em comparação com o rendimento de referência Y_R (adaptado de Chikh *et al.*, 2021).

Tabela 9 - Comparação dos rendimentos finais dos subsistemas fotovoltaicos de 100 kWp (adaptado de Chikh *et al.*, 2021).

Subsistemas	$Y_{F\text{MÁX}}$ (kWh/kWp)	$Y_{F\text{MÍN}}$ (kWh/kWp)	$(Y_{R\text{MÁX}} - Y_{F\text{MÁX}})/Y_{R\text{MÁX}}$ (%)	$(Y_{R\text{MÍN}} - Y_{F\text{MÍN}})/Y_{R\text{MÍN}}$ (%)
a-Si	6,54	4,29	7,10	22,84
CdTe	5,76	4,24	18,18	23,74
m-Si	5,64	4,27	19,88	23,20
mc-Si	5,18	3,93	26,42	29,31

Como apresentado nessa tabela, o subsistema com a tecnologia de a-Si possui o melhor desempenho, com um desvio relativo mínimo e máximo em comparação com Y_R de cerca de 7,10% e 22,84%, respectivamente (Chikh *et al.*, 2021).

De acordo com os resultados apresentados na Tabela 9, o subsistema mc-Si apresenta o menor desempenho energético, com perdas de produção de 26,42%. Essas perdas importantes podem ser devido à indisponibilidade de produção de energia durante os períodos em que ocorreram manutenções de quebras de módulos e ao efeito de outras condições ambientais. As perdas reais podem ser induzidas por parâmetros e fatores, como efeitos ópticos (ângulo e amplitude), sombreamento, sujeira, efeito da temperatura no desempenho dos módulos fotovoltaicos, efeito de incompatibilidade, qualidade dos módulos, perdas resistivas em cabos, desempenho dos inversores e desempenho dos transformadores (Chikh *et al.*, 2021).

O P_R médio da usina fotovoltaica após 12 meses de operação atingiu um valor aproximadamente de 81,12%, o que pode ser considerado significativo. Isso pode significar que o sistema tem funcionado de forma correta e eficiente sem nenhum problema técnico maior durante o período de produção considerado. Normalmente, o P_R do sistema fotovoltaico varia com as estações do ano. O P_R foi maior no inverno e depois diminuiu para mínimo durante os meses mais quentes à medida que a temperatura do módulo aumentou e voltou a subir durante o período do outono ao inverno. A Figura 16 apresenta uma curva típica de P_R para os subsistemas (Chikh *et al.*, 2021).

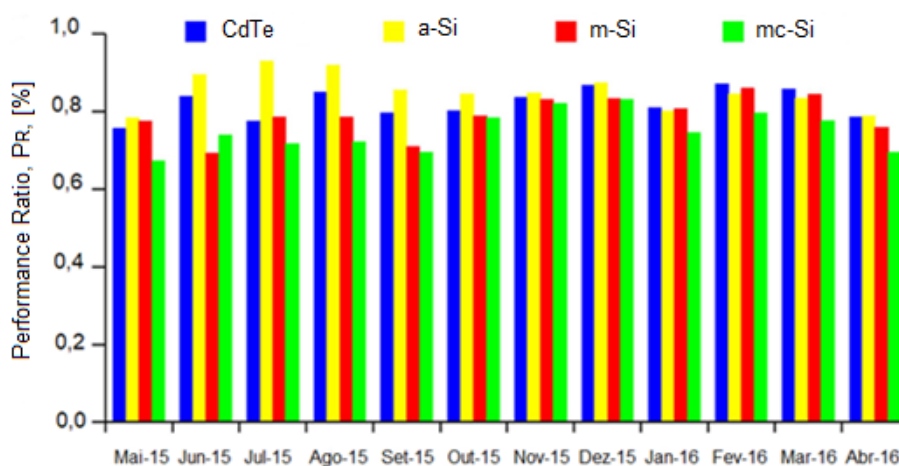


Figura 16 - P_R médio mensal dos diferentes subsistemas fotovoltaicos de 100 kWp (adaptado de Chikh *et al.*, 2021).

A Figura 16 mostra que o P_R aumenta de setembro a março e depois diminui para as tecnologias de c-Si. Por outro lado, a tendência de P_R segue um padrão quase diferente para os subsistemas de CdTe e a-Si: aumenta nas estações quentes, depois se estabiliza após uma ligeira queda nos meses de outono e inverno e retoma sua tendência de alta no resto do ano. Apesar do fato de que a região considerada é caracterizada por um grande aumento de temperatura, não houve um efeito negativo pronunciado nos subsistemas fotovoltaicos, especialmente o da tecnologia de silício amorfo. A pequena queda no P_R em setembro e abril certamente se deve à indisponibilidade de alguns subsistemas fotovoltaicos, como os de m-Si e mc-Si (Chikh *et al.*, 2021).

O F_C do subsistema a-Si (Figura 17) aparece como o mais alto entre os outros subsistemas, variando entre 17,88% e 27,25%, com uma média de 22,11%. O F_C do subsistema CdTe está entre 17,67% e 24,50% com valor médio de 21,22%. O subsistema m-Si vem em terceiro lugar com um mínimo de 17,80%, um máximo de 23,48% e uma média de 20,51%. Alguns indicadores para os filmes finos são melhores, entretanto é preciso ressaltar algumas desvantagens da tecnologia, sendo que o mercado é dominado pelos módulos de silício cristalino. Os subsistemas mc-Si apresentam um F_C médio em torno de 19,00%. O valor médio do F_C dos quatro subsistemas é de 20,72%. O valor médio para os quatro subsistemas pode ser considerado aceitável para o desempenho dos sistemas fotovoltaicos em relação aos valores relatados na literatura. Os F_C considerados no trabalho estão com a potência c.c. do gerador (Chikh *et al.*, 2021).

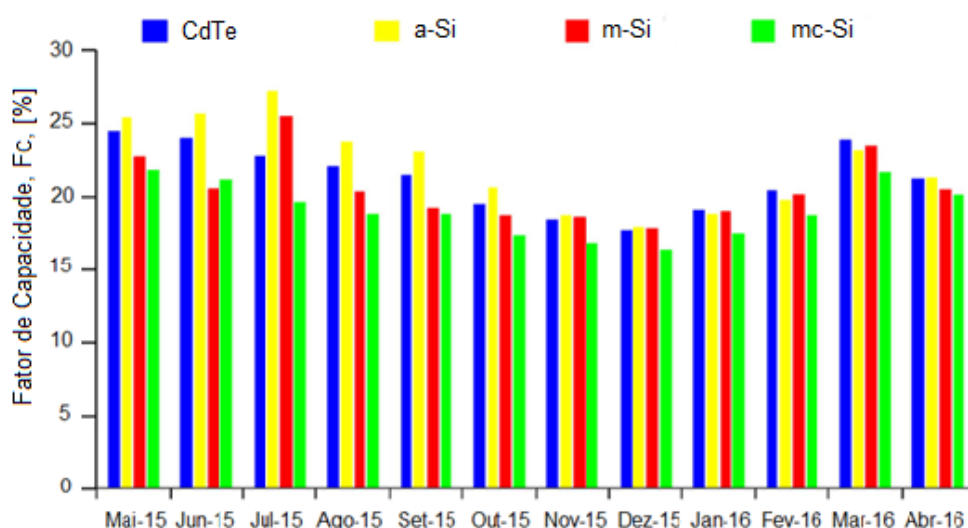


Figura 17 – F_C médio mensal dos diferentes subsistemas fotovoltaicos de 100 kWp utilizando a potência c.c. do gerador (adaptado de Chikh *et al.*, 2021).

A Tabela 10 apresenta um resumo atualizado dos indicadores de desempenho para alguns trabalhos importantes selecionados, conforme relatado na literatura científica.

Tabela 10 -Parâmetros de desempenho de SFVs em locais áridos e semiáridos
(Chikh *et al.*, 2021).

Localização	Referência	Tecnologia	Potência (kWp)	Y_F (kWh/kWp /ano)	P_R (%)	F_C (%)	Período de monitoramento (anos)
Espanha, Málaga	Piliougine, M. et al., 2013	mc-Si	0,195	1934,50	94,1	22,08	1
Marrocos, Er-Rachidia	Abdellatif Bouaichi, et al., 2019	mc-Si1	2,04	1941,80	82,5	22,16	3
		a-Si1	2,04	1938,15	82,2	22,12	3
Marrocos, Marraquexe	N. Aarich, et al., 2018	m-Si2	2,04	1927,20	81,6	22,00	3
		mc-Si2	2,04	1744,70	80,8	19,91	2,5
		a-Si2	1,86	1810,40	83,3	20,66	2,5
Burkina-Faso, Ouagadougou	K. Alain, 2016	m-Si	0,05		84		1
		mc-Si	0,05		84		1
		μ -Si	0,128		92		1
Kuwait, Multa	A. Hajjah, et al., 2012	mc-Si1	100	1861,00		21,24	3
Kuwait, Al Wafra	A. Hajjah, et al., 2012	mc-Si2	100	1922,70		21,94	3
Omã	H.A. Kazem, et al., 2014	mc-Si	1,4	1875,00	84,6	21,00	1
Abu Dhabi	Mahieddine Emziane, et al., 2015	m-Si1	114,4	1521,60	80	17,37	1
		m-Si2	50,4	1801,80	81	20,57	1
		mc-Si1	215,7	1325,30	70	15,13	1
		mc-Si2	994	1437,80		16,40	1
Irã, Rafsandjan	M. Mirzaei, et al., 2017	m-Si1	1,25	1702,14	89,4	19,40	1
		mc-Si1	1,25	1605,87	92,0	18,33	1
Irã, Kerman	S. Edalati, et al., 2015	m-Si2	5,52	1914,40	80,8	21,85	1
		mc-Si2	5,52	1965,10	82,9	22,43	1
Chile, Antofagasta	P. Ferrada, et al., 2015	μ -Si	3,36	1690,00	79,0	19,30	1
		m-Si	3,33	1760,00	78,0	20,10	1
Jordan, Zarqa	Bashar Hammad, et al., 2017	mc-Si	7,98	1959,00	85,0	22,36	1
Algeria, Ghardaia	Chikh et al., 2021	mc-Si	100	1659,00	78,0	19,03	1
		m-Si	100	1772,00	80,0	20,51	1
		a-Si	100	1933,00	85,0	22,11	1
		CdTe	100	1820,00	81,5	21,22	1

Na Tabela 10, os estudos realizados em climas áridos e semiáridos foram resumidos. São comparados os valores de P_R e F_C que indicam a eficiência das usinas estudadas operando sob diferentes condições climáticas para diferentes períodos de monitoramento.

Chikh *et al.* (2021) concluíram que a tecnologia fotovoltaica de filmes finos aparenta ser muito promissora para uma grande implementação nas regiões do país caracterizadas por climas áridos e que são envolvidas pelo programa de desenvolvimento de energia renovável da Argélia. Apesar dos resultados do presente estudo, investigações complementares devem ser realizadas, especialmente aquelas relacionadas à degradação devido aos efeitos do envelhecimento dos módulos fotovoltaicos. Seria importante, também, avaliar o efeito de vendavais, de areia e de poeira no desempenho de módulos fotovoltaicos que poderia induzir perdas de produção de energia superiores a 21%.

4 METODOLOGIA

Esta seção faz referência ao desenvolvimento da metodologia de previsão de geração fotovoltaica (RRRa) por meio das plataformas de previsão do tempo *Ventusky* e *Open Weather*. A aplicação e validação do método RRRa no SFCR do IFSC foi por meio da plataforma de previsão do tempo *Ventusky* e através das análises de índice de desempenho do sistema de geração fotovoltaica localizado no IFSC.

4.1 SISTEMAS FOTOVOLTAICOS DE GERAÇÃO DISTRIBUÍDA

Os SFGDs utilizados no âmbito deste trabalho se encontram na UFSC, Campus Araranguá, e no IFSC, Campus Criciúma – SC.

4.1.1 SFGD da Universidade Federal de Santa Catarina – UFSC, Araranguá – SC

O sistema fotovoltaico de referência (SFVr) no desenvolvimento do método está instalado na UFSC – Campus Araranguá. O SFVr é composto por 3 módulos fotovoltaicos de modelo 330PHK-36 do fabricante *Build Your Dreams* (BYD) com potência nominal individual de 330 Wp e 1 inversor de modelo PHB1500-NS do fabricante PHB Solar com potência nominal de 1,5 kW. A potência do sistema é de 0,99 kWp.

O arranjo fotovoltaico está instalado no telhado da planta piloto bioclimática, localizada no Centro de Ciências, Tecnologias e Saúde (CTS) da Universidade Federal de Santa Catarina (UFSC), no município de Araranguá – SC, apresentado e destacado na Figura 18. Os dados do sistema estão apresentados na Tabela 11.

Tabela 11– Especificações do Sistema Fotovoltaico da UFSC – Campus Araranguá – SC.

Potência nominal do sistema	0,99 kWp
Arranjo fotovoltaico	1 <i>string</i> - 3 módulos
Ângulo de inclinação	20°
Desvio azimutal (orientação dos módulos)	0° N
Fabricante dos módulos/modelo	BYD/330PHK-36
Potência unitária dos módulos	330 Wp
Inversor	1x PHB1500-NS
Potência nominal do inversor	1,5 kW



Figura 18 – SFVr da UFSC – Campus Araranguá – SC.

4.1.2 SFGD do Instituto Federal de Santa Catarina – IFSC, Criciúma-SC

O sistema fotovoltaico total (SFV_T) do IFSC é composto por 229 módulos fotovoltaicos de modelo CS6K do fabricante *Canadian Solar* com potência nominal individual de 320 Wp e 5 inversores de modelo *Symo 15.0-3-M* do fabricante *Fronius* com potências nominais de 15 kW. A potência total de geração do SFV_T é de 73,28 kWp. Os arranjos fotovoltaicos estão dispostos em três blocos do campus Criciúma–SC (latitude 28,40° S, longitude 49,19° W e 47 m acima do nível do mar). O SFV_T conectado à rede está dividido em 5 subsistemas (Sub 1, Sub 2, Sub 3, Sub 4 e Sub 5).

As orientações geográficas dos módulos fotovoltaicos no SFGD são norte, oeste e leste, conforme apresentado na Figura 19. Os módulos estão instalados na cobertura das edificações e acompanham um ângulo de inclinação de 10° e um ângulo de desvio azimutal de -9° em relação ao norte para o Sub 1 e o Sub 2. As especificações dos inversores *Symo 15.0-3-M* estão apresentadas na Tabela 12. Os parâmetros elétricos dos módulos fotovoltaicos CS6K com potência nominal de 320 W estão apresentados na Tabela 13.

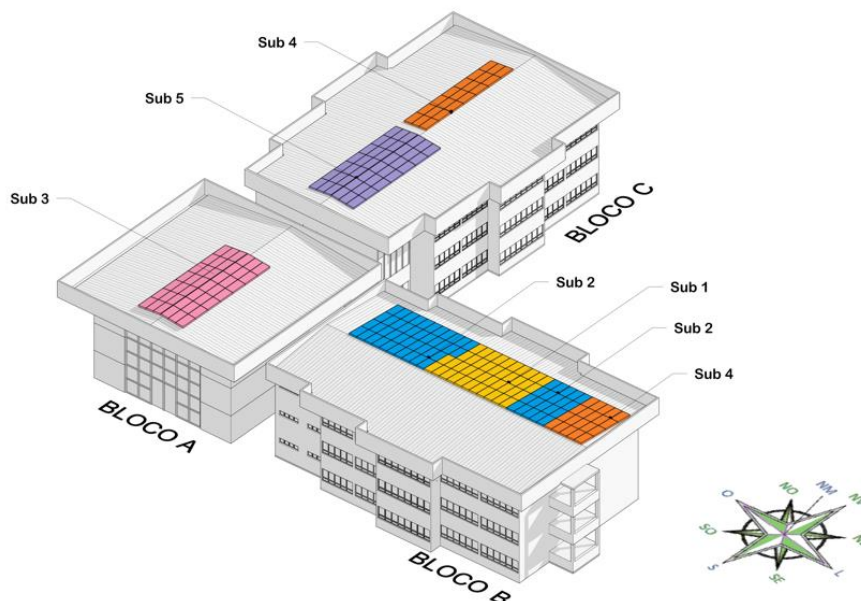


Figura 19 – Sistema de geração no telhado dos 3 blocos.

Tabela 12 – Especificações dos inversores.

DADOS DOS INVERSORES	
Potência nominal [kW]	15,0
Faixa de tensão de operação [V]	3-NPE 220/127
Corrente nominal [A]	41,6
Fator de potência	> 0.99 ind/cap
Rendimento [%]	98,1
Frequência de operação [Hz]	60
Máxima tensão de saída [V]	270
Distorção máxima [%]	< 3
Grau de proteção	IP - 54
Topologia	<i>Transformeless</i>
Resfriamento	Ventilação forçada
Comunicação	Wi-fi
Fabricante/Modelo	<i>Fronius/SYMO</i>

Tabela 13 – Parâmetros elétricos do módulo fotovoltaico CS6K nas condições STC.

CANADIAN 320 W - STC	
P_{MAX} (W)	320,00
V_{OC} (V)	45,30
I_{SC} (A)	9,26
I_{MP} (A)	8,69
V_{MP} (V)	36,80
η (%)	16,68

A distribuição das conexões dos módulos (*strings*) e da ligação com os inversores está apresentada na Tabela 14. Os fatores de dimensionamento do inversor (FDIs) dos subsistemas também estão apresentados nessa tabela. Percebe-se que o Sub 3 e o Sub 5 são subsistemas idênticos, com a mesma inclinação e orientação e com o mesmo FDI. Os subsistemas Sub 1 e Sub 2 possuem a mesma inclinação e a mesma orientação. Os FDI do Sub 1 e do Sub 2 são diferentes, o subsistema Sub 1 possui um FDI de 1,12 enquanto o subsistema Sub 2 tem FDI de 0,76. O subsistema Sub 4 é composto por duas orientações diferentes, oeste e com um desvio azimutal de -9° norte.

Tabela 14 – Distribuição das *strings* nos inversores.

INVERSORES	MÓDULOS	STRINGS	POTÊNCIA (kWp)	FDI
Inversor 1	42	2 x 21 módulos	13,44	1,12
Inversor 2	62	2 x 21 + 1 x 20 módulos	19,84	0,76
Inversor 3	42	2 x 21 módulos	13,44	1,12
Inversor 4	41	1 x 21 + 1 x 20 módulos	13,12	1,14
Inversor 5	42	2 x 21 módulos	13,44	1,12
Total	229		73,28	1,02

O monitoramento on-line do sistema é disponibilizado pelo fabricante do inversor (*Fronius*). As principais grandezas relacionadas ao sistema de geração podem ser visualizadas e acompanhadas e relatórios podem ser emitidos. O sistema pode ser monitorado pelo acesso do site *SolarWeb.com*.

A instalação do sistema fotovoltaico de geração distribuída no campus do IFSC – Criciúma - SC foi entregue em setembro de 2017. Os relatórios dos dados sobre o sistema de geração já estão disponíveis no sistema on-line desde o mês de outubro de 2017. Para a realização das análises, foram emitidos relatórios detalhados mensais do período de janeiro de 2018 a dezembro de 2023, totalizando 6 anos, minimizando efeitos que podem ocorrer em períodos atípicos entre um ano e outro.

4.2 MÉTODO RRRa DE PREDIÇÃO DE GERAÇÃO FOTOVOLTAICA

4.2.1 Metodologia RRRa da predição de geração fotovoltaica

A metodologia proposta se baseia em uma relação com uma plataforma de previsão do tempo meteorológica junto com os dados de geração fotovoltaica do local em

que se deseja realizar a predição. O método foi desenvolvido no SFGD da UFSC, Campus Araranguá.

A metodologia RRRa desenvolvida prevê a geração fotovoltaica futura em um HRT de curto e médio prazos. O HRT de curto prazo considerou a predição de 1h até 10h futuras (diárias). O HRT de médio prazo considerou a predição de 24h futuras (dia seguinte) e 72h futuras (3 dias seguintes). A aplicação da RRRa é simples e precisa somente de duas buscas/entradas. A primeira entrada é dos dados de previsão do tempo da plataforma de previsão de tempo e a segunda é de um valor padrão final de predição para cada previsão do tempo (PF) que foi obtido por meio de dados históricos reais de geração fotovoltaica no local em que se deseja efetuar a predição da energia solar fotovoltaica.

Por meio do PF obtido com os dados históricos e junto com uma plataforma de rede meteorológica de previsão do tempo, consegue-se prever a geração futura para a região em que o sistema fotovoltaico está instalado para cada tipo de previsão do tempo disponibilizada na plataforma. O primeiro passo para realizar a predição de geração fotovoltaica se dá por meio da obtenção do valor do PF para cada mês do ano e para cada previsão do tempo de uma determinada plataforma de busca. Para a aplicação da metodologia, a principal plataforma utilizada de previsão do tempo é a *Ventusky*. A plataforma *Open Weather* foi utilizada como um comparativo da plataforma *Ventusky* para avaliar o impacto de diferentes plataformas de previsão do tempo no método desenvolvido.

4.2.1.1 Plataformas de busca das previsões do tempo

Os dados de previsão do tempo foram extraídos de maneiras diferentes. Na plataforma *Ventusky*, os dados de previsão são extraídos diariamente para o dia e para os três dias futuros. Na plataforma *Open Weather*, os dados de previsão foram extraídos diariamente somente para o dia.

4.2.1.1.1 Plataforma *Ventusky*

A plataforma *Ventusky* foi desenvolvida na empresa *InMeteo*. Na plataforma *Ventusky*, as previsões do tempo são extraídas todos os dias. No dia de busca, a previsão é extraída no horário das 06:00h até as 18:00h. Para os três dias futuros, a previsão é

extraída a cada três horas (06:00h, 09:00h, 12:00h, 15:00h e 18:00h) devido à plataforma não disponibilizar os dados horários. Para o HRT = 1 h até 10 h, as previsões horárias foram realizadas no período das 08:00h até as 18:00h. Para o HRT = 24 h e HRT = 72 h, as previsões horárias foram realizadas nos intervalos das 09:00h–10:00h, 12:00h–13:00h e 15:00h–16:00h. Os intervalos entre 06:00h–07:00h e 18:00h–19:00h para os HRT = 24h e HRT = 72h foram desconsiderados. Nesses intervalos, a irradiação é baixa e energeticamente é insignificativa. A Figura 20 apresenta a legenda para as previsões do tempo na plataforma *Ventusky*.



Figura 20 – Legenda adaptada da plataforma *Ventusky*.

4.2.1.1.2 Plataforma *Open Weather*

A *Open Weather* é composta por uma equipe de especialistas em tecnologia da informação e cientistas de dados que pratica ciência de dados meteorológicos profundos. Para cada ponto do globo terrestre, o *Open Weather* fornece dados meteorológicos históricos, atuais e previstos. A sede da empresa fica na cidade de Londres, no Reino Unido. A plataforma apresenta os percentuais de probabilidade de chuva, temperatura e velocidade do vento. A Figura 21 apresenta um dia ensolarado (céu limpo) com o

percentual de probabilidade de chuva para cada horário. Além disso, a plataforma também apresenta o perfil da curva de temperatura durante os intervalos horários.

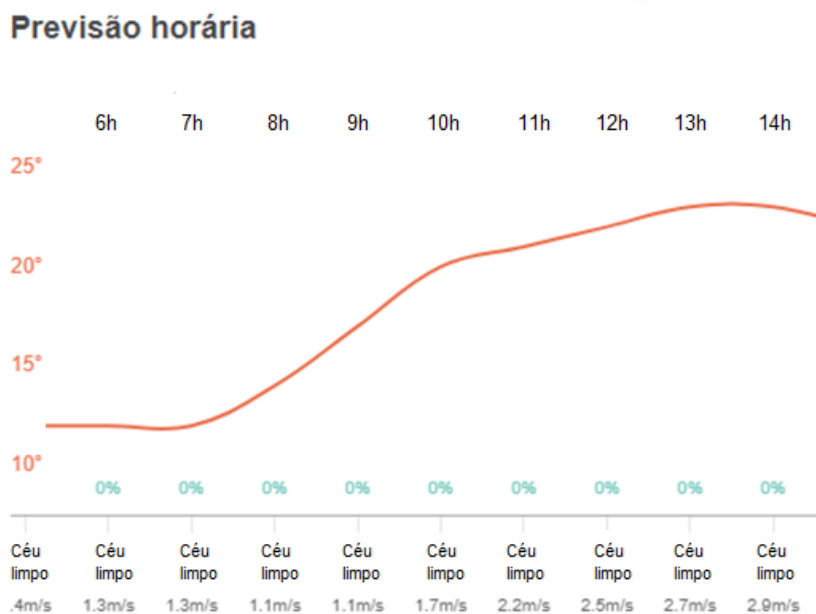


Figura 21 – Legenda adaptada da plataforma *Open Weather*.

4.2.1.2 Obtenção do valor padrão final de predição para diferentes previsões do tempo utilizando a plataforma *Ventusky*

A partir das curvas de geração do SFVr (Figura 22) e das previsões do tempo obtidas por meio da plataforma *Ventusky*, um valor padrão final (PF) de predição fotovoltaica foi obtido para cada intervalo (horário) entre 6h até 18h. O valor horário do PF também foi obtido para cada mês do ano. O primeiro valor PF de predição encontrado foi para todos os meses do ano com a previsão de dias ensolarados (céu limpo). Os outros valores de PF com previsões de dias diferentes foram obtidos da mesma maneira dos dias ensolarados. A partir da curva de geração fotovoltaica para dias ensolarados de cada mês do ano, a geração foi integrada para cada intervalo horário, incluindo das 6h até as 18h. As curvas de geração fotovoltaica para as previsões de chuvas e trovoadas não foram obtidas devido ao fato de não se ter um dia completo com essa previsão no período analisado.

As previsões realizadas foram no período de março de 2022 até fevereiro de 2024. No primeiro ano, no período de março de 2022 até fevereiro de 2023, as previsões foram realizadas utilizando os valores de PF do ano anterior (2021). No segundo ano, no

período de março de 2023 até fevereiro de 2024, as previsões foram realizadas utilizando valores de PF de dois anos anteriores (2021 e 2022). No segundo ano de previsão, a amostragem de valores de PF foi maior para cada previsão do tempo.

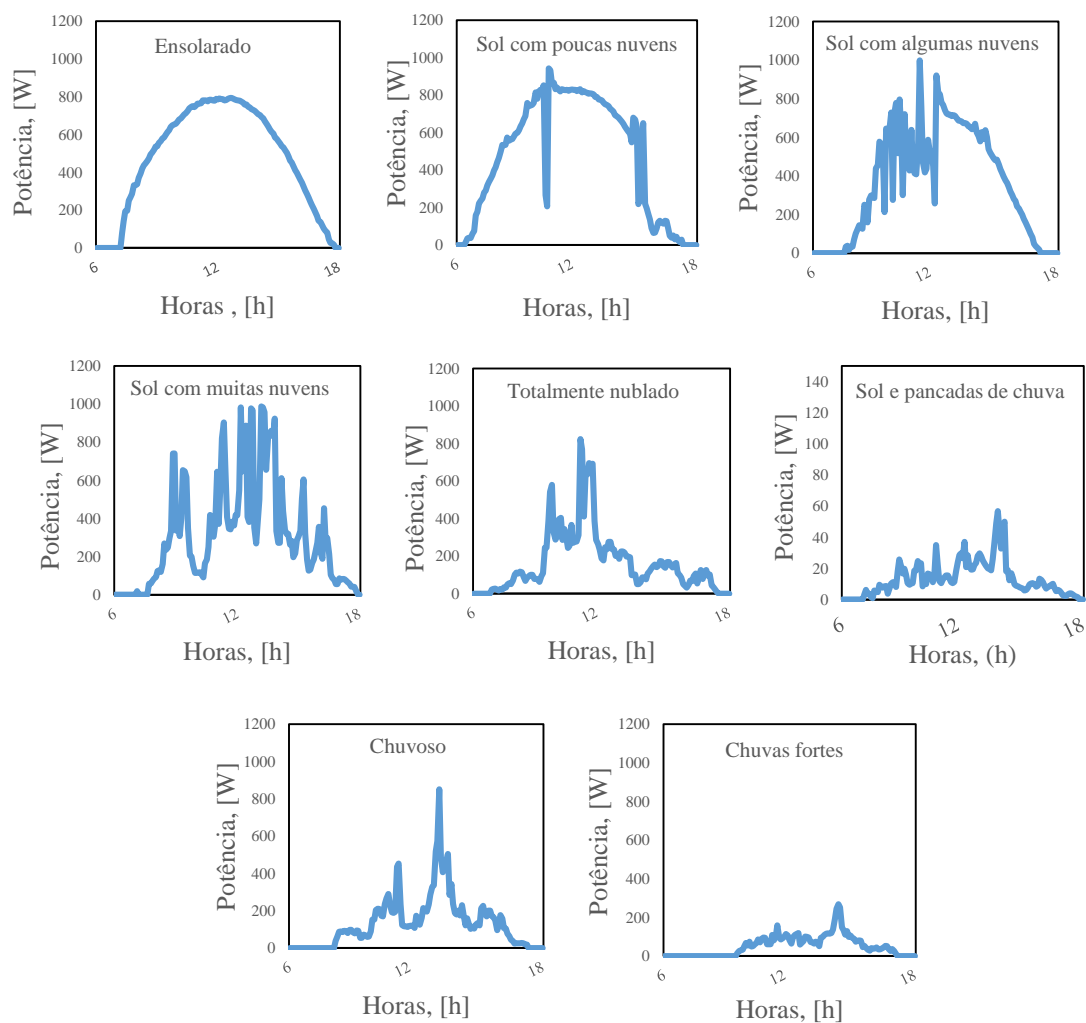


Figura 22 – Curvas de Potência Fotovoltaica do Sistema Fotovoltaico da UFSC, Araranguá.

A Figura 23 apresenta o diagrama representativo dos passos para se obter o valor do PF de previsão.

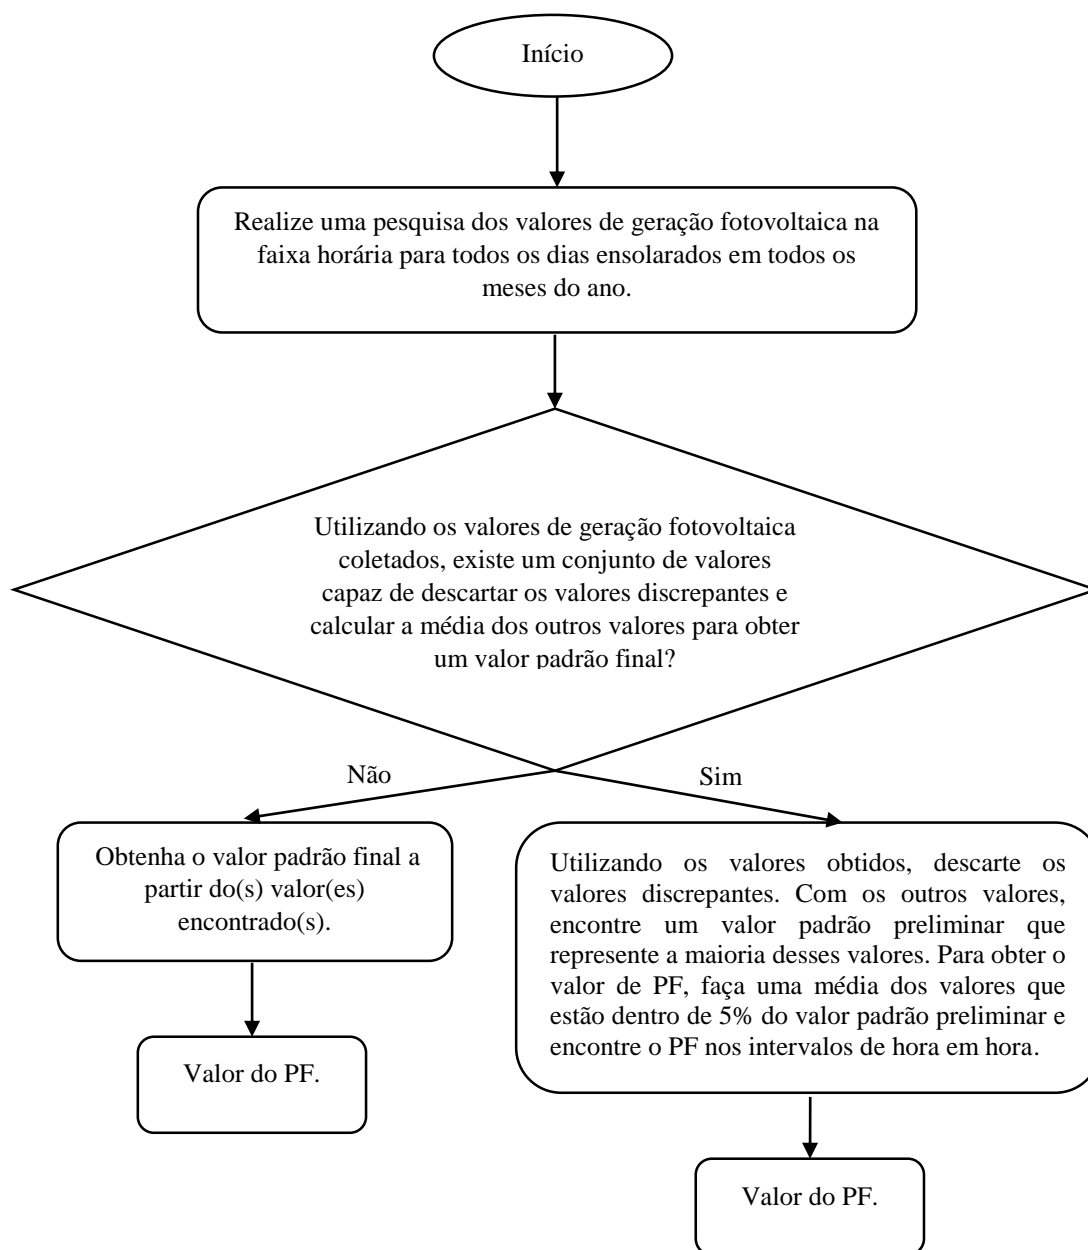


Figura 23 - Fluxograma para obtenção do valor padrão final de predição para cada mês do ano e para cada previsão do tempo.

4.2.1.3 Levantamento dos perfis utilizados para realizar a predição de geração RRRa utilizando as plataformas *Ventusky* e *OpenWeather*

Devido às plataformas de previsão do tempo possuírem uma legenda muito ampla para cada tipo de dia, foram divididos em três perfis os tipos de previsões do tempo das plataformas *Ventusky* e *OpenWeather* (Tabela 15).

Tabela 15 – Perfis de previsões do tempo obtidos das plataformas *Ventusky* e *OpenWeather*.

PERFIS	TIPOS DE PREVISÕES VENTUSKY
Ensolarado	ensolarado, sol com poucas nuvens, sol com algumas nuvens e sol e cirrus
Intermediário	sol com muitas nuvens, sol e pancadas de chuva e totalmente nublado
Chuvoso	chuvoso, chuvas e trovoadas e chuvas fortes
PERFIS	TIPOS DE PREVISÕES OPENWEATHER
Ensolarado	céu limpo, poucas nuvens e nuvens dispersas
Intermediário	nuvens encobertas e nuvens separadas (partidas)
Chuvoso	chuva leve, chuva moderada e chuva forte

Por meio dos perfis apresentados na Tabela 15, foi obtido o padrão final de perfil (\overline{PFP}) para cada perfil (Ensolarado, Intermediário e Chuvoso). Entretanto, por meio do (\overline{PFP}), obtêm-se as previsões de geração fotovoltaica para cada perfil. O (\overline{PFP}) é obtido através da Equação (4.1), realizando uma média dos PFs dos tipos de previsões de cada perfil. As previsões de geração fotovoltaica para a cidade de Araranguá-SC foram realizadas por meio de cada perfil, utilizando as plataformas *Ventusky* e *OpenWeather*.

$$\overline{PFP} = \frac{1}{n} \sum_{i=1}^n PFi \quad (4.1)$$

Após determinar o valor médio do padrão final de perfil (\overline{PFP}) no local do sistema fotovoltaico onde foi aplicada a metodologia RRRa, o (\overline{PFP}) pode ser correlacionado com a produtividade do sistema (Y_F) para obter a previsão em outras regiões geográficas.

O primeiro passo é encontrar o valor do padrão final de perfil do sistema fotovoltaico (\overline{PFP}_{PVS}) que será utilizado para a previsão fotovoltaica no outro local. O valor de (\overline{PFP}_{PVS}) é determinado utilizando o valor da média do perfil padrão final do sistema fotovoltaico no qual o método foi implementado (\overline{PFP}_{PSD}) e a potência de ambos os sistemas fotovoltaicos Equação (4.2).

$$\overline{PFP}_{PVS} = \frac{\overline{PFP}_{PSD} \cdot P_{\text{fotovoltaic PVS}}}{P_{\text{fotovoltaic PSD}}} \quad (4.2)$$

O segundo passo é usar o Y_F do ano anterior do local onde o método foi desenvolvido no mês para o qual a predição deve ser determinada. Com o Y_F do ano anterior e o Y_F do local em que se deseja determinar a predição, determina-se o (\overline{PFP}_{PVS}) para o sistema fotovoltaico do local a ser prevista a geração fotovoltaica (Equação 4.3).

$$\overline{PFP}_{PVS} = \frac{\overline{PFP}_{PVS} \cdot Y_F(PVS)}{Y_F(PSD)} \quad (4.3)$$

O (\overline{PFP}_{PVS}) pode ser determinado para intervalos horários de cada mês e para cada perfil de dados meteorológicos.

4.2.2 Horizonte de Resolução Temporal

Os principais fatores que afetam o desempenho na predição de geração fotovoltaica são o horizonte de tempo, a resolução de tempo, as condições climáticas, a localização geográfica, a disponibilidade e a qualidade dos dados (Nespoli *et al.*, 2019).

O horizonte de resolução temporal (HRT) que foi utilizado no trabalho é de predição de prazos curto e médio. O horizonte de prazo curto pode variar de 1 minuto até 24 horas. O horizonte de prazo médio pode variar de 24 horas até 1 semana. No presente estudo, está sendo adotado um horizonte de predição do dia (1h até 10h futuras) de 24h e 72h futuras para a plataforma *Ventusky*. O método desenvolvido teve como base a plataforma *Ventusky* e a plataforma *Open Weather* foi usada para se comparar as duas. As predições para a *Open Weather* são realizadas apenas no horizonte de prazo curto (1h até 10h) devido ao fato de serem extraídas somente para o dia.

4.2.3 Métricas estatísticas para avaliação do desempenho do método proposto

Segundo Barbieri *et al.* (2017), o desempenho de um modelo de previsão é frequentemente avaliado por raiz do erro médio quadrático (RMSE), erro médio quadrático normalizado (nRMSE) ou erro médio quadrático relativo (rRMSE), erro médio absoluto (MAE) ou erro médio de polarização (MBE), entre outros meios.

A Agência Internacional de Energia (IEA, 2013) afirma que as principais métricas utilizadas são raiz do erro médio quadrático (RMSE), erro médio absoluto (MAE) e erro médio (MBE). Cada métrica possui suas características particulares que

podem determinar com maior ou melhor qualidade os erros. Gueymard (2014) realizou uma revisão detalhada sobre as principais métricas estatísticas utilizadas para previsões de radiação solar. As métricas utilizadas no trabalho são apresentadas nas equações (4.4), (4.5) e (4.6).

$$RMSE [\%] = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (GR - GP)^2}}{\overline{GR}} \cdot 100 \quad (4.4)$$

$$MAE [\%] = \frac{\frac{1}{N} \sum_{i=1}^N |GR - GP|}{\overline{GR}} \cdot 100 \quad (4.5)$$

$$MAPE [\%] = \frac{1}{N} \sum_{i=1}^N \left| \frac{GR - GP}{GR} \right| \cdot 100 \quad (4.6)$$

em que:

GR = geração real do SFV;

GP = geração predita do SFV;

\overline{GR} = geração real média do SFV.

Os erros utilizados no trabalho foram calculados em percentuais. O RMSE, o MAE e o MAPE foram obtidos em intervalos horários das 8 h até 18 h para os três perfis com o HRT = 1h até 10h, utilizando as plataformas *Ventusky* e *OpenWeather*. Para os HRT = 24h e HRT = 72h, RMSE, MAE e MAPE foram obtidos em intervalos horários das 9h-10h, 12-13h e 15-16h para os três perfis, utilizando as plataformas *Ventusky* e *OpenWeather*.

Foram obtidos erros médios anuais para os três perfis, utilizando RMSE, MAE e MAPE. O erro médio mensal foi obtido utilizando RMSE, MAE e MAPE para todos os meses do intervalo analisado.

4.3 ANÁLISE DO DESEMPENHO ENERGÉTICO DO SFCR DO IFSC

Os índices de mérito técnico de um SFCR representam índices de energia, eficiência do sistema, produtividade, desempenho e perdas. O desempenho energético dos subsistemas de geração do IFSC é avaliado por meio da produtividade do sistema fotovoltaico (Y_F). A Y_F é o índice de produtividade do sistema calculado pela divisão da

energia elétrica em corrente alternada (c.a.) pela potência nominal instalada do sistema fotovoltaico. Esse índice representa qual a produção em um período considerado em kWh para cada kWp instalado. Esse parâmetro também indica o número de horas que o sistema deveria operar, em sua potência nominal, para fornecer a mesma energia. Esse índice normaliza a energia produzida em relação ao tamanho do sistema, conseqüentemente, é uma maneira conveniente de comparar a energia produzida por sistemas fotovoltaicos de tamanhos diferentes. A Equação 4.7 representa Y_F :

$$Y_F = \frac{\int_0^T P_{CA}(t)dt}{P_{STD}} \quad (4.7)$$

em que:

P_{CA} é a potência elétrica entregue à rede no instante t [kW];

P_{STD} é a potência do sistema na condição padrão [kWp];

T = período de integração.

A equação 4.1 pode ser simplificada tornando-se a equação 4.8:

$$Y_F = \frac{\text{Energia gerada [kWh]}}{\text{Potência nominal [kWp]}} \quad (4.8)$$

5 RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos a partir do desenvolvimento do método no SFV_r da UFSC e da aplicação e validação no Sub 1 e no Sub 5 do SFV_T do IFSC, bem como as discussões relevantes acerca deles.

5.1 PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV_r) UTILIZANDO A PLATAFORMA *VENTUSKY* NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2023

5.1.1 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h

A Tabela 16 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso. O método RRRa apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

O perfil ensolarado apresentou menores RMSE, MAE e MAPE em relação aos três perfis. O perfil ensolarado possui a característica de não variar a radiação solar em um curto período de tempo. O RMSE para o método RRRa foi de 20,2% a 28,4%. O MP apresentou valores de RMSE entre 36,8% e 57,7%. No perfil ensolarado, os horários com maiores valores de radiação solar apresentaram RMSE, MAE e MAPE menores. Os menores erros foram entre os intervalos 9-10h até 13-14h.

O perfil intermediário apresentou maiores RMSE, MAE e MAPE em relação aos três perfis. É o perfil que possui maior desafio em relação à precisão das predições fotovoltaicas. É o mais desafiador devido ao aumento de circulações de nuvens. O RMSE para o método RRRa foi de 45,0% a 63,5%. O MP apresentou valores de RMSE entre 76,6% e 95,6%. O menor RMSE foi entre 16h e 17h. O MAE e o MAPE seguiram o mesmo perfil que o RMSE, mantendo valores menores para o método RRRa quando comparado com o MP.

O perfil chuvoso apresentou valores de RMSE entre os valores obtidos nos perfis ensolarado e intermediário na maioria dos intervalos. Nos intervalos das 11-12h, 14-15h e 15-16h, o perfil chuvoso apresentou menores RMSE que o perfil ensolarado. O RMSE para o método RRRa foi de 21,5% a 154,8%. O MP apresentou valores de RMSE entre

114,7% e 263,5%. O menor RMSE foi entre 11h e 12h. O MAE e o MAPE seguiram o mesmo perfil que o RMSE, mantendo valores menores para o método RRRa quando comparado com o MP.

Tabela 16 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h, utilizando os métodos RRRa e MP para o primeiro ano de predição.

	8-9h	9-10h	10-11h	11-12h	12-13h	13-14h	14-15h	15-16h	16-17h	17-18h
RMSE [%] - ENSOLARADO										
RRRa - SFVr	25,9	22,8	20,8	23,3	20,2	23,7	25,5	26,7	27,8	28,4
MP - SFVr	41,9	42,7	36,8	38,2	38,7	37,0	40,1	41,6	50,6	57,7
MAE [%] - ENSOLARADO										
RRRa - SFVr	14,9	13,2	12,1	12,7	10,9	13,7	14,0	15,6	17,2	20,4
MP - SFVr	28,8	28,7	24,7	26,0	25,8	23,6	26,0	26,3	34,5	36,9
MAPE [%] - ENSOLARADO										
RRRa - SFVr	46,1	25,6	20,3	24,9	19,6	24,0	38,3	36,4	38,3	33,6
MP - SFVr	68,0	71,0	29,8	30,2	31,5	27,0	45,9	44,1	51,6	48,9
RMSE [%] - INTERMEDIÁRIO										
RRRa - SFVr	49,0	50,7	62,9	57,6	58,8	56,5	63,5	56,4	45,0	50,1
MP - SFVr	85,1	85,9	86,1	80,4	79,5	95,6	91,1	81,0	82,7	76,6
MAE [%] - INTERMEDIÁRIO										
RRRa - SFVr	34,8	40,6	47,0	43,5	42,0	39,9	45,5	41,7	35,4	32,0
MP - SFVr	81,1	75,7	68,9	63,6	70,0	80,2	73,1	67,6	69,8	52,5
MAPE [%] - INTERMEDIÁRIO										
RRRa - SFVr	48,1	44,2	51,8	57,6	55,0	43,6	76,6	67,9	67,5	84,4
MP - SFVr	120,3	113,7	105,8	95,1	136,1	120,3	129,9	110,0	260,3	128,5
RMSE [%] - CHUVOSO										
RRRa - SFVr	33,9	33,8	31,7	21,5	63,1	51,9	21,9	18,8	86,9	154,8
MP - SFVr	123,1	168,1	172,3	128,9	119,8	126,7	114,7	128,4	263,5	177,4
MAE [%] - CHUVOSO										
RRRa - SFVr	21,4	21,7	18,7	12,0	32,1	24,8	13,3	10,8	53,2	75,9
MP - SFVr	102,3	383,9	133,7	102,6	82,9	105,8	87,6	110,2	211,2	144,1
MAPE [%] - CHUVOSO										
RRRa - SFVr	32,6	37,3	27,6	16,8	30,8	23,6	27,0	17,0	170,3	241,8
MP - SFVr	144,0	167,8	183,7	134,2	137,4	243,3	187,7	274,7	306,4	375,5

O método RRRa apresentou maiores erros no intervalo entre 17h e 18h nos perfis ensolarado e chuvoso. Esses erros não possuem um impacto energeticamente considerável devido a esse intervalo possuir uma baixa irradiação. No perfil intermediário, os erros nos intervalos horários de menores irradiações tiveram valores próximos aos dos outros intervalos. O método RRRa se mostrou um modelo mais eficaz e preciso para os perfis ensolarado e chuvoso.

O desempenho de predição da geração fotovoltaica dos métodos RRRa e MP, em diferentes estações do ano, também está apresentado na Figura 24. O horizonte

considerado para esta análise foi apenas para $HRT = 1h$ a $10h$. Foram analisados sete dias consecutivos para cada estação do ano. Entre esses dias, estão inseridos todos os três perfis de previsão do tempo. A previsão utilizando o método RRRa foi comparada com o método MP em relação à geração fotovoltaica real (GR). Os gráficos de desempenho mostram, visualmente, que o RRRa obteve um desempenho melhor que o MP em todas as estações do ano.

Na estação do verão, o método RRRa teve um bom desempenho durante os sete dias consecutivos. O método MP apresentou um desempenho inferior ao método RRRa em comparação com a GR. Na estação do outono, o método RRRa teve um bom desempenho nos primeiros três dias, bem como no sexto e sétimo dias. No quarto e no quinto dia, o desempenho do método RRRa diminuiu devido à plataforma *Ventusky* ser menos precisa nesses dias. O método MP obteve um pior desempenho em comparação com o RRRa em relação à GR.

Na estação inverno, o método RRRa apresentou um desempenho inferior no segundo, terceiro, quarto, quinto e sexto dias. No primeiro e no sétimo dia, o método RRRa teve um melhor desempenho. Durante o inverno, os dias consecutivos selecionados apresentaram uma instabilidade considerável, o que colocou desafios à previsão fotovoltaica. Na primavera, o método RRRa teve um bom desempenho no primeiro, segundo, quinto, sexto e sétimo dias. No terceiro e quarto dias, o método RRRa apresentou um desempenho menor. O método MP teve um desempenho pior em comparação com o RRRa no primeiro, segundo e quarto dias. A previsão fotovoltaica utilizando os dois métodos apresenta uma incerteza mais significativa nos dias com perfis intermédios e chuvosos em todas as estações do ano, devido estes perfis apresentarem instabilidades maiores na previsão do tempo e uma maior circulação de nuvens.

A Figura 25 mostra que a previsão RRRa obteve uma amplitude menor quando comparada com a geração real do SFVr e com a previsão do MP para os perfis ensolarado, intermediário e chuvoso. No perfil ensolarado, a amplitude menor é devido aos valores (\overline{PFP}) serem próximos ao longo do ano para cada intervalo horário. O RRRa apresentou uma menor variação horária anual de previsão quando comparado com o MP. O RRRa mostrou uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP nos três perfis.

Para o perfil intermediário (Figura 25), o método RRRa apresentou uma menor variação horária anual de previsão quando comparado com o MP e uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP. No perfil

chuvoso (Figura 24), o método RRRa também apresentou uma menor variação horária anual de predição quando comparado com o MP. O RRRa apresentou uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP.

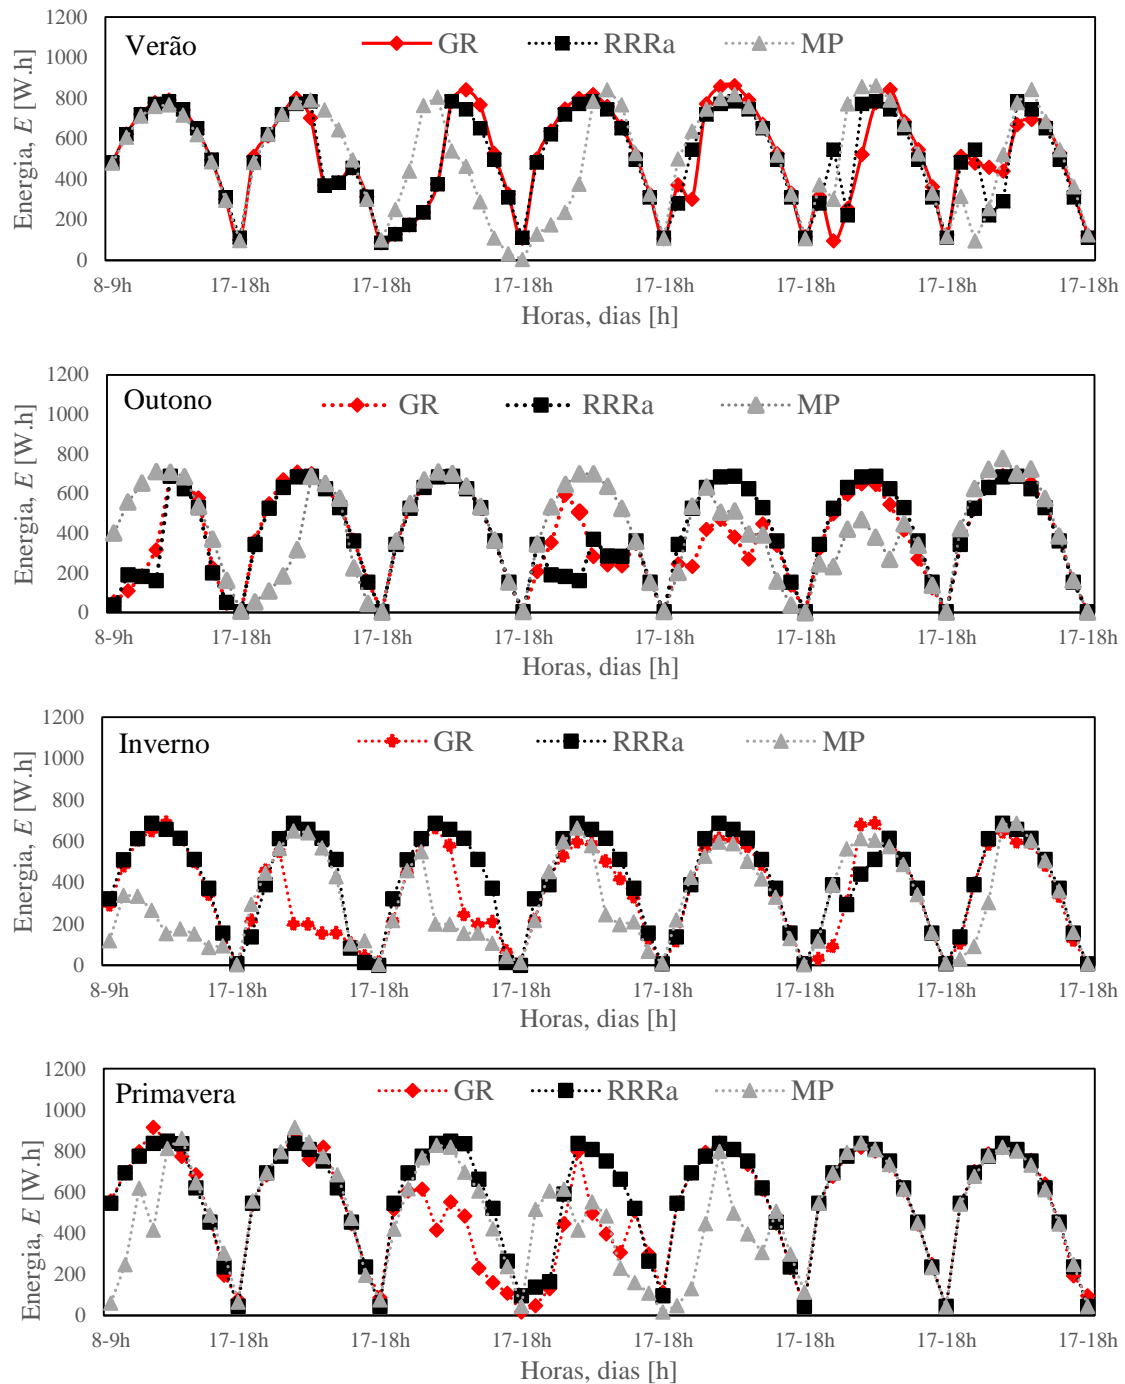


Figura 24 - Gráfico de predições RRRa e MP com a GR de 7 dias para as quatro estações do ano utilizando a plataforma *Ventusky*.

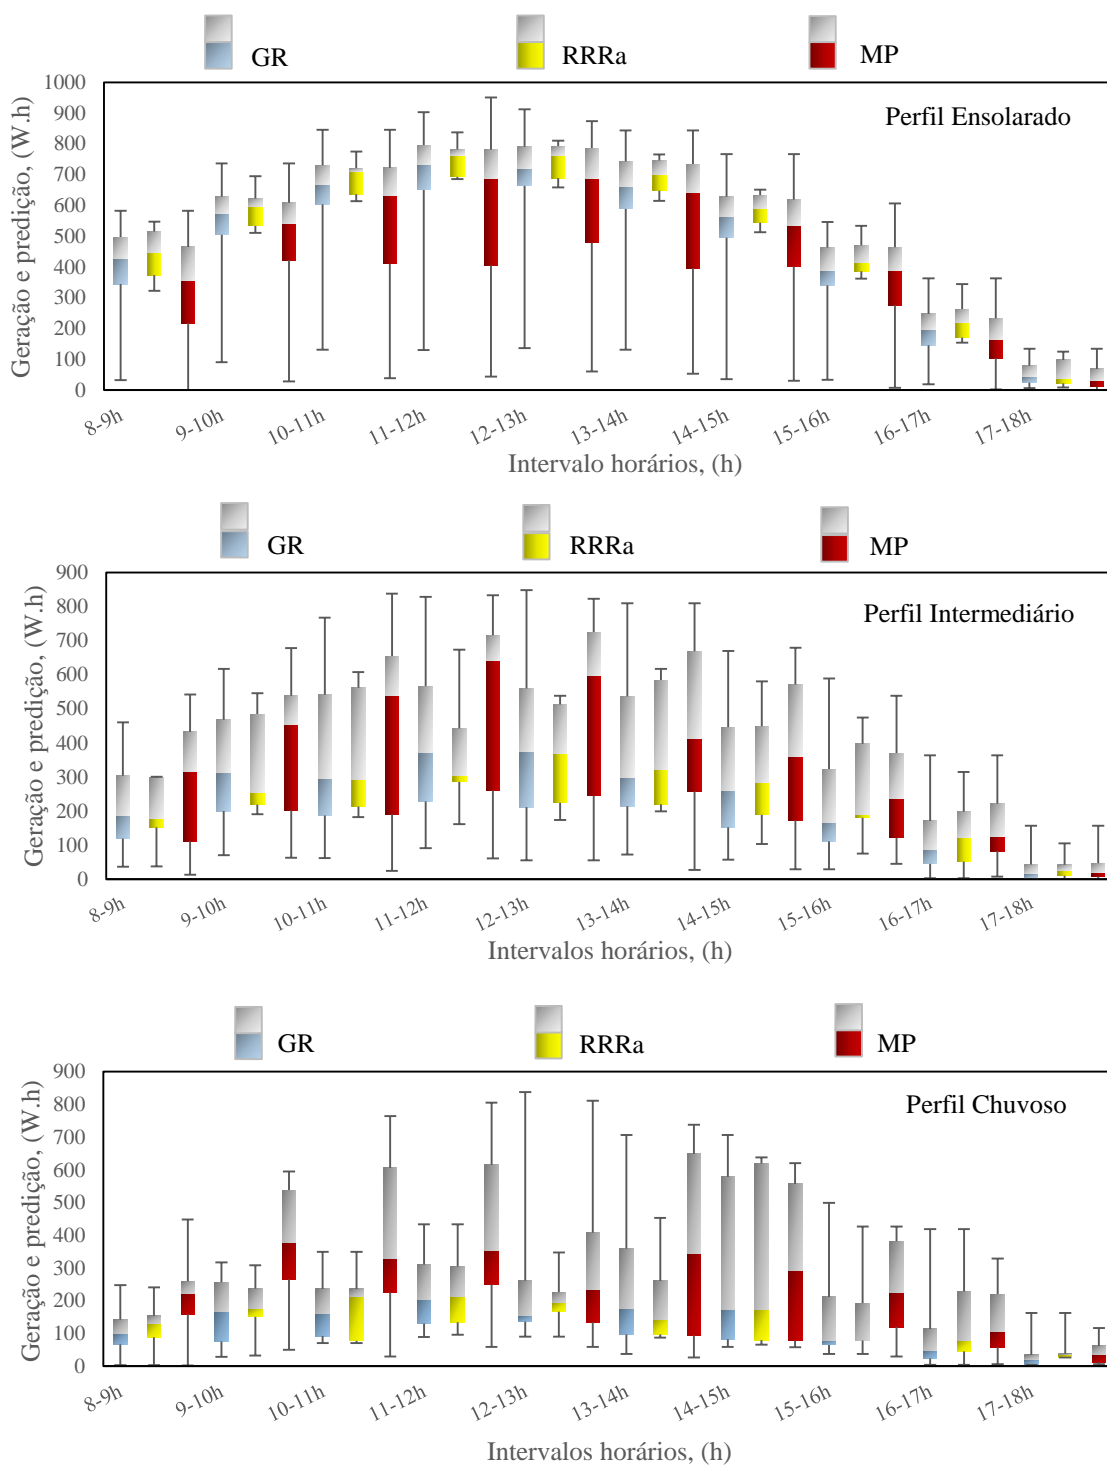


Figura 25 - Box Plot da geração e previsões utilizando a plataforma *Ventusky* dos meses de março de 2022 até fevereiro de 2023 para um HRT = 1h até 10h.

5.1.2 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h

A Tabela 17 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das 9h-10h, 12-13h e 15-16h. Para o HRT = 24h, o método RRRa também apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

O perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos 3 perfis. O RMSE para o método RRRa foi de 21,1% a 26,8%. O MP apresentou valores de RMSE entre 38,8% e 40,1%. O perfil intermediário apresentou maiores RMSE, MAE e MAPE em relação aos 3 perfis. Apenas no intervalo das 15-16h o método RRRa apresentou RMSE menor que o perfil chuvoso. O MAE e o MAPE seguiram o mesmo perfil que o RMSE, mantendo valores menores para o método RRRa quando comparado com o MP.

Tabela 17 – RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h, utilizando os métodos RRRa e MP para o primeiro ano de predição.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa - SFVr	21,1	23,5	26,8	57,3	54,6	66,3	30,6	34,9	73,0
MP - SFVr	38,9	40,1	38,8	74,9	77,6	81,1	138,5	172,7	256,6
MAE [%]									
RRRa - SFVr	12,4	13,1	15,9	44,0	39,8	52,4	19,7	26,8	48,4
MP - SFVr	24,7	26,4	25,7	62,8	59,6	63,4	116,3	147,8	202,1
MAPE [%]									
RRRa - SFVr	22,3	22,7	29,1	74,4	59,8	95,7	28,0	26,7	62,2
MP - SFVr	25,5	32,1	30,2	129,8	144,2	147,1	400,7	175,6	386,4

Novamente, para o HRT = 24h, o perfil chuvoso apresentou valores de RMSE entre o perfil ensolarado e o intermediário na maioria dos intervalos. No intervalo das 15-16h, o perfil chuvoso apresentou maior RMSE que o perfil ensolarado e o intermediário. O perfil chuvoso apresenta um maior desvio do modelo RRRa quando comparado com o MP. Este maior desvio é devido ao método da persistência utilizar sempre a geração do dia anterior e podendo apresentar desvios altos de geração do dia anterior pra o dia da predição.

Entretanto, comparando a predição com HRT = 1h até 10h com HRT = 24h, o método RRRa se mostrou com um bom desempenho em ambos os horizontes. O RMSE

e o MAE para o perfil ensolarado se mantiveram praticamente os mesmos. O MAPE foi inferior nos intervalos 09h-10h e 15h-16h utilizando o HRT = 24h quando comparado com HRT = 1h até 10h. Essas diferenças se dão devido ao desempenho da plataforma de previsão do tempo. Quanto maior o horizonte de previsão, menor vai ser o desempenho da plataforma de previsão de tempo. Analisando a Figura 26, percebe-se que a previsão RRRa obteve novamente uma amplitude menor quando comparada com a geração e com a previsão através de MP para o perfil ensolarado.

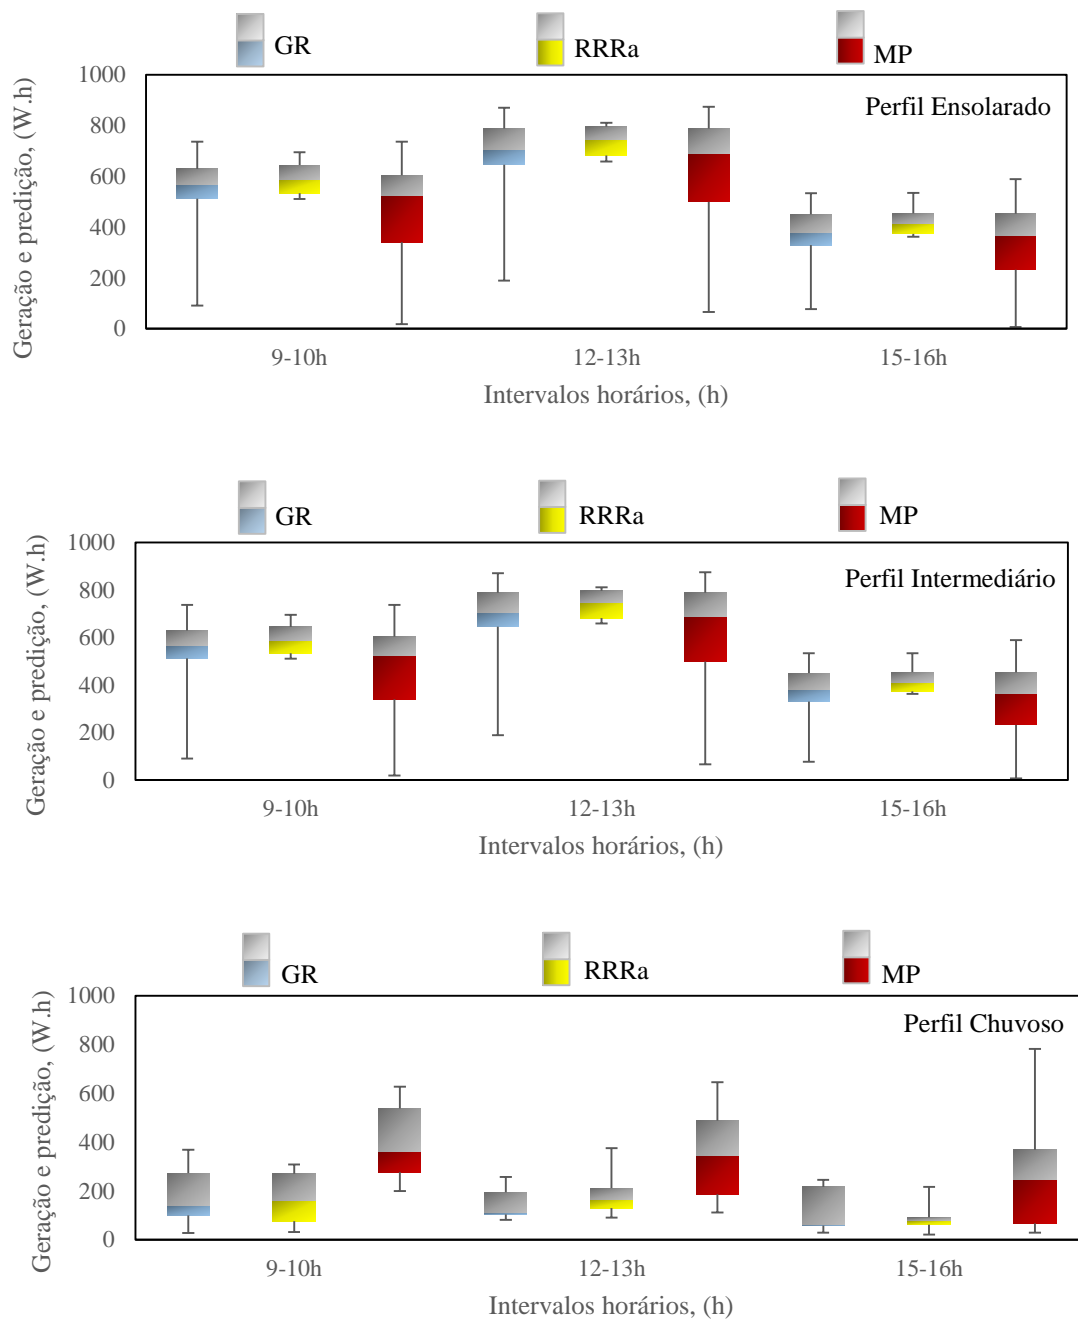


Figura 26 - Box Plot da geração e previsões utilizando a plataforma *Ventusky* para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2023 para um HRT = 24h.

Essa amplitude menor também é devido aos valores (\overline{PFP}) horários serem próximos ao longo do ano para o perfil ensolarado. O método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP e uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP.

Para o perfil intermediário (Figura 26), o método RRRa obteve novamente uma amplitude menor quando comparado com a geração e com a predição com MP. O método RRRa apresentou uma menor variação horária anual de predição e uma correlação maior com a geração fotovoltaica em todos os intervalos horários quando comparado com o MP. No perfil chuvoso (Figura 26), o método RRRa também apresentou uma menor variação horária anual de predição e uma correlação maior com a geração fotovoltaica em todos os intervalos horários quando comparado com o MP.

5.1.3 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h

A Tabela 18 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das 9h-10h, 12-13h e 15-16h. Para o HRT = 72h, o método RRRa também apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

O perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos três perfis. O perfil intermediário e chuvoso apresentaram valores próximos de RMSE, MAE e MAPE.

Tabela 18 – RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h utilizando os métodos RRRa e MP para o primeiro ano de predição.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa - SFVr	22,1	21,5	28,5	62,3	56,7	64,5	72,7	48,5	69,2
MP - SFVr	39,0	39,3	37,7	85,1	82,5	80,6	165,4	259,3	232,0
MAE [%]									
RRRa - SFVr	13,2	12,3	17,1	47,3	52,5	50,0	50,1	27,2	46,8
MP - SFVr	26,6	26,2	23,5	72,7	66,9	67,5	140,6	233,9	182,2
MAPE [%]									
RRRa - SFVr	29,0	20,3	33,7	71,7	42,6	89,8	101,0	47,8	53,6
MP - SFVr	30,6	32,0	32,6	112,9	98,3	143,8	363,3	191,4	317,9

No HRT = 72h, o perfil chuvoso apresentou erros maiores quando comparado com o HRT = 1h até 10h e HRT = 24h. A plataforma de previsão do tempo apresentou um desempenho menor para o perfil chuvoso em três dias futuros devido a plataforma de previsão do tempo possuir um desempenho menor na previsão para o perfil chuvoso no HRT = 72h.

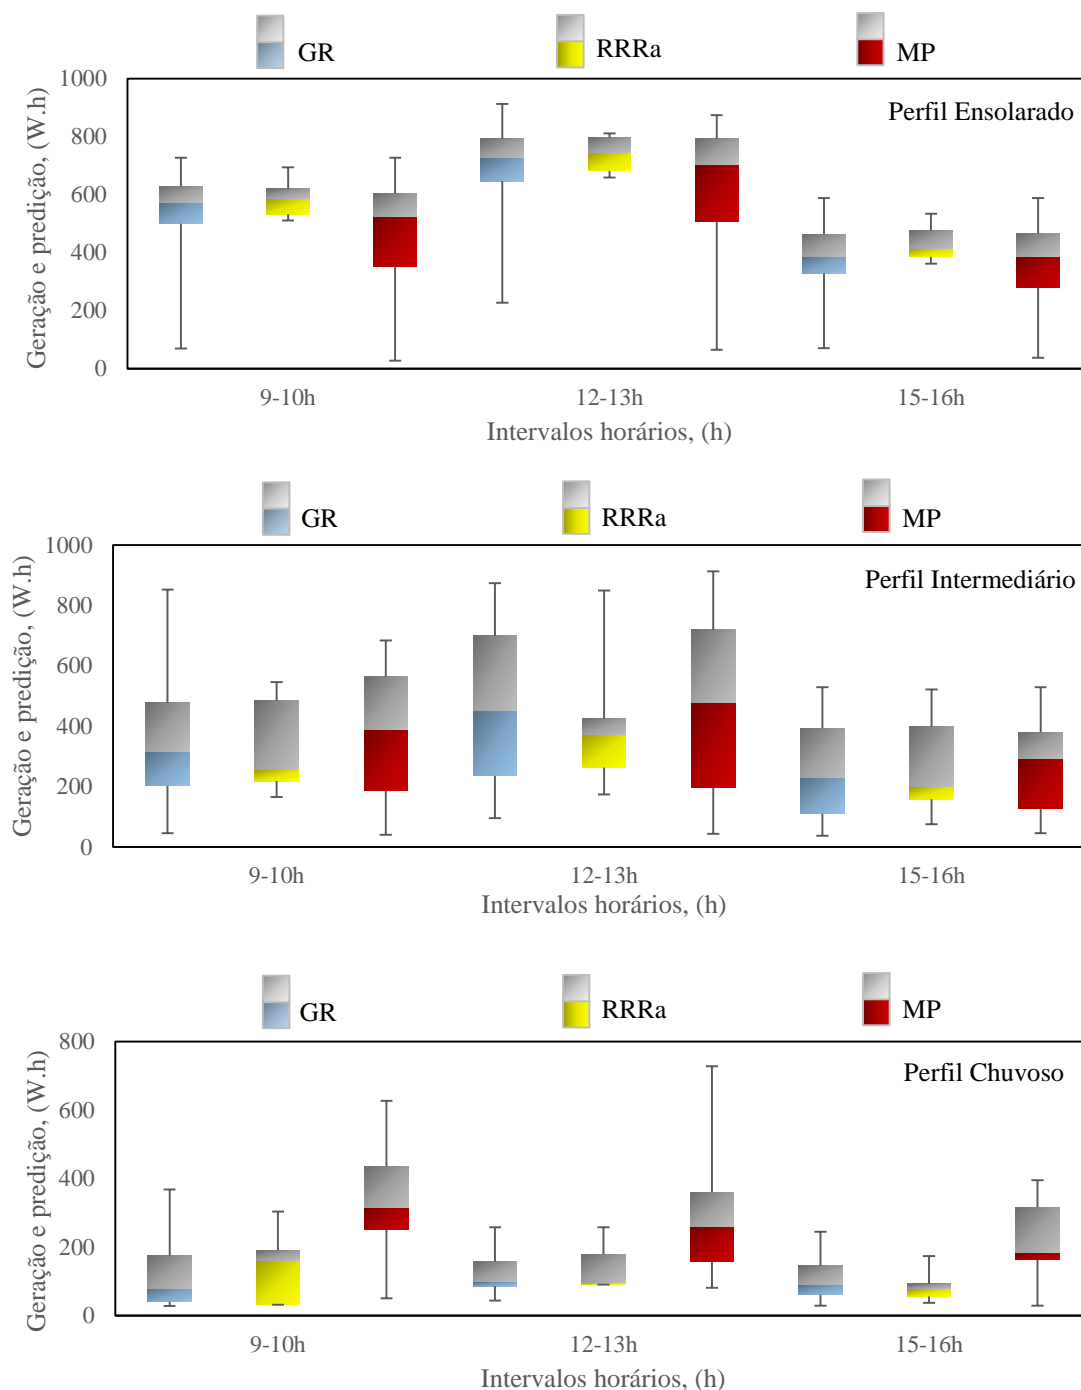


Figura 27 - Box Plot da geração e previsões utilizando a plataforma *Ventusky* para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2023 para um HRT = 72h.

Analisando a Figura 27, no perfil ensolarado, o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP e uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP.

Para o perfil intermediário (Figura 27), o método RRRa obteve novamente uma amplitude menor quando comparado com a geração. O método RRRa apresentou uma menor variação horária anual de predição e uma correlação maior com a geração fotovoltaica nos intervalos horários das 9h-10h e 15-16h quando comparado com o MP. No intervalo das 12h-13h, o método RRRa apresentou uma correlação menor com a geração quando comparado com o MP.

No perfil chuvoso (Figura 27), o método RRRa também apresentou uma menor variação horária anual de predição e uma correlação maior com a geração fotovoltaica em todos os intervalos horários quando comparado com o MP. Este apresentou uma amplitude maior quando comparado com a geração e com o método RRRa. Essa amplitude maior mostra que o método MP possui um baixo desempenho de predição no perfil chuvoso.

A Figura 28 apresenta a diferença dos erros RMSE, MAE e MAPE para o método RRRa utilizando os horizontes de HRT = 1h até 10h, HRT = 24h e HRT = 72h. No perfil ensolarado, o método RRRa se mostrou com um bom desempenho para os três horizontes em todos os intervalos horários analisados. O RMSE se apresentou com valores próximos nos três horizontes e em todos os intervalos horários analisados.

No perfil intermediário, na maioria dos casos, o método se mostrou menos eficiente nos HRT = 24h e HRT = 72h. Apenas no intervalo horário das 12-13h o RMSE para a predição de curto prazo foi maior que as predições de médio prazo. Na maioria dos intervalos, o MAE obteve um desempenho melhor para a predição de curto prazo. Apenas no intervalo das 12-13h, o MAE obteve um melhor desempenho para a predição de médio prazo (24h).

No perfil chuvoso, o HRT = 72h obteve o menor desempenho no intervalo das 9h-10h. Nos outros intervalos, o perfil chuvoso também mostrou menor desempenho quando comparado com o perfil ensolarado. O método RRRa mostrou que apresenta desempenhos próximos dos três horizontes nos perfis ensolarado e intermediário. No perfil chuvoso, o método apresentou um menor desempenho para o HRT = 24h e HRT = 72h.

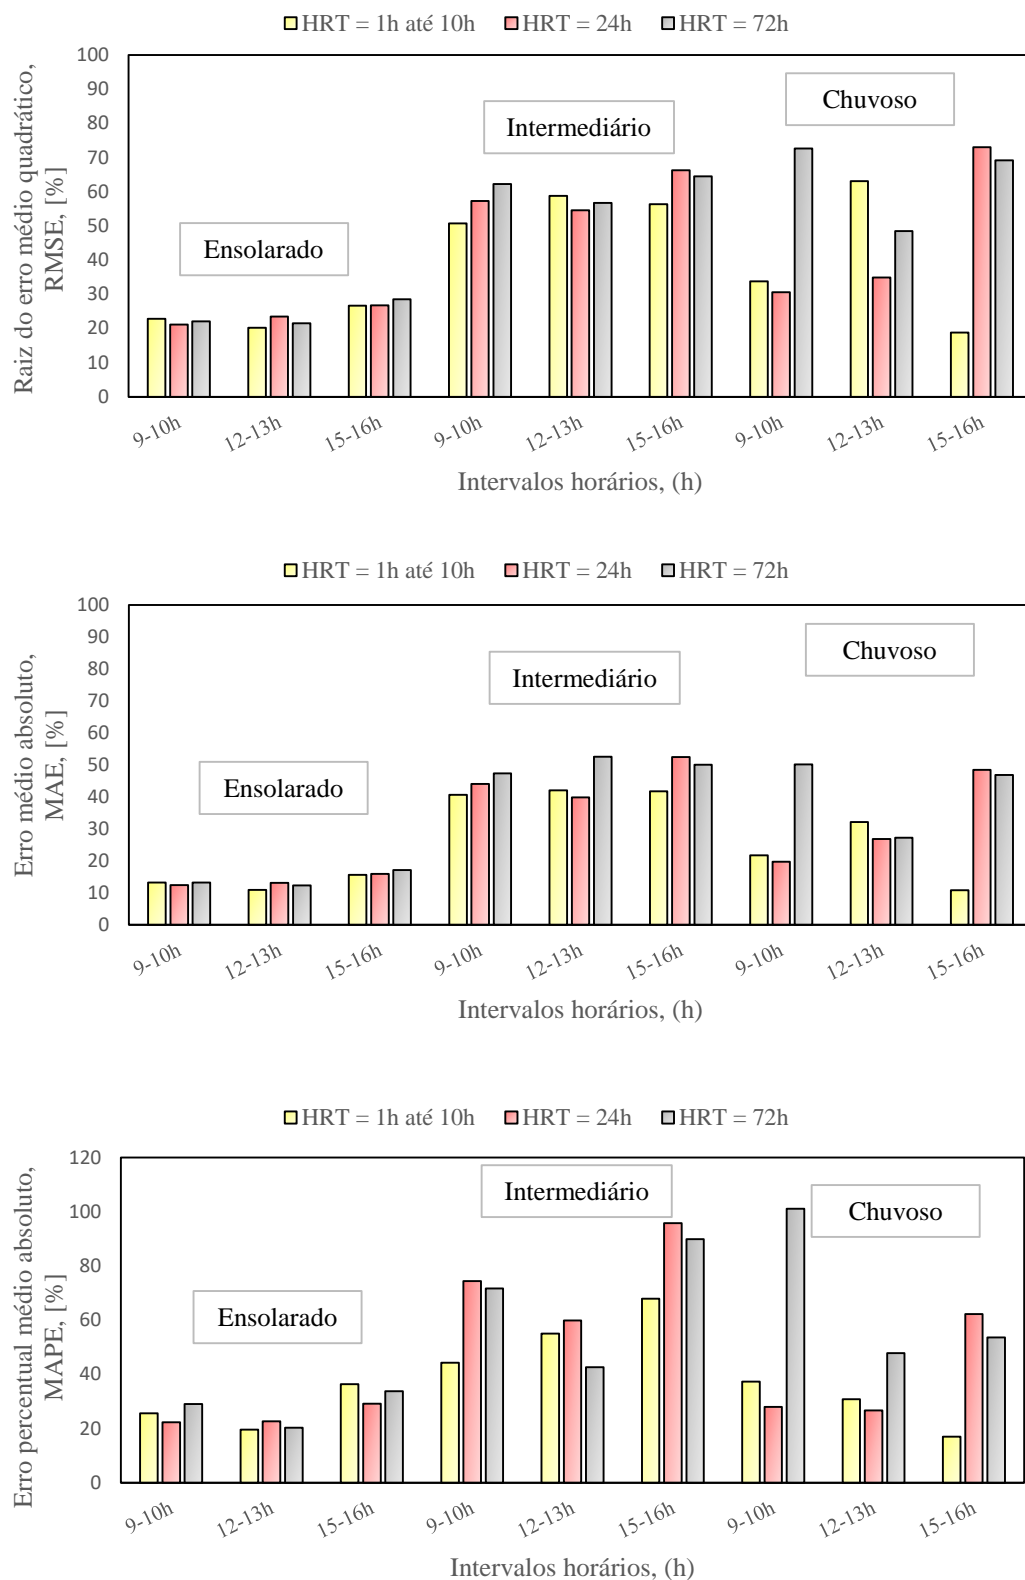


Figura 28 - RMSE, MAE e MAPE para os três perfis utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h.

5.1.4 Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h

O RMSE, o MAE e o MAPE médios diários anuais foram obtidos para os três perfis. A Tabela 19 apresenta os valores obtidos. O maior desempenho do RRRa foi para o perfil chuvoso (HRT = 1h até 10h), com RMSE médio anual de 9,9%, MAE médio anual de 8,3% e MAPE médio anual de 8,7%.

Como já esperado, o perfil intermediário obteve um valor maior de RMSE médio, 25,0%. Ele é o perfil com maior desafio para se realizar as predições. Nele, a radiação solar é intermitente devido a um grande acúmulo e passagem de nuvens. Para o perfil ensolarado, o RMSE médio foi de 15,7%. Comparando o RRRa com o MP para todos os perfis (HRT = 1h até 10h, HRT = 24h e HRT = 72h), o método RRRa obteve maior desempenho que o MP.

Entretanto, o RMSE, o MAE e o MAPE médios diários anuais aumentaram seu desempenho quando comparados com os intervalos horários. Esse desempenho maior é devido às métricas de desempenho serem calculadas para o dia completo.

Tabela 19 - Erro médio diário anual RSME, MAE e MAPE para os três perfis utilizando a plataforma *Ventusky* no primeiro ano de predição.

PERFIS	RMSE (%)	MAE (%)	MAPE (%)	RMSE (%)	MAE (%)	MAPE (%)
	RRRa - SFV _r	RRRa - SFV _r	RRRa - SFV _r	MP - SFV _r	MP - SFV _r	MP - SFV _r
Ensolarado *	15,7	9,7	11,9	20,4	15,5	15,7
Intermediário *	25,0	19,4	19,7	47,8	37,2	44,7
Chuvoso *	9,9	8,3	8,7	85,6	63,5	78,5
Ensolarado **	18,4	10,9	18,5	31,6	21,5	26,9
Intermediário **	33,7	26,8	32,5	52,7	43,4	65,5
Chuvoso **	23,3	16,2	24,8	173,2	126,0	140,8
Ensolarado ***	17,3	11,5	17,5	30,4	19,8	26,2
Intermediário ***	30,9	25,1	26,6	48,3	39,9	55,6
Chuvoso ***	26,8	19,3	21,9	216,6	150,1	166,9

*Horizonte de 1h até 10h.

** Horizonte de 24h.

*** Horizonte de 72h.

A Figura 29 apresenta um comparativo com o estudo de Zhu *et al.*, (2015). No trabalho de Zhu *et al.*, (2015), os autores encontraram RMSE de 9,30% (RNA) e de 7,19% (DW + RNA) para a previsão do tempo de céu claro. Utilizando o perfil ensolarado, o método RRRa obteve o RMSE de 6,4% maior quando comparado com o método RNA e de 8,5% maior quando comparado com o DW + RNA. Um dos motivos do método RRRa obter esse menor desempenho é que no perfil ensolarado foram consideradas previsões de sol com algumas nuvens e sol com poucas nuvens junto com céu limpo. Esses tipos de

previsões possuem a passagem de nuvens durante o dia, não sendo um dia totalmente ensolarado. Outro motivo é o horizonte de HRT = 1h até 10h ser um horizonte maior quando comparado com o estudo de Zhu *et al.*, (2015).

Na previsão de nublado, Zhu *et al.*, (2015) encontraram RMSE de 18,5% (RNA) e 17,6% (DW + RNA). Utilizando o perfil intermediário, o método RRRa obteve o RMSE de 6,5% maior quando comparado com o método RNA e de 7,4% maior quando comparado com o DW + RNA. O método RRRa considerou a previsão de sol e pancadas de chuva como perfil intermediário, aumentando, assim, a variabilidade da irradiância ao longo do dia.

Para o perfil chuvoso, o método RRRa apresentou RMSE médio de 9,9%, enquanto Zhu *et al.*, (2015), para a previsão chuvosa, apresentaram RMSE de 22,9% para o método RNA e de 19,6% para o método DW + RNA. O método RRRa apresentou maior desempenho para o perfil chuvoso quando comparado com os dois métodos apresentados por Zhu *et al.*, (2015). Vale destacar que os modelos de Zhu *et al.*, (2015) utilizaram horizontes de 1 minuto (futuro) para realizar as previsões, enquanto que, para essa comparação, utilizamos o HRT = 1h até 10h. Não podemos alegar qual método possui um melhor desempenho.

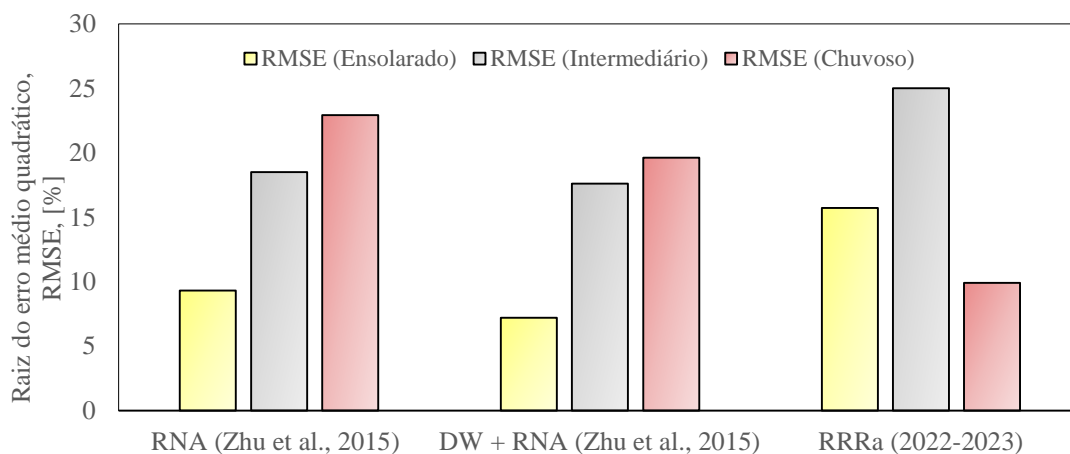


Figura 29 – Comparação do método RRRa com RNA e DW + RNA de Zhu *et al.* (2015) utilizando o período de previsão de março de 2022 até fevereiro de 2023.

Para o HRT = 24h, o método RRRa obteve RMSE, MAE e MAPE maiores que para HRT = 1h até 10h. No perfil ensolarado, o RMSE, o MAE e o MAPE foram de 2,7%, 1,2% e 6,6%, respectivamente, maiores quando comparados com HRT = 1h até 10h. No perfil intermediário foi de 8,7%, 7,4% e 12,8% maiores quando comparado o HRT = 24h com o HRT = 1h até 10h. Para o perfil chuvoso, foi de 13,4%, 7,9% e 16,1% maiores.

Em relação à predição fotovoltaica para o dia seguinte ($HRT = 24h$), o método RRRa apresentou um desempenho próximo para a predição do dia ($HRT = 1h$ até $10h$). A diferença da assertividade quando comparados os dois horizontes de predição é devido as plataformas de previsão do tempo possuírem um desempenho inferior na previsão do dia seguinte. As plataformas possuem um processo de probabilidade que depende de inúmeros fatores.

Para o $HRT = 72h$, o método RRRa obteve RMSE, MAE e MAPE maiores que para $HRT = 1h$ até $10h$ e valores próximos do $HRT = 24h$. No perfil ensolarado, o RMSE, o MAE e o MAPE foram de 1,6%, 2,2% e 5,6%, respectivamente, maiores quando comparados com $HRT = 1h$ até $10h$. No perfil intermediário, foi de 5,9%, 5,7% e 6,9% maiores quando comparado o $HRT = 72h$ com o $HRT = 1h$ até $10h$. Para o perfil chuvoso, foi de 16,9%, 11,0% e 13,2% maiores. O método RRRa se mostrou com um bom desempenho quando comparado o $HRT = 24h$ com o $HRT = 72h$.

Em geral, o método RRRa apresentou um desempenho próximo dos desempenhos da literatura científica. As diferenças se dão devido às metodologias, aos locais de predição e às premissas dos modelos serem diferentes. Se houver ampliação do número de dados e com um tempo maior de predição, o modelo RRRa apresentará um melhor desempenho. Outra forma de aumentar a assertividade do método é usar plataformas de previsão do tempo mais precisas. Uma das vantagens de se utilizar o modelo RRRa é que não há necessidade de altos investimentos em equipamentos de medições juntos ao sistema fotovoltaico de operação. O método RRRa mostrou que é possível realizar predições de FV sem dados de radiação solar e com um grau aceitável de assertividade.

5.1.5 Análise de predição de geração fotovoltaica mensal por meio dos erros médios diários utilizando $HRT = 1h$ até $10h$, $HRT = 24h$ e $HRT = 72h$

A Tabela 20 apresenta os valores de RMSE, MAE e MAPE médios mensais para o método RRRa e o MP com $HRT = 1h$ até $10h$, $HRT = 24h$ e $HRT = 72h$. Utilizando horizonte de $1h$ até $10h$, o RMSE médio mensal para o RRRa variou de 7,3% e 50,1%. Para o método MP, o RMSE médio mensal variou entre 15,1% e 65,0%. Portanto, com $HRT = 24h$, o RMSE médio mensal para o RRRa variou de 4,5% e 43,2%. Para o método MP, o RMSE médio mensal variou entre 11,5% e 75,0%. No $HRT = 72h$, o RMSE médio

mensal variou de 13,8% e 36,9%. Para o método MP, o RMSE médio mensal variou entre 15,2% e 68,9%.

No HRT = 1h até 10h, o RRRa apresentou maior desempenho que o MP praticamente em todos os meses no intervalo analisado. Por outro lado, no mês de abril de 2022, o RRRa apresentou RMSE, MAE e MAPE maiores que o MP. Utilizando o HRT = 24h e HRT = 72h, o RRRa apresentou maior desempenho em todos os meses do intervalo quando comparado com o MP. O mês de abril de 2022 foi um mês com muita instabilidade, nebulosidade e chuvoso. Desse modo, a plataforma *Ventusky* teve uma assertividade menor quanto à previsão do tempo. Em abril de 2022, essa plataforma obteve um desempenho maior realizando a previsão do tempo do dia seguinte e de três dias futuros em comparação com a previsão no dia. Entretanto, quanto maior for o desempenho de assertividade da plataforma de previsão do tempo, maior será o desempenho do método RRRa.

Tabela 20 - RMSE, MAE e MAPE médios diários mensais para os métodos RRRa e MP com HRT = 1h até 10h, HRT = 24h e HRT = 72h utilizando a plataforma *Ventusky* para o primeiro ano de predição.

Horizonte de 1h até 10h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	30,4	50,1	13,7	17,8	20,5	23,3	23,7	24,1	15,7	15,3	7,3	11,8
MP - SFVr	65,0	42,9	41,2	36,5	39,3	38,9	63,0	36,1	37,3	31,3	15,1	20,4
MAE [%]												
RRRa - SFVr	20,3	38,9	11,5	12,3	14,7	16,3	20,2	17,2	8,9	12,1	5,0	7,9
MP - SFVr	49,2	37,1	28,1	30,4	31,4	24,8	53,0	27,5	26,2	23,6	12,5	16,7
MAPE [%]												
RRRa - SFVr	27,8	49,4	12,6	13,5	20,3	30,2	28,7	27,6	11,7	16,5	6,1	9,6
MP - SFVr	64,4	48,8	38,3	39,7	37,4	31,0	86,1	34,8	26,6	26,5	13,1	18,4
Horizonte de 24h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	43,2	34,4	22,4	15,3	19,9	21,8	30,1	32,5	18,2	20,5	4,5	15,0
MP - SFVr	69,5	44,4	31,8	40,9	29,8	58,7	75,0	56,2	35,9	20,8	11,5	16,0
MAE [%]												
RRRa - SFVr	26,8	25,3	14,0	11,1	15,2	15,4	25,2	24,5	10,7	13,1	4,4	10,6
MP - SFVr	48,5	38,2	22,9	31,2	21,8	40,8	59,9	46,8	23,8	15,8	8,2	13,8
MAPE [%]												
RRRa - SFVr	45,4	29,1	14,5	14,7	18,0	44,9	43,5	34,0	15,5	19,5	4,4	11,6
MP - SFVr	89,0	68,4	35,6	32,5	24,2	114,0	97,3	88,3	29,1	21,2	8,2	14,7
Horizonte de 72h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	29,5	36,6	28,9	28,2	20,3	24,6	29,5	36,9	23,8	13,8	14,0	16,7
MP - SFVr	68,9	52,0	44,3	51,8	26,1	48,8	66,6	59,7	40,7	15,2	15,2	18,4
MAE [%]												
RRRa - SFVr	16,6	31,1	18,2	21,8	17,1	17,5	22,5	26,2	17,8	11,1	9,6	10,9
MP - SFVr	48,2	45,6	31,8	45,8	20,9	32,0	54,1	48,2	29,7	12,1	14,5	16,0
MAPE [%]												
RRRa - SFVr	28,1	43,8	17,1	29,8	19,5	27,2	35,8	37,0	25,2	12,2	8,7	13,0
MP - SFVr	92,1	72,1	46,3	88,4	22,1	80,4	80,4	52,1	33,1	15,3	10,0	19,3

Quando utilizamos a RRRa para $HRT = 24h$, observamos que em alguns meses o RMSE foi menor quando comparado com o $HRT = 1h$ até $10h$. Esse resultado mostra que o método RRRa é um método confiável para horizontes de curto e médio prazos. O erro MAE e MAPE seguiu o mesmo padrão que o RMSE e em alguns meses os erros com $HRT = 24h$ foram menores que o $HRT = 1h$ até $10h$.

No $HRT = 72h$, o método RRRa apresentou RMSE maiores que $HRT = 24h$ e $HRT = 1h$ até $10h$ na maioria dos meses. Somente em abril de 2022, julho de 2022 e dezembro de 2022 o RMSE foi menor utilizando o $HRT = 72h$. Conforme se aumenta o horizonte de predição, a plataforma meteorológica diminui o desempenho da previsão do tempo. Portanto, na maioria dos meses, o $HRT = 72h$ apresentou RMSE, MAE e MAPE levemente maiores quando comparado com $HRT = 24$. O $HRT = 24h$ apresentou RMSE, MAE e MAPE levemente maiores quando comparado com $HRT = 1h$ até $10h$.

O método RRRa está com um desempenho próximo dos desempenhos dos métodos da literatura. Em comparação com o estudo de Dewangan *et al.*, (2020) que utilizou a previsão do dia seguinte, o mês de janeiro de 2023 com $HRT = 24h$ obteve menor RMSE que todos os métodos combinados e não combinados para as três usinas nos quatro meses apresentados pelos autores. Para $HRT = 72h$, o mês de janeiro de 2023 apresentou melhor desempenho no primeiro mês comparado com a Usina 2 e todos os métodos combinados. No terceiro mês, a Usina 2 obteve pior desempenho com os modelos RVSG e RPGMa quando comparados com o RRRa no $HRT = 72h$.

Nos meses de fevereiro de 2023, junho e novembro de 2022, o método RRRa apresentou desempenho parecido com o dos métodos combinados de Dewangan *et al.*, (2020) para a Usina 2. Para o mês de janeiro, o método RRRa apresentou o erro MAPE menor que todos os métodos avaliados por Dewangan *et al.*, (2020) nos meses um, três e quatro. A Figura 30 apresenta um comparativo do método RRRa com o estudo de Dewangan *et al.*, (2020). Observando a figura, percebe-se que o modelo RRRa apresentou desempenhos parecidos com os modelos apresentados no trabalho de Dewangan *et al.*, (2020).




Figura 30 – Comparativo do método RRRa com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan *et al.*, (2020) por meio do horizonte de predição para o dia seguinte (HRT = 24h) utilizando o período de predição de 2022 até 2023.

Muitas dessas diferenças se dão pelas predições de geração fotovoltaica serem realizadas em lugares diferentes e com metodologias, premissas, pressupostos e climas diversos. O método RRRa apresentou um bom desempenho e um grau aceitável de assertividade para as predições mensais.

Portanto, o RMSE, o MAE e o MAPE médios diários mensais aumentaram novamente o seu desempenho quando comparados com os intervalos horários. Esse desempenho maior é devido às métricas de desempenho para o erro médio diário mensal também serem calculadas para o dia completo.

5.2 PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV_r) UTILIZANDO A PLATAFORMA *OPEN WEATHER* NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2023

A plataforma *Open Weather* foi utilizada como um comparativo em relação à plataforma *Ventusky* para avaliar o impacto de diferentes plataformas de previsão do tempo no método desenvolvido. Entretanto, os dados de previsão foram extraídos diariamente somente para o dia. As predições realizadas com a *Open Weather* foram com horizonte de HRT = 1h até 10h.

5.2.1 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h

A Tabela 21 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso. O método RRRa apresentou valores de RMSE, MAE e MAPE menores que o método MP no perfil ensolarado. No perfil intermediário, o MP apresentou RMSE menor que o RRRa no intervalo das 16-17h. No mesmo perfil, o MP apresentou MAE menor que o RRRa no intervalo das 10-11h. No perfil chuvoso, o MP apresentou RMSE, MAE e MAPE menores que o RRRa no intervalo das 16-17h.

Tabela 21 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h utilizando os métodos RRRa e MP para o primeiro ano de predição.

	8-9h	9-10h	10-11h	11-12h	12-13h	13-14h	14-15h	15-16h	16-17h	17-18h
RMSE [%] - ENSOLARADO										
RRRa - SFVr	24,7	18,2	14,8	15,6	14,9	14,8	14,1	15,9	25,6	38,1
MP - SFVr	46,3	39,4	33,4	35,6	37,8	40,2	39,0	37,5	50,3	67,3
MAE [%] - ENSOLARADO										
RRRa - SFVr	14,9	10,9	9,0	9,0	8,6	8,7	8,6	8,9	14,9	22,4
MP - SFVr	31,5	27,6	21,6	23,6	24,4	26,0	24,5	23,3	34,1	41,2
MAPE [%] - ENSOLARADO										
RRRa - SFVr	28,9	15,1	11,7	12,3	11,9	12,4	11,5	13,6	26,9	56,9
MP - SFVr	40,4	30,0	22,8	24,9	26,1	28,7	26,1	28,0	45,1	57,9
RMSE [%] - INTERMEDIÁRIO										
RRRa - SFVr	58,2	54,6	54,4	58,0	50,2	51,9	65,1	56,6	69,9	61,1
MP - SFVr	81,0	63,2	58,5	62,9	66,4	72,8	77,9	68,8	69,4	78,1
MAE [%] - INTERMEDIÁRIO										
RRRa - SFVr	44,0	41,3	44,4	48,3	39,7	39,9	50,3	43,5	51,5	40,8
MP - SFVr	64,7	48,5	44,2	49,8	53,2	59,2	62,5	57,0	54,0	54,3
MAPE [%] - INTERMEDIÁRIO										
RRRa - SFVr	56,9	67,2	57,7	61,8	56,0	49,2	69,6	68,1	77,0	105,3
MP - SFVr	84,0	96,3	65,5	73,9	85,7	95,0	142,8	125,4	82,2	179,2
RMSE [%] - CHUVOSO										
RRRa - SFVr	85,2	73,6	71,5	66,2	72,0	81,4	83,4	66,4	91,0	87,2
MP - SFVr	129,0	117,8	109,7	100,1	76,4	86,2	85,0	85,1	77,5	96,3
MAE [%] - CHUVOSO										
RRRa - SFVr	57,6	48,5	47,7	40,3	45,8	51,1	61,1	44,9	66,0	62,5
MP - SFVr	104,7	97,2	89,2	79,8	57,6	65,7	65,9	65,7	59,5	70,1
MAPE [%] - CHUVOSO										
RRRa - SFVr	115,9	63,3	68,0	36,0	58,1	41,9	68,4	61,1	110,6	275,9
MP - SFVr	234,0	169,0	160,8	146,9	147,3	168,6	120,0	165,6	115,2	220,6

O perfil ensolarado apresentou novamente menores RMSE, MAE e MAPE em relação aos três perfis. O RMSE para o método RRRa foi de 14,1% a 38,1%. O MP apresentou valores de RMSE entre 33,4% e 67,3%. No perfil ensolarado, os horários com maiores radiação solar apresentaram RMSE, MAE e MAPE menores também com a plataforma *Open Weather*. Os menores erros foram entre os intervalos das 10h até 14h.

O perfil intermediário apresentou valores de RMSE, MAE e MAPE entre o perfil ensolarado e chuvoso na maioria dos intervalos. O RMSE para o método RRRa foi de 50,2% a 69,9%. O MP apresentou valores de RMSE entre 58,5% e 81,0%. O MAE apresentou valores menores para o método RRRa na maioria dos intervalos quando comparado com o MP. Somente no intervalo das 10-11h o MP apresentou valor de MAE menor que o RRRa. Em relação ao MAPE, o método RRRa obteve menores valores que o MP em todos os intervalos horários.

O perfil chuvoso apresentou maiores RMSE, MAE e MAPE em relação aos três perfis. O RMSE para o método RRRa foi de 66,2% a 91,0%. O MP apresentou valores de RMSE entre 76,4% e 129,0%. O MAE seguiu o mesmo perfil que o RMSE, mantendo valores menores para o método RRRa quando comparado com o MP. Em relação ao MAPE, o MP obteve menor valor que o RRRa somente no intervalo das 17-18h.

O método RRRa apresentou maiores RMSE no intervalo entre o início (8h e 9h) e final do dia (16h e 17h, 17h e 18h) no perfil ensolarado. Como já discutido, os erros maiores nesses intervalos não possuem um impacto energeticamente relativo devido a esse intervalo possuir uma baixa irradiação.

No primeiro ano de predição, para o perfil ensolarado, a aplicação do método de predição utilizando os dados da plataforma *Open Weather* obteve RMSE menores na maioria dos intervalos horários quando comparada com a predição utilizando os dados da plataforma *Ventusky*. Para o perfil intermediário, a aplicação do método de predição utilizando os dados da plataforma *Open Weather* obteve valores de RMSE maiores nos intervalos horários quando comparada com a predição utilizando os dados da plataforma *Ventusky*. No perfil chuvoso, a aplicação do método de predição utilizando os dados da plataforma *Open Weather* obteve valores de RMSE maiores em todos os intervalos horários quando comparada com a predição utilizando os dados da plataforma *Ventusky*. A plataforma *Open Weather*, comparada com a plataforma *Ventusky* no perfil intermediário e chuvoso, apresentou amplitudes menores nos valores de RMSE, MAE e MAPE entre os métodos RRRa e MP. Essas menores amplitudes indicam que o desempenho do método RRRa está próximo do desempenho do MP.

O desempenho de predição da geração fotovoltaica dos métodos RRRa e MP em diferentes estações do ano também está apresentado na Figura 31.

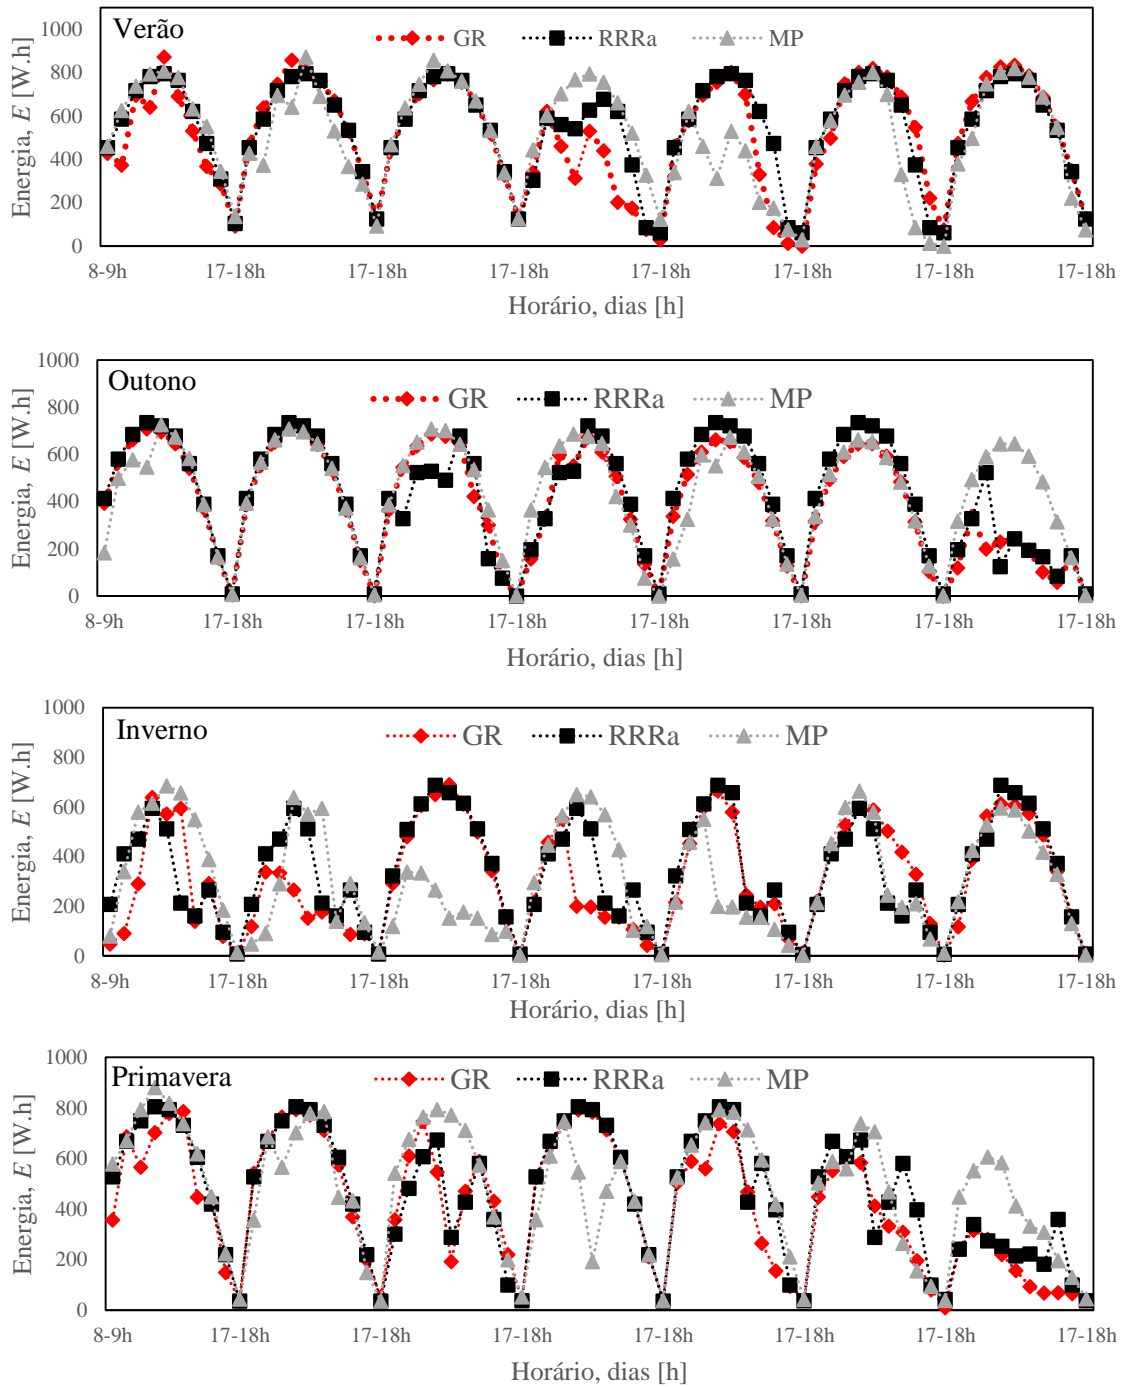


Figura 31 - Gráfico de predições RRRa e MP com a GR de 7 dias para as quatro estações do ano utilizando a plataforma *Open Weather*.

O horizonte considerado foi o mesmo da plataforma *Ventusky* (HRT = 1h a 10h). Foram também analisados sete dias consecutivos para cada estação do ano. Entre esses dias, estão inseridos todos os três perfis de previsão do tempo.

A previsão utilizando o RRRa foi comparada com o MP em relação à GR. Os gráficos de desempenho mostram, visualmente, que, por meio da plataforma *Open Weather*, o RRRa obteve um desempenho melhor que o MP em todas as estações do ano.

Utilizando a plataforma *Open Weather* na estação verão, o método RRRa também obteve um bom desempenho durante os sete dias consecutivos. O método MP apresentou um desempenho inferior ao método RRRa em comparação com a GR no segundo, quarto, quinto e sexto dias. Na estação outono, o método RRRa teve um bom desempenho no primeiro, segundo, quarto e sétimo dias. No terceiro, quinto e sexto dias, o desempenho do método RRRa foi inferior ao do MP. O desempenho do RRRa diminuiu devido à plataforma *Open Weather* ser menos precisa nesses dias.

Na estação inverno, o método RRRa apresentou um desempenho inferior somente no sétimo dia em comparação com o MP. Na primavera, o método RRRa teve um melhor desempenho que o MP em todos os sete dias.

Analisando a Figura 32, nos perfis intermediário e chuvoso, o método RRRa apresentou amplitudes maiores, variação horária anual maior e correlação maior de previsão que o método MP.

Essa correlação maior do método RRRa em comparação com o método MP é devido à plataforma *Open Weather* apresentar um menor desempenho na assertividade das previsões do tempo nos perfis intermediário e chuvoso. No perfil ensolarado, o método RRRa obteve uma variação horária anual menor e correlação maior de previsão com a geração real. A plataforma *Open Weather* se mostrou com um bom desempenho na assertividade da previsão do tempo para o perfil ensolarado.

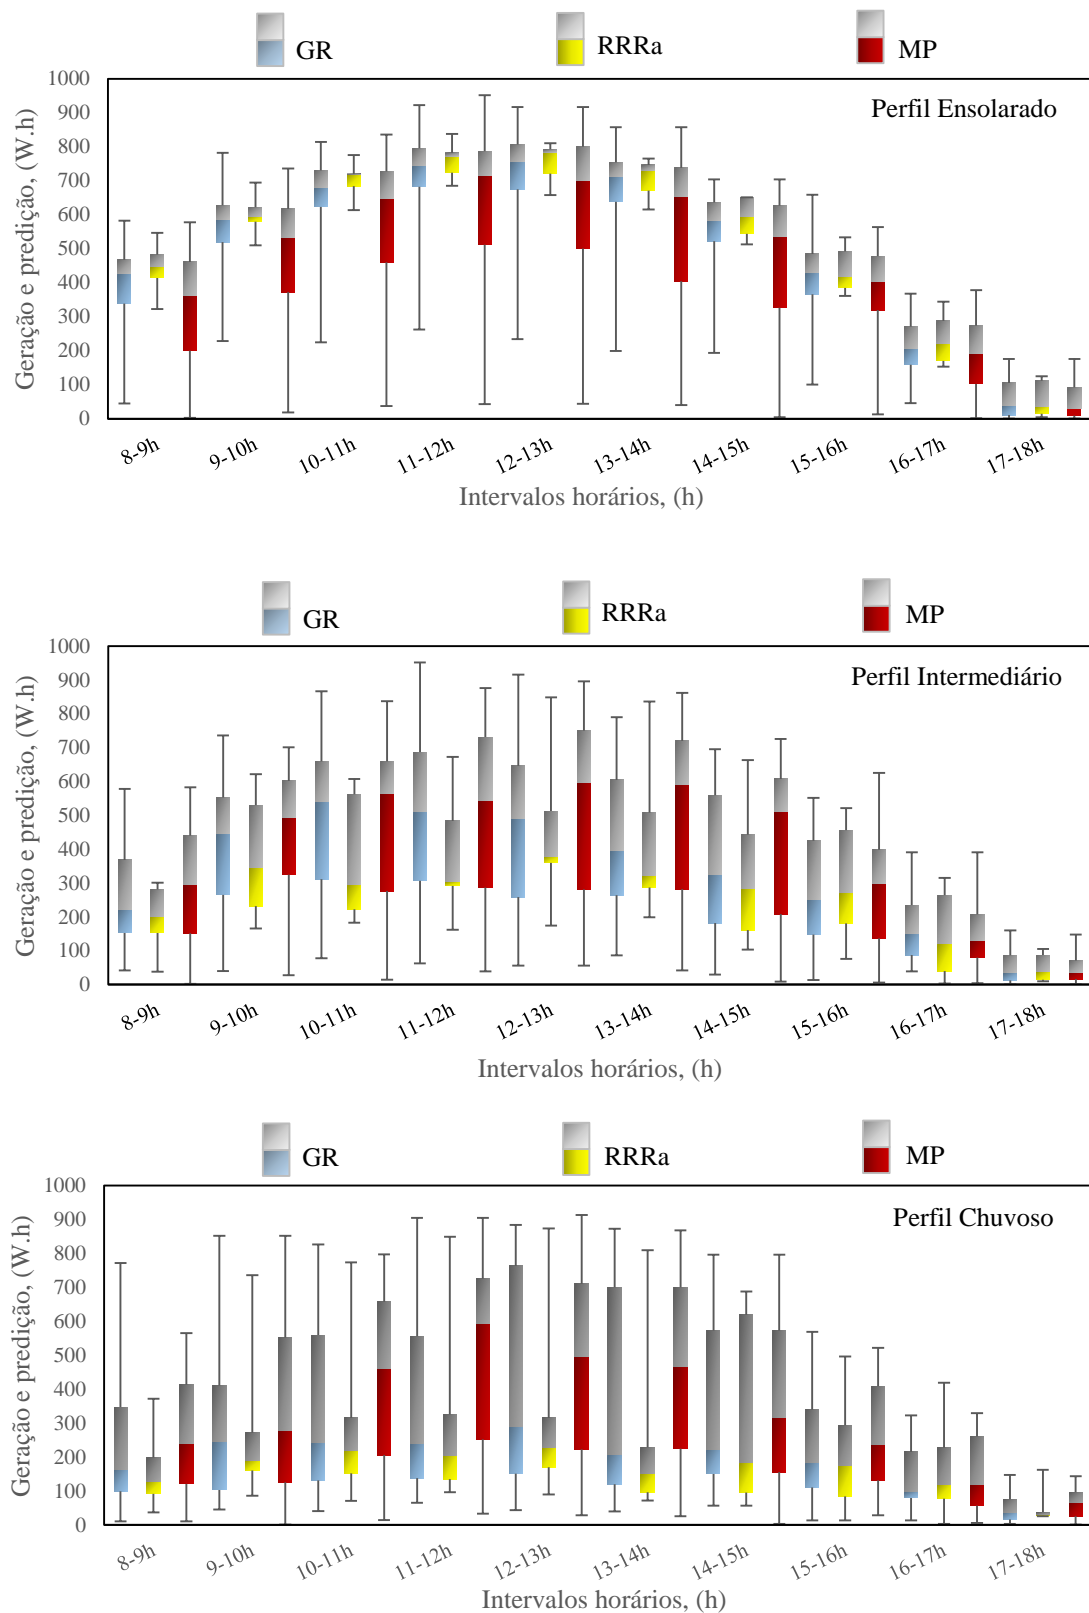


Figura 32 - Box Plot da geração e predições utilizando a plataforma *Open Weather* para os perfis nos intervalos horários para HRT = 1h até 10h no primeiro ano de predição.

5.2.2 Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h

O RMSE, o MAE e o MAPE médios anuais foram obtidos para os três perfis. A Tabela 22 apresenta os valores obtidos. O maior desempenho do RRRa foi para o perfil ensolarado com RMSE médio anual de 10,2%, MAE médio anual de 6,2% e MAPE médio anual de 7,1%.

Tabela 22 - Erro médio diário anual RSME, MAE e MAPE para os três perfis utilizando a plataforma *Open Weather* para primeiro ano de predição.

PERFIS	RMSE (%)	MAE (%)	MAPE (%)	RMSE (%)	MAE (%)	MAPE (%)
	RRRa - SFV _r	RRRa - SFV _r	RRRa - SFV _r	MP - SFV _r	MP - SFV _r	MP - SFV _r
Ensolarado	10,2	6,2	7,1	23,1	17,0	17,4
Intermediário	24,7	19,4	20,6	21,9	18,3	22,1
Chuvoso	40,9	30,8	31,2	42,2	33,9	45,4

O perfil chuvoso obteve um valor maior de RMSE médio, 40,9%. Comparando o RRRa com o MP, o primeiro obteve maior desempenho que o segundo nos perfis ensolarado e chuvoso. No perfil intermediário, o método RRRa obteve RMSE e MAE maiores que o MP. Nos intervalos intermediário e chuvoso, o método RRR apresentou erros próximos dos do método MP. Essa proximidade é devido à assertividade da previsão do tempo com a plataforma *Open Weather* ser menor nesses perfis.

A Figura 33 apresenta a influência das plataformas de previsão de tempo nas predições de FV por meio do método RRRa para o primeiro ano de predições utilizando os erros médios diários anuais.

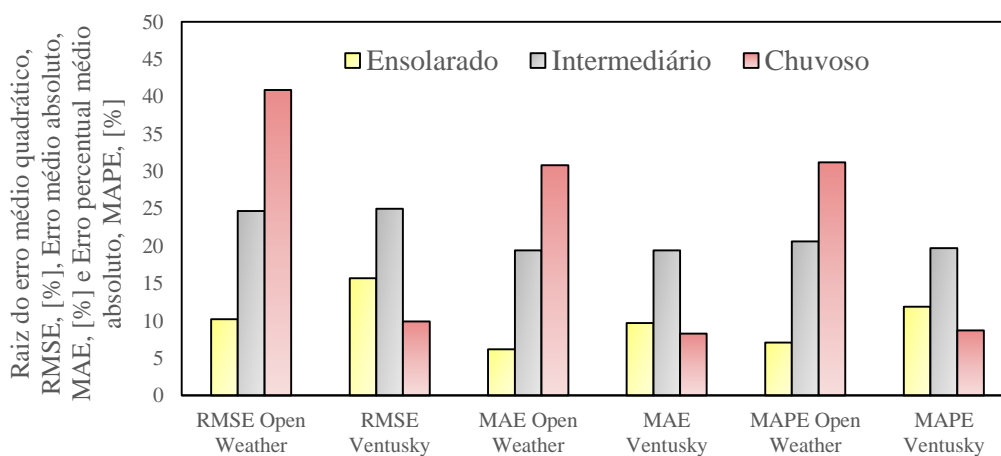


Figura 33 – Comparação de desempenho das plataformas *Ventusky* e *Open Weather* no primeiro ano de predições utilizando os erros médios diários anual.

No perfil ensolarado, a plataforma *Open Weather* obteve uma assertividade maior na previsão do tempo quando comparada com a *Ventusky*. No perfil chuvoso, a plataforma *Ventusky* apresentou uma assertividade maior. No perfil intermediário, as duas plataformas apresentaram uma assertividade parecida na previsão do tempo. A plataforma *Ventusky* apresentou o MAPE levemente inferior quando comparada com a *Open Weather* no perfil intermediário.

5.2.3 Análise de previsão de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h

A Tabela 23 apresenta os valores de RMSE, MAE e MAPE médios mensais para o método RRRa e o MP com HRT = 1h até 10h utilizando a plataforma *Open Weather*. O RMSE médio mensal para o RRRa variou de 10,3% e 39,9%. Devido às previsões com a plataforma *Open Weather* serem realizadas da mesma forma que a plataforma *Ventusky*, nas previsões mensais o MP apresenta os mesmos erros.

Tabela 23 - RMSE, MAE e MAPE médios diários mensais para os métodos RRRa e MP com HRT = 1h até 10h utilizando a plataforma *Open Weather* para o primeiro ano de previsão.

	Horizonte de 1h até 10h											
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFV _r	36,5	30,4	13,4	19,8	19,2	18,3	30,4	31,3	39,9	36,1	16,5	10,3
MP - SFV _r	65,0	42,9	41,2	36,5	39,3	38,9	63,0	36,1	37,3	31,3	15,1	20,4
MAE [%]												
RRRa - SFV _r	24,9	23,0	10,2	15,2	13,1	13,2	23,3	19,9	26,2	30,9	11,0	7,8
MP - SFV _r	49,2	37,1	28,1	30,4	31,4	24,8	53,0	27,5	26,2	23,6	12,5	16,7
MAPE [%]												
RRRa - SFV _r	53,4	27,9	15,7	20,8	13,3	15,1	40,6	23,2	27,1	35,1	11,6	10,0
MP - SFV _r	64,4	48,8	38,3	39,7	37,4	31,0	86,1	34,8	26,6	26,5	13,1	18,4

A aplicação do método de previsão utilizando os dados da plataforma *Open Weather* apresentou um menor desempenho em sete meses por meio das métricas RMSE e MAE quando comparada com a plataforma *Ventusky*. Para o erro MAPE, a plataforma *Open Weather* apresentou um menor desempenho em oito meses quando comparada com a plataforma *Ventusky*. No geral, a plataforma *Ventusky* apresentou um melhor desempenho que a plataforma *Open Weather* no primeiro ano (março de 2022 até fevereiro de 2023) de previsões.

A Figura 34 apresenta a influência das plataformas de previsão de tempo nas predições de FV por meio do método RRRa para o primeiro ano de predições utilizando os erros médios diários mensais.




Figura 34 - Comparação de desempenho das plataformas *Ventusky* e *Open Weather* no primeiro ano de predições utilizando os erros médios diários mensais.

A aplicação do método de predição utilizando os dados da plataforma *Ventusky* obteve melhor desempenho na maioria dos meses durante o ano. No mês de maio de 2022, as duas plataformas obtiveram praticamente os mesmos RMSE. Os melhores desempenhos de ambas as plataformas foram nos meses de maio de 2022 e janeiro e fevereiro de 2023.

5.3 PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV_r) UTILIZANDO A PLATAFORMA *VENTUSKY* NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2024

Para o segundo ano, no período de março de 2023 até fevereiro de 2024, as predições foram realizadas utilizando uma amostragem maior dos valores de PF para cada previsão do tempo. A tendência é que, conforme se amplie o intervalo de predição, a amostragem dos valores de PF aumenta e um novo valor de (\overline{PF}) é obtido com uma amostragem maior dos valores de PF.

5.3.1 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h

A Tabela 24 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso. O método RRRa apresentou valores de RMSE e MAE menores que o MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso. O MAPE do método RRRa foi menor que o MP nos perfis intermediário e chuvoso. No perfil ensolarado, nos intervalos do período da tarde, o MAPE do método RRRa foi maior que MP.

No perfil ensolarado, em comparação com o primeiro ano, os métodos RRRa e MP apresentaram novamente menores RMSE, MAE e MAPE em relação aos três perfis. O RMSE para o método RRRa foi de 0,6% a 30,2% maior quando comparado com o primeiro ano no perfil ensolarado. A maior amplitude entre as duas predições foi para o horário das 17-18h. Nos horários com maiores irradiações, o RMSE, o MAE e o MAPE ficaram próximos na predição do primeiro ano e na predição dos dois anos seguidos. Os valores de RMSE foram de 21,7% a 58,6% para o método RRRa. Para o MP, os valores de RMSE foram de 34,0% até 59,1%. Os valores de MAE e MAPE seguiram o mesmo padrão que os valores de RMSE para os dois métodos.

Tabela 24 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 1h até 10h utilizando os métodos RRRa e MP para os dois anos de predição.

	8-9h	9-10h	10-11h	11-12h	12-13h	13-14h	14-15h	15-16h	16-17h	17-18h
RMSE [%] - ENSOLARADO										
RRRa - SFVr	30,0	26,1	22,9	23,9	21,7	25,5	25,6	31,3	38,2	58,6
MP - SFVr	43,7	38,0	34,0	36,9	36,4	36,0	35,6	39,1	47,2	59,1
MAE [%] - ENSOLARADO										
RRRa - SFVr	19,2	16,0	14,0	14,8	13,5	16,2	15,8	20,7	24,5	34,3
MP - SFVr	28,6	25,2	22,5	24,8	23,8	23,2	22,6	24,8	31,5	35,4
MAPE [%] - ENSOLARADO										
RRRa - SFVr	45,8	31,1	23,6	23,8	20,3	25,3	31,2	36,1	43,9	38,7
MP - SFVr	37,8	97,4	26,7	28,4	27,2	26,1	33,3	34,8	42,5	45,7
RMSE [%] - INTERMEDIÁRIO										
RRRa - SFVr	52,4	59,7	60,5	52,4	57,0	59,1	65,1	63,7	61,3	61,0
MP - SFVr	81,4	75,0	72,8	75,0	80,2	82,3	83,3	83,1	84,1	85,5
MAE [%] - INTERMEDIÁRIO										
RRRa - SFVr	42,0	48,3	50,8	42,1	46,7	48,3	49,7	48,2	46,8	41,5
MP - SFVr	66,5	62,3	58,4	60,3	64,6	65,5	66,7	65,5	64,7	60,7
MAPE [%] - INTERMEDIÁRIO										
RRRa - SFVr	68,5	40,4	40,0	44,3	46,6	52,3	75,9	75,1	80,4	56,1
MP - SFVr	108,3	110,0	90,2	95,3	114,3	114,3	121,7	108,0	169,1	125,0
RMSE [%] - CHUVOSO										
RRRa - SFVr	44,6	43,5	56,8	47,3	57,2	67,3	64,3	89,7	120,6	123,2
MP - SFVr	156,8	168,4	205,7	191,9	125,4	134,2	97,6	120,8	174,1	146,8
MAE [%] - CHUVOSO										
RRRa - SFVr	29,5	32,5	38,8	27,0	32,3	36,0	37,8	44,5	76,6	55,6
MP - SFVr	127,7	134,8	153,1	155,1	97,8	109,0	72,4	88,5	131,5	111,5
MAPE [%] - CHUVOSO										
RRRa - SFVr	46,9	37,1	56,7	33,3	29,1	74,6	106,2	40,1	142,5	180,9
MP - SFVr	213,6	313,4	238,6	227,6	138,9	224,4	174,1	187,5	208,0	245,5

No perfil intermediário, na predição dos dois anos, o RMSE para o método RRRa foi maior na maioria dos intervalos e nos horários de menores irradiações. Nos horários de maiores irradiações, a predição dos dois anos obteve RMSE menor. Os valores de RMSE foram de 52,4% a 65,1% para o método RRRa. Para o MP, os valores de RMSE foram de 72,8% até 85,5%. Os valores de MAE e MAPE seguiram o mesmo padrão que os valores de RMSE para os dois métodos.

No perfil chuvoso, a predição de dois anos também obteve RMSE maior na maioria dos intervalos horários quando comparada com o primeiro ano de predição para o método RRRa. Os valores de RMSE foram de 43,5% a 123,2% para o método RRRa. Para o MP, os valores de RMSE foram de 97,6% até 205,7%. Os valores de MAE e MAPE seguiram o mesmo padrão que os valores de RMSE para os dois métodos.

O método RRRa apresentou maiores erros no intervalo entre 17h e 18h no perfil ensolarado. No perfil intermediário, os maiores erros foram no intervalo das 14h até as 18h. No perfil chuvoso, os maiores erros foram no intervalo das 16h até as 18h. Novamente, os maiores erros foram nos intervalos de menores irradiações.

A Figura 35 mostra que para dois anos a predição RRRa obteve novamente uma amplitude menor quando comparada com a geração e com a predição com o MP para os perfis ensolarado, intermediário e chuvoso.

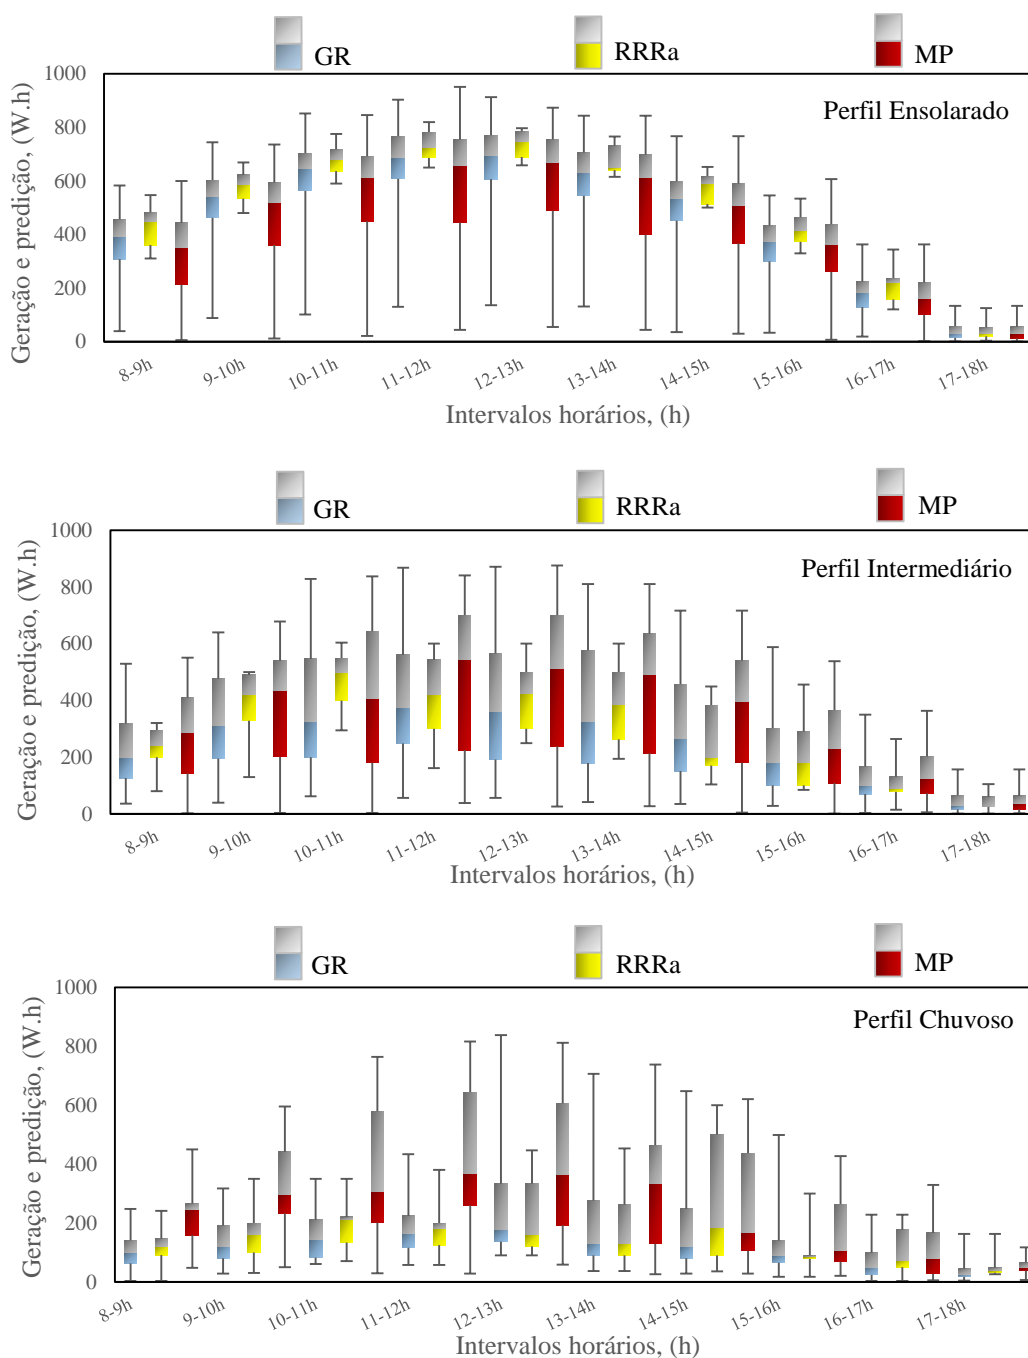


Figura 35 - Box Plot da geração e predições utilizando a plataforma *Ventusky* para os perfis nos intervalos horários para os dois anos de predições com HRT = 1h até 10h.

No perfil ensolarado, o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP. Conforme o primeiro ano, o RRRa mostrou uma correlação maior com a geração em todos os intervalos horários quando comparado com MP no perfil ensolarado. Para o perfil intermediário (Figura 35), o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP e uma correlação maior com a geração em alguns intervalos horários quando comparado com o MP. Entretanto, o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o primeiro ano. Essa menor variação é devido a uma amostragem mais consolidada e maior de valores de PF para o perfil intermediário.

Novamente, no perfil chuvoso (Figura 35), o método RRRa também apresentou uma menor variação horária anual de predição quando comparado com o MP. O RRRa apresentou amplitudes próximas e uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP. O RRRa apresentou uma correlação maior de variação horária anual com GR quando comparado com o primeiro ano de predição.

5.3.2 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h

A Tabela 25 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das 9h-10h, 12-13h e 15-16h. Para o HRT = 24h, utilizando dois anos de predição, o método RRRa também apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

O perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos três perfis. Em comparação com a predição do primeiro ano, o RMSE e o MAE foram levemente maiores. No mesmo perfil, os MAPE foram levemente menores para o segundo ano.

Tabela 25 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h, utilizando os métodos RRRa e MP para os dois anos de predição.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa - SFVr	23,5	22,7	28,5	57,2	54,3	64,2	49,7	59,1	59,4
MP - SFVr	38,7	35,8	37,8	75,9	78,2	84,0	163,6	185,8	201,9
MAE [%]									
RRRa - SFVr	14,4	14,3	19,2	46,8	48,8	49,6	32,1	40,8	34,9
MP - SFVr	24,4	23,0	24,5	62,5	61,6	66,0	135,3	154,5	134,9
MAPE [%]									
RRRa - SFVr	24,3	21,3	26,9	95,0	74,5	78,0	37,5	67,3	33,8
MP - SFVr	27,8	25,9	27,7	113,2	112,4	123,5	369,2	242,0	206,4

No perfil intermediário, os valores de RMSE foram próximos aos valores do perfil chuvoso. No intermediário, os RMSE foram levemente menores no segundo ano quando comparados com o primeiro ano. No perfil chuvoso, o segundo ano apresentou RMSE, MAE e MAPE menores nos intervalos 9-10h e 12-15h quando comparado com o primeiro ano. No intervalo 15-16h, o segundo ano apresentou RMSE, MAE e MAPE menores.

A Figura 36 mostra que, para os dois anos de predição, o RRRa também obteve uma amplitude menor quando comparado com a geração fotovoltaica real e com o MP utilizando HRT = 24h para os perfis ensolarado, intermediário e chuvoso.

No perfil ensolarado, o método RRRa apresentou novamente uma menor variação horária anual de predição e amplitudes menores quando comparado com o MP. Conforme o primeiro ano, o RRRa também mostrou uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP no perfil ensolarado para HRT = 24h.

Para o perfil intermediário (Figura 36), o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP e uma correlação maior com a geração em todos intervalos horários. Entretanto, novamente o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o primeiro ano. Essa menor variação é devido à amostragem maior de PF.

Do mesmo modo, no perfil chuvoso (Figura 36), o método RRRa também apresentou uma menor variação horária anual de predição quando comparado com o MP. O RRRa também apresentou uma correlação maior de variação horária anual com GR quando comparado com o primeiro ano de predição utilizando HRT = 24h.

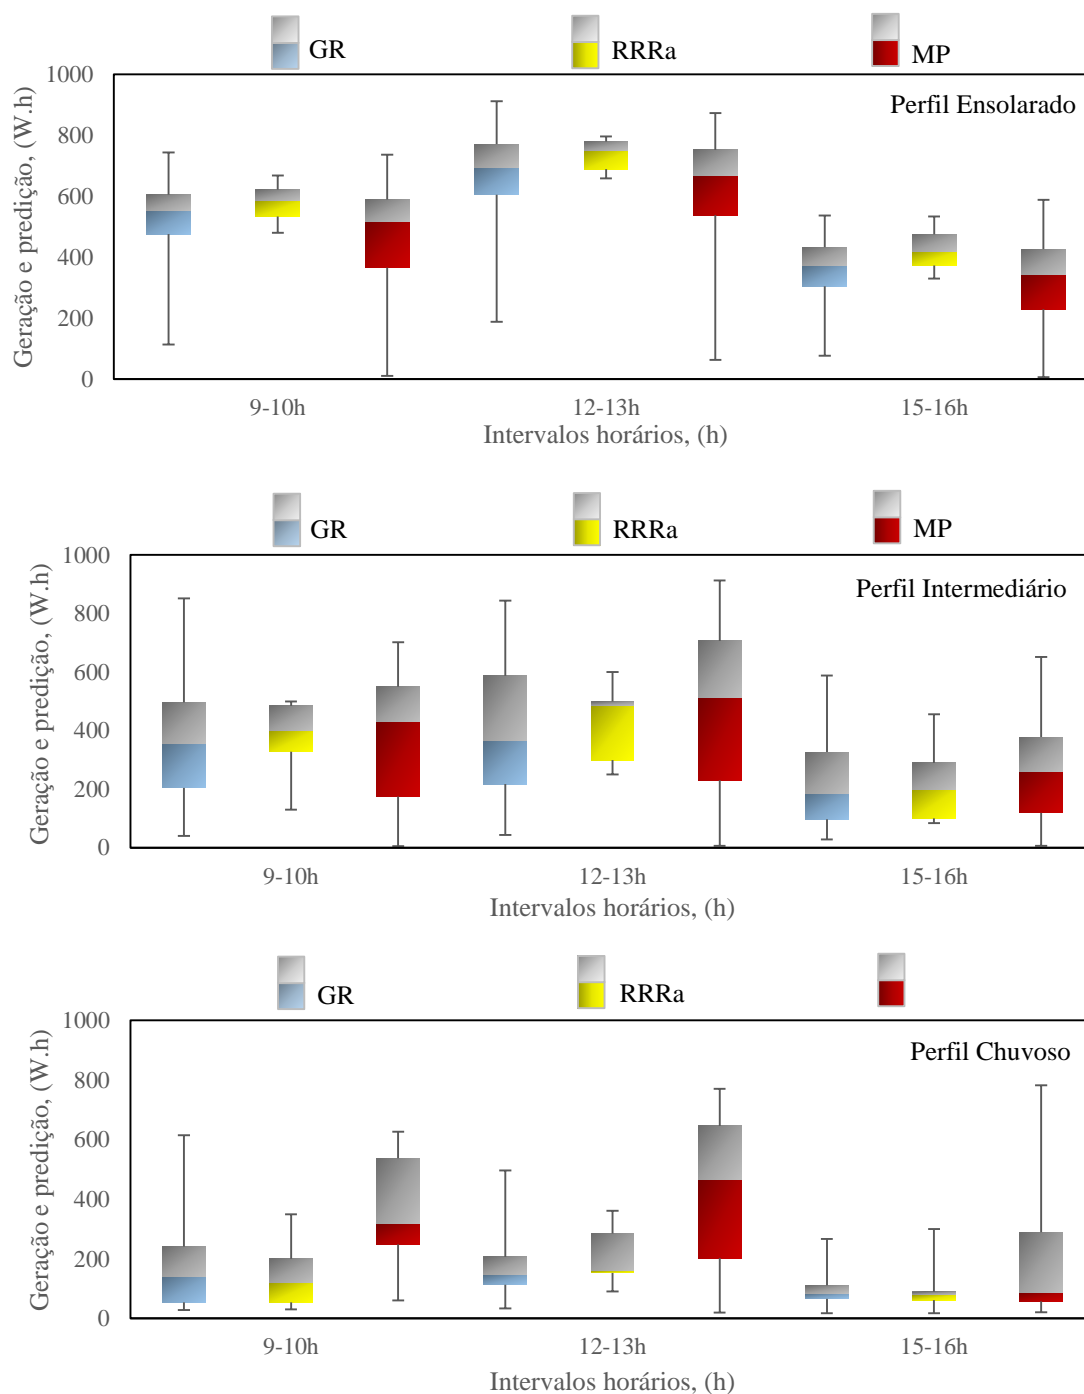


Figura 36 –Box Plot da geração e predições utilizando a plataforma *Ventusky* para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2024 para um HRT = 24h.

5.3.3 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h

A Tabela 26 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das

9h-10h, 12-13h e 15-16h. Para o HRT = 72h, utilizando dois anos de predição o método RRRa também apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

Tabela 26 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h, utilizando os métodos RRRa e MP para os dois anos de predição.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa - SFVr	24,7	22,4	30,1	55,3	50,7	61,3	118,5	66,8	78,1
MP - SFVr	41,4	38,8	38,7	79,8	81,0	79,4	234,3	157,0	152,7
MAE [%]									
RRRa - SFVr	16,1	14,7	20,1	45,1	41,3	49,1	76,7	38,8	41,9
MP - SFVr	28,3	26,1	25,2	65,3	66,1	64,7	192,5	118,4	105,2
MAPE [%]									
RRRa - SFVr	23,6	21,0	27,2	75,2	55,3	59,3	143,9	34,8	38,0
MP - SFVr	36,0	31,6	33,1	109,3	99,3	115,3	381,6	151,1	148,1

Em comparação com a predição do primeiro ano, o RMSE e o MAE foram levemente maiores no perfil ensolarado. No mesmo perfil, os MAPE foram menores para o segundo ano nos intervalos das 9-10h e 15-16h. No intervalo das 12-13h, o MAPE para o segundo ano foi levemente maior.

No perfil intermediário, ao contrário do primeiro ano, os valores de RMSE foram menores quando comparados com os valores do perfil chuvoso. No intermediário, os RMSE foram menores no segundo ano quando comparados com o primeiro ano. No perfil chuvoso, o segundo ano apresentou RMSE maiores em todos os intervalos quando comparado com o primeiro ano.

A Figura 37 mostra que utilizando HRT = 72h para os dois anos de predição o RRRa também obteve uma amplitude e uma variação horária anual menor quando comparado com GR e MP nos três perfis. No perfil ensolarado, o método RRRa apresentou novamente uma menor variação horária anual de predição e amplitudes menores quando comparado com o MP.

Conforme o primeiro ano, o RRRa também mostrou uma correlação maior com a geração em todos os intervalos horários quando comparado com o MP no perfil ensolarado para HRT = 72h.

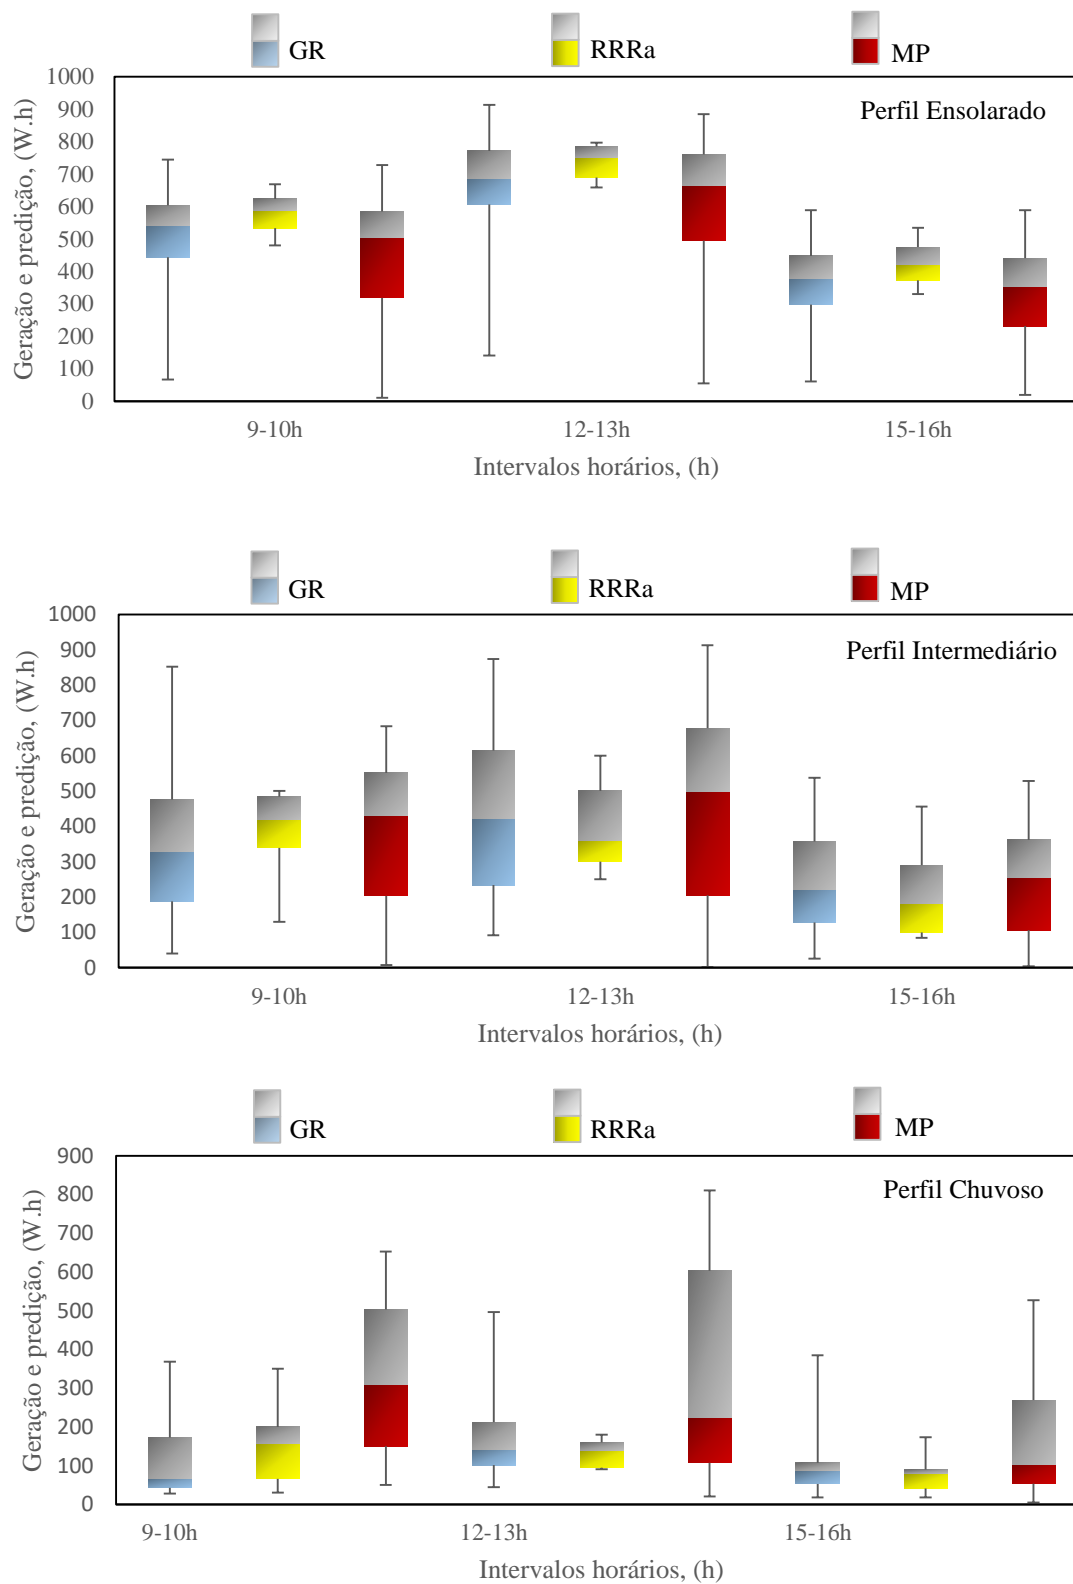


Figura 37 –Box Plot da geração e predições utilizando a plataforma *Ventusky* para os perfis nos intervalos horários dos meses de março de 2022 até fevereiro de 2024 para um HRT = 72h.

Para o perfil intermediário, o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o MP e uma correlação maior com a geração em todos intervalos horários. Contudo, o método RRRa apresentou uma menor variação horária anual de predição quando comparado com o primeiro ano.

Do mesmo modo, no perfil chuvoso, o método RRRa também apresentou uma menor variação horária anual de predição quando comparado com o primeiro ano. O RRRa também apresentou uma correlação maior de variação horária anual com GR quando comparado com o primeiro ano de predição utilizando $HRT = 72h$.

Em síntese, utilizando as predições no período de 2022 até 2024 e com uma amostragem maior de valores de PF, o método RRRa se apresentou com um desempenho próximo do período de 2022 até 2023 para as predições em intervalos horários. No perfil ensolarado, o RMSE, o MAE e o MAPE variaram levemente quando se compararam os dois anos com o primeiro ano. No perfil intermediário, o MAPE variou mais quando se compararam os dois anos com o primeiro ano. O RMSE e o MAE variaram menos. Em alguns intervalos, os dois anos de predição melhoraram o desempenho de RMSE e de MAE.

A Figura 38 apresenta a diferença dos erros RMSE, MAE e MAPE para o método RRRa no $HRT = 1h$ até $10h$, $HRT = 24h$ e $HRT = 72h$ utilizando as predições de 2022 até 2023 e 2022 até 2024.

Os valores de RMSE e MAE se mantiveram próximos nos perfis ensolarado e intermediário utilizando as predições de 2022 até 2023 e 2022 até 2024. No perfil chuvoso, o RMSE, o MAE e o MAPE aumentaram o valor utilizando as predições de 2022 até 2024 para o $HRT = 72h$. Em geral, o método RRRa se manteve com o mesmo desempenho utilizando uma amostragem maior de PF no intervalo de dois anos para as predições em intervalos horários.

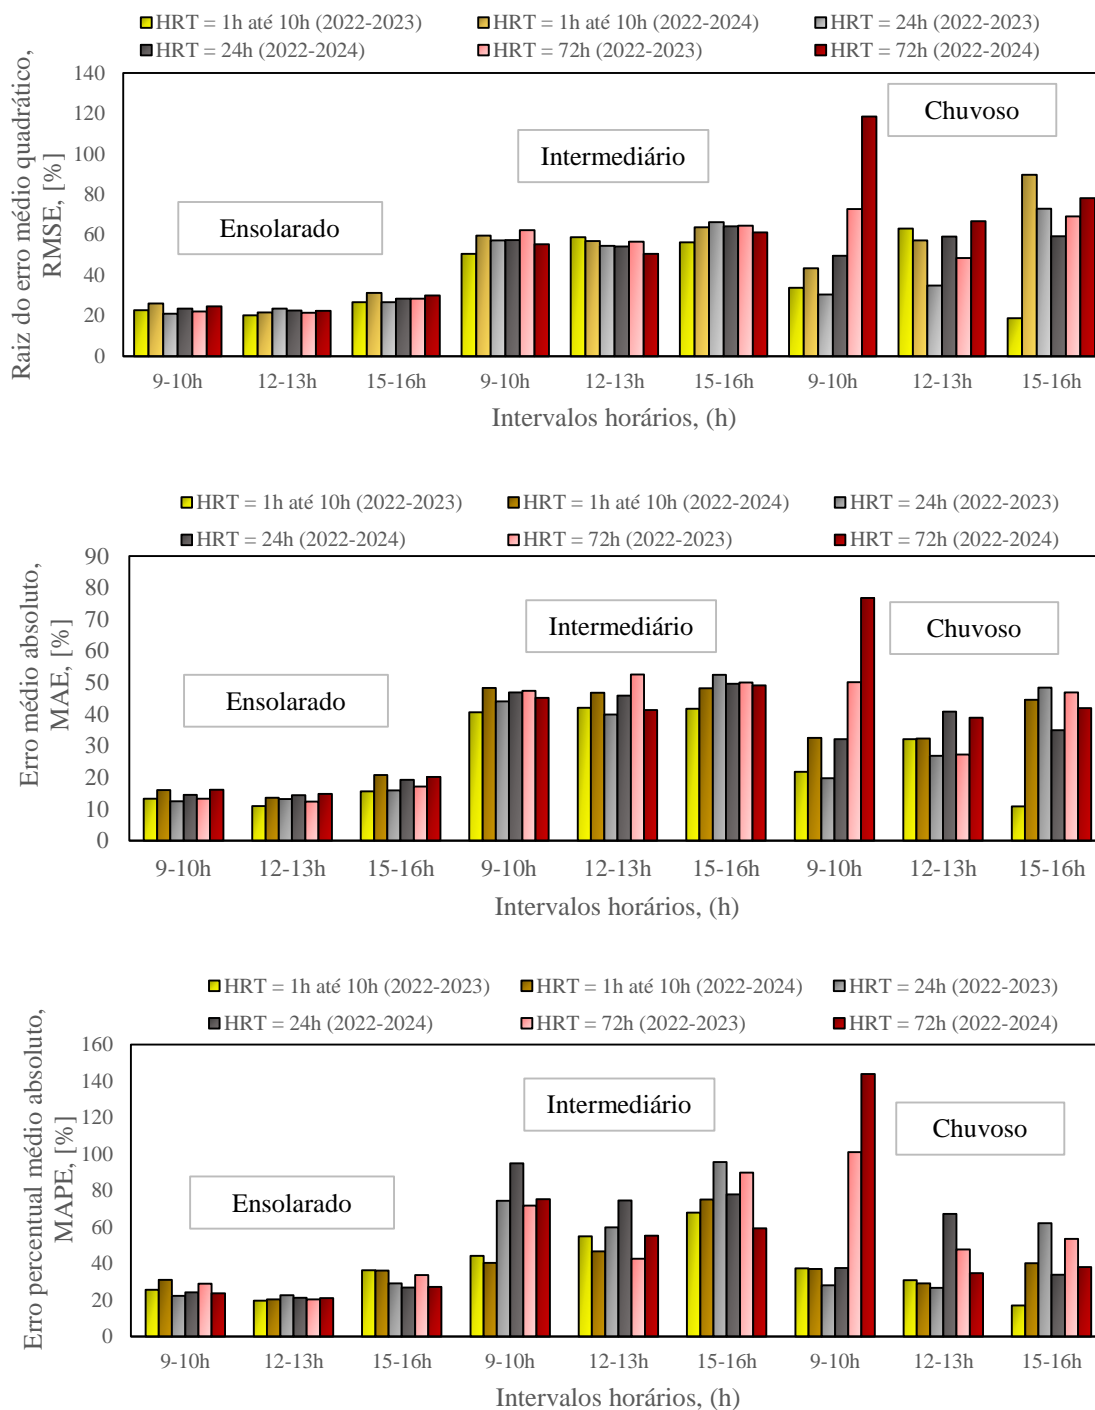


Figura 38 – Comparativo do RMSE, do MAE e do MAPE para os três perfis utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h entre 2022 até 2023 e 2022 até 2024.

5.3.4 Análise de previsão de geração fotovoltaica anual por meio dos erros médios diários

A Tabela 27 apresenta os valores obtidos de RMSE, MAE e MAPE médios diários anuais para os três perfis. O melhor desempenho do RRRa foi para o perfil

ensolarado (HRT = 1h até 10h) com RMSE médio anual de 16,7%, MAE médio anual de 12,2% e MAPE médio anual de 15,2%.

O perfil intermediário obteve um desempenho menor que os outros perfis no horizonte de HRT= 1h até 10h e HRT = 24h. Para o horizonte de HRT = 72h, o perfil chuvoso apresentou um menor desempenho. O método RRRa apresentou melhor desempenho que o MP em todos os perfis e nos três HRT utilizando as métricas RMSE e MAE. Somente para o perfil ensolarado, utilizando HRT = 72h, o MAPE foi menor no método MP comparado com o RRRa.

Tabela 27 - Erro médio diário anual RSME, MAE e MAPE para os três perfis.

PERFIS	RMSE (%) RRRa - SFV _r	MAE (%) RRRa - SFV _r	MAPE (%) RRRa - SFV _r	RMSE (%) MP - SFV _r	MAE (%) MP - SFV _r	MAPE (%) MP - SFV _r
Ensolarado *	16,7	12,2	15,2	18,7	14,4	15,7
Intermediário *	23,7	17,4	22,5	39,5	30,0	36,1
Chuvoso *	20,9	15,3	21,6	99,8	80,6	94,3
Ensolarado **	20,1	13,5	30,0	28,2	19,2	36,4
Intermediário **	37,9	30,1	37,6	50,6	40,5	53,3
Chuvoso **	28,2	20,0	20,2	140,3	112,5	158,3
Ensolarado ***	22,0	15,4	36,9	28,4	19,7	27,1
Intermediário ***	35,1	27,8	35,0	51,5	39,7	55,1
Chuvoso ***	54,2	37,8	37,5	194,6	157,6	293,9

*Horizonte de 1h até 10h.

** Horizonte de 24h.

*** Horizonte de 72h.

A Figura 39 apresenta um comparativo com o estudo de Zhu *et al.* (2015) e a comparação com o primeiro ano de predição. O método RRRa continuou apresentando melhor desempenho que o RNA de Zhu *et al.*, (2015) para o perfil chuvoso na análise de 2022 até 2024. No perfil ensolarado, para as predições de 2022 até 2024, utilizando o HRT = 1h até 10h, o método RRRa apresentou RMSE, MAE e MAPE de 1%, 2,5% e 3,3% respectivamente maiores que o primeiro ano.




Figura 39 - Comparação do método RRRa utilizando a plataforma Ventusky do período de 2022-2023 e 2022-2024 com RNA e DW + RNA de Zhu *et al.*, (2015).

No perfil intermediário, para as previsões de 2022 até 2024, utilizando o HRT = 1h até 10h, o método RRRa apresentou RMSE e MAE de 1%, 2% respectivamente menores que o primeiro ano. O MAPE foi de 2,8% maior que o primeiro ano de previsão.

No perfil chuvoso, para as previsões de 2022 até 2024, utilizando o HRT = 1h até 10h, o método RRRa apresentou RMSE, MAE e MAPE de 11%, 7% e 12,9% respectivamente maiores que o primeiro ano. No perfil chuvoso, os erros aumentaram em relação ao primeiro ano devido ao ano de 2023 ter sido muito chuvoso. O ano de 2021 e 2022 teve menos chuva em comparação com 2023. A amostragem de valores de PF para cada mês com o perfil chuvoso era relativamente pequena. A tendência é que para os próximos anos o desempenho do método RRRa aumente no perfil chuvoso e no intermediário devido ao aumento da amostragem de valores PF para cada mês.

Em relação à previsão fotovoltaica para o dia seguinte e para três dias futuros (HRT = 24h e HRT = 72h), o método RRRa apresentou um desempenho próximo para a previsão do dia (HRT = 1h até 10h). Entretanto, essa diferença da assertividade quando comparados os dois horizontes de previsão ocorre devido ao desempenho da plataforma *Ventusky*.

Em síntese, utilizando as previsões no período de 2022 até 2024 e com uma amostragem maior de valores de PF, o método RRRa se apresentou com um desempenho próximo do período de 2022 até 2023 para as previsões de geração fotovoltaica anual. No perfil ensolarado, o RMSE, o MAE e o MAPE variaram levemente quando comparados os dois anos com o primeiro ano. No geral, para o perfil intermediário, com uma amostragem maior, o método melhorou seu desempenho.

5.3.5 Análise de previsão de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h

A Tabela 28 apresenta o RMSE, o MAE e o MAPE médios diários mensais para cada mês de março de 2022 até fevereiro de 2024. As previsões mensais realizadas no período de 2022 até 2023 se mantiveram as mesmas do primeiro ano. As previsões mensais do período de março de 2023 até fevereiro de 2024 foram realizadas utilizando uma amostragem maior de valores de PF para a obtenção de um novo valor de \overline{PFP} .

Tabela 28 - RMSE, MAE e MAPE médios diários mensais para os métodos RRRa e MP com
HRT = 1h até 10h, HRT = 24h e HRT = 72h.

Horizonte de 1h até 10h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	30,4	50,1	13,7	17,8	20,5	23,3	23,7	24,1	15,7	15,3	7,3	11,8
MP - SFVr	65,0	42,9	41,2	36,5	39,3	38,9	63,0	36,1	37,3	31,3	15,1	20,4
MAE [%]												
RRRa - SFVr	20,3	38,9	11,5	12,3	14,7	16,3	20,2	17,2	8,9	12,1	5,0	7,9
MP - SFVr	49,2	37,1	28,1	30,4	31,4	24,8	53,0	27,5	26,2	23,6	12,5	16,7
MAPE [%]												
RRRa - SFVr	27,8	49,4	12,6	13,5	20,3	30,2	28,7	27,6	11,7	16,5	6,1	9,6
MP - SFVr	64,4	48,8	38,3	39,7	37,4	31,0	86,1	34,8	26,6	26,5	13,1	18,4
	Mar/23	Abr/23	Mai/23	Jun/23	Jul/23	Ago/23	Set/23	Out/23	Nov/23	Dez/23	Jan/24	Fev/24
RMSE [%]												
RRRa - SFVr	18,0	14,2	22,5	20,2	28,0	13,2	18,5	28,4	19,8	26,4	35,4	77,5
MP - SFVr	19,4	33,1	29,3	39,4	45,9	30,6	34,4	57,2	35,4	41,8	44,1	34,7
MAE [%]												
RRRa - SFVr	12,7	10,7	16,8	17,1	22,0	10,8	15,0	24,3	15,6	23,3	28,6	66,2
MP - SFVr	16,1	23,2	21,2	26,9	34,8	17,5	21,6	46,4	29,7	32,0	29,4	25,9
MAPE [%]												
RRRa - SFVr	14,7	16,2	23,5	18,4	34,9	14,1	23,4	32,8	23,3	34,7	38,6	87,2
MP - SFVr	18,3	32,5	26,9	56,2	64,5	21,4	29,1	55,4	34,0	40,8	49,2	32,0
Horizonte de 24h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	43,2	34,4	22,4	15,3	19,9	21,8	30,1	32,5	18,2	20,5	4,5	15,0
MP - SFVr	69,5	44,4	31,8	40,9	29,8	58,7	75,0	56,2	35,9	20,8	11,5	16,0
MAE [%]												
RRRa - SFVr	26,8	25,3	14,0	11,1	15,2	15,4	25,2	24,5	10,7	13,1	4,4	10,6
MP - SFVr	48,5	38,2	22,9	31,2	21,8	40,8	59,9	46,8	23,8	15,8	8,2	13,8
MAPE [%]												
RRRa - SFVr	45,4	29,1	14,5	14,7	18,0	44,9	43,5	34,0	15,5	19,5	4,4	11,6
MP - SFVr	89,0	68,4	35,6	32,5	24,2	114,0	97,3	88,3	29,1	21,2	8,2	14,7
	Mar/23	Abr/23	Mai/23	Jun/23	Jul/23	Ago/23	Set/23	Out/23	Nov/23	Dez/23	Jan/24	Fev/24
RMSE [%]												
RRRa - SFVr	16,0	14,4	24,3	26,4	21,3	21,5	15,7	26,1	30,2	32,8	37,3	62,5
MP - SFVr	30,6	34,2	37,4	44,3	38,6	31,6	45,4	56,2	59,8	41,7	46,1	37,2
MAE [%]												
RRRa - SFVr	10,1	10,7	19,1	23,3	15,0	15,1	12,5	20,2	23,8	27,3	29,7	51,3
MP - SFVr	15,0	22,9	26,0	29,5	26,6	19,0	30,4	46,4	47,6	30,7	35,2	29,1
MAPE [%]												
RRRa - SFVr	11,3	15,3	35,4	25,4	19,3	27,1	15,2	39,0	35,0	34,2	40,3	66,5
MP - SFVr	14,3	32,7	54,5	56,0	34,6	31,7	34,7	50,1	72,6	38,7	42,9	35,8
Horizonte de 72h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	29,5	36,6	28,9	28,2	20,3	24,6	29,5	36,9	23,8	13,8	14,0	16,7
MP - SFVr	68,9	52,0	44,3	51,8	26,1	48,8	66,6	59,7	40,7	15,2	15,2	18,4
MAE [%]												
RRRa - SFVr	16,6	31,1	18,2	21,8	17,1	17,5	22,5	26,2	17,8	11,1	9,6	10,9
MP - SFVr	48,2	45,6	31,8	45,8	20,9	32,0	54,1	48,2	29,7	12,1	14,5	16,0
MAPE [%]												
RRRa - SFVr	28,1	43,8	17,1	29,8	19,5	27,2	35,8	37,0	25,2	12,2	8,7	13,0
MP - SFVr	92,1	72,1	46,3	88,4	22,1	80,4	80,4	52,1	33,1	15,3	10,0	19,3
	Mar/23	Abr/23	Mai/23	Jun/23	Jul/23	Ago/23	Set/23	Out/23	Nov/23	Dez/23	Jan/24	Fev/24
RMSE [%]												
RRRa - SFVr	19,9	19,3	21,7	23,0	48,3	25,2	16,5	34,2	33,7	36,0	46,5	49,5
MP - SFVr	33,8	32,0	44,5	47,4	51,9	45,4	53,0	56,4	50,4	45,0	40,1	26,7
MAE [%]												
RRRa - SFVr	12,0	13,0	16,7	18,6	31,8	18,4	13,2	26,8	24,7	27,5	37,2	42,9
MP - SFVr	19,0	22,0	32,4	32,6	34,4	32,2	38,0	42,8	38,0	35,0	31,6	19,3
MAPE [%]												
RRRa - SFVr	12,9	15,1	36,9	19,5	59,8	30,4	17,0	36,5	34,2	35,9	50,5	48,5
MP - SFVr	19,9	30,9	69,8	59,4	65,2	49,7	47,7	44,3	40,3	43,1	36,1	19,2

Observando os valores de RMSE, MAE e MAPE mensais para os dois anos seguidos, o desempenho do método RRRa não foi melhor que o MP em todos os meses. Nos meses de janeiro e fevereiro de 2024, o método RRRa apresentou RMSE, MAE e MAPE maiores que o MP nos horizontes de HRT = 72h e para fevereiro de 2024 nos HRT = 1h até 10h, HRT = 24h. Nos meses de janeiro e fevereiro de 2024 a plataforma *Ventusky* obteve um desempenho baixo nas previsões do tempo. Em alguns dias de janeiro de 2024 a plataforma alegou sol com algumas nuvens e o dia foi chuvoso. Em fevereiro de 2024, a plataforma errou: em relação aos dias ensolarados, alegou que eram dias com sol com muitas nuvens ou totalmente nublados.

Dessa forma, esse baixo desempenho da plataforma *Ventusky* nesses dois meses trouxe uma eficiência de predição mensal menor que o método RRRa. Em suma, para os outros meses do período de 2023-2024, o método RRRa obteve um melhor desempenho que o MP. Novamente, o método RRRa está com um desempenho próximo dos desempenhos dos métodos da literatura para os meses de predição do segundo ano. Em comparação com o estudo de Dewangan *et al.* (2020), levando em consideração o primeiro mês da Usina 2, nos meses de março, abril e setembro de 2023 o método RRRa (HRT = 24h) obteve RMSE próximo de todos os métodos combinados e não combinados do estudo de Dewangan *et al.* (2020).

A Figura 40 apresenta um comparativo do método RRRa com o estudo de Dewangan *et al.* (2020).




Figura 40 – Comparativo do método RRRa com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan *et al.* (2020) por meio do horizonte de predição para o dia seguinte utilizando o período de predição de 2022 até 2024.

Observando a figura, percebe-se que o modelo RRRa apresentou desempenhos parecidos com os modelos apresentados no trabalho de Dewangan *et al.*, (2020). De forma geral, pode-se dizer que o método RRRa mostrou-se possível para a obtenção de uma predição de FV sem a presença de dados solarimétricos e com um grau aceitável de assertividade. Uma das vantagens da utilização do método é que não se precisa adicionar nenhum equipamento de medição junto aos sistemas fotovoltaicos. Por meio do método proposto, consegue-se realizar predições de FV sem equipamentos de medição de radiação solar, como piranômetros, pireliômetros e células de referência. O método proposto é parecido com o da persistência em relação ao custo, ambos são de baixo custo. Uma das vantagens do RRRa é que praticamente sem custo se consegue um melhor desempenho que o do MP.

5.4 PREDIÇÃO DA GERAÇÃO FOTOVOLTAICA NO SISTEMA FOTOVOLTAICO DE REFERÊNCIA (SFV_r) UTILIZANDO A PLATAFORMA *OPEN WEATHER* NO INTERVALO DE MARÇO DE 2022 ATÉ FEVEREIRO DE 2024

As predições de FV para os dois anos também foram realizadas utilizando a plataforma *Open Weather*.

5.4.1 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 1h até 10h

A Tabela 29 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso. Na plataforma *Open Weather*, o método RRRa apresentou valores de RMSE, MAE e MAPE menores que os do MP nos intervalos horários dos perfis ensolarado e intermediário. No perfil chuvoso, na maioria dos intervalos, o RMSE e o MAE foram menores para o RRRa quando comparados com MP. O MP apresentou melhor desempenho que o RRRa nos intervalos das 15h até 18h. O MAPE do método RRRa foi menor que o MP em todos os perfis.

No perfil ensolarado, em comparação com o primeiro ano, os métodos RRRa e MP apresentaram novamente menores RMSE, MAE e MAPE em relação aos três perfis. A plataforma *Open Weather* apresentou um desvio maior dos valores de RMSE, MAE e MAPE quando comparados os dois anos com o primeiro ano.

Tabela 29 - Erros nos 3 perfis em intervalos horários para os meses de março de 2022 até fevereiro de 2024 utilizando os métodos RRRa e MP.

	8-9h	9-10h	10-11h	11-12h	12-13h	13-14h	14-15h	15-16h	16-17h	17-18h
RMSE [%] - ENSOLARADO										
RRRa - SFVr	32,1	25,5	22,9	22,9	20,8	22,6	22,8	29,9	36,5	59,2
MP - SFVr	45,6	39,4	34,2	35,9	36,5	37,9	35,8	39,1	47,9	69,4
MAE [%] - ENSOLARADO										
RRRa - SFVr	19,8	15,5	13,5	14,0	12,8	13,9	13,8	18,3	22,6	33,0
MP - SFVr	30,4	26,4	22,2	24,0	23,4	24,0	22,3	24,7	31,7	39,4
MAPE [%] - ENSOLARADO										
RRRa - SFVr	34,6	28,5	23,6	22,4	19,2	22,3	24,4	34,4	44,5	47,9
MP - SFVr	43,4	32,2	25,7	26,5	26,3	27,8	27,2	35,3	47,4	51,2
RMSE [%] - INTERMEDIÁRIO										
RRRa - SFVr	58,4	49,2	45,2	54,2	51,0	49,4	61,8	60,7	61,2	64,4
MP - SFVr	67,6	58,6	53,7	59,2	62,4	65,1	73,0	68,2	69,9	77,8
MAE [%] - INTERMEDIÁRIO										
RRRa - SFVr	45,9	39,3	38,4	45,3	42,0	40,8	48,4	47,3	48,8	44,2
MP - SFVr	52,3	45,8	41,1	46,2	50,0	51,3	58,5	55,2	52,8	54,0
MAPE [%] - INTERMEDIÁRIO										
RRRa - SFVr	68,7	65,2	59,6	59,8	63,5	58,6	69,9	71,8	68,7	89,9
MP - SFVr	76,8	77,5	61,6	67,0	82,3	91,1	99,6	108,3	72,6	99,0
RMSE [%] - CHUVOSO										
RRRa - SFVr	82,5	81,6	78,6	75,4	77,4	80,6	78,5	87,3	77,9	103,1
MP - SFVr	126,4	118,2	100,5	103,2	83,1	94,1	82,9	77,3	79,5	88,9
MAE [%] - CHUVOSO										
RRRa - SFVr	57,3	54,9	57,1	52,5	54,9	54,0	57,8	64,4	58,0	74,7
MP - SFVr	100,2	92,9	77,8	82,2	64,9	73,6	63,2	55,9	60,7	65,0
MAPE [%] - CHUVOSO										
RRRa - SFVr	93,6	73,6	74,8	57,7	56,1	54,2	71,9	73,8	81,8	104,1
MP - SFVr	106,2	172,4	143,7	147,6	122,9	142,3	109,3	120,1	107,7	112,0

O RMSE para o método RRRa foi de 5,9% a 21,1% maior quando comparado com o primeiro ano no perfil ensolarado. A maior amplitude entre as duas previsões foi para o horário das 17-18h. Nos perfis intermediário e chuvoso, o RMSE foi maior na maioria dos intervalos para os dois anos quando comparado com o primeiro ano.

Após os dois anos de previsão, no perfil ensolarado, a plataforma *Open Weather* apresentou praticamente o mesmo desempenho que a plataforma *Ventusky*. No perfil intermediário, a plataforma *Open Weather* apresentou melhor desempenho quando comparada com a *Ventusky*. No perfil chuvoso, a *Ventusky* foi a que apresentou melhores desempenhos. A Figura 41 mostra que para dois anos a previsão RRRa obteve novamente uma amplitude menor quando comparada com a geração e a previsão utilizando o MP para os perfis ensolarado, intermediário e chuvoso.

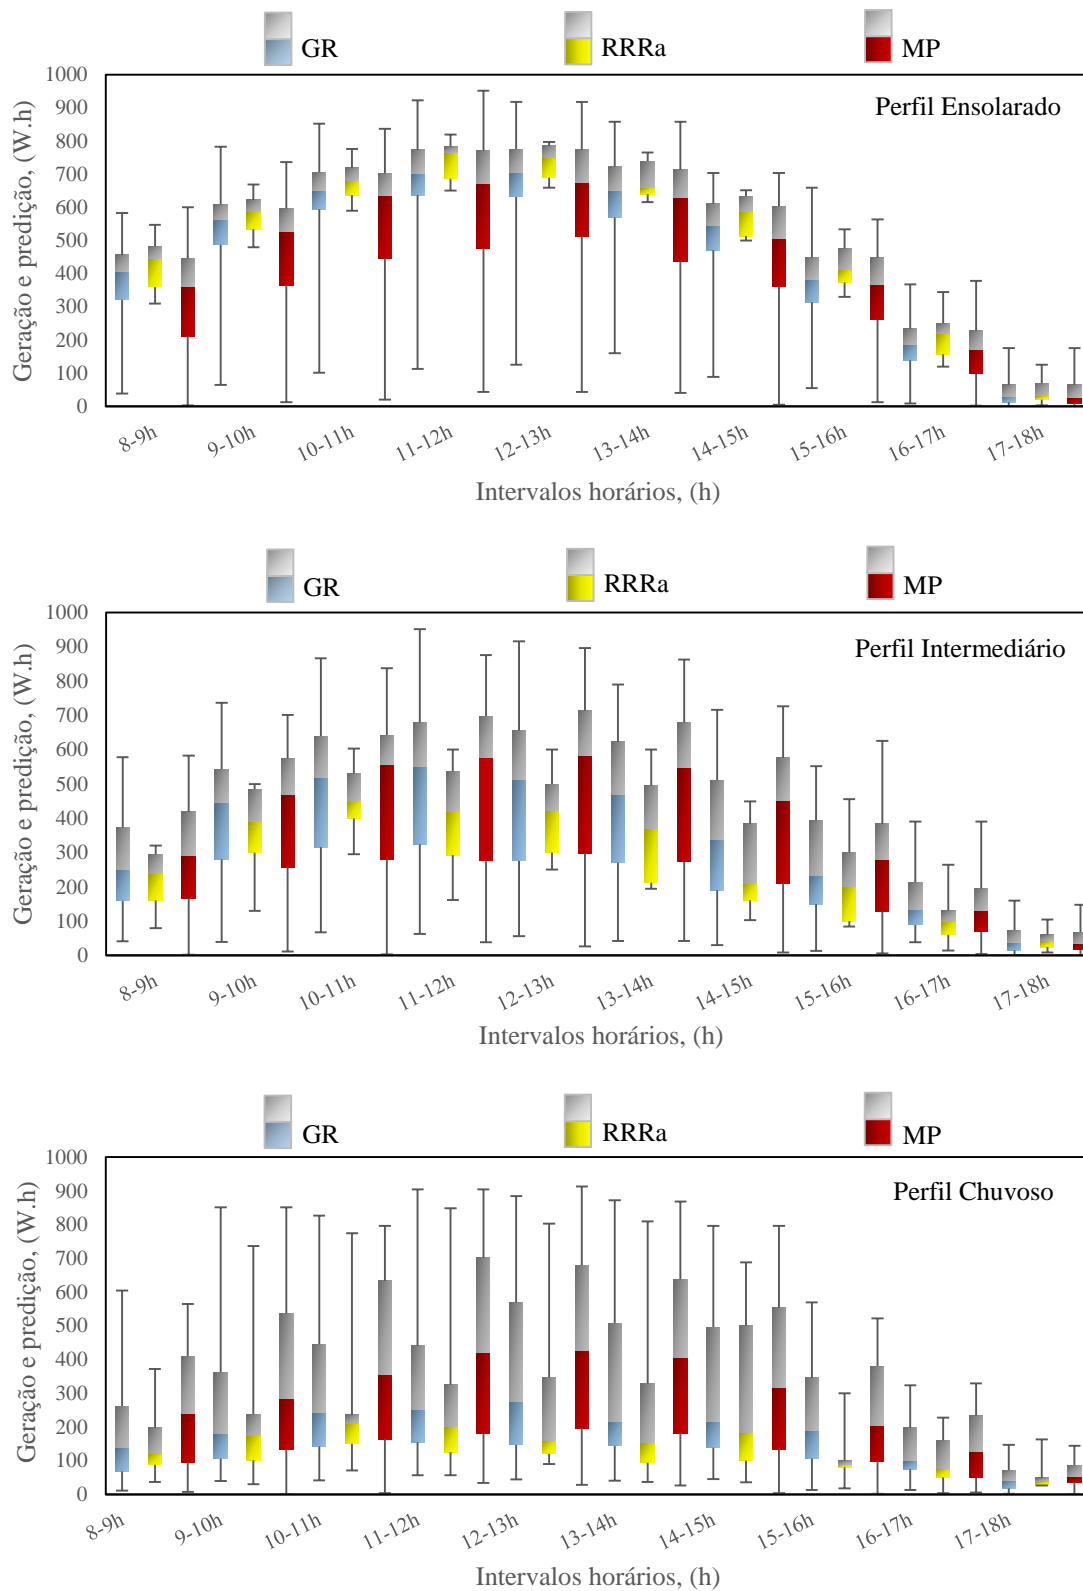


Figura 41 - Box Plot da geração e previsões utilizando a plataforma *Open Weather* para os perfis nos intervalos horários para os dois anos de previsões com HRT = 1h até 10h.

Em todos os perfis, o método RRRa apresentou uma menor variação horária anual de previsão quando comparado com o MP. Conforme o primeiro ano, para o perfil

ensolarado, o RRRa mostrou uma correlação maior com a geração em todos os intervalos horários quando comparado com MP.

Para o perfil intermediário, o método RRRa apresentou uma menor variação horária anual de predição e uma correlação maior com a geração em alguns intervalos horários quando comparado com o MP. Entretanto, o método RRRa apresentou novamente uma menor variação horária anual de predição quando comparado com o primeiro ano na maioria dos intervalos. Essa menor variação ocorre devido a uma amostragem mais consolidada e maior de valores de PF para o perfil intermediário.

Novamente, no perfil chuvoso, o método RRRa também apresentou uma menor variação horária anual de predição quando comparado com o MP. O RRRa apresentou amplitudes próximas e uma correlação maior com a geração em alguns intervalos horários quando comparado com o MP. A plataforma *Ventusky* apresentou uma correlação maior do RRRa com a GR nos intervalos horários para o perfil chuvoso.

5.4.2 Análise de predição de geração fotovoltaica anual por meio dos erros médios diários utilizando HRT = 1h até 10h

A Tabela 30 apresenta os valores obtidos de RMSE, MAE e MAPE médios diários anuais para os três perfis. O melhor desempenho do RRRa foi para o perfil ensolarado com RMSE médio anual de 15,1%, MAE médio anual de 11,1% e MAPE médio anual de 14,2%.

Tabela 30 - Erro médio diário anual RSME, MAE e MAPE para os três perfis.

PERFIS	RMSE (%)	MAE (%)	MAPE (%)	RMSE (%)	MAE (%)	MAPE (%)
	RRRa - SFV _r	RRRa - SFV _r	RRRa - SFV _r	MP - SFV _r	MP - SFV _r	MP - SFV _r
Ensolarado	15,1	11,1	14,2	19,9	14,4	15,1
Intermediário	25,5	20,2	20,8	20,6	16,5	18,2
Chuvoso	52,4	36,0	35,5	42,8	33,0	39,2

O perfil chuvoso obteve um desempenho menor que os outros perfis. O método RRRa apresentou melhor desempenho que o MP apenas no perfil ensolarado. Nos perfis intermediário e chuvoso, o método RRRa apresentou um pior desempenho que o MP utilizando a plataforma *Open Weather*.

A Figura 42 apresenta um comparativo com o estudo de Zhu *et al.* (2015) e a comparação com o primeiro ano de predição. O método RRRa utilizando a plataforma

Open Weather não apresentou melhor desempenho que o RNA e DW + RNA de Zhu *et al.*, (2015) em todos os perfis.




Figura 42 - Comparação do método RRRa utilizando a plataforma *Open Weather* do período de 2022-2023 e 2022-2024 com RNA e DW + RNA de Zhu *et al.*, (2015).

No perfil ensolarado, para as previsões de 2022 até 2024, o método RRRa apresentou RMSE, MAE e MAPE de 4,9%, 4,9% e 7,1% respectivamente maiores que o primeiro ano. No perfil intermediário, nas previsões de 2022 até 2024, o método RRRa apresentou RMSE, MAE e MAPE de 0,8%, 0,8% e 0,2% respectivamente maiores que o primeiro ano. No perfil chuvoso, nas previsões de 2022 até 2024, o método RRRa apresentou RMSE, MAE e MAPE de 11,1%, 5,2% e 4,3% respectivamente maiores que o primeiro ano.

A plataforma *Open Weather* apresentou um desempenho inferior ao da plataforma *Venstuky* para as previsões de FV anual por meio dos erros médios diários. Entretanto, utilizando as previsões no período de 2022 até 2024 e com uma amostragem maior de valores de PF, o método RRRa não se apresentou com um desempenho próximo do período de 2022 até 2023 para as previsões de geração fotovoltaica anual utilizando a plataforma *Open Weather*.

A Figura 43 apresenta a influência das plataformas de previsão de tempo nas previsões de FV através do método RRRa para o segundo ano de previsões utilizando os erros médios diários anual. No perfil ensolarado, a plataforma *Open Weather* obteve uma assertividade maior na previsão do tempo quando comparada com a *Ventusky*.




Figura 43 – Comparação de desempenho das plataformas *Ventusky* e *Open Weather* no segundo ano de predições utilizando os erros médios diários anual.

Nos perfis intermediário e chuvoso, a plataforma *Ventusky* apresentou uma assertividade maior. O RMSE e o MAE foram menores para a plataforma *Ventusky* quando comparados com a *Open Weather* nos perfis intermediário e chuvoso. O MAPE foi menor para a plataforma *Open Weather* nos perfis ensolarado e intermediário.

Consequentemente, a plataforma escolhida para realizar uma das entradas de dados da previsão do tempo no método RRRa gera um impacto no desempenho do método. Uma das maneiras de mitigar os erros no método é escolher as plataformas mais precisas de previsão do tempo.

5.4.3 Análise de previsão de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h

A Tabela 31 apresenta RMSE, MAE e MAPE médios diários mensais para cada mês de março de 2022 até fevereiro de 2024. Igualmente, na plataforma *Ventusky*, as predições mensais realizadas no período de 2022 até 2023 se mantiveram as mesmas do primeiro ano. As predições mensais do período de março de 2023 até fevereiro de 2024 foram realizadas utilizando uma amostragem maior de valores de PF para a obtenção de um novo valor de \overline{PFP} .

Tabela 31 - RMSE, MAE e MAPE médios diários mensais para os dois anos com os métodos RRRa e MP utilizando a plataforma *Open Weather*.

Horizonte de 1h até 10h												
	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23
RMSE [%]												
RRRa - SFVr	36,5	30,4	13,4	19,8	19,2	18,3	30,4	31,3	39,9	36,1	16,5	10,3
MP - SFVr	65,0	42,9	41,2	36,5	39,3	38,9	63,0	36,1	37,3	31,3	15,1	20,4
MAE [%]												
RRRa - SFVr	24,9	23,0	10,2	15,2	13,1	13,2	23,3	19,9	26,2	30,9	11,0	7,8
MP - SFVr	49,2	37,1	28,1	30,4	31,4	24,8	53,0	27,5	26,2	23,6	12,5	16,7
MAPE [%]												
RRRa - SFVr	53,4	27,9	15,7	20,8	13,3	15,1	40,6	23,2	27,1	35,1	11,6	10,0
MP - SFVr	64,4	48,8	38,3	39,7	37,4	31,0	86,1	34,8	26,6	26,5	13,1	18,4
	Mar/23	Abr/23	Mai/23	Jun/23	Jul/23	Ago/23	Set/23	Out/23	Nov/23	Dez/23	Jan/24	Fev/24
RMSE [%]												
RRRa - SFVr	19,5	14,1	20,9	24,3	29,2	16,2	16,3	26,2	26,9	30,4	41,5	75,8
MP - SFVr	19,4	33,1	29,3	39,4	45,9	30,6	34,4	57,2	35,4	41,8	44,1	34,7
MAE [%]												
RRRa - SFVr	14,9	10,5	15,1	20,4	23,6	13,1	12,6	22,1	21,9	25,3	37,9	64,4
MP - SFVr	16,1	23,2	21,2	26,9	34,8	17,5	21,6	46,4	29,7	32,0	29,4	25,9
MAPE [%]												
RRRa - SFVr	15,9	18,5	17,7	21,8	33,0	16,3	16,8	31,0	23,3	37,6	48,7	87,7
MP - SFVr	18,3	32,5	26,9	56,2	64,5	21,4	29,1	55,4	34,0	40,8	49,2	32,0

Observando os valores de RMSE, MAE e MAPE mensais para os dois anos seguidos, o desempenho do método RRRa não foi melhor que o do MP em todos os meses. Nos meses de março de 2023 e fevereiro de 2024, o método RRRa apresentou RMSE, MAE e MAPE maiores que os do MP. Nos meses de março de 2023 e fevereiro de 2024, a plataforma *Open Weather* obteve um desempenho baixo nas previsões do tempo. Em suma, para os outros meses do período de 2023-2024, o método RRRa obteve um melhor desempenho que o MP.

A plataforma *Open Weather* apresentou um menor desempenho em sete meses por meio das métricas RMSE, MAE e MAPE quando comparada com a plataforma *Ventusky*. No geral, a plataforma *Ventusky* apresentou novamente um melhor desempenho de previsão que a plataforma *Open Weather* nos dois anos (março de 2022 até fevereiro de 2024).

A Figura 44 apresenta a influência das plataformas de previsão de tempo nas previsões de FV por meio do método RRRa para os dois anos de previsões utilizando os erros médios diários mensais.




Figura 44 - Comparação de desempenho das plataformas *Ventusky* e *Open Weather* no período de março de 2023 até fevereiro de 2024 utilizando os erros médios diários mensal.

A plataforma *Ventusky* obteve melhor desempenho na maioria dos meses durante o ano. No mês de abril de 2023, as duas plataformas obtiveram praticamente os mesmos RMSE. Os melhores desempenhos de ambas as plataformas foram nos meses de março, abril, agosto e setembro de 2023.

Outra vantagem que o método RRRa apresenta é que, quando não tiver os dados de geração do local em que se deseja realizar as previsões, consegue-se realizar por meio de dados de um SFV próximo. Uma vez que a PFV em um determinado local tenha sido concluída, podemos usar correlações com os índices de desempenho e aplicar a metodologia para realizar a previsão em qualquer local do planeta para qualquer configuração, orientação e tecnologia de SFV.

A plataforma escolhida para a validação do método RRRa no SFCR do IFSC foi a plataforma *Ventusky*. Ela apresentou um desempenho melhor que a plataforma *Open Weather* e possibilita a obtenção da previsão do tempo com $HRT = 24h$ e $HRT = 72h$.

O método RRRa mostrou que se consegue desenvolver um método de previsão de FV utilizando como entrada dois blocos de dados de natureza diferente, sendo eles a previsão do tempo e o histórico de geração real de um SFV no local em que se deseja realizar a previsão.

5.5 ANÁLISE DE PRODUTIVIDADE DO SISTEMA (Y_F) DOS SUBSISTEMAS e SFV_T DO IFSC

O índice de desempenho utilizado no trabalho foi a produtividade do sistema (Y_F). A Y_F foi determinada na base mensal para os Sub 1, Sub 2, Sub 3, Sub 4, Sub 5 e SFV_T .

5.5.1 Índice de mérito de desempenho Y_F do Sub 1 e do Sub 2 do IFSC

A primeira análise é dos subsistemas que possuem a mesma orientação e FDI diferente. As figuras 45 e 46 apresentam os valores mensais do índice Y_F dos Sub 1 e Sub 2 respectivamente para os anos de 2018, 2019, 2020, 2021, 2022 e 2023.

Analisando essas figuras, pode-se observar que os subs apresentam uma maior Y_F nos meses de janeiro, fevereiro, novembro e dezembro e uma menor Y_F nos meses de junho e julho. Esse comportamento é devido a Y_F possuir uma correlação com a irradiação.




Figura 45 – Índice de Y_F mensais do Sub 1 nos anos de 2018 até 2023.

Analisando a Figura 45, pode-se observar que quando comparado o ano de 2019 com os outros anos, o Sub 1 apresentou uma Y_F menor nos meses de abril e maio. Essa Y_F menor ocorre devido à irradiação solar de 2019 ter sido menor em comparação com os outros anos.

Quando comparado o ano de 2023 com os outros anos, o Sub 1 e o Sub 2 apresentaram uma Y_F menor nos meses de setembro até dezembro. Essa Y_F menor ocorreu devido à ocorrência de muitas chuvas nesses meses.

Analisando a Figura 46, pode-se observar que o Sub 2 também apresenta uma maior Y_F nos meses de janeiro, fevereiro, novembro e dezembro e uma menor Y_F nos meses de junho e julho. Outra análise que pode ser destacada é que o Sub 2 tem uma Y_F menor nos meses de verão quando comparado com a produtividade do Sub 1 (tabelas 32 e 33).




Figura 46 – Índice de Y_F mensais do Sub 2 nos anos de 2018 até 2023.

Essa menor produtividade é consequência do FDI que implica maior ocorrência dos períodos de sobrepotência. No período em que ocorre a sobrepotência, verifica-se também uma redução de corrente elétrica na entrada do inversor. A razão é que em valores acima de 850 W/m^2 o inversor do Sub 2 opera em sua potência máxima de saída, por medida de segurança o inversor sai do Ponto de Máxima Potência (PMP) em direção à tensão de circuito aberto (V_{OC}), reduzindo a corrente elétrica em sua entrada e aumentando a tensão. O inversor subdimensionado apresenta maiores frequências de sobrepotência e, conseqüentemente, atinge maiores níveis de temperatura de operação, o que pode reduzir a vida útil do inversor.

Analisando a Figura 47, o Sub 2 apresentou uma menor variação mensal anual do indicador de desempenho Y_F em todos os seis anos.




Figura 47 - Y_F em base mensal para os dois subsistemas nos anos de 2018 até 2023.

O Sub 2 apresentou a menor variação mensal anual, com um valor de $70,53 \text{ kWh/kWp}$, enquanto o Sub 1 apresentou a menor variação de $75,87 \text{ kWh/kWp}$, ambas em 2020. A maior variação mensal anual foi em 2019, o Sub 1 apresentou uma variação de $106,28 \text{ kWh/kWp}$ enquanto o Sub2, uma variação de $103,26 \text{ kWh/kWp}$.

O Sub 1 apresentou um valor máximo de $167,81 \text{ kWh/kWp}$ em 2019. O valor máximo do Sub 2 também foi em 2019, $165,72 \text{ kWh/kWp}$. O valor mínimo foi de $47,97 \text{ kWh/kWp}$ para o Sub 1 em 2022. O valor mínimo para o Sub 2 foi de $49,77 \text{ kWh/kWp}$ em 2022.

As tabelas 32 e 33 apresentam os valores de Y_F mensais para o Sub 1 e o Sub 2 nos anos de 2018 até 2023. Elas também apresentam os valores totais de Y_F para cada ano, à média (\bar{x}) e o desvio-padrão (S). O Sub 1 (Tabela 32) apresentou a menor média

de Y_F para o ano de 2023 com um valor de 91,94 kWh/kWp. A maior média foi para o ano de 2018 com um valor de 107,92 kWh/kWp.

Analisando as tabelas 32 e 33, pode-se observar que, com o passar dos anos, a média de Y_F diminui. Essa diminuição é devido aos módulos fotovoltaicos dos subsistemas não terem passado por um processo de limpeza. Outro efeito que diminui a Y_F ao longo dos anos é a degradação dos módulos.

Para o Sub 1 e o Sub 2, pode-se observar que a média de Y_F diminui com um impacto maior nos três últimos anos. Analisando as tabelas 32 e 33, pode-se observar que a Y_F anual para ambos os subsistemas está variando entre 1.103,30 kWh/kWp e 1.295,00 kWh/kWp. De acordo com Pereira *et al.*, (2017), pode-se observar, no mapa de potencial de geração, que para o sul do estado de Santa Catarina o potencial de geração solar fotovoltaica em termos de produtividade anual varia de 1.200,00 kWh/kWp a 1.300,00 kWh/kWp, considerando sistemas fotovoltaicos com uma *Performance Ratio* (P_R) de 80%.

Tabela 32 – Y_F do sistema em base mensal do Sub 1.

Sub 1						
MESES	2018	2019	2020	2021	2022	2023
	Y_F	Y_F	Y_F	Y_F	Y_F	Y_F
	(kWh/kWp)	(kWh/kWp)	(kWh/kWp)	(kWh/kWp)	(kWh/kWp)	(kWh/kWp)
JAN	126,84	137,45	136,68	114,81	134,06	140,30
FEV	132,11	114,98	123,85	126,11	128,91	115,61
MAR	115,50	107,62	134,36	101,45	95,00	118,14
ABR	113,20	85,72	113,58	101,89	79,71	90,17
MAI	90,06	61,52	95,44	85,52	70,22	78,18
JUN	69,16	68,97	60,81	52,76	47,97	62,06
JUL	68,44	66,12	71,17	82,10	62,60	63,21
AGO	94,54	92,07	84,42	67,05	76,48	87,34
SET	83,19	87,82	74,97	78,95	86,67	73,63
OUT	105,31	97,57	111,03	98,37	94,51	70,67
NOV	139,93	133,93	112,52	116,70	121,96	89,32
DEZ	156,74	167,81	119,72	131,49	132,27	114,67
TOTAL	1.295,00	1.221,58	1.238,54	1.157,20	1.130,36	1.103,30
\bar{x}	107,92	101,80	103,21	96,43	94,19	91,94
S	27,98	32,20	5,29	23,97	29,10	24,92

Analisando a Y_F anual para o Sub 1 e o Sub 2, percebe-se que o Sub 1 com o FDI maior não necessariamente apresenta menores produtividades. Observando o ano de 2018, o Sub 1 apresentou uma Y_F anual de 1295,00 kWh/kWp enquanto a Y_F anual do Sub 2 foi de 1276,89 kWh/kWp.

Em 2021 e em 2022, o Sub 1 apresentou uma Y_F anual de 1.157,20 kWh/kWp e 1.130,36 kWh/kWp enquanto a Y_F anual do Sub 2 foi de 1.142,56 kWh/kWp e 1.126,80 kWh/kWp, respectivamente.

Tabela 33 – Y_F do sistema em base mensal do Sub 2.

Sub 2						
MESES	2018	2019	2020	2021	2022	2023
	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)
JAN	123,56	134,71	134,41	109,98	132,02	138,33
FEV	127,39	112,96	121,01	115,39	126,68	115,13
MAR	115,33	107,40	133,82	101,51	94,47	117,87
ABR	113,86	86,09	114,34	102,62	79,69	90,91
MAI	91,76	62,46	97,29	87,27	70,97	79,40
JUN	71,57	71,93	63,88	54,91	49,77	64,48
JUL	69,83	68,80	74,23	84,35	63,97	65,09
AGO	95,28	93,33	86,41	67,76	77,33	88,62
SET	83,41	89,21	77,58	79,09	87,45	74,27
OUT	102,66	98,25	113,20	97,57	94,34	71,48
NOV	129,36	132,44	111,98	114,69	120,15	90,24
DEZ	152,86	165,72	118,99	127,42	129,95	115,22
TOTAL	1276,89	1223,30	1247,15	1.142,56	1.126,80	1.111,04
\bar{x}	106,41	101,94	103,93	95,21	93,90	92,58
S	25,20	30,57	23,61	21,24	27,64	23,90

Em 2019 e em 2022, a Y_F anual dos dois subsistemas foi similar, com um valor de 1.221,58 kWh/kWp e 1.130,36 kWh/kWp, respectivamente para o Sub 1, e um valor de 1.223,30 kWh/kWp e 1.126,80 kWh/kWp, respectivamente para o Sub 2. Segundo Scarabelot (2020), os inversores atuais apresentam elevadas eficiências em praticamente todos os níveis de carregamento. Scarabelot (2020) comprovou a mudança no comportamento dos inversores em questões de eficiência média, sendo que, em inversores da década de 90, as maiores eficiências eram encontradas em cenários de subdimensionamento do inversor.

5.5.2 Índice de mérito de desempenho Y_F do Sub 3 e do Sub 5 do IFSC

A segunda análise é dos subsistemas que possuem a mesma orientação e FDI igual. As figuras 48 e 49 apresentam os valores mensais do índice Y_F dos Sub 3 e Sub 5 respectivamente para os anos de 2018, 2019, 2020, 2021, 2022 e 2023.

Analisando as figura 48 e 49 e as tabelas 34 e 35, pode-se observar que o Sub 3 tem uma maior produtividade em praticamente todos os meses no ano de 2018 quando comparado com a produtividade do Sub 5. No ano de 2019 e 2020, o Sub 3 obteve uma produtividade maior somente entre os meses de fevereiro e maio.




Figura 48 – Índice de Y_F mensais do Sub 3 nos anos de 2018 até 2023.

Analisando a Figura 49, pode-se observar que o Sub 5 apresenta valores de Y_F muito próximos do Sub 3. A média anual dos seis anos do Y_F para o Sub 5 (Tabela 35) é de 1.160,10 (kWh/kWp) enquanto para o Sub 3 (Tabela 34) é de 1.179,06 (kWh/kWp). A diferença da média anual dos seis anos é de 18,96 (kWh/kWp) entre os dois subsistemas.




Figura 49 – Índice de Y_F mensais do Sub 5 nos anos de 2018 até 2023.

Nos anos 2021, 2022 e 2023, o Sub 3 tem uma maior produtividade em praticamente todos os meses quando comparado com a produtividade do Sub 5. Essas diferenças acontecem devido às perdas por incompatibilidade na associação dos módulos fotovoltaicos em ambos os subsistemas, já que ambos possuem a mesma inclinação, orientação e FDI.

Analisando a Figura 50, percebe-se que o Sub 3 e o Sub 5 estão com os valores mínimos e máximos próximos quando comparados um com o outro em todos os anos. O

Sub 3 apresentou uma maior variação diária anual do indicador de desempenho Y_F nos anos de 2018 e 2022 quando comparado com o Sub 5. Em 2019, o Sub 5 apresentou uma maior variação que o Sub 3. Em 2021, ambos os subsistemas apresentaram uma menor variação diária de Y_F .

O Sub 5 apresentou a menor variação mensal anual, com um valor de 81,02 kWh/kWp, enquanto o Sub 3 apresentou a menor variação de 81,19 kWh/kWp, ambos em 2020. A maior variação mensal anual foi em 2019. O Sub 5 apresentou uma variação de 113,93 kWh/kWp enquanto o Sub 3, uma variação de 113,65 kWh/kWp.

O Sub 3 apresentou um valor máximo de 172,57 kWh/kWp em 2019. O valor máximo do Sub 5 também foi em 2019, 171,92 kWh/kWp. O valor mínimo foi de 44,73 kWh/kWp para o Sub 5 em 2022. O valor mínimo para o Sub 3 foi de 45,27 kWh/kWp em 2022.




Figura 50 - Y_F em base mensal para os dois subsistemas nos anos de 2018 até 2023.

As tabelas 34 e também apresentam os valores totais de Y_F para cada ano, a média (\bar{x}) e o desvio-padrão (S). Analisando essas tabelas, pode-se observar que entre os seis anos a $Y_{F\text{anual}}$ para o Sub 3 está variando entre 1.093,85 kWh/kWp e 1.295,53 kWh/kWp. Para o Sub 5, a Y_F anual variou entre 1.066,55 kWh/kWp e 1.277,52 kWh/kWp nos seis anos analisados.

A diferença de Y_F anual, quando comparado o Sub 3 com o Sub 5 em 2018, foi de 18,01 kWh/kWp. A menor diferença entre os dois subsistemas foi de 9,28 kWh/kWp em 2020. A maior diferença entre os dois subsistemas foi de 27,30 kWh/kWp em 2023.

Tabela 34 – Y_F do sistema em base mensal do Sub 3.

Sub 3						
MESES	2018	2019	2020	2021	2022	2023
	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)
JAN	138,62	140,51	139,47	116,84	137,35	144,94
FEV	134,42	116,76	124,78	128,67	130,99	118,53
MAR	115,02	107,54	132,27	100,77	94,61	117,36
ABR	108,80	83,04	108,83	96,56	77,37	87,35
MAI	84,21	58,92	90,13	78,52	65,86	73,60
JUN	65,46	64,71	58,28	49,03	45,27	58,68
JUL	64,20	62,12	66,74	73,29	57,58	59,69
AGO	89,04	85,94	79,46	62,45	71,33	82,32
SET	80,99	86,05	73,59	76,29	84,49	72,15
OUT	105,42	97,34	109,42	97,87	94,59	71,25
NOV	147,59	135,82	113,43	118,44	124,97	91,18
DEZ	161,76	172,57	121,99	135,38	136,74	116,80
TOTAL	1.295,53	1.211,32	1.218,39	1.134,11	1.121,15	1.093,85
\bar{x}	107,96	100,94	101,53	94,51	93,43	91,15
S	32,37	35,12	27,10	27,13	32,20	27,29

Tabela 35 – Y_F do sistema em base mensal do Sub 5.

Sub 5						
MESES	2018	2019	2020	2021	2022	2023
	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)
JAN	137,51	138,57	139,46	116,59	133,15	142,34
FEV	133,49	114,89	124,66	127,41	127,88	116,11
MAR	112,83	104,58	128,75	98,03	90,93	113,55
ABR	105,93	79,89	104,23	91,59	74,37	83,68
MAI	83,50	57,99	87,01	76,72	64,39	72,21
JUN	65,12	64,70	58,44	48,95	44,73	57,96
JUL	63,71	62,57	66,81	72,67	57,14	58,22
AGO	87,06	84,91	78,51	61,76	70,07	78,78
SET	79,36	85,86	74,15	74,94	82,92	68,97
OUT	104,02	97,23	111,01	96,87	93,74	69,50
NOV	145,92	134,98	114,18	116,39	123,19	89,80
DEZ	159,08	171,92	121,92	130,59	134,32	115,43
TOTAL	1.277,52	1.198,10	1.209,11	1.112,51	1.096,83	1.066,55
\bar{x}	106,46	99,84	100,76	92,71	91,40	88,88
S	31,96	34,87	26,85	26,39	31,38	26,95

Percebe-se que essa diferença é relativamente pequena, na ordem de 1% a 2%. Ela acontece devido às perdas por incompatibilidade na associação dos módulos fotovoltaicos em ambos os dois subsistemas.

5.5.3 Índice de mérito de desempenho Y_F do Sub 4 e do SFV_T do IFSC

A terceira análise é do sistema fotovoltaico total (SFV_T) e do Sub 4, que possuem duas orientações (-9° Norte e Oeste) e com o FDI próximo dos Sub 1, Sub 3 e Sub 5. As

figuras 51 e 52 apresentam os valores mensais do índice Y_F do Sub 4 e do SFV_T respectivamente para os anos de 2018, 2019, 2020, 2021, 2022 e 2023.




Figura 51– Índice de Y_F mensais do Sub 4 nos anos de 2018 até 2023.




Figura 52 – Índice de Y_F mensais do SFV_T nos anos de 2018 até 2023.

Analisando essas figuras, pode-se observar que o Sub 4 e o SFV_T também apresentaram uma maior Y_F nos meses de janeiro, fevereiro, novembro e dezembro e uma menor Y_F nos meses de junho e julho. Outra análise que pode ser destacada é que o Sub 4 e o SFV_T apresentam uma Y_F menor quando comparados com os outros subsistemas no ano de 2019 nos meses de março, abril, maio, junho, julho e agosto. Essa menor produtividade é consequência de uma *string* do Sub 4 ter ficado desconectada do arranjo do subsistema nesse intervalo de tempo.

As tabelas 36 e 37 também apresentam os valores totais de Y_F para cada ano, a média (\bar{x}) e o desvio-padrão (S). Analisando essas tabelas, pode-se observar que entre os

seis anos a Y_F anual para o Sub 4 está variando entre 1.010,90 kWh/kWp e 1.332,00 kWh/kWp. Para o SFV_T, a Y_F anual variou entre 1.101,63 kWh/kWp e 1.291,43 kWh/kWp nos seis anos analisados.

Tabela 36 – Y_F do sistema em base mensal do Sub 4.

Sub 4						
MESES	2018	2019	2020	2021	2022	2023
	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)
JAN	139,91	142,17	142,17	119,16	137,69	146,07
FEV	136,63	118,28	127,19	129,92	131,92	119,46
MAR	118,28	71,16	137,45	103,32	96,76	121,13
ABR	114,27	44,21	114,58	101,30	80,07	91,18
MAI	90,15	31,74	96,19	85,03	69,85	78,57
JUN	70,25	36,66	62,32	52,94	48,58	63,39
JUL	68,90	34,82	72,08	80,34	62,47	63,74
AGO	94,76	47,57	84,92	66,87	76,51	87,09
SET	84,91	75,55	77,55	79,88	88,53	74,63
OUT	107,60	99,40	114,18	100,38	97,85	72,47
NOV	144,22	138,03	116,06	119,91	126,94	93,00
DEZ	162,11	171,31	123,68	136,26	138,17	118,85
TOTAL	1.332,00	1.010,90	1.268,37	1.175,31	1.155,34	1.129,58
\bar{x}	111,00	84,24	105,69	97,94	96,28	94,13
S	30,30	48,50	26,47	25,70	30,92	26,46

Tabela 37 – Y_F do sistema em base mensal do SFV_T.

SFV_T						
MESES	2018	2019	2020	2021	2022	2023
	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)	Y_F (kWh/kWp)
JAN	132,41	138,32	138,07	114,98	134,59	142,02
FEV	132,31	115,33	124,00	124,60	129,04	116,80
MAR	115,37	100,46	133,36	101,05	94,35	117,62
ABR	111,43	76,82	111,38	103,14	81,52	88,84
MAI	88,26	55,32	93,56	83,01	68,49	76,65
JUN	68,59	62,42	61,01	51,99	47,48	61,58
JUL	67,25	59,85	70,55	79,05	61,02	62,25
AGO	92,40	82,00	83,05	65,40	74,60	85,15
SET	82,45	85,53	75,73	77,93	86,13	72,86
OUT	104,79	97,98	111,88	98,14	94,93	71,10
NOV	138,17	134,80	113,48	116,99	123,14	90,66
DEZ	158,00	166,79	121,05	131,79	133,89	116,10
TOTAL	1.291,43	1.205,40	1.237,12	1.148,07	1.129,18	1.101,63
\bar{x}	107,62	100,45	103,09	95,67	94,09	91,80
S	28,87	33,16	25,62	24,56	29,86	25,69

A menor diferença de Y_F anual entre os dois subsistemas foi de 27,24 kWh/kWp em 2021. A maior diferença entre os dois subsistemas foi de 164,72 kWh/kWp em 2019.

Analisando a média anual de Y_F dos subsistemas e do sistema total, pode-se observar que no primeiro ano de geração (2018) todos os subsistemas (e por consequência

o sistema total) apresentaram uma média de Y_F maior quando comparados com os outros anos. A Y_F foi diminuindo gradativamente ao longo dos anos para todos os subsistemas devido a não limpeza dos módulos fotovoltaicos e à degradação dos módulos.

Em geral, nos três primeiros anos, a produtividade anual dos subsistemas está de acordo com Pereira *et al.*, (2017). Somente para o segundo ano (2019) o Sub 4 apresentou uma Y_F anual menor que os outros subsistemas devido à *string* desconectada do arranjo do sistema. Nos outros anos, a Y_F anual começou a diminuir devido ao acúmulo de sujeira nos módulos e à própria degradação.

5.6 VALIDAÇÃO DO MÉTODO NO Sub 1 E NO Sub 5 DO IFSC

Os subsistemas que foram escolhidos para a realização da validação do método RRRa foram os Sub 1 e Sub 5. O intuito de escolher o Sub 1 e o Sub 5 foi apresentar que o método RRRa pode ser aplicado para qualquer orientação e configuração de sistemas fotovoltaicos.

Por meio da correlação com a produtividade do sistema (Y_F), pode-se determinar o valor do (\overline{PFP}) para o local em que se deseja realizar a predição fotovoltaica (\overline{PFP}_{PVS}). O valor de \overline{PFP}_{PVS} foi determinado em intervalos horários por meio das equações 4.2 e 4.3 utilizando os valores corrigidos após os dois anos de predições no SFVr. Entretanto, foram escolhidos quatro meses aleatórios para realizar as predições dos Sub 1 e Sub 5. Os meses escolhidos foram maio de 2022, fevereiro de 2023, agosto de 2023 e novembro de 2023. As estações do ano são representadas por cada mês.

A Tabela 38 apresenta os Y_F do SFVr para os anos de 2021 e 2022.

Tabela 38 – Y_F do SFVr nos anos de 2021 e 2022.

Mês	Y_F 2021 (kWh/kWp)	Y_F 2022 (kWh/kWp)
Janeiro	135,01	148,35
Fevereiro	160,50	150,62
Março	106,14	114,57
Abril	143,24	84,95
Maio	127,70	119,38
Junho	96,49	94,73
Julho	132,99	103,03
Agosto	103,12	113,13
Setembro	119,78	112,99
Outubro	120,93	120,85
Novembro	144,68	163,44
Dezembro	159,68	145,27
Total	1550,26	1471,31

Para realizar a predição de geração do Sub 1 e do Sub 5 para o mês de maio de 2022, foi realizada uma correlação com a Y_F do SFVr de maio de 2021. Para realizar a predição de geração do Sub 1 e do Sub 5 para o mês de fevereiro de 2023, agosto de 2023 e novembro de 2023, foi realizada uma correlação com a Y_F do SFVr dos meses de fevereiro de 2022, agosto de 2022 e novembro de 2022.

5.6.1 Análise da predição de geração fotovoltaica horária para o Sub 1 e o Sub 5 utilizando os perfis desenvolvidos com o HRT = 1h até 10h

A Tabela 39 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso.

O método RRRa apresentou valores de RMSE, MAE e MAPE menores que o MP em todos os intervalos horários nos perfis intermediário e chuvoso. No perfil ensolarado, o método RRRa apresentou valores menores de RMSE, MAE e MAPE que o MP nos intervalos das 9h até 17h. Nos intervalos de menores irradiações, o MP obteve um melhor desempenho que o método RRRa.

No perfil intermediário, o RMSE, o MAE e o MAPE para o método RRRa foram maiores na maioria dos intervalos e nos horários de menores irradiações quando comparados com os perfis ensolarado e chuvoso para ambos os subsistemas.

Nos horários de maiores irradiações, a predição de ambos os subsistemas obteve RMSE, MAE e MAPE menores para os perfis ensolarado e intermediário. Utilizando o método RRRa, os valores de RMSE no perfil ensolarado foram de 13,9% a 77,9% para o Sub 1 e de 15,9% a 147,8% para o Sub 5. Para o MP, os valores de RMSE foram de 34,2% a 49,1% para o Sub 1 e de 34,1% a 89,6% para o Sub 5. Os valores de MAE e MAPE seguiram o mesmo padrão que os valores de RMSE para os dois métodos.

Na validação do método RRRa nos subsistemas do IFSC, o método apresentou maiores erros nos intervalos do início da manhã e fim da tarde para os perfis ensolarado e intermediário. Novamente, os maiores erros foram nos intervalos de menores irradiações. Como já comentado, os erros maiores nesses intervalos de menores irradiações não possuem um impacto energeticamente expressivo.

Tabela 39 - Erros em intervalos horários para os meses de maio de 2022, fevereiro de 2023, agosto de 2023 e novembro de 2023 utilizando os métodos RRRa e MP para o Sub 1 e o Sub 5.

	8-9h	9-10h	10-11h	11-12h	12-13h	13-14h	14-15h	15-16h	16-17h	17-18h
RMSE [%] - ENSOLARADO										
RRRa – Sub 1	77,9	28,4	17,6	13,9	17,4	21,7	24,1	35,0	37,5	61,9
RRRa – Sub 5	90,9	29,6	18,1	15,9	17,3	21,5	24,2	35,2	50,5	147,8
MP – Sub 1	41,7	37,2	34,2	34,9	35,0	39,9	40,4	35,0	38,0	49,1
MP – Sub 5	44,6	36,6	34,2	35,7	34,1	38,9	38,7	35,8	51,3	89,6
MAE [%] - ENSOLARADO										
RRRa – Sub 1	66,0	20,9	13,4	11,3	14,4	18,0	19,8	27,4	26,8	45,6
RRRa – Sub 5	86,5	22,6	14,0	12,3	14,1	17,7	20,0	26,6	31,9	115,6
MP – Sub 1	30,1	25,0	21,9	22,1	24,6	29,1	28,3	23,9	27,0	22,9
MP – Sub 5	27,8	24,4	21,9	22,8	24,4	28,4	27,7	25,6	32,4	133,3
MAPE [%] - ENSOLARADO										
RRRa – Sub 1	80,4	24,5	14,2	11,5	15,8	20,2	18,8	25,1	19,8	41,6
RRRa – Sub 5	93,6	25,4	14,5	12,7	15,2	19,5	19,2	23,8	32,1	74,3
MP – Sub 1	36,4	26,9	22,4	22,5	25,9	31,9	31,4	28,8	38,6	35,2
MP – Sub 5	29,3	25,4	22,0	22,8	25,4	31,0	30,2	29,1	39,5	35,7
RMSE [%] - INTERMEDIÁRIO										
RRRa – Sub 1	78,2	51,2	42,2	45,7	36,3	41,8	61,5	61,4	61,7	91,8
RRRa – Sub 5	78,9	50,8	41,3	44,9	36,5	41,3	64,2	61,8	62,9	93,4
MP – Sub 1	87,7	75,0	62,1	51,9	67,8	63,6	87,8	63,6	70,5	146,9
MP – Sub 5	97,6	81,0	68,7	59,5	56,7	58,9	81,7	68,2	63,3	102,5
MAE [%] - INTERMEDIÁRIO										
RRRa – Sub 1	64,9	43,4	36,6	33,8	27,3	35,9	52,1	46,5	45,4	46,7
RRRa – Sub 5	71,6	42,8	35,0	35,2	28,9	35,0	53,8	50,5	44,6	52,5
MP – Sub 1	76,4	62,7	47,3	44,0	57,9	58,2	71,2	50,7	52,0	99,3
MP – Sub 5	81,5	67,7	51,9	49,7	47,8	52,5	64,9	51,1	48,4	65,5
MAPE [%] - INTERMEDIÁRIO										
RRRa – Sub 1	87,4	67,7	51,0	48,6	36,3	45,2	75,6	55,1	61,9	52,4
RRRa – Sub 5	82,8	64,2	49,5	51,4	35,6	44,4	75,3	49,0	67,7	53,0
MP – Sub 1	88,6	88,7	60,3	49,5	66,8	69,6	104,7	73,1	132,9	154,0
MP – Sub 5	88,7	89,8	67,6	64,8	54,0	70,8	93,7	65,9	134,3	123,5
RMSE [%] - CHUVOSO										
RRRa – Sub 1	71,0	49,1	41,3	43,8	34,5	43,0	53,7	40,7	23,2	4,8
RRRa – Sub 5	66,8	50,0	42,6	33,9	34,4	43,4	36,7	20,4	19,0	3,2
MP – Sub 1	257,5	363,0	218,0	297,5	143,4	207,7	161,2	191,5	205,6	450,7
MP – Sub 5	262,0	317,1	273,6	402,4	337,2	261,6	122,8	160,6	141,1	33,5
MAE [%] - CHUVOSO										
RRRa – Sub 1	64,2	35,0	26,6	37,5	13,7	36,8	39,9	24,0	17,0	3,8
RRRa – Sub 5	55,4	36,3	28,3	30,0	34,2	37,2	26,3	12,9	12,4	2,2
MP – Sub 1	119,9	283,7	135,4	185,0	107,5	140,6	151,8	152,7	133,3	262,8
MP – Sub 5	164,6	378,5	250,7	346,9	323,5	210,4	94,1	122,1	90,3	21,9
MAPE [%] - CHUVOSO										
RRRa – Sub 1	64,8	59,3	22,0	46,0	40,1	70,1	39,2	22,1	32,8	25,0
RRRa – Sub 5	55,2	61,0	26,8	35,8	40,1	63,3	35,9	23,2	25,3	33,1
MP – Sub 1	150,4	316,6	100,9	215,4	218,9	261,1	155,7	293,9	169,8	451,6
MP – Sub 5	153,9	375,1	250,3	339,4	423,0	323,0	162,7	207,9	147,7	58,6

5.6.2 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 24h

A Tabela 40 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das 9h-10h, 12-13h e 15-16h. Para o HRT = 24h, o método RRRa apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

Tabela 40 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 24h utilizando os métodos RRRa e MP para o Sub 1 e o Sub 5.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa-Sub 1	26,4	16,5	33,7	50,4	46,7	74,6	48,7	52,0	39,2
RRRa-Sub 5	27,7	17,0	33,8	51,3	45,8	76,9	49,5	51,7	39,3
MP-Sub 1	32,9	28,0	36,5	71,0	49,8	94,7	361,3	54,9	149,2
MP-Sub 5	37,9	31,3	38,6	57,4	55,1	89,5	363,3	53,7	146,9
MAE [%]									
RRRa-Sub 1	19,9	13,5	26,9	42,5	39,0	53,8	34,4	48,4	21,7
RRRa-Sub 5	21,9	13,7	26,6	44,9	39,1	56,0	35,5	48,2	22,8
MP-Sub 1	20,2	18,7	27,5	57,8	44,6	73,6	278,8	50,1	106,9
MP-Sub 5	22,7	19,6	27,9	48,8	47,4	63,7	279,6	49,7	104,4
MAPE [%]									
RRRa-Sub 1	22,6	14,3	25,9	63,8	51,2	79,6	58,9	51,1	19,4
RRRa-Sub 5	23,1	14,4	25,0	64,7	50,8	81,6	60,4	51,1	20,1
MP-Sub 1	24,4	19,6	28,7	95,8	55,4	209,0	313,4	52,0	164,9
MP-Sub 5	23,9	19,7	27,9	68,4	57,7	166,4	316,2	51,9	155,1

O perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos três perfis para ambos os subsistemas. Em comparação com a predição do segundo ano do SFVr utilizando a plataforma *Venstuky*, os RMSE e MAE foram levemente maiores nos intervalos das 9-10h e 15-16h. No intervalo de maior irradiação (12-13h, o Sub 1 e o Sub 5 apresentaram RMSE e MAE menores que o SFVr. Para o mesmo perfil, os MAPE foram levemente menores para o Sub 1 e o Sub 5 em todos os intervalos quando comparados com SFVr. As predições para o Sub 1 e o Sub 5 mostraram que nos intervalos de menor irradiação o método RRRa se aproxima mais do MP. Nos intervalos de maior irradiação, o desempenho do método RRRa aumenta.

5.6.3 Análise da predição de geração fotovoltaica horária para os perfis desenvolvidos utilizando HRT = 72h

A Tabela 41 apresenta os valores de RMSE, MAE e MAPE horários utilizando o RRRa e o MP para os perfis ensolarado, intermediário e chuvoso nos intervalos das 9h-10h, 12-13h e 15-16h. Para o HRT = 72h, o método RRRa apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

Tabela 41 -RMSE, MAE e MAPE para os três perfis em intervalos horários com HRT = 72h utilizando os métodos RRRa e MP para o Sub 1 e o Sub 5.

	ENSOLARADO			INTERMEDIÁRIO			CHUVOSO		
	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h	9-10h	12-13h	15-16h
RMSE [%]									
RRRa-Sub 1	34,0	16,8	35,1	47,2	51,2	72,7	171,7	106,2	94,4
RRRa-Sub 5	39,0	16,8	32,4	48,3	49,6	73,0	181,1	151,9	93,2
MP-Sub 1	39,3	34,7	37,9	68,0	69,9	76,8	364,2	487,1	178,2
MP-Sub 5	39,1	34,8	33,5	78,4	70,4	78,9	365,8	472,8	174,8
MAE [%]									
RRR-Sub 1	26,7	12,6	27,2	40,9	43,5	53,8	128,5	149,8	73,5
RRR-Sub 5	26,5	12,6	23,5	41,1	42,8	54,9	162,4	151,9	73,1
MP-Sub 1	26,8	22,8	27,8	48,7	57,6	58,9	261,2	457,4	155,7
MP-Sub 5	26,6	23,1	23,7	56,7	59,1	59,4	261,6	446,9	152,4
MAPE [%]									
RRRa-Sub 1	29,0	15,2	26,0	64,0	59,8	60,7	106,3	250,2	192,1
RRRa-Sub 5	31,3	14,8	21,3	59,3	56,3	62,8	105,4	258,3	93,2
MP-Sub 1	32,1	26,0	30,9	93,5	89,0	102,6	252,2	662,5	383,6
MP-Sub 5	31,4	25,3	24,9	80,9	87,4	105,5	254,2	667,6	366,9

O perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos três perfis para ambos os subsistemas. Em comparação com a predição do segundo ano do SFVr utilizando a plataforma *Venstuky*, os RMSE e MAE foram maiores nos intervalos das 9-10h e 15-16h. No intervalo de maior irradiação (12-13h), o Sub 1 e o Sub 5 apresentaram RMSE, MAE e MAPE menores que o SFVr. Novamente, as predições para o Sub 1 e o Sub 5 mostraram que nos intervalos de menor irradiação solar o método RRRa se aproxima mais do MP. Nos intervalos de maior irradiação, o desempenho do método RRRa aumenta.

Para o perfil chuvoso, ambos os métodos (RRRa e MP) diminuem os seus desempenhos para um horizonte de HRT = 72h. As plataformas de previsão do tempo diminuem suas precisões para os dias instáveis na previsão do tempo de 72h futuras.

5.6.4 Análise de previsão de geração fotovoltaica mensal por meio dos erros médios diários utilizando HRT = 1h até 10h, HRT = 24h e HRT = 72h

A Tabela 42 apresenta os RMSE, MAE e MAPE médios diários mensais para os meses escolhidos na previsão do Sub 1 e do Sub 5. Observando os valores de RMSE, MAE e MAPE mensais, o desempenho do método RRRa foi melhor que o MP em todos os meses e nos HRT = 1h até 10h, HRT = 24h e HRT = 72h.

Tabela 42 - RMSE, MAE e MAPE médios diários mensais para os métodos RRRa e MP com HRT = 1h até 10h, HRT = 24h e HRT = 72h.

Horizonte de 1h até 10h								
	Mai/22		Fev/23		Ago/23		Nov/23	
RMSE [%]	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5
RRRa	14,6	13,6	11,1	11,6	15,2	16,8	23,9	23,0
MP	41,4	40,0	22,2	21,8	36,9	33,0	46,1	52,5
MAE [%]								
RRRa	11,7	11,0	9,5	10,4	11,8	13,1	19,7	18,7
MP	31,0	29,5	19,9	19,6	25,4	21,7	36,5	45,0
MAPE [%]								
RRRa	16,2	13,8	10,1	10,8	11,6	15,4	24,7	24,1
MP	57,0	53,1	21,3	20,9	26,9	23,3	42,4	68,0
Horizonte de 24h								
	Mai/22		Fev/23		Ago/23		Nov/23	
RMSE [%]	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5
RRRa	16,8	17,7	16,3	11,9	18,1	18,9	25,4	24,2
MP	31,6	29,0	21,1	19,2	36,1	20,8	42,9	48,1
MAE [%]								
RRRa	14,0	15,0	13,8	9,0	13,5	14,7	21,4	20,8
MP	23,5	21,7	18,4	17,3	20,5	13,6	33,8	36,8
MAPE [%]								
RRRa	14,6	15,9	14,5	9,9	18,6	19,3	26,9	26,6
MP	28,8	25,7	19,5	17,7	20,7	16,0	43,7	43,1
Horizonte de 72h								
	Mai/22		Fev/23		Ago/23		Nov/23	
RMSE [%]	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5	Sub 1	Sub 5
RRRa	27,6	27,8	16,1	11,2	23,7	22,9	27,3	26,7
MP	36,4	33,8	38,8	16,1	49,8	48,1	56,1	55,7
MAE [%]								
RRRa	21,6	22,2	14,3	9,9	17,1	17,8	21,0	16,3
MP	28,0	26,8	22,9	14,7	36,0	34,2	42,2	45,1
MAPE [%]								
RRRa	32,1	30,1	14,5	10,6	25,9	26,0	24,8	24,7
MP	39,8	36,3	21,8	14,8	42,5	41,7	51,3	55,4

A Figura 53 apresenta o comparativo das previsões mensais do Sub 1 e do Sub 5 com o SFVr utilizando o HRT = 1h até 10h. No mês de maio de 2022 e fevereiro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE próximo do RMSE do SFVr. No mês de maio de 2022, o Sub 5 apresentou um RMSE de 13,6% (Tabela 42 e Figura 53) e o SFVr

de 13,7% (Tabela 20 e Figura 53). Para o mês de fevereiro de 2023, o Sub 1 e o Sub 5 apresentaram o RMSE de 11,1% e 11,6% (Tabela 42 e Figura 53) respectivamente. Contudo, o SFVr apresentou o RMSE de 11,8% (Tabela 20 e Figura 53).

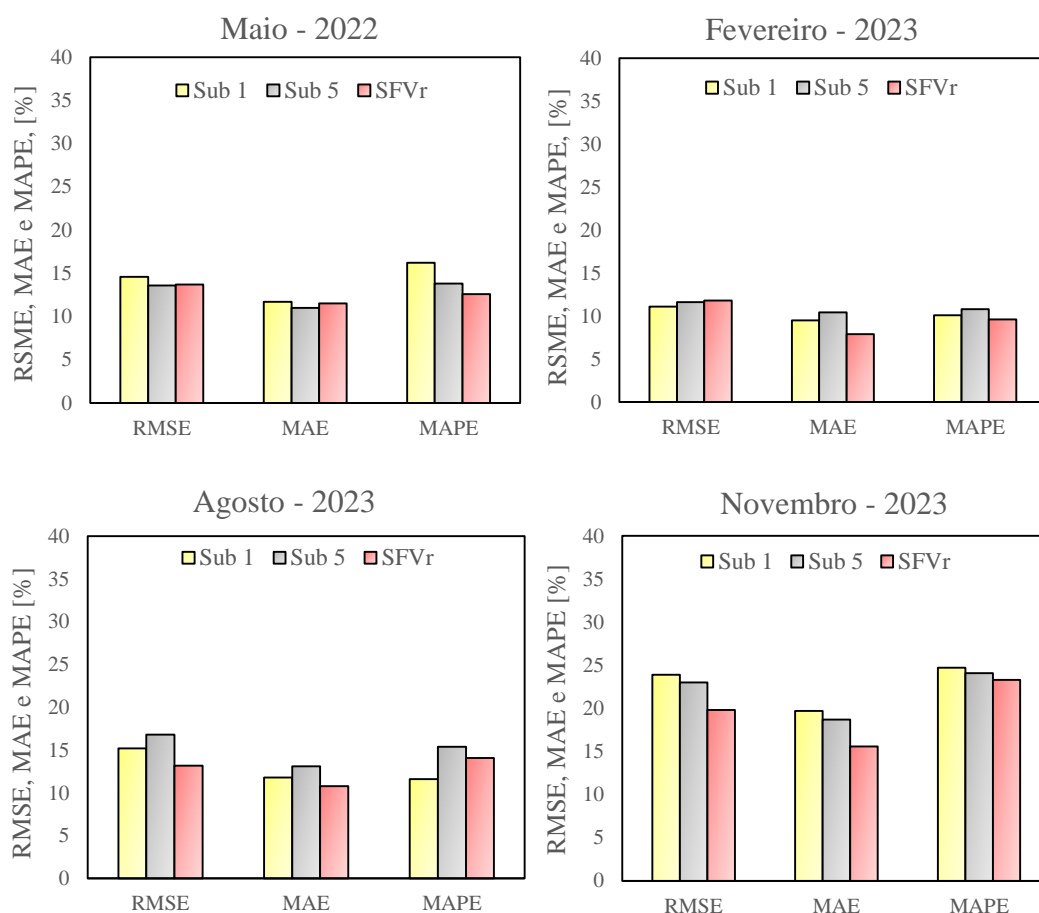


Figura 53 – Comparativo da validação do método RRRa por meio do Sub 1 e do Sub 5 com o SFVr na análise de predição mensal (HRT = 1h até 10h).

No mês de agosto de 2023, o Sub 1 e o Sub 5 apresentaram o RMSE de 15,2% e 16,8% respectivamente e o SFVr de 13,2%. Entretanto, para o mês de novembro de 2023, o Sub 1 e o Sub 5 apresentaram o RMSE de 23,9% e 23,0% respectivamente e o SFVr de 19,8%. Os valores de MAE e MAPE seguiram o mesmo padrão dos valores de RMSE.

Diante disso, o modelo de predição RRRa apresentado mostrou ser possível prever a geração fotovoltaica em diferentes configurações e orientações de sistemas fotovoltaicos, utilizando uma correlação com os índices de desempenho e com o método proposto. O método RRRa pode ser aplicado em qualquer localização geográfica do planeta. Ele mostrou que é possível realizar uma predição de geração fotovoltaica sem a utilização de dados solarimétricos e que, se não for possível obter dados de geração de

um sistema fotovoltaico no local em que se deseja realizar a predição, pode-se utilizar dados de sistemas fotovoltaicos próximos a essa localização para se obter os valores de \overline{PPF} . Entretanto, a precisão da predição de energia com o RRRa pode apresentar grandes diferenças em relação a GR e que, para determinadas aplicações, a medição da irradiância e temperatura podem ser necessárias para aumentar a precisão do método proposto.

A Figura 54 apresenta o comparativo das predições mensais do Sub 1 e do Sub 5 com o SFVr utilizando o HRT = 24h. No mês de maio de 2022, o Sub 1 e o Sub 5 apresentaram RMSE menores que o SFVr. Nesse mês, o Sub 1 e o Sub 5 apresentaram RMSE de 16,8% e 17,7% respectivamente e o SFVr apresentou RMSE de 22,4%.




Figura 54 – Comparativo da validação do método RRRa por meio do Sub 1 e do Sub 5 com o SFVr na análise de predição mensal (HRT = 24h).

Para o mês de fevereiro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 16,3% e 11,9% respectivamente, enquanto o SFVr de 15,0%. No mês de agosto de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 18,1% e 18,9% respectivamente e o SFVr de 21,5%. Entretanto, para o mês de novembro de 2023, o Sub 1 e o Sub 5 apresentaram

RMSE de 25,4% e 24,2% respectivamente e o SFVr de 30,2%. Entretanto, na maioria dos meses, o desempenho do Sub 1 e do Sub 5 foi melhor que o do SFVr. Os valores de MAE e MAPE seguiram o mesmo padrão dos valores de RMSE.

Em comparação com os trabalhos da literatura de previsões do dia seguinte, El-Baz *et al.*, (2018) obteve RMSE de 17,3% e MAE de 9,3% no primeiro mês de treinamento. Após quatro meses de treinamento, o RMSE foi de 15,3% e o MAE de 8,5%. Na maioria dos meses, o Sub 1 e o Sub 5 apresentaram RMSE próximos do trabalho de El-Baz *et al.* (2018).

A Figura 55 apresenta um comparativo das previsões do Sub 1 e do Sub 5 com o trabalho de El-Baz *et al.* (2018) utilizando as métricas RMSE e MAE.




Figura 55 – Comparativo das previsões do Sub 1 e do Sub 5 com a metodologia de El-Baz *et al.* (2018).

Observando a Figura 55, percebe-se que o modelo RRRa nas previsões para o Sub 1 e o Sub 5 apresentou desempenhos parecidos com os do modelo apresentado no trabalho de El-Baz *et al.* (2018).

A Figura 56 apresenta um comparativo do método RRRa nas previsões para o Sub 1 e o Sub 5 com o estudo de Dewangan *et al.* (2020).




Figura 56 - Comparativo das previsões do Sub 1 e do Sub 5 com alguns métodos combinados e não combinados utilizados no trabalho de Dewangan *et al.* (2020).

Em comparação com esse estudo, nos meses de maio de 2022 e fevereiro de 2023, as previsões do Sub 1 e do Sub 5 obtiveram RMSE próximo dos de alguns métodos combinados e não combinados. Observando a Figura 56, percebe-se que o modelo RRRa apresentou desempenhos parecidos com os dos modelos apresentados no trabalho de Dewangan *et al.* (2020).

A Figura 57 apresenta o comparativo das previsões mensais do Sub 1 e do Sub 5 com o SFVr utilizando o HRT = 72h. No mês de maio de 2022, fevereiro de 2023, agosto de 2023 e novembro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE menor que o SFVr. No mês de maio, o Sub 1 e o Sub 5 apresentaram RMSE de 27,6% e 27,8% respectivamente e o SFVr apresentou RMSE de 28,9%. Para o mês de fevereiro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 16,1% e 11,2% respectivamente, enquanto o SFVr de 16,7%.

No mês de agosto de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 23,7% e 22,9% respectivamente e SFVr de 25,2%. Entretanto, para o mês de novembro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 27,3% e 26,7% respectivamente e SFVr de 33,7%. Em síntese, em todos os meses, o desempenho do Sub 1 e do Sub 5 foi melhor que o do SFVr para o HRT = 72h. Os valores de MAE e MAPE seguiram o mesmo padrão dos valores de RMSE nos meses de agosto de 2023 e novembro de 2023. Nos meses de maio de 2022 e fevereiro de 2023, o MAE e o MAPE foram menores para o SFVr quando comparados com o Sub 1. Comparando com o Sub 5, o MAE e o MAPE foram menores para SFVr no mês de maio de 2022 e maiores no mês de fevereiro de 2023.




Figura 57 – Comparativo da validação do método RRRa por meio do Sub 1 e do Sub 5 com o SFVr na análise de predição mensal (HRT = 72h).

Por conseguinte, mostrou-se possível o desenvolvimento de um método de predição de geração fotovoltaica (RRRa) utilizando como entrada dois blocos de dados de natureza diferente, sendo eles o histórico real de geração fotovoltaica de um SFV local de predição e o de dados meteorológicos de uma plataforma de previsão do tempo.

O método RRRa apresentou o desempenho parecido com os horizontes HRT= 1h até 10h, HRT = 24h e HRT = 72h. No perfil chuvoso, o HRT = 72h obteve um desempenho inferior devido ao erro da plataforma de previsão meteorológica ser maior para um horizonte de três dias futuros.

É possível aplicar diferentes plataformas de previsão do tempo no método proposto, mas é fundamental a busca de uma mais eficiente na assertividade da previsão do tempo para que o método apresente um melhor desempenho. As plataformas *Ventusky* e *Open Weather* mostraram que podem possuir um melhor desempenho em um determinado perfil em comparação com os outros perfis. Os perfis intermediário e

chuvoso são desafiadores para se obter a predição fotovoltaica utilizando o modelo proposto devido à assertividade da previsão do tempo das plataformas ser menor.

O método RRRa mostrou-se mais eficiente que o MP em quase todas as situações. As incertezas do método RRRa começam a aumentar no momento que o horizonte de predição aumenta.

Por meio da correlação com os índices de mérito de desempenho, o método RRRa pode ser aplicado para SFV com diferentes ângulos de inclinação e diferentes ângulos de azimute do sistema fotovoltaico de referência. Ele também pode ser aplicado para sistemas fotovoltaicos de diferentes tecnologias. O método RRRa se mostra vantajoso por não precisar da utilização de equipamentos de medição junto dos SFV.

Em geral, ele obteve um desempenho próximo aos da literatura. As diferenças ocorrem devido a metodologias, locais de predição e modelos diversos. Com o passar dos anos e o aumento do número de dados de geração do SFVr, o método RRRa aumentará o seu desempenho. Outra maneira de melhorar a assertividade do método é usar plataformas de previsão do tempo mais precisas. E a vantagem de se usar o método RRRa é que não há necessidade de se investir em equipamentos de medição junto aos sistemas fotovoltaicos em operação.

6 CONCLUSÕES DA TESE

O objetivo geral e os objetivos específicos desta Tese foram atingidos a partir da proposta metodológica descrita sobre a obtenção de um método de predição de geração fotovoltaica sem a utilização de dados de radiação solar. Esta tese apresentou um método de predição RRRa de geração fotovoltaica de curto e médio prazos que foi desenvolvido utilizando como entrada dois blocos de dados de natureza diferente: o primeiro bloco foram os dados históricos reais de geração de energia elétrica de um sistema fotovoltaico conectado à rede, e o segundo bloco foram os dados de previsão meteorológica de duas plataformas de previsão do tempo.

Para a obtenção dos dados de geração real de energia elétrica, foi utilizado o sistema fotovoltaico conectado à rede (SFV_r) localizado na UFSC, Campus Araranguá-SC. Para a obtenção dos dados meteorológicos, foram utilizadas as plataformas de previsão do tempo *Ventusky* e *Open Weather*. As predições de geração fotovoltaica foram realizadas com predições em intervalos horários, predições anuais e predições mensais, utilizando as plataformas *Ventusky* e *Open Weather*. Por meio da plataforma *Ventusky*, os horizontes de predição foram de HRT = 1h até 10h, HRT = 24h e HRT = 72h e, por meio da plataforma *Open Weather*, o horizonte de predição foi de HRT = 1h até 10h.

A metodologia foi desenvolvida no SFV_r, aplicada e validada nos subsistemas do sistema fotovoltaico conectado à rede (SFV_T) localizado no IFSC, Campus Criciúma-SC, e comparada com o método da persistência. Os subsistemas escolhidos para a validação da metodologia foram os Sub 1 e Sub 5, pois possuem orientações diferentes. O desenvolvimento da metodologia foi realizado durante o período de 2022 a 2024 e dividido em dois períodos, de 2022 a 2023 e de 2022 a 2024.

Na predição da geração fotovoltaica anual com HRT = 1h até 10h, HRT = 24 h e HRT = 72h, utilizando os dados da plataforma *Ventusky*, o método RRRa obteve melhor desempenho que o MP nos perfis ensolarado, intermediário e chuvoso nos períodos de predição de 2022 a 2023 e no período de 2022 a 2024 na maioria das métricas. Somente no perfil ensolarado, na métrica MAPE, o MP apresentou melhor desempenho que o RRRa para um HRT = 72h no período de 2022 a 2024. Utilizando os dados da plataforma *Open Weather*, o método RRRa não apresentou melhor desempenho que o MP em alguns perfis e em algumas métricas. No período de 2022 a 2023, no perfil intermediário, o RMSE e o MAE do método MP foram menores que os do RRRa. Nos perfis ensolarado e chuvoso, o método RRRa apresentou melhor desempenho que o MP. No período de

2022 a 2024, o MP apresentou menor RMSE, MAE e MAPE no perfil intermediário que o RRRa. No perfil chuvoso, o método MP apresentou menor RMSE e MAE em comparação com o RRRa.

Comparando-se as duas plataformas na predição de geração anual no período de 2022 a 2023, no perfil ensolarado o método RRRa utilizando os dados da plataforma *Open Weather* obteve uma assertividade maior quando comparado com a *Ventusky*. No perfil chuvoso, o método RRRa utilizando os dados da plataforma *Ventusky* apresentou um desempenho maior. No perfil intermediário, o método RRRa apresentou um desempenho próximo utilizando os dados das plataformas *Ventusky* e *Open Weather*.

Entretanto, utilizando as predições no período de 2022 até 2024 e com uma amostragem maior de valores de PF, o método RRRa não apresentou um desempenho próximo do período de 2022 até 2023 nas predições de geração fotovoltaica anual utilizando a plataforma *Open Weather*. No perfil ensolarado, o método RRRa apresentou um melhor desempenho quando utilizou os dados da plataforma *Open Weather* quando comparado com a *Ventusky*. Nos perfis intermediário e chuvoso, o método RRRa apresentou um melhor desempenho utilizando os dados da plataforma *Ventusky*. Portanto, essa plataforma apresentou melhor desempenho que a plataforma *Open Weather* para as predições de FV anual por meio dos erros médios diários.

Na predição da geração fotovoltaica mensal utilizando os dados da plataforma *Ventusky* para o período de 2022 a 2023 e com HRT = 1h até 10h, o método RRRa teve melhor desempenho do que o MP, exceto em abril de 2022. O RMSE médio mensal para o RRRa variou de 7,3% a 50,1%. Para o MP, o RMSE médio mensal variou de 15,1% a 65,0%. Portanto, com HRT = 24 h, o RMSE médio mensal para o RRRa variou de 4,5% a 43,2%. Para o MP, o RMSE médio mensal variou de 11,5% a 75,0%. Utilizando o HRT = 72h, o RMSE médio mensal para o RRRa variou de 13,8% a 36,9%. Para o MP, o RMSE médio mensal variou de 15,2% a 68,9%.

Usando HRT = 24 h e HRT = 72h, o método RRRa obteve um melhor desempenho que o MP em todos os meses do intervalo analisado. O mês de abril de 2022 foi um mês com muita instabilidade e nebulosidade e chuvoso. Desse modo, a plataforma *Ventusky* teve uma assertividade menor quanto à previsão do tempo.

Utilizando o método RRRa para HRT = 24h, observamos que em alguns meses o RMSE foi menor quando comparado com o HRT = 1h até 10h. Esse resultado mostra que o método RRRa é confiável para horizontes de curto e médio prazos. No HRT = 72h, o método RRRa apresentou RMSE maiores que HRT = 24h e HRT = 1h até 10h na

maioria dos meses. Conforme aumenta o horizonte de predição, a plataforma meteorológica diminui o desempenho da previsão do tempo. Portanto, na maioria dos meses, o HRT = 72h apresentou RMSE, MAE e MAPE levemente maiores quando comparado com HRT = 24h e o HRT = 24h apresentou RMSE, MAE e MAPE levemente maiores quando comparado com HRT = 1h até 10h. A aplicação do método de predição utilizando os dados da plataforma *Open Weather* apresentou um menor desempenho em sete meses por meio das métricas RMSE e MAE quando comparada com a plataforma *Ventusky*.

Na predição da geração fotovoltaica mensal utilizando os dados da plataforma *Ventusky* para o período de 2022 a 2024, o desempenho do método RRRa não foi melhor que o MP em todos os meses. Nos meses de janeiro e fevereiro de 2024, o método RRRa apresentou RMSE, MAE e MAPE maiores que o MP nos horizontes de HRT = 1h até 10h, HRT = 24h e HRT = 72h. Os meses de janeiro e fevereiro de 2024 apresentaram muitas instabilidades e a plataforma *Ventusky* obteve um desempenho baixo nas previsões do tempo.

Na predição da geração fotovoltaica mensal utilizando a plataforma *Open Weather* para o período de 2022 a 2024, o desempenho do método RRRa também não foi melhor que o do MP em todos os meses. Nos meses de março de 2023 e fevereiro de 2024, o método RRRa apresentou RMSE, MAE e MAPE maiores que o MP. Nos meses de março de 2023 e fevereiro de 2024, a plataforma *Open Weather* obteve um desempenho baixo nas previsões do tempo. A plataforma *Ventusky* obteve melhor desempenho na maioria dos meses durante o ano. No mês de abril de 2023, as duas plataformas obtiveram praticamente os mesmos RMSE. Os melhores desempenhos de ambas as plataformas foram nos meses de março, abril, agosto e setembro de 2023.

Na predição da geração fotovoltaica horária (HRT = 1h até 10h) utilizando os dados da plataforma *Ventusky* para o período de 2022 a 2023, o método RRRa apresentou um desempenho melhor que o MP em todos os perfis. No perfil ensolarado o RRRa apresentou menores RMSE, MAE e MAPE em relação aos três perfis. O perfil intermediário apresentou maiores RMSE, MAE e MAPE em relação aos três perfis. Esse perfil é o mais desafiador devido ao aumento de circulações de nuvens. O perfil chuvoso apresentou valores de RMSE entre os perfis ensolarado e intermediário na maioria dos intervalos. Utilizando HRT = 24h, o método RRRa apresentou um desempenho melhor que o MP em todos os perfis. Para o HRT = 72h, o método RRRa também apresentou

valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

Na predição da geração fotovoltaica horária (HRT = 1h até 10h) utilizando os dados da plataforma *Open Weather* para o período de 2022 a 2023, o método RRRa também apresentou um desempenho melhor que o MP em todos os perfis. O perfil ensolarado apresentou novamente menores RMSE, MAE e MAPE em relação aos três perfis. O perfil intermediário apresentou valores de RMSE, MAE e MAPE entre o perfil ensolarado e chuvoso na maioria dos intervalos. O perfil chuvoso apresentou maiores RMSE, MAE e MAPE em relação aos três perfis.

Na predição da geração fotovoltaica horária (HRT = 1h até 10h) utilizando os dados da plataforma *Ventusky* para o período de 2022 a 2024, o método RRRa e o MP apresentaram novamente menores RMSE, MAE e MAPE para o perfil ensolarado em relação aos três perfis. O RMSE para o método RRRa foi de 0,6% a 30,2% maiores quando comparado com o primeiro ano no perfil ensolarado. Nos perfis intermediário e chuvoso, o RMSE para o método RRRa foi maior na maioria dos intervalos e nos horários de menores irradiações quando comparado com o período de 2022 a 2023.

Na predição da geração fotovoltaica horária (HRT = 24h e HRT = 72h) utilizando os dados da plataforma *Ventusky* para o período de 2022 a 2024, o método RRRa no perfil ensolarado novamente apresentou menores RMSE, MAE e MAPE em relação aos três perfis. Em comparação com a predição do primeiro ano, os RMSE e MAE foram levemente maiores para todos os perfis.

Na predição da geração fotovoltaica horária utilizando a plataforma *Open Weather* para o período de 2022 a 2024, o método RRRa apresentou valores de RMSE, MAE e MAPE menores que o MP nos intervalos horários dos perfis ensolarado e intermediário. No perfil chuvoso, na maioria dos intervalos, o RMSE e o MAE foram menores para o RRRa quando comparados com MP. O RMSE para o método RRRa foi de 5,9% a 21,1% maior quando comparado com o primeiro ano no perfil ensolarado.

Após os dois anos de predição, para a predição em intervalos horários, no perfil ensolarado, a aplicação do método RRRa de predição utilizando os dados da plataforma *Open Weather* apresentou praticamente o mesmo desempenho que a plataforma *Ventusky*. No perfil intermediário, o método RRRa apresentou melhor desempenho utilizando os dados da plataforma *Open Weather* quando comparado com a *Ventusky*. No perfil chuvoso, a aplicação do método RRRa de predição utilizando os dados da plataforma *Ventusky* foi a que apresentou melhores desempenhos.

A validação do método utilizando o Sub 1 e o Sub 5 foi aplicada para previsões em intervalos horários e mensais com $HRT = 1h$ até $10h$, $HRT = 24h$ e $HRT = 72h$, utilizando a plataforma *Ventusky*.

O método RRRa ($HRT = 1h$ até $10h$) apresentou valores de RMSE, MAE e MAPE menores que os do MP em todos os intervalos horários nos perfis intermediário e chuvoso. No perfil ensolarado, o método RRRa apresentou valores menores que os do MP para RMSE, MAE e MAPE nos intervalos das 9h até 17h. Nos intervalos de menores irradiações, o MP obteve um melhor desempenho que o método RRRa. No perfil intermediário, o RMSE, MAE e MAPE para o método RRRa foram maiores na maioria dos intervalos e nos horários de menores irradiações quando comparados com os perfis ensolarado e chuvoso para ambos os subsistemas.

Na validação do método RRRa nos subsistemas do IFSC, o método apresentou maiores erros nos intervalos do início da manhã e fim da tarde para os perfis ensolarado e intermediário. Novamente, os maiores erros foram nos intervalos de menores irradiações. Para o $HRT = 24h$ e $HRT = 72h$, o método RRRa apresentou valores de RMSE, MAE e MAPE menores que o método MP em todos os intervalos horários nos perfis ensolarado, intermediário e chuvoso.

Na previsão da geração fotovoltaica mensal dos Sub 1 e Sub 5, o desempenho do método RRRa foi melhor que o MP em todos os meses e em todos os horizontes. Para $HRT = 1h$ até $10h$, nos meses de maio de 2022 e fevereiro de 2023 o Sub 1 e o Sub 5 apresentaram RMSE próximo ao SFVr. No mês de maio de 2022, o Sub 5 apresentou RMSE de 13,6% e SFVr de 13,7%. Para o mês de fevereiro de 2023, o Sub 1 e o Sub 5 apresentaram RMSE de 11,1% e 11,6% respectivamente. Contudo, o SFVr apresentou RMSE de 11,8%.

O modelo de previsão RRRa apresentado mostrou ser possível prever a geração fotovoltaica em diferentes configurações e orientações de sistemas fotovoltaicos, utilizando uma correlação com os índices de desempenho e com o método proposto. Ele pode ser aplicado em qualquer localização geográfica do planeta. O modelo mostrou que é possível realizar uma previsão de geração fotovoltaica sem a utilização de dados solarimétricos e que, se não for possível obter dados de geração de um sistema fotovoltaico no local em que se deseja realizar a previsão, podemos obter dados de sistemas fotovoltaicos próximos a essa localização para se calcular os valores de \overline{PFP} .

A presente Tese mostrou ser possível o desenvolvimento de um método de previsão de geração fotovoltaica (RRRa) utilizando como entrada dois blocos de dados

de natureza diferente, sendo eles o histórico real de geração fotovoltaica de um SFV no local de predição e o de dados meteorológicos de uma plataforma de previsão do tempo. O método RRRa apresentou o desempenho parecido com os horizontes $HRT = 1h$ até $10h$, $HRT = 24h$ e $HRT = 72h$. No perfil chuvoso, o $HRT = 72h$ obteve um desempenho inferior devido ao erro das plataformas de previsão meteorológica ser maior para um horizonte de três dias futuros.

É possível aplicar diferentes plataformas de previsão do tempo no método proposto, mas é fundamental a busca de uma plataforma mais eficiente na assertividade da previsão do tempo para que o método apresente um melhor desempenho. As plataformas *Ventusky* e *Open Weather* mostraram que podem possuir um melhor desempenho em um determinado perfil em comparação com os outros perfis. Os perfis intermediário e chuvoso são desafiadores para se obter a predição fotovoltaica utilizando o modelo proposto devido à assertividade da previsão do tempo das plataformas ser menor.

O método RRRa mostrou-se mais eficiente que o MP em quase todas as situações. As incertezas do método RRRa começam a aumentar no momento que o horizonte de predição aumenta.

Por meio da correlação com os índices de mérito de desempenho, o método RRRa pode ser aplicado para SFV com diferentes ângulos de inclinação e diferentes ângulos de azimute do sistema fotovoltaico de referência. Uma vez que a PFV em um determinado local tenha sido concluída, podemos usar correlações com os índices de desempenho e aplicar a metodologia para realizar a predição em qualquer local do planeta para qualquer configuração, orientação e tecnologia de SFV. Ele também pode ser aplicado para sistemas fotovoltaicos de diferentes tecnologias. O método RRRa se mostra vantajoso por não precisar da utilização de equipamentos de medição junto dos SFV. Ele é um método parecido com o da persistência em relação a praticamente não ter custo. Uma das vantagens do RRRa é que mesmo sendo parecido com o MP se consegue um melhor desempenho que o MP.

Em geral, o método RRRa obteve um desempenho próximo aos da literatura. Essas diferenças ocorrem devido a metodologias, locais de predição e modelos diversos. Com o passar dos anos e o aumento do número de dados de geração do SFV_r, o método RRRa aumentará o seu desempenho. Outra maneira de melhorar a assertividade do método é usar plataformas de previsão do tempo mais precisas.

6.1 Sugestões para trabalhos futuros

- Alguns parâmetros podem ser melhorados para o método RRRa apresentar um melhor desempenho. O primeiro parâmetro é criar um valor de PF para cada 15 dias em vez de utilizar os valores mensais e segundo é criar um padrão para cada previsão do tempo em vez de criar padrões para os perfis ensolarado, intermediário e chuvoso.
- Realizar as próximas previsões fotovoltaicas com plataformas meteorológicas de previsão do tempo mais precisa que as plataformas utilizadas no âmbito da Tese.
- Realizar previsões fotovoltaicas com sistemas fotovoltaicos de diferentes tecnologias, como módulos bifaciais, módulos de filmes finos, entre outros.
- Realizar as previsões em outras regiões do país, com climas, latitudes e longitudes diferentes da região Sul.

REFERÊNCIAS BIBLIOGRÁFICAS

ABSOLAR. **Energia Solar Fotovoltaica no Brasil – infográfico ABSOLAR**. 2024. Disponível em: <https://www.absolar.org.br/mercado/infografico>. Acesso em: 11 out. 2024.

AGOVA, X.G.; GIRARD, R.; KARINIOTAKIS, G. Probabilistic Models for Spatio-Temporal Photovoltaic Power Forecasting. **IEEE Trans. Sustain. Energy**, v. 10, pp. 780–789, 2019. <http://dx.doi.org/10.1109/TSTE.2018.2847558>

ALMEIDA, P. M.; ZILLES, R.; LORENZO, E. Extreme overirradiance events in São Paulo, Brazil. **Solar Energy**, v. 110, pp. 168-173, 2014. <http://dx.doi.org/10.1016/j.solener.2014.09.012>

ANEEL. Resolução Normativa 482/2012. Agência Nacional de Energia Elétrica, 2012.

ANEEL. Resolução Normativa 687/2015. Agência Nacional de Energia Elétrica, 2015.

ANTONANZAS, J.; OSORIO, N.; ESCOBAR, R.; URRACA, R.; MARTINEZ-DE-PISON, F.J.; ANTONANZAS-TORRES, F. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, pp. 78–111, 2016. <http://dx.doi.org/10.1016/j.solener.2016.06.069>

ARYAN, V; FONT-BRUCART, M; MAGA, D. A comparative life cycle assessment of end-of-life treatment pathways for photovoltaic backsheets, **Progress in Photovoltaics**, v. 26, pp. 443-459, 2018. <https://doi.org/10.1002/pip.3003>

BAKKER, K.; WHAN, K.; KNAP, W.; SCHMETTS, M. Comparison of statistical post-processing methods for probabilistic NWP forecasts of solar radiation. **Solar Energy**, v. 191, pp. 138-150, 2019. <https://doi.org/10.1016/j.solener.2019.08.044>

BARBIERI, F.; RAJAKARUNA, S.; GHOSH, A. Very short-term photovoltaic power forecasting with cloud modeling: A review. **Renewable and Sustainable Energy Reviews**, v. 75, pp. 242-263, 2017. <http://dx.doi.org/10.1016/j.rser.2016.10.068>

BLAGA, R.; SABADUS, A.; STEFU, N. DUGHIR, C.; PAULESCU, M. BADESCU, V. A current perspective on the accuracy of incoming solar energy forecasting. **Progress in energy and Combustion Science**, v. 70, p. 119-144, 2019.

<https://doi.org/10.1016/j.pecs.2018.10.003>

BÖÖK, H; LINDFORS, A. Site-specific adjustment of a NWP-based photovoltaic production forecast, **Solar Energy**, v. 211, pp. 779-788, 2020.

<https://doi.org/10.1016/j.solener.2020.10.024>

BOUZERDOUM, M.; MELLIT, A.; MASSI PAVAN, A. A hybrid model (SARIMA–SVM) for short-term powerforecasting of a small-scale grid-connected photovoltaic plant. **Solar Energy**, v. 98, pp. 226–235, 2013.<http://dx.doi.org/10.1016/j.solener.2013.10.002>

BRACALE, A.; CARPINELLI, G.; De Falco, P. A probabilistic competitive ensemble method for short-term photovoltaic power forecasting. **IEEE Trans. Sustain. Energy**, v. 8, pp. 551–560, 2017.<http://dx.doi.org/10.1109/TSTE.2016.2610523>

BRASIL. Lei N° 14.300, DE 6 DE JANEIRO DE 2022, Institui o marco legal da microgeração e minigeração distribuída, o Sistema de Compensação de Energia Elétrica (SCEE) e o Programa de Energia Renovável Social (PERS); altera as Leis n°s 10.848, de 15 de março de 2004, e 9.427, de 26 de dezembro de 1996; e dá outras providências, Art. 1, p. 12, 2022. Disponível em: https://www.planalto.gov.br/ccivil_03/ato2019-2022/2022/lei/114300.htm#:~:text=Fica%20instituído%20o%20Programa%20de,20%20de%20janeiro%20de%202020.

CHIKH, M.; BERKANE, S.; MAHRANE, A.; SELLAMI, R.; YASSAA, N. Performance assessment of a 400 kWp multi- technology photovoltaic grid-connected pilot plant in arid region of Algeria, **Renewable Energy**, v. 172, pp. 488-501, 2021.

<https://doi.org/10.1016/j.renene.2021.02.168>

CHIRADEJA, P. Benefit of Distributed Generation: A Line Loss Reduction Analysis, **IEEE/PES Transmission & Distribution Conference & Exposition: Asia and Pacific**, pp. 1–5, 2005.<https://doi.org/10.1109/TDC.2005.1546964>.

COSTA, V. B. F.; SCIANNI, L.; MIRANDA, R. C.; BONATTO, B. Assessment of the status and trends of photovoltaic distributed generation in Brazil: An in-depth approach based on big data processing, **Solar Energy**, v. 249, pp. 694-711, 2023. <https://doi.org/10.1016/j.solener.2022.12.018>

DAS, U.K.; TEY, K.S.; SEYEDMAHMOUDIAN, M.; MEKHILEF, S.; IDRIS, M.Y.I.; VAN DEVENTER, W.; STOJCEVSKI, A. Forecasting of photovoltaic power generation and model optimization: A review. **Renew. Sustain. Energy Rev.** v. 81, pp. 912–928, 2018. <http://dx.doi.org/10.1016/j.rser.2017.08.017>

DEWANGAN, C. L.; SINGH, S. N.; CHAKRABARTI, S. Combining forecasts of day-ahead solar power, **Energy**, v. 202, 2020. <https://doi.org/10.1016/j.energy.2020.117743>

DIAGNE, M.; DAVID, M.; LAURET, P. BOLAND, J. SCHMUTZ, N. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, v. 27, pp. 65-76, 2013. <http://dx.doi.org/10.1016/j.rser.2013.06.042>

DOLARA, A.; LEVA, S.; MANZOLINI, G. Comparison of different physical models for PV power output prediction. **Solar Energy**, v. 119, pp. 83–99, 2015. <http://dx.doi.org/10.1016/j.solener.2015.06.017>

DUFFIE, J. A.; BECKMAN, W. A. **Solar engineering of thermal processes**. Wiley, p. 910, 2013.

DYRESON, A. R.; MORGAN, E. R.; MONGER, S. H.; ACKER, T. L. Modeling solar irradiance smoothing for large PV power plants using a 45-sensor network and the Wavelet Variability Model. **Solar Energy**, v. 110, pp. 482-495, 2014. <http://dx.doi.org/10.1016/j.solener.2014.09.027>

ELASSER, A., AGAMY, M., SABATE, J., STEIGERWALD, R., FISHER, R., HARFMAN -TODOROVIC, M. A comparative study of central and distributed mppt architectures for megawatt utility and large scale comercial photovoltaic plants. In: **IECON 36th Annual Conference on IEEE Industrial Electronics Society**, 2010.

<http://dx.doi.org/10.1109/IECON.2010.5675108>

EL-BAZ, W.; TZSCHEUTSCHLER, P.; WAGNER, U. Day-ahead probabilistic PV generation forecast for buildings energy management systems, **Solar Energy**, v. 171, pp. 478-490, 2018. <https://doi.org/10.1016/j.solener.2018.06.100>

GASPARIN, F. P.; BÜHLER, A. J.; RAMPINELLI, G. A.; KRENZINGER, A. Statistical analysis of I-V curve parameters from photovoltaic modules, **Solar Energy**, v. 131, pp. 30-38, 2016. <http://dx.doi.org/10.1016/j.solener.2016.01.061>

GRADITI, G.; FERLITO, S.; ADINOLFI, G. Comparison of Photovoltaic plant power production prediction methods using a large measured dataset. **Renewable Energy**, v. 90, pp. 513-519, 2016. <http://dx.doi.org/10.1016/j.renene.2016.01.027>

GUEYMARD, C. A. A review of validation methodologies and statistical performance indicators for modeled solar radiation data: Towards a better bankability of solar projects, **Renewable and Sustainable Energy Reviews**, v. 39, pp. 1024 – 1034, 2014.

<http://dx.doi.org/10.1016/j.rser.2014.07.117>

HAAG, R.; KRENZINGER, A.; Stoffel, T. Análise Preliminar do “offset” térmico em piranômetros sob diferentes condições atmosféricas, **III Congresso Brasileiro de Energia Solar**, Belém, 21 a 24 de setembro, 2010.

IEA - PVPS - INTERNATIONAL ENERGY AGENCY - PHOTOVOLTAIC POWER SYSTEMS PROGRAMME. Photovoltaic and Solar Forecasting: State of the Art. 2013. ISBN 978-3-906042-13-8Disponível em:

<http://www.iea-pvps.org/index.php?id=3&eID=dam_frontend_push&docID=1690>

JANG, H.S.; BAE, K.Y.; PARK, H.S.; SUNG, D.K. Solar power prediction based on satellite images and support vector machine. **IEEE Trans. Sustain. Energy**, v. 7, pp. 1255–1263, 2016. <http://dx.doi.org/10.1109/TSTE.2016.2535466>

KALOGIROU, S. A. Solar energy engineering: processes and systems. **Elsevier Inc.**, p. 841, 2013.

LAI, C. S.; JIA, Y.; LAI, L. L.; XU, Z.; MCCULLOCH, M. D.; WONG, K. P. A comprehensive review on large-scale photovoltaic system with applications of electrical energy storage. **Renewable and Sustainable Energy Reviews**, v. 78, pp. 439-451, 2017. <http://dx.doi.org/10.1016/j.rser.2017.04.078>

LARSON, D.P.; NONNENMACHER, L.; COIMBRA, C.F. Day-ahead forecasting of solar power output from photovoltaic plants in the American Southwest. **Renewable Energy**, v. 91, pp. 11–20, 2016. <http://dx.doi.org/10.1016/j.renene.2016.01.039>

LORENZO, E. **Radiación Solar y Dispositivos Fotovoltaicos, Electricidad Solar Fotovoltaica**, V. II, España, 2006.

LORENTE D. G.; PEDRAZZI, S.; ZINI, G.; ROSA, A. D.; TARTARINI, P. Mismatch losses in PV power plants. **Solar Energy**, v. 100, pp. 42-49, 2014. <http://dx.doi.org/10.1016/j.solener.2013.11.026>

LUQUE, A.; HEGEDUS, S. **Handbook of Photovoltaic Science and Engineering**. 2^a Edição, 2011.

MACÊDO, W. N. **Análise do fator de dimensionamento do inversor aplicado a sistemas fotovoltaicos conectados à rede**, Tese de Doutorado, USP, São Paulo, 2006.

MACIEL, J. N. **Método Híbrido de Predição com Processamento de Imagens e Inteligência Artificial Aplicável à Geração de Energia Solar Fotovoltaica**, Tese de Doutorado, UNILA, Foz do Iguaçu, 2022.

MACIEL, J. N.; LEDESMA, J. J. G.; ANDO JUNIOR, O. H. Forecasting Solar Power Output Generation: A Systematic Review with the Proknow-C. **IEEE Latin America Transactions**, v. 19, n. 4, p. 612-624, 2021.

Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9448544>

MALVONI, M. A.; LEGGIERI, G.; MAGGIOTTO, P.M.; CONGEDO, M.G.; DE GIORGI. Long term performance, losses and efficiency analysis of a960 kWP photovoltaic system in the Mediterranean climate. **Energy Conversion and Management**, 2017. <http://dx.doi.org/10.1016/j.enconman.2017.04.075>

MARKOVIC, M. L.; CIRIC, R. M. Efficiency analysis of grid-connected photovoltaic power plants. **CSEE Journal of Power and Energy Systems**, v. 3, n. 3, pp. 269–277, 2017.

<http://dx.doi.org/10.17775/CSEEJPES.2016.01100>

MELLIT, A.; PAVAN, A.M.; OGLIARI, E.; LEVA, S.; LUGHI, V. Advanced methods for photovoltaic output power forecasting: a review. **Applied Sciences**, v. 10, pp. 1–23, 2020. <https://doi.org/10.3390/app10020487>

MELLIT, A.; KALOGIROU, S.A. Artificial intelligence techniques for photovoltaic applications: A review. **Progress in Energy and Combustion Science**, v. 34, pp. 574–632, 2008. <https://doi.org/10.1016/j.pecs.2008.01.001>

MOSAVI, A.; SALIMI, M.; ARDABILI, S. F.; RABCZUK, T.; SHAMSHIRBAND, S.; VARKONYI-KOCZY, A. R. State of the Art of Machine Learning Models in Energy Systems, a Systematic. **Review. Energies**, v. 12, n. 7, p. 1301, 2019. <https://doi.org/10.3390/en12071301>

NDIAYE, A.; CHARKI, A.; KOBI, A.; KÉBÉ, C. M. F.; NDIAYE P. A.; SAMBOU, V. Degradations of silicon photovoltaic modules: A literature review. **Solar Energy**, v. 96, pp. 140-151, 2013. <http://dx.doi.org/10.1016/j.solener.2013.07.005>

NESPOLI, A.; OGLIARI, E.; LEVA, S.; PAVAN, M. A.; MELLIT, A.; LUGHI, V.; Dolara, A. Day-Ahead Photovoltaic Forecasting: A Comparison of the Most effective Techniques. **Energies**, v. 12, pp. 1621, 2019.

<http://dx.doi.org/10.3390/en12091621>

NOBRE, A. M.; SEVERIANO, C. A.; KARTHIK, S.; KUBIS, M.; ZHAO, L.; MARTINS, F. R.; PEREIRA, E. B.; RÜTHER, R.; REINDL, T. PV power conversion and short-term forecasting in a tropical, densely-built environment in Singapore. **Renewable Energy, Solar Energy Research Institute of Singapore**, National University of Singapore, v. 94, p. 496–509, 2016. <http://dx.doi.org/10.1016/j.renene.2016.03.075>

OGLIARI, E.; DOLARA, A.; MANZOLINI, G.; LEVA, S. Physical and hybrid methods comparison for the day ahead PV output power forecast. **Renewable Energy**, v. 113, pp 11-21, 2017. <http://dx.doi.org/10.1016/j.renene.2017.05.063>

OLIVEIRA, S. H. F. **Geração Distribuída de Eletricidade: Inserções de Edificações Fotovoltaicas Conectadas à Rede no Estado de São Paulo**. Tese de Doutorado, PIPGE/USP, São Paulo, Brasil, 2002.

OLIVEIRA, F. S. **Metodologia e instrumentação para ensaios de séries e arranjos fotovoltaicos de grande porte**. Tese de Doutorado. UFRGS, 2020.

PEARSALL, N. **The Performance of Photovoltaic (PV) Systems, Modelling, Measurement and Assessment**, Elsevier, 1ª edição, pp. 352, 2017.

PELLAND, S.; GALANIS, G.; KALLOS, G. Solar and photovoltaic forecasting through post-processing of the Global Environmental Multiscale numerical weather prediction model. **Prog. Photovolt. Res. Appl**, v. 21, pp. 284–296, 2013.

<http://dx.doi.org/10.1002/pip.1180>

PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L.; RÜTHER, R.; ABREU, S. L.; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. **Atlas Brasileiro de Energia Solar**, 2ª edição, pp. 88. São José dos Campos, 2017.

PINHO, J. T., GALDINO, M. A. **Manual de engenharia para sistemas fotovoltaicos**. Rio de Janeiro, 2014.

QIAN, K.; ZHOU, C.; YUAN, Y.; SHI, X.; ALLAN, M. Analysis of the environmental benefits of Distributed Generation, **IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy**, pp. 1–5, 2008.

<http://dx.doi.org/10.1109/PES.2008.4596137>

RAMPINELLI, G. A. **Estudo de Características Elétricas e Térmicas de Inversores para Sistemas Fotovoltaicos Conectados à Rede**. Tese de Doutorado, PROMEC/UFRGS, Porto Alegre, Brasil, 2010.

RAZA, M.Q.; NADARAJAH, M.; EKANAYAKE, C. On recent advances in PV output power forecast, **Solar Energy**, v. 136, pp. 125-144, 2016.

<http://dx.doi.org/10.1016/j.solener.2016.06.073>

ROSSO, A. P. **Desenvolvimento de células e módulos de referência para medição da radiação solar**. Dissertação de Mestrado. UFSC, 2019.

REINSEL, G. C.; VELU, R. P. 1998. **Multivariate Reduced-Rank Regression**, pp. 260. Nova York.

RÜTHER, R. 2004. **Edifícios Solares Fotovoltaicos. O Potencial da Geração Solar Fotovoltaica Integrada a Edificações Urbanas e Interligada à Rede Elétrica Pública no Brasil**, 1ª edição, pp. 113. Florianópolis.

SANJARI, M.J.; GOOI, H.B. Probabilistic forecast of PV power generation based on higher order Markov chain. **IEEE Trans. Power Syst**, v. 32, pp. 2942–2952, 2017.

<http://dx.doi.org/10.1109/TPWRS.2016.2616902>

SCARABELOT, L. **Influência do fator de dimensionamento de inversor no desempenho termoenergético de sistemas fotovoltaicos de geração distribuída**, Tese de Doutorado, UFSC, Florianópolis, Brasil, 2020.

SOBRI, S.; KOOHI-KAMALI, S.; RAHIM, N.A. Solar photovoltaic generation forecasting methods: A review. **Energy Convers. Manag.** V. 156, pp. 459–497, 2018.

<https://doi.org/10.1016/j.enconman.2017.11.019>

TIBA, C.; LEAL, S. S. Enhancement of UV Radiation by Cloud Effect in NE of Brazil. **International Journal of Photoenergy**, Hindaw, 9p. 2017.

<https://doi.org/10.1155/2017/8107435>

TUOHY, A.; ZACK, J.; HAUPT, S. E.; SHARP, J.; AHLSTROM, M.; DISE, S.; BLACK, J. Solar Forecasting: Methods, challenges, and performance. **IEEE Power Energy Mag.** v. 13, pp. 50-59, 2015. <https://doi.org/10.1109/MPE.2015.2461351>

VON APPEN, J.; BRAUN M.; STETZ T.; DIWOLD, K.; GEIBEL, D. Time in the sun: the challenge of high PV penetration in the German electric grid. **IEEE Power Energy Mag.** v. 11 pp. 55–64, 2013. <http://dx.doi.org/10.1109/MPE.2012.2234407>

WANG, G.; SU, Y.; SHU, L. One-day-ahead daily power forecasting of photovoltaic systems based on partialfunctional linear regression models. **Renewable Energy**,v. 96, pp. 469–478, 2016. <https://doi.org/10.1016/j.renene.2016.04.089>

WIRTH, H. Recent Facts about Photovoltaics in Germany, Fraunhofer ISE, 2020. Disponível: <https://www.ise.fraunhofer.de/en/publications/studies/recent-facts-about-pv-in-germany.html>

WOLFF, B.; KÜHNERT, J.; LORENZ, E.; KRAMER, O.; HEINEMANN, D. Comparing support vector regression for PVpower forecasting to a physical modeling approach using measurement, numerical weather prediction, andcloud motion data. **Solar Energy**,v. 135, pp. 197–208, 2016. <https://doi.org/10.1016/j.solener.2016.05.051>

WOYTE, A. et al. Analytical Monitoring of Grid-connected Photovoltaic Systems,Report **IEA-PVPS T13-03International Energy Agency Photovoltaic Power Systems Programme. Brussels: IEA**, 2014.

YANG, D.; DONG, Z. Operational photovoltaics power forecasting using seasonal time series ensemble. **Solar Energy**, v. 166, pp. 529–541, 2018.

<https://doi.org/10.1016/j.solener.2018.02.011>

ZHANG, X.; LI, Y.; LU, S.; HAMANN, H.F.; HODGE, B.M.; LEHMAN, B. A solar time based analog ensemble method for regional solar power forecasting. **IEEE Trans. Sustain. Energy**, v. 10, pp. 268–279, 2019. <http://dx.doi.org/10.1109/TSTE.2018.2832634>

ZHU, H.; LI, X.; SUN, Q.; NIE, L. YAO, J.; ZHAO, G. A Power Prediction Method for Photovoltaic Power Plant Based on Wavelet Decomposition and Artificial Neural Networks, **Energies**, pp. 1-15, 2015. doi:<http://dx.doi.org/10.3390/en9010011>

ZOMER, C.; RÜTHER, R. Simplified method for shading-loss analysis in BIPV systems – part 1: Theoretical study. **Energy and Buildings**, v. 141, pp. 69-82, 2017. <https://doi.org/10.1016/j.enbuild.2017.02.042>

ZOMER, C.; CUSTÓDIO, I.; GOULART, S.; MANTELLI, S.; MARTINS, G.; CAMPOS, R.; PINTO, G.; RÜTHER, R. Energy balance and performance assessment of PV systems installed at a positive-energy Building (PEB) solar energy research centre, **Solar Energy**, v. 212, pp. 258-274, 2020. <https://doi.org/10.1016/j.solener.2020.10.080>