



Ministério da
**Ciência, Tecnologia
e Inovação**



PREVISÃO DE IRRADIAÇÃO SOLAR NO NORDESTE DO BRASIL EMPREGANDO O MODELO WRF AJUSTADO POR REDES NEURAS ARTIFICIAIS (RNAs)

Francisco José Lopes de Lima

Tese de Doutorado do Curso de Pós-Graduação em Meteorologia, orientado pelo Dr. Enio Bueno Pereira, aprovado em 10 de junho de 2015.

URL do documento original:
<<http://urlib.net/xx/yy>>

INPE
São José dos Campos
2015

Dados Internacionais de Catalogação na Publicação

Cutter Lima, F. J. L.
Previsão de Irradiação Solar no Nordeste do Brasil Empregando o
modelo WRF Ajustado por Redes Neurais Artificiais (RNAs) / F. J.
L. Lima. - São José dos Campos: INPE, 2015.

Doutorado em Meteorologia - Instituto Nacional de Pesquisas
Espaciais, São José dos Campos, 2015.
Orientador: Enio Bueno Pereira.

1. Radiação solar. 2. Redes Neurais Artificiais. 3. Previsão. 4.
Análise de Agrupamento. 5. Nordeste do Brasil. I. Título

CDU

Copyright AAAA do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente no propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright AAAA by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming or otherwise, without written permission from the INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

Folha da banca

Inserida pelo SID

Verso da Folha da Banca

Em branco

“Eu sou de uma terra que o povo padece, mas não esmorece e procura vencer. Da terra adorada, que a bela caboca de riso na boca zomba no sofrê. Não nego meu sangue, não nego meu nome, olho para a fome e pergunto o que há? Eu sou brasileiro, filho do Nordeste, sou cabra da Peste, sou do Ceará”.

Patativa do Assaré

Dedico este trabalho a meus pais e avós, José Gerônimo de Lima, Antônia Leusimar Lopes de Lima e Antônio Joaquim Neto e Angelita Lopes da Silva, a quem devo toda minha vida.

Ofereço e dedico

AGRADECIMENTOS

A Deus pela alegria da vida e pela força de ter me ajudado a superar as dificuldades que surgiram.

A minha família, por estarem sempre me apoiando, compreensíveis nos momentos em que precisei.

Aos meus amigos e colegas, inclusive os mais distantes, pelo companheirismo e por terem contribuído para minha formação profissional e humana.

Agradeço sinceramente ao Dr. Enio Bueno Pereira, meu orientador, e ao Dr. Fernando Ramos Martins, por terem acreditado e apostado em mim, e pelas oportunidades que vêm me oferecendo.

Ao programa CAPES/DAAD/GIZ/NOPA pela bolsa de Doutorado Sanduíche no exterior, processo nº 4404/13-0.

Ao Dr. Detlev Heinemann e Dra. Elke Lorenz e toda a equipe do grupo *Energy Meteorology* da *Carl Von Ossietzky University*, pela acolhida e pelos conhecimentos compartilhados durante o Doutorado Sanduíche. Meu agradecimento à Dra. Rejane Moraes Duzat, Dra. Annette Hammer e Jan Kuehnert.

Agradeço aos colegas de doutorado, pela amizade e compartilhamento de conhecimento ao longo do período de disciplinas.

Agradeço aos colegas do grupo de pesquisa, pela ajuda no desenvolvimento deste trabalho, especialmente Marcelo Pes, Jefferson Sousa, Maria Velloso, Lucía Chipponelli, Rafael Chagas, Eduardo Luiz, Venize Teixeira, Silvia Pereira, Rodrigo Costa e André Gonçalves, pela companhia diária, pela amizade e pelos conhecimentos transmitidos.

Ao Instituto Nacional de Pesquisas Espaciais – INPE, ao seu Centro de Previsão do Tempo e Estudos Climáticos – CPTEC e ao Centro de Ciências do Sistema Terrestre – CCST, pela oportunidade de estudo e disponibilização de infraestrutura.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq e À Coordenação de Aperfeiçoamentos de Pessoal de Nível Superior - CAPES, pelo suporte financeiro.

Ao Instituto Nacional de Meteorologia – INMET, pela disponibilidade dos dados empregados nesta tese.

Aos membros da Banca examinadora, pela colaboração na melhoria deste trabalho.

E a todas as demais pessoas que participaram de mais essa fase de minha vida.

RESUMO

Este trabalho tem como objetivo avaliar a capacidade de um modelo numérico regional de mesoescala, em representar o escoamento atmosférico da região Nordeste do Brasil (NEB), possibilitando seu uso para previsão de irradiação solar usando um refinamento estatístico para a redução dos erros sistemáticos inerente ao modelo de mesoescala. A motivação deste estudo decorre da importância da radiação solar como recurso vital para a manutenção da vida no planeta e para atividades humanas tais como agricultura e aproveitamento de energia. A intensidade da irradiação solar que incide sobre a superfície é de natureza variável, principalmente devido às nuvens e o ciclo diurno. Este trabalho se propôs a desenvolver uma metodologia para previsão de irradiação solar incidente para a região Nordeste do Brasil com o uso de Redes Neurais Artificiais (RNAs), alimentadas por saídas do modelo WRF, visando reduzir as incertezas associadas à previsão de irradiação solar deste modelo. As variáveis de saída do modelo WRF, representando as condições atmosféricas previstas, foram empregadas como preditores em modelos de RNAs e Regressões Lineares Múltiplas (RLM). O método de análise de cluster foi utilizado para estabelecer regiões de características homogêneas sob o ponto de vista climatológico da irradiação solar. Os dados usados neste trabalho foram dados do INMET, para o período de sete anos de 2005 a 2011. Diversos experimentos foram realizados para ajuste e definição de preditores e simulação dos modelos de RNAs. Parâmetros de avaliação de erros, determinados frente aos dados observacionais de cada estação de coleta de dados em superfície foram calculados, permitindo a comparação de desempenho das RNA e RLM e da previsão de irradiação solar obtida diretamente do modelo WRF. Visando maximizar o ganho de desempenho sobre o modelo WRF e minimizar o número de variáveis, encontrou-se a melhor arquitetura e um grupo de 10 preditores, com o qual análises mais aprofundadas foram realizadas, incluindo avaliação de desempenho para o outono e primavera de 2011, período chuvoso e seco no NEB, principalmente no norte do NEB. Houve uma diferença significativa entre os modelos de RNA e RLM, mostrando que os modelos de RNAs foram superiores ao modelo RLM. Porém ambos os métodos promoveram redução do viés e do *RMSE* e aumento do coeficiente de correlação em comparação com as saídas de irradiação solar do WRF.

FORECAST OF SOLAR IRRADIATION IN NORTHEAST OF BRAZIL USING THE WRF MODEL ADJUSTED BY ARTIFICIAL NEURAL NETWORK (ANN)

ABSTRACT

This work aims to evaluate the ability of a regional numerical mesoscale model, to represent the atmospheric flow in the Northeast region of Brazil (NEB), allowing its use for forecasting solar irradiation using a statistical refinement to reduce systematic errors inherent in the mesoscale model. The motivation of this study lies in the importance of solar radiation as a vital resource for the maintenance of life on Earth and to human activities such as agriculture and energy. The intensity of the solar radiation incident on the surface is variable in nature, mainly because of clouds and the diurnal cycle. This study aimed to develop a methodology to forecast the incident surface solar irradiation in the Northeast of Brazil by using mesoscale WRF model outputs adjusted by Artificial Neural Networks (ANN to reduce the model uncertainties. The output variables of the WRF model, representing the forecast atmospheric conditions, were used as predictors by RNAs and Multiple Linear Regressions (MLR), (with the inclusion of a clearsky model), adjusted to calculate the incident solar irradiation, in four homogeneous regions defined by the Ward's method. The data used in this study cover the period of seven years from 2005 to 2011. Several predictors were tested in the adjustment and simulation of the ANN. Error evaluation parameters, determined by the observational data of each measurement station were calculated for each simulation, allowing the comparison of RNA and RLM, and the prediction of solar irradiation directly from WRF model. To maximize the performance gain of the WRF model and minimize the number of variables, it was establish the best architecture and a group of 10 predictors, with which more in-depth analyzes were performed, including performance evaluation for fall and spring of 2011 (rainy and dry season at the NEB, mainly in North of the Northeast). There was a significant difference between RNA and MLR models, showing that RNA models were superior to the MLR model. However, both methods produced lower bias and RMSE, and an increase in the correlation coefficient in comparison with the solar radiation in the WRF Model.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 1.1 - A teoria do Pico do Petróleo ou Pico de Hubbert.	2
Figura 1.1 – Balanço de energia global, ilustrando as interações entre a radiação solar e os constituintes atmosféricos. Fonte: Pereira et al. (2006).....	10
Figura 2.2 – Espectros da radiação solar no topo da atmosfera e incidente na superfície terrestre, ao nível do mar, com o espectro de emissão de um corpo negro a 6000 K. Fonte: Modificado de Robinson (1966).	11
Figura 2.3 – Representação de grade de Arakawa-C. Fonte: Skamarock et al. (2005, 2008).	17
Figura 2.4 – Coordenadas vertical sigma. Fonte: Skamarock et al. (2005, 2008).	17
Figura 2.5 – Representação de uma RNA-MLP. Fonte: Adaptado de Haykin (2001).....	24
Figura 2.6 – Modelo de um neurônio. Fonte: Adaptado de Haykin (2001).....	25
Figura 2.7 – Sinais de saída de diferentes funções de ativação: a) função degrau; b) função linear; c) função sigmoidal logística; d) função sigmoidal tangente hiperbólica.	26
Figura 2.8 – Média anual de radiação solar em superfície em MJ/m ² . Fonte: Atlas Solarimétrico do Brasil. Fonte: TIBA (2000).	30
Figura 2.9 – Média anual da radiação solar global. Fonte: Atlas Brasileiro de Energia Solar (PEREIRA et al. 2006). ...	32
Figura 3.1 – Distribuição espacial de todas as estações localizadas no Nordeste (NEB). O número sinótico das estações inicia-se com 1 e termina em 121.	38

Figura 3.2 – Fluxograma do procedimento para controle de qualidade dos dados de irradiação solar coletados pelo INMET.	41
Figura 4.1 – Número de Estações qualificadas distribuídas por meses ao longo do período de estudo. A linha em vermelho representa o limite mínimo aceitável para a utilização da série anual no processo de interpolação espacial.....	58
Figura 4.2 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de B. da Corda e Natal.....	59
Figura 4.3 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Sobral e Morada Nova.	60
Figura 4.4 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Buriti e Ouricuri.	61
Figura 4.5 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Santa Cruz e Itaberaba.	62
Figura 4.6 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Macajuba e Abrolhos.	63
Figura 4.7 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Remanso e S ^o r do Bomfim.....	64
Figura 4.8 – Distribuição espacial de todas as estações localizadas no Nordeste (NEB) e usadas para a interpolação e Análise de Agrupamento (AA).....	65
Figura 4.9 – Mapeamento da Irradiação Solar (kWh/m ²) com base na média dos totais diários dos dados observados disponíveis e qualificados nesta pesquisa.	66

Figura 4.10 – Mapas climatológicos da Irradiação Solar (kWh/m ²), para os trimestres (a) DJF (verão), (b) MAM (outono), (c) JJA (inverno) e (d) SON (primavera).	69
Figura 4.11 – Dendrograma resultante da análise objetiva das 110 estações meteorológicas, usando o método aglomerativo hierárquico de Ward para irradiação solar.	72
Figura 4.12 – Dendrograma resultante da análise objetiva das 105 estações meteorológicas, usando o método aglomerativo hierárquico de Ward para irradiação solar e temperatura média.	72
Figura 4.13 – Distribuição das regiões homogêneas em relação às estações Grupo1, verde, Grupo2, ciano, Grupo3, roxo, Grupo4, vermelho, para irradiação solar.....	73
Figura 4.14 – Distribuição das regiões homogêneas em relação às estações Grupo1, roxo, Grupo2, ciano, Grupo3, vermelho, Grupo4, verde, para a irradiação solar e temperatura.	74
Figura 4.15 – Médias totais anuais, diárias, mensais e horarias para as quatro regiões homogêneas usando todo o período de dados medidos para irradiação solar.....	75
Figura 4.16 – Médias mensais para os anos de 2008 a 2011 para as quatro regiões homogêneas.....	77
Figura 4.17 – Definição dos domínios utilizados no modelo WRF e suas respectivas grades para o teste de sensibilidade das principais parametrizações físicas: Convecção, Microfísica e Radiação para o NEB, domínio 1 com 15 km, domínios 2, 3 e 4 com 5 km.....	80
Figura 4.18 – Posicionamento das grades configuradas para o modelo WRF. Em roxo é a grade do modelo sobre a Região1, em vermelho sobre as Região2 e Região3, em verde sobre a Região4, todos com resolução horizontal de 5 km.....	81
Figura 4.19 – Subgrupos das regiões homogêneas para definir as estações usadas nos testes de sensibilidade.....	82

Figura 4.20 – Estações selecionadas para a avaliação dos testes de sensibilidade.....	83
Figura 4.21 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.....	87
Figura 4.22 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.....	87
Figura 4.23 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.	87
Figura 4.24 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.....	89
Figura 4.25 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.....	89
Figura 4.26 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.	89
Figura 4.27 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.....	90
Figura 4.28 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.....	90
Figura 4.29 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.	90
Figura 4.30 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.....	92
Figura 4.31 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.....	92
Figura 4.32 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.	92

Figura 4.32 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.	95
Figura 4.33 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.	95
Figura 4.34 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.	95
Figura 4.35 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.	97
Figura 4.36 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.	97
Figura 4.37 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.	97
Figura 4.38 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.	98
Figura 4.39 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.	98
Figura 4.40 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.	98
Figura 4.41 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.	100
Figura 4.42 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.	100
Figura 4.42 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.	100
Figura 4.44 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.	103

Figura 4.45 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.	103
Figura 4.46 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.	103
Figura 4.47 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.	104
Figura 4.48 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.	104
Figura 4.49 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.	104
Figura 4.50 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.	106
Figura 4.51 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.	106
Figura 4.52 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.	106
Figura 4.53 – Medidas de erro (<i>ME</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.	108
Figura 4.54 – Medidas de erro (<i>RMSE</i>) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.	108
Figura 4.55 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.	108
Figura 5.1 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2009).	114
Figura 5.2 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2009).	115

Figura 5.3 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2009).....	116
Figura 5.4 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2009).....	117
Figura 5.5 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2009).....	118
Figura 5.6 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2009).....	119
Figura 5.7 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2009).....	120
Figura 5.8 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2009).....	121
Figura 5.9 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2010).....	123
Figura 5.10 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2010).	124
Figura 5.11 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2010).....	125
Figura 5.12 – de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2010).....	126
Figura 5.13 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2010).....	127
Figura 5.14 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2010).	129

Figura 5.15 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2010).....	130
Figura 5.16 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2010).	131
Figura 5.17 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2011).....	132
Figura 5.18 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2011).	134
Figura 5.19 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2011).....	135
Figura 5.20 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2011).	136
Figura 5.21 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2011).....	137
Figura 5.22 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2011).	138
Figura 5.23 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2011).....	139
Figura 5.24 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2011).	140
Figura 5.25 – Mapas da Irradiação Solar, (kWh/m ²), para 2009. (A) dados medidos para o outono, (B) dados estimados para o outono, (C) dados medidos para a primavera e (D) dados estimados para a primavera.	143
Figura 5.26 – Mapas da Irradiação Solar, (kWh/m ²), para 2010. (A) dados medidos para o outono, (B) dados estimados para o outono, (C)	

dados medidos para a primavera e (D) dados estimados para a primavera.	144
Figura 5.27 – Mapas da Irradiação Solar, (kWh/m ²), para 2011. (A) dados medidos para o outono, (B) dados estimados para o outono, (C) dados medidos para a primavera e (D) dados estimados para a primavera.	145
Figura 5.28 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para o outono de 2009....	146
Figura 5.29 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para a primavera de 2009.	146
Figura 5.30 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para o outono de 2010....	147
Figura 5.31 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para a primavera de 2010.	147
Figura 5.32 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para o outono de 2011....	148
Figura 5.33 – Mapas de diferença de irradiação solar (kWh/m ²) entre os dados medidos e as saídas do modelo WRF para a primavera de 2011.	148
Figura 6.1 – Grupo de preditores para as estações da região homogênea R1.	153
Figura 6.2 – Grupo de preditores para as estações da região homogênea R2.	154
Figura 6.3 – Grupo de preditores para as estações da região homogênea R3.	155
Figura 6.4 – Grupo de preditores para as estações da região homogênea R4.	156
Figura 6.5 – Arquitetura da RNA para as quatro regiões homogêneas.	162

Figura 6.6 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 01).	164
Figura 6.7 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 02).	166
Figura 6.8 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 03).	168
Figura 6.9 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 04).	171
Figura 6.10 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para A do Gurgeia (R1).	175
Figura 6.11 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Cabaceiras (R2).	176
Figura 6.12 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Brumado (R3).	177
Figura 6.13 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Itapipoca (R4).	178
Figura 6.14 – Mapas da Irradiação Solar, (kWh/m ²), para 2011. (A) dados medidos para o outono, (B) dados estimados pela RNA para o outono, (C) dados medidos para a primavera e (D) dados estimados pela RNA para a primavera.	185
Figura 6.15 – Mapas de diferença de Irradiação Solar, (kWh/m ²), para 2011. (A) entre os dados medidos e as saídas do modelo WRF, para o outono, (B) entre os dados medidos e as saídas do modelo RNA, para o outono, (C) entre os dados medidos e as saídas do modelo WRF, para a primavera e (D) entre os dados medidos e as saídas do modelo RNA, para a primavera.	187

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 – Parametrizações usadas no modelo numérico de mesoescala WRF.	44
Tabela 4.1 – Localização das estações para a validação dos testes de sensibilidade.....	84
Tabela 4.2 – Esquema das principais parametrizações físicas para o teste de sensibilidade (radiação).	85
Tabela 4.3 – Esquema das principais parametrizações físicas para o teste de sensibilidade (Microfísica).	93
Tabela 4.4 – Esquema das principais parametrizações físicas para o teste de sensibilidade (Convecção).	101
Tabela 6.1 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 01.	157
Tabela 6.2 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 02.	158
Tabela 6.3 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 03.	158
Tabela 6.4 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 04.	159
Tabela 6.5 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 01.	162
Tabela 6.6 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 02.	162
Tabela 6.7 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 03.	162

Tabela 6.8 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 04.....	162
Tabela 6.9 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 01. Em destaque estão os melhores índices.	165
Tabela 6.10 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 02.....	167
Tabela 6.11 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 03.....	170
Tabela 6.12 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 04.....	172
Tabela 6.13 - Índices estatísticos para a Região 01 (outono/primavera).	180
Tabela 6.14 - Índices estatísticos para a Região 02 (outono/primavera).	181
Tabela 6.15 - Índices estatísticos para a Região 03 (outono/primavera).	182
Tabela 6.16 - Índices estatísticos para a Região 04 (outono/primavera).	183

LISTA DE SIGLAS E ABREVIATURAS

AA	Análise de Agrupamento
ACP	Análises em Componentes Principais
AFWA	<i>Air Force Weather Agency</i>
AGCM's	<i>Atmospheric General Circulation Models</i>
ASAN	Anticiclones Subtropicais do Atlântico Norte
ASAS	Anticiclones Subtropicais do Atlântico Sul
ASRC	Centro de Pesquisa em Ciências Atmosféricas
BSRN	<i>Baseline Surface Radiation Network</i>
CAPE	<i>Convective Potential Available Energy</i>
CCST	Centro de Ciência do Sistema Terrestre
CLP	Camada limite planetária
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CSP	Solares Térmicas
DLR	Centro Aeroespacial Alemão
FAA	<i>Federal Aviation Administration</i>
FSL	<i>Naval Research Laboratory</i>
GEF	Fundo Global para o Meio Ambiente
GFS	<i>Global Forecast System</i>
GTEF	Grupo de Trabalho em Energia Solar Fotovoltaica
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
LSM	<i>Land Surface Model</i>
MclCA	<i>Monte-Carlo independente column approximation</i>
ME	Viés ou Bias
MLP	<i>multilayer perceptron</i>
MOS	<i>Model Output Statistical</i>
MSE	Erro Absoluto Médio
MYJ	Mellhor-Yamada-Janjic
NCAR	<i>National Center for Atmospheric Research</i>

NCEP	<i>National Center for Environmental Prediction</i>
NCN	Núcleos de Condensação de Nuvens
NEB	Nordeste brasileiro
NOAA	<i>National Oceanic and Atmospheric Administration</i>
NREL	Laboratório Nacional de Energias Renováveis dos EUA
OLADE	Organização Latino Americana de Energia
PNUMA	Programa das Nações Unidas para o Meio Ambiente
PV	Fotovoltaicas
RAMS	<i>Regional Atmospheric Modeling System</i>
RLM	Regressão Linear Múltipla
<i>RMSE</i>	Erros quadráticos médios
RNAs	Redes Neurais Artificiais
RRTM	<i>Rapid Radiative Transfer Method</i>
RSM	<i>Regional Spectral Model</i>
SIN	Sistema Interligado Nacional
SONDA	Sistema Nacional de Organização de Dados Ambientais
SWERA	<i>Solar and Wind Energy Resource Assessment</i>
TERI	Instituto de Recursos Energéticos na Índia
TOA	Irradiância solar no topo da atmosfera
TSM	Temperatura de superfície do mar
VCAS	Vórtices Ciclônicos de Ar Superior
WMO	World Meteorological Organization
WRF	Weather Research and Forecasting Model
WSM6	Single-Momento 6-classe
ZCIT	Zona de convergência intertropical

LISTA DE SÍMBOLOS

<i>ClearSky</i>	Irradiação solar em dia de Céu Claro
<i>clfhi</i>	Coberturas de nuvens altas
<i>clflo</i>	Coberturas de nuvens baixas
<i>clfmi</i>	Coberturas de nuvens médias
<i>dj</i>	Dia juliano
<i>hour</i>	Hora
<i>k*</i>	Índice de céu claro
<i>Kt</i>	Índice de claridade ou coeficiente de transmitância atmosférica global
<i>pw</i>	Água precipitável
<i>R</i>	Coeficientes de correlação
<i>r_{h2}</i>	Umidade relativa
<i>S_o</i>	Constante Solar
<i>t₂</i>	<i>Temperatura</i>
<i>u10</i>	Velocidade zonal a 10m

SUMÁRIO

	<u>Pág.</u>
1	INTRODUÇÃO 1
1.1.	Contexto e Justificativas..... 1
1.2.	Objetivos 7
2	FUNDAMENTAÇÃO TEÓRICA 9
2.1.	Radiação Solar e a Atmosfera Terrestre 9
2.2.	Descrição Geral da Área em Estudo 13
2.3.	Modelos Numéricos de Mesoescala: O Modelo WRF 15
2.4.	Análise de Agrupamento (AA) 19
2.5.	Redes Neurais Artificiais 22
2.5.1.	Perceptrons de Múltiplas Camadas..... 23
2.5.2.	Neurônio Artificial 24
2.5.3.	Aprendizado da RNA..... 26
2.6.	Trabalhos Relevantes na Área de Interesse 28
2.6.1.	Aplicações das Redes Neurais Artificiais 32
3	DADOS E METODOLOGIA 37
3.1.	Dados..... 37
3.1.1.	Dados Observados..... 37
3.2.	Metodologia..... 38
3.2.1.	Qualificação dos Dados 40
3.2.2.	Análise de Agrupamento (AA) 42
3.2.3.	Teste de Sensibilidade das Principais Parametrizações do WRF . 43
3.2.4.	Extração de Dados da Saída do Modelo WRF 48
3.2.5.	Dados Derivados de Saídas do WRF..... 48
3.2.6.	Modelo de MOS (Model Output Statistical) 49
3.3.	Desenvolvimento das Redes Neurais Artificiais (RNAs) 51
3.3.1.	Seleção dos Preditores 51
3.3.2.	Treinamento das RNAs 52
3.3.3.	Definição do Número de Neurônios Ocultos 53

3.4.	Análise Estatística	54
4	RESULTADOS: PARTE I	57
4.1.	Verificação da Qualidade dos dados Observados.....	57
4.2.	Variabilidade espacial da Radiação Solar no NEB entre 2008 e 2011.	65
4.3.	Configuração e Definição das Estações para Avaliação do WRF ...	78
4.4.	Teste de Sensibilidade do WRF (Radiação, Microfísica e Convecção)	84
4.4.1.	Avaliação das Parametrizações de Radiação do WRF	85
4.4.2.	Avaliação das Parametrizações de Microfísica do WRF	93
4.4.3.	Avaliação das Parametrizações de Convecção do WRF	101
5	RESULTADOS: PARTE II	111
5.1.	Avaliação das Previsões do Modelo WRF	111
5.1.1.	Cenário de 2009.....	112
5.1.2.	Cenário de 2010.....	122
5.1.3.	Cenário de 2011.....	132
5.2.	Análise Espacial da Irradiação Solar para 2009, 2010 e 2011 ...	141
6	RESULTADOS: PARTE III	151
6.1.	Experimentos para a Seleção de Preditores	151
6.2.	Definição da Arquitetura das RNAs.....	160
6.3.	Avaliação das Previsões	163
6.3.1.	Região Homogênea 01	163
6.3.2.	Região Homogênea 02	165
6.3.3.	Região Homogênea 03	167
6.3.4.	Região Homogênea 04	171
6.3.5.	Discussões do Desempenho entre os Modelos	173
6.4.	Avaliação das Previsões para o Outono e Primavera de 2011 ...	178
6.4.1.	Região Homogênea 01 (2011)	179
6.4.2.	Região Homogênea 02 (2011)	180
6.4.3.	Região Homogênea 03 (2011)	181
6.4.4.	Região Homogênea 04 (2011)	182

6.4.5.	Análise Espacial para 2011	184
7	CONCLUSÕES	189
8	SUGESTÕES DE TRABALHOS FUTUROS	195
	REFERÊNCIAS BIBLIOGRÁFICAS	197
	ANEXO A - LOCALIZAÇÃO DAS ESTAÇÕES USADAS NESTA PESQUISA	213

1 INTRODUÇÃO

A radiação solar é a fonte primária de energia disponível ao planeta para a manutenção da vida, governando inúmeros processos, tais como evaporação, ciclos diurno e sazonal de temperatura e fotossíntese, além de ter implicações importantes nas diversas atividades humanas, como o aproveitamento de energia solar, a agropecuária, a engenharia, a arquitetura, a hidrologia e diversos outros setores do conhecimento. Diante disso, mudanças na quantidade de energia solar disponível em superfície têm consequências ambientais e socioeconômicas profundas (WILD, 2009).

O estudo da radiação solar incidente na superfície terrestre tem implicações diretas na meteorologia, especialmente nos estudos sobre o clima e na variabilidade climática (LOHMANN et al. 2006).

Em termos agrometeorológicos, a radiação solar é responsável por processos fotobioquímicos dos vegetais, floração e frutificação, interferindo na qualidade dos frutos e grãos (LIMA et al. 2007). A radiação solar também desempenha grande papel na assimilação do carbono nos dosséis das plantas e, conseqüentemente, na produtividade dos ecossistemas (COHEN et al. 2002; GU et al. 2003; RODERICK et al. 2001; SILVA et al. 2010; SILVA et al. 2007). A evapotranspiração está intrinsecamente relacionada ao balanço de radiação da atmosfera cujo conhecimento permite quantificar a energia a ser repartida entre o aquecimento do solo, do ar e o processo de evapotranspiração (SILVA et al. 2005).

1.1. Contexto e Justificativas

O atendimento da demanda energética mundial primária depende em sua grande parte dos combustíveis fósseis. O emprego dessas fontes de energia lança na atmosfera uma grande quantidade de poluentes, especialmente

óxidos de carbono, relacionados à intensificação do efeito estufa. Contudo, ao lado da preocupação ambiental, existe uma preocupação estratégica decorrente da percepção de que os reservatórios destes combustíveis fósseis são limitados, isto é, trata-se de recursos de energia esgotáveis. No contexto mundial a maior e mais importante fonte de energia convencional a partir do século passado tem sido sem dúvida, o petróleo. Hubbert (1962) desenvolveu um modelo que previa o comportamento da produção de petróleo em 48 estados americanos e passou a ocupar um lugar de destaque no mundo do petróleo. A Figura 1.1 ilustra essa curva, indicando o pico de extração/produção e o perfil de declínio inevitável previsto pelo modelo. Segundo Geller (2003), num cenário otimista, a depleção desse recurso energético deverá iniciar a partir do pico de produção/demanda por volta de 2030 quando, então, terá início o seu esgotamento gradual a nível mundial.

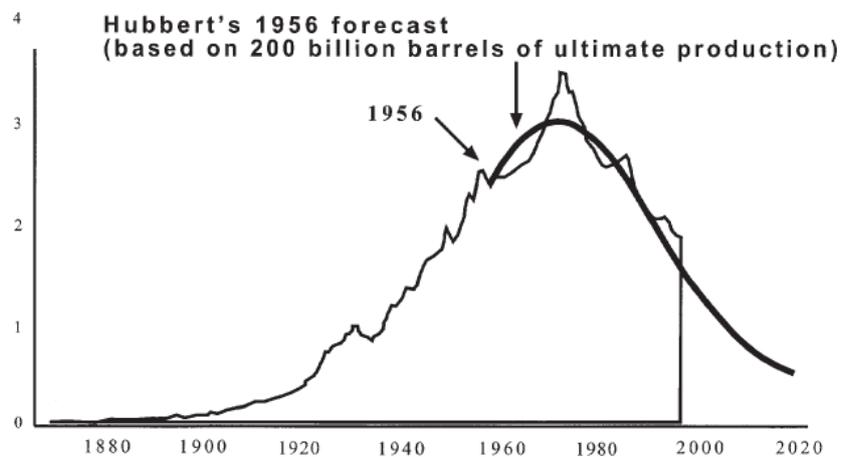


Figura 1.1 - A teoria do Pico do Petróleo ou Pico de Hubbert.

Segundo estudos compilados por Bentley (2002), o declínio na produção do petróleo deverá ser superior a 3-5% ao ano após o seu apogeu de produção. Raciocínio análogo pode ser feito para as outras fontes não renováveis de energia, como o carvão e o gás natural, mas obviamente com escalas bem diferentes de apogeu e declínio. Assim, uma nova consciência mundial, quanto

à utilização dos recursos naturais e energéticos, tem apontado para a inserção de fontes de energia alternativas, que não apenas apresentem reduzido impacto ambiental, mas que também venham a ser economicamente viáveis e que sejam renováveis.

Entende-se por energias renováveis todas as formas de energia cuja taxa de utilização é inferior a sua taxa de renovação, podendo-se citar a energia solar, eólica, da biomassa, geotérmica e hidroelétrica. No caso do Brasil, sua matriz energética já contempla de forma exemplar o emprego das energias renováveis, principalmente através da hidroeletricidade e da biomassa.

Contudo, com o esperado crescimento da economia brasileira, haverá uma demanda proporcionalmente crescente por mais energia (GOLDEMBERG; VILLANUEVA, 2003). As energias renováveis solar e eólica representam importante opção, não só pelas vantagens inerentes à diversificação e complementaridade das fontes de energia, como também pelo fato de que haverá grande pressão mundial para estabilizar as taxas de emissão de carbono para a atmosfera, levando a reprimir o crescimento do uso de combustíveis fósseis.

O desenvolvimento socioeconômico de uma sociedade está intimamente relacionado à produção e consumo de energia (GOLDEMBERG; LUCON, 2008; PEREIRA et al. 2006). A busca por fontes de energia que minimizem a degradação dos recursos naturais do planeta e que agreguem segurança ao fornecimento de energia em tempos de seca se torna necessário frente à atual demanda energética brasileira e mundial.

O aumento da demanda e consumo de energia decorrente do progresso tecnológico e do avanço no desenvolvimento humano são apontados como os fatores mais importantes na aceleração das alterações climáticas e ambientais observadas e descritas pela comunidade científica. O aumento da demanda energética em conjunto com a possibilidade de redução da oferta de combustíveis convencionais e a crescente preocupação com preservação do meio ambiente está impulsionando a comunidade científica a pesquisar e

desenvolver fontes alternativas de energia menos poluentes, renováveis e que produzam pouco impacto ambiental.

A energia de fonte solar vem ganhando importância nos últimos anos, acompanhando a crescente demanda energética mundial, as perspectivas de escassez dos combustíveis fósseis e as motivações ambientais ligadas ao aquecimento global. Embora seja uma fonte de energia abundante, tem a desvantagem de ser de difícil captação em comparação com a energia hidroelétrica e possui oferta inconstante na medida em que está sujeita à variabilidade climática, principalmente devido às nuvens e aos ciclos diurno e sazonal. Portanto, para ser aproveitada, são demandados estudos que possibilitem conhecer melhor sua disponibilidade regional, variabilidade temporal e previsibilidade.

Informações provenientes da previsão de radiação solar incidente são de vital importância na operação de sistemas híbridos de geração de eletricidade, permitindo um gerenciamento mais eficiente das fontes de energia e o emprego otimizado de energia solar-fotovoltaica, em prol da economia de outros recursos.

O aproveitamento da energia da radiação solar incidente na superfície da Terra é uma alternativa para complementar a matriz energética brasileira atual que se baseia principalmente em sistemas de usinas hidroelétrica e combustíveis fósseis (ANEEL, 2011; PEREIRA et al. 2006). Além disso, o conhecimento e previsão do potencial disponível de energia solar tem um papel de extrema importância para apoiar o setor energético no planejamento de operação do sistema elétrico do País e na operação de plantas de geração solar como as fotovoltaicas (PV) e solares térmicas (CSP) (MARTINS et al. 2006).

No que concerne à hidrologia, as alterações na taxa de energia solar que incide na superfície terrestre, interferem na quantidade de água armazenada em lagos, rios e oceanos, influenciando no balanço hidrológico de uma região (ROSENBERG et al. 1983).

A utilização da energia solar requer um maior conhecimento no que diz respeito a sua variabilidade espacial e temporal. Porém, informações confiáveis sobre essa variável ainda são escassas no Brasil. Martins e Pereira (2011), Martins et al. (2006) e Leal e Tiba (2006), ao investigarem a disponibilidade e a variabilidade da irradiação solar no Brasil, enfrentaram muitas limitações em função da baixa densidade de estações radiométricas no território brasileiro. Uma das ferramentas utilizadas com bastante frequência para suprimir a baixa densidade de estações sobre o Brasil são modelos baseados em dados de satélites (MARTINS et al. 2008; CEBALLOS; BOTTINO, 2002, 2004). Os modelos numéricos de mesoescala também permitem a obtenção da radiação solar sobre regiões extensas e em locais isolados onde as estações não podem ser instaladas e com uma boa variabilidade temporal (GUARNIERI, 2006).

Em razão do exposto, evidencia-se que o setor energético demandará da previsão de recursos solares para o planejamento de curto prazo de operação do sistema de geração e distribuição de eletricidade à medida que novas plantas de geração solar forem implantadas e operadas no Sistema Interligado Nacional (SIN). Além disso, outros setores da economia poderão se beneficiar do desenvolvimento de metodologias de previsão de irradiação solar a médio e longo prazo. Dessa forma, o desenvolvimento de ferramentas e serviços de meteorologia pode contribuir significativamente tanto na orientação de políticas de incentivo e regulamentação como no do setor energético e em outros setores como os agronegócios, a arquitetura e a construção civil.

A crise na geração de energia elétrica enfrentada pelo Brasil recentemente expôs fragilidades do sistema energético atual. A energia hidroelétrica possui papel central na matriz energética brasileira. Trata-se de uma forma de energia limpa quanto à emissão de poluentes para a atmosfera, embora a construção dos reservatórios ocasione alagamento de grandes áreas, afetando a fauna e a vegetação locais, e modificando o microclima regional. Além desses impactos ambientais ainda não adequadamente avaliados, a dependência dessa forma

de energia ao regime de chuvas cria vulnerabilidades em épocas de estiagem, como ocorreu em período recente e atual. Visando sustentar a oferta de energia em longo prazo e aumentar a confiabilidade do sistema, a reestruturação energética nacional atualmente em curso prevê a inclusão de recursos alternativos aos atualmente empregados.

A conversão de energia solar em energia elétrica ou térmica possui impactos reduzidos e emissão de poluentes nula durante a operação da planta de geração. Contudo, além das barreiras tecnológicas ainda não solucionadas, quanto à sua variabilidade de oferta e dependência às condições de tempo e clima, outra barreira que se opõe à exploração e uso pleno desta abundante fonte energética é o custo relativamente alto em relação à energia hidroelétrica. Desta forma, no cenário atual, a energia solar e outras energias renováveis não serão empregadas em substituição aos combustíveis fósseis ou à energia hidráulica, mas será gradativamente inserida de forma a complementar às atuais fontes, em sistemas energéticos híbridos. As limitações ao uso da energia solar tendem a ser reduzidas ou até mesmo eliminadas com o tempo, principalmente em resposta ao crescimento da demanda de energia mundial devido ao crescimento das economias de países em desenvolvimento, o aparecimento de novas tecnologias de armazenamento de energia e o crescimento da escala de mercado dessas tecnologias.

Por ser um país localizado em sua maior parte na região intertropical, o Brasil possui grande potencial de energia solar ao longo de todo o país. Mas para que se possa otimizar os vultosos investimentos de implantação de estruturas coletoras de energia solar e sua exploração eficiente, faz-se necessário conhecer os locais com maior disponibilidade, os potenciais de utilização e as incertezas da variabilidade climática que influenciam este recurso de energia.

Contudo, o Brasil possui escassez de dados confiáveis que suportem esses estudos de viabilidade. Na tentativa de suprir tal carência, duas iniciativas do INPE, através do CCST e CPTEC merecem destaque: o emprego de modelos de radiação baseados em imagens de satélite, como os modelos BRASIL-SR

(PEREIRA et al. 1996; MARTINS, 2001) e GL (CEBALLOS et al. 2004), e a ampliação da rede de estações medidoras de radiação solar, através de projetos como o SONDA. Com a disponibilidade desses novos dados, estudos são demandados para que sejam produzidas informações e ferramentas úteis ao setor energético, incluindo modelos de previsão de curto prazo.

1.2. Objetivos

O objetivo deste trabalho é avaliar e implementar melhorias na previsão da radiação solar incidente usando o modelo de previsão de tempo WRF, visando atender a grande demanda do setor de produção e distribuição de energia elétrica no Brasil, com a finalidade de possibilitar um melhor aproveitamento da energia solar em futuros projetos de exploração e comercialização dessa fonte renovável de energia. Este trabalho visa à implementação de uma ferramenta destinada a fornecer essas previsões às concessionárias, geradoras e distribuidoras de energia elétrica e ao Operador Nacional do Sistema Elétrico. Para tal finalidade, foram empregados modelos estatísticos simples, alimentados com dados gerados pelo modelo WRF e que expressam as condições atmosféricas e da superfície para instantes futuros. Durante o desenvolvimento e avaliação destes modelos estatísticos foram empregados dados de radiação solar medida em 121 estações do INMET.

A região em estudo foi definida por apresentar comprimento de dia solar médio de aproximadamente 12 horas com longos períodos de baixa cobertura de nuvens e fluxos de radiação solar de até 1200 W/m². Em suma, a área de estudo dispõe de condições climáticas favoráveis à utilização da energia solar como fonte primária de energia a ser transformada em energia elétrica, possibilitando uma aplicação prática imediata dos resultados alcançados nesta pesquisa.

Almeja-se verificar também se, na solução específica do problema deste trabalho, o emprego de Redes Neurais Artificiais (RNAs) oferece algum ganho

frente ao modelo de Regressão Linear Múltipla RLM em termos de redução dos erros sistemáticos. O emprego de RNAs é justificável pela sua conhecida capacidade de reconhecimento de padrões e ajuste funcional, e por proporcionar bons resultados em problemas que apresentem elevado grau de não linearidade.

Além disso, a investigação da influência da variabilidade climática na disponibilidade do recurso de energia solar sobre o Nordeste Brasileiro será realizada a partir dos resultados obtidos com a metodologia desenvolvida.

Os resultados deste trabalho proverão informações para várias questões de relevância maior:

- Desenvolver uma ferramenta para a previsão de curto prazo de irradiação solar que poderá atender diversos setores da economia brasileira;
- Aprimorar o entendimento e conhecimento da disponibilidade e variabilidade dos recursos de energia solar na área em estudo;
- Prover o setor energético com dados de irradiação solar confiável que possibilitem atender a demanda de informações e serviços de meteorologia aplicada para suporte ao desenvolvimento e operação de plantas de geração solar no Nordeste do Brasil.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Radiação Solar e a Atmosfera Terrestre

A energia proveniente do Sol, denominada radiação solar, é o fator mais importante para o desenvolvimento dos processos físicos que influenciam as condições de tempo e clima. Logo, pode-se afirmar que todos os fenômenos físicos, químicos, físico-químicos e biológicos responsáveis pela manutenção da vida no sistema Terra-Atmosfera estão de certo modo ligados de maneira direta ou indireta com a quantidade de radiação solar incidente no planeta. Essa energia sofre várias interações com os diversos constituintes atmosféricos ao atravessar a atmosfera. Parte da irradiação solar é espalhada e parte é absorvida pelas partículas e moléculas presentes no ar, como vapor d'água, dióxido de carbono, ozônio e compostos nitrosos.

A radiação solar tem a maior parte de sua energia contida em comprimentos de onda entre 0,1 e 4 μm , correspondendo às bandas do ultravioleta, do visível e do infravermelho próximo (BRUTSAERT, 1982). O espectro solar é comumente dividido em três faixas principais: ultravioleta ($0,1 \leq \lambda \leq 0,4 \mu\text{m}$), visível ($0,4 < \lambda \leq 0,7 \mu\text{m}$) e infravermelho ($> 0,7 \mu\text{m}$) (IQBAL, 1983).

O fluxo de energia radiante, energia por unidade de tempo, que incide sobre uma superfície de área unitária normal aos raios solares e a uma distância média Terra-Sol é definida como constante solar (S_0) e seu valor recomendado pela WMO, (*World Meteorological Organization*), é de 1367 W/m². Devido às ligeiras variações da distância Terra-Sol ao longo do ano, decorrentes da excentricidade da órbita terrestre, a irradiância solar que atinge o topo da atmosfera (TOA) sofre alterações.

A radiação solar, ao atravessar a atmosfera, sofre complexas interações com os constituintes atmosféricos através de processos de absorção e espalhamento da radiação incidente. Embora a atmosfera seja muito

transparente estima-se que apenas 25% da radiação incidente no topo da atmosfera (TOA) chegam à superfície terrestre sem sofrer nenhuma interferência dos constituintes atmosféricos. Os 75% restantes são absorvidos, refletidos de volta ao espaço ou espalhados e, neste caso, normalmente atinge a superfície em uma direção diferente da direção de incidência no topo da atmosfera. Esses complexos processos, ilustrados na Figura 2.1, dependem do comprimento de onda da radiação e do tamanho e natureza do gás ou particulado atmosférico que interage com a radiação solar (LIOU, 2002).

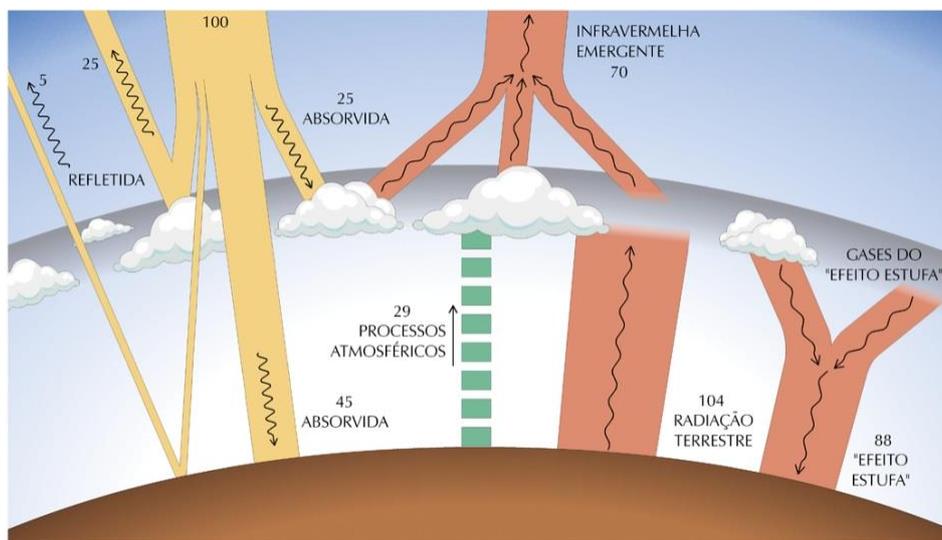


Figura 1.1 – Balanço de energia global, ilustrando as interações entre a radiação solar e os constituintes atmosféricos.
 Fonte: Pereira et al. (2006).

A absorção da radiação solar na atmosfera é realizada principalmente pelo ozônio atmosférico na faixa de radiação ultravioleta e por vapor d'água e dióxido de carbono nas bandas do infravermelho. O espalhamento, por sua vez, é causado principalmente pela interação entre a radiação solar e moléculas de ar, água e poeira. O espectro da radiação solar incidente no topo da atmosfera, juntamente com o espectro da radiação solar direta que chega à superfície terrestre é apresentado na Figura 2.2 que permite identificar as principais bandas de absorção de radiação pelos gases atmosféricos.

A absorção da radiação solar por um gás é caracterizada por aumento no movimento molecular interno do gás e, conseqüentemente, em sua temperatura, favorecendo o aquecimento da atmosfera. As diferentes bandas de absorção de radiação solar e radiação terrestre de um gás são determinadas por suas características físico-químicas, associadas aos diferentes tipos de reações e processos fotoquímicos que as moléculas de gás podem sofrer (LIOU, 2002).

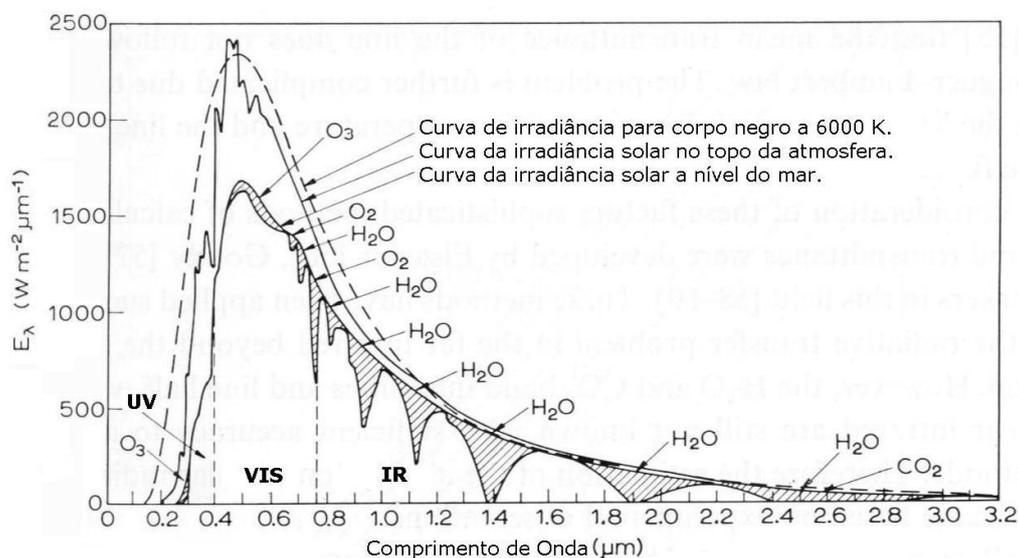


Figura 2.2 – Espectros da radiação solar no topo da atmosfera e incidente na superfície terrestre, ao nível do mar, com o espectro de emissão de um corpo negro a 6000 K.
 Fonte: Modificado de Robinson (1966).

A radiação solar global que alcança a superfície é constituída pela radiação solar difusa e direta, sendo influenciada por alguns fatores tais como elevação solar, condições de profundidade ótica e grau de nebulosidade (ALVES, 1981). Quando o céu está limpo, a radiação direta corresponde de 60 a 87% da radiação global (LESTRADE et al. 1990). Na presença de nebulosidade, a radiação solar diminuir, pois a nebulosidade e a elevação solar são fatores de primeira ordem na determinação da variação da irradiação solar à superfície (KONDRATYEV, 1969).

As nuvens, que cobrem em média de 40 a 60% da superfície da Terra, desempenham um papel fundamental no balanço de energia do planeta, (ECHER et al. 2001). As condições de nebulosidade são um dos fatores que mais influenciam a variação da radiação solar global, principalmente em locais de baixa latitude. Nessa linha de estudo, Liou (1976) calculou os processos de absorção, reflexão e transmissão da radiação solar em uma atmosfera com nuvens mediante modelos de transferência radiativa.

As propriedades radiativas de uma nuvem dependem primariamente de suas dimensões físicas, sua altura na atmosfera e de suas características microfísicas, tais como distribuição de tamanho das gotas e dos cristais de gelo, morfologia dos cristais de gelo, quantidade de água líquida, índice de refração da água pura e do gelo (LIOU, 1992; HEYMSFIELD, 1993). Os resultados obtidos por Liou (1976) indicaram que nuvens nimbostratus e cumulonimbus refletem 80 a 90% e absorvem 10 a 20% da radiação solar incidente sobre elas. A reflexão e a absorção dos cúmulos de bom tempo, de espessura igual a 0,45 km, variam de 68 a 85% e de 4 a 9%, respectivamente. Uma nuvem stratus fina, de espessura de 0,1 km, reflete cerca de 50 a 72% e absorve cerca de 1 a 6% do fluxo de radiação solar incidente no topo. Já, uma nuvem altostratus de espessura de 0,6 km tem reflexão variando entre 55 a 77% e absorção de 30 a 40%.

Tradicionalmente, essas condições de nebulosidade (ou cobertura de nuvens), podem ser identificadas através do índice de claridade, também chamado de coeficiente de transmitância atmosférica global (K_t). Este índice é obtido pela razão entre a radiação solar global incidente na superfície e a radiação solar incidente no topo da atmosfera (IQBAL, 1983). Diversos estudos têm sido realizados com o intuito de avaliar a variabilidade para medidas pontuais da radiação solar global em relação aos efeitos das condições de nebulosidade (transmitância atmosférica) e da sazonalidade. Estes trabalhos mostram que uma camada de nuvem pode causar um aumento ou diminuição na ordem de 50% da radiação solar incidente na superfície (SOUZA, 1997; AGUIAR, 1997;

SEGAL; DAVIS, 1992; PALIATSOS et al. 2003; SOUZA et al. 2005; SILVA, 2007).

O espalhamento é um processo físico que ocorre em todos os comprimentos de onda do espectro eletromagnético, caracterizado pela remoção de energia da onda incidente pelas partículas ou moléculas de gases no seu caminho e dispersão dessa energia em outras direções. O regime de espalhamento é determinado a partir da razão entre o tamanho do espalhador e o comprimento de onda da radiação incidente, através da definição do termo físico chamado parâmetro de tamanho.

O regime de espalhamento Rayleigh ocorre quando a partícula espalhadora é muito menor do que o comprimento de onda da radiação incidente, como é o caso do espalhamento da radiação visível realizado pelas moléculas de ar. Para partículas cujos tamanhos são comparáveis ou maiores do que o comprimento de onda da radiação predomina o espalhamento Lorenz-Mie (LIOU, 2002).

Partículas de aerossóis em suspensão na atmosfera influenciam fortemente o balanço radiativo da atmosfera e o clima, a química da atmosfera e a visibilidade, desde a escala local até as escalas regional e global (ARTAXO et al. 2006). Os aerossóis atmosféricos podem influenciar o balanço de radiação de dois modos: direto e indireto. Na presença de aerossóis espera-se uma diminuição da radiação solar que chega à superfície, devido à influência direta e indireta da presença de aerossóis (LIEPERT; KUKLA, 1997). O efeito direto ocorre a partir do espalhamento ou de absorção de radiação solar pelas partículas. O efeito indireto ocorre devido ao fato das partículas de aerossóis atuarem como núcleos de condensação de nuvens (NCN), podendo alterar as propriedades físicas e ópticas das nuvens, tais como distribuição do tamanho das gotas e albedo (KAUFMAN; NAKAJIMA, 1993; TWOMEY, 1977; KAUFMAN; FRASER, 1997).

2.2. Descrição Geral da Área em Estudo

A região em estudo compreende a região Nordeste do território brasileiro, abrangendo grande variedade de fatores climatológicos e antrópicos característicos dessas regiões. Este tópico descreve, sucintamente, as principais características climatológicas desta região do Brasil. Para uma referência mais completa, sugere-se a leitura de (CAVALCANTI et al. 2009).

A Região Nordeste do Brasil possui uma área territorial de 1.558.196 km², correspondendo a 18% do território nacional. Segundo (KAYANO; ANDREOLI, 2009), a região costuma ser dividida em três climas principais, com precipitações anuais variando entre 300 e 2000 mm: clima litorâneo úmido, estendendo-se do litoral da Bahia ao do Rio Grande do Norte, clima tropical, em áreas dos estados da Bahia, Ceará, Maranhão e Piauí, e clima tropical semiárido, em todo o sertão nordestino. É a região do país mais subdividida politicamente, com nove estados: Alagoas, Bahia, Ceará, Maranhão, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe.

O Nordeste apresenta elevados valores de médias anuais de temperatura do ar, que variam de 20 a 28 °C, em virtude da alta incidência de radiação solar, que lhe confere o maior potencial de energia solar disponível no Brasil, com uma radiação global média estimada em 5,9 kWh/m² de acordo com o Atlas Brasileiro de Energia Solar (PEREIRA et al. 2006). Em áreas elevadas da Chapada Diamantina e do Planalto da Borborema, as médias anuais de temperatura atingem valores inferiores a 20°C (KAYANO; ANDREOLI, 2009; PEREIRA et al. 2006).

A precipitação na Região Nordeste apresenta distribuição desigual ao longo do ano e apresenta grande variabilidade espaço-temporal. A precipitação está associada a sistemas sinóticos ou circulações atmosféricas regionais, tais como os Anticiclones Subtropicais do Atlântico Sul (ASAS) e Atlântico Norte (ASAN), e o cavado equatorial (KAYANO; ANDREOLI, 2009). A caracterização das chuvas no Nordeste é bastante complexa, sendo identificados três regimes de precipitação: no Norte da região (Ceará, Rio Grande do Norte, interior da

Paraíba e Pernambuco) as chuvas ocorrem no outono associadas ao deslocamento mais ao sul da Zona de Convergência Intertropical (ZCIT) (KOUSKY, 1979; MOLION, 2002; MENEGHETTI; FERREIRA, 2009); no litoral Leste (desde o litoral do Rio Grande do Norte até a Bahia) as precipitações são devido à influência das massas de ar tropical ou por distúrbios ondulatórios de leste (MENEGHETTI; FERREIRA, 2009), e na parte Sul (Bahia e partes do Maranhão, Piauí e Pernambuco) a precipitação ocorre no verão pela atuação de sistemas frontais, convecção local e vórtices ciclônicos (MENEGHETTI; FERREIRA, 2009).

2.3. Modelos Numéricos de Mesoescala: O Modelo WRF

Vários modelos numéricos de mesoescala como, por exemplo, o RAMS (*Regional Atmospheric Modeling System*) descrito em Cotton et al. (2003), o RSM (*Regional Spectral Model*) descrito em Juang e Kanamitsu (1994), o MM5 descrito em Duhdia et al. (2005), resolvem processos físicos desde a superfície até a alta atmosfera. Estes modelos são aplicados desde estudos de previsão de tempo, até a avaliação de dispersão de poluentes. O modelo atmosférico WRF (*Weather Research and Forecasting*) é um modelo de previsão numérico de tempo, desenvolvido tanto para fins de pesquisa quanto operacionais. Foi desenvolvido conjuntamente por uma série de instituições e agências governamentais: *National Center for Atmospheric Research* (NCAR), *National Oceanic and Atmospheric Administration* (NOAA), *Forecast Systems Laboratory* (FSL), *Air Force Weather Agency* (AFWA), *Naval Research Laboratory*, *Oklahoma University* e *Federal Aviation Administration* (FAA). O desenvolvimento do modelo conta ainda com a participação de cientistas de várias universidades. Foi concebido para ser uma ferramenta de topo na arte da simulação atmosférica, flexível e eficiente em variadas plataformas de computação. O modelo WRF é de domínio público sendo disponibilizado gratuitamente (SKAMAROCK et al. 2005, 2008). Ele tem um código-fonte

simples, o que facilita o seu entendimento e aplicação. Possui um sistema de assimilação de dados com captação em três dimensões. Além disso, pode ser configurado para resoluções horizontais desde a escala de metros até milhares de quilômetros. As principais parametrizações físicas deste modelo estão divididas em cinco categorias distintas: microfísica, parametrização de nuvens, parametrização da CLP, modelos de ocupação do solo e radiação. As opções de esquemas físicos foram sendo incorporadas ao WRF com a intenção de produzir um único sistema de modelagem. Assim, o maior problema enfrentado consiste em escolher um grupo de parametrizações que seja adequado às condições da região a ser estudada e também à capacidade computacional disponível.

O funcionamento do WRF no eixo horizontal é baseado na grade de Arakawa-C. Esta adota as componentes do vento u e v da velocidade horizontal no centro das faces das células, com as demais variáveis termodinâmicas inseridas no centro de cada célula. As simulações são realizadas em quatro dimensões, pois a cada passo de tempo a malha horizontal repete-se em todos os níveis verticais. O WRF permite aninhamento de domínios, ou seja, é possível inserir domínios menores dentro dos domínios maiores.

Os níveis verticais são fornecidos ao modelo em coordenadas sigma que, junto ao solo, acompanham o contorno do terreno, conforme ilustra a Figura 2.4. A coordenada sigma é relacionada com a pressão atmosférica, então possui formulação mais simples, favorecendo a resolução eficiente da equação do movimento na simulação de campos de advecção de temperatura e vento, principalmente sobre terrenos suavizados.

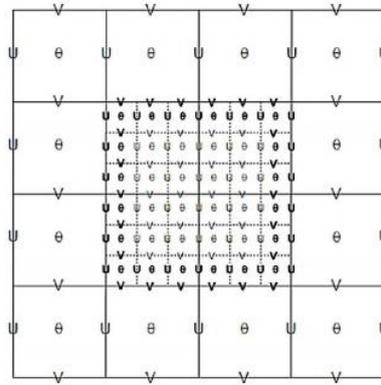


Figura 2.3 – Representação de grade de Arakawa-C.
 Fonte: Skamarock et al. (2005, 2008).

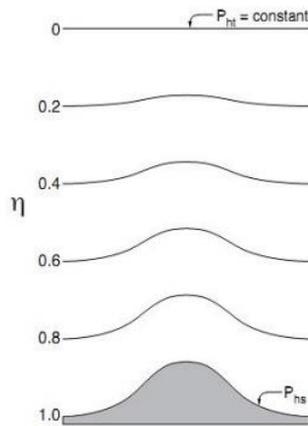


Figura 2.4 – Coordenadas vertical sigma.
 Fonte: Skamarock et al. (2005, 2008).

Alguns fenômenos atmosféricos importantes e que influenciam determinadas variáveis meteorológicas ocorrem em escalas espaciais menores que a resolução espacial utilizada para a solução das equações. Para que os efeitos destes fenômenos sobre as variáveis meteorológicas sejam levados em consideração é necessário que de alguma forma estes fenômenos possam ser resolvidos. Assim, procura-se um equilíbrio estatístico entre os fenômenos e variáveis; logo, o que irá interessar será o efeito estatístico sobre o fluxo dos fenômenos de pequena escala. Este processo descrito chama-se parametrização. No WRF, alguns dos fenômenos parametrizados são:

radiação, convecção e microfísica. Neste estudo foi realizada uma avaliação dessas três categorias de parametrizações.

O processo radiativo é o mais importante da atmosfera sendo responsável por todo balanço de energia que alimenta os demais processos atmosféricos. O esquema de parametrização de radiação reproduz os efeitos da radiação de ondas curta e longa na atmosfera e no solo e sua interação com alguns componentes da atmosfera.

Os processos relacionados com movimentos ascendentes ocasionados por diferenças de densidade ou por forçantes topográficas ocorrem muitas vezes em escalas espaciais menores do que o espaçamento utilizado na resolução das equações do modelo. Como exemplo, tem-se a formação de uma nuvem Cumulonimbus, a qual possui dimensões espaciais horizontais menores do que a maioria das resoluções horizontais utilizadas nos modelos. Desta maneira, estes processos convectivos necessitam ser parametrizados.

Muitas vezes os processos convectivos estão associados à formação de nuvens e conseqüentemente precipitação, além da transferência de momento e de propriedades térmicas entre as camadas mais baixas e mais altas da atmosfera. Esta distribuição de propriedades na coluna atmosférica poderá produzir instabilidade atmosférica e, assim, resultar na formação de nuvens.

Muitos modelos e esquemas de nuvens tratam de processos específicos para representar a precipitação. O esquema de microfísica de nuvens trata de forma explícita a formação dos hidrometeoros constituintes de uma nuvem.

Essencialmente, a parametrização de microfísica descreve a evolução das características de hidrometeoros no tempo, os mecanismos de interação entre as mesmas e a permanente troca de vapor e calor com a fase gasosa. As categorias inicialmente envolvidas nos processos microfísicos são as gotículas de nuvens e cristais de gelo. Este tipo de parametrização garante certa versatilidade ao usuário, ao permitir que o experimento numérico seja conduzido dentro de certas restrições por ele estabelecidas, como por exemplo, a escolha do conjunto de hidrometeoros a serem introduzidos na

simulação, como também é possível que o usuário defina o diâmetro médio para cada categoria de gelo e água nos processos de microfísica (SKAMAROCK et al. 2005; 2008).

2.4. Análise de Agrupamento (AA)

A técnica estatística de análise multivariada tornou-se popular nas análises de dados atmosféricos após Lorenz (1956). A partir daí, inúmeros pesquisadores fizeram uso de tais técnicas como Ceballos e Braga (1995), Esteban et al. (2006), Frago e Gomes (2008) e outros que empregaram em uma variedade de aplicações meteorológicas. A Análise em Componentes Principais (ACP) e a Análise de Agrupamento (AA) são algumas técnicas de análise multivariada muito utilizada em ciências atmosféricas, seja em conjunto ou separadamente. As técnicas de análises multivariadas permitem reduzir a dimensão da matriz de observações sem perder as informações importantes dos dados originais; investigam o comportamento espaço-temporal das variáveis envolvidas no problema, assim como detectam grupos de variáveis que apresentem comportamento homogêneo.

A Análise de Agrupamento (AA) tem sido consolidada como uma das maneiras mais úteis no processo de filtrar dados para descobrir grupos homogêneos e identificar padrões que estejam ocultos nos dados (HALKIDI et al. 2001). A Análise de Agrupamento (AA) permite a exploração de séries temporais onde as variáveis classificatórias são inicialmente separadas em grandes grupos, utilizando para isso uma medida de similaridade ou dissimilaridade (AMANAJÁS et al. 2010; LIMA et al. 2010; WILKS, 2006), fornecendo assim a espacialização de regiões climaticamente homogêneas. Com isso a AA se revela ferramenta significativa na regionalização de series temporal e distribuição de dados espacial.

A Análise de Agrupamento é aplicada para pesquisa geofísica desde 1960. Uma pesquisa detalhada da literatura de análise de agrupamento usada nos

campos da geofísica foi realizada dando conta que vários métodos de análise de agrupamento foram extensamente usados em tipos diferentes de problemas em pesquisa atmosféricas (GONG e RICHMAN, 1995).

Esta técnica estatística de análise multivariada tem como objetivo principal classificar os indivíduos de uma população que são conhecidos por suas características, em grupos que sejam homogêneos intragrupos e heterogêneos intergrupos. As técnicas objetivas de agrupamentos diminuem a subjetividade, pois quantificam a similaridade ou dissimilaridade entre indivíduos. Dentre os vários métodos ou algoritmos de classificação de grupos estão aqueles que utilizam as técnicas hierárquicas. Neste, a partição se dá a partir de um número de grupo não definido inicialmente, onde os grupos majoritários são divididos em subgrupos minoritários agrupando aqueles indivíduos que apresentam características semelhantes.

O objetivo principal da Análise de Agrupamento é reunir objetos, baseando-se nas características dos mesmos. Ela os classifica segundo o que cada elemento tem de similar em relação a outros determinados grupos, considerando um critério de seleção predeterminado. O grupo resultante dessa classificação devem então exibir um alto grau de homogeneidade interna e alta heterogeneidade externa (CORRAR et al. 2007). Assim, se a classificação for bem sucedida, os objetos dentro dos agrupamentos estarão próximos quando representados graficamente e diferentes agrupamentos estarão distantes (HAIR et al. 2005). Essa técnica é comparável à análise de componentes principais em seu objetivo de determinar a estrutura.

Portanto, o problema que se pretende resolver é: dada uma amostra de n objetos, ou indivíduos, cada um deles medidos segundo p variáveis, procurar um esquema de classificação que agrupe objetos em g grupos. Deve ser determinado também o número e as características meteorológicas desses grupos.

A classificação dos indivíduos em grupos distintos é feita a partir de uma função de agrupamento denominada distância ou similaridade e de um critério

matemático de agrupamento (BOUROCHE; SAPORTA, 1982). Tanto a distância euclidiana, medida de dissimilaridade, quanto o coeficiente de correlação, medida de similaridade, podem ser usados na determinação dos grupos.

A distância Euclidiana é a medida de dissimilaridade mais comumente usada em agrupamentos, embora muitas outras medidas de distância existam. Uma discussão detalhada de várias dissimilaridades é apresentada em (DURAN; ODELL, 1974). De acordo com Wilks (2006) esta função é usada como critério para medir a distância entre dois pontos X_i e X_j ou para estabelecer o quanto eles são parecidos. Logo, distancia euclidiana entre dois indivíduos é dada pela Equação 2.1.

$$d_{ij} = [X_i - X_j] = \left[\sum_{k=1}^n (X_{i,k} - X_{j,k})^2 \right]^{1/2} \quad (2.1)$$

Dois métodos de agrupamento, os hierárquicos e o não hierárquicos, são utilizados para a determinação dos grupos homogêneos. Nos métodos hierárquicos vários critérios de agrupamentos são possíveis, dentre eles optou-se pelo método de Ward (1963).

Este método procura por partições que minimizem a perda associada a cada agrupamento (EVERITT, 1974; BUSSAB et al. 1990; MINGOTI, 2005). Essa perda é quantificada pela diferença entre a soma dos erros quadráticos de cada padrão e a média da partição em que está contido, ou seja, a perda de informação, que resulta do agrupamento de indivíduos em grupos, pode ser medida pela soma total do quadrado dos desvios de todos os pontos em torno da média do grupo para o qual estão contidos. A soma dos erros quadrados é definida como:

$$SQD = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \quad (2.2)$$

onde n é o número total de elementos do agrupamento e x_i é o i -ésimo elemento do agrupamento.

Algumas características desse método são:

- Apresenta bons resultados tanto para distâncias euclidianas quanto para outros métodos de dissimilaridade;
- Pode apresentar resultados insatisfatórios quando o número de elementos em cada grupo é praticamente igual;
- Apresenta tendência a combinar grupos com poucos elementos.

As etapas descritas anteriormente, embora instrutivas acerca do processo de agrupar indivíduos, não facilitam a interpretação dos resultados a respeito de como serão obtidos os grupos e o número deles num processo de agrupamento. Necessita-se de instrumentos mais apropriados; um deles é o dendrograma que é uma representação gráfica muito usada na análise de agrupamento para apresentar o resultado de um agrupamento.

2.5. Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são ferramentas estatísticas capazes de armazenar conhecimento a partir de exemplos e serem empregadas na solução de problemas de ajuste funcional, reconhecimento de padrões e diversas outras aplicações. Esta forma de computação não algorítmica é caracterizada por sistemas que em algum nível, relembram a estrutura do cérebro humano. Por não ser baseada em regras ou programas, a computação neural se constitui em uma alternativa à computação algorítmica convencional (BRAGA, 1998). Ainda, uma rede neural artificial (RNA) é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento e torná-lo

disponível para o uso (HAYKIN, 2001). As RNAs assemelham-se ao cérebro em dois aspectos: o primeiro é o conhecimento adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; o segundo são as forças de conexão entre neurônios, conhecidas como pesos sinápticos, que são utilizadas para armazenar o conhecimento adquirido.

Em RNAs, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, na qual um conjunto de exemplos é apresentado para a rede, que extrai automaticamente as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas para o problema (BRAGA, 1998). As RNAs possuem a capacidade de representar fenômenos físicos complexos e por isso vêm sendo largamente utilizada nas geociências, propiciando grandes avanços na área de modelagem (MENDES; MARENGO, 2010, MARTINS et al. 2012).

O emprego de uma RNA passa inicialmente por uma fase de aprendizagem, onde os pesos das conexões são ajustados até proporcionarem à rede a capacidade de representar o problema. Uma vez treinada, os pesos são fixados e a rede pode ser empregada como um modelo, estimando saídas a partir de um conjunto de dados de entrada.

2.5.1. Perceptrons de Múltiplas Camadas

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Fazem parte da arquitetura da rede os seguintes parâmetros:

- O número de camadas;
- O número de neurônios em cada camada;
- O tipo de conexão entre os neurônios e topologia da rede.

Existem duas classificações para as RNAs: recorrentes (*feedback*) e não-recorrentes (*feedforward*). A RNA não recorrente pode conter uma única camada ou múltiplas camadas sendo que esta última possui as chamadas camadas ocultas (*hidden layers*). As RNAs com mais de uma camada oculta são denominadas Perceptrons de Múltiplas Camadas (*multilayer perceptron – MLP*) conforme ilustrado na Figura 2.5. Ainda, a RNA não recorrente possui retroalimentação, ou seja, após a primeira iteração a saída realimenta as entradas da RNA.

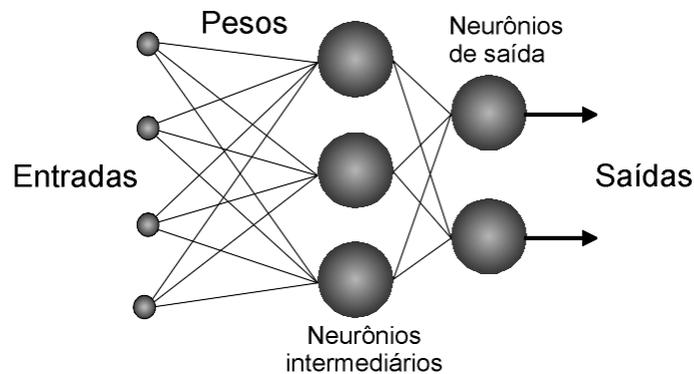


Figura 2.5 – Representação de uma RNA-MLP.
Fonte: Adaptado de Haykin (2001).

Dentre os vários tipos e topologias de RNAs, o modelo MLP de treinamento supervisionado é uma das arquiteturas mais empregadas na atualidade em numerosas áreas de ciência e tecnologia (HAYKIN, 1994; FIORIN, 2009; MENDES; MARENGO, 2010; GONÇALVES, 2011; MARTINS et al. 2012).

2.5.2. Neurônio Artificial

O neurônio artificial é a unidade fundamental da RNA e, de acordo com a representação da Figura 2.6, é um modelo composto por três elementos básicos: pesos sinápticos, função aditiva e função de ativação.

O elemento x_i representa um sinal de entrada de um determinado neurônio k_i o qual possui um peso sináptico w_{ki} , onde o primeiro subscrito refere-se ao

neurônio em questão e o segundo subscrito refere-se ao sinal de entrada para qual o peso sináptico se refere. Os valores dos pesos sinápticos podem ser negativos ou positivos de acordo com a relevância a ser dada pelo neurônio ao sinal daquela conexão, indicando se o tratamento deve ser inibitório ou excitatório, respectivamente.

O nível de atividade interna do neurônio (v_i) é resultado da combinação do somatório das entradas ponderadas com outro valor ajustável denominado *bias* (b_i). O *bias* tem a função de aumentar ou diminuir a entrada líquida da função de ativação ($\varphi(\cdot)$) dependendo se ele é positivo ou negativo.

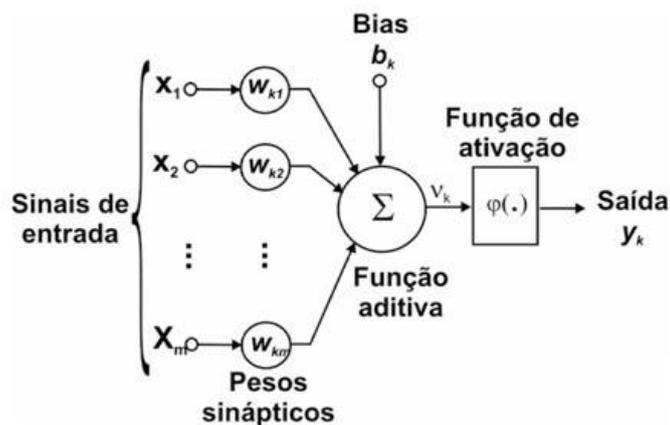


Figura 2.6 – Modelo de um neurônio.
Fonte: Adaptado de Haykin (2001).

O neurônio índice j pode ser definido por:

$$v_j = \sum_{i=1}^m w_{ji} x_i + b_j \quad (2.3)$$

$$y_j = \varphi(v_j) \quad (2.4)$$

A função de ativação define a saída de um neurônio de acordo com o nível de atividade produzida pelas suas entradas. De acordo com Braga et al. (1998) e Haykin (2001), as funções de ativação comumente empregadas são: Função

Degrau, Função Linear, Função Sigmoide Logística e Função Sigmoide Tangente Hiperbólica representadas na Figura 2.7. A função sigmoide é a mais comumente usada na construção de RNAs tipo MLP (HAYKIN, 2001), por serem contínuas, crescentes, diferenciáveis e não lineares.

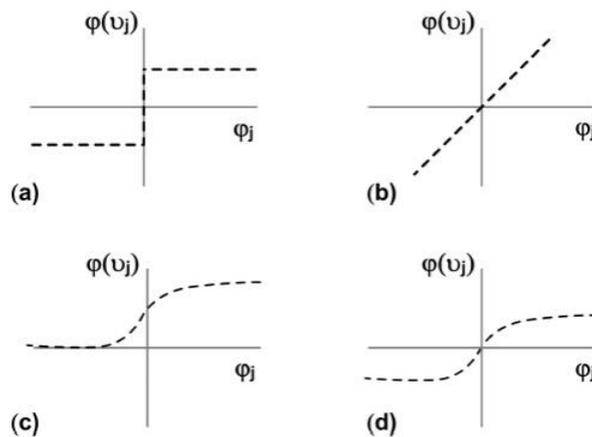


Figura 2.7 – Sinais de saída de diferentes funções de ativação: a) função degrau; b) função linear; c) função sigmoide logística; d) função sigmoide tangente hiperbólica.

2.5.3. Aprendizado da RNA

A utilização de uma RNA na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação apresentados para ela, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando (BRAGA, 1998). O ajuste dos pesos sinápticos é chamado de algoritmo de treinamento, sendo que o treinamento pode ser classificado como treinamento supervisionado e treinamento não supervisionado.

No treinamento supervisionado, um sinal de entrada e um valor alvo são apresentados à rede, e a partir da entrada a rede calcula a saída, a qual é comparada com o alvo repetindo esse procedimento até a RNA atingir o melhor resultado ajustando os pesos sinápticos. A cada interação, a RNA adapta-se para corrigir os erros ($e(t)$) procurando minimizar a diferença entre a soma ponderada das entradas pelos pesos sinápticos, ou seja, a saída da RNA ($y(t)$) calculada no instante t , e o alvo ($d(t)$). O erro é determinado pela seguinte equação:

$$e(t) = d(t) - y(t) \quad (2.5)$$

A alteração dos pesos sinápticos por correção dos erros é representado pela equação

$$w_{ji}(t + 1) = w_{ji}(t) + \eta e(t) x_{ji}(t) \quad (2.6)$$

onde o peso sináptico w_{ji} do neurônio j recebe o ajuste $\Delta w_{ji}(t)$ e assume um novo valor $w_{ji}(t + 1)$. O ajuste é obtido pela minimização da chamada função de custo expressa como:

$$E(t) = \frac{1}{2} e_j^2(t) \quad (2.7)$$

A minimização desta função para o caso particular de um neurônio de saída com função de ativação linear resulta na regra delta (WIDROW; HOFF, 1960) que afirma que o ajuste de um peso é proporcional ao produto entre o erro e a entrada da sinapse (x_i).

Um dos algoritmos mais utilizados para o treinamento de redes MLP é o algoritmo supervisionado chamado backpropagation. Neste algoritmo, ocorre numa primeira fase a propagação do sinal funcional (*feedforward*) e numa segunda fase a retropropagação do erro (*backpropagation*). Na primeira fase, a partir das entradas, o sinal funcional propaga-se pela rede até a geração de uma saída, mantendo-se fixos os pesos das sinapses. Na segunda fase, a

saída é comparada com um alvo produzindo um sinal de erro. O sinal de erro propaga-se da saída para entrada, e os pesos são ajustados de maneira a minimizar o erro (GUARNIERI, 2006).

2.6. Trabalhos Relevantes na Área de Interesse

Diversos são os trabalhos de estimativa da radiação solar global em função de outras variáveis meteorológicas, tais como duração do brilho solar, nebulosidade, temperatura do ar, pressão atmosférica, umidade relativa do ar e precipitação pluvial (KIMBAL, 1919; ÅNGSTRÖM, 1924; PRESCOTT et al. 1940; ALLEN et al. 1997; SUEHRCKE, 2000; WONG; CHOW, 2001; LIU; SCOTT, 2001). A escolha da variável que define a estimativa fica a critério da disponibilidade do elemento meteorológico, que também é uma dificuldade quando se pretende mapear uma região. Dentre os trabalhos de estimativa destacam-se Tiba (1997, 2000) para Nordeste Brasileiro (NEB) e para o Brasil, e Nicácio (2002) para 5 regiões de Maceió–AL. Recentemente, observam-se estudos utilizando novas técnicas, como modelos de lógica fuzzy e Redes Neurais.

Bennett (1965) relatou a confecção de mapas mensais de médias diárias de radiação solar para os Estados Unidos. Neste trabalho foram testados vários modelos estatísticos visando suprir a falta de dados ou dados incompletos em algumas estações. Muitas estações de coleta tiveram os dados desconsiderados pela falta de confiabilidade nos mesmos e substituídos por valores estimados. Foram gerados 12 mapas mensais de médias diárias de radiação solar.

Em 1987, a Organização Latino Americana de Energia (OLADE) publicou o Atlas de Climatologia Solar para a América Latina e Caribe. O Atlas foi feito a partir de pesquisas sobre a solarimetria física e modelos de estimação existentes. A base de todo o cálculo se estabeleceu nas medidas de insolação, pois as medidas de radiação eram, como hoje, escassas. Devido à falta de

consenso sobre o melhor modelo a ser aplicado nos diversos países, optou-se por determinar, inicialmente, o K_t para aplicação no modelo de Ångström. Com esta equação foram determinados os valores de K_t para cada ponto sobre o território em questão. Com o K_t conhecido e a correspondente latitude, tem-se finalmente o valor de irradiação global. O Atlas com mapas de radiação apresenta 12 cartas mensais por sub-região e para cada uma das componentes da radiação solar: radiação global máxima média mensal e radiação máxima direta média mensal (OLADE, 1987).

Kessler e Corbella (1979) utilizaram dados de 25 estações de medida do IPAGRORS (Instituto de Pesquisa Agropecuária do Rio Grande do Sul), utilizando diferentes períodos para cada estação, variando de doze a quinze anos. As cidades sem estações de coleta tiveram todos os seus dados estimados pela modelo de Ångström–Prescott. Foram encontradas possíveis fontes de erro nos valores estimados, utilizando-se um único valor de a e b para todo o estado.

O Atlas Solarimétrico do Brasil (TIBA, 2000) e o Atlas Brasileiro de Energia Solar (PEREIRA et al. 2006), são as principais publicações para o Brasil.

Outra importante fonte de informação é o serviço disponibilizado operacionalmente pelo CPTEC em seu portal de INTERNET, que fornece dados de irradiância diários médios obtidos com o uso do modelo de transferência radiativa GL (satelite.cptec.inpe.br/radiacao/) a partir de imagens do satélite GOES.

Em Janeiro de 1993, sob a coordenação do Centro de Pesquisas de Eletricidade da ELETROBRÁS, foi criado um Grupo de Trabalho em Energia Solar Fotovoltaica – GTEF. O GTEF tinha uma abrangência nacional e foi constituído por empresas do setor elétrico, grupos de pesquisas, universidades e fabricantes ou representantes de equipamentos; em maio de 1996 foi assinado o convênio que permitiu executar a criação do Atlas Solatimétrico do Brasil. Elaborado utilizando publicações nacionais sobre solarimetria nos anos anteriores, foram escolhidas publicações que continham dados de radiação, de

insolação, mapas solarimétricos, mapas climatológicos e fitogeográficos do Brasil e de países limítrofes.

Na Figura 2.8 mostra-se a média anual de radiação solar incidente obtida por interpolação. Observa-se uma média anual de 18 MJ/m² para a região Nordeste, área de estudo para o desenvolvimento deste trabalho. Para toda a região de interesse não se observa uma variação na irradiação solar; por isso necessita-se de uma base de dados de uma maior resolução para o desenvolvimento desta pesquisa.

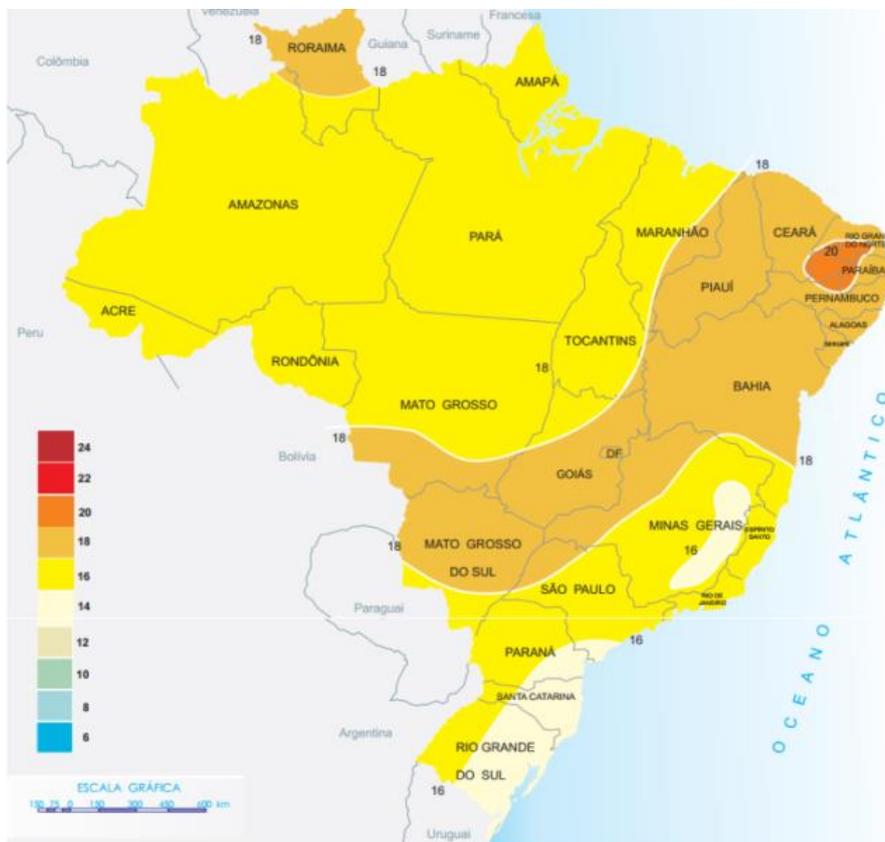


Figura 2.8 – Média anual de radiação solar em superfície em MJ/m². Fonte: Atlas Solarimétrico do Brasil. Fonte: TIBA (2000).

O Atlas Brasileiro de Energia Solar foi desenvolvido dentro do escopo do projeto SWERA (*Solar and Wind Energy Resource Assessment*), financiado pelo Programa das Nações Unidas para o Meio Ambiente (PNUMA) e pelo

Fundo Global para o Meio Ambiente (GEF). O projeto, iniciado em 2002, teve como foco principal promover o desenvolvimento de uma base de dados confiável e de alta qualidade, visando auxiliar no planejamento e concepção de políticas públicas de incentivo a projetos nacionais de energia solar e eólica e atrair investimentos da iniciativa privada para área de energias renováveis. Este trabalho contou com a contribuição do ASRC – Centro de Pesquisa em Ciências Atmosféricas / Universidade Estadual de Nova York em Albany/EUA, do DLR – Centro Aeroespacial Alemão, do NREL – Laboratório Nacional de Energias Renováveis dos EUA, do TERI – Instituto de Recursos Energéticos na Índia e do Instituto Nacional de Pesquisas Espaciais.

O Atlas Brasileiro de Energia Solar foi elaborado com uso de um modelo de transferência radiativa BRASIL-SR. Trata-se de um modelo físico utilizado na obtenção de estimativas da irradiação solar incidente na superfície, que teve como base o modelo alemão IGMK (STUHLMANN et al. 1990). Utilizando a aproximação de “Dois-fluxos” na solução da equação de transferência radiativa, o modelo faz uso de dados climatológicos (temperatura do ar, albedo de superfície, umidade relativa, visibilidade atmosférica) e elevação da superfície. A cobertura de nuvens é considerada como principal fator de modulação da transmitância atmosférica, sendo determinada a partir de imagens de satélite geoestacionário (MARTINS, 2001). Os arquivos com os dados de entrada são preparados através da base de dados climatológicos e do processamento das imagens de satélite para o período de execução, onde é obtida a cobertura efetiva de nuvens. Após o tratamento dos dados de entrada, o modelo resolve a equação de transferência radiativa utilizando a aproximação de “Dois-Fluxos” para o cálculo das componentes do fluxo de radiação solar.

As estimativas de irradiação solar fornecidas pelo modelo BRASIL-SR foram validadas por meio de comparação com valores medidos em superfície em estações distribuídas pelo território brasileiro. Foram utilizados dados coletados em estações da rede SONDA (Sistema de Organização Nacional de Dados Ambientais para o Setor Energético).

O mapa da Figura 2.9 mostra a média anual do total diário de irradiação solar global incidente no território brasileiro. Apesar das diferentes características climáticas observadas no Brasil, pode-se observar que a média anual de irradiação global apresenta boa uniformidade, com médias anuais relativamente altas em todo o país. O valor máximo de irradiação global, 6,5 kWh/m², ocorre no Norte do estado da Bahia, próximo à fronteira com o estado do Piauí. A menor irradiação solar global, 4,25 kWh/m², ocorre no litoral norte de Santa Catarina.



Figura 2.9 – Média anual da radiação solar global.
Fonte: Atlas Brasileiro de Energia Solar (PEREIRA et al. 2006).

2.6.1. Aplicações das Redes Neurais Artificiais

No contexto de previsão, para a construção de um modelo de RNA é necessário definir as variáveis preditoras que são utilizadas como entradas para a rede, e os preditandos, que são as saídas. Previsões de radiação solar, temperatura do ar, precipitação, temperatura de superfície do mar (TSM), dentre outros, já foram realizadas, tendo como base séries temporais da variável a ser estimada (GREISCHAR; HASTENRATH, 2000; YUVAL, 2000; TANGANG et al. 1998). Posteriormente, foram também incorporadas outras variáveis meteorológicas como preditores da variável a ser estimada.

Segundo Guarnieri (2006), apesar de tratar-se de uma ferramenta estatística que considera relações empíricas entre as variáveis meteorológicas, as RNAs têm-se apresentado como um método alternativo com boa destreza frente a problemas não lineares ou de natureza estocástica, como os complexos processos físicos que influenciam na disponibilidade de energia solar e eólica.

Guarnieri (2006) comparou RNAs e regressão linear múltipla para estimativas de radiação solar utilizando dados de previsões fornecidas pelo modelo Eta como preditores. Seus resultados demonstraram que há um ganho significativo em relação às saídas do modelo, mas o desempenho das regressões e da RNA foi similar. Uma justificativa seria que os processos físicos relacionados à determinação da radiação não apresentariam grandes não linearidades que justificassem um melhor desempenho das RNAs.

Mendes e Marengo (2010) utilizaram uma rede tipo MLP para o refinamento das saídas de precipitação de modelos climáticos do IPCC sobre a região amazônica, obtendo resultados bem superiores em relação a modelos auto regressivos.

Soares et al. (2004) utilizaram redes MLP de 3 camadas, treinadas com o algoritmo padrão *backpropagation* com momento, para modelar a radiação solar difusa horária na cidade de São Paulo. Os autores constataram que valores medidos de irradiação solar global na superfície, a irradiação solar no topo da atmosfera (TOA), valores de umidade relativa e da irradiação de onda longa são informações relevantes para esta aplicação de RNA. Neste estudo,

os autores verificaram que a temperatura do ar e a pressão atmosférica não influenciavam na precisão e confiabilidade das estimativas produzidas e enfatizaram que medidas de irradiação de onda longa podem substituir dados de nebulosidade quando estes não estão disponíveis.

Al-Alawi e Al-Hinai (1998) empregaram uma rede MLP com 15 nodos na camada interna para estimativa de valores médios mensais de radiação solar global, utilizando como dados de entrada os valores diários de pressão, temperatura, umidade relativa, velocidade do vento, duração de brilho do Sol e latitude da estação. O modelo desenvolvido apresentou boa capacidade de generalização, estimando a irradiação solar global para sítios não utilizados no treinamento com precisão da ordem de 95%.

Elminir et al., (2005) utilizaram RNAs do tipo MLP, treinadas com o algoritmo de *Levenberg-Marquardt*, para previsão de valores diários de irradiação solar global, irradiação de onda longa e irradiação ultravioleta, utilizando dados de temperatura do ar, umidade do ar, cobertura de nuvens, direção e velocidade do vento. Os resultados obtidos apresentaram boa correlação entre os valores previstos e medidos, tanto para a estação onde a rede foi treinada, quanto para uma segunda estação, demonstrando a capacidade de generalização do modelo desenvolvido.

Stetsos e Coonick (2000) testaram diferentes tipos de RNAs, tais como redes MLP, RBF, ANFIS, recorrentes de Elman, além de regressão linear, para a previsão da irradiação solar horária utilizando séries temporais de temperatura, pressão, velocidade e direção do vento. Os melhores resultados foram obtidos empregando a rede do tipo MLP treinada pelo algoritmo de *Levenberg Marquardt*.

Chevallier et al. (1998), investigaram a possibilidade de elaborar uma nova geração de modelos de transferência radiativa com base em técnicas de redes neurais artificiais. Os autores mostram com sucesso a derivação com precisão do balanço radiativo de onda longa. Dois modelos de transferência radiativa são aplicados para o cálculo da parte radiativa do conjunto de dados: um

modelo de linha por linha e um modelo de banda. Ambos alcançaram uma precisão comparável ao atual modelo de circulação de transferência radiativa, entretanto, muito mais rapidamente.

Dürr e Philipona (2004) apresentaram um algoritmo de detecção automática da fração de cobertura de nuvens baseados apenas em medidas exatas de radiação de onda longa descendente, temperatura e umidade relativa do ar na altura da estação. O método fornece cobertura de nuvens a cada 10 minutos durante o dia e à noite e é aplicável às estações de radiação sem conhecimento de observações sinóticas de nuvens, com resultados bastante satisfatórios.

Weigang et al. (1996) utilizaram uma série de dados de anomalias de precipitação sobre o Nordeste do Brasil, para gerar um modelo de previsão baseado numa RNA.

Valverde et al. (1999) fazendo uso de imagens do radar de Bauru e imagens do satélite GOES-8, construíram uma arquitetura de RNA para prever precipitação sobre a área central do estado de São Paulo.

3 DADOS E METODOLOGIA

3.1. Dados

Neste tópico serão descritos os dados utilizados na pesquisa. O presente estudo envolve a utilização dos seguintes tipos de dados:

- Dados de irradiação solar horário de estações meteorológicas automáticas para o Nordeste do Brasil. O período de estudo compreende os anos de 2005 a 2011.
- Saídas do modelo atmosférico global GFS (*Global Forecast System*) do NCEP (*National Center for Environmental Prediction*) para o período compreendido nos anos de 2005 a 2011 foram usadas para a inicialização das simulações com o modelo WRF. Os dados apresentam resolução espacial de 1° e resolução temporal de 6 horas.

3.1.1. Dados Observados

Os dados utilizados nesta pesquisa foram observações médias horárias de irradiação solar global para um período de sete anos, janeiro de 2005 a dezembro de 2011, coletados em estações distribuídas em toda a região Nordeste do Brasil. Trata-se de 121 estações meteorológicas automáticas de superfície operadas pelo Instituto Nacional de Meteorologia (INMET).

Estas estações contêm sensores para medição de parâmetros meteorológicos como pressão atmosférica, temperatura, precipitação, radiação solar, entre outras. A radiação solar é medida por um piranômetro da Kipp & Zonen. No Anexo A e na Figura 3.1, apresenta-se as localizações das estações automáticas do INMET, no Nordeste do Brasil.

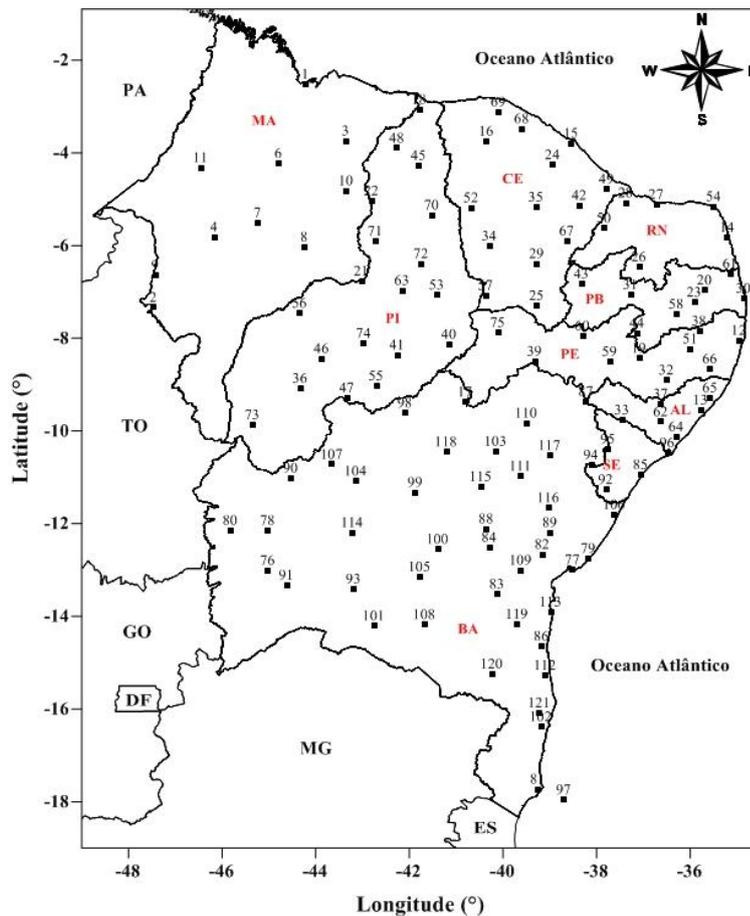


Figura 3.1 – Distribuição espacial de todas as estações localizadas no Nordeste (NEB). O número sinótico das estações inicia-se com 1 e termina em 121.

Dentro do período que compreende os anos de 2005 e 2011, foram observadas lacunas de dias, meses ou anos na aquisição dos dados, por falhas nas medições. Em vista deste problema, foi realizada uma qualificação dos dados de irradiação solar e retiradas as estações com séries de dados muito curtas ou com medições incoerentes.

3.2. Metodologia

Atualmente, os modelos atmosféricos de circulação geral - *Atmospheric General Circulation Models* (AGCM's) apresentam uma boa resolução espacial,

o que contribui para a boa qualidade das suas previsões. Entretanto, para tomada de decisão ao nível regional/local, tanto pelo estado quanto pela sociedade civil, há uma demanda por uma maior resolução destas previsões e dos seus cenários, já que a variabilidade espacial e temporal da precipitação, associada com processos físicos não resolvidos em AGCMs pode afetar de forma significativa determinadas atividades econômicas.

Tratando-se especificamente do Nordeste brasileiro, a agricultura e o gerenciamento de recursos hídricos tipicamente precisam de uma informação mais detalhada do que aquela que pode ser proporcionada por tais modelos. O setor de energias renováveis, especialmente a energia eólica e solar, cujo crescimento tem sido acentuado no NEB, também requer de informação de alta resolução espacial para planejamento de suas ações na escala de previsão, bem como para avaliação dos potenciais impactos da variabilidade climática de origem natural ou antrópica sobre a disponibilidade dos recursos energéticos renováveis na região.

Com o propósito de se obter uma previsão com melhor resolução para a radiação solar sobre o Nordeste brasileiro, foi desenvolvida uma metodologia para obtenção de previsões e simulações de curto prazo com o auxílio de um modelo meteorológico de mesoescala de alta resolução. Nesses casos, as estimativas e previsões de radiação devem ser realizadas utilizando este tipo de modelagem, com o uso devido de um refinamento estatístico para que sejam diminuídos os erros sistemáticos dos modelos. A solução das equações prognósticas para um fluido compressível e não hidrostático asseguram que as componentes não estacionárias e não balanceadas do escoamento sejam devidamente representadas. Outro aspecto de grande importância no uso de modelos numéricos são os dados de entrada, que irão fornecer as informações necessárias para a realização das parametrizações adotadas na simulação (“*garbage in – garbage out*”).

A metodologia empregada no desenvolvimento deste trabalho foi subdividida em tarefas específicas para um melhor desenvolvimento, sendo estas:

- Qualificação dos Dados e Análise de Agrupamento;
- Teste de Sensibilidade das Principais Parametrizações do WRF;
- Desenvolvimento de RLM usando modelo de Céu Claro;
- Desenvolvimento do Modelo de RNA;
- Avaliação de confiabilidade das Previsões dos Modelos.

3.2.1. Qualificação dos Dados

A qualificação dos dados consiste em analisar os arquivos estruturalmente realizando uma análise exploratória que consiste em adequação, qualificação e exclusão ou não das séries de dados ou estações defeituosas. Alguns fatores podem afetar a confiabilidade dos dados medidos por equipamentos automáticos como os piranômetros, como a interrupção da alimentação do sensor, as descargas elétricas, as mudanças no ambiente onde está localizado o equipamento, entre outras. O primeiro passo deste trabalho foi o controle de qualidade dos dados observados de irradiação solar, que se faz necessário para minimizar a possibilidade de uma análise tendenciosa, devido à baixa confiabilidade dos dados observados.

Neste estudo foi empregado um processo de qualificação similar ao adotado para estações participantes da BRSN (*Baseline Surface Radiation Network*), coordenado pela WMO (*World Meteorological Organization*) (MARTINS; PEREIRA, 2011).

A adoção destes procedimentos vai permitir a definição das estações que serão utilizadas nesse estudo, tanto para a etapa da Análise de Agrupamento, nos testes de sensibilidade das parametrizações de radiação, de microfísica e de convecção do WRF, como para a configuração da Regressão Linear Múltipla, (RLM) ou modelo MOS e das Redes Neurais Artificiais, (RNA) e para a validação dos resultados obtidos.

Roesch et al. (2011) avaliando os registros do banco de dados de irradiação disponibilizados pela BSRN determinaram os limites aceitáveis para eventos extremamente raros e fisicamente possíveis. A Figura 3.2 apresenta o fluxograma do algoritmo de qualificação empregado.

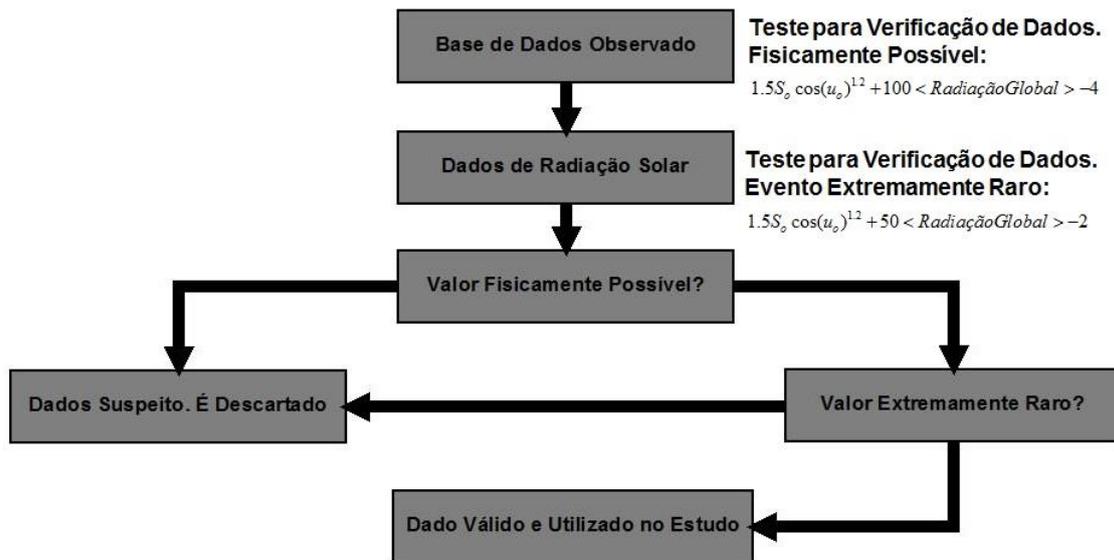


Figura 3.2 – Fluxograma do procedimento para controle de qualidade dos dados de irradiação solar coletados pelo INMET.

Os dados medidos utilizados nessa pesquisa foram disponibilizados pelo Instituto Nacional de Meteorologia (INMET), sendo esta base de dados constituída por valores médios horários de irradiação solar global. Estes estão distribuídos especialmente na região Nordeste do Brasil, divididas por estados. Cada estação é dotada de suas coordenadas geográficas, latitude, longitude e altitude do local e as séries temporais de dados medidos correspondem a um período de sete anos, iniciando em 1 de janeiro de 2005 e terminando em 31 de dezembro de 2011.

A base de dados apresentou séries incompletas em quase todas as estações, principalmente nos anos de 2005 a 2007, tanto por falhas na aquisição de dados quanto por carência de manutenção. Como o uso deste algoritmo resultou em dados medidos dentro dos limites impostos no método de

qualificação, uma análise qualitativa dos dados foi realizada após este processo. Nesta etapa foi aplicado um diagnóstico para selecionar as estações de acordo com os seguintes critérios:

- a) **Representatividade dos horários de medição da irradiação solar nas estações selecionadas:** Só utilizar dados onde cada dia possua ao menos nove medições para radiação solar.

- b) **Representatividade de 70% dos dados medidos:** esse critério assume como aceitáveis um número de falhas inferior a 30% da extensão total das séries. Ou seja, foram consideradas como aceitáveis as estações que continham séries de dados medidos com aproximadamente 20 ou mais dias em um mês e 8 meses em um ano.

Em seguida foi realizado o cálculo das médias anuais, mensais, diárias e horárias para todo o período, em cada uma das estações meteorológicas onde foram analisadas quantitativamente. O objetivo deste procedimento é definir quais seriam as melhores estações no NEB e retirar as séries de dados espúrias que não foram identificadas pelos critérios anteriores.

Após isto, foi calculada a média trimestral, que foi utilizada para o cálculo dos mapas espaciais de irradiação solar, com o intuito de analisar a climatologia local e sua variação sazonal. Os trimestres definidos foram os seguintes: dezembro, janeiro e fevereiro (DJF), março, abril e maio (MAM), junho, julho e agosto (JJA) e setembro, outubro e novembro (SON). Para efeito de cálculo não se usou os trimestres astronômicos, que definem as estações do ano.

3.2.2. Análise de Agrupamento (AA)

O passo seguinte foi a identificação de regiões homogêneas. Para tal, foi usado o método de análise de *cluster*, ou análise de agrupamento (AA). Um vetor de dados é associado a cada estação, de modo que elas possam ser particionadas ou agregadas em grupos, de acordo com a similaridade de seus vetores de dados. Para a definição dos agrupamentos, foi feito o cálculo da média mensal para todas as estações meteorológicas que passaram no teste de qualificação e nas análises qualitativas.

Foram determinadas as regiões homogêneas através de uma matriz de dados, a qual foi organizada da seguinte forma: as linhas são compostas pelas estações meteorológicas e as colunas pelas médias dos meses de todo o período, ou seja, uma matriz de (estações X meses). Nesta matriz também foram incluídas as coordenadas de posição geográfica de cada estação, o que exigiu a padronização dos dados. Para o agrupamento, foi aplicado o método hierárquico aglomerativo de agrupamento à matriz de dados, sendo usado o método de Ward (1963), também empregado por (BRAGA; SILVA, 1990; BECKER et al. 1992; SILVA et al. 1996; BRAGA et al. 1998; CORREIA, 2000; BARRETO, 2001; TENNANT; HEWITSON, 2002; LIMA et al. 2010; PAIXÃO et al. 2011) com função de agrupamento a distância Euclidiana que é a soma dos quadrados das diferenças (HAIR et al. 2005).

Tanto o número de grupos como as estações contidas em cada uma deles, foram determinadas de forma subjetiva através de um corte transversal no dendrograma. O objetivo principal do uso de análise de agrupamento foi dividir o Nordeste em regiões semelhantes e com isso configurar o modelo de mesoescala, ou seja, verificar as melhores parametrizações aplicadas a cada região homogênea.

3.2.3. Teste de Sensibilidade das Principais Parametrizações do WRF

O modelo numérico de mesoescala usado nesta pesquisa foi o WRF. A avaliação do seu desempenho foi realizada por meio de testes e simulações

utilizando as diferentes parametrizações dos processos atmosféricos e comparação das estimativas fornecidas com observações realizadas nas estações de coleta de dados, sendo a versão aqui usada a 3.6, lançada em abril de 2014.

As parametrizações físicas para a configuração nas simulações do WRF estão descritas na Tabela 3.1.

Tabela 3.1 – Parametrizações usadas no modelo numérico de mesoescala WRF.

Parametrizações	
Camada Limite Superficial	TSMO (MONIN; OBUKHOV, 1954)
Camada Limite Atmosférica	MYJ (JANJIC, 1994)
Superfície do solo	Noah LSM (CHEN; DUDHIA, 2001)
Microfísica	Lin, Thompson e WSM6
Radiação de onda longa	RRTM, RRTMG e New Goddard
Radiação de onda curta	Dudhia, RRTMG e New Goddard
Cúmulos	Grell 3D, Kain-Fritsch e Desligado

Para os processos envolvendo ondas longas foi utilizado o esquema RRTM (*Rapid Radiative Transfer Method*) baseado no esquema disponível no modelo MM5 (MLAWER et al. 1997), RRTMG (*Rapid Radiative Transfer Method*), descrito em (IACONO et al. 2008) é uma nova versão do RRTM que inclui o método de (*Monte-Carlo independente column approximation*) McICA e New Goddard foi desenvolvida por (CHOU; SUAREZ, 1994) para serem usados em modelos climáticos. Para a radiação de onda curta será considerado um esquema baseado em Dudhia (1989), RRTMG e New Goddard.

Para este trabalho, três parametrizações de microfísica foram escolhidas a WRF Single-Momento 6-classe (WSM6), Thompson e Lin. O esquema WSM6 é um esquema relativamente sofisticado, mais indicado para o uso em pesquisas. Incluem seis classes de hidrometeoros, vapor d'água, chuva, neve, gelo e água de nuvem, *graupel*, e processos de fase mista que são parametrizados. Os ajustes nos processos de saturação da água e do gelo são tratados separadamente conforme Dudhia (1989); Hong et al. (1998).

A parametrização de microfísica baseada em Thompson et al. (2004) foi desenvolvida com o intuito de melhorar a previsão de eventos de congelamento para alertas de segurança na aviação. Foi extensivamente testada e comparada, tanto em estudos de caso idealizados quanto em eventos reais e documentados a partir de observações realizadas durante o inverno em latitudes médias. A parametrização de Lin et al. 1983, é um esquema sofisticado, inclui processos de gelo, neve e *graupel*. É apropriado para simulações de alta resolução para dados reais.

Nesta pesquisa foram usadas duas parametrizações de cúmulos disponíveis no WRF, Kain-Fritsch, Grell-3D e com ela desligada. A parametrização de Kain e Fritsch, (1990; 1993) utiliza um modelo de nuvem simples, com correntes de umidade ascendentes e descendentes, incluindo efeitos de interação com a atmosfera e uma microfísica relativamente simples. Este esquema foi formulado para assegurar a conservação de massa, energia térmica, umidade total e momentum, e considera que toda a Energia Potencial Disponível para Convecção (CAPE – do inglês, *Convective Potential Available Energy*), num elemento de malha é removida no instante de ajustamento.

Grell 3D é um melhoramento da parametrização de Grell e Devenyi (2002) que pode ser usado em alta resolução. Eles introduziram uma parametrização cúmulos por conjunto em que simultaneamente múltiplos esquemas de convecção e variações são rodados para todos os elementos de malha, produzindo uma média dos resultados. A princípio, a média pode ser ponderada a fim de aperfeiçoar a parametrização, mas geralmente pesos iguais são atribuídos. Os esquemas são todos do tipo fluxo de massa, mas com diferentes parâmetros para correntes ascendentes e descendentes de entranhamento e desentranhamento, e eficiência de precipitação. Essas diferenças no controle estático são combinadas com diferenças no controle dinâmico, que é o método para determinar o fluxo de massa na nuvem. Os fechamentos do controle dinâmico são baseados na CAPE, na velocidade vertical nos níveis baixos ou na convergência de umidade. Tipicamente esta

parametrização é composta por 144 membros que distinguem os tipos de nuvens.

Os esquemas da camada limite superficial determinam as velocidades de fricção e os coeficientes de troca que permitem o cálculo do aquecimento da superfície e dos fluxos de umidade nos modelos de solo-superfície e da turbulência superficial no esquema da camada limite planetária. Os fluxos de superfície neste trabalho foram calculados de acordo com a Teoria da Similaridade.

Para este trabalho foi escolhido o modelo de solo-superfície Noah LSM (*Land Surface Model*) de quatro camadas que inclui zona radicular, de evapotranspiração, drenagem do solo e escoamento superficial, e considera categorias de vegetação, fração e textura do solo. O esquema disponibiliza fluxos de calor sensível e latente para o esquema de CLP.

Na camada limite atmosférica, fenômenos de escala temporal muito rápido ocorrem na atmosfera em escalas espaciais muito menores que o espaçamento de grade dos modelos de circulação geral da atmosfera e modelo de área limitada. Estes processos são determinados pelos fluxos de calor, momento e umidade entre a superfície e a atmosfera adjacente. Estes fenômenos incluem turbulência, ondas de gravidade, turbilhões entre outras que não podem ser resolvidas através das equações governantes dentro dos modelos e por isso precisam ser parametrizadas. Como descrito em Anthes et al. (1980), uma resolução detalhada da Camada Limite Planetária (CLP) é essencial para melhores soluções para o aquecimento diferenciado ao longo de um terreno complexo, ou através de limites entre terra e água (PIELKE, 2002).

As simulações deste trabalho foram realizadas utilizando o esquema de camada limite Mellor-Yamada-Janjic que usa termos contra gradientes para representar fluxos devidos a gradientes não locais, adicionando um tratamento explícito de camada de entranhamento no topo da CLP. O topo da CLP é definido usando um número de Richardson “bulk” crítico igual à zero, somente

dependente do perfil de flutuabilidade. Uma descrição ainda mais detalhada do modelo pode ser encontrada em seu manual e em Skamarock et al. (2008).

Antes das rodadas efetivas do modelo, foram realizados três testes de sensibilidade, a fim de obter a configuração de modelo mais apropriada para o local e para a variável analisada nesse estudo. Foram avaliadas três das parametrizações físicas utilizadas no WRF (radiação, convecção e microfísica), com dados de condições iniciais do modelo global GFS, utilizando a técnica *downscaling* sobre o Nordeste do Brasil.

As estações para a validação dos testes de sensibilidade e seus períodos de realização destes foram definidas com base nas análises dos dados observacionais, descritos nas etapas anteriores. Ou seja, os testes de sensibilidade foram realizados com base nas regiões definidas na AA e seus períodos foram aqueles nos quais se observaram as menores incidências de irradiação solar nas regiões homogêneas, ou períodos onde ocorreram fenômenos meteorológicos que influenciaram de maneira significativa a quantidade de radiação solar à superfície.

Visando estabelecer uma configuração de grade que melhor representasse as regiões homogêneas observadas, o modelo WRF foi configurado com quatro domínios de integração. O domínio mais externo foi definido com resolução horizontal de 15 km e cobre toda a região Nordeste do Brasil, enquanto que os domínios aninhados possuem resolução espacial de 5 km, sendo definido conforme a configuração das regiões homogêneas.

Todas as previsões com o WRF foram inicializadas as 1800 UTC com horizonte de simulação de 30 horas utilizando as primeiras 6 horas como o tempo de ajuste do modelo (*spin up*).

Foram utilizadas análises numéricas globais do GFS, com resolução temporal de seis horas e resolução horizontal de 1°, para gerar as condições iniciais e de contorno de cada simulação feita.

Para os testes, foram utilizados diferentes esquemas de microfísica (Thompson, WSM6 e Lin), convecção (Grell 3D, Kain Fritsch e Desligado) e

radiação atmosférica curta e longa (Dudhia/RRTM, RRTMG/RRTMG e Goddard/Goddard). Já as parametrizações física da camada limite superficial, camada limite planetária e o modelo de solo utilizado foram a Teoria da Similaridade (ETA), Mellhor-Yamada-Janjic (MYJ) e Noah LSM, respectivamente, sendo definidas e permanecendo inalteradas em todo o processamento.

Simulações foram realizadas para os períodos, onde foram avaliados os menores valores de irradiação solar nos grupos homogêneos descritos na etapa anterior, combinando as diferentes parametrizações de microfísica, convecção e radiação, sendo todos os domínios do modelo configurados com os mesmos conjuntos de parametrizações.

3.2.4. Extração de Dados da Saída do Modelo WRF

Após a previsão dos dados do modelo WRF para todo o período em estudo foi realizada a extração dos dados, apenas dos pontos de grade mais próximos às estações usadas neste estudo, sendo extraídos e concatenados de modo a formarem séries temporais para cada uma das estações. A leitura destes arquivos, assim como o desenvolvimento das rotinas computacionais e o processamento deste trabalho foi realizado utilizando os softwares MATLAB® e Surfer®. Foram assimiladas todas as variáveis de superfície. Em seguida, foi realizada a sincronização dos dados, ou seja, o acoplamento entre os dados modelados e os dados medidos, de forma sincronizada no tempo. Todas as estações estavam referenciadas em horário UTC, assim como os dados modelados. Após a sincronização o número de amostras por estação ficou reduzido, sendo limitado pela quantidade de dados medidos disponíveis.

3.2.5. Dados Derivados de Saídas do WRF

A partir dos dados de umidade relativa (r_{h2}) e de temperatura (t_2) fornecidos pelo modelo WRF para a altura de 2 metros acima da superfície, foi calculado o conteúdo de água precipitável (pw). O Cálculo foi realizado de acordo com a relação empírica formulada por Leckner (1978):

$$pw = \frac{0,493r_{h2}p_s}{t_2} \quad e \quad p_s = e^{\left(\frac{26,23-5416}{t_2}\right)} \quad (3.1)$$

onde p_s é a pressão de saturação de vapor d'água e t_2 é em Kelvin.

A Equação 3.1 determina a água precipitável nas condições normais de temperatura e pressão. Apesar de alguns estudos indicarem que valores de água precipitável obtidos através do uso de formulações empíricas são imprecisos (GAMBI, 1998; DIEKMANN et al. 1986), a formulação de Leckner é mencionada como uma das que apresenta melhores resultados (IQBAL, 1983). Esta variável foi calculada para cada passo de tempo, de todos os dias que compõem o conjunto de dados do WRF. Assim como as demais variáveis do modelo, essa nova variável é instantânea.

3.2.6. Modelo de MOS (Model Output Statistical)

O MOS é uma técnica de previsão de tempo objetiva, que consiste em determinar uma relação estatística entre um preditando e variáveis previstas por um modelo numérico, em diferentes tempos de previsão (GLAHN; LOWRY, 1972). A utilização desta técnica implementada com os produtos do modelo WRF requer uma série longa de dados, para que seja estabelecida uma relação de previsão confiável. Alguns estudos indicam que são necessários pelo menos dois anos de dados para derivar uma equação MOS útil ou confiável (JACKS et al. 1990; VISLOCKY; FRITCH, 1995).

Como mencionado anteriormente, o objetivo deste trabalho é ajustar modelos de RNAs e MOS (que a partir de agora será referenciado como RLM), capazes de estimar a radiação solar incidente, tendo como entrada dados meteorológicos previstos pelo modelo WRF e valores calculados para radiação solar incidente à superfície (sem a influência de nuvens - modelo de céu claro ou modelo de *Clear Sky*), para instantes futuros.

Além de se tentar obter uma melhor previsão de radiação solar frente àquelas disponibilizadas diretamente pelo WRF, pretende-se verificar se a RLM oferece ganhos em relação às saídas desta variável obtidas pelo modelo. Trata-se do desenvolvimento e avaliação de um refinamento estatístico da previsão de irradiação solar do WRF, através de um procedimento que faz o papel de um MOS (*Model Output Statistics*).

Verificou-se que existe uma forte relação entre a fração de cobertura de nuvens calculada pelo modelo e a razão entre a radiação observada e a radiação que chegar a superfície em dia de céu claro (*ClearSky*), que é denominado índice (k^*), Equação 3.2 (LORENZ et al. 2010).

O modelo WRF calcula a fração de cobertura de nuvens alta, média e baixa como sendo uma porcentagem da área de uma caixa de grade, utilizando a simulação que está coberta pelas nuvens em questão. Foi utilizado o modelo de céu claro baseado em Dumortier (1998), que se baseia no coeficiente de *Linke Turbidity*. Este parâmetro, em particular, é uma aproximação conveniente para modelar a absorção e espalhamento atmosférico da radiação solar sobre céu claro. Descreve-se a espessura óptica da atmosfera devida tanto à absorção pelo vapor de água e absorção e dispersão de partículas de aerossol em relação a um ambiente seco e limpo (KASTEN, 1996; DIABATÉ et al. 2003). Quanto maior for o *Linke*, maior a atenuação da radiação na atmosfera para céu claro.

O modelo de céu claro é um parâmetro importante, tanto para o desenvolvimento do modelo de RLM, quanto para ser um possível dado de entrada dos modelos de RNAs, pois incorpora a dependência sazonal, a massa

óptica atmosférica e conseqüentemente a altitude (LINARES-RODRIGUEZ et. al., 2013). Foram utilizadas médias mensais para o fator de *Linke Turbidity*, na região de estudo.

$$k^* = \frac{Global}{ClearSky} \quad (3.2)$$

Em seguida, foi calculada a regressão linear múltipla entre o índice k^* e as coberturas de nuvens baixas, médias e altas do WRF. A nova saída de irradiação solar usando a correção estatística do modelo de RLM é dada pela equação 3.3.

$$IrradiaçãoSolar = (a(clflo) + b(clfmi) + c(clfhi) + d)ClearSky \quad (3.3)$$

onde *clflo*, *clfmi* e *clfhi*, são as coberturas de nuvens baixas, médias e altas dadas pelo WRF, respectivamente; os parâmetros *a*, *b* e *c* são os coeficientes da regressão linear múltipla para os três tipos de nuvens; e *ClearSky* é a irradiação solar em dia de céu claro.

3.3. Desenvolvimento das Redes Neurais Artificiais (RNAs)

Neste trabalho são empregadas RNAs do tipo MLP (perceptrons de múltipla camada), desenvolvidas utilizando um conjunto de ferramentas do software MATLAB® (DEMUTH et al. 2014), que permitem sua construção e treinamento.

3.3.1. Seleção dos Preditores

Conforme discutido anteriormente, a seleção de preditores é uma etapa mais sensível no desenvolvimento de modelos de RNA, exigindo conhecimento

sobre os processos físicos presentes na interação da radiação solar incidente com a atmosfera. Ela parte de um grande número de previsores em potencial e agrega uma complexidade desnecessária à rede, precisando ser reduzida. A seleção com base em correção linear é uma técnica bastante consolidada quando os fenômenos envolvidos não apresentam grandes não linearidades. Neste caso, entretanto, um cuidado adicional se faz necessário para preservar estas possíveis relações.

Existem diversas variáveis disponibilizadas nas saídas do modelo WRF que podem ser agrupadas em conjuntos com complexidade variada e empregadas para o ajuste de modelos de cálculos de radiação solar incidente. Testar e analisar todas as combinações possíveis, sem utilizar um embasamento físico ou estatístico, demandaria um longo tempo. Foram realizados três experimentos para amparar a escolha de grupos de preditores, utilizando três conjuntos diferentes.

No experimento 01, foram utilizadas as mesmas variáveis do modelo de RLM descrito anteriormente, usando a radiação solar incidente em dia de céu claro (*ClearSky*) e as três coberturas de nuvens dadas pelo WRF. No experimento 02, usou-se os preditores definidos como os melhores para a previsão de radiação solar incidente usando o modelo Eta, descritos em Guarnieri (2006), mas substituindo o TOA (radiação no topo da atmosfera) pelo modelo de *clearsky* definindo oito variáveis. São elas: *clearsky*, r_{h2} , t_2 , $u10$, $clflo$, $clmi$, $clphi$ e pw . Por último, no experimento 03 usou-se as mesmas variáveis definidas por Guarnieri (2006), com a inclusão do dj (Dia Juliano) e $hour$ (hora), para buscar um padrão temporal as redes.

3.3.2. Treinamento das RNAs

Foram feitas simulações para os três experimentos descritos anteriormente, sendo empregadas RNAs do tipo MLP, devido à sua capacidade de aproximação de qualquer função contínua aliada à capacidade de

generalização. Como nesta etapa a melhor configuração da RNA ainda não foi definida, adotou-se uma configuração padrão, com uma camada oculta, função de transferência do tipo tangente hiperbólica na camada intermediária e na camada de saída. A literatura menciona que a utilização da função sigmoidais nas camadas escondidas é o que proporciona a capacidade de não linearidade (HAYKIN, 2001).

Durante o treinamento foi utilizado o método posposto por Reed (1993), onde os dados foram divididos em conjuntos de treinamento e de validação. Para evitar o sobre ajuste, a proporção definida foi de 60% dos dados para treinamento, 30% dos dados para a validação e 10% dos dados para o teste, com o número de neurônios variando de 8 a 22.

Foram efetuados 100 treinamentos pelo algoritmo de retropropagação de Levenberg-Marquardt para cada subconjunto de cada estação e assim calculados os erros quadráticos médios (*RMSE*) e coeficientes de correlação *R* entre as saídas das RNAs e seu respectivo alvo no conjunto de teste. Os treinamentos foram realizados de forma iterativa, onde os conjuntos de treinamento, validação e teste eram divididos aleatoriamente respeitando a proporção anteriormente mencionada (60%, 30% e 10% para treinamento, validação e teste, respectivamente). É importante mencionar que para o ajuste de qualquer modelo estatístico é comum realizar o ajuste e o teste do modelo com conjuntos de dados independentes.

3.3.3. Definição do Número de Neurônios Ocultos

Com o número de preditores para a RNA definido, o próximo passo foi determinar o número adequado de neurônios na camada oculta. Quanto maior este número, maior a flexibilidade da rede para se ajustar aos resultados; no entanto, maior também é a dificuldade de treinamento e maior o risco de sobre ajuste da rede. Guarnieri (2006) verificou que as RNAs com duas camadas escondidas levaram a resultados ligeiramente melhores do que aqueles com o

emprego de apenas uma camada escondida. Segundo o autor, que utilizou como alvo a radiação solar, observou-se que a estrutura ($RNA-(n)-(2n)-(n)-alvo$) produziu melhores resultados (onde n é o número de preditores).

Para verificar qual configuração de RNA apresenta os melhores resultados foi feita uma comparação entre as redes com uma camada oculta, variando os neurônios de 8 a 22, e usando a configuração descrita pela estrutura ($RNA-(n)-(2n)-(n)-alvo$).

3.4. Análise Estatística

Para a avaliação das previsões de irradiação solar dadas pela RNA, pelo modelo RLM e pelo modelo WRF, os valores previstos foram comparados com os valores de irradiação solar medidos nas localidades de interesse. Diversas são as formas de comparação de modelos com os dados observacionais, com destaque para a comparação direta entre os dados da simulação numérica computacional com os dados das estações meteorológicas e a análise estatística de erros.

Em geral, esse processo de validação é focado na diferença do Erro Quadrático Médio (RMSE) e na diferença do Viés, ou ME, ou do termo em inglês, Bias, como mostrado em estudos como os de Davies et al. (1988), Djemaa e Delorme (1992), Pereira et al. (1996), Perez et al. (1997), Argiriou et al. (1999), Schillings et al. (2003), e Lefèvre et al. (2007).

O *ME* é, dentre as consideradas aqui, a mais simples e menos representativa da medida de habilidade do modelo em gerar previsões. Ele indica o erro sistemático, ou seja, subestimação ou superestimação do modelo em relação aos dados observados. Se for positivo, significa que os dados modelados tendem a superestimar os valores reais; enquanto que se for negativo, significa que existe uma tendência do modelo em subestima-los em relação aos valores reais. O *ME* é dado por:

$$ME = \frac{1}{N} \sum_{i=1}^N (\phi_i - \phi_o) \quad (3.4)$$

onde ϕ_o é o valor observado da variável no i -ésimo instante do tempo e ϕ_i é o valor da mesma variável produzida pelo modelo, correspondente ao mesmo instante de tempo do observado e N é o número de instante de tempo da série. O ME pode assumir qualquer valor real e tem a mesma unidade da variável em análise. O valor mais próximo de zero representa o menor desvio médio entre estimativas e observações.

O Erro Absoluto Médio (MSE) é a medida da magnitude média dos erros da previsão. Varia de 0 ao infinito e seu valor para previsão perfeita é 0. Possui a mesma unidade das previsões ou observações.

$$MSE = \frac{1}{N} \sum_{i=1}^N |\phi_i - \phi_o| \quad (3.5)$$

O Erro Quadrático Médio ($RMSE$) é dado pela soma dos quadrados das diferenças entre os resultados do modelo e observações:

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (\phi_i - \phi_o)^2 \right]^{1/2} \quad (3.6)$$

Pode assumir qualquer valor positivo e tem a mesma unidade de medida das séries em estudo. Assim como o ME , quanto mais próximo o valor do $RMSE$ for de 0 maior a confiabilidade das estimativas fornecidas pelo modelo.

Essas medidas de erro são comumente expressas como frações percentuais em relação à média das observações, isto é, como erros relativos. Assim $MSE(\%)$ e o $RMSE(\%)$ representam as razões entre os valores de erro e a média das observações, multiplicada por 100.

O índice de correlação permite uma interpretação linear entre observações e previsões e é definida por:

$$r = \frac{\Sigma(\phi_i - \bar{\phi}_i)(\phi_o - \bar{\phi}_o)}{\sqrt{[\Sigma(\phi_i - \bar{\phi}_i)^2][\Sigma(\phi_o - \bar{\phi}_o)^2]}} \quad (3.7)$$

Em que $\bar{\phi}_i$ e $\bar{\phi}_o$ são as médias das previsões e observações. Pode variar de -1 a 1 e seu valor para previsão perfeita é 1. É adimensional. Por ser independente da escala e por não levar em conta o viés da previsão é possível encontrar uma correlação elevada para uma previsão com alto viés.

O valor de um coeficiente de correlação não é garantia de que as variáveis envolvidas realmente estejam correlacionadas, porém antes de tirar qualquer conclusão sobre os valores dos coeficientes de correlação é necessária a aplicação de testes estatísticos para conhecer o grau real de ligação entre as variáveis.

Para testar a igualdade entre duas médias, o teste t de Student é muito utilizado nos dias de hoje. É um dos mais apropriados por ser um teste paramétrico, o que oferece maior poder estatístico (HUANG; PAES, 2009). Neste trabalho, optou-se pela utilização do teste estatístico t de Student, por ser um teste de fácil aplicação e mundialmente aceito como um teste eficiente para verificar a significância estatística do coeficiente de correlação (BRUNI, 2007).

4 RESULTADOS: PARTE I

Neste capítulo, são mostrados os resultados obtidos após a qualificação dos dados para a definição das estações e do período utilizado no presente trabalho. São mostrados também os resultados da Análise de Agrupamento dos dados de irradiação solar e temperatura média do ar e os testes de sensibilidade usando as principais parametrizações do WRF: radiação, microfísica e convecção.

4.1. Verificação da Qualidade dos dados Observados.

Esta seção é dedicada a descrever os resultados aplicados no tratamento dos dados medidos que serão utilizados nas análises pontual e espacial.

As séries temporais dos dados medidos correspondem a um período de sete anos, iniciando em 1 de janeiro 2005 e terminando em 31 de dezembro de 2011. A base de dados apresentou séries incompletas em quase todas as estações, principalmente nos anos de 2005 a 2007, tanto por falhas na aquisição de dados quanto por carência de manutenção.

De acordo com Landim (2000), é recomendado que o número de pontos amostrados não seja menor que 30 na aplicação do método de interpolação por krigagem, devido a número insuficiente de pares de amostras para a modelagem do semivariograma. Sendo assim, visando garantir a qualidade mínima dos resultados das interpolações, foi adotado um limite inferior de pelo menos 40 pontos interpoladores. A Figura 4.1 apresenta a disponibilidade das estações por meses ao longo dos anos de 2005 a 2011. De acordo com os motivos acima mencionados, as séries de dados observados dos anos de 2005, 2006 e 2007 foram excluídas do estudo, pois o número de amostras resultantes do processo de qualificação foi inferior a 40.

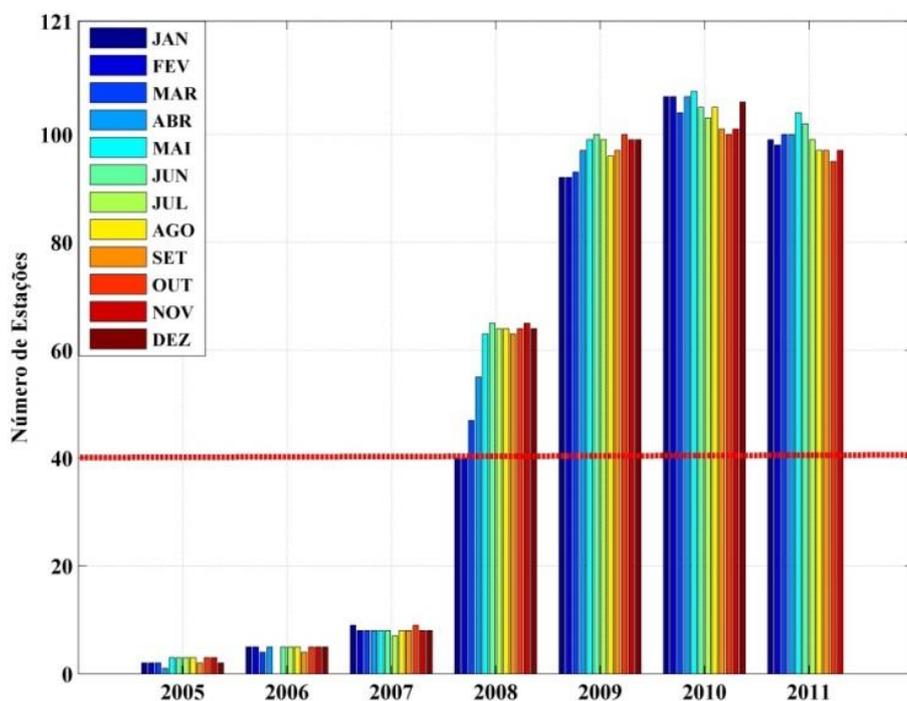


Figura 4.1 – Número de Estações qualificadas distribuídas por meses ao longo do período de estudo. A linha em vermelho representa o limite mínimo aceitável para a utilização da série anual no processo de interpolação espacial.

Nas Figuras 4.2 a 4.7 pode-se observar a média total anual, diária, mensal e horária de algumas estações, em especial as que apresentaram problemas. Estas médias foram calculadas para todas as estações qualificadas, a fim de analisar visualmente dados suspeitos que eventualmente foram aprovados no teste de qualificação. Observam-se dados suspeitos nas estações de Morada Nova, para o ano de 2009 e em Senhor do Bomfim para todo o período, enquanto que nas demais localidades verificam-se lacunas nos gráficos, indicando quantidade de dados inferior a 70% de sua série. Já em B da Corda, observa-se uma boa série de dados.

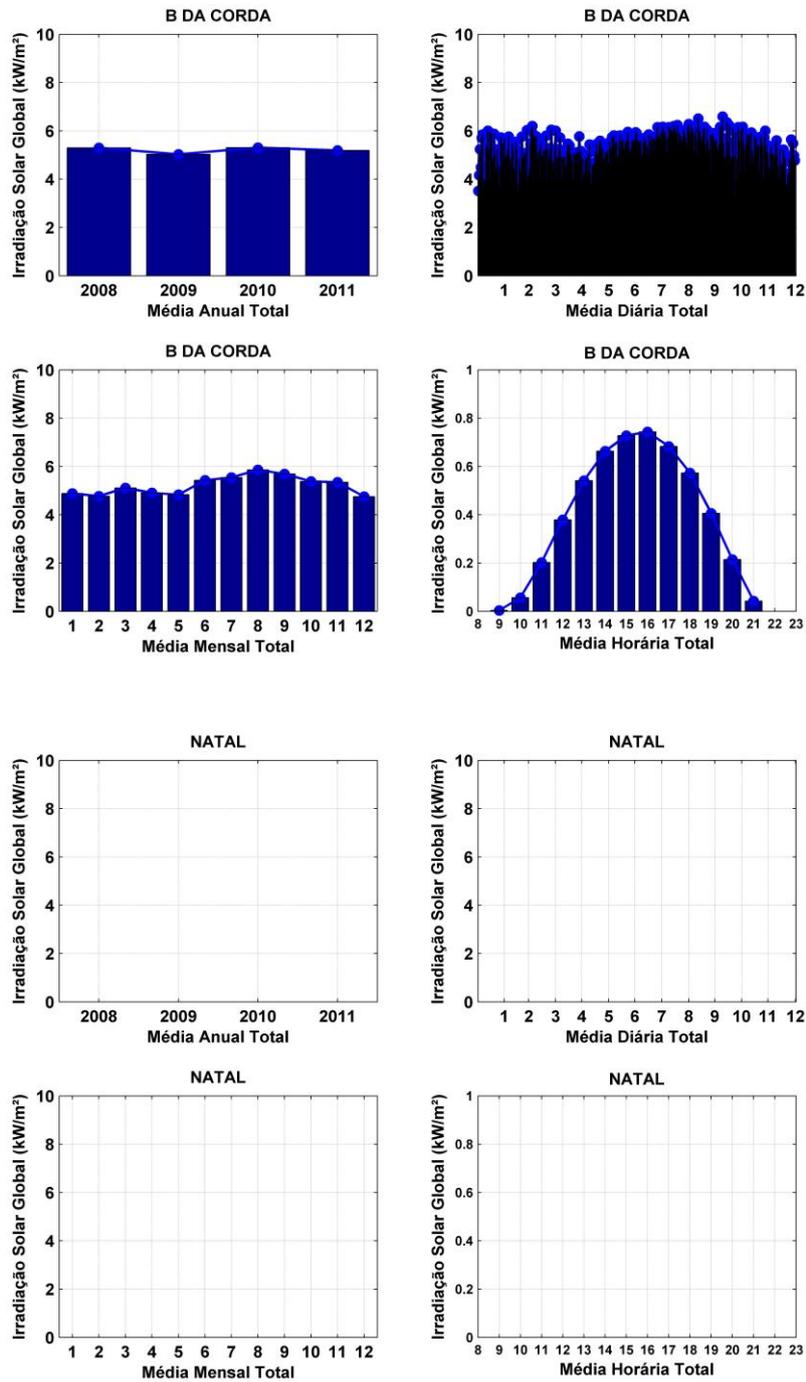


Figura 4.2 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de B. da Corda e Natal.

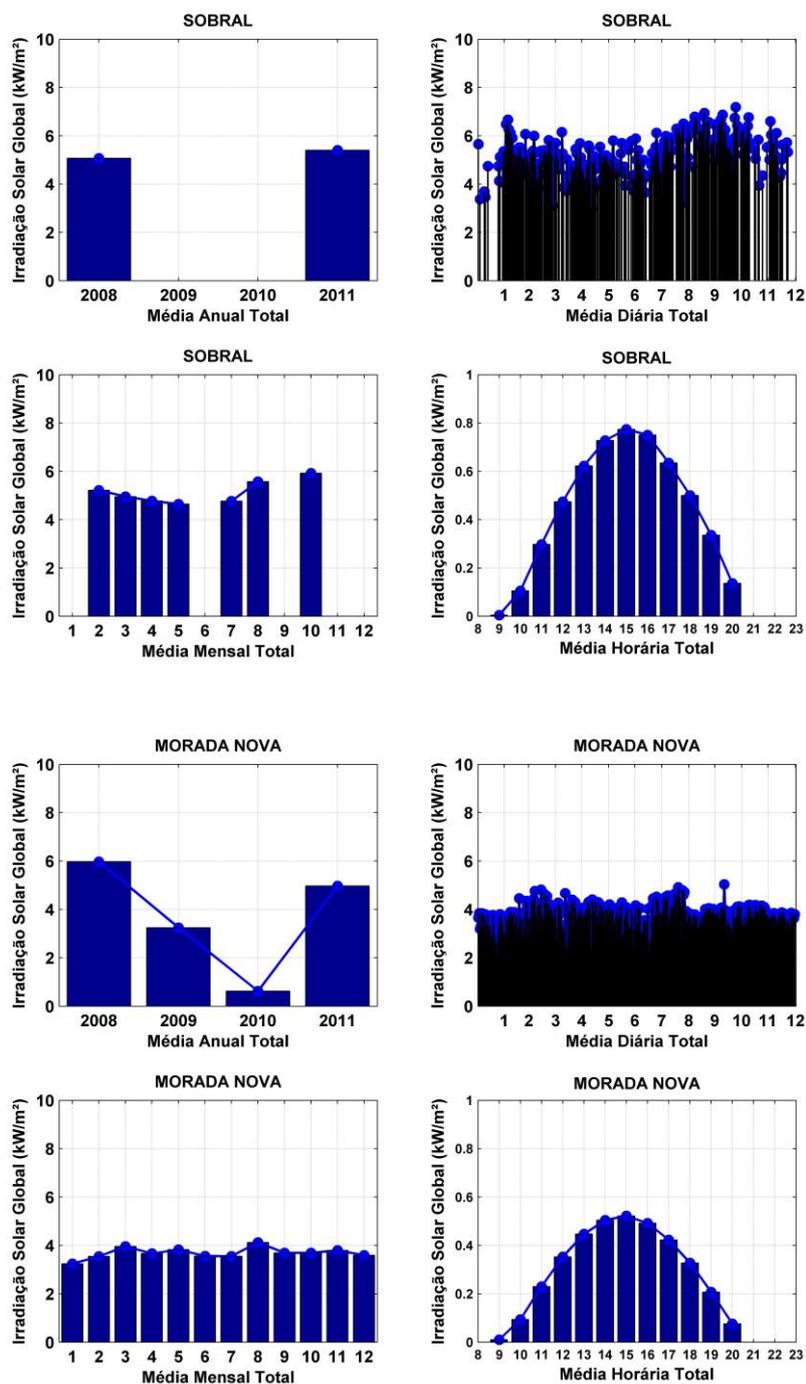


Figura 4.3 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Sobral e Morada Nova.

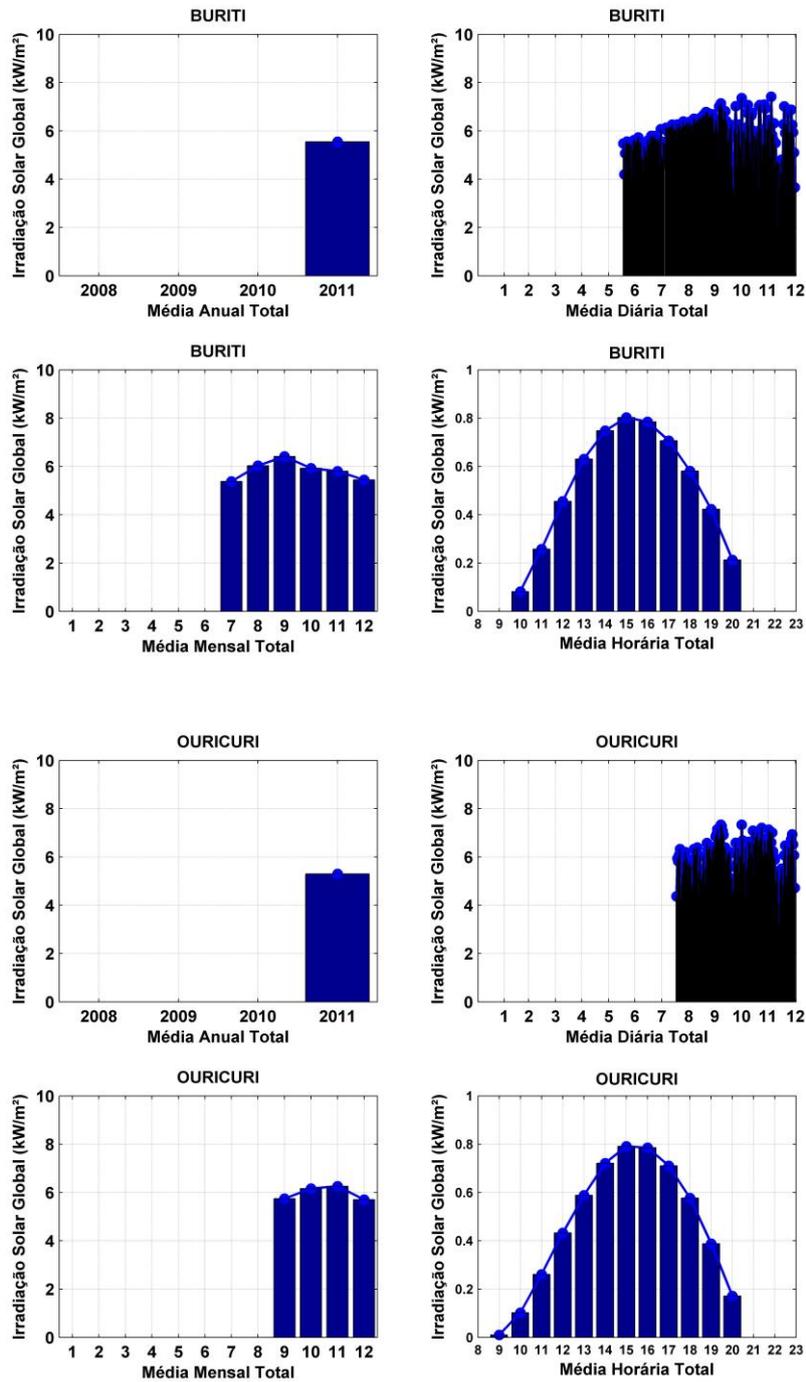


Figura 4.4 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Buriti e Ouricuri.

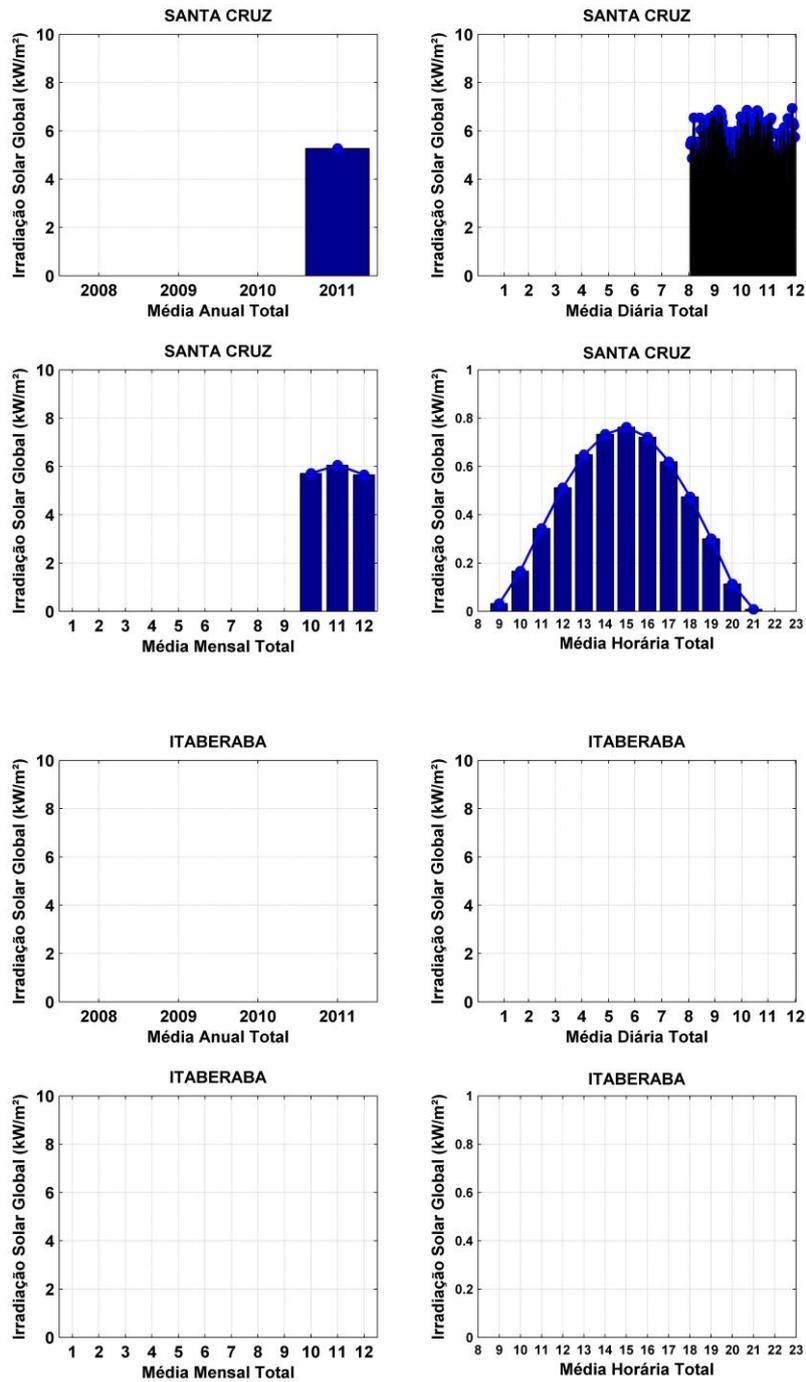


Figura 4.5 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Santa Cruz e Itaberaba.

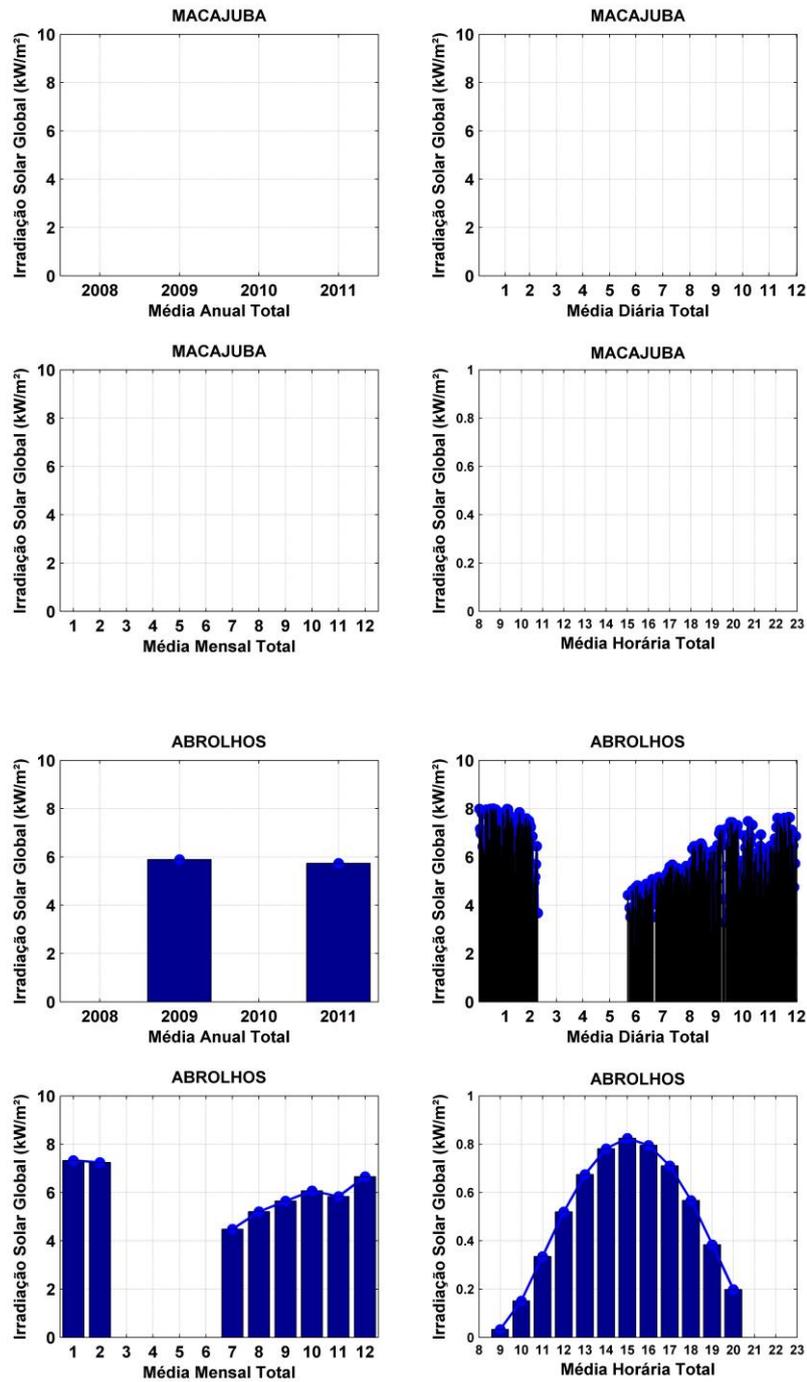


Figura 4.6 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Macajuba e Abrolhos.

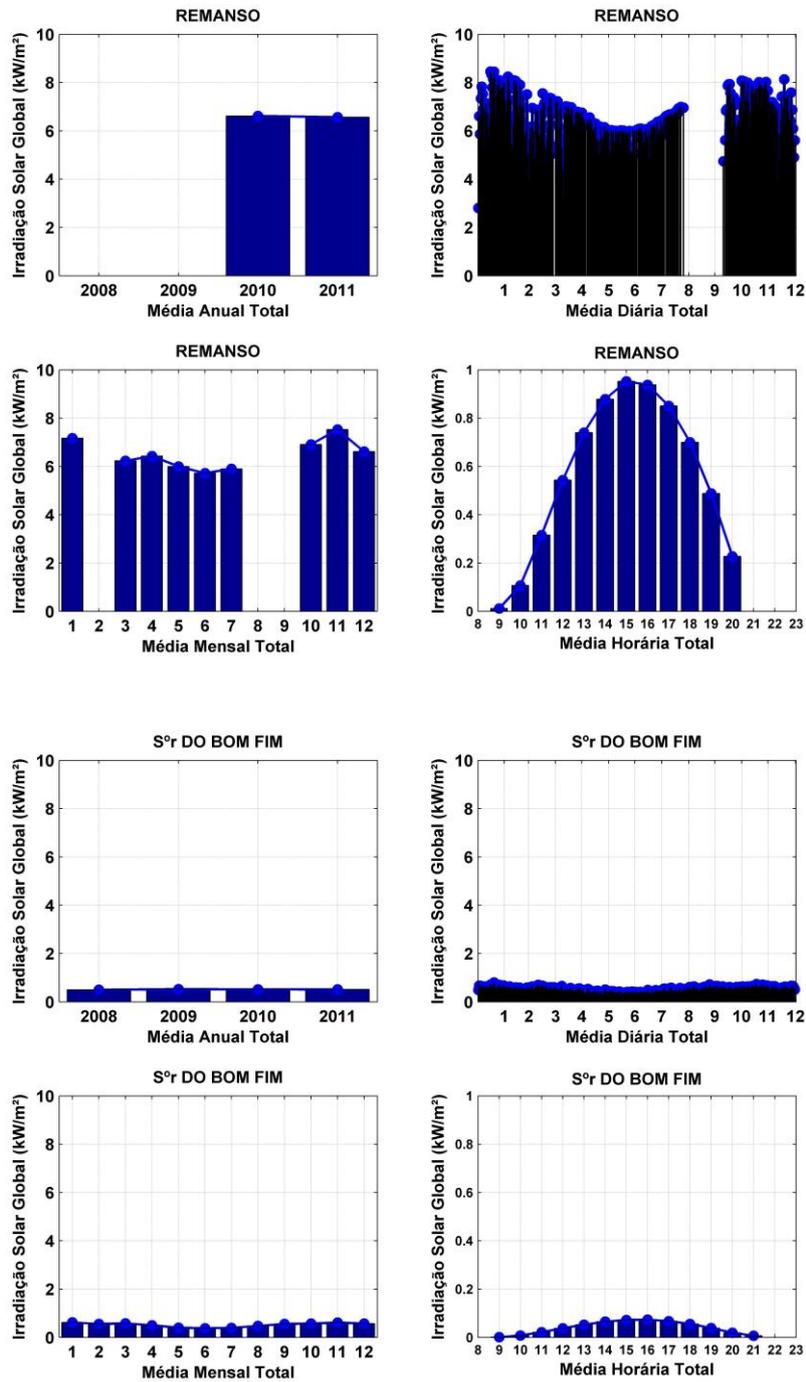


Figura 4.7 – Média total anual, diária, mensal e horária para todo o período em estudo para a verificação de dados incoerentes de irradiação solar estações de Remanso e Sºr do Bomfim.

Como resultado da aplicação da metodologia proposta nos dados qualificados de todas as estações (espaço amostral), 11 delas foram excluídas. As Figuras 4.2 a 4.7 são séries que não atenderam os critérios adotados, exceto em B da Corda.

Assim, 110 estações, ou pontos no espaço amostral, foram selecionados para serem interpoladas espacialmente utilizando a técnica de krigagem, para análise de agrupamento, para validação dos testes de sensibilidade e para avaliação dos modelos WRF, RLM e RNA. Na Figura 4.8, observa-se a distribuição espacial das 110 estações qualificadas para a continuidade desta pesquisa.

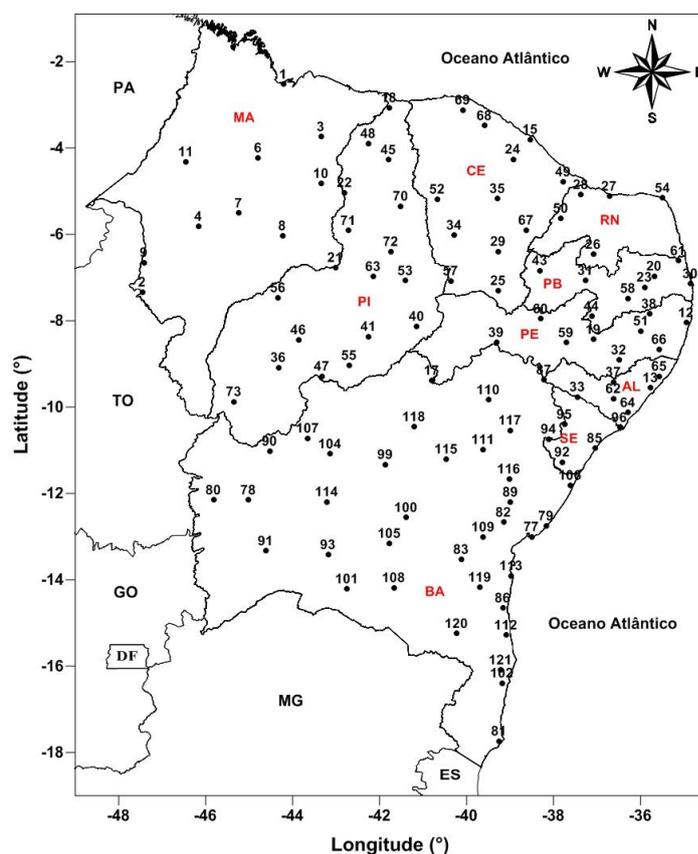


Figura 4.8 – Distribuição espacial de todas as estações localizadas no Nordeste (NEB) e usadas para a interpolação e Análise de Agrupamento (AA).

4.2. Variabilidade espacial da Radiação Solar no NEB entre 2008 e 2011.

Antes da utilização dos dados, foi realizada uma verificação qualitativa dos mesmos, com o objetivo de verificar possíveis falhas de leituras nos sensores e obter uma consistência nos valores medidos, como descrito na seção 4.1. A variabilidade da radiação solar no Nordeste do Brasil é significativamente heterogênea, seja por efeitos dinâmicos provocados pela sua topografia ou pela atuação dos diferentes sistemas atmosféricos que atingem esta região, apresentando grande variabilidade espaço-temporal. Para investigar o comportamento espacial da irradiação solar média para o período compreendido entre os anos de 2008 a 2011, foi gerado um mapa com a média total da irradiação solar, mostrado na Figura 4.9.

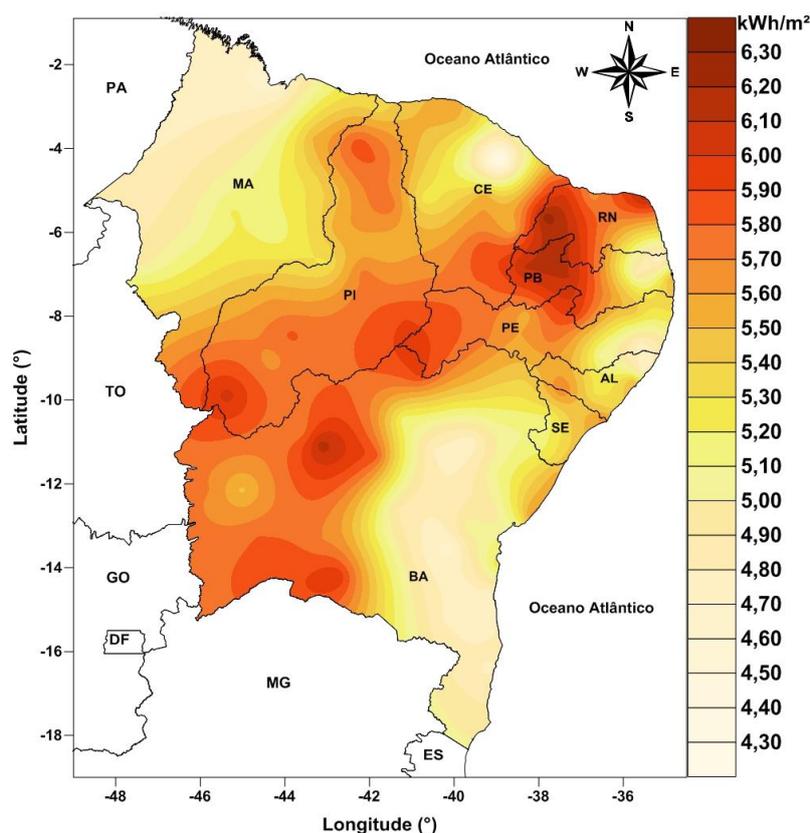


Figura 4.9 – Mapeamento da Irradiação Solar (kWh/m²) com base na média dos totais diários dos dados observados disponíveis e qualificados nesta pesquisa.

No Nordeste, os altos índices de irradiação solar são explicados pela baixa nebulosidade, principalmente no Sertão. Os máximos de irradiação solar anual estão situados no setor Norte e Nordeste, exceto na região costeira, na Chapada Diamantina na Bahia e na sub-região da Zona da mata, onde está inserido o estado do Maranhão. Observam-se os maiores índices de irradiação solar no Sertão, onde são observados os menores totais pluviométricos no Nordeste.

Ainda na Figura 4.9, verifica-se que os maiores valores de irradiação solar média na faixa litorânea ocorrem a Nordeste da região, em geral, ocorrem com destaque para o estado do Rio Grande do Norte. Os menores valores de radiação foram observados em parte dos estados do Maranhão, Alagoas, Sergipe e na parte costeira da Bahia. Essa distribuição caracteriza-se pela atuação de fenômenos meteorológicos que atuam na região Nordeste ao longo do ano, os quais se destacam: a Zona de Convergência Intertropical (ZCIT), Sistemas Frontais, Vórtices Ciclônicos de Ar Superior (VCAS), Distúrbios de Leste e Sistemas de Brisas e ventos alísios de Sudeste, como citado em Silva, (2003).

Medições climatológicas costumeiramente indicam que a irradiação solar varia de forma temporal, e estas variações temporais estão associadas a fenômenos de diversas escalas espaciais. A radiação pode ser mais intensa em algumas áreas que em outras e pode aumentar sua intensidade por alguns meses do ano. As principais razões destas variações são as influencias dos fenômenos meteorológicos. O principal condicionamento para as variações interanuais no Nordeste está ligado às mudanças permanentes nos padrões climáticos do planeta como: a elevação da temperatura global e pequenas irregularidades nos ciclos interanuais da ZCIT como, por exemplo, os episódios de El Niño e La Niña.

As mudanças no comportamento da circulação geral da atmosfera ao longo do ano provocam significativas variações sazonais na irradiação solar. Estas variações estão associadas principalmente a movimentação da ZCIT ao longo

do ano. As variações sazonais da radiação solar são de grande importância em estudos de energia solar, pois tem um efeito significativo ao longo do ano. Considerou-se conveniente analisar a climatologia da região sob o ponto de vista do comportamento sazonal, uma vez que fenômenos climáticos ou suas combinações em diferentes escalas de tempo e espaço podem provocar significativas variações na radiação solar de uma determinada região, de modo que sua média anual não evidenciaria este comportamento. Na Figura 4.10 podemos verificar a variação sazonal média da irradiação solar ao longo dos anos de 2008 a 2011, para os trimestres de DJF, MAM, JJA e SON, ou seja, verão, outono, inverno e primavera, respectivamente, no Hemisfério Sul.

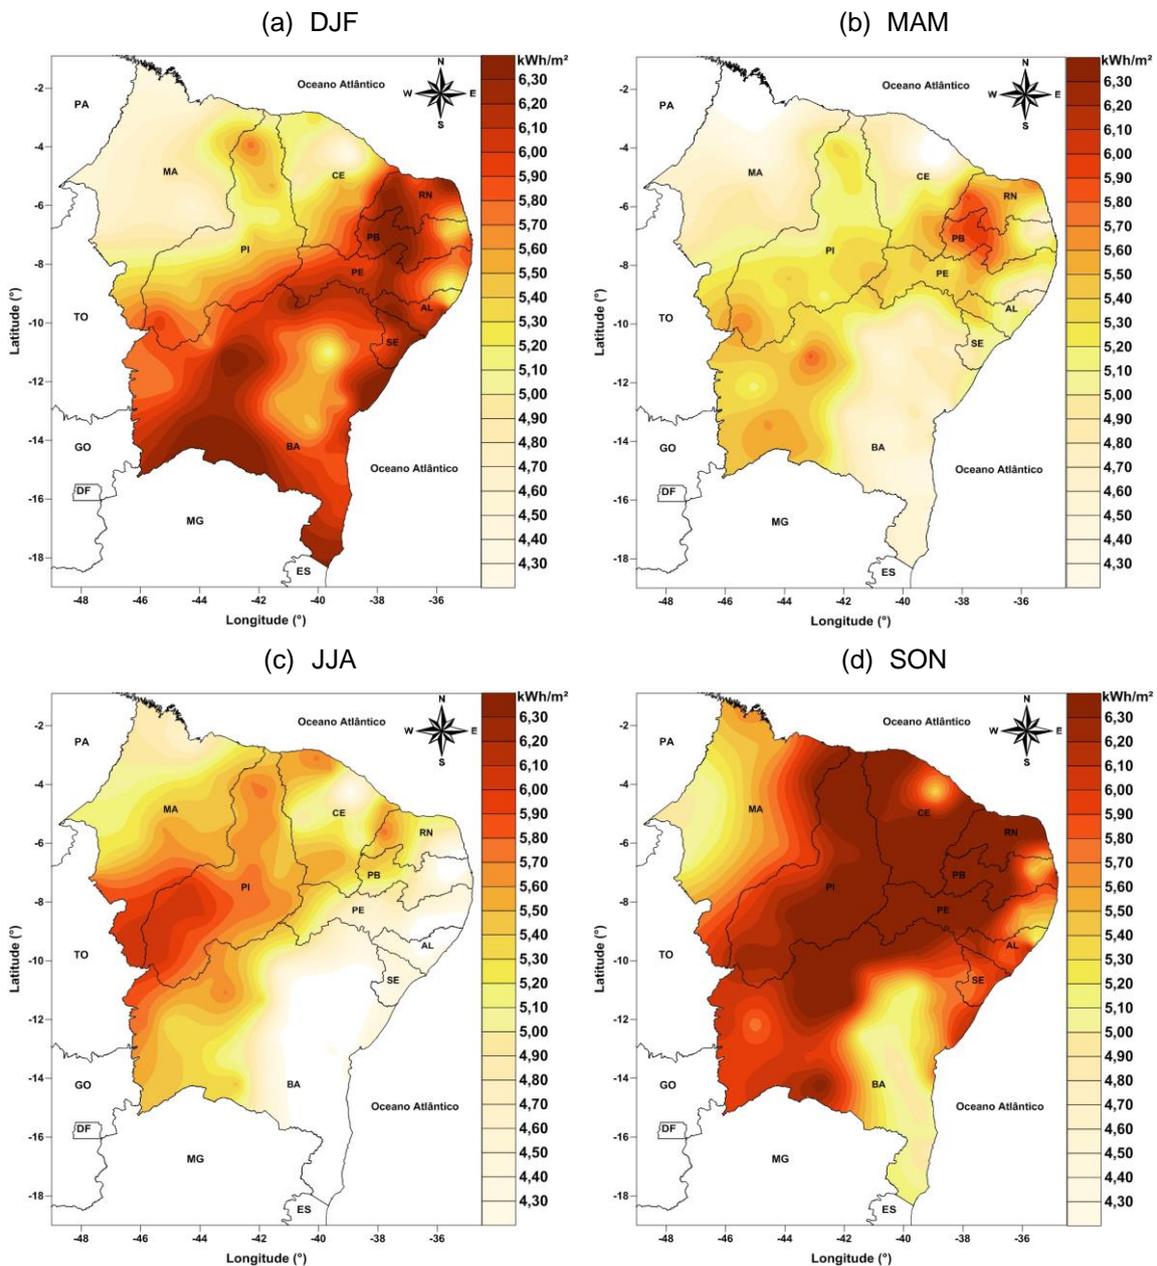


Figura 4.10 – Mapas climatológicos da Irradiação Solar (kWh/m^2), para os trimestres (a) DJF (verão), (b) MAM (outono), (c) JJA (inverno) e (d) SON (primavera).

Observa-se claramente na Figura 4.10 que o trimestre de SON, primavera no Hemisfério Sul, abriga os meses com maior incidência de irradiação solar, caracterizando o período seco no NEB (Figura 4.10d). De forma contrastante, o trimestre MAM (Figura 4.10b) caracteriza o período com menores incidências

de irradiação solar, coincidindo com o ápice da atividade convectiva na região associada à atuação direta da ZCIT, que atinge maior intensidade no trimestre de MAM (NOBRE; SHUKLA, 1996). Este é o período mais chuvoso na região, quando a irradiação solar atinge médias trimestrais variando entre 4,30 e 5,80 kWh/m².

Os trimestres de JJA e SON são os mais secos do ano com médias variando entre 4,90 e 6,30 kWh/m², Figura 4.10c e 4.10.d. Nessa época do ano a banda de nebulosidade associada à ZCIT encontra-se em sua posição mais ao Norte sobre o Oceano Atlântico (MOLION; BERNARDO, 2002). A baixa incidência de radiação no Norte e no centro do NEB, mais especificamente nos estados do Maranhão, Piauí e Ceará, nos dois primeiros trimestres do ano, deve-se à influência da ZCIT do Atlântico.

A baixa radiação nos dois últimos trimestres do ano no Sul do NEB é ocasionada pela incursão de Sistemas Frontais, que interagem com a convecção local, causando precipitação nesse período, no Sul do Nordeste. Para o setor Leste do NEB a baixa incidência de radiação solar nos trimestres de MAM e JJA, podem ser explicadas pelas ondas de leste e pelos remanescentes de sistemas frontais que se deslocam sobre a região e podem atingir latitudes equatoriais, principalmente no inverno do Hemisfério Sul.

A determinação das regiões homogêneas no NEB em relação à irradiação solar na superfície foi realizada através de vários métodos de classificação, utilizando como dados de entrada apenas a irradiação solar e avaliando como entrada na AA a irradiação solar juntamente com a temperatura média do ar. O método de agrupamento utilizado para encontrar as regiões homogêneas foi o método de agrupamento hierárquico de Ward, e a medida de similaridade utilizada foi a Distância Euclidiana, uma vez que este método apresentou os melhores resultados, de acordo com o objetivo deste trabalho.

A escolha do número de regiões foi realizada de forma subjetiva através do dendrograma, efetuado onde houve um decréscimo da inércia. Obteve-se assim quatro regiões homogêneas, em ambos os casos, utilizando como

entrada na AA a irradiação solar média mensal e utilizando a irradiação solar a temperatura do ar média mensal, bem como a latitude e longitude das localidades nos dois casos.

Este número de regiões foi considerado satisfatório, pois cada uma dessas regiões apresentou um número representativo de estações meteorológicas. As Figuras 4.11 e 4.12 mostram os dendrogramas obtidos pelo método de agrupamento de Ward, e o corte para a divisão do NEB em quatro regiões, utilizando como medida de similaridade a distância euclidiana e considerando como variável de agrupamento os valores padronizados de radiação solar, de temperatura média para todos os meses dos conjuntos de dados qualificados do INMET, além das coordenadas das estações.

A escala vertical mostra o nível de similaridade, pois a cada partição corresponde um valor numérico que representa o nível em que ocorre o agrupamento. Quanto maior for o índice, mais heterogêneos são os indivíduos, ou neste caso, estações meteorológicas agrupadas. As estações são apresentadas na horizontal, ou seja, 110 pontos referenciados pelos seus respectivos ID's, que podem ser consultados no Anexo A.

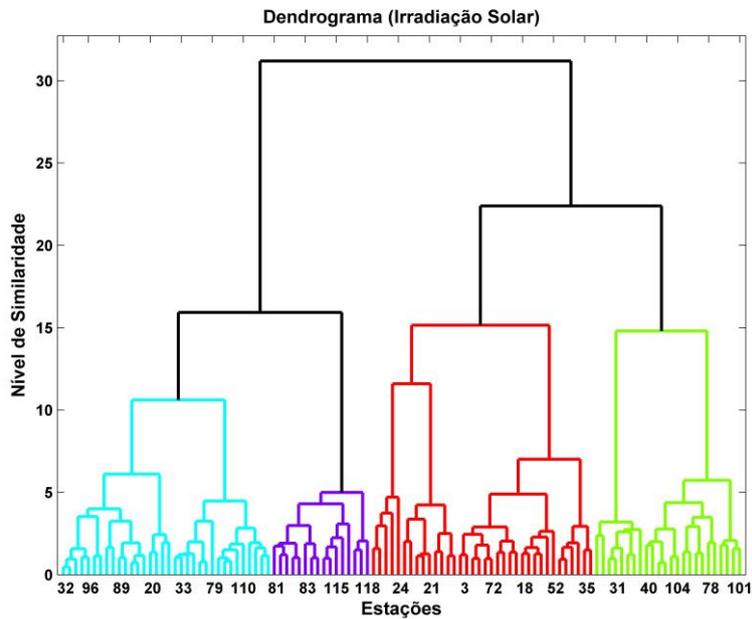


Figura 4.11 – Dendrograma resultante da análise objetiva das 110 estações meteorológicas, usando o método aglomerativo hierárquico de Ward para irradiação solar.

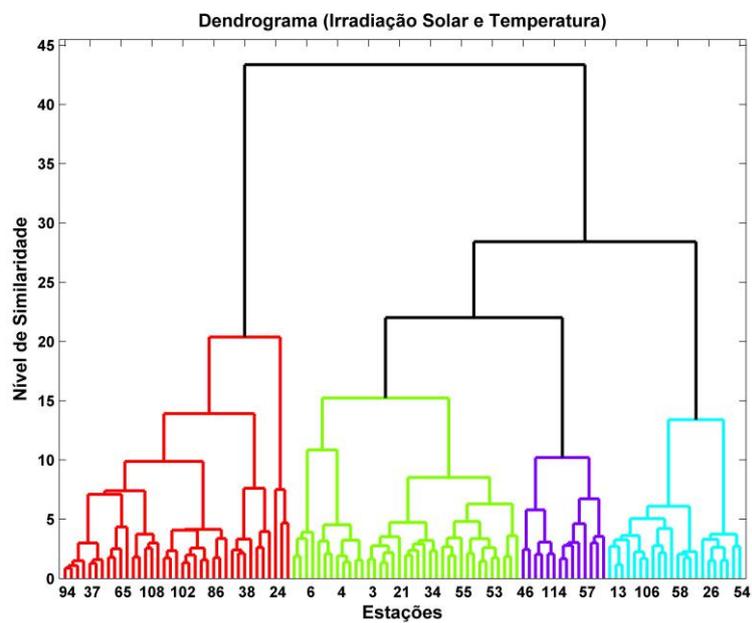


Figura 4.12 – Dendrograma resultante da análise objetiva das 105 estações meteorológicas, usando o método aglomerativo hierárquico de Ward para irradiação solar e temperatura média.

Como a proximidade física das localidades não garante semelhança climática entre elas, ocorreram casos onde são observadas as mesmas regiões homogêneas em áreas distintas do NEB. Ficou bem caracterizada a influência dos fenômenos meteorológicos, descritos na climatologia das Figuras 4.9 e 4.10 na configuração das regiões.

As Figuras 4.13 e 4.14 mostram os mapas com as configurações das regiões para os dois casos onde foram obtidas regiões homogêneas. Os números dentro de cada região no mapa representam a identificação das estações observadas no Anexo A.

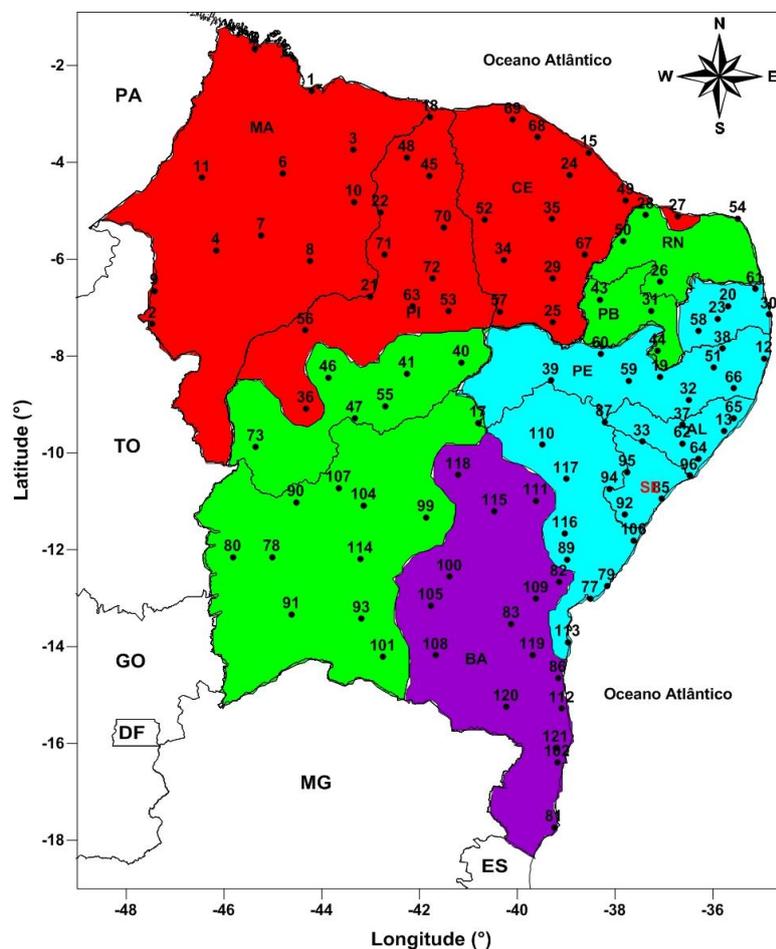


Figura 4.13 – Distribuição das regiões homogêneas em relação às estações Grupo1, verde, Grupo2, ciano, Grupo3, roxo, Grupo4, vermelho, para irradiação solar.

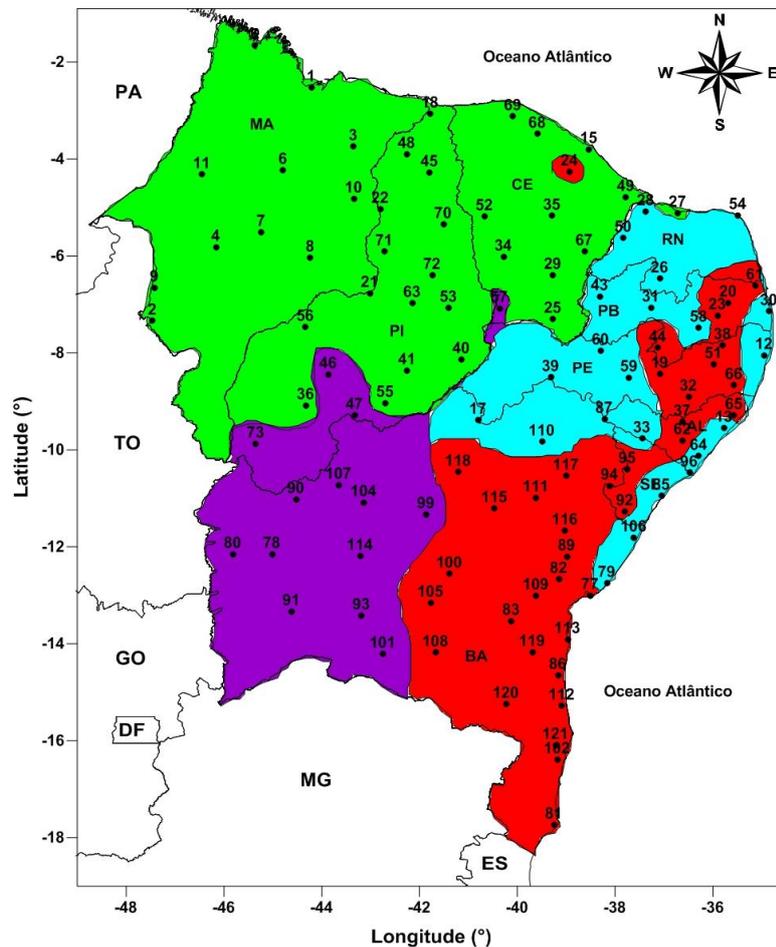


Figura 4.14 – Distribuição das regiões homogêneas em relação às estações Grupo1, roxo, Grupo2, ciano, Grupo3, vermelho, Grupo4, verde, para a irradiação solar e temperatura.

Nas Figuras acima as cores correspondem às regiões homogêneas. Pode-se observar uma forte concordância entre os grupos formados e a climatologia, apresentada na Figura 4.9. Em virtude de representar melhor a climatologia e os fenômenos que atuam no NEB, bem como uma melhor facilidade para a configuração das grades do modelo, optou-se por usar na configuração do modelo WRF e na validação dos refinamentos estatísticos as regiões criadas pela AA usando as duas variáveis, as quais apresentaram uma boa divisão do Nordeste em quatro regiões homogêneas.

Com a definição dos grupos, foi realizado um estudo climatológico, onde foram realizadas médias regionais anuais, mensais, diárias e horárias das estações

de cada região, para o período em estudo. A distribuição da irradiação solar reflete sua associação a eventos meteorológicos, geográficos e sazonais justificando a localização de cada região e dando uma ideia das características da distribuição desta variável ao longo do Nordeste.

Com relação à irradiação solar destes grupos, verificou-se que em todos os períodos os maiores valores são encontrados na Região1 e na Região2 e os menores valores são para a Região3 e Região4, o que pode ser observado na Figura 4.15.

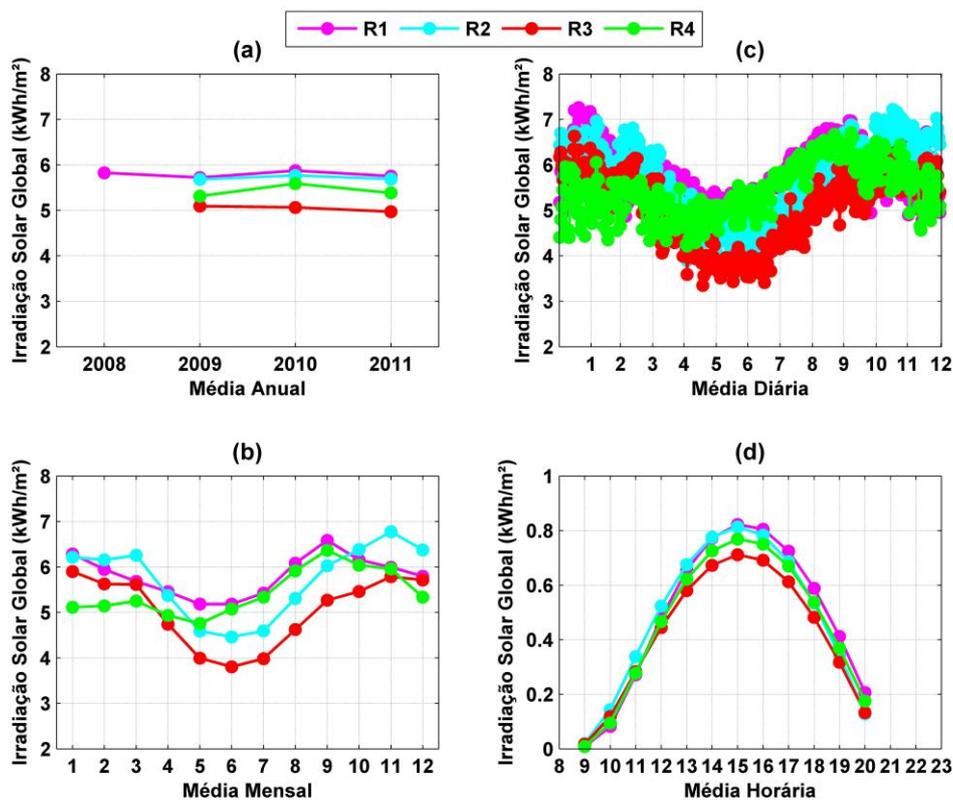


Figura 4.15 – Médias totais anuais, diárias, mensais e horarias para as quatro regiões homogêneas usando todo o período de dados medidos para irradiação solar.

Verificando a irradiação solar para R2, R3 e R4, observa-se que estas não obtiveram dados para o ano de 2008, ou que a quantidade de estações das regiões foi inferior a 70% das localidades que compõem este grupo.

Analisando a variabilidade sazonal, R2 e R3 apresentam a mesma concordância com os maiores valores no início e final do ano e menores valores no período de abril a agosto. Já para a R1 e R4, observa-se um padrão similar entre essas duas, com maiores valores nos meses de julho a outubro e menores valores de janeiro a junho, período de maior intensidade convectiva no NEB. Para todas as regiões, os menores valores foram encontrados no mês de maio e os maiores valores no mês de setembro, períodos chuvoso e seco no Nordeste, respectivamente. O fator primordial que afeta a radiação solar incidente é o regime de chuvas; o período de chuvas mais significativas no NEB inicia-se em dezembro de cada ano e pode estender-se até junho ou julho, dependendo das condições oceânicas e atmosféricas atuantes. Na Figura 4.16, observa-se a média mensal da irradiação solar incidente para cada ano em estudo e por regiões homogêneas.

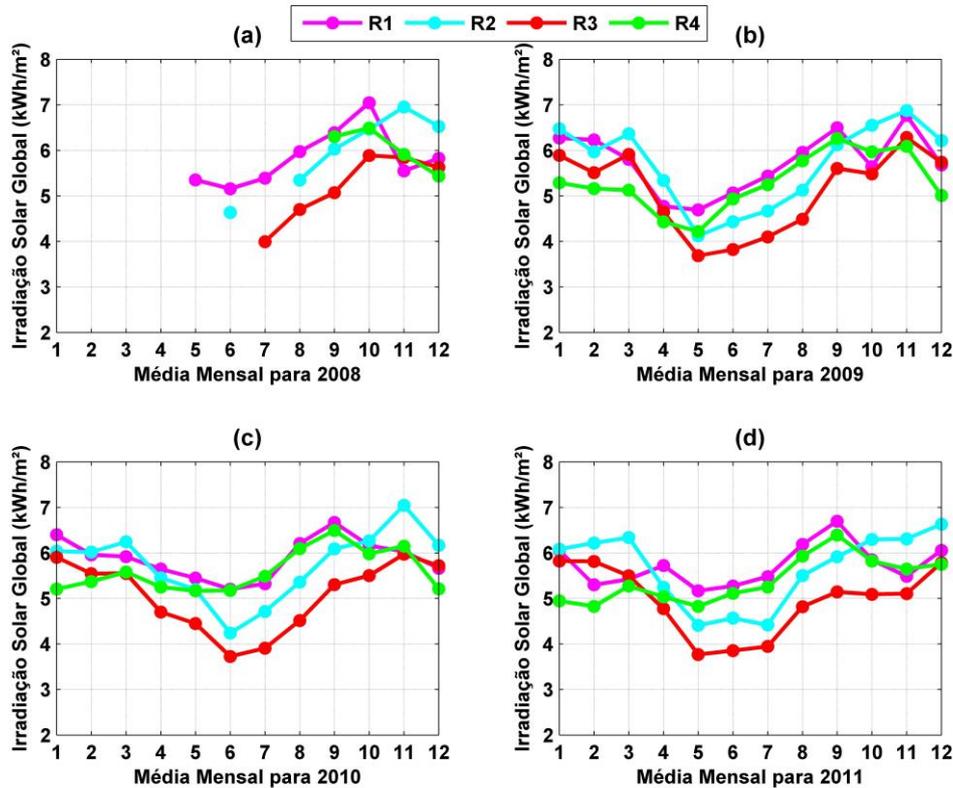


Figura 4.16 – Médias mensais para os anos de 2008 a 2011 para as quatro regiões homogêneas.

Um fator fundamental na caracterização da incidência de radiação solar no Nordeste é o padrão de temperatura das águas superficiais do Oceano Atlântico tropical, cujo comportamento pode favorecer ou dificultar a atuação dos principais fenômenos meteorológicos que influenciam a região. Ressalta-se que a ZCIT alcança sua posição mais ou Sul nos meses de março e abril (UVO, 1989), sendo assim determinante para o período chuvoso em boa parte do (norte do) Nordeste, além dos menores valores de incidência de radiação solar.

Observa-se na Figura 4.16 que para o ano de 2008, para as 4 regiões, houve uma grande quantidade de dados faltosos, ou a quantidade de estações para o mês faltoso foi inferior a 70% do total de estações que representam o grupo em questão. Por esse motivo, no decorrer deste trabalho optou-se por analisar somente os anos de 2009, 2010 e 2011. Para o ano de 2009, observa-se no

período de março a maio uma diminuição da radiação incidente bem mais acentuada que nos outros anos, provavelmente devido à alta atividade convectiva nesta época. Segundo Dantas et. al. (2013), os meses de março a maio de 2009 foram marcados pelo excesso de chuva na maior parte da região do NEB, com a ZCIT atuando e com a formação de linhas de instabilidade ao longo da costa das regiões R1 e R4. Estes foram os sistemas que mais favoreceram a ocorrência de chuvas, na parte Leste da região Norte e Norte do Nordeste. Estiveram associados também à atuação da ZCIT e à formação de Distúrbios Ondulatórios de Leste, R2 e R3. De junho de 2009 a maio 2010 foi caracterizado como um ano de El Niño forte, com menor volume de precipitação no NEB, ou seja, menor nebulosidade, o que explicaria a alta taxa de incidência de radiação solar nesse período. No caso de 2011, os padrões de ambos os oceanos foram favoráveis para o regime chuvoso na região onde se pode observar um padrão sazonal semelhante com o ano de 2009, porém com valores de radiação solar mais intenso nos dois primeiros trimestres do ano e menores nos dois últimos.

4.3. Configuração e Definição das Estações para Avaliação do WRF

Nesta seção são mostrados os resultados obtidos dos testes de sensibilidade das principais parametrizações físicas do WRF, radiação, microfísica e convecção para a escolha das melhores parametrizações para cada uma das regiões homogêneas definidas na etapa anterior. Também são avaliadas as simulações do modelo para todas as estações qualificadas na seção anterior. Para efeitos de avaliação, foram escolhidos apenas os três primeiros dias do mês de maio de 2009, já que é inviável realizar simulações com todas as combinações em todo o período de estudo. Em especial, a definição destes dias foi pautada pelo fato destes apresentarem os menores valores de incidência de irradiação solar para todas as quatro regiões formadas pela AA, conseqüentemente maior nebulosidade na região; isso, por si só, aumenta a

complexidade das simulações e diminui a destreza do modelo para esta variável.

Visando estabelecer a configuração de grades que melhor representasse as regiões em estudo, o modelo WRF foi configurado com quatro domínios de integração e baseado nas regiões homogêneas definidas, conforme mostrado nas Figuras 4.17 e 4.18.

O domínio mais externo; **domínio 1** possui resolução horizontal de 15 km e cobre toda a região Nordeste do Brasil. Já o **domínio 2** abrange toda a Região homogênea 4, onde está localizada os estados do Ceará, Maranhão e quase todo o estado do Piauí; o **domínio 3** abrange a parte Oeste da Bahia e a parte Sul do Piauí, R1 e o **domínio 4** abrange todas as estações pertencente as regiões R2 e R3. Optou-se por essa configuração pelo fato destas duas últimas regiões apresentarem um padrão sazonal semelhante. Importante mencionar que todos os domínios de maior resolução são aninhados à grade de menor resolução. Somente os parâmetros meteorológicos obtidos dos domínios de alta resolução foram de fato utilizados neste estudo.

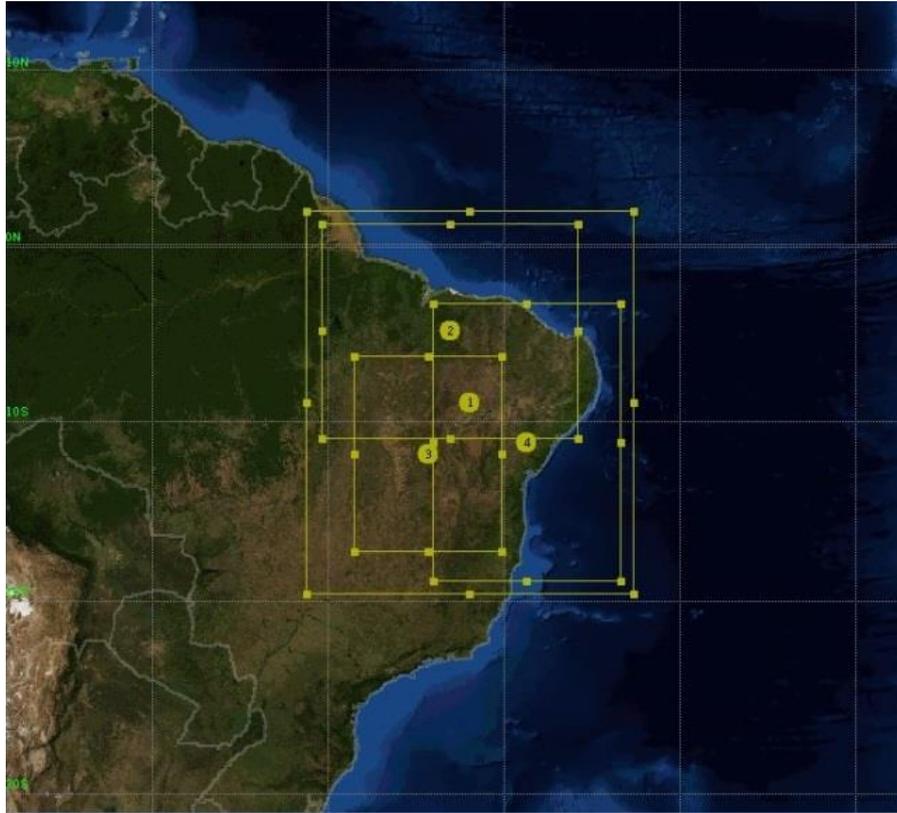


Figura 4.17 – Definição dos domínios utilizados no modelo WRF e suas respectivas grades para o teste de sensibilidade das principais parametrizações físicas: Convecção, Microfísica e Radiação para o NEB, domínio 1 com 15 km, domínios 2, 3 e 4 com 5 km.

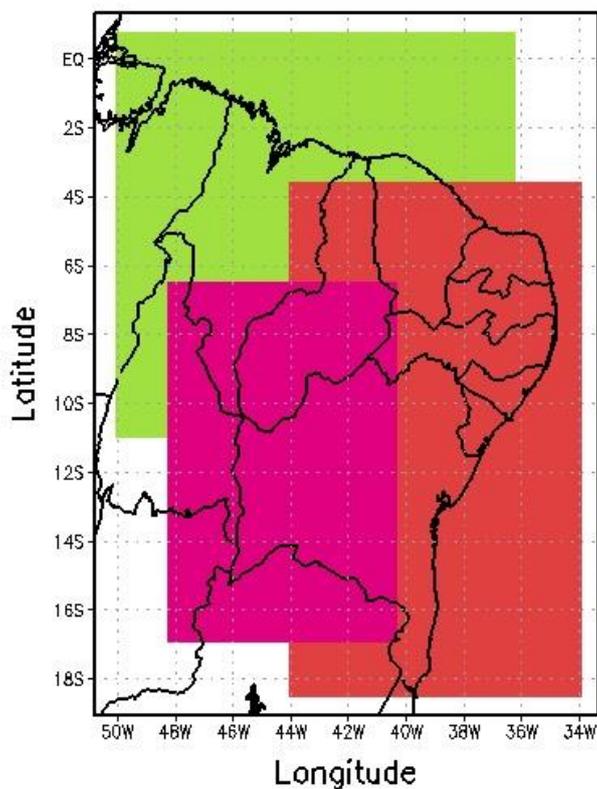


Figura 4.18 – Posicionamento das grades configuradas para o modelo WRF. Em roxo é a grade do modelo sobre a Região1, em vermelho sobre as Região2 e Região3, em verde sobre a Região4, todos com resolução horizontal de 5 km.

Em virtude da grande quantidade de estações de superfície utilizadas nessa pesquisa, optou-se por subdividir as quatro regiões homogêneas em subgrupos, a fim de diminuir as estações que serão usadas para validação dos testes de sensibilidade. Na Figura 4.19, tem-se o dendrograma das quatro regiões subdivididas.

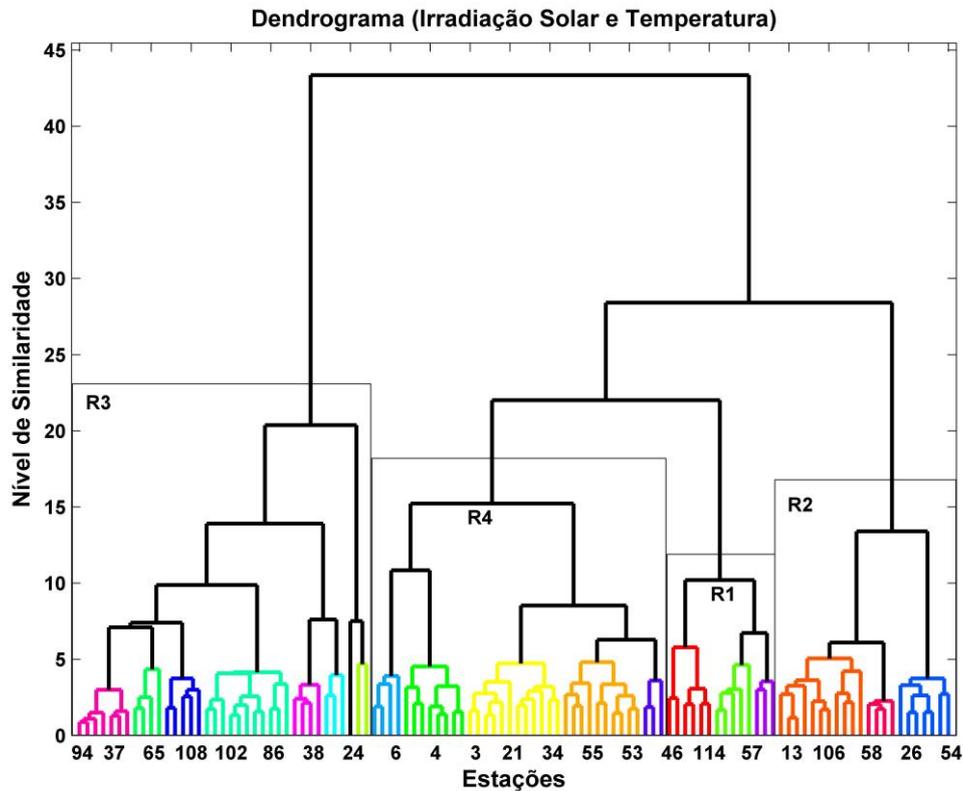


Figura 4.19 – Subgrupos das regiões homogêneas para definir as estações usadas nos testes de sensibilidade.

No intuito de diminuir as estações para a avaliação dos testes, as regiões R1, R2, R3 e R4 foram subdividas e foram escolhidas algumas estações em cada um desses subgrupos para que estas representassem a sua região. A escolha foi feita pela qualidade das estações; aquelas que tiveram um resultado no controle de qualidade dos dados superior às demais foram escolhidas. Também houve uma preocupação com a representação espacial das estações no NEB.

Em função disso, a divisão ficou a seguinte: R1, quatro estações; R2, seis estações; R3, sete estações e R4, oito estações. A Figura 4.20 mostra as escolhidas e sua localização na região de estudo.

É importante mencionar que todas as análises realizadas nesse estudo foram realizadas para as 110 estações, mas para facilitar a organização do

documento, são mostrados os resultados das estações subdivididas. Na Tabela 4.1 mostra-se a localização das estações e o seu ID.

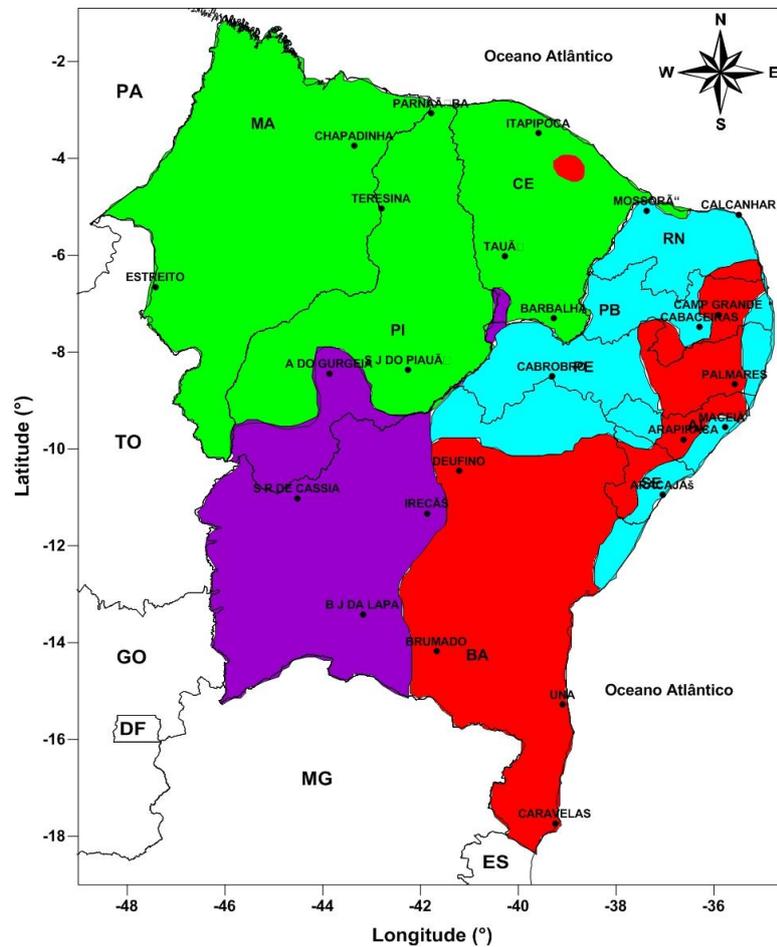


Figura 4.20 – Estações selecionadas para a avaliação dos testes de sensibilidade.

Tabela 4.1 – Localização das estações para a validação dos testes de sensibilidade.

LONGITUDE (°)	LATITUDE (°)	ESTAÇÕES	ID	REGIÕES
-43,86	-8,44	A DO GURGEIA	46	R1
-44,53	-11,02	S R DE CASSIA	90	R1
-43,18	-13,42	B J DA LAPA	93	R1
-41,86	-11,33	IRECÊ	99	R1
-35,77	-9,55	MACEIÓ	13	R2
-37,37	-5,08	MOSSORÓ	28	R2
-39,31	-8,50	CABROBRO	39	R2
-35,49	-5,16	CALCANHAR	54	R2
-36,29	-7,48	CABACEIRAS	58	R2
-37,05	-10,95	ARACAJÚ	85	R2
-35,91	-7,23	CAMP GRANDE	23	R3
-36,62	-9,80	ARAPIRACA	62	R3
-35,57	-8,67	PALMARES	66	R3
-39,25	-17,73	CARAVELAS	81	R3
-41,67	-14,18	BRUMADO	108	R3
-39,09	-15,28	UNA	112	R3
-41,21	-10,46	DEUFINO	118	R3
-43,35	-3,74	CHAPADINHA	3	R4
-47,42	-6,65	ESTREITO	9	R4
-41,78	-3,07	PARNÁIBA	18	R4
-42,80	-5,03	TERESINA	22	R4
-39,27	-7,30	BARBALHA	25	R4
-40,28	-6,02	TAUÁ	34	R4
-42,25	-8,36	S J DO PIAUÍ	41	R4
-39,59	-3,48	ITAPIOCA	68	R4

4.4. Teste de Sensibilidade do WRF (Radiação, Microfísica e Convecção)

Os três primeiros dias do mês de maio de 2009 foram simulados usando diferentes esquemas de radiação (RRTMG, Dudhia/RRTM e New Goddard), microfísica (Lin, Thompson e WSM6) e convecção (Grell 3D, Kain-Fritsch e Desligada). As simulações foram realizadas para os três dias descritos, combinando as diferentes parametrizações de radiação, microfísica e

convecção e todos os domínios do WRF foram configurados com o mesmo conjunto de parametrizações.

4.4.1. Avaliação das Parametrizações de Radiação do WRF

Tabela 4.2 – Esquema das principais parametrizações físicas para o teste de sensibilidade (radiação).

Convecção	Microfísica	Radiação	Legenda
Grell 3D	Thompson	RRTMG	Combinação 01
Grell 3D	Thompson	Dudhia/RRTM	Combinação 02
Grell 3D	Thompson	New Goddard	Combinação 03

A seguir foram comparadas as séries observadas com as simulações para o R1. Foram consideradas três simulações distintas, descritas na Tabela 4.2, onde são mostradas as combinações das parametrizações variando apenas a radiação, Comb. 01, Comb. 02 e Comb. 03. Pode-se verificar uma significativa subestimação da irradiação solar mais intensa por parte do modelo, em todas as estações. A estação de B J da Lapa não apresentou significância estatística ao nível de 5% segundo o teste de t-Student para as três simulações e em A do Gurgeia para a Comb. 03 e por isso, optou-se por excluir as estações que não obtiveram um resultado satisfatório no teste.

Nas Figuras 4.21 a 4.23 estão os índices estatísticos *ME*, *RMSE* e correlação das estações com significância estatística segundo o teste utilizado na pesquisa, para as localidades que compõem essa região. Na Figura 4.21, pode-se verificar uma subestimativa da irradiação solar mais intensa nas estações de A do Gurgeia e S R de Cassia, exceto para a Comb. 03, onde observa-se um valor em cerca de 3 W/m². Ainda nesta Figura, os valores mostram que a Comb. 01 leva à obtenção de melhores resultados na maioria das localidades para a variável em questão, sendo superior em duas das três estações. Já a Comb. 03 obteve o melhor resultado em S R de Cassia.

Observa-se um alto *ME* em todas as estações, exceto onde a Comb. 03 foi melhor.

Analisando o *RMSE*, observa-se que a Comb. 01 foi superior nas estações de A do Gurgeia e S R de Cassia, e teve desempenho semelhante ao apresentado pela Comb. 03, em Irecê, embora ambas apresentem valores de erro elevados. No caso do *RMSE*, novamente a Comb. 01 foi superior aos demais.

Na análise das correlações a Comb. 02 foi superior na primeira localidade, enquanto que na segunda e quarta o desempenho das Combinações 01 e 03 foram semelhantes. Ainda nas Figuras, a avaliação revela que a Combinação de parametrizações 01 leva à obtenção de melhores resultados, apresentando índices melhores na maioria das estações, correlações maiores e menores medidas de erro *ME* e *RMSE*.

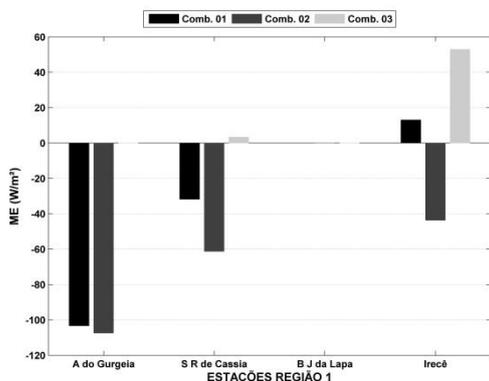


Figura 4.21 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.

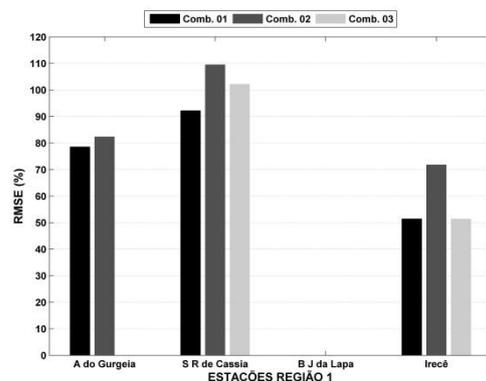


Figura 4.22 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.

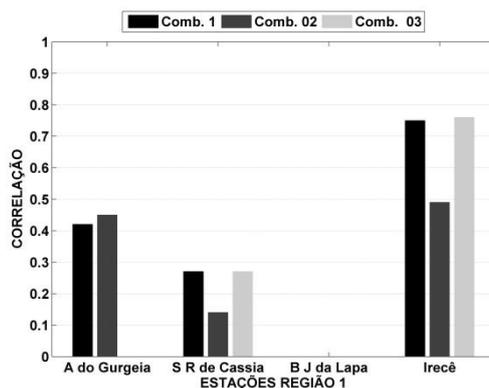


Figura 4.23 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de radiação.

Nas Figuras 4.24 a 4.26 estão os índices estatísticos *ME*, *RMSE* e correlação das estações com significância estatística, segundo o teste realizado para os três dias nas localidades que compõem a região 02. A estação de Aracaju não apresentou significância segundo o teste de t-Student.

Observa-se que a Comb. 02 foi superior nas estações de Mossoró, Calcanhar e Cabaceiras, enquanto que as Combinações 01 e 03 foram superiores em apenas uma estação cada, Cabrobro e Maceió respectivamente, para o *ME* ao Comb. 02 teve um melhor desempenho na região.

Verificando o *RMSE*, observa-se que a Comb. 02 foi superior nas mesmas estações analisadas para o *ME*, embora todas as configurações tenham mostrado um desempenho semelhante. Entretanto, ambas apresentaram valores de desvios superiores a 50%.

Na análise das correlações os melhores resultados foram obtidos em Cabrobro, Calcanhar, Mossoró, Maceió e Cabaceiras, respectivamente. A Comb. 02 foi superior na primeira e segunda localidade, enquanto que na quinta o desempenho da Comb. 01 foi superior. A Comb. 03 foi semelhante ao desempenho da Comb. 01 para Cabaceiras e teve um melhor resultado em Calcanhar, enquanto que a estação de Cabrobro não foi analisada por apresentar baixa correlação.

Os índices estatísticos para a R^2 revelam que os melhores resultados de irradiação solar são obtidos com a Comb. 02, mas a parametrização RRTMG obteve um desempenho semelhante.

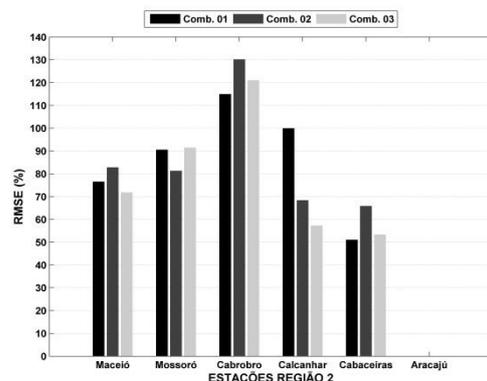
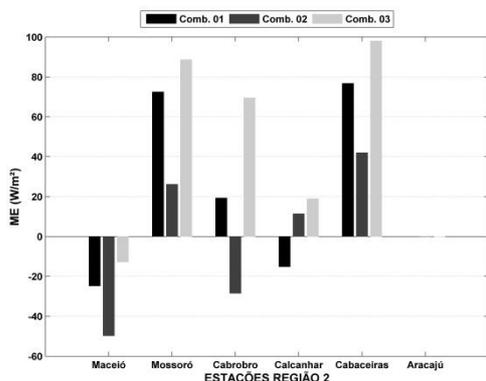


Figura 4.24 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.

Figura 4.25 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.

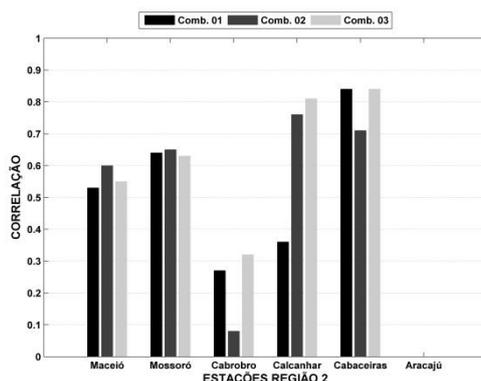


Figura 4.26 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de radiação.

Nas Figuras 4.27 a 4.29 estão os índices estatísticos para a R3, revelando que as Combinações 01 e 02 obtiveram um desempenho semelhante ao simular a irradiação solar. As estações de Arapiraca e Brumado não apresentaram significância estatística ao nível de 5% para as três simulações.

Na Figura 4.27, observa-se que a Comb. 02 foi superior nas estações de Campina Grande, Caravelas e Una, enquanto que a Comb. 01 foi melhor em Palmares e Deufino. A Comb. 03 não obteve resultados significativos para essa região, logo para o *ME* a Comb. 01 foi semelhante com uma ligeira vantagem para a Comb. 02.

No *RMSE*, observa-se que as Combinações 01 e 02 foram semelhantes, já que as duas foram melhores em três estações cada. Entretanto, ambas mostraram-se com um erro alto, observado em quase todas as estações até agora. Os menores valores foram obtidos em Palmares, Deufino e Caravelas, enquanto os mais altos foram verificados na estação de Una.

Analisando as correlações, obtiveram-se altos valores em todas as estações. Novamente, as Combinações 01 e 02 apresentaram desempenho semelhante.

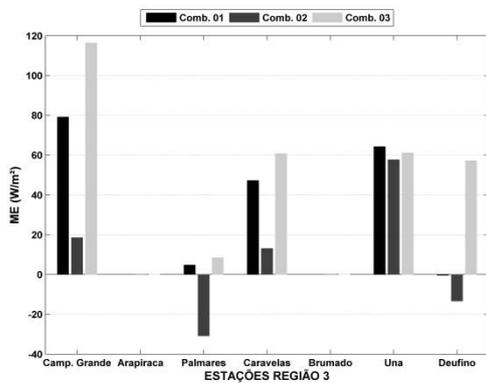


Figura 4.27 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.

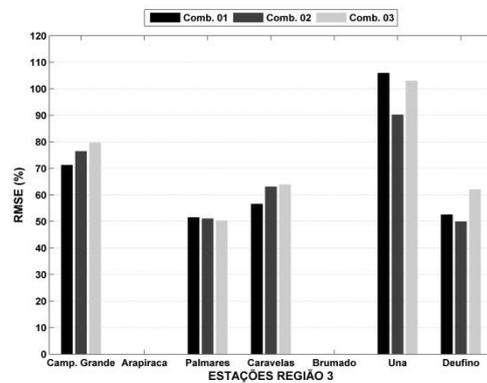


Figura 4.28 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.

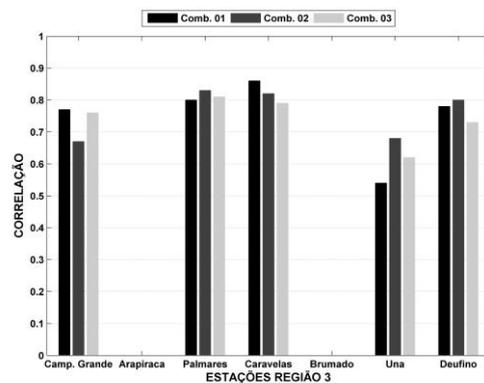


Figura 4.29 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de radiação.

Nas Figuras 4.30 a 4.32 estão os índices estatísticos para a R4, revelando que a Comb. 01 obteve um desempenho superior em relação às demais combinações ao simular a irradiação solar, apresentando índices melhores na maioria das estações, com menores valores de *ME*, *RMSE* e boa correlação.

As estações de Chapadinha e Teresina não apresentaram significância estatística ao nível de significância de 5%, para as Combinações 02 e 03. Já as estações de Parnaíba e Tauá não apresentaram significância para a Comb. 02. Verifica-se que a Comb. 01 foi melhor em quase todas as estações, exceto em Itapipoca onde a Comb. 02 foi superior; já em Estreito, a Comb. 03 apresentou melhor desempenho. Observa-se ainda que o modelo tende a subestimar a irradiação solar medida, exceto em Itapipoca, onde a tendência é contrária. Logo, para o *ME* a Comb. 01 foi bastante superior às demais.

Na Figura 4.31, observa-se que a Comb. 01 novamente foi melhor que as demais, sendo superior em cinco estações, enquanto que a Comb. 02 foi melhor em Itapipoca e a Comb. 03 obteve um resultado favorável em Estreito e S J do Piauí. Todas as estações apresentaram um erro significativamente alto. Analisando as correlações, verificam-se altos valores em Chapadinha, Estreito, Teresina e Tauá. O desempenho foi inferior em Caravelas, Barbalha e Itapipoca e baixo em Parnaíba. Novamente, a Comb. 01 obteve resultados superiores em quatro estações.

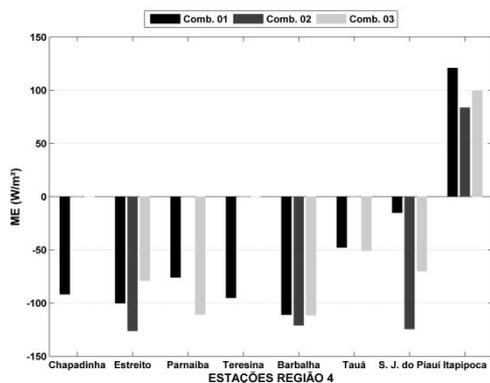


Figura 4.30 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.

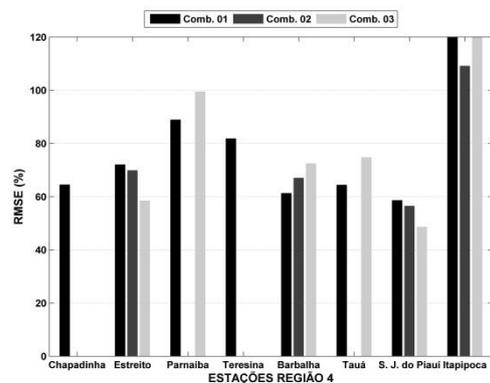


Figura 4.31 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.

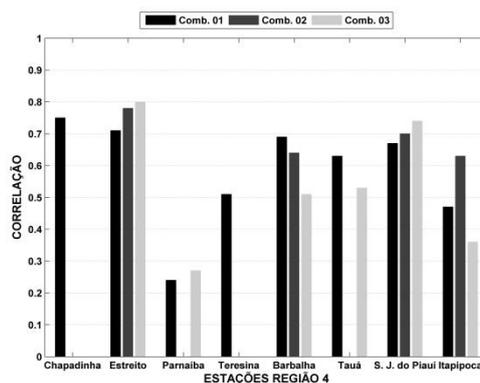


Figura 4.32 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de radiação.

Em geral, não houve uma diferença significativa entre as parametrizações de radiação RRTMG, (IACONO et al. 2008), Dudhia/RRTM, (DUDHIA, 1989; MLAWER et al. 1997), exceto para a Região 4, onde o desempenho da Comb. 01 foi bem superior ao das demais. Analisando todas as estações juntas, a parametrização de RRTMG obteve o melhor desempenho.

Considerando o *ME*, o desempenho foi melhor em 11 estações, contra sete da parametrização de Dudhia/RRTM e três para a New Goddard (CHOU; SUAREZ, 1994). Já para o *RMSE*, o esquema com a parametrização de

RRTMG foi melhor em sete estações contra seis da Comb. 02 e cinco do esquema usando a New Goddard.

Analisando as regiões separadamente, novamente a parametrização de RRTMG foi melhor em todas as áreas. Nas regiões 02 e 03, a parametrização de RRTMG apresentou desempenho semelhante à parametrização de Dudhia/RRTM. Nestas regiões, a primeira obteve os melhores resultados para o índice *RMSE*, enquanto a segunda foi melhor para o *ME* e correlação. Como o *RMSE* é uma medida de erro mais sensível a maiores desvios entre as séries do que o *ME*, o torna mais relevante quando se trata de prevenir grandes erros. Por isso, serão atribuídos pesos maiores em relação a este índice.

Para as próximas simulações, foi utilizada a Comb. 01, como sendo a combinação que apresentou os melhores resultados em todas as regiões. Este desempenho foi superior considerando todas as regiões junta e isoladamente um desempenho acima das outras para as regiões 01 e 04 e ainda com desempenho semelhante a Comb. 02 para as regiões 02 e 03.

4.4.2. Avaliação das Parametrizações de Microfísica do WRF

Tabela 4.3 – Esquema das principais parametrizações físicas para o teste de sensibilidade (Microfísica).

Convecção	Microfísica	Radiação	Legenda
Grell 3D	Thompson	RRTMG	Combinação 01
Grell 3D	WSM6	RRTMG	Combinação 04
Grell 3D	Lin	RRTMG	Combinação 05

Na Tabela 4.3, são mostradas as combinações das parametrizações variando apenas a microfísica e usando a parametrização de RRTMG em todas as simulações, onde serão comparadas as séries observadas com as simulações para as regiões R1, R2, R3 e R4.

Nas Figuras 4.32 a 4.34 são mostrados os índices estatísticos para os três dias nas quatro estações que compõem a região 01. Assim, foram consideradas três simulações distintas, descritas na Tabela 4.3, onde se pode verificar a tendência de subestimar a irradiação solar em todas as estações, em todas as combinações de parametrizações. Exceção na estação de Irecê, onde as Combinações 01 e 05 obtiveram valores ligeiramente superestimados. De acordo com o teste de t-Student, a estação de B J da Lapa não apresentou significância estatística em nenhuma das simulações.

Avaliando o *ME*, observa-se que a Comb. 05 apresentou o melhor resultado em Irecê e teve um desempenho semelhante às Combinações 01 e 04 para a estação de A do Gurgeia. Para a estação de S R de Cassia, o esquema usando a parametrização de Thompson foi superior, ou seja, as três configurações obtiveram desempenho semelhante. As localidades de A do Gurgeia e S R de Cassia apresentaram um alto *ME*.

Observa-se que a Comb. 04 foi melhor que as demais, sendo superior em duas estações, enquanto a Comb. 01 foi melhor em S R de Cassia. Todas as estações apresentaram um alto valor de *RMSE*, exceto em Irecê, onde se tem valor em cerca de 50% para todas as combinações.

Analisando as correlações, verifica-se que os maiores valores foram obtidos em Irecê, enquanto que os mais baixos estiveram nas estações de A do Gurgeia e S R de Cassia. Novamente, a Comb. 04 obteve resultados superiores. Ainda nas Figuras 4.32 a 4.34, as técnicas estatísticas utilizadas indicam que a Comb. 04 leva à obtenção de melhores resultados ao simular a irradiação solar, apresentando índices melhores na maioria das estações, correlações maiores e menores medidas de *RMSE*.

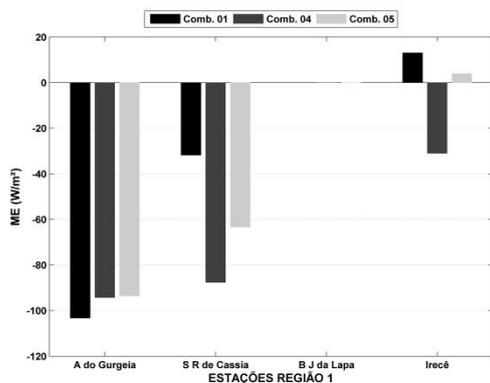


Figura 4.32 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.

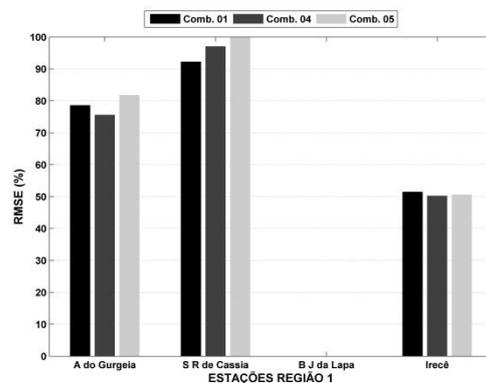


Figura 4.33 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.

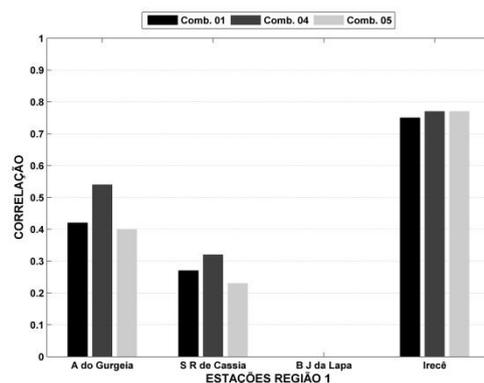


Figura 4.34 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de microfísica.

Os resultados das simulações para a grade R2 são exibidos nas Figuras 4.35 a 4.37, onde se verificam os valores dos índices estatísticos para os três dias nas estações. Pode-se verificar uma clara tendência de superestimava da irradiação solar e a ausência de significância estatística para a estação de Aracajú.

Pode-se verificar uma significativa superestimação na Figura 4.35, da irradiação solar nas estações de Mossoró, Cabrobro, Cabaceiras e Calcanhar, exceto para a Comb. 01. Já na estação de Maceió, o modelo subestima para as Combinações 01 e 05 e superestima para a parametrização WSM6.

Ainda nas Figuras 4.35 a 4.37, a estatística revela que a Comb. 01 leva à obtenção de melhores resultados na maioria das localidades ao simular a irradiação solar, sendo superior em cinco das seis estações. Já a Comb. 04 obteve o melhor resultado em Mossoró.

Observa-se para o *RMSE* que as Combinações 01 e 04 obtiveram resultados semelhantes, com melhores simulações em duas estações cada (Maceió, Cabaceiras, Mossoró e Cabrobro, respectivamente); enquanto isso, a Comb. 05 foi superior apenas na estação de Calcanhar. As duas primeiras Combinações para essa região obtiveram um desempenho similar, embora ambas tenham mostrado um erro alto.

Na análise das correlações, observa-se que a Comb. 01 foi superior em Maceió e Cabaceiras, enquanto que em Mossoró e Calcanhar a Comb. 05 foi melhor. A Comb. 04 foi superior em Cabrobro.

Nas Figuras, as técnicas estatísticas aplicadas revelam que a Comb. 01 leva à obtenção de melhores resultados de uma maneira geral, apresentando índices melhores na maioria das estações, principalmente no *ME*. É importante mencionar que o desempenho da Comb. 04 foi similar a Comb. 01, para o *RMSE*.

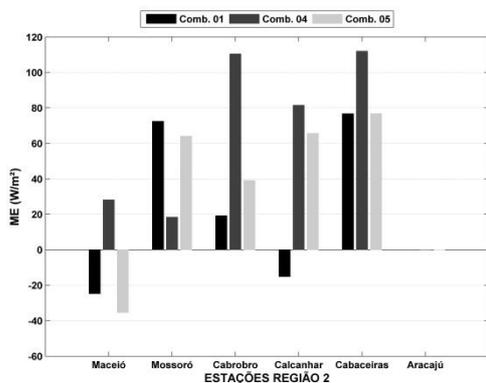


Figura 4.35 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.

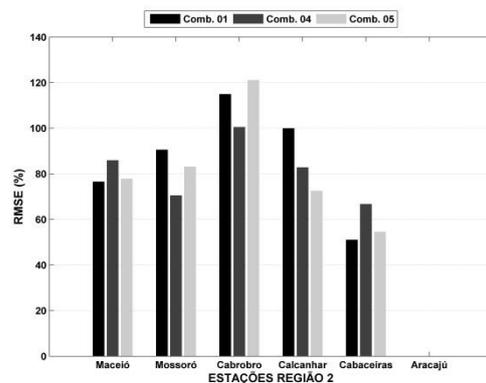


Figura 4.36 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.

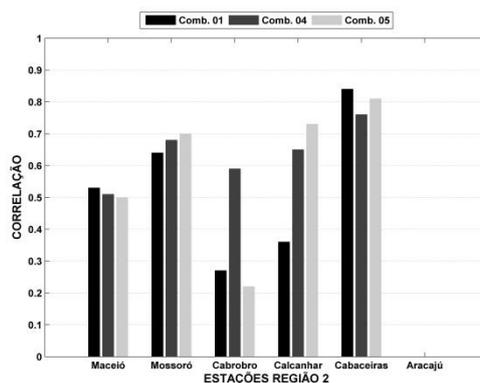


Figura 4.37 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de microfísica.

Observando as simulações para o R3 nas Figuras 4.38 a 4.40, estão os índices estatísticos das estações que compõem essa região. Pode-se verificar em geral uma superestimava da irradiação solar. As estações de Arapiraca e Brumado não apresentaram significância estatística.

Observa-se através dos valores de *ME* que a Comb. 04 foi superior nas estações de Campina Grande, Palmares e Caravelas, enquanto que a Comb. 01 funcionou melhor em Una e Deufino. O *ME* para as outras duas Combinações foi semelhante, com uma ligeira vantagem para a Comb. 04. A Comb. 05 não obteve resultados significativos para essa região.

Verificam-se na Figura 4.39 que as combinações 01 e 04 foram semelhantes, sendo (Campina Grande, Deufino) e (Palmares, Caravelas), as melhores para cada uma, respectivamente. Entretanto ambas apresentaram um *RMSE* alto, nas estações de Campina Grande e Una e valores médios nas localidades de Palmares, Caravelas e Deufino. A Comb. 05 obteve o menor valor em Una. Na análise das correlações, obtiveram-se valores superiores a 0,6 em todas as estações. Em Campina Grande e Deufino, a Comb. 01 foi melhor, enquanto que em Palmares a Comb. 04 foi melhor, em Una a Comb. 05 foi superior, em Caravelas para as três Combinações os valores de correlações foram idênticos. Nessa região as Combinações 01 e 05 foram semelhantes.

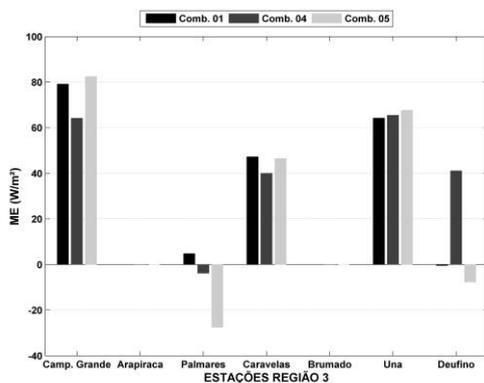


Figura 4.38 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.

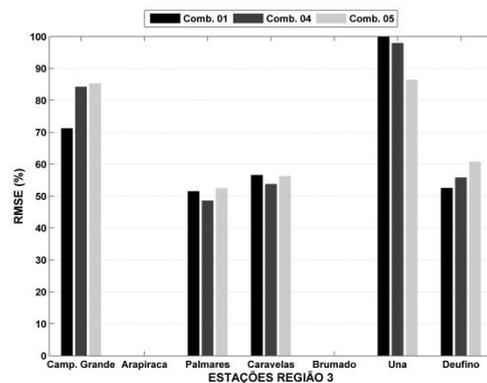


Figura 4.39 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.

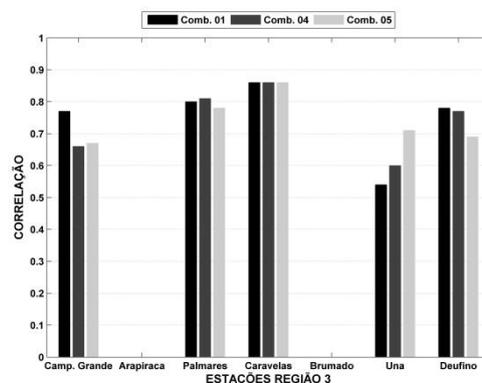


Figura 4.40 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de microfísica.

Nas Figuras 4.41 a 4.43 estão os índices estatísticos para R4, onde todas as estações apresentaram significância estatística segundo o teste de t-Student. Verificam-se nos valores de *ME* que a Comb. 05 foi melhor em cinco estações, enquanto a Comb. 04 foi superior em três. A Comb. 01 não obteve resultados significativos para o *ME*. Observa-se ainda que o modelo tende a subestimar a irradiação solar medida, exceto em Itapipoca, onde o WRF superestima. Logo, para o *ME*, a Comb. 05 foi ligeiramente superior a Comb. 04, sendo os dois superiores à Comb. 01.

Verifica-se, para o *RMSE*, que a Comb. 04 foi melhor em Estreito, Parnaíba, Teresina, Tauá e S J do Piauí. A Comb. 01 foi melhor em Chapadinha e Itapipoca, apesar de em Itapipoca para todas as configurações tem-se um valor alto de *RMSE*. Em Barbalha, a Comb. 05 foi melhor, porém em todas as estações mostraram-se altos valores de erro.

Analisando as correlações, verificam-se valores entre 60% e 80% em quase todas as estações. Em Chapadinha e Estreito, a Comb. 01 foi melhor. A Comb. 04 têm-se os melhores resultados em Teresina, Tauá e S J do Piauí já para a Comb. 01 Parnaíba, Barbalha e Itapipoca foram superiores.

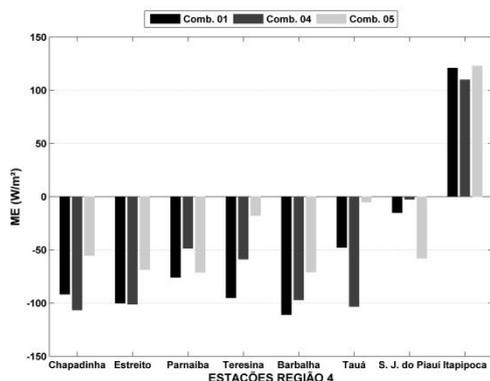


Figura 4.41 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.

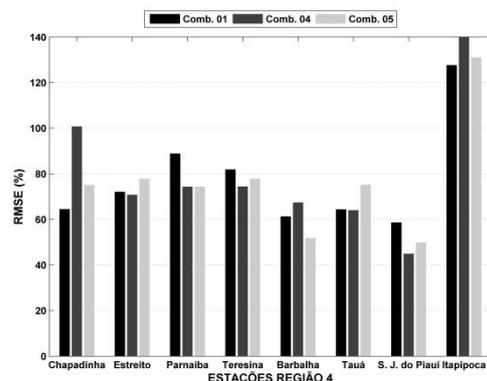


Figura 4.42 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.

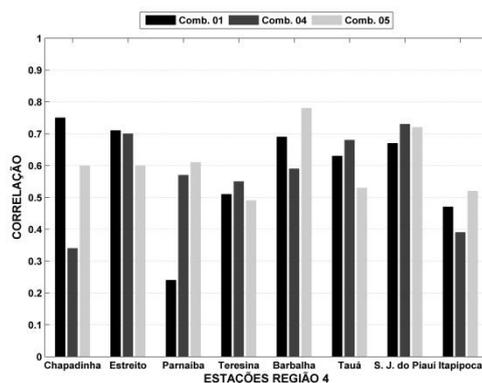


Figura 4.42 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de microfísica.

Em geral, houve diferença entre as parametrizações de microfísica Thompson et al. (2004), WSM6, (HONG et al, 1998) e Lin et al. (1983).

Analisando todas as regiões juntas, os esquemas de Thompson e WSM6 obtiveram um melhor desempenho em relação à parametrização de Lin, obtendo um *ME* melhor em seis estações para Thompson contra sete da parametrização WSM6 e sete para Lin. Para o *RMSE*, têm-se na Comb. 01, melhores resultados em nove estações, contra dez localidades para WSM6 e três para Lin. Para a correlação, Thompson foi melhor em sete, WSM6 em oito

e Lin em oito. Logo se conclui que a Comb. 04 foi ligeiramente superior ao esquema usando a parametrização de microfísica de Thompson e Lin.

Para as regiões 01, 02, 03 e 04 analisadas separadamente, a parametrização de WSM6 foi superior em R1 e R4, obtendo os melhores índices em um número maior de estações. Importante lembrar que o *RMSE* é um índice estatístico mais confiável dentre os três utilizados e, portanto optou-se por atribuir um maior peso para esse erro. Para as regiões R2 e R3, a parametrização de Thompson foi ligeiramente melhor que a configuração usando a parametrização WSM6. Para as próximas simulações foram usadas a Comb. 04 para R1 e R4 e a Comb. 01 para R2 e R3.

4.4.3. Avaliação das Parametrizações de Convecção do WRF

Na Tabela 4.4 são mostradas as combinações das parametrizações variando apenas a convecção e usando as parametrizações de RRTMG para radiação e WSM6 para a microfísica nas regiões 01 e 04 e para as áreas 02 e 03 usando a parametrização de microfísica Thompson em todas as simulações.

Tabela 4.4 – Esquema das principais parametrizações físicas para o teste de sensibilidade (Convecção).

Convecção	Microfísica	Radiação	Legenda	Regiões
Grell 3D	WSM6	RRTMG	Combinação 04	
Kain-Fritsch	WSM6	RRTMG	Combinação 06	1,4
Desligado	WSM6	RRTMG	Combinação 07	
Grell 3D	Thompson	RRTMG	Combinação 01	
Kain-Fritsch	Thompson	RRTMG	Combinação 08	2,3
Desligado	Thompson	RRTMG	Combinação 09	

Os resultados referentes às comparações das opções de parametrização de convecção são apresentados. Foram analisadas a seguir as séries observadas com as simulações para as regiões R1, R2, R3 e R4, sendo consideradas seis simulações distintas, descritas na Tabela 4.4.

Nas Figuras 4.44 a 4.46, estão os índices estatísticos para os três dias das estações que compõem a região 01. A estação de B J da Lapa, mais uma vez, não apresentou significância estatística de 5% segundo o teste de t-Student para as três simulações.

Pode-se verificar, no *ME*, uma significativa superestimação da irradiação solar em todas as estações, (exceto para o a parametrização de Grell-3D, que tendeu a subestimar). Ainda na Figura, a análise estatística revela que as Combinações apresentam desempenho semelhante ao simular a irradiação solar, sendo seus resultados superiores em uma localidade cada. Observa-se na Figura 4.45, que a Comb. 04 foi superior nas estações de A do Gurgeia e Irecê, enquanto que o desempenho apresentado pela a Comb. 06 foi melhor em S R de Cassia. Todas as estações apresentaram um alto erro, os melhores resultados encontram-se em Irecê e A do Gurgeia. Para o *RMSE* a Comb. 04 foi superior às demais.

Na Figura 4.46, a Comb. 04 foi superior na quarta localidade, enquanto que na primeira e segunda o desempenho da Comb. 06 foi melhor. Na região 01 a Comb. 04 obteve um melhor desempenho sobre as demais Combinações, por apresentar um melhor resultado quando foi analisado o índice de maior significância usado neste estudo.

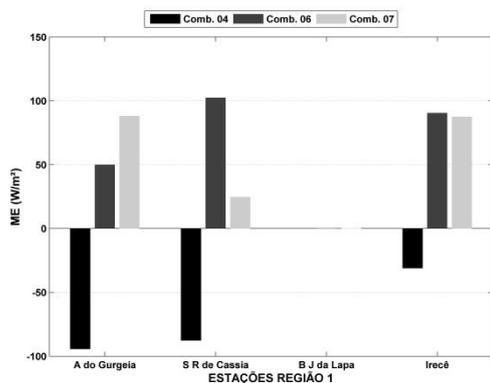


Figura 4.44 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.

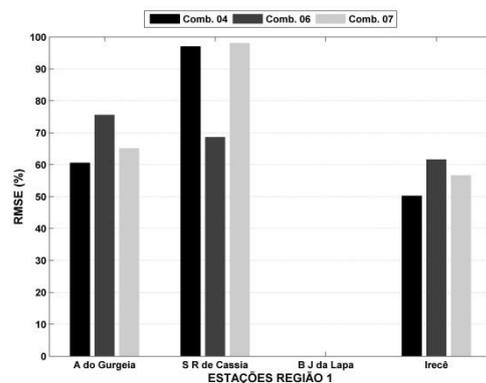


Figura 4.45 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.

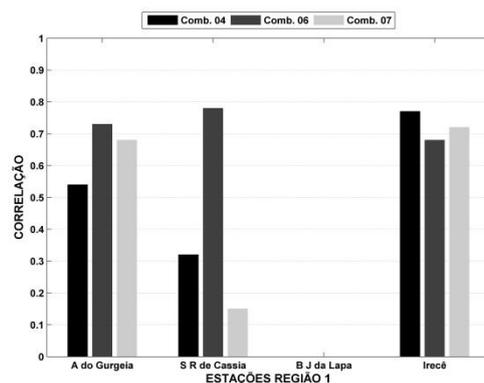


Figura 4.46 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R1 para a parametrização de convecção.

Nas Figuras 4.47 a 4.49 estão os índices estatísticos para a R2, que revelam melhores resultados para as Combinações 01 e 09 e levam à obtenção de melhores resultados ao simular a irradiação solar. Para todas as localidades usando a Comb. 08, para a estação de Aracaju usando a Comb. 01, em Maceió e Cabrobro para a Comb. 09, não apresentaram significância estatística ao nível de 5% segundo o teste de t-Student.

Observam-se, no *ME*, que as Combinações 01 e 09 foram superiores em três estações cada, com ótimos valores de *ME* em todas as estações; logo, para o

índice em questão, as parametrizações de Grell-3D e com a cúmulos desligada obtiveram um desempenho semelhante para essa região.

Na Figura 4.48 observa-se que as Combinações 01 e 09 foram superiores novamente nas mesmas estações analisadas para o *ME*; entretanto ambas mostram-se com um erro alto.

Na análise das correlações A Comb. 01 foi superior na primeira, segunda e quinta localidade, enquanto que na quarta e sexta o desempenho da Comb. 09 foi superior. Portanto para correlação o desempenho da Comb. 01 foi melhor, embora as parametrizações para a Comb. 09 apresentassem um desempenho semelhante.

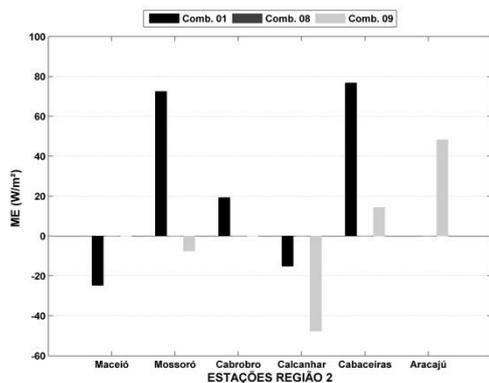


Figura 4.47 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.

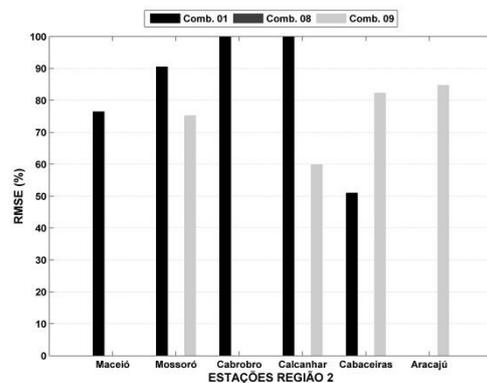


Figura 4.48 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.

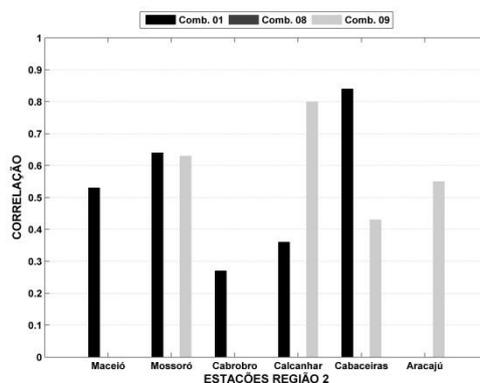


Figura 4.49 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R2 para a parametrização de convecção.

Nas Figuras 4.50 a 4.53 estão os índices estatísticos para a R3, revelando que a Comb. 01 leva à obtenção dos melhores índices. Apresentando índices melhores nas maiorias das estações. Para as localidades de Campina Grande, Caravelas, Una e Deufino usado a Comb. 08, e para a estação de Arapiraca usando as Combinações 01 e 09, e para todos as Combinações em Brumado, não apresentaram significância estatística ao nível 5% segundo o teste de t-Student.

Observa-se, na Figura 4.50, que a Comb. 01 foi superior nas estações de Palmares, Una e Deufino, enquanto que a Comb. 08 foi melhor em Arapiraca e a Comb. 09 foi superior em Campina Grande e Caravelas, logo para o *ME* a Comb.01 foi melhor na região.

Na Figura 4.51, observa-se que a Comb. 01 foi novamente superior às demais. Foram melhores em quatro estações, enquanto a Comb. 08 foi superior em Arapiraca. A Comb. 09 foi melhor em Una, entretanto ambas mostram-se com um alto valor de *RMSE*. Obtendo os menores valores em Palmares, Deufino e Caravelas e alto valores na estação de Una e Campina Grande.

Analisando as correlações obtiveram-se altos valores em todas as estações. Novamente a Comb. 01 foi melhor nessa região.

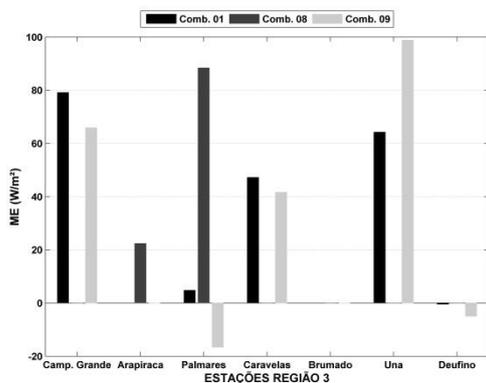


Figura 4.50 – Medidas de erro (ME) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.

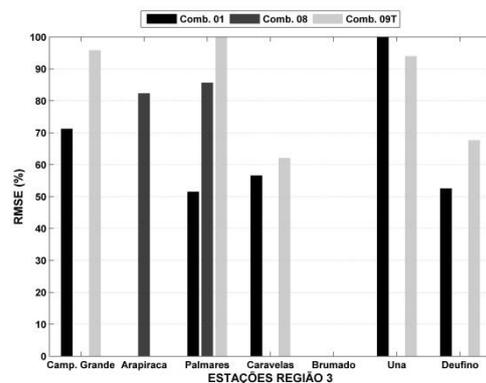


Figura 4.51 – Medidas de erro (RMSE) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.

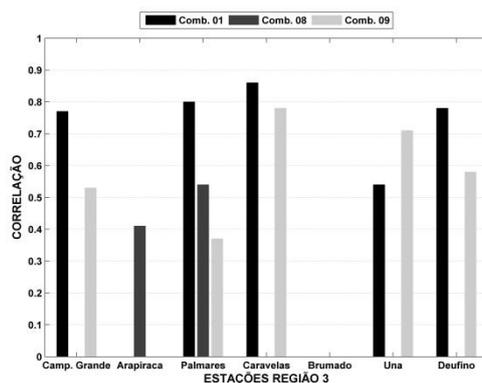


Figura 4.52 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R3 para a parametrização de convecção.

Nas Figuras 4.53 a 4.55 estão os índices estatísticos para R4, que revelam que a Comb. 04 leva à obtenção de melhores resultados. Para as localidades de Parnaíba, S J do Piauí e Itapipoca usando a Comb. 06, na estação de Itapipoca usando a Comb. 07, não apresentaram significância estatística ao nível de 5% segundo o teste de t-Student.

Na Figura 4.53, verifica-se que as Combinações 04 e 07 foram semelhantes sendo melhores em quatro estações cada, são elas: Parnaíba, Barbalha, S J do Piauí e Itapipoca (Comb. 04) e Chapadinha, Estreito, Teresina e Tauá

(Comb. 07). Logo para o *ME* as Combinações 04 e 07 apresentaram um bom desempenho.

Para o *RMSE* observa-se que a Comb. 04 foi melhor que as demais, sendo superior em cinco estações, Estreito, Parnaíba, Tauá, S J do Piauí e Itapipoca. A Comb.06 foi melhor em Chapadinha, Teresina e Barbalha e a Comb. 07 não obteve um resultado significativo. Todas as estações apresentaram um erro significativo.

A Comb. 06 obteve os melhores resultados em quatro estações contra duas da Comb. 04 e uma localidade para a Comb. 07, logo para correlação o desempenho da Comb. 06 foi superior às demais; entretanto analisando os três índices a Comb. 04 foi a melhor configuração para essa região.

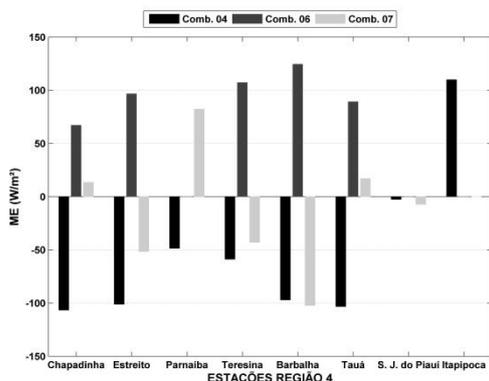


Figura 4.53 – Medidas de erro (*ME*) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.

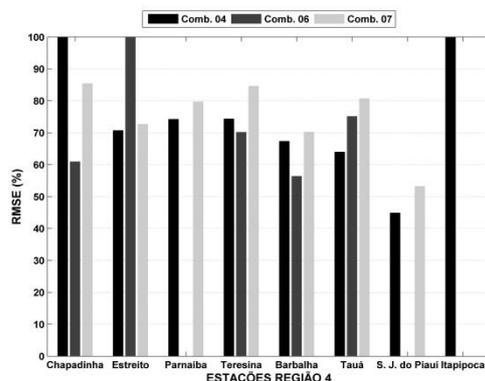


Figura 4.54 – Medidas de erro (*RMSE*) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.

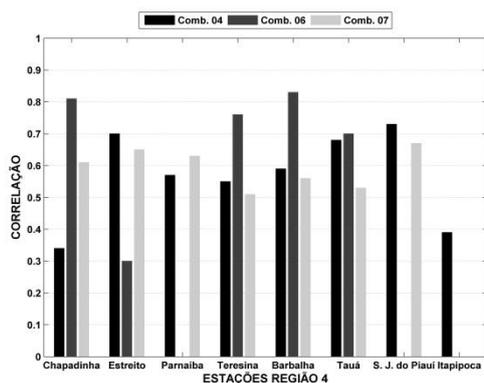


Figura 4.55 – Medidas de erro (Correlação) para a irradiação solar das estações que compõem a R4 para a parametrização de convecção.

Em geral houve diferença entre as parametrizações de Cúmulo Grell-3D (GRELL; DEVENYI, 2002), Kain-Fritsch (KAIN; FRITSCH, 1993) e com a cúmulo desligado. Para todas as regiões 01, 02, 03 e 04 a parametrização de Grell-3D obteve um melhor desempenho em relação às demais.

Na R1 para o *ME* a parametrização de Grell-3D foi melhor em uma estação contra 1 para a parametrização de Kain-Fritsch e uma também com a cúmulo desligadas. Para o *RMSE* Grell-3D foi melhor em 2 estações contra uma de Kain-Fritsch. Já na correlação, Kain-Fritsch foi superior em 2 localidades e 1 para Grell-3D.

Para R2 e R3 a parametrização de Grell-3D foi superior obtendo o ME melhor em 6 estações. Contra 1 da parametrização de Kain-Fritsch e 5 com a cúmulos desligada. Na análise do *RMSE* e correlação novamente Grell-3D foi melhor que as demais parametrizações, sendo melhor em sete estações para o *RMSE* e correlação. Na R4, a parametrização de Grell-3D foi semelhante à de Kain-Fritsch, obtendo o *ME* melhor em quatro estações, contra nenhuma da parametrização de Kain-Fritsch e quatro com a parametrização desligada, já para o *RMSE*, Kain-Fritsch e Grell-3D obtiveram um desempenho parecido sendo melhor em quatro estações cada; para a correlação Kain-Fritsch foi superior em quatro estações contra três de Grell-3D e uma para cúmulos desligados.

Conclui-se que a parametrização de Grell-3D foi a melhor em todas as regiões. Para as próximas simulações/previsões foram utilizadas a melhor Combinação para cada uma das regiões. Nas regiões R1 e R4 foi usada a Comb. 04 e nas regiões R2 e R3 a Comb. 01 foi usada.

5 RESULTADOS: PARTE II

Neste capítulo são mostrados os resultados obtidos pela comparação entre previsões e medidas de irradiação solar. Uma avaliação da previsão de irradiação solar dada pelo modelo WRF é apresentada, juntamente com uma descrição dos diagramas e discussões sobre os erros médios.

5.1. Avaliação das Previsões do Modelo WRF

A irradiação solar no NEB possui sazonalidade com algumas características locais. Avaliando a distribuição espaço-temporal da radiação global no Nordeste, com os dados medidos nos mesmos sítios estudados neste trabalho (Capítulo 4), constataram que os maiores valores ocorrem durante a primavera, nos meses de setembro, outubro e novembro, estação seca na região e os menores valores foram encontrados no outono, nos meses de março, abril e maio, período chuvoso em grande parte da região, exceto no Leste do Nordeste onde os menores valores foram encontrados no inverno.

No intuito de minimizar o tempo computacional foram escolhidos esses dois períodos para a avaliação do modelo WRF em simular/prever a irradiação solar no Nordeste do Brasil. Neste trabalho a irradiação solar das grades de 5 km do modelo WRF foi avaliada contra dados observacionais. Previsões de até 24 horas foram realizadas para todos os meses do outono e da primavera para os anos de 2009, 2010 e 2011, a fim de avaliar a capacidade do modelo em prever esse parâmetro.

Como mencionado nos capítulos anteriores, os modelos numéricos possuem um conhecido viés na previsão de radiação solar incidente na superfície. Este foi um dos fatores que motivaram a realização desse trabalho, uma vez que refinamentos e a obtenção de previsões com menores erros são necessários para diversas aplicações. Nesta seção uma avaliação da previsão de irradiação

solar dada pelo modelo WRF, para as quatro regiões homogêneas e para todas as estações subdivididas em cada uma dessas regiões, são apresentadas, sendo quantificados o *ME*, *MSE*, *RMSE* e *R*.

Nas figuras de dispersão são apresentados diagramas para as estações subdivididas das regiões homogêneas, em que as previsões (ordenadas) são comparadas com as observações (abscissas) de irradiação solar. Foram empregadas dados dos anos de 2009, 2010 e 2011 para o outono e primavera. Em todos os diagramas de dispersão apresentados neste capítulo, o comportamento geral das previsões (*P*) dos modelos, em função das observações (*O*), é descrito por ajustes lineares ($P = a + b.O$) calculados com base em todos os pontos e representados por linhas vermelhas. Os coeficientes lineares (*a*) e angulares (*b*), bem como os coeficientes de correlação, calculados para o ajuste linear são apresentados nos cantos superiores esquerdo de cada diagrama de dispersão. As linhas azuis são diagonais, que passam pelas origens dos gráficos e possuem coeficientes angulares unitários, representam os casos ideais, isto é, elas representam os casos em que previsões seriam perfeitas, assumindo o mesmo valor das observações ($P = O$). Nos diagramas dos gráficos lineares são mostrados os totais diários para todos os dias dos meses do outono e inverno e nos diagramas de dispersão são apresentadas as médias horárias.

5.1.1. Cenário de 2009

Nesta seção são apresentados os resultados para o outono e primavera de 2009. Nas figuras abaixo podem ser visto os índices estatísticos para todas as estações subdivididas para cada uma das quatro regiões homogêneas, apesar de em algumas estações o modelo apresentar um alto viés, o modelo foi capaz de prever a irradiação solar de forma satisfatória na região 01 do NEB. Foi calculado o viés, o erro sistemático (*ME*), o erro absoluto médio em porcentagem (*MSE%*), a raiz do erro médio quadrático em porcentagem

(*RMSE%*) e a correlação (*R*). Na Figura 5.1 são apresentados os diagramas dos índices estatísticos para a Região 01.

Verificando na Figura 5.1, que os maiores valores para *ME*, *MSE* e *RMSE* ocorrem em A do Gurgeia (46) e Irecê (99), a estação 90 mostra-se com um baixo *ME*, mas com altos índices de *MSE* e *RMSE*. Porém os menores valores de *ME* são encontrados em S R de Cassia (90) e B J Lapa (93), embora em todas as estações o *RMSE* fosse superior a 40%. Observa-se ainda que, apesar de o modelo apresentar um *ME* elevado e um *RMSE* também expressivo, na primeira, segunda, (exceto para o *ME*) e quarta estações, os coeficientes de correlação indicam bons níveis de correlações entre previsões e observações, sempre superiores a 0,60. Todas as estações a partir de agora serão referenciadas por seu ID descrito na Tabela 4.1 do Capítulo 4.

Ainda na Figura 5.1 para a primavera os maiores valores de *ME*, *MSE* e *RMSE* ocorrem nas estações 46 e 90, porém os menores valores de *ME* são encontrados em 93 e 90, em todas as estações os índices foram melhores na primavera que no outono, mostrando que o modelo é mais eficiente para os meses do ano com maior incidência de radiação na superfície. Observa-se um ótimo nível de correlações entre previsões e observações, sempre superiores a 0,80. Verifica-se que em todas as estações o modelo claramente superestima, exceto na estação 46 para o outono, embora se observe uma boa concordância entre os dados observados e previstos. Devido ao grande número de estações usadas nesta pesquisa serão mostrados os gráficos de dispersão e linear das estações que apresentarem um baixo desempenho para cada região homogênea.

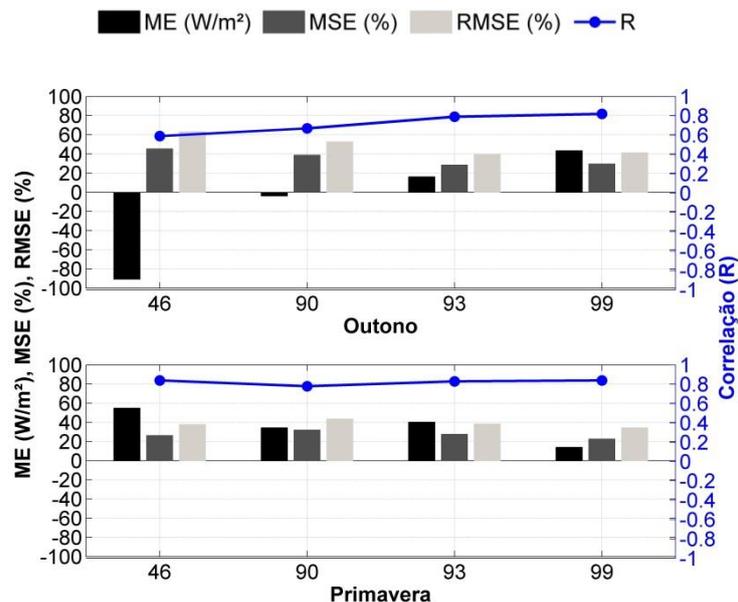


Figura 5.1 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2009).

Na Figura 5.2, têm-se o diagrama linear e de dispersão para a estação 46, mostrando que o modelo tende a subestimar a irradiação para o outono e sobrestimar para a primavera. Nos gráficos de dispersão mostra-se um alto desvio entre os dados medidos e estimados, mas com uma boa correlação para a primavera. Usando o teste de t-Student, tanto para o outono como para a primavera o modelo não apresentou significância estatística ao nível de 0,05.

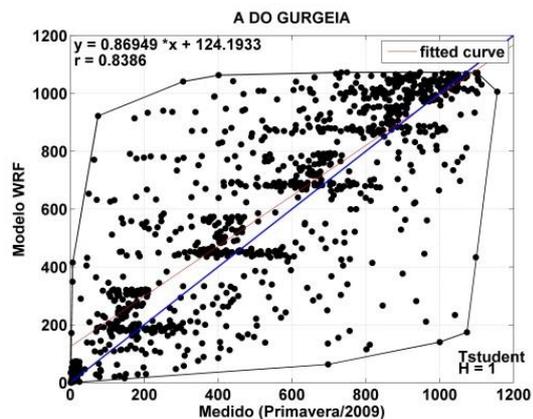
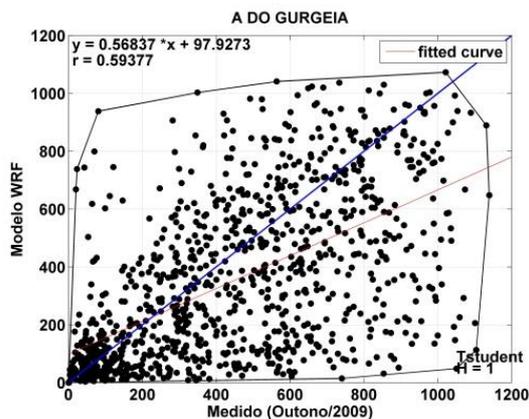
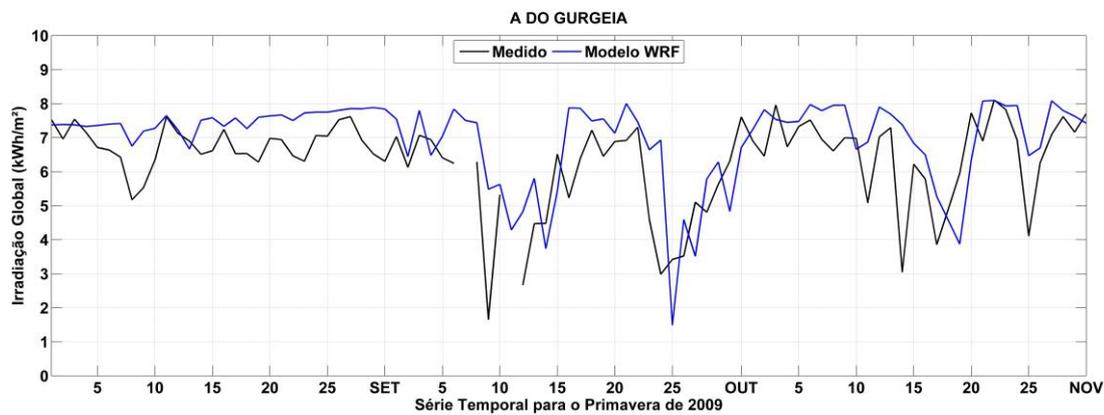
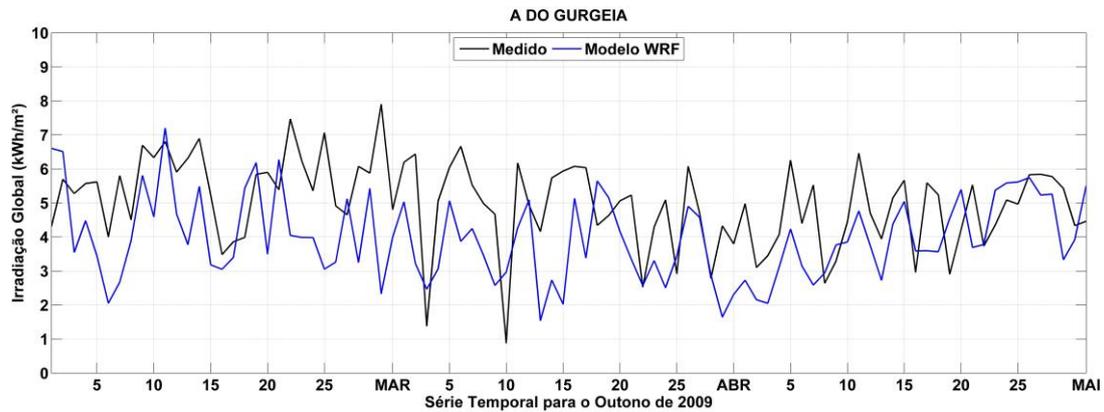


Figura 5.2 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2009).

Observando a Figura 5.3, os maiores valores para *ME*, *MSE* e *RMSE* ocorrem em 39 e 58, para outono e primavera, porém com razoáveis valores nas

demais estações. Observa-se um ótimo nível de correlações entre previsões e observações, sempre superiores a 0,70. Verifica-se que em quase todas as estações que o modelo claramente superestima os dados observados, embora se observe uma boa concordância entre os dados observados e previstos. Isto mostra que apesar de todos os erros inerentes a um modelo de previsão e todas as dificuldades ligadas à imprevisibilidade e não linearidades atmosféricas o modelo possui uma considerável habilidade em simular a irradiação solar, especialmente para os dias com maior incidência de radiação solar e, conseqüentemente, menor cobertura de nuvens.

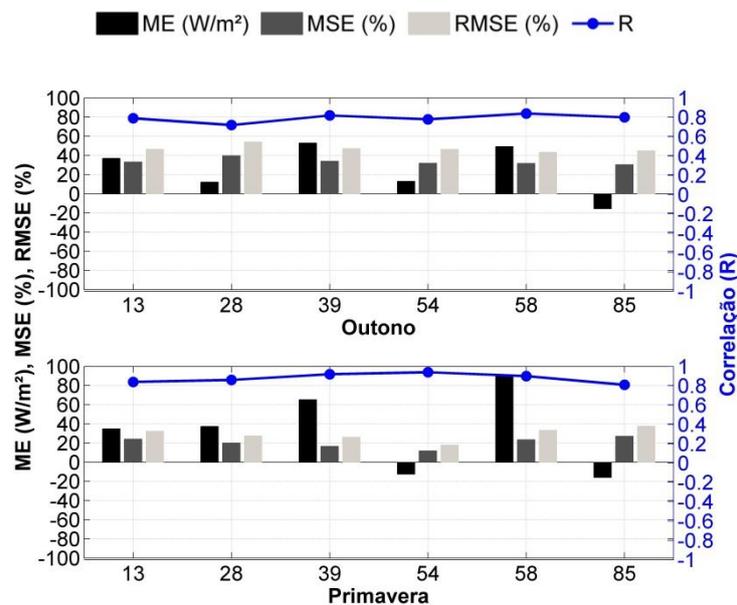


Figura 5.3 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2009).

Na Figura 5.4, têm-se o diagrama linear e de dispersão para a estação 58, mostrando que o modelo tende a superestimar a irradiação para o outono e primavera. Nos gráficos de dispersão mostra-se um alto desvio entre os dados medidos e estimados, mas com boas correlações. Usando o teste de t-Student, tanto para o outono como para a primavera, o modelo não apresentou significância estatística ao nível de 0,05.

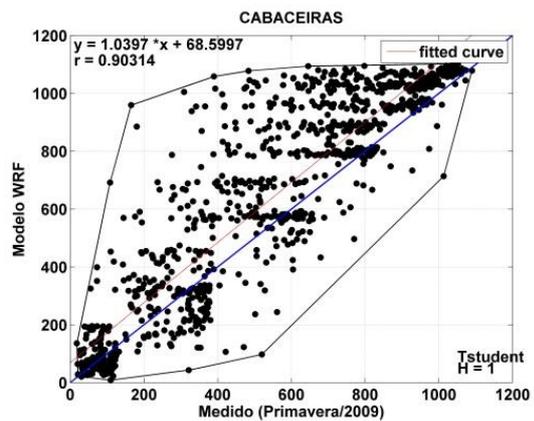
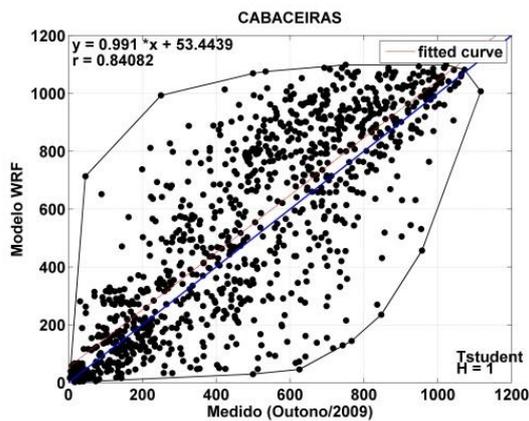
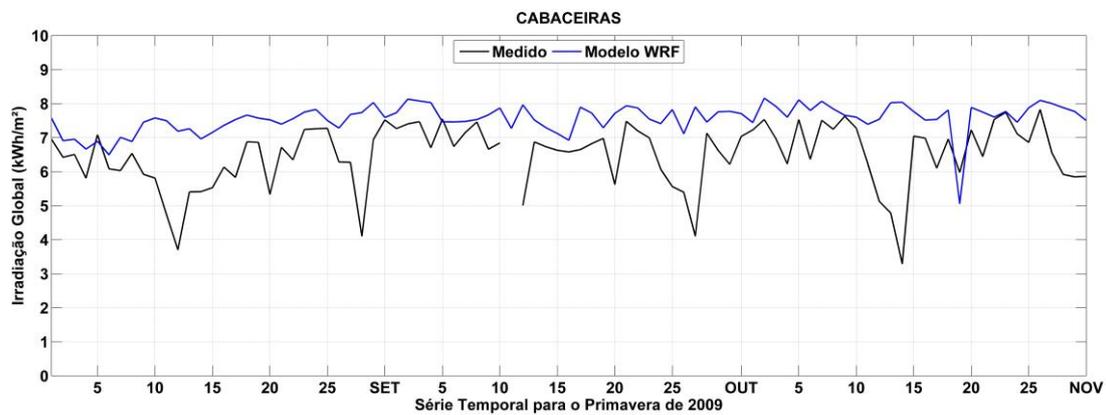
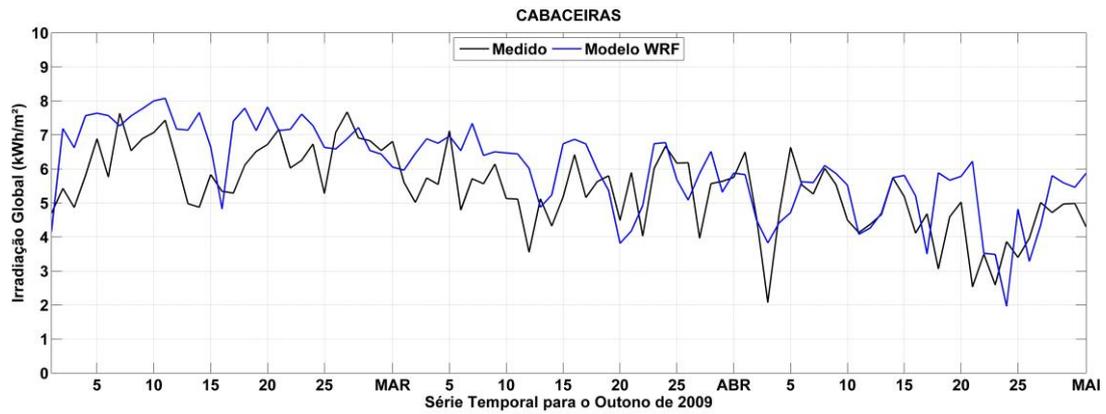


Figura 5.4 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2009).

Para a região 03, Figura 5.5, os maiores valores para *ME* ocorrem em 62, 81 para o outono e em 81, 108 e 118 para a primavera. Nas estações 23, 66 112,

(outono) e 62, 66, (primavera) mostra-se um baixo *ME*, mas com médios índices de *MSE* e *RMSE*. Em todas as estações o *RMSE* foi superior a 40%. Observa-se ainda que, apesar de o modelo apresentar um *ME* elevado e um *RMSE* também expressivo, em algumas estações, os coeficientes de correlação indicam bons níveis de correlações entre previsões e observações, sempre superiores a 0,7. Em quase todas as estações os índices foram médios para as duas épocas do ano, mostrando que o modelo é satisfatório, mas apresenta um erro sistemático alto. Observa-se que na região 03 o modelo claramente superestima os dados observados.

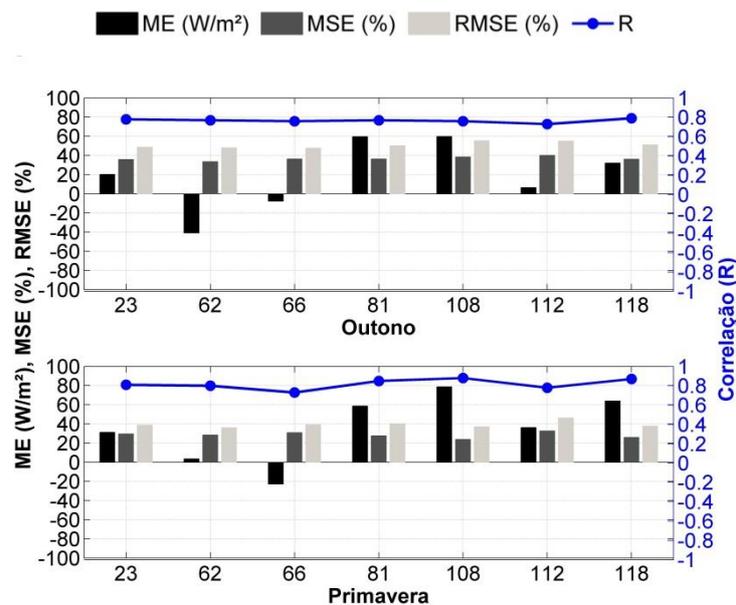


Figura 5.5 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2009).

Observa-se o diagrama linear e de dispersão para a estação 108, na Figura 5.6, mostrando que o modelo tende a superestimar a irradiação para o outono e primavera, mas com uma boa concordância entre os dados medidos e estimados. Os gráficos de dispersão mostram-se novamente com altos desvios entre os dados medidos e estimado, o que acarreta altos valores nos índices estatísticos, mas com uma boa correlação.

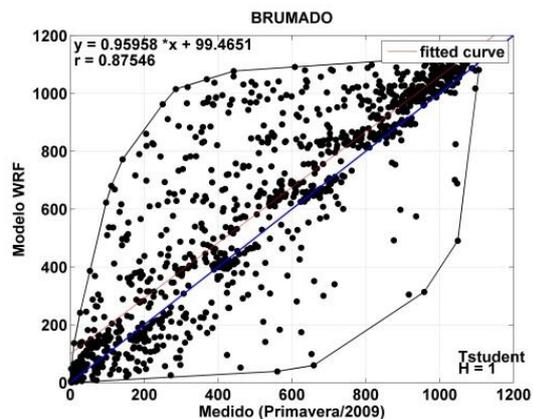
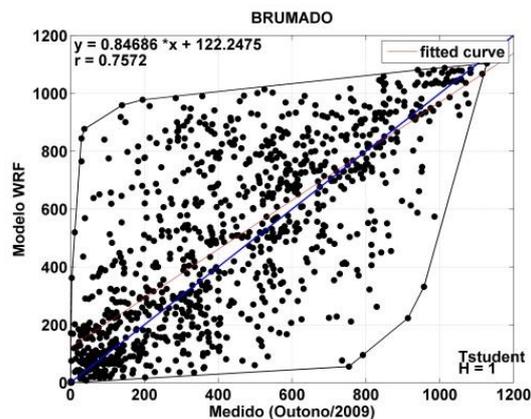
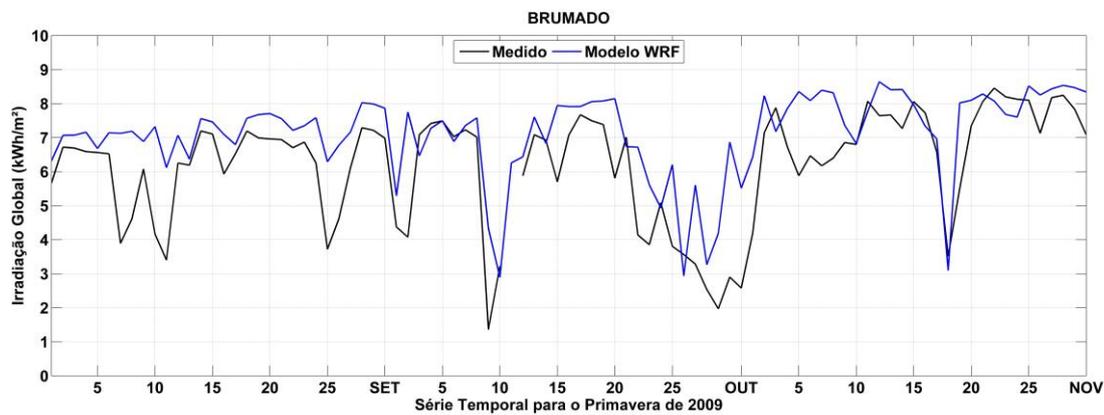
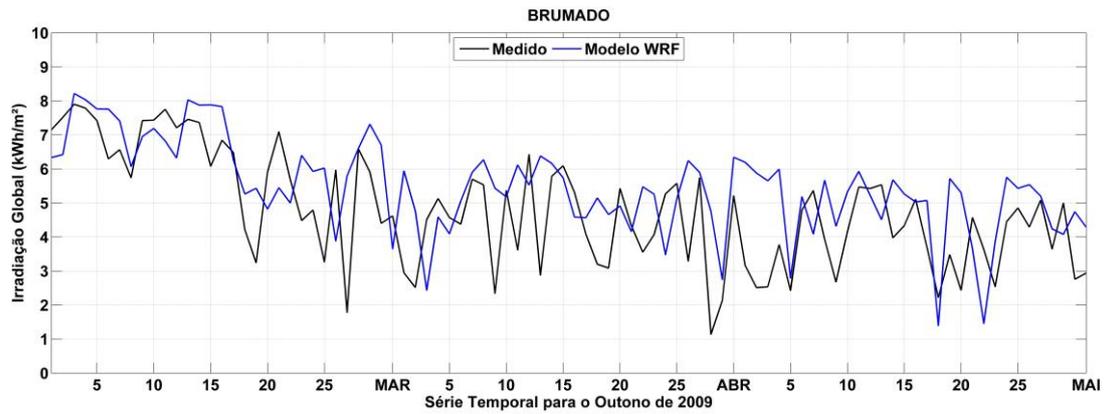


Figura 5.6 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2009).

Na região 04, Figura 5.7, no outono mostra-se os maiores valores de *MSE* e *RMSE* acima de 60%, em todas as estações. Para a primavera têm-se os

maiores valores de *ME*, acima de 100 W/m², exceto para as estações 3 e 18 que ficaram em cerca de 80 W/m². Apesar de altos índices, observa-se um ótimo nível de correlações entre previsões e observações, sempre superiores a 0,60. Verifica-se que para a região 04 o modelo teve maior dificuldade em simular a irradiação solar, provavelmente porque o ano de 2009 foi considerado um ano chuvoso para o Norte do Nordeste, onde está inserida a região homogênea 04; conseqüentemente foi um ano com bastante nebulosidade, o que diminui a capacidade do modelo.

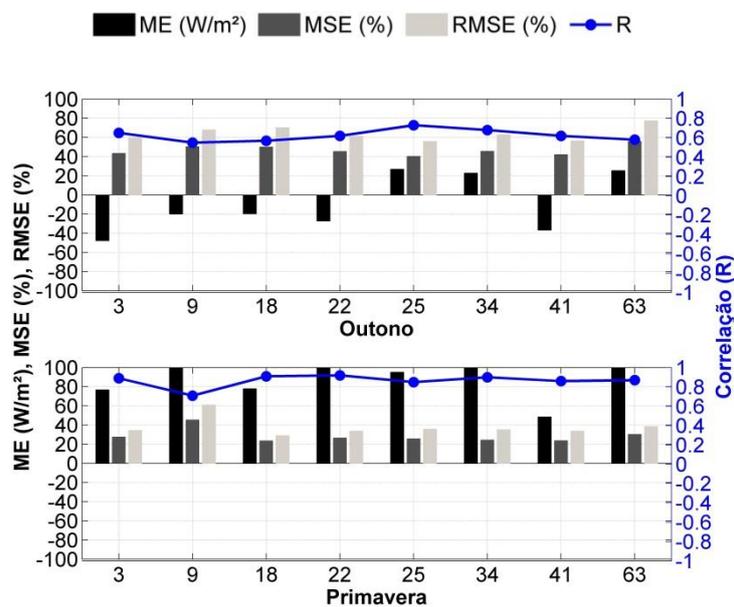


Figura 5.7 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2009).

Na Figura 5.8 observa-se o diagrama linear e a dispersão para a estação 63, mostrando que o modelo tende a superestimar a irradiação para a primavera, mas com uma boa concordância para o outono, apesar de um alto desvio. Os gráficos de dispersão mostram-se novamente com um alto desvio entre os dados medidos e estimados, o que acarreta em altos valores nos índices estatísticos.

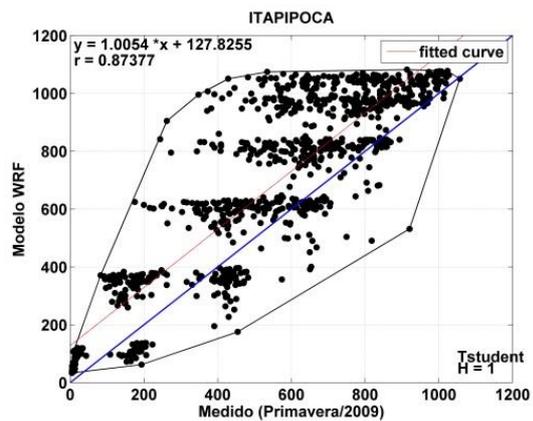
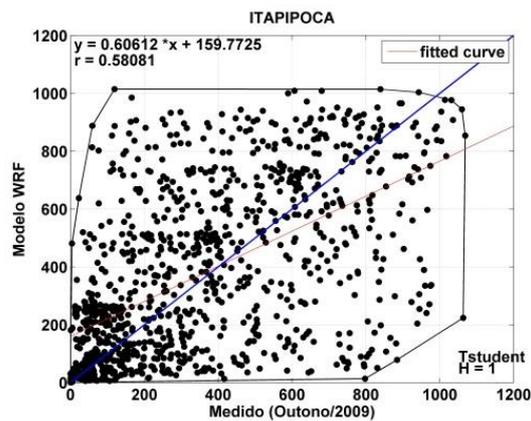
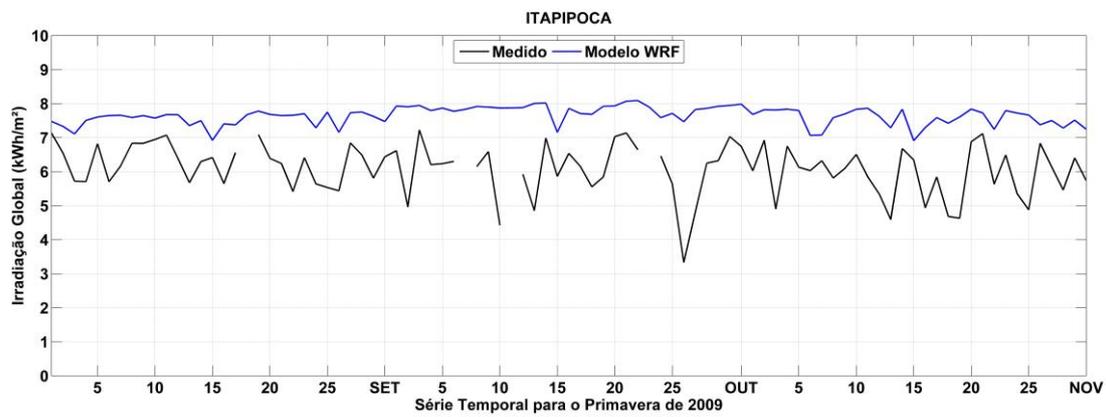
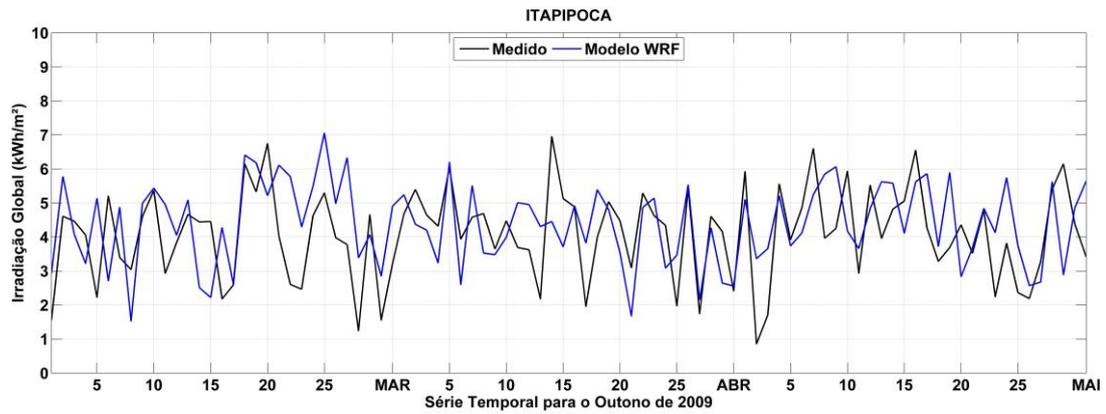


Figura 5.8 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2009).

5.1.2. Cenário de 2010

Nesta seção são apresentados os resultados para o outono e primavera de 2010. Nas figuras abaixo podem ser vistos os índices estatísticos para todas as estações subdivididas para cada uma das quatro regiões homogêneas. Em geral o modelo apresentar um alto viés, principalmente na região 04.

Observa-se na Figura 5.9, que os maiores valores para *ME*, *MSE* e *RMSE* ocorrem em 46 e 99. A estação 90 mostra-se com um *ME* maior que o da estação 99, embora esta estação apresente maiores valores de *MSE* e *RMSE*. Porém os menores valores de *ME* são encontrados em 93 e 99. Observa-se ainda que o modelo apresenta valores de erros médios na região, principalmente para a primavera como mostrar os coeficientes de correlação com bons níveis entre previsões e observações, sempre superiores a 0,65 para o outono e maiores que 0,80 para a primavera. Verifica-se que em todas as estações o modelo claramente superestima os valores de irradiação solar para a primavera. Para a região 01 em geral o modelo foi satisfatório na tarefa de simular a irradiação solar.

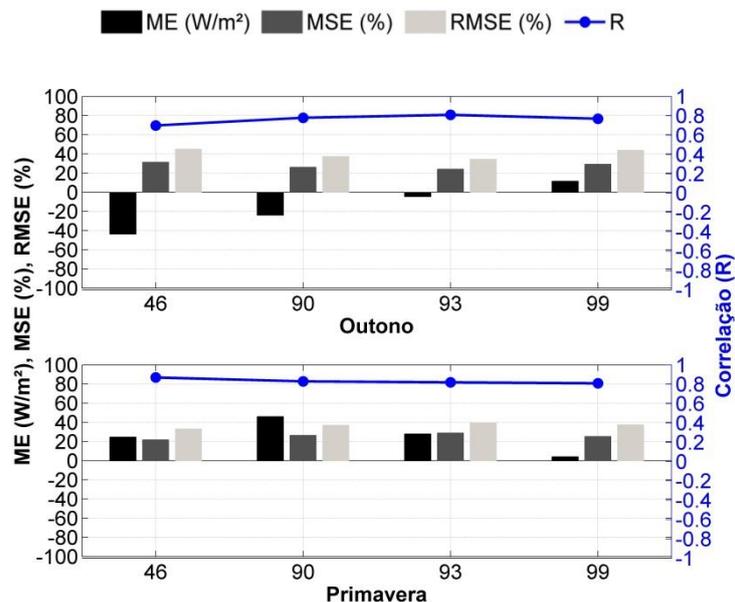


Figura 5.9 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2010).

Na Figura 5.10, têm-se o diagrama linear e de dispersão para a estação 46, comprovando que o modelo tende a subestimar a irradiação para o outono e superestimar para a primavera; entretanto verifica-se que o modelo segue a tendência dos dados medidos para os dois períodos em questão. Os gráficos de dispersão mostram um alto desvio entre os dados medido e estimado. O teste de t-Student, não apresentou significância estatística para o outono, porém para a primavera o modelo tem semelhança com os dados medidos ao nível de significância de 0,05.

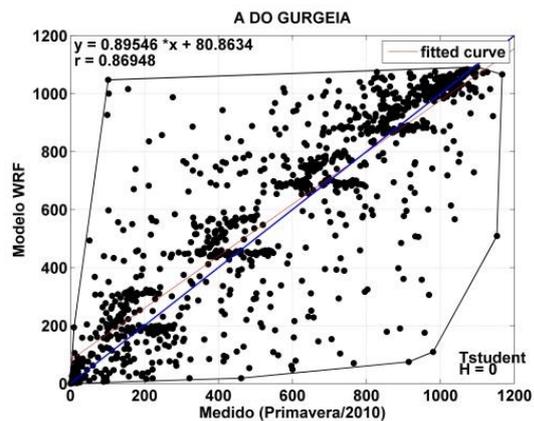
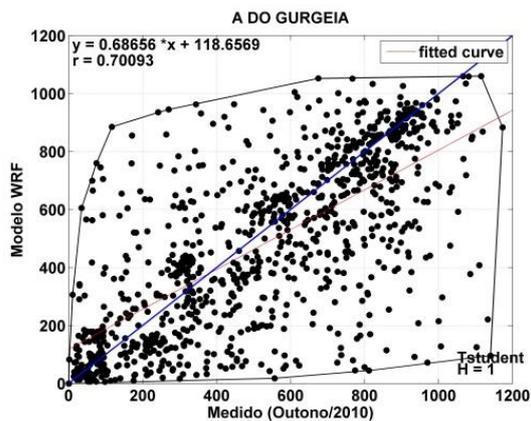
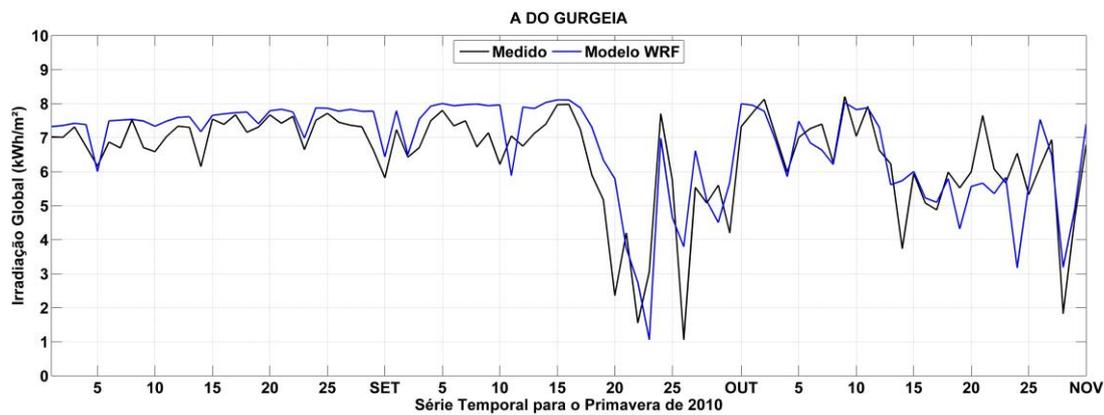
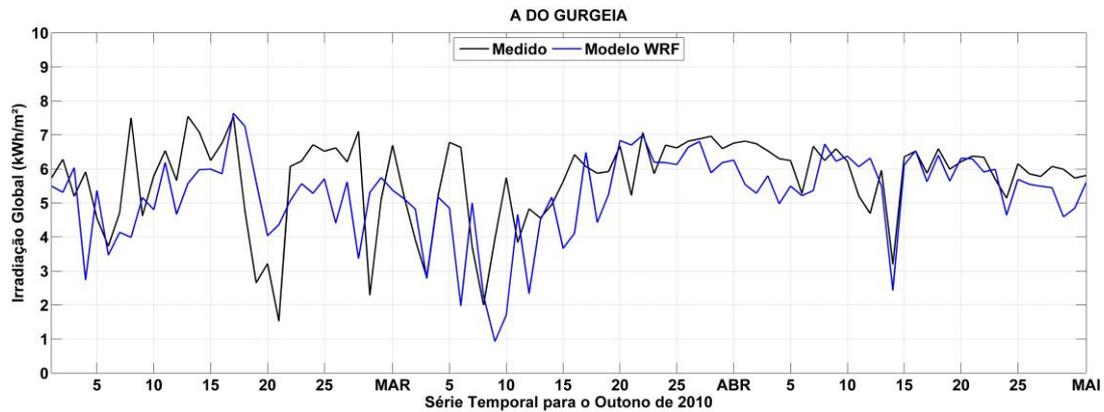


Figura 5.10 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2010).

Observando a Figura 5.11, nota-se que os maiores valores para *ME*, *MSE* e *RMSE* ocorrem em 39 e 58, para outono e 39, 58 e 85 para a primavera, porém

com razoáveis valores nas demais estações para todos os índices. Observa-se um ótimo nível de correlações entre previsões e observações, sempre superiores a 0,80. Verifica-se que em quase todas as estações o modelo claramente superestima, exceto para a primavera na estação 54. Isto mostra que o modelo possui uma considerável habilidade em simular a irradiação solar para a região 02.

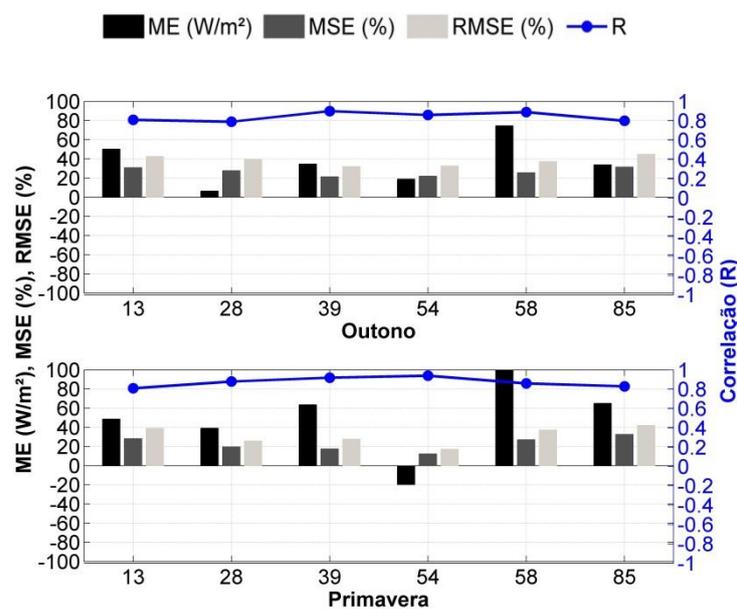


Figura 5.11 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2010).

Na Figura 5.12, têm-se o diagrama linear e de dispersão para a estação 58, mostrando que o modelo tende a superestimar a irradiação para o outono e primavera. Os gráficos de dispersão mostram um alto desvio entre os dados medido e estimado, mas com uma boa correlação para as duas épocas do ano. Observa-se que o modelo segue a tendência dos dados medidos apesar de tem um alto *ME*.

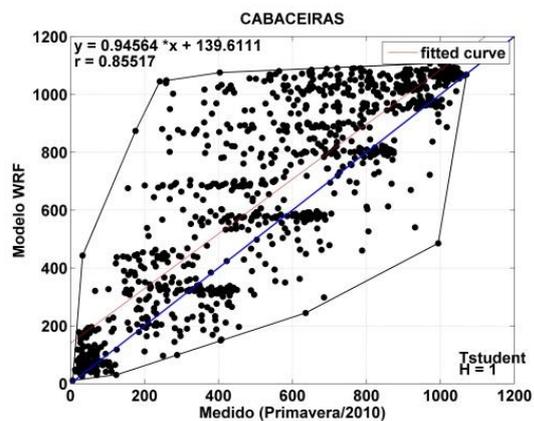
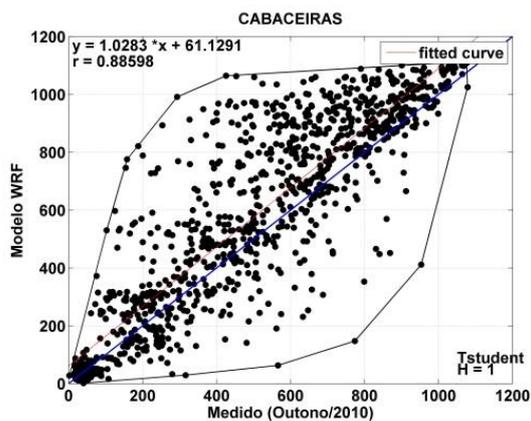
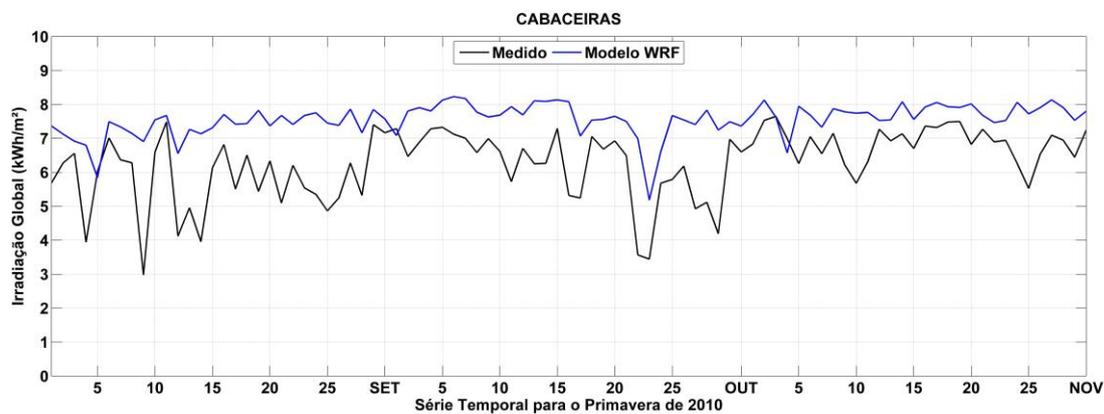
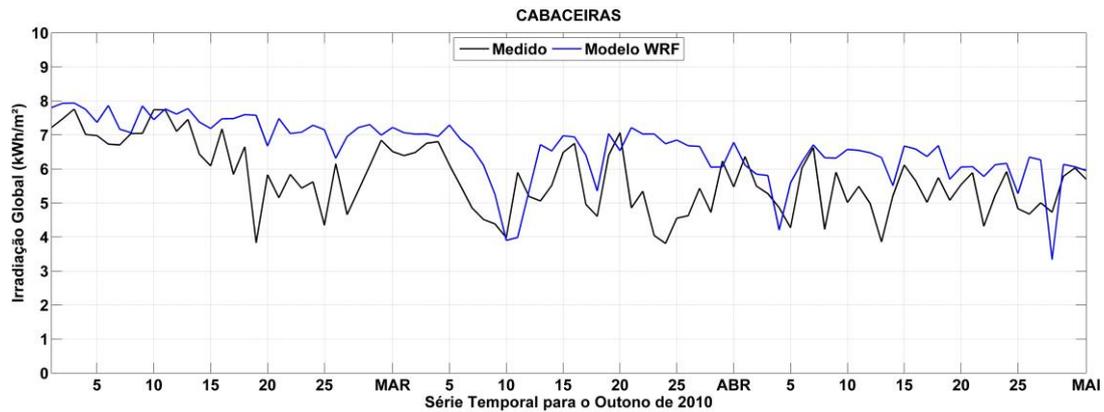


Figura 5.12 – de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2010).

Para a região 03, Figura 5.13, têm-se razoáveis valores para *ME*, exceto para a estação 108, para as duas épocas do ano. Para o *MSE* e *RMSE* verifica-se que os melhores índices foram na primavera, enquanto que para o outono os

valores de *RMSE* foram superiores a 40% e *MSE* em torno de 25%. Observa-se que, apesar de o modelo apresentar um *ME* alto na estação 108 e um *RMSE* expressivo em algumas estações, principalmente no outono, os coeficientes de correlação indicam bons níveis de correlação entre previsões e observações, sempre superiores a 0,70.

Em quase todas as estações os índices foram médios para as duas épocas do ano, mostrando que o modelo é satisfatório para prever/simular a irradiação solar, mas apresenta um erro sistemático alto em algumas estações. Observa-se que, em geral, na região 03 o modelo claramente superestima. Para as estações 81 e 112 para a primavera, não havia dados medidos disponíveis, ou os dados não foram aprovados no controle de qualidade.

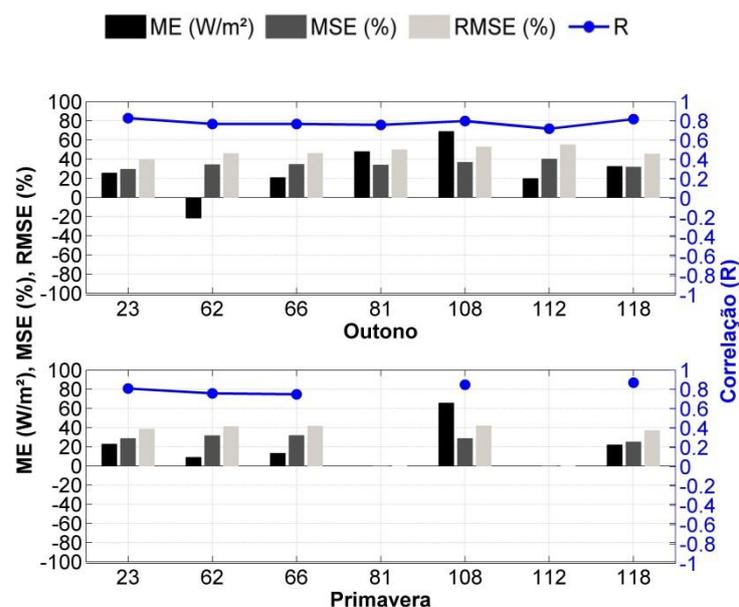


Figura 5.13 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2010).

Observa-se que o diagrama linear e de dispersão para a estação 108, na Figura 5.14, comprova que o modelo tende a superestimar a irradiação para o outono e primavera. Com uma boa concordância entre os dados medidos e estimados, principalmente para a primavera, o modelo apresentou maior

dificuldade no período do outono, principalmente a partir do dia 5 de março. Os gráficos de dispersão mostram-se novamente com alto desvio entre os dados medido e estimado, o que acarreta altos valores nos índices estatísticos, mas com uma boa correlação.

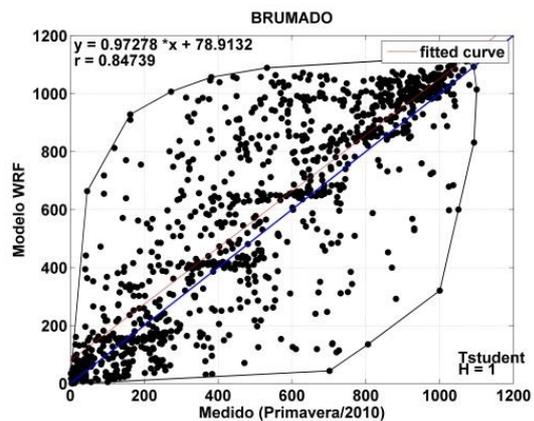
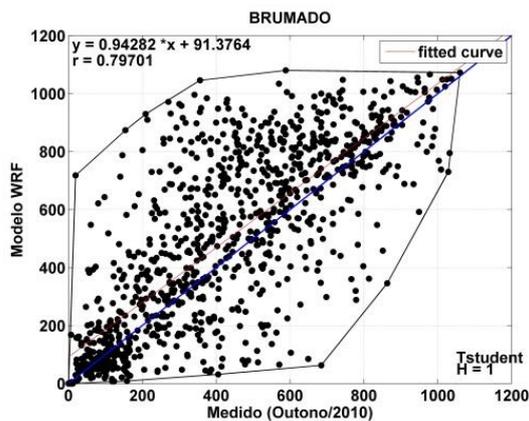
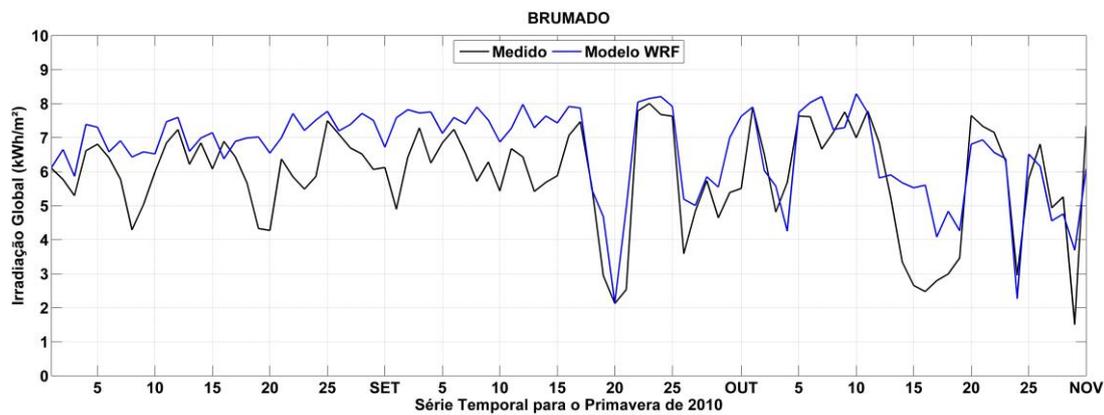
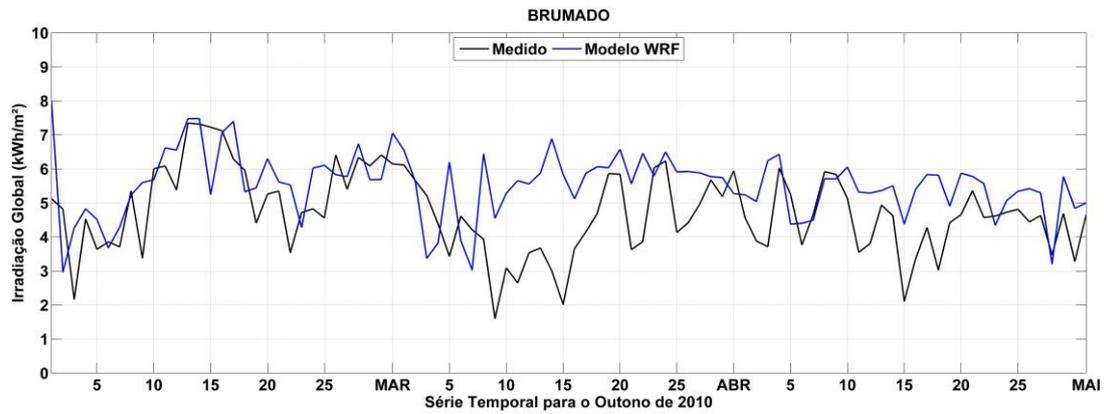


Figura 5.14 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2010).

Na região 04, Figura 5.15, mostram-se valores altos de *MSE* e *RMSE* para o outono e baixos valores de *ME*, exceto nas estações 3, 34 e 63 onde se verifica

altos valores para o índice. Para a primavera têm-se os maiores valores de *ME* acima de 100 W/m² em quase todas as estações. O mesmo que foi verificado no ano de 2009, embora tenha apresentado baixos valores de *MSE* e *RMSE*. Na região 04 o modelo teve maior dificuldade em simular a irradiação solar, ou seja, o modelo apresentou um alto erro para essa região.

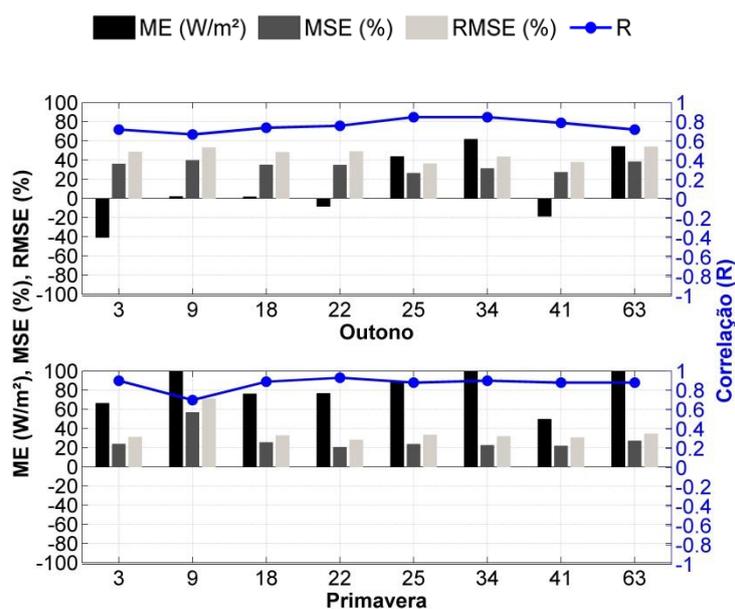


Figura 5.15 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2010).

Na Figura 5.16 observa-se o diagrama linear e a dispersão para a estação 9, mostrando que o modelo tende a superestimar, de maneira significativa, a irradiação para a primavera, mas com uma boa concordância para o outono, apesar de um alto desvio.

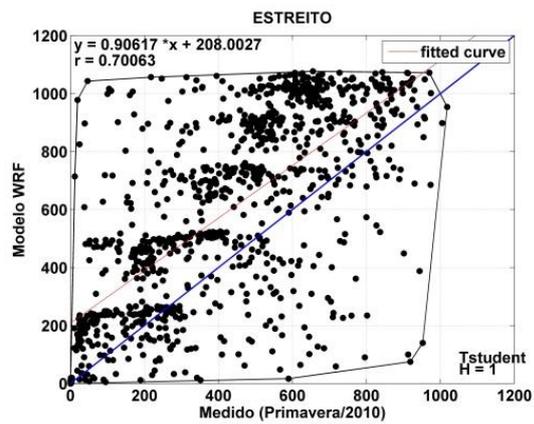
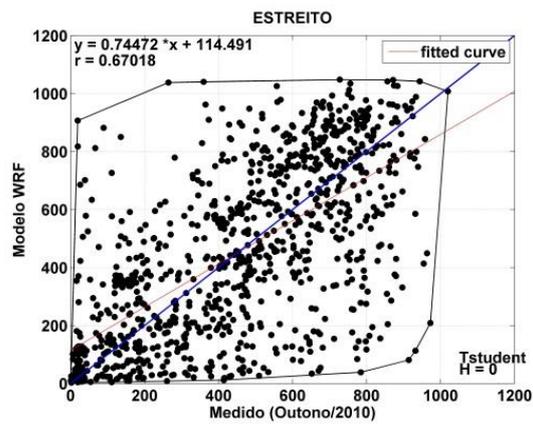
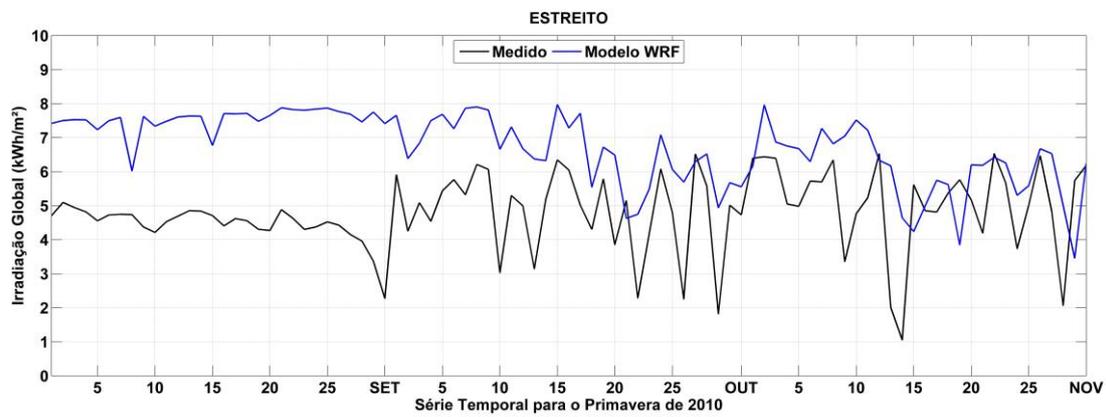
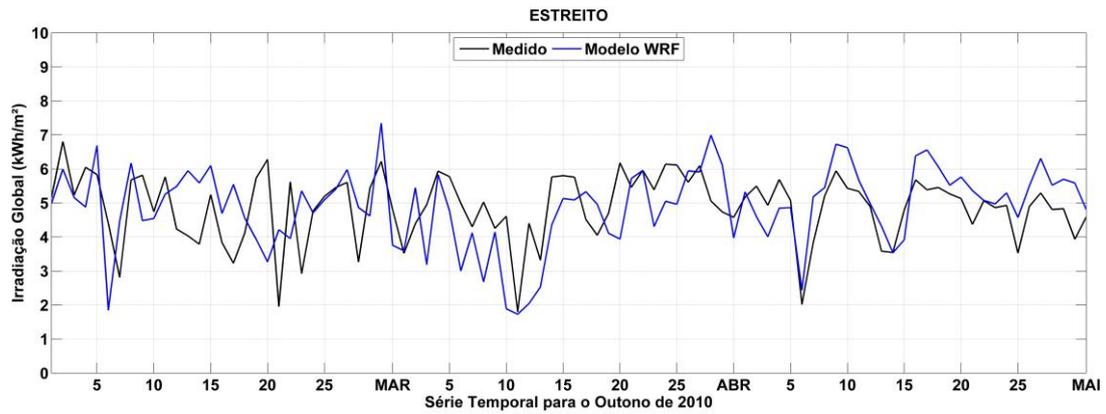


Figura 5.16 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2010).

5.1.3. Cenário de 2011

Nesta seção são apresentados os resultados para o outono e primavera de 2011. Nas Figuras abaixo poderão ser vistos os índices estatísticos, em geral o modelo apresentar um alto viés. Observa-se na Figura 5.17, que os valores para *ME*, *MSE* e *RMSE* são razoáveis para a região 01, porém no outono os valores de *RMSE* foram superiores a 40%, ou seja, como já era esperado o modelo obteve um melhor desempenho para a primavera. A localização da região 01 favorece a incidência de irradiação solar por apresentar menos nebulosidade o que facilita a capacidade do modelo WRF em prever/simular a radiação solar na região.

Observa-se ainda que os coeficientes de correlação apresentam-se com bons níveis entre previsões e observações, sempre superiores a 0,70 para o outono e maiores que 0,80 para a primavera. Para a região 01 em geral o modelo foi satisfatório na tarefa de simular a irradiação solar.

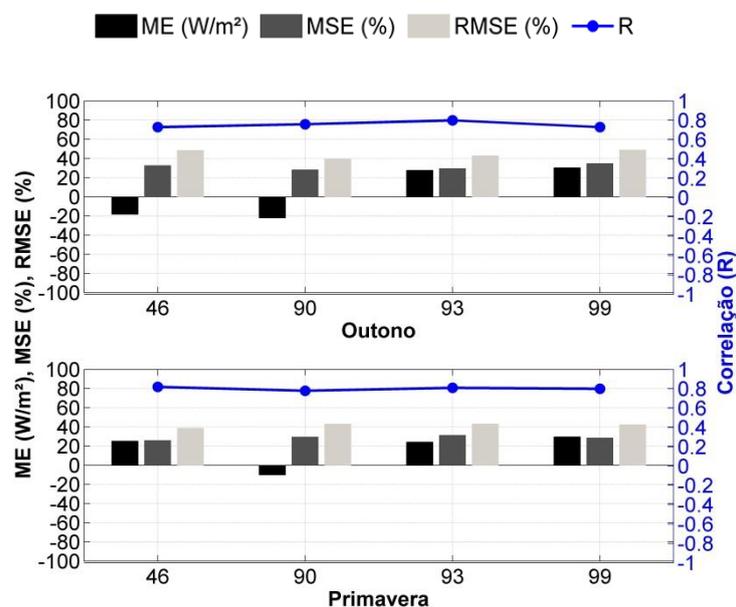


Figura 5.17 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2011).

Na Figura 5.18, têm-se o diagrama linear e de dispersão para a estação 99, mostrando que o modelo tende a superestimar a irradiação para todo o período. Os gráficos de dispersão mostram um alto desvio entre os dados medido e estimado, mas com boas correlações. Usando o teste de t-Student, tanto para o outono como para a primavera o modelo não apresentou significância estatística ao nível de 0,05.

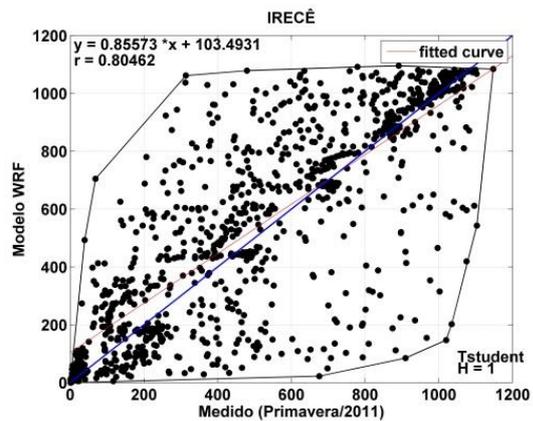
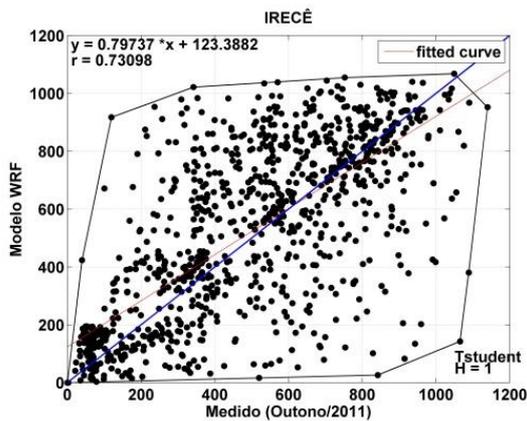
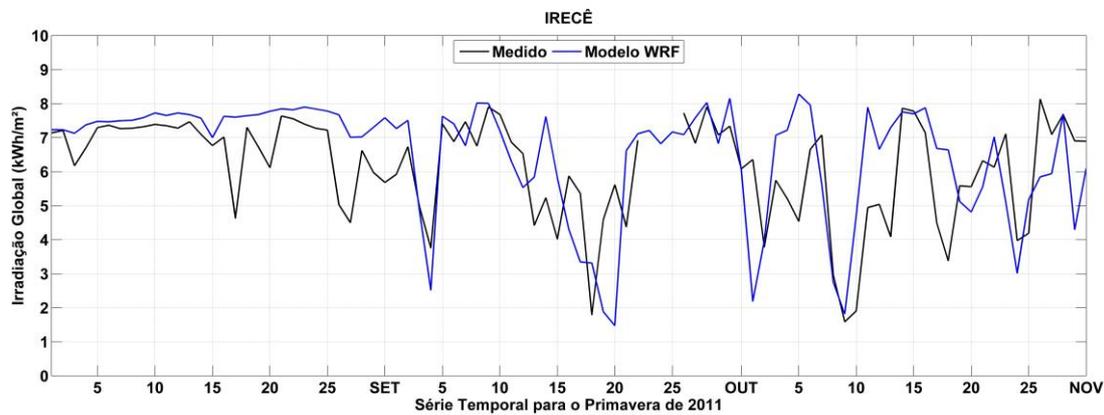
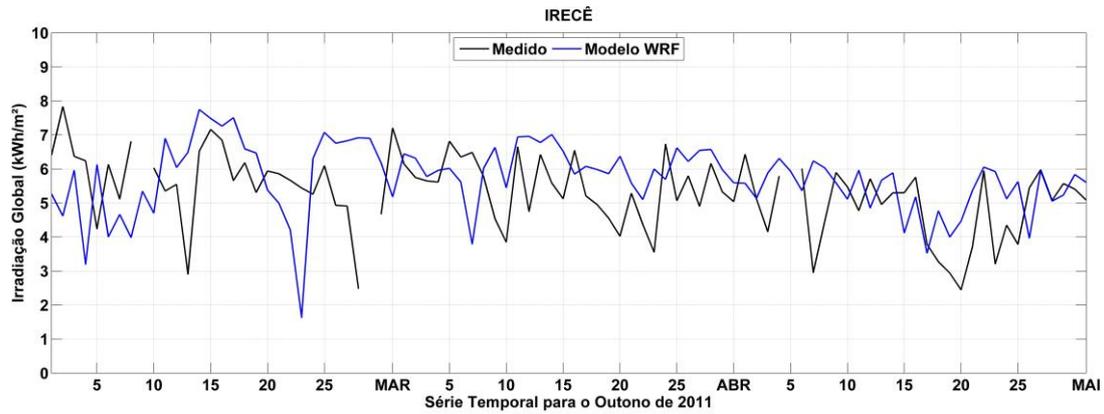


Figura 5.18 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 01 (2011).

Observa-se na Figura 5.19, que os valores de *ME* são altos tanto para o outono como para a primavera, exceto nas estações 28 e 54 para a primavera. Para

outono observa-se médios valores de *MSE* e *RMSE* e para primavera têm-se valores razoáveis. Observa-se um ótimo nível de correlações entre previsões e observações, sempre em torno de 0,80. Verifica-se que em quase todas as estações o modelo claramente superestima a irradiação solar, embora se observe uma boa concordância entre os dados observados e previstos. Isto mostra que apesar de todos os erros inerentes a um modelo de previsão e apesar de um alto viés na região, o modelo possui uma considerável habilidade em simular a irradiação solar.

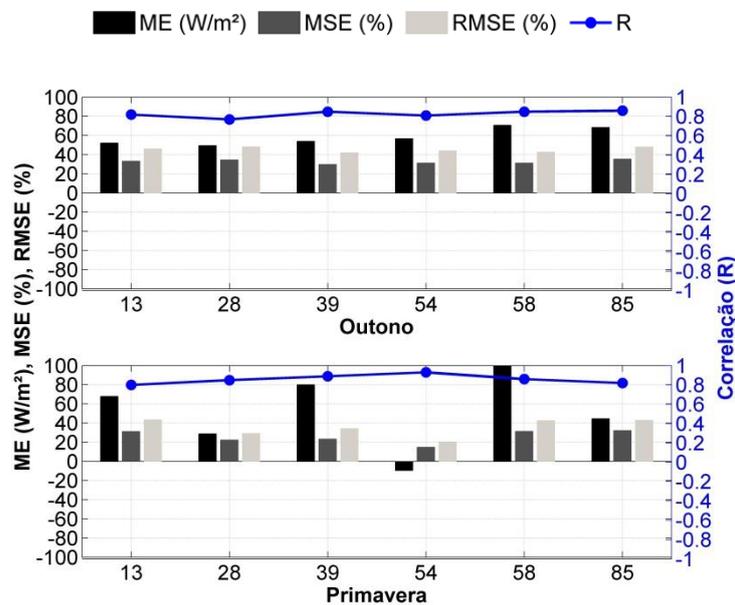


Figura 5.19 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2011).

Na Figura 5.20, têm-se o diagrama linear e de dispersão para a estação 58, mostrando que o modelo tende a superestimar a irradiação para todo o período. Os gráficos de dispersão mostram novamente um alto desvio entre os dados medido e estimado, mas com boas correlações. Usando o teste de T-Student, tanto para o outono como para a primavera o modelo não apresentou significância estatística ao nível de 0,05.

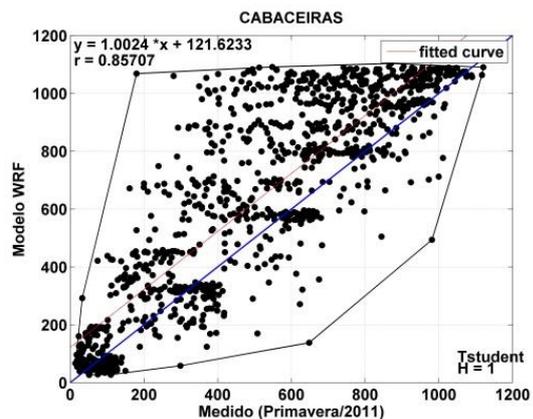
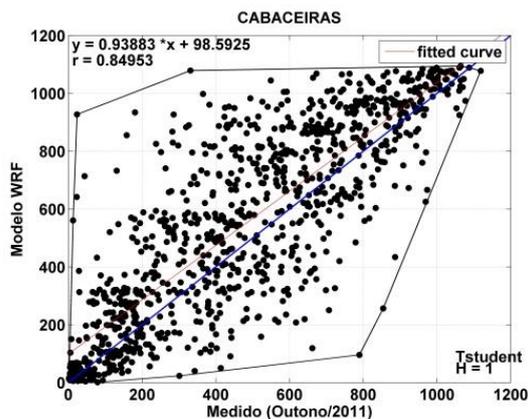
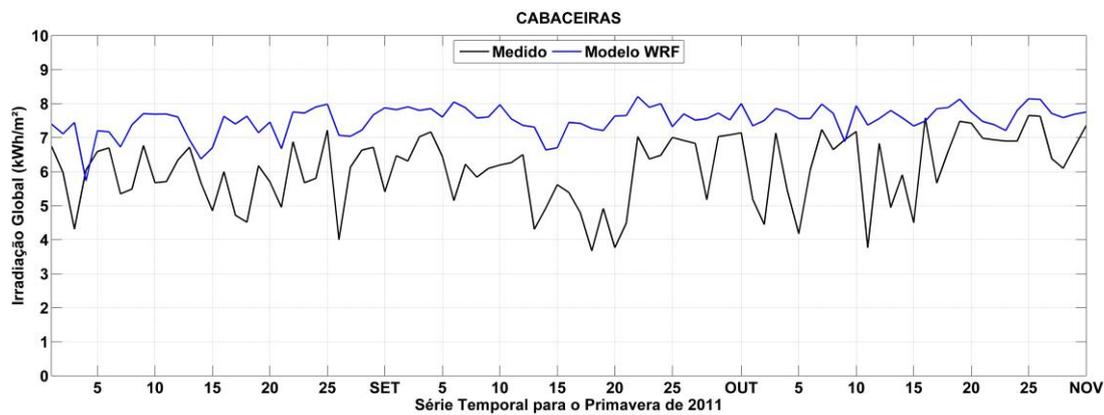
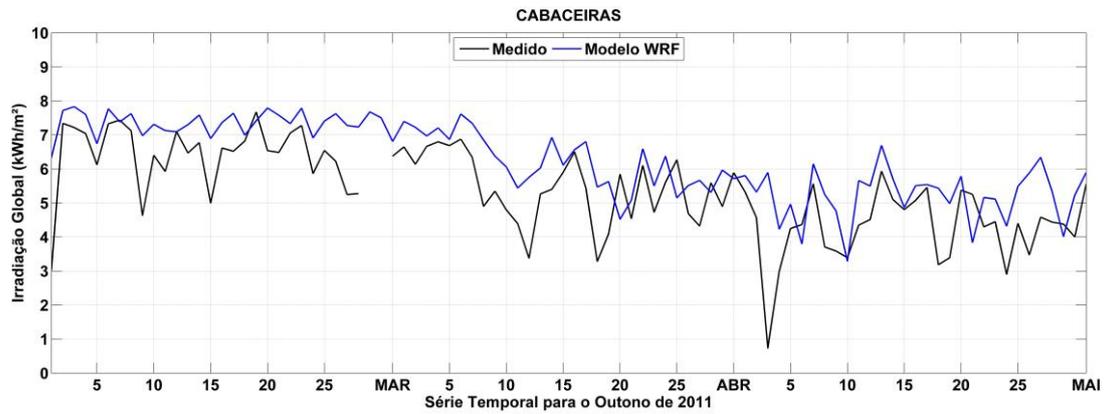


Figura 5.20 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 02 (2011).

Para a região 03, Figura 5.21, têm-se altos valores para *ME*, exceto para as estações 62, 66 e 112 para as duas épocas do ano. Para o *MSE* e *RMSE*

verificam-se médios para altos valores para a primavera e para o outono os valores de *RMSE* foram superiores a 40% e *MSE* em torno de 30%. Observa-se que, apesar de o modelo apresentar um *ME* alto e um *RMSE* expressivo em algumas estações, principalmente no outono, os coeficientes de correlação indicam bons níveis de correlação entre previsões e observações, em torno de 0,70.

Para a região o modelo apresentou altos índices em quase todas as estações nas duas épocas do ano, mostrando que o modelo teve um alto erro sistemático. Observa-se que, em geral, na região 03 o modelo claramente superestima os níveis de irradiação solar. Para a estação 23 na primavera, não houve dados medidos, ou os dados não foram aprovados no controle de qualidade.

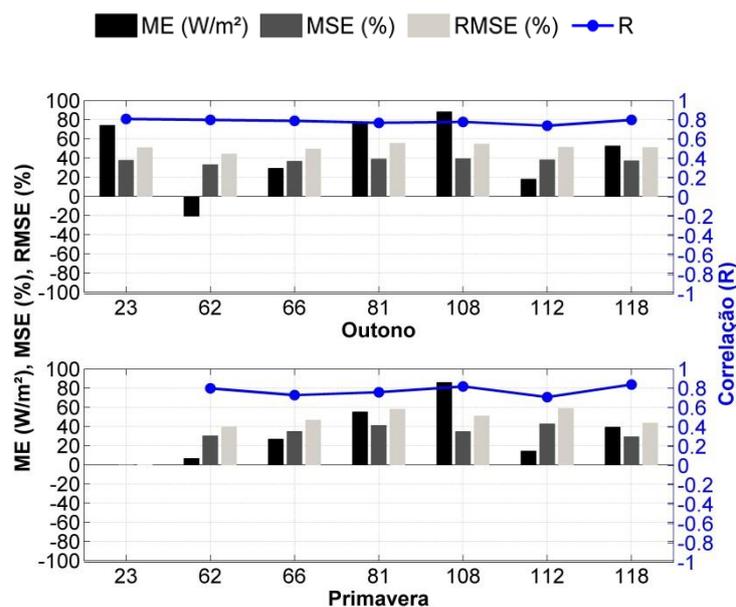


Figura 5.21 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2011).

Observa-se o diagrama linear e de dispersão para a estação 108, na Figura 5.22, mostrando que o modelo tende a superestimar a irradiação para o outono e primavera, mas com uma boa concordância entre os dados medidos e estimados, principalmente para a primavera. Os gráficos de dispersão

mostram-se novamente com alto desvio entre os dados medido e estimado, o que acarreta altos valores nos índices estatísticos, mas com uma boa correlação.

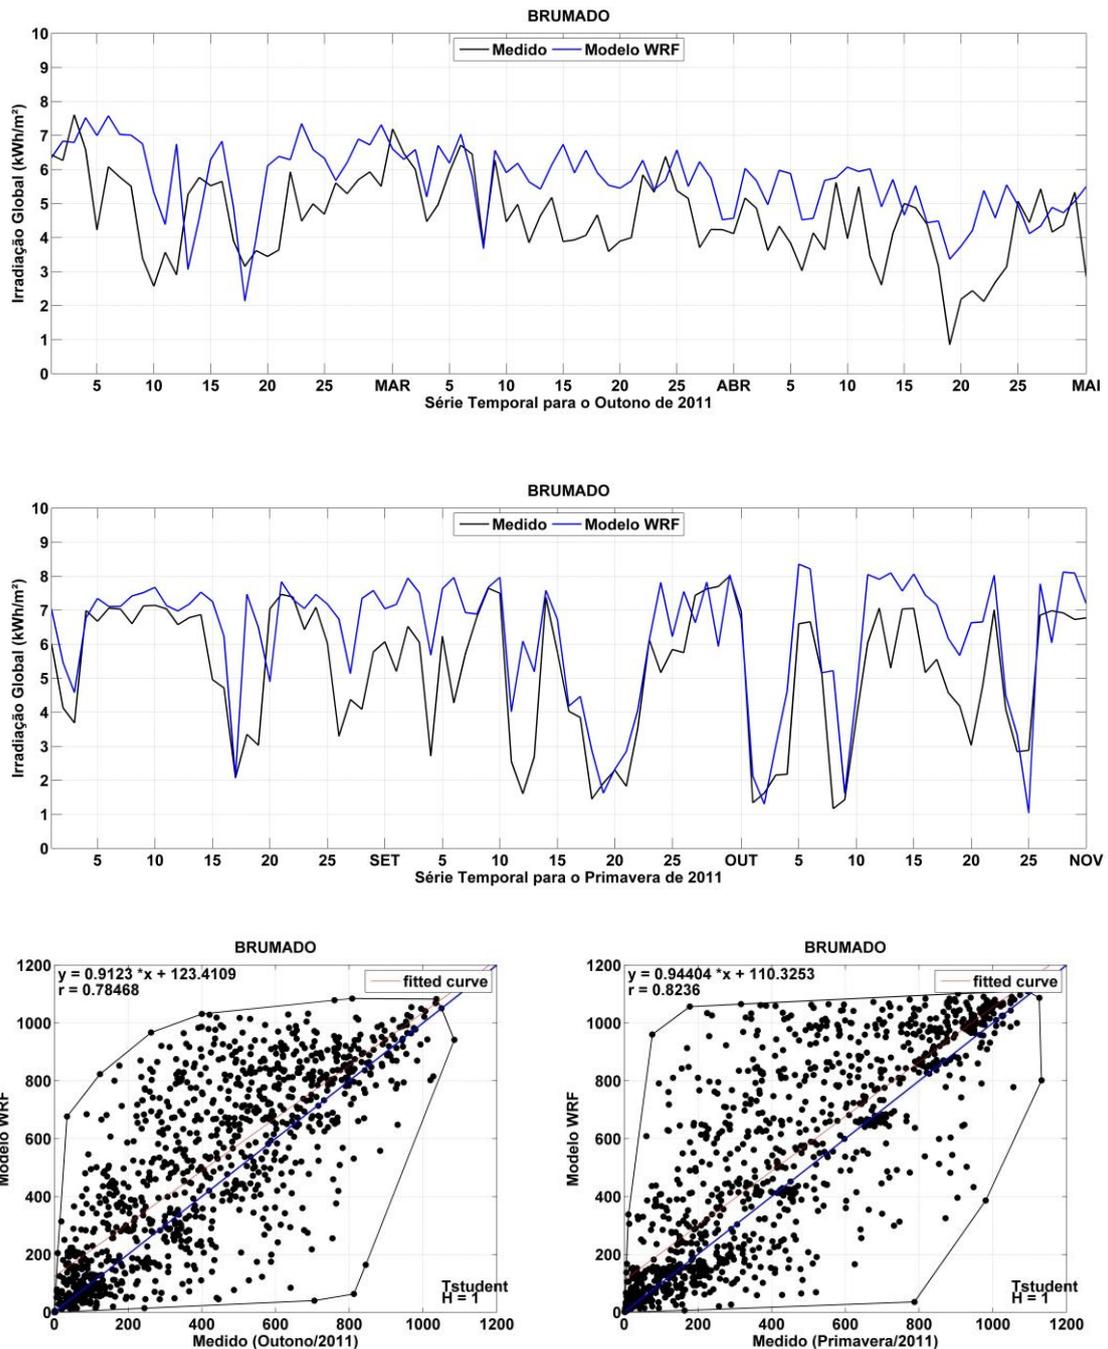


Figura 5.22 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 03 (2011).

Na região 04, Figura 5.23, mostra-se valores altos de *MSE* e *RMSE* para o outono e razoáveis valores de *ME*, exceto para a estação 63. Para a primavera têm-se os maiores valores de *ME* acima de 100 W/m² em quase todas as estações, o mesmo verificado no ano de 2009 e 2010, embora tenha apresentado médios valores de *MSE* e *RMSE*. Na região 04 o modelo teve maior dificuldade em simular a irradiação solar, ou seja, o modelo apresentou um alto erro para essa região, o que foi verificado nos três anos de estudo desta pesquisa. Para a estação 22 na primavera, não houve dados medidos, ou os dados não foram aprovados no controle de qualidade.

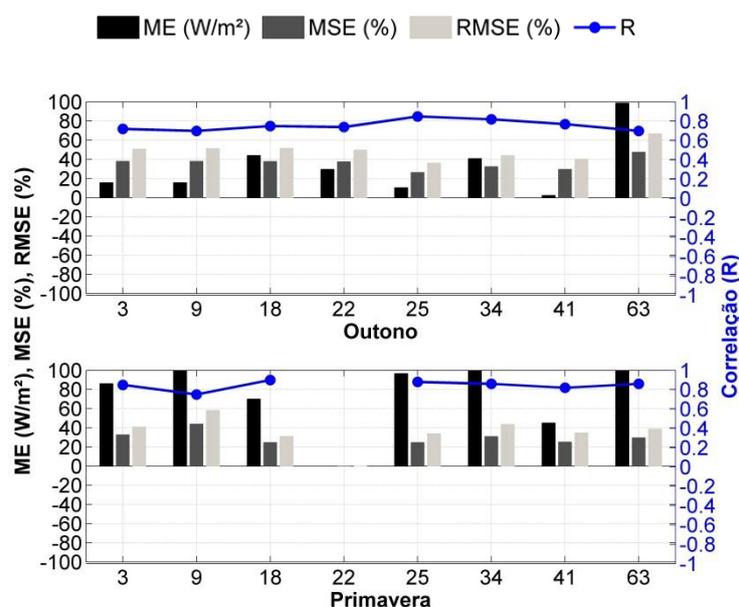


Figura 5.23 – Diagrama dos índices estatísticos para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2011).

Na Figura 5.24 observam-se o diagrama linear e a dispersão para a estação 63, mostrando que o modelo tende a superestimar, de maneira significativa, a irradiação para a primavera e outono, mas com uma boa concordância. Apesar dos altos erros o modelo segue a tendência dos dados medidos.

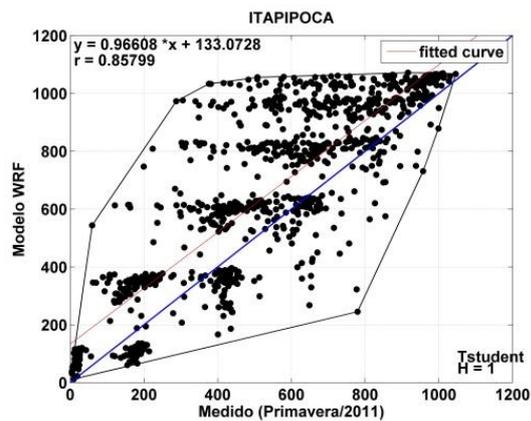
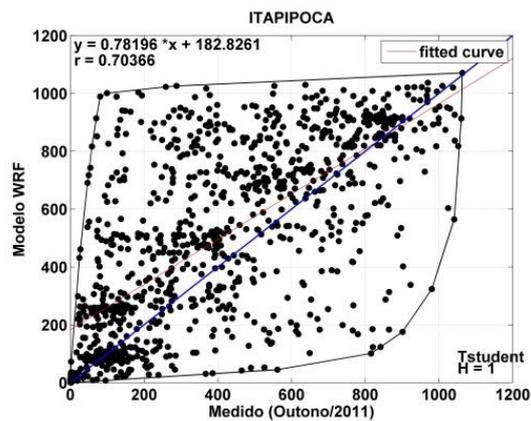
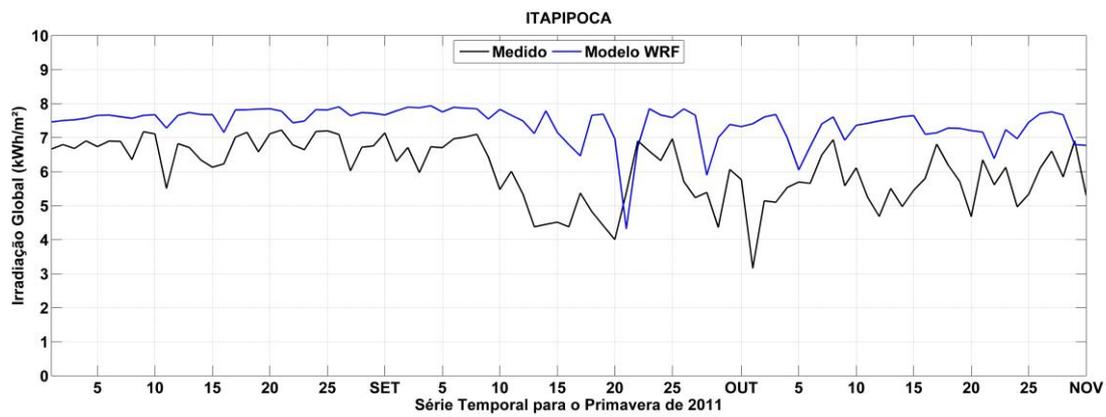
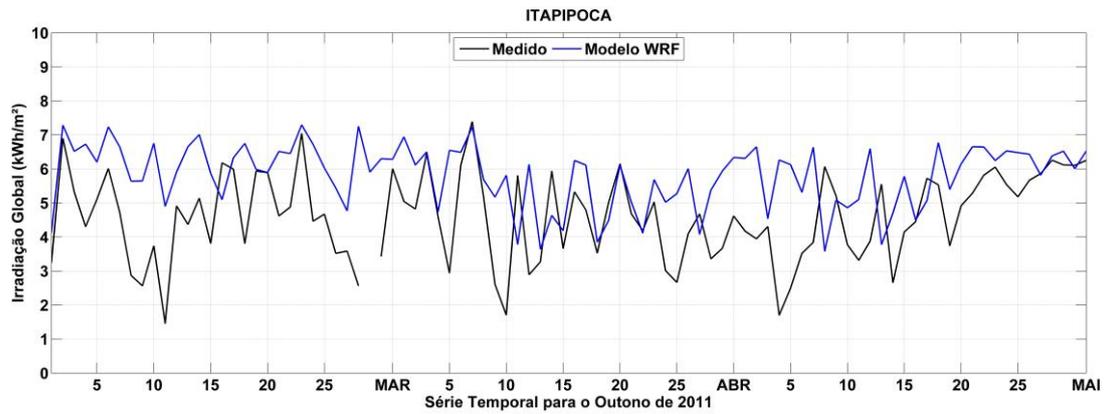


Figura 5.24 – Diagramas de dispersão (médias horárias) e linear (totais diárias), para as previsões de radiação solar incidente do modelo WRF para a Região 04 (2011).

5.2. Análise Espacial da Irradiação Solar para 2009, 2010 e 2011

No intuito de analisar espacialmente e qualitativamente as saídas de irradiação solar do modelo WRF, primeiro usou-se os dados medidos de irradiação para as 110 estações, espacialmente distribuída em todo o NEB, (como mostrado na Figura 4.8) e usou-se a técnica de interpolação por krigagem. Os dados foram arranjados por médias para o outono e primavera dos anos em questão.

Todo tipo de interpolação apresenta incertezas. Como o intuito desta seção é apenas uma comparação qualitativa entre os dados medidos e estimados pelo modelo, foram separados apenas os dados dos pontos de grade do modelo WRF mais próximos às 110 estações usadas nessa pesquisa, como representativos destas, onde também foi empregada a técnica de interpolação com a mesma quantidade de pontos usada para a interpolação dos dados medidos. Com isso, foram construídos mapas de irradiação solar com os dados medidos e estimados e os erros referentes à interpolação dos dados foram incluídos nas duas amostras.

Os mapas da irradiação solar e da diferença da irradiação solar entre os dados medidos e estimados para os anos de 2009, 2010 e 2011 são mostrados nas figuras abaixo, para o outono e primavera.

O conhecimento da irradiação solar e sua variabilidade espaço-temporal são essenciais para o planejamento energético e operação eficiente de projetos que utilizam o recurso solar. Nesse contexto, foram elaborados mapas de irradiação solar para o NEB, em todos os anos em estudo.

As Figuras 5.25 a 5.27 mostram a distribuição espacial da média sazonal da irradiação solar, para os dados medido e estimado para 2009, 2010 e 2011. Observa-se claramente que a distribuição da radiação solar incidente apresenta variações sazonais, ou seja, são submetidas às condições climáticas locais. De modo geral, no período de outono percebe-se um regime relativamente baixo de radiação solar. Este comportamento é percebido devido principalmente aos efeitos da ZCIT, que é caracterizada por movimentos

ascendentes, baixas pressões à superfície, nebulosidade e chuvas abundantes (FERREIRA, 1996), principalmente no Norte do NEB. No período da primavera, a ZCIT está posicionada mais ao Norte do equador, e conseqüentemente, maior quantidade de radiação solar incidente é observada na região.

Embora no final da primavera (novembro) a radiação solar incidente seja alta na região, o setor Sul do NEB, que cobre praticamente todo o Leste da Bahia, teve redução significativa da radiação solar. Esta redução está possivelmente relacionada à Zona de Convergência do Atlântico Sul (ZCAS) e a passagem de sistemas frontais e seus resquícios. Estes sistemas contribuem na intensificação da convecção local nos meses da primavera (e no verão), principalmente. Já no setor Norte e Nordeste do NEB notaram-se altos valores de radiação solar. Ainda nas figuras, para todos os anos em estudo, observa-se uma boa concordância entre os dados medidos e estimados; porém mostra-se que o modelo tende a superestimar a irradiação solar, em todos os anos, principalmente para a primavera. Os anos de 2009 e 2011, para o outono, foram considerados anos chuvosos, porém com distribuição espacial irregular e com chuvas menos intensas no ano de 2011, ou seja, a irradiação solar para o outono em 2009 foi menos intensa que para o ano de 2011. Já para a primavera, nos três anos em estudo, foram considerados períodos secos na região.

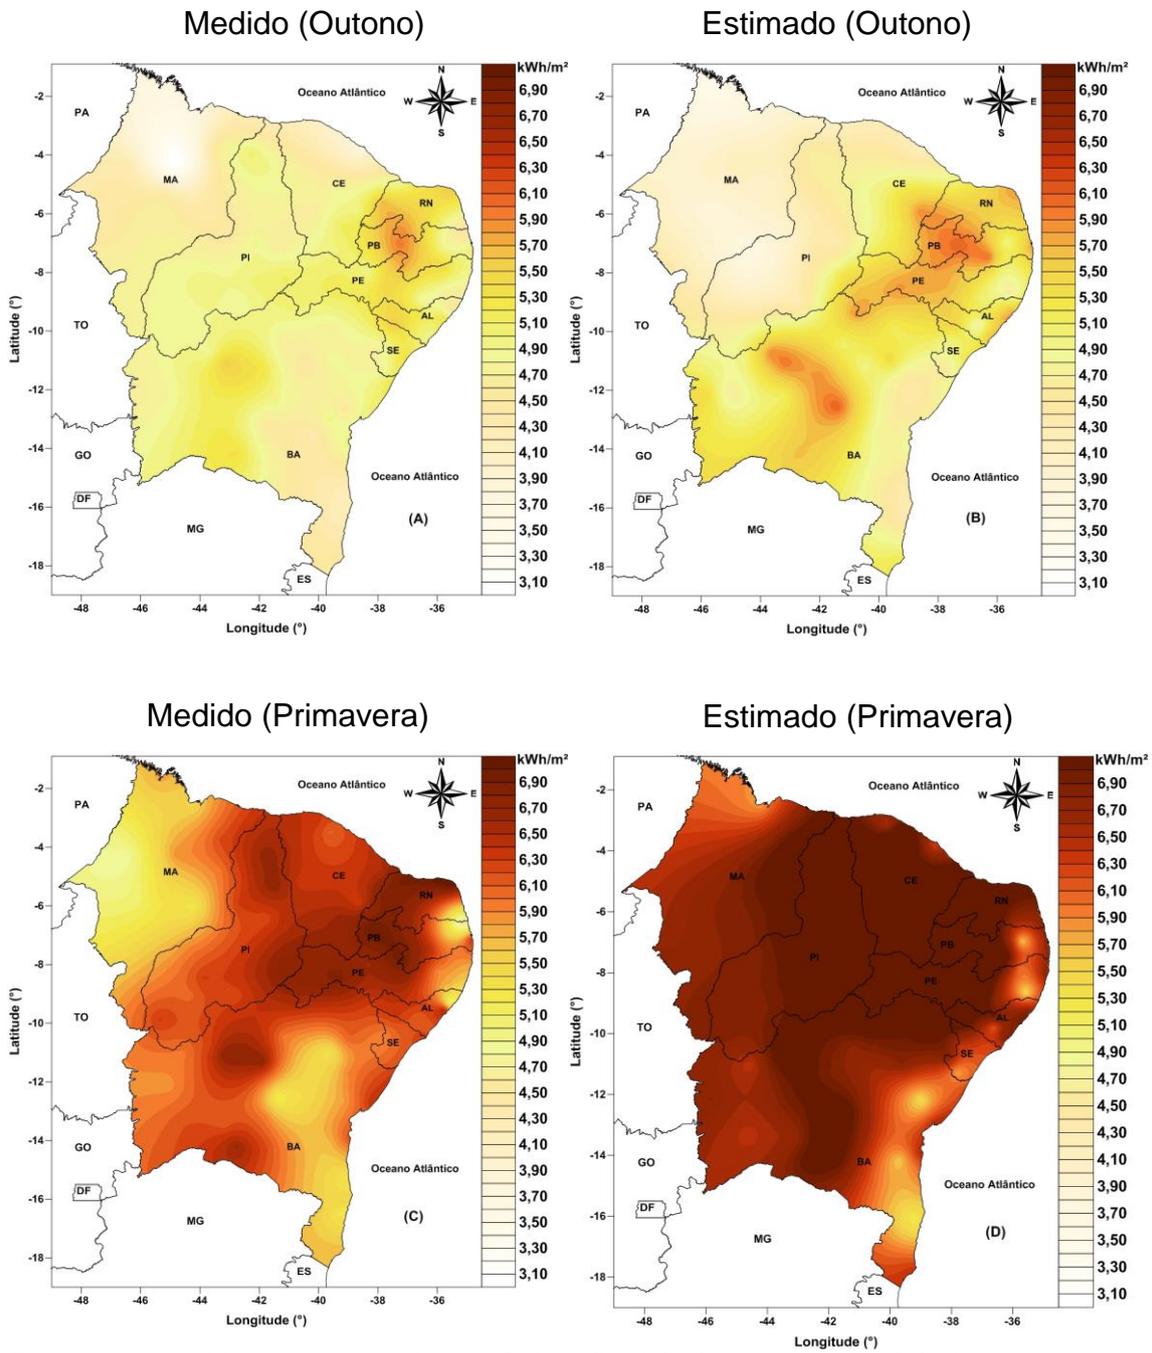


Figura 5.25 – Mapas da Irradiação Solar, (kWh/m²), para 2009. (A) dados medidos para o outono, (B) dados estimados para o outono, (C) dados medidos para a primavera e (D) dados estimados para a primavera.

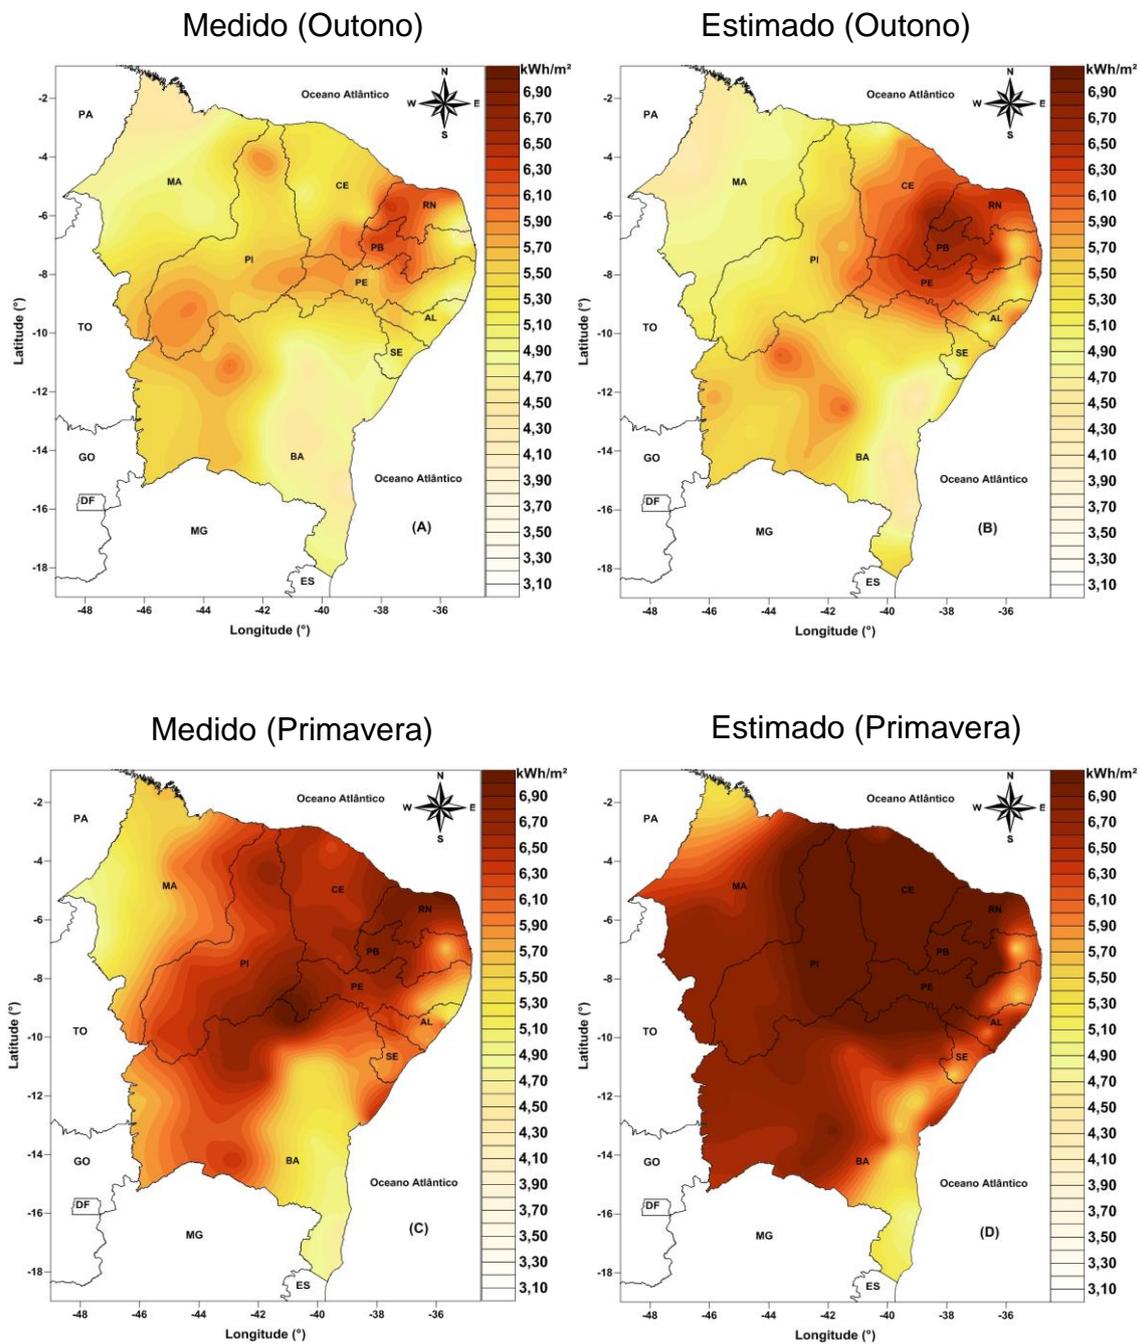


Figura 5.26 – Mapas da Irradiação Solar, (kWh/m²), para 2010. (A) dados medidos para o outono, (B) dados estimados para o outono, (C) dados medidos para a primavera e (D) dados estimados para a primavera.

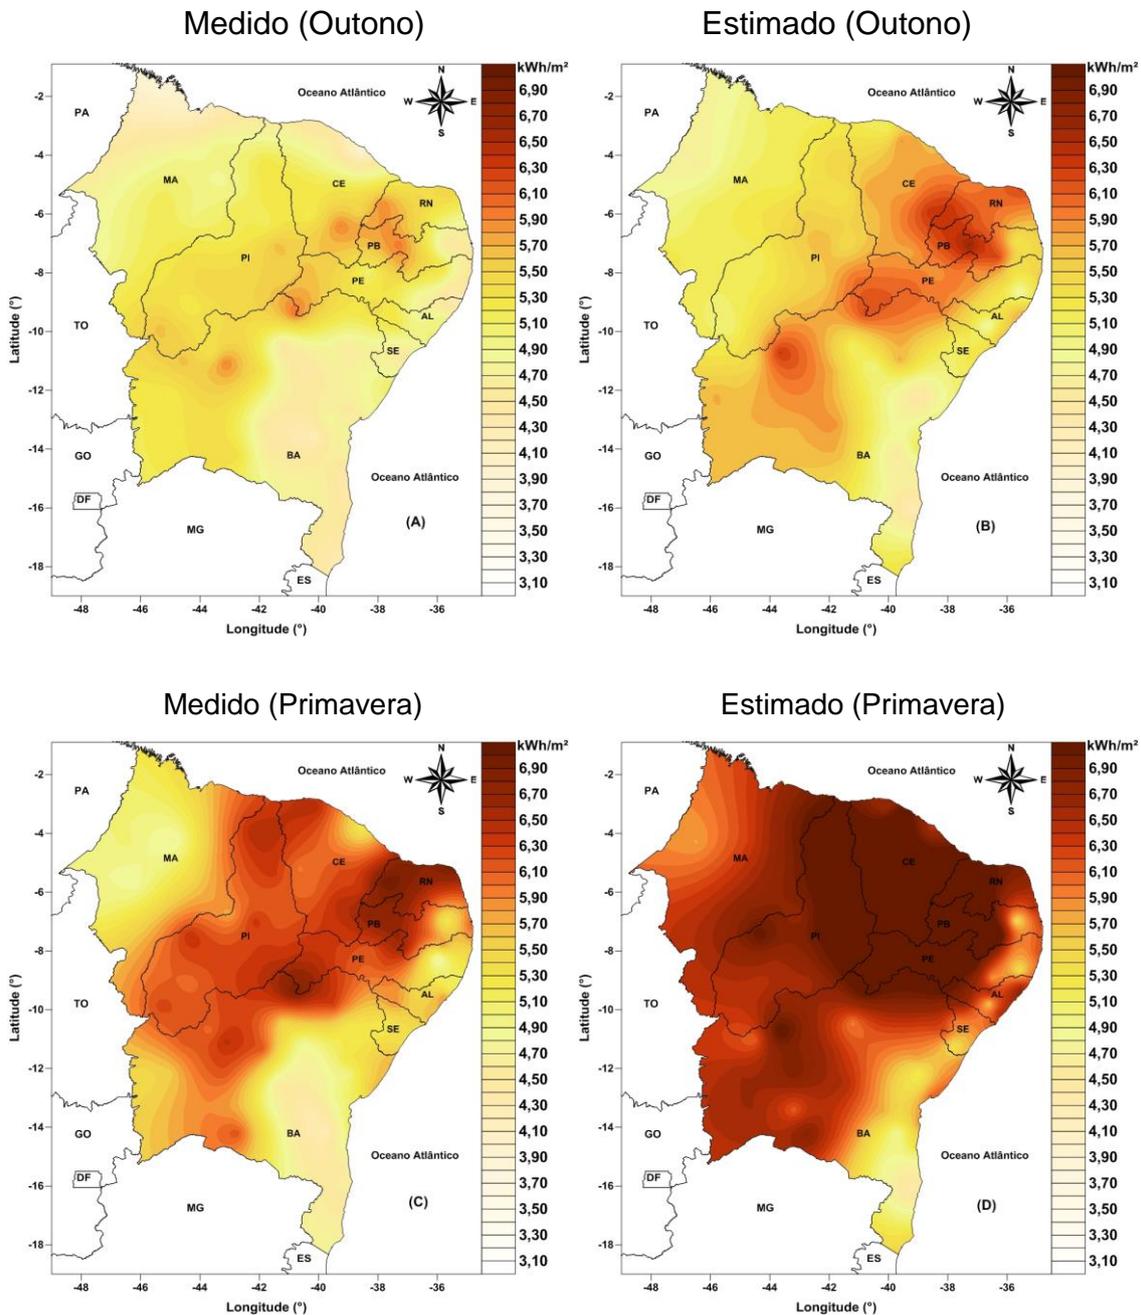


Figura 5.27 – Mapas da Irradiação Solar, (kWh/m²), para 2011. (A) dados medidos para o outono, (B) dados estimados para o outono, (C) dados medidos para a primavera e (D) dados estimados para a primavera.

Nas Figuras 5.28 e 5.29 têm-se os mapas da diferença entre os dados medidos e estimados pelo WRF para 2009, onde se verifica para o outono que o modelo superestima a irradiação solar em todo o Sertão do Nordeste. Nos estados do Piauí e Maranhão o modelo subestima, porém existe uma região no Maranhão

onde o modelo superestima. Isto acontece provavelmente devido à má qualidade dos dados medidos localizado nesta estação. Para a primavera o modelo tende a superestimar a irradiação solar em toda a região. Para o ano de 2009 o modelo foi capaz de seguir a tendência dos dados medidos, porém observa-se que o modelo apresenta um alto viés.

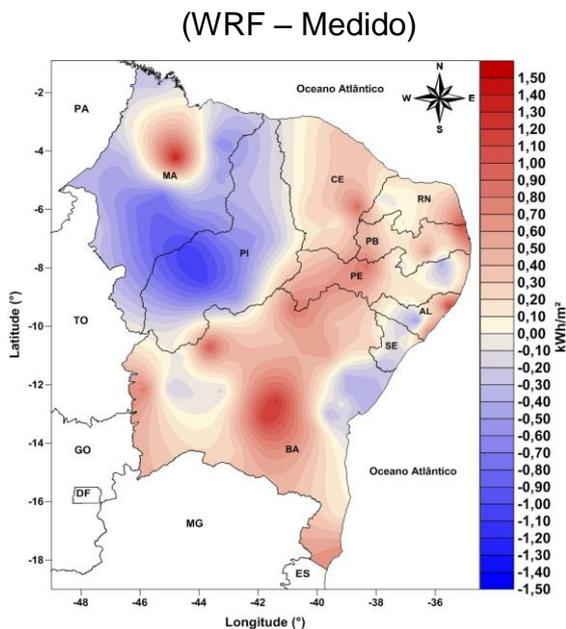


Figura 5.28 – Mapas de diferença de irradiação solar (kWh/m²) entre os dados medidos e as saídas do modelo WRF para o outono de 2009.

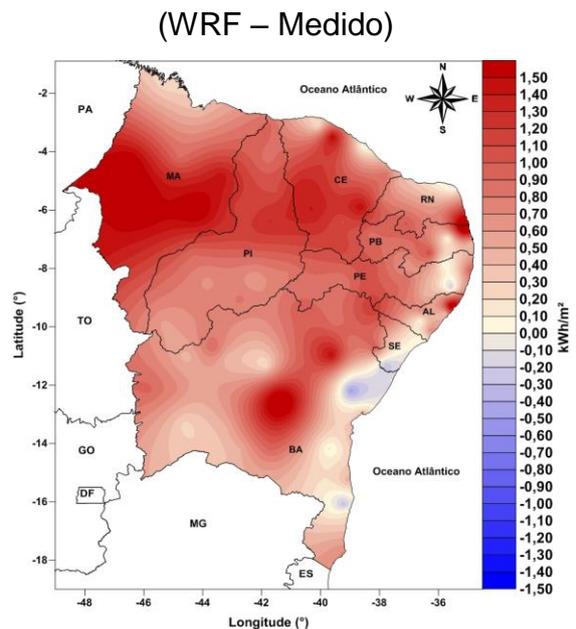


Figura 5.29 – Mapas de diferença de irradiação solar (kWh/m²) entre os dados medidos e as saídas do modelo WRF para a primavera de 2009.

Nas Figuras 5.30 e 5.31 estão os mapas da diferença da radiação solar incidente para o outono e primavera de 2010, onde têm-se uma configuração parecida com o apresentado para o ano de 2009, no qual o modelo superestima de maneira significativa toda a região do NEB para a primavera. Para o outono o modelo superestima a irradiação solar em todo o Sertão do Nordeste. Nos estados do Piauí e Maranhão e no Leste e Oeste da Bahia o modelo subestima. Para o ano de 2010 o modelo novamente foi capaz de seguir a tendência dos dados medidos, porém com um alto erro sistemático.

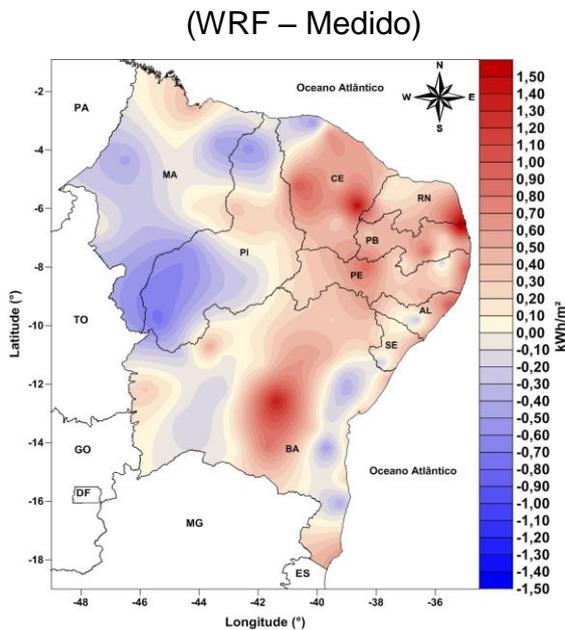


Figura 5.30 – Mapas de diferença de irradiação solar (kWh/m²) entre os dados medidos e as saídas do modelo WRF para o outono de 2010.

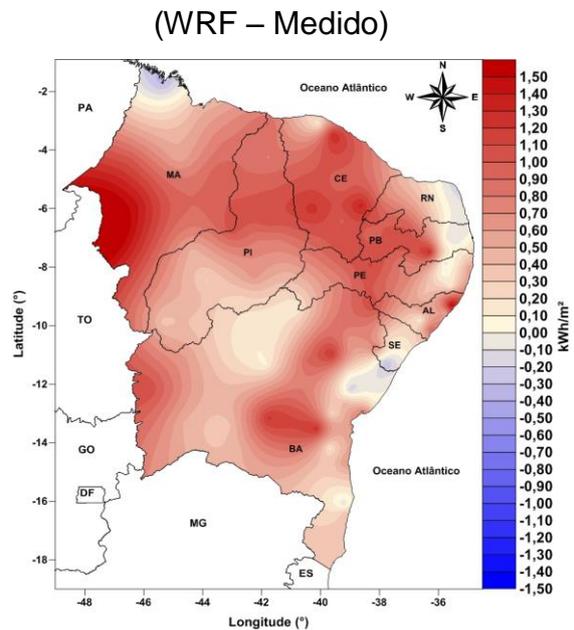


Figura 5.31 – Mapas de diferença de irradiação solar (kWh/m²) entre os dados medidos e as saídas do modelo WRF para a primavera de 2010.

Nas Figuras 5.32 e 5.33 têm-se os mapas da diferença entre os dados medidos e estimados pelo WRF para 2011, onde verifica-se que tanto para o outono como para a primavera o modelo superestima a irradiação solar em todo o NEB, exceto no Sul do Piauí onde o modelo subestima.

Para os anos de 2009, 2010 e 2011 o modelo foi capaz de seguir a tendência dos dados medidos; porém observa-se que o modelo apresenta um alto viés. Com isso fica evidente que o modelo WRF é capaz de prever/simular a irradiação solar na região; porém é necessária a utilização de uma técnica estatística de refinamento, como o emprego de Regressão Linear Múltipla ou Redes Neurais Artificiais para a diminuição desses erros inerentes no modelo.

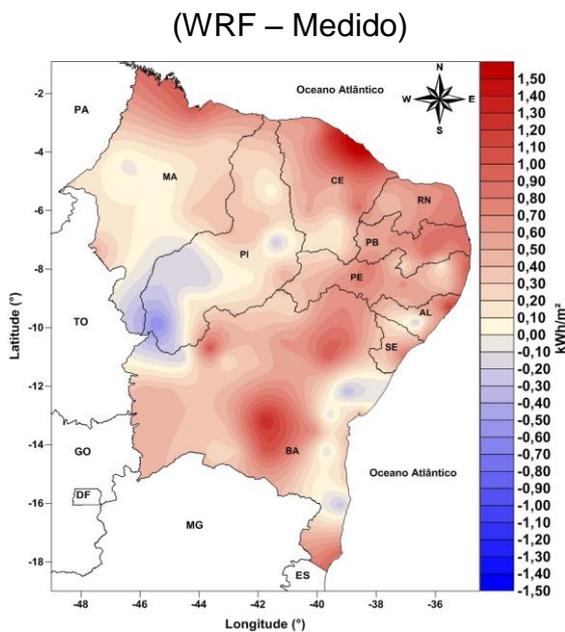


Figura 5.32 – Mapas de diferença de irradiação solar (kWh/m^2) entre os dados medidos e as saídas do modelo WRF para o outono de 2011.

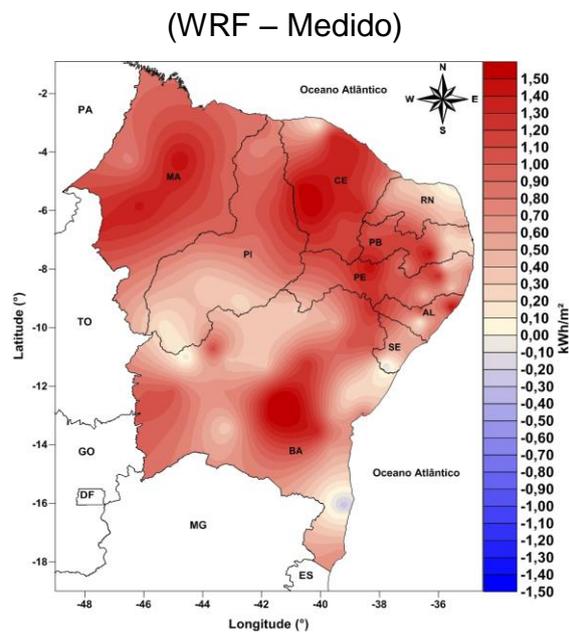


Figura 5.33 – Mapas de diferença de irradiação solar (kWh/m^2) entre os dados medidos e as saídas do modelo WRF para a primavera de 2011.

Em geral, para os três anos, enfatiza-se a tendência de o modelo sistematicamente superestimar a radiação solar incidente, devido possivelmente, a uma deficiência na modelagem dos processos que atenuam a radiação solar. A ocorrência de maior superestimava para os dias com menores valores de observações, também poderia estar ligada a uma geração deficiente da cobertura de nuvens em dias nublados, pelo modelo WRF.

Vale mencionar que os modelos meteorológicos são empregados para a geração de campos de variáveis, não sendo objetivada a previsão pontual. As previsões para um dado ponto de grade representam uma condição média prevista para uma área extensa. Assim ao compararmos as previsões com observações, os erros avaliados não representam apenas o erro do procedimento de cálculo do modelo, mas também englobam os erros inerentes a comparar um campo com um ponto específico dentro do campo, bem como os erros decorrentes de imprecisões nas condições iniciais e de contorno empregadas pelo modelo WRF.

O processo de refinamento busca, justamente, corrigir o valor do campo para o ponto de interesse e remover erros sistemáticos decorrentes de imprecisões existentes no modelo e nos dados por ele empregados, ou seja, a redução desses erros de previsão de radiação é o objetivo almejado pelo ajuste dos modelos de RNA e RLM. Como exposto acima, nas próximas seções serão analisado os modelos de RLM e RNA, onde foram aplicadas as saídas do modelo para cada uma das 110 estações usadas nesta pesquisa.

6 RESULTADOS: PARTE III

Neste capítulo são mostrados os resultados obtidos pela comparação entre previsões e medidas de irradiação solar. Em uma primeira parte são apresentadas as previsões dos modelos de RNAs, onde são avaliadas em experimentos utilizando diversos conjuntos de preditores, sendo apontado um conjunto mínimo de preditores e neurônios que leva a uma previsão satisfatória. Previsões obtidas a partir do modelo de RLM são obtidas usando as coberturas de nuvens do WRF e o modelo de *ClearSky*. A avaliação do desempenho do modelo WRF e dos demais modelos ajustados, em cada estação do ano, são discutidas. Na última seção, uma avaliação de previsões realizada com diferentes antecedências é apresentada. Em cada seção são discutidos os resultados pelos novos modelos frente ao WRF e pela RNAs frente ao modelo de RLM.

6.1. Experimentos para a Seleção de Preditores

Foi realizado um estudo para identificar as variáveis meteorológicas necessárias para simular a irradiação solar para todo o NEB, (por regiões homogêneas e as estações subdivididas para validação dos resultados). Nas Figuras 6.1 a 6.4 são mostrados os resultados dos testes com diferentes combinações de variáveis utilizadas para alimentar a RNA para as quatro regiões homogêneas definidas anteriormente. Tanto as RNAs como o RLM foram desenvolvidos utilizando para o treinamento os períodos de outono e primavera dos anos de 2009 e 2010 e deixando o ano de 2011 para os testes de validação dos modelos. Os experimentos e as variáveis usadas foram descritos na seção 3.7.1. Para o procedimento de seleção dos preditores foram utilizados dados do outono e primavera dos anos de 2009 e 2010 e uma topologia padrão com uma camada oculta com o número de neurônios variando de 8 a 22, e função de ativação tangente hiperbólica.

Todos os experimentos foram realizados 100 vezes para cada configuração, variando os neurônios de dois em dois (8, 10, 12, 14, 16, 18, 20, 22), onde foram calculados os seus índices estatísticos. A rede correspondente ao experimento que gerou os melhores resultados no treinamento foi salva, obtendo oito redes, uma para cada configuração de neurônios ocultos, ou seja, foram salvas apenas as RNAs que apresentaram os menores erros. Esse procedimento foi adotado, pois, em cada treinamento, os pesos de cada neurônio são inicializados aleatoriamente e sofrem sequências de ajustes diferentes, levando a pesos finais diferentes. Eventualmente o treinamento pode ser interrompido com o erro ainda elevado e distante do valor real, acarretando em RNAs ineficientes. Em seguida foi comparada qual a quantidade de neurônios na camada oculta gerou o melhor resultado, obtendo-se assim, uma única RNA para cada estação. No estudo, todas as simulações com as RNAs foram inicializadas após a separação aleatória dos dados para as etapas de treinamento, validação e teste.

O primeiro experimento foi realizado com as mesmas variáveis usadas para o desenvolvimento do modelo RLM. No segundo experimento utilizou-se os preditores definidos como melhores para o modelo Eta por Guarnieri, 2006, substituindo-se o TOA (radiação no topo da atmosfera) pelo modelo de *clearsky*, totalizando oito variáveis. Já no terceiro experimento utilizaram-se as mesmas variáveis do segundo experimento, mas com a inclusão do *dj* (Dia Juliano) e *hour* (hora) para indicar um padrão temporal às redes. Os valores de *RMSE*, bem como o número de neurônios com o qual a rede neural obteve os melhores resultados para cada um dos experimentos são apresentados nas figuras abaixo.

Nas Figuras 6.1 a 6.4 têm-se as estações que compõem as regiões homogêneas 01, 02, 03 e 04, respectivamente, onde nas ordenadas observa-se o *RMSE* (normalizado) e nas abscissas o número de neurônios na camada oculta para os três experimentos. As setas mostram qual a quantidade de neurônios gerou o melhor resultado para cada experimento. Para todas as

estações os experimentos 02 e 03 obtiveram resultados significativamente melhores em comparação com o experimento 01, enquanto o Experimento 03 foi melhor em todas as estações. Não se observou uma diferença significativa em relação à quantidade de neurônios na camada oculta, lembrando que, como os preditores estavam em unidades diferentes, foi necessário a normalização dos mesmos a fim de evitar a influência das diferentes escalas de grandeza.

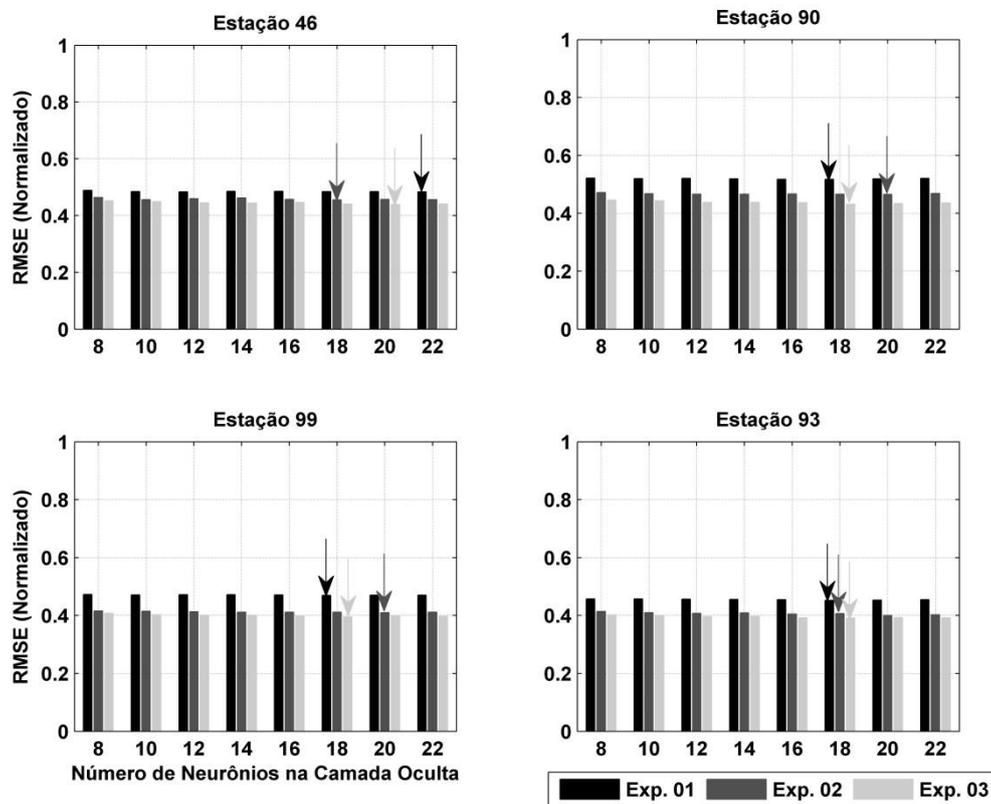


Figura 6.1 – Grupo de preditores para as estações da região homogênea R1.

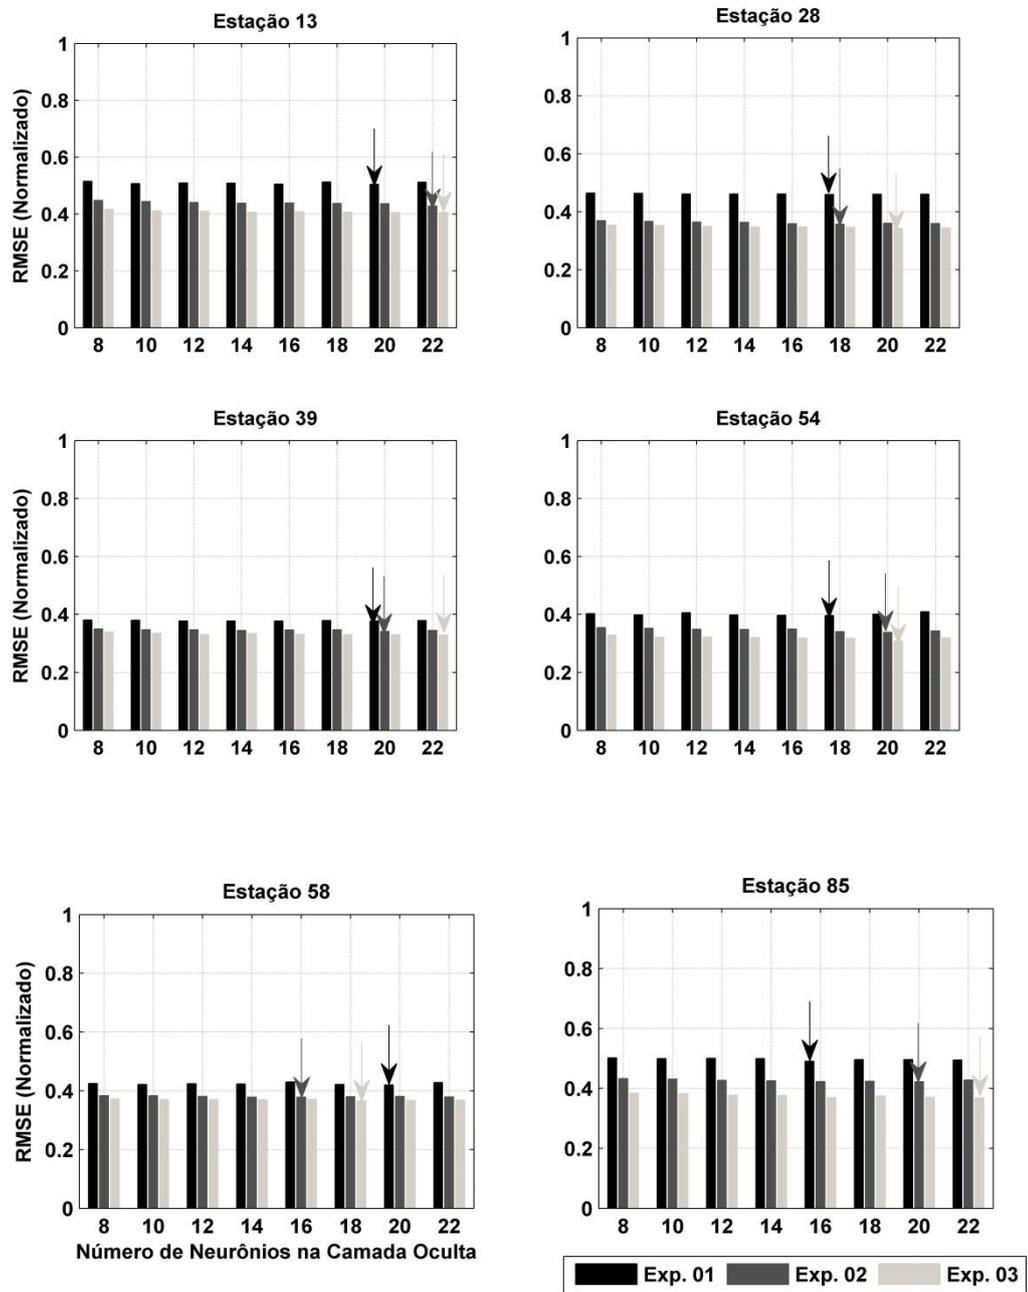


Figura 6.2 – Grupo de preditores para as estações da região homogênea R2.

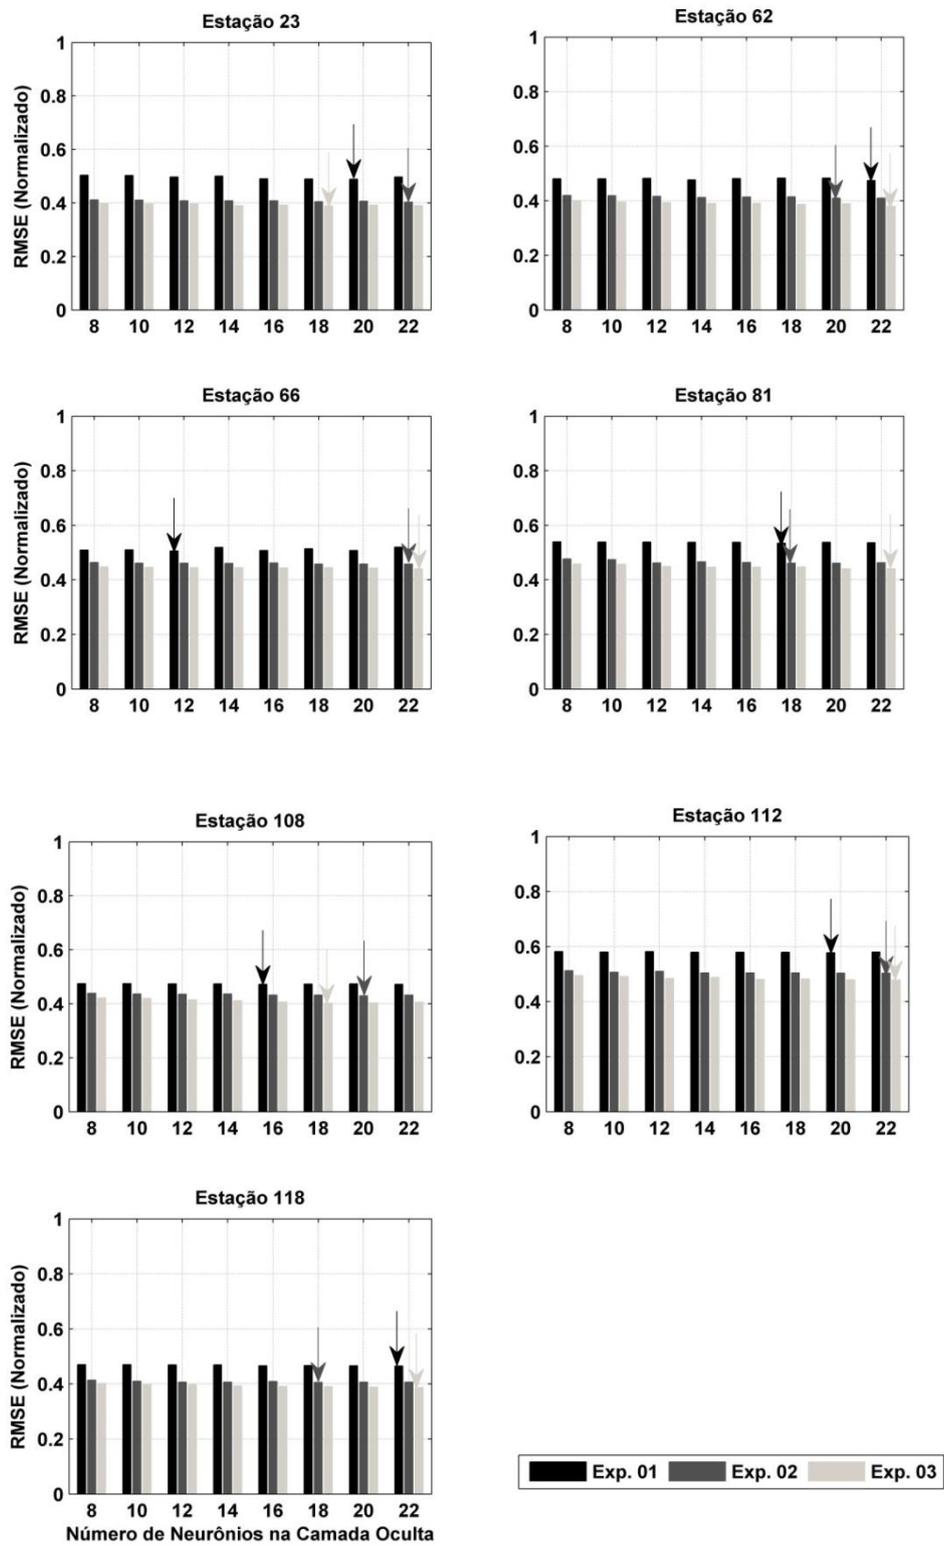


Figura 6.3 – Grupo de preditores para as estações da região homogênea R3.

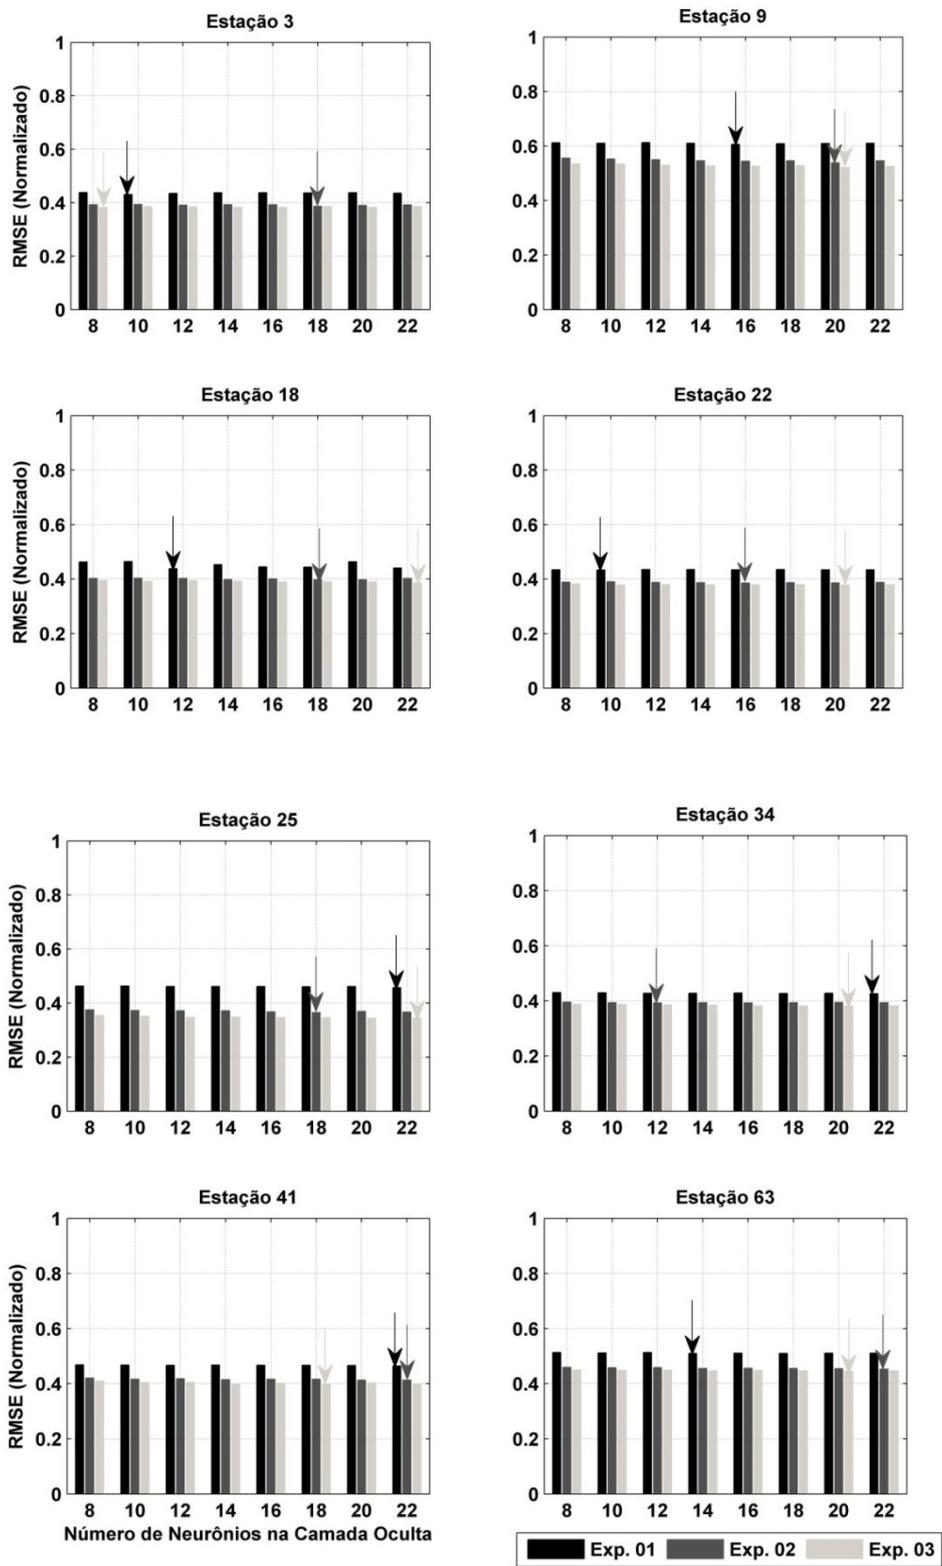


Figura 6.4 – Grupo de preditores para as estações da região homogênea R4.

Na Tabela 6.1, tem-se o *RMSE* e a correlação (*R*) para as estações da R1 para o experimento 03, mostrando que as estações 90, 99 e 93 foram melhores com 18 neurônios na camada oculta, enquanto que a estação 46 foi melhor com 20 neurônios. Os melhores resultados foram encontrados nas estações 99 e 93 com *RMSE* de 0,40 e 0,39, respectivamente em unidades adimensionais. Para a avaliação das previsões e generalização das RNAs, para a região homogênea 01 foi testada a configuração de rede desenvolvida para a estação 93, pois apresentou os melhores resultados, com 18 neurônios na camada oculta.

Tabela 6.1 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 01.

ESTAÇÕES	46	90	99	93
NEURÔNIOS OCULTOS	20	18	18	18
RMSE	0,44	0,43	0,40	0,39
R	0,90	0,90	0,92	0,92

Na Tabela 6.2, tem-se o *RMSE* e a correlação para as estações da R2, mostrando que as melhores redes foram encontradas nas estações 54, 39, 28, 58, 85 e 13. Com 20 neurônios, na camada oculta, a estação 54 obteve valores de 0,31 e 0,95 de *RMSE* e *R*, enquanto que a estação 13 com 22 neurônios teve o pior desempenho nesse grupo. Os melhores resultados foram encontrados nas estações 54, 39 e 28 com *RMSE* de 0,31, 0,33 e 0,37, respectivamente. Para a avaliação das previsões e generalização das RNAs para a região homogênea 02 foi testada a configuração de rede desenvolvida para a estação 54 e 28 que apresentou os melhores resultados com 20 neurônios na camada oculta. Embora não houvesse uma diferença significativa para as demais estações, exceto na estação 13 onde o *RMSE* é de 0,41, para diminuir o tempo computacional de treinamento das RNAs foram usados para todas as estações da R2 apenas 20 neurônios na camada oculta.

Tabela 6.2 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 02.

ESTAÇÕES	13	28	39	54	58	85
NEURÔNIOS OCULTOS	22	20	22	20	18	22
RMSE	0,41	0,34	0,33	0,31	0,37	0,37
R	0,91	0,94	0,94	0,95	0,93	0,93

Na próxima Tabela, tem-se o *RMSE* e a correlação para as estações da R3, mostrando que as melhores estações foram encontradas em 62 e 23 com 22 neurônios na camada oculta, nas estações 23 e 108 também obteve-se ótimos valores, porém com 18 neurônios na camada oculta. O melhor resultado foi na estação 62 com valores de *RMSE* de 0,38 e *R* de 0,90, enquanto que a estação 112 com 22 neurônios teve o pior desempenho nesse grupo. Para a avaliação das previsões e generalização das RNAs para a região homogênea 03 possivelmente será testada a configuração de rede desenvolvida para as estações 62, 66, 81, 112 e 118, com 22 neurônios na camada oculta, embora não houvesse uma diferença significativa entre as demais estações. Portanto para diminuir o tempo computacional de treinamento das RNAs foram usados para a R3 22 neurônios na camada oculta em todas as estações do grupo.

Tabela 6.3 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 03.

ESTAÇÕES	23	62	66	81	108	112	118
NEURÔNIOS OCULTOS	18	22	22	22	18	22	22
RMSE	0,39	0,38	0,44	0,44	0,40	0,48	0,39
R	0,92	0,93	0,90	0,90	0,92	0,88	0,92

Na Tabela 6.4, tem-se o *RMSE* e a correlação para as estações da R4, mostrando que as melhores estações foram encontradas em 25, 3, 22, 34, 38, 18, 41, 63 e 9. Com 22 neurônios na camada oculta, a estação 54 obteve os melhores resultados com valores de 0,34 e 0,94 de *RMSE* e *R*, enquanto que a estação 9, com 20 neurônios, teve o pior desempenho nesse grupo. Os melhores resultados foram encontrados com 22 e 20 neurônios, porém na estação 3 o melhor resultado foi encontrado com apenas 8 neurônios. Para a

avaliação das previsões e generalização das RNAs para a região homogênea 04 optou-se por usar a configuração de rede desenvolvida para as estações 63, 34, 22 e 9, pois apresentaram os melhores resultados com 20 neurônios na camada oculta. Enquanto duas estações foram melhores com 20, inclusive a estação 25 onde se observa os melhores resultados, embora não tenha sido verificada uma diferença significativa entre as demais estações, portanto para diminuir o tempo computacional de treinamento das RNAs foram usados para a R4, 20 neurônios na camada oculta em todas as estações do grupo.

Tabela 6.4 – Grupo de preditores do experimento 03 e o número de neurônios ocultos que apresentou os melhores resultados para a Região 04.

ESTAÇÕES	3	9	18	22	25	34	41	63
NEURÔNIOS OCULTOS	8	20	22	20	22	20	18	20
RMSE	0,38	0,52	0,39	0,38	0,34	0,38	0,40	0,44
R	0,92	0,85	0,92	0,93	0,94	0,92	0,92	0,90

Analisando os preditores do experimento 03 onde foram definidas 10 variáveis como as mais significativas, a importância da umidade relativa pode ser explicada pela elevada correlação negativa com o preditando observado, a irradiação solar, possivelmente devido ao fato de que em dias nublados e chuvosos a umidade relativa é elevada e a incidência de radiação é baixa, enquanto que em dias de céu claro ocorre o contrário. As demais variáveis, apesar de não terem apresentado correlação direta com a irradiação solar para a série completa de dados, podem possuir alguma relação com a radiação solar incidente para dias com condições de tempo particulares, dias de céu claro ou dias nublados. Assim essas variáveis podem conter informações que, combinadas, consigam explicar grande parte da variação da irradiação solar. Pode-se explicar a importância da variável *clearsky* pelo fato de que esta possui alta correlação com a radiação incidente em dias de céu claro. A variável água precipitável deve apresentar elevados valores em dias chuvosos, quando a radiação solar incidente é reduzida. A temperatura em superfície correlaciona-se com a radiação solar incidente em dias de céu limpo, uma vez

que o aquecimento da camada de ar próxima à superfície é uma resposta da radiação solar incidente. Quanto ao vento zonal em superfície $u10$, embora presente nos preditores segundo Guarnieri, 2006, é difícil supor uma ligação entre $u10$ e a irradiação solar. Possivelmente algum fator climático que influencia as condições de tempo e a incidência de radiação, também está vinculado a maiores ou menores intensidades de vento zonal.

Observa-se que a inclusão das variáveis hora e dia juliano trouxeram uma melhora em todas as estações de todas as regiões homogêneas, em algumas estações sendo mais significativas que em outras. Uma explicação possível é que com a inclusão dessas variáveis foi incluído o ciclo horário e anual no treinamento das redes neurais artificiais, ou seja, um padrão temporal que poderia estar relacionado ao ciclo diário de erro sistemático do modelo WRF.

É importante mencionar que as RNAs dependem da qualidade e quantidade dos exemplos apresentados durante o treinamento para que possa extrair padrões corretos e representativos do comportamento e relação entre as variáveis. Sendo assim, por apresentar um desempenho satisfatório, os 10 preditores do Experimento 03 foram adotados como preditores para as próximas análises.

6.2. Definição da Arquitetura das RNAs

Nas Tabelas 6.5 a 6.8 encontram-se os vários testes de arquiteturas utilizando as variáveis selecionadas no tópico anterior. São apresentados os coeficientes de correlação R e o $RMSE$ para as estações subdividas para as quatro regiões homogêneas para os anos de 2009 e 2010. Da mesma forma que anteriormente, cada arquitetura foi treinada 100 vezes, para cada conjunto de neurônios. Em seguida foram comparadas as configurações de uma e duas camadas ocultas, a primeira variando os neurônios de 8 a 22, como usado anteriormente. Foram salvas apenas as RNAs que obtiveram os melhores

resultados e comparadas com a configuração com duas camadas ocultas, configuração (RNA-10-[20-10]-1), descrita na metodologia desta pesquisa.

Em todas as estações não houve uma diferença significativas entre as duas configurações. Nas regiões homogêneas 03 e 04, Tabelas 6.7 e 6.8, em todas as estações os índices foram iguais, enquanto na Tabela 6.5, onde têm-se as estações que compõem a região homogênea 01, apenas na estação 99 o teste com duas camadas ocultas teve um desempenho levemente superior, pois o *RMSE* apresentou valor de 0,39 contra 0,40 com uma camada oculta. Na Tabela 6.6, para a região 02, novamente não observa-se uma diferença significativa entre as duas configurações, exceto nas estações 12 e 39, onde há uma ligeira vantagem para a configuração com duas camadas ocultas.

Apesar de não apresentarem diferenças significativas, optou-se pela configuração com duas camadas ocultas por apresentar um desempenho levemente superior e um menor tempo computacional em relação à configuração de uma camada oculta, variando os neurônios de 8 a 22.

Isto ocorre devido ao fato de que em cada estação, a configuração com uma camada oculta precisa ser executada 100 vezes para cada quantidade de neurônios ocultos, 8, 10, 12, 14, 16, 18, 20 e 22, para que seja então selecionada a RNA que levou ao menor erro. Enquanto que na segunda opção, com duas camadas ocultas, a rede foi treinada apenas 100 vezes para cada estação, pois só foi testada uma configuração de neurônios ocultos, sendo escolhida a RNA que apresentou os menores erros entre as 100. Isto explica porque o tempo computacional será menor se for usada a configuração com duas camadas ocultas.

Na Figura 6.5 tem-se a arquitetura da RNA usada no restante desta pesquisa, sendo a mesma para todas as regiões homogêneas, com 10 preditores: *dj*, *hour*, *clearsky*, r_{h2} , t_2 , *u10*, *clflo*, *clfmi*, *clfhi* e *pw*, com duas camadas ocultas e função de transferência do tipo tangente hiperbólica nas duas camadas ocultas e na camada de saída. Com a definição dos preditores e arquitetura da RNA foi configurada uma rede para cada uma das 110 estações usadas nesta

pesquisa. Nas próximas seções é apresentada uma análise mais detalhada das previsões obtidas e uma confrontação com os parâmetros de desempenho das demais previsões, WRF e RLM.

Tabela 6.5 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 01.

Estações	46		90		99		93	
Neurônios	[20]	[20-10]	[18]	[20-10]	[18]	[20-10]	[18]	[20-10]
RMSE	0,44	0,44	0,43	0,43	0,40	0,39	0,39	0,39
r	0,90	0,90	0,90	0,90	0,92	0,92	0,92	0,92

Tabela 6.6 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 02.

Estações	12		28		39		54		58		85	
Neurônios	[22]	[20-10]	[20]	[20-10]	[22]	[20-10]	[20]	[20-10]	[18]	[20-10]	[22]	[20-10]
RMSE	0,41	0,40	0,34	0,34	0,33	0,33	0,31	0,31	0,37	0,37	0,37	0,37
r	0,91	0,92	0,94	0,94	0,94	0,95	0,95	0,95	0,93	0,93	0,93	0,93

Tabela 6.7 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 03.

Estações	23		62		66		81		108		112		118	
Neurônios	[18]	[20-10]	[22]	[20-10]	[22]	[20-10]	[22]	[20-10]	[18]	[20-10]	[22]	[20-10]	[22]	[20-10]
RMSE	0,39	0,39	0,38	0,38	0,44	0,44	0,44	0,44	0,4	0,4	0,48	0,48	0,39	0,39
r	0,92	0,92	0,93	0,93	0,9	0,9	0,9	0,9	0,92	0,92	0,88	0,88	0,92	0,92

Tabela 6.8 – Comparação das duas configurações das RNAs com uma e duas camadas ocultas para Região 04.

Estações	3		9		18		22		25		34		41		63	
Neurônios	[8]	[20-10]	[20]	[20-10]	[22]	[20-10]	[20]	[20-10]	[22]	[20-10]	[20]	[20-10]	[18]	[20-10]	[20]	[20-10]
RMSE	0,38	0,38	0,52	0,52	0,39	0,39	0,38	0,38	0,34	0,34	0,38	0,38	0,4	0,4	0,44	0,44
r	0,92	0,92	0,85	0,85	0,92	0,92	0,93	0,93	0,94	0,94	0,92	0,92	0,92	0,92	0,9	0,9

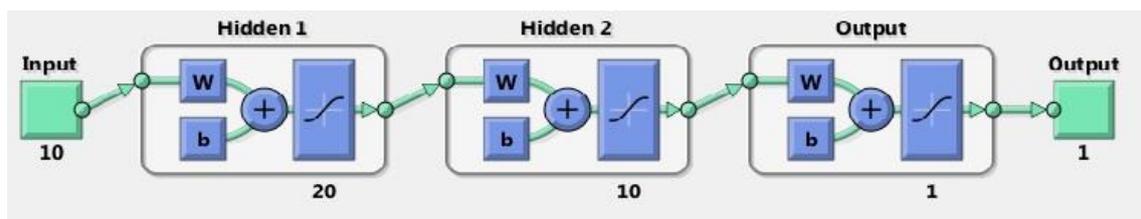


Figura 6.5 – Arquitetura da RNA para as quatro regiões homogêneas.

6.3. Avaliação das Previsões

Nesta seção são apresentados os resultados das previsões usando os modelos WRF, RLM e RNA, por regiões homogêneas para os anos de 2009 e 2010. São apresentados sete índices estatísticos. Os índices foram calculados a partir do conjunto dos dados identificado como Teste – dados não utilizados no treinamento ou na validação da RNA. Uma vez que foram definidos os preditores, a arquitetura final e a configuração da RNA pode-se dizer que a metodologia de refinamento estatístico da irradiação solar por RNAs está completa. Sua aplicação se deu a princípio sobre as 110 estações utilizadas nesta pesquisa, divididas em quatro regiões, para as quais foram realizados 100 treinamentos em cada e foi salva a RNA com o menor erro entre as 100. Devido à grande quantidade de informações, são apresentadas nas tabelas apenas as estações subdivididas anteriormente. Nos gráficos de dispersão são apresentados apenas os padrões mais significativos das previsões efetuadas pelos diferentes modelos.

6.3.1. Região Homogênea 01

Com a finalidade de comparar visualmente os resultados encontrados nas subseções anteriores, os parâmetros de avaliação das previsões analisadas são apresentados na Figura 6.6 para R1. São mostrados os valores de *ME*, *MSE*, *RMSE* e *R* para as previsões dos modelos WRF, RLM e RNA.

Verifica-se, nos gráficos da Figura 6.6, que qualquer das previsões derivadas dos modelos de RLM e RNA promovem a remoção do viés, redução do *MSE* e *RMSE* e aumento dos coeficientes de correlação, para todas as estações da R1. Como observado na figura, as previsões dos modelos de RLM e RNA possuem desempenhos superiores aos observados pelo modelo WRF, embora

o modelo RNA apresenta um desempenho superior ao modelo de RLM. Apesar de o modelo de RLM mostrar uma redução nos valores de *MSE* e *RMSE* e aumento no coeficiente de correlação, o modelo tende a subestimar os dados medidos ao apresentar valores de *ME* superiores aos do modelo WRF. Por fim, os modelos de RLM e RNA apresentaram um resultado significativo para a redução do erro sistemático do modelo WRF, porém o modelo RNA foi superior aos resultados da RLM.

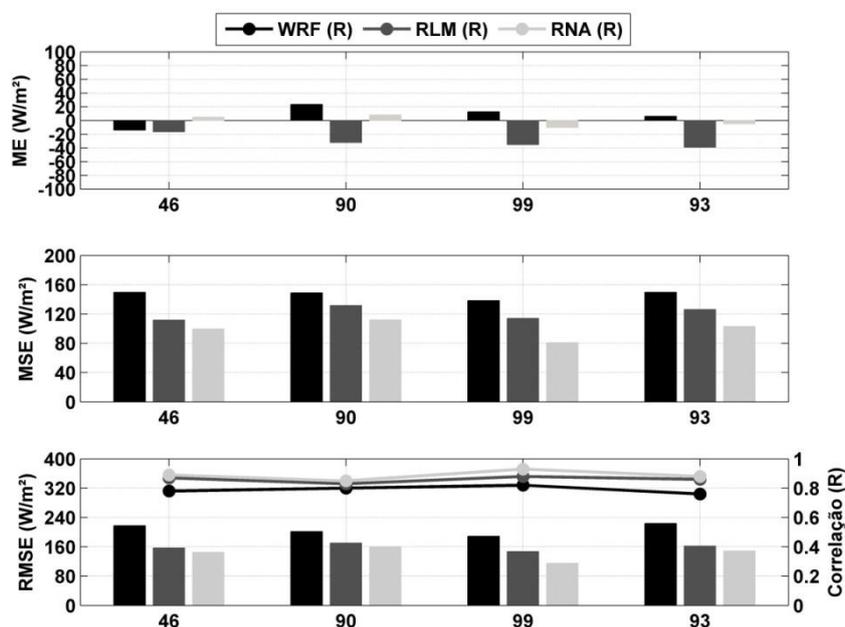


Figura 6.6 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 01).

Na Tabela 6.9, tem-se um resumo estatístico dos índices calculados para R1. É realizada uma comparação quantitativa que evidencia a superioridade do modelo RNA frente ao modelo de RLM e de ambos frente ao modelo WRF levando a previsões com viés bastante reduzido, como verificado na Tabela 6.9, exceto para o modelo de RLM que apresentar valores de viés maiores que o modelo WRF, mas com valores reduzidos para os demais índices. Portanto ambos os ajustes, apresentaram valores de *RMSE* menores. Enquanto o

RMSE(%) para o modelo WRF é de aproximadamente 45%, 40%, 37% e 43% para as estações de A do Gurgeia, S R de Cassia, B J da Lapa e Irecê, respectivamente, os novos modelos apresentaram valores da ordem de 33%, 34%, 29% e 31% para RLM e 30%, 32%, 22% e 28% para RNA, nas referidas estações, revelando uma redução significativa nos erros apresentados pela irradiação solar do modelo WRF.

Tabela 6.9 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 01. Em destaque estão os melhores índices.

Estações	A DO GURGEIA			S R DE CASSIA		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	-14,07	-16,44	4,64	23,48	-32,30	7,92
MSE	149,59	111,82	99,61	148,88	131,63	111,92
MSE(%)	31,21	23,33	20,78	29,65	26,22	22,29
RMSE	217,75	156,74	145,06	201,39	170,22	160,47
RMSE(%)	45,42	32,70	30,26	40,11	33,90	31,96
r	0,78	0,87	0,89	0,80	0,83	0,85
R ²	0,61	0,76	0,79	0,64	0,69	0,72
Estações	B J DA LAPA			IRECÊ		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	12,55	-35,27	-10,24	6,18	-39,07	-4,73
MSE	138,22	114,04	80,88	149,50	126,17	103,00
MSE(%)	27,06	22,33	15,84	28,57	24,11	19,69
RMSE	188,58	146,88	114,87	223,71	161,84	148,32
RMSE(%)	36,93	28,76	22,49	42,76	30,93	28,35
r	0,82	0,88	0,93	0,76	0,86	0,88
R ²	0,67	0,78	0,86	0,57	0,75	0,78

6.3.2. Região Homogênea 02

Verifica-se na Figura 6.7 que o desempenho da RNA apresentou uma melhora significativa e superior ao dos modelos de RLM em todas as estações da R2. Os coeficientes de correlação e os erros médios para RLM e RNA

apresentaram uma diferença significativa. Observa-se que o modelo de regressão tende a subestimar os dados medidos.

Apesar de o uso de RNA proporcionar ganhos sobre o modelo RLM, ambos os modelos apresentaram coeficiente da ordem de 0,80 em todas as estações analisadas e proporcionaram uma redução dos erros médios frente às previsões do modelo WRF.

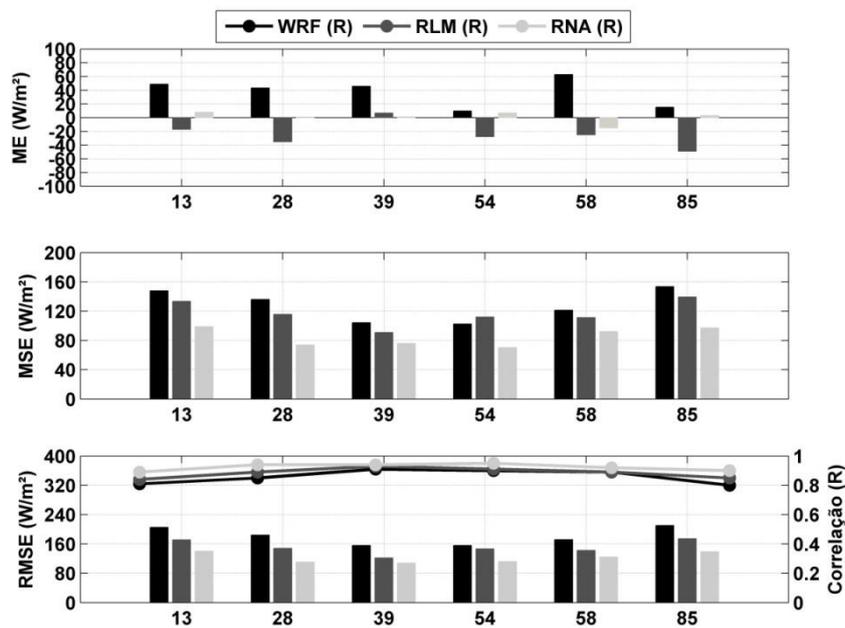


Figura 6.7 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 02).

Analisando a Tabela 6.10 em termos de *ME* observa-se uma redução significativa para o modelo de RNA frente aos demais, enquanto que o modelo de RLM obteve uma redução em algumas estações e um aumento do viés em outras, como verificado, nas estações de Calcanhar e Aracajú. Porém, em geral, ambos os modelos apresentaram erros muito baixos em comparação com as simulações do modelo WRF. Os valores de *RMSE*(%) do modelo RNA são bastante reduzidos em relação ao demais modelos. Assim, os novos

modelos, principalmente para o modelo RNA, levam a previsões com erros reduzidos, superando as previsões originais do WRF.

Tabela 6.10 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 02.

Estações	MACEIÓ			MOSSORÓ		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	48,57	-17,03	7,69	43,08	-35,24	0,93
MSE	147,77	133,36	98,89	135,87	115,60	73,87
MSE(%)	29,57	26,68	19,79	24,61	20,94	13,38
RMSE	205,31	171,17	140,35	183,82	148,11	110,49
RMSE(%)	41,08	34,25	28,08	33,30	26,83	20,02
r	0,81	0,84	0,89	0,85	0,89	0,94
R ²	0,65	0,70	0,80	0,72	0,80	0,88
Estações	CABROBRO			CALCANHAR		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	45,53	6,74	1,15	9,75	-27,91	6,54
MSE	104,23	90,82	75,84	102,54	111,98	70,14
MSE(%)	20,92	18,23	15,22	19,00	20,75	13,00
RMSE	155,83	121,99	107,86	155,61	146,50	112,18
RMSE(%)	31,28	24,49	21,65	28,83	27,14	20,78
r	0,91	0,93	0,94	0,90	0,91	0,95
R ²	0,83	0,87	0,89	0,81	0,83	0,90
Estações	CABACEIRAS			ARACAJÚ		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	62,64	-24,95	-14,73	15,23	-48,98	3,07
MSE	121,34	111,21	92,21	153,58	139,42	97,02
MSE(%)	23,53	21,57	17,88	31,17	28,29	19,69
RMSE	171,88	142,26	124,47	210,44	174,41	138,78
RMSE(%)	33,33	27,59	24,14	42,71	35,40	28,16
r	0,89	0,89	0,92	0,80	0,85	0,90
R ²	0,79	0,80	0,84	0,63	0,72	0,81

6.3.3. Região Homogênea 03

Na Figura 6.8 observa-se que qualquer das previsões derivadas dos modelos de RLM e RNA promovem a remoção do viés, exceto para as estações 62 e

66, onde o modelo de RLM apresentou valores de *ME* maiores. Já para a RNA verifica-se uma redução do *MSE* e *RMSE* e aumento dos coeficientes de correlação, para todas as estações da R3. Como observado na Figura 6.8, as previsões dos modelos de RLM e RNA possuem desempenhos superiores aos observados pelo modelo WRF, embora o modelo RNA apresente um desempenho superior ao modelo de RLM. Apesar de o modelo de RLM mostrar uma redução nos valores de *MSE* e *RMSE* e aumento no coeficiente de correlação o modelo tende a subestimar os dados medidos. Por fim, pode-se dizer que o modelo de RNA apresenta um resultado significativo para a redução do erro sistemático do modelo WRF.

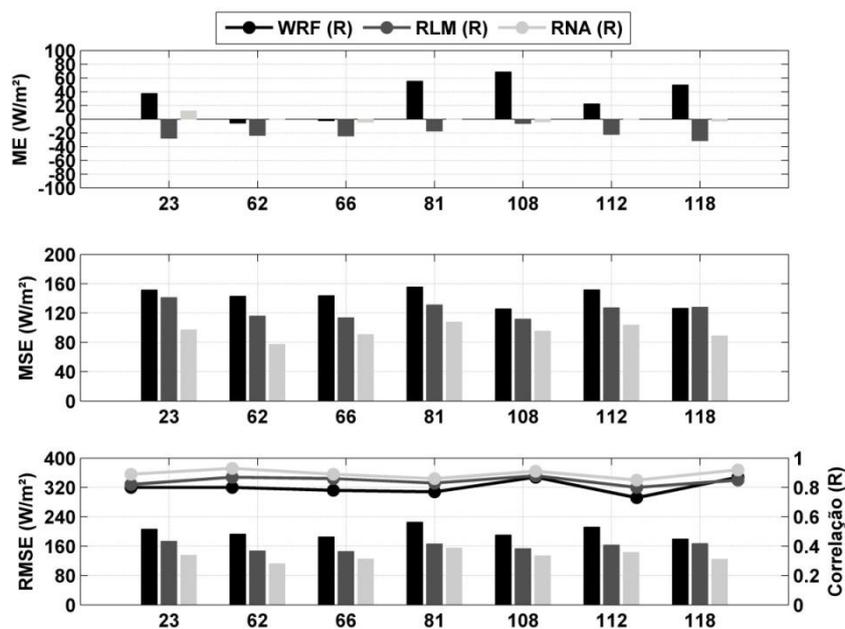


Figura 6.8 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 03).

Na Tabela 6.11 comprova-se a superioridade do modelo de RNA frente ao modelo de RLM e de ambos em relação as saídas do modelo WRF para a irradiação solar. Em geral, os modelos RLM e RNA apresentaram erros muito baixos e correlações mais altas em comparação com as simulações do modelo

WRF. Os valores de $RMSE(\%)$ do modelo RNA são bastante reduzidos em relação ao demais modelos.

Tabela 6.11 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 03.

Estações	CAMP GRANDE			ARAPIRACA		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	37,48	-27,88	11,70	-5,86	-23,72	-0,14
MSE	151,46	141,13	97,12	143,03	115,90	77,13
MSE(%)	31,88	29,70	20,44	31,86	25,82	17,18
RMSE	205,93	173,48	135,15	192,78	146,76	111,82
RMSE(%)	43,34	36,51	28,44	42,94	32,69	24,91
r	0,80	0,82	0,89	0,80	0,87	0,93
R²	0,64	0,67	0,80	0,64	0,76	0,86
Estações	PALMARES			CARAVELAS		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	-2,30	-24,56	-4,34	55,25	-17,37	0,14
MSE	143,81	113,47	90,71	155,43	130,96	107,62
MSE(%)	32,57	25,70	20,54	35,51	29,92	24,59
RMSE	185,14	145,21	124,78	225,22	166,27	154,92
RMSE(%)	41,92	32,88	28,26	51,45	37,98	35,39
r	0,78	0,86	0,89	0,77	0,83	0,86
R²	0,61	0,74	0,80	0,59	0,70	0,74
Estações	BRUMADO			UNA		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	68,72	-6,29	-3,85	22,38	-22,29	-0,35
MSE	125,76	111,66	95,28	151,75	127,19	103,57
MSE(%)	27,93	24,80	21,16	38,62	32,37	26,36
RMSE	190,09	153,38	133,80	211,70	163,13	142,85
RMSE(%)	42,22	34,07	29,72	53,88	41,52	36,36
r	0,87	0,88	0,91	0,73	0,80	0,85
R²	0,75	0,77	0,83	0,53	0,64	0,72
Estações	DEUFINO					
Modelos	WRF	RLM	RNA			
ME	49,88	-31,26	-2,62			
MSE	126,54	127,84	88,67			
MSE(%)	28,15	28,44	19,73			
RMSE	179,66	167,21	124,14			
RMSE(%)	39,96	37,19	27,61			
r	0,87	0,85	0,92			
R²	0,76	0,73	0,85			

6.3.4. Região Homogênea 04

Verifica-se na Figura 6.9 e Tabela 6.12 que o desempenho da RNA apresentou uma melhora significativa em relação aos modelos de RLM, em todas as estações. Os coeficientes de correlação e os erros médios para RLM e RNA apresentaram uma diferença significativa entre si, mas sempre uma redução dos erros médios frente ao WRF. Em todas as estações a RNA apresentou um desempenho bastante superior ao modelo RLM. Observa-se que o modelo de regressão tende a subestimar os dados medidos; além disso, na R4 foi onde o WRF apresentou os maiores erros e os novos modelos conseguiram uma redução mais significativa do erro sistemático, principalmente o modelo de RNA. Apesar de o uso de RNA proporcionar ganho frente a RLM, ambos os modelos apresentaram altos coeficientes de correlação e proporcionaram uma redução dos erros.

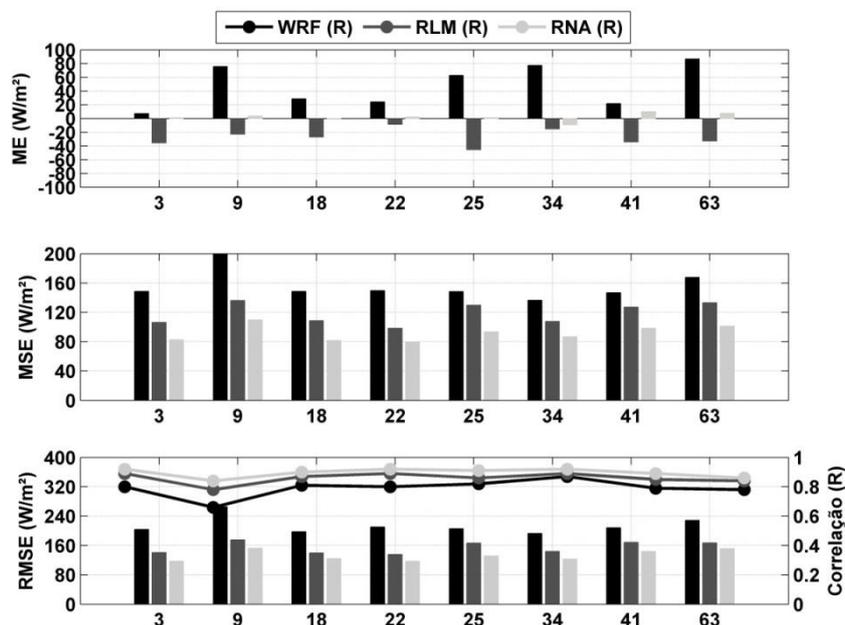


Figura 6.9 – Comparação entre os dados medidos e os modelos WRF, RLM e RNA (Região 04).

Tabela 6.12 – Resumo dos índices estatísticos dos modelos WRF, RLM e RNA para a Região 04.

Estações	CHAPADINHA			ESTREITO		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	7,03	-35,48	1,19	75,74	-22,92	3,62
MSE	148,48	106,44	82,53	199,65	136,10	109,62
MSE(%)	32,48	23,29	18,05	47,11	32,12	25,87
RMSE	203,68	140,66	117,15	265,35	175,35	152,51
RMSE(%)	44,56	30,77	25,63	62,61	41,38	35,99
r	0,80	0,89	0,92	0,66	0,78	0,84
R²	0,65	0,80	0,85	0,44	0,61	0,70
Estações	PARNAÍBA			TERESINA		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	28,59	-27,03	-0,91	24,18	-8,54	2,30
MSE	148,66	108,55	81,52	149,63	98,44	79,76
MSE(%)	30,39	22,19	16,66	33,30	21,91	17,75
RMSE	197,18	140,01	124,43	210,23	135,68	116,93
RMSE(%)	40,30	28,62	25,43	46,79	30,19	26,02
r	0,81	0,87	0,90	0,80	0,89	0,92
R²	0,66	0,76	0,81	0,63	0,79	0,84
Estações	BARBALHA			TAUÁ		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	62,76	-45,26	1,18	77,30	-15,17	-9,04
MSE	148,36	129,68	93,43	136,53	107,50	86,76
MSE(%)	29,08	25,42	18,31	27,85	21,93	17,70
RMSE	205,70	166,74	131,78	192,77	143,79	123,01
RMSE(%)	40,32	32,68	25,83	39,32	29,33	25,09
r	0,82	0,86	0,91	0,87	0,89	0,92
R²	0,68	0,75	0,83	0,75	0,80	0,85
Estações	S J DO PIAUÍ			ITAPIPOCA		
Modelos	WRF	RLM	RNA	WRF	RLM	RNA
ME	21,86	-34,13	10,04	86,58	-32,84	7,43
MSE	146,69	127,13	98,41	167,59	133,15	101,26
MSE(%)	28,99	25,13	19,45	36,51	29,00	22,06
RMSE	208,34	168,34	144,08	228,25	167,09	151,77
RMSE(%)	41,18	33,27	28,48	49,72	36,40	33,06
r	0,79	0,85	0,89	0,78	0,84	0,86
R²	0,63	0,72	0,79	0,61	0,70	0,75

6.3.5. Discussões do Desempenho entre os Modelos

Verificou-se em todas as regiões homogêneas que os modelos de RLM e RNA apresentaram uma redução dos erros médios das saídas originais de irradiação solar do WRF, porém foi verificado um desempenho destacadamente maior pelo uso de RNAs. O desempenho das RNA foi sempre superior em relação ao desempenho do modelo RLM, apresentando sempre uma diferença significativa em *RMSE*, *ME*, *MSE* e *R*.

Uma das possíveis razões para um desempenho melhor com o uso de RNA, que constitui-se uma ferramenta mais complexa e poderosa, é a possibilidade de a relação entre as variáveis não ser linear; logo como o diferencial das RNAs é justamente sua habilidade de ajuste de não-linearidade, isto possibilita um melhor desempenho deste modelo frente a RLM. Outro fator seria a utilização de apenas quatro variáveis para a construção dos modelos de RLM, enquanto que as RNAs foram construídas com 10 variáveis. É importante mencionar que ambas as metodologias, RLM e RNA, consistem em criar modelos que minimizam o erro quadrático médio, na tarefa de redução dos erros sistemáticos do modelo WRF. A utilização dos modelos de RLM e RNA apresentaram resultados satisfatórios; entretanto o modelo de RNA foi superior ao modelo de RLM.

Devido à enorme quantidade de informação, optou-se por mostrar os diagramas de dispersão para as previsões dos modelos WRF, RLM e RNA, apenas de uma estação para cada região homogênea. Em todos os diagramas de dispersão apresentados neste capítulo os coeficientes lineares (*a*) e angulares (*b*), bem como os coeficientes de correlação, *ME* e *RMSE* calculados para os ajustes lineares são apresentados nos cantos superiores esquerdo de cada diagrama de dispersão. As linhas azuis (WRF), verdes (RLM) e vermelhas (RNA) são diagonais, que passam pelas origens dos gráficos e possuem coeficientes angulares unitários, representando os casos ideais, isto é, elas

representam os casos em que previsões seriam perfeitas, assumindo o mesmo valor das observações ($P = 0$).

Diagramas de dispersão para as simulações por RLM e RNA, para as estações de A do Gurgeia, Cabaceiras, Brumado e Itapipoca com ID 46, 58, 108 e 63, respectivamente são apresentados nas Figuras 6.10 a 6.13. Verifica-se a capacidade dos modelos de RNA e RLM na redução dos erros inerentes no WRF. Observa-se a comprovação de que o modelo RNA apresenta o melhor desempenho, com as dispersões para todas as regiões apresentando um aspecto mais próximo do real do que as obtidas anteriormente para o WRF e RLM. Observa-se que os índices melhoram significativamente em todas as estações o que indica que a metodologia funcionou bem para o NEB. Os resultados mostram que as RNAs agregam uma quantidade significativa de variância explicada aos modelos estatísticos em relação à RLM para todas as estações analisadas.

É importante mencionar que todos os gráficos e índices foram desenvolvidos em relação aos dados de teste divididos aleatoriamente pelas as RNAs, na proposição de 60%, para treinamento, 30% para validação e 10% para o teste. Com isto fica evidente que o desempenho das RNAs é significativamente superior ao da RLM para todas as estações e regiões. A partir desta avaliação dos resultados é possível determinar o quão efetivo é o método proposto na modelagem da irradiação solar para o Nordeste do Brasil.

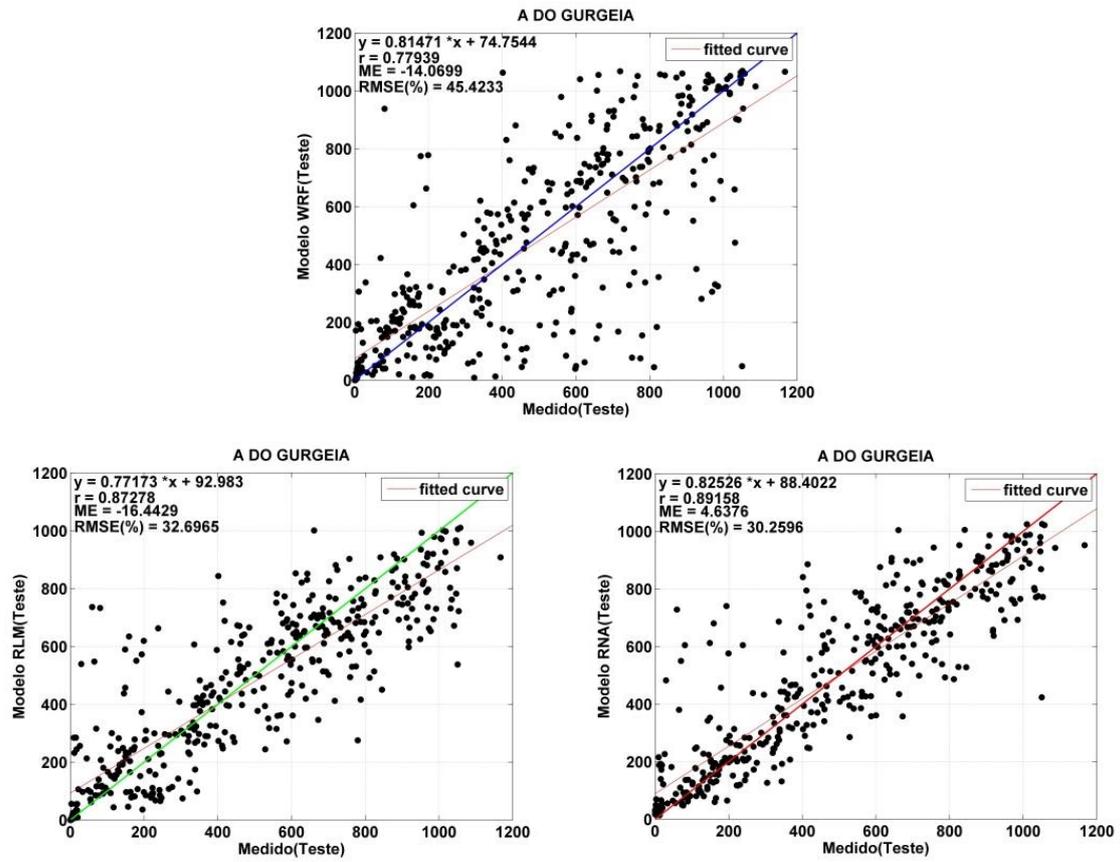


Figura 6.10 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para A do Gurgeia (R1).

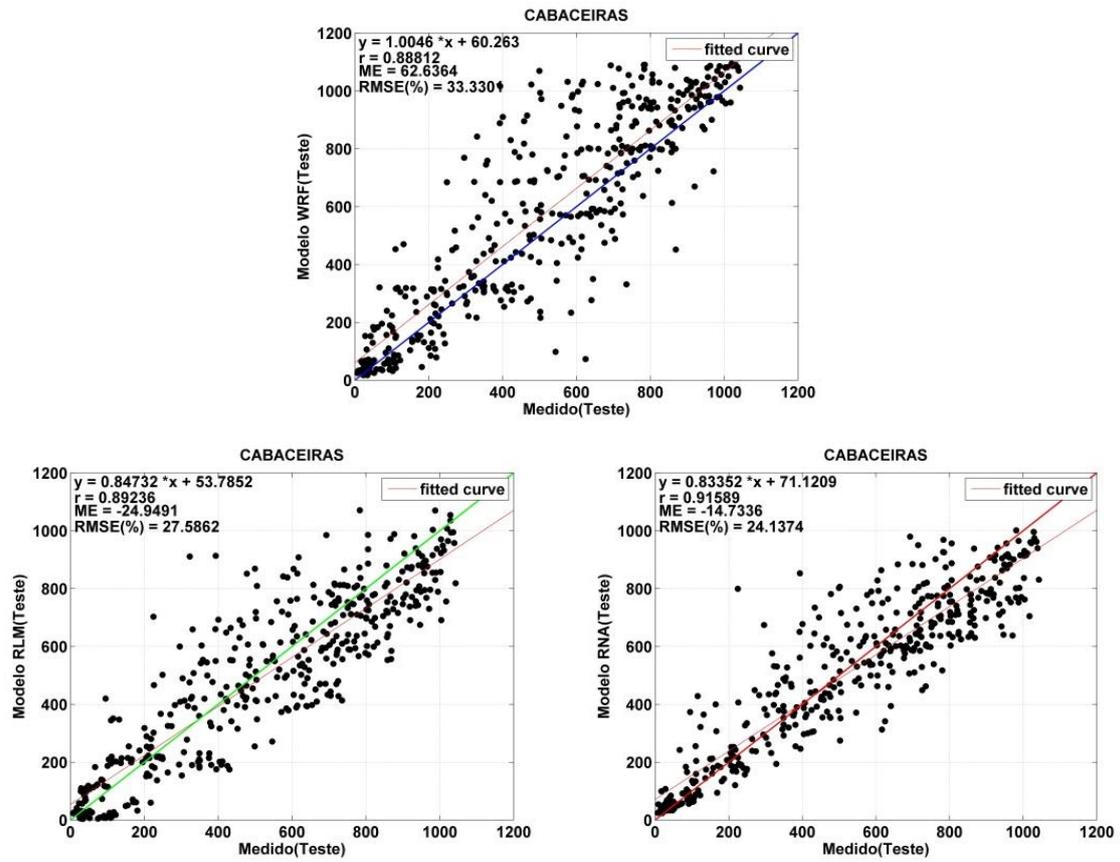


Figura 6.11 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Cabaceiras (R2).

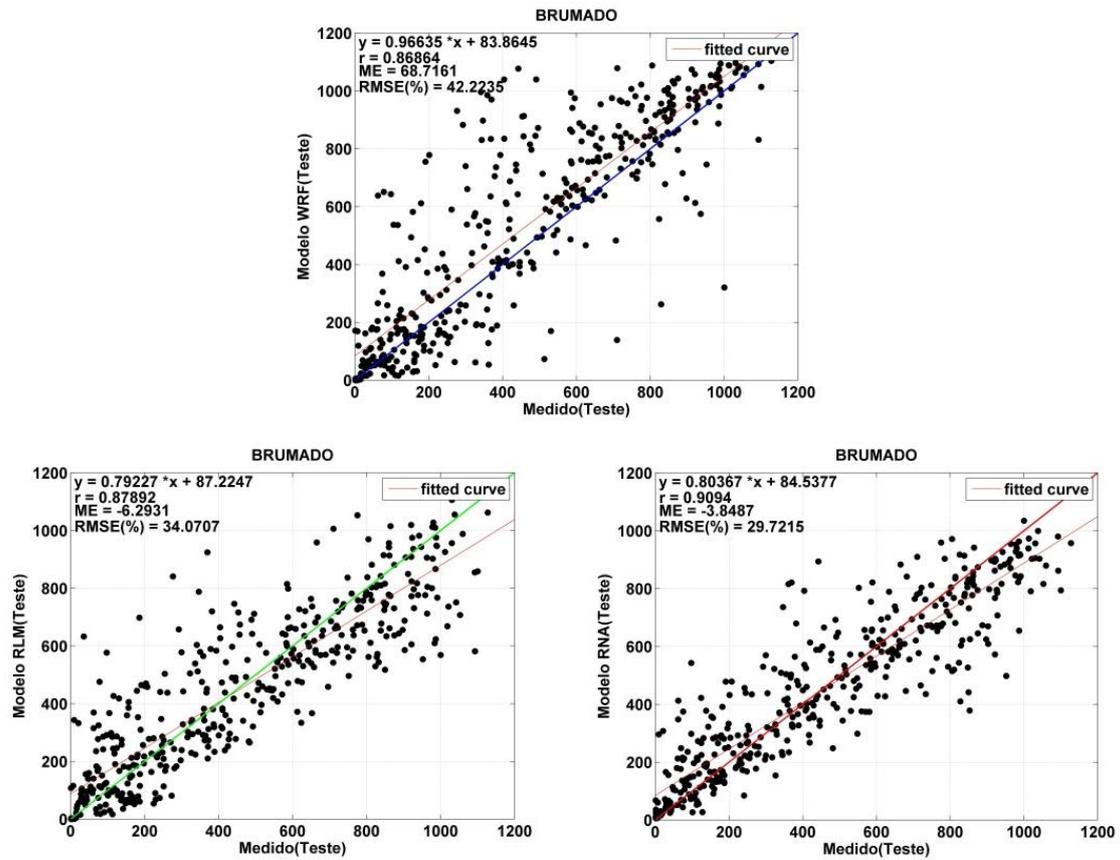


Figura 6.12 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Brumado (R3).

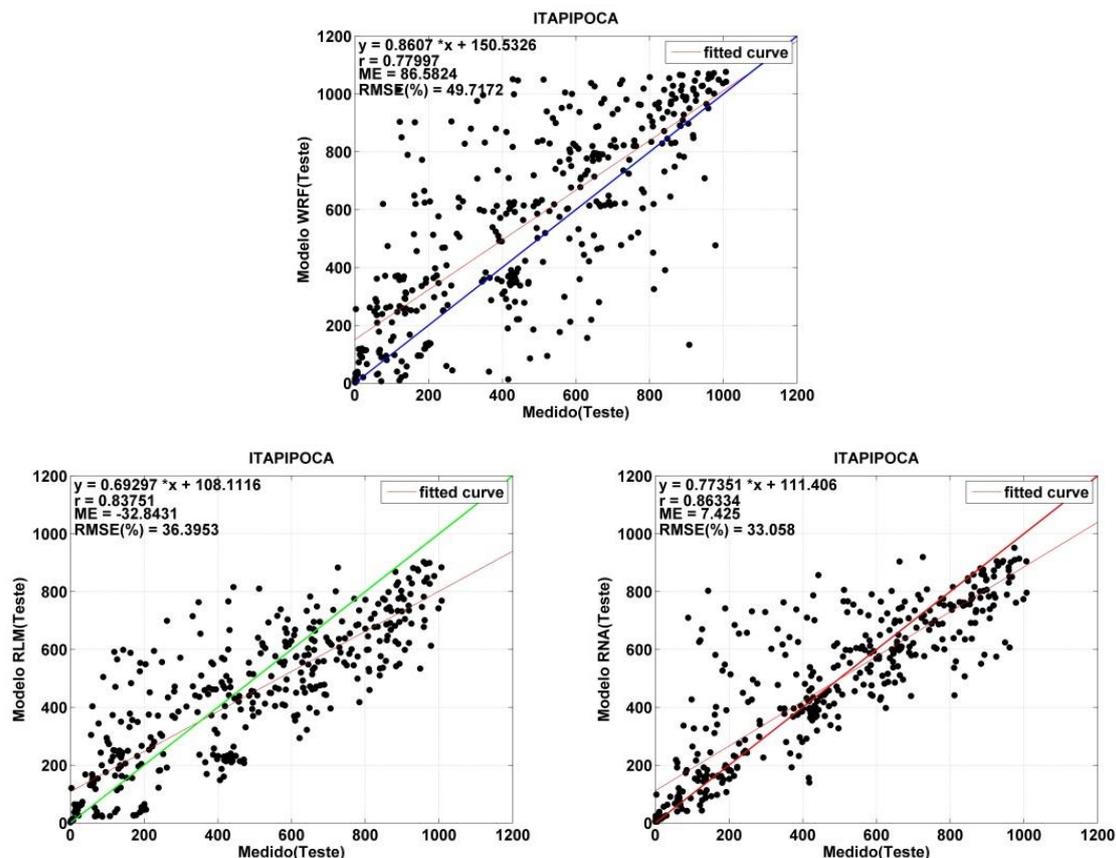


Figura 6.13 - Dispersão final obtida entre a irradiação solar observado e a modelada pela RLM e RNA para Itaipioca (R4).

6.4. Avaliação das Previsões para o Outono e Primavera de 2011

Uma vez que se observam condições de tempo e clima bastante distintas para o outono e primavera, e como os sistemas e processos meteorológicos atuantes em cada uma dessas estações podem ser bastante distintos para uma dada localidade, ou em cada uma das regiões homogêneas, os modelos de previsão de tempo nem sempre apresentam o mesmo desempenho na previsão de certas variáveis, para todas as épocas do ano.

A fim de analisar as previsões de irradiação solar, em cada região homogênea para o outono e primavera usou-se o ano de 2011, que foi deixado para teste,

ou seja, os dados de irradiação solar do ano de 2011 não foram usados para o treinamento dos novos modelos. Foi analisada a capacidade do modelo RNA, que mostrou um desempenho superior ao modelo de RLM na seção anterior, em prever a variação da irradiação entre o outono e primavera de 2011. Novamente foram calculados os coeficientes de correlação, o *ME*, *MSE* e *RMSE*. Os valores de *MSE* e *RMSE* foram convertidos em *MSE(%)* e *RMSE(%)*.

6.4.1. Região Homogênea 01 (2011)

Os índices mostrados na Tabela 6.13, são o *ME*, *MSE(%)*, *RMSE(%)* e os coeficientes de correlação, para o outono e primavera. Verifica-se na Tabela 6.13 que o desempenho do modelo WRF foi semelhante em todas as estações em relação ao outono e primavera; porém observa-se em ambos os períodos que o modelo de RNA obteve uma redução significativa dos erros em relação às saídas do modelo WRF, exceto analisando o viés na estação de S R de Cassia, onde se tem um viés de $-9,91 \text{ W/m}^2$ para a primavera, enquanto o modelo de RNA apresentou um valor de $-19,78 \text{ W/m}^2$. No entanto a RNA apresentou melhores valores de *MSE(%)*, *RMSE(%)* e *R*, com valores de $20,95 \text{ W/m}^2$, $29,48 \text{ W/m}^2$ e $0,88$ respectivamente, enquanto o WRF apresentou valores de *MSE(%)* de $29,51 \text{ W/m}^2$, *RMSE(%)* de $42,87 \text{ W/m}^2$, *r* de $0,78$.

Tabela 6.13 - Índices estatísticos para a Região 01 (outono/primavera).

ÍNDICES	ME(W/m ²)		MSE(%)		RMSE(%)		r	
	WRF	RNA	WRF	RNA	WRF	RNA	WRF	RNA
OUTONO								
A DO GURGEIA	-18,13	-1,17	32,53	26,54	48,36	37,66	0,73	0,82
S R DE CASSIA	-21,94	15,82	28,19	21,06	39,36	30,57	0,76	0,84
B J DA LAPA	27,67	22,68	29,47	22,49	42,81	33,50	0,80	0,86
IRECÊ	30,28	-4,17	34,75	25,79	48,89	35,92	0,73	0,83
PRIMAVERA								
A DO GURGEIA	25,21	5,57	25,94	19,25	38,66	29,22	0,82	0,89
S R DE CASSIA	-9,91	-19,78	29,51	20,95	42,87	29,48	0,78	0,88
B J DA LAPA	24,20	14,59	31,32	25,52	43,12	37,19	0,81	0,83
IRECÊ	29,61	17,90	28,41	21,41	42,29	31,64	0,80	0,88

6.4.2. Região Homogênea 02 (2011)

Verifica-se na Tabela 6.14 que o pior desempenho do modelo WRF ocorre em outono. Isso pode ser explicado pelo fato de nessa época do ano favorecem a ocorrência de nuvens e precipitação convectivas. Em cinza estão os melhores resultados para cada índice, mostrando que o modelo RNA foi superior às saídas originais do WRF em todas as estações, para todos os índices e nos dois períodos em análise. As diferenças encontradas foram mais significativas do que em relação às análises na Região 01. Para todas as estações de medição o modelo RNA apresenta coeficientes de correlação mais elevados do que os encontrados no modelo WRF. Para a Região 02 o modelo de RNA reduziu significativamente os valores dos erros, conseguindo uma diminuição significativa do viés (*ME*) nos dois períodos em estudo, além de apresentar menores valores de *RMSE* e *MSE* comprovando a eficiência da metodologia na região.

Tabela 6.14 - Índices estatísticos para a Região 02 (outono/primavera).

ÍNDICES	ME(W/m ²)		MSE(%)		RMSE(%)		r	
	WRF	RNA	WRF	RNA	WRF	RNA	WRF	RNA
OUTONO								
MACEIÓ	52,09	-5,73	33,24	24,68	45,99	33,54	0,82	0,87
MOSSORÓ	49,48	4,04	34,53	26,15	48,13	37,07	0,77	0,84
CABROBRO	54,02	-7,36	29,82	23,16	41,95	31,44	0,85	0,88
CALCANHAR	56,77	15,48	31,36	26,79	44,03	39,58	0,81	0,83
CABACEIRAS	70,73	-6,31	31,22	22,16	42,64	30,32	0,85	0,89
ARACAJÚ	68,42	25,31	35,37	22,83	48,10	34,36	0,86	0,88
PRIMAVERA								
MACEIÓ	67,94	-18,01	31,34	23,77	43,47	33,73	0,80	0,84
MOSSORÓ	28,75	-9,75	22,42	10,31	29,11	15,04	0,85	0,96
CABROBRO	80,12	19,30	23,43	18,83	34,31	26,20	0,89	0,91
CALCANHAR	-9,38	-3,60	14,81	9,81	20,51	15,07	0,93	0,96
CABACEIRAS	122,85	4,14	31,51	18,18	42,59	24,92	0,86	0,91
ARACAJÚ	44,64	-1,29	32,31	22,72	42,90	32,63	0,82	0,85

6.4.3. Região Homogênea 03 (2011)

Observa-se na, Tabela 6.15, que o melhor desempenho do modelo RNA ocorre em todas as estações para o outono e primavera, exceto na estação de Una, onde para o *ME* o WRF apresentou-se menor em relação ao modelo de RNA. Porém a RNA mostra um melhor desempenho para a redução dos erros *MSE* e *RMSE* e um aumento do índice de correlação. Em destaque estão os melhores resultados para cada índice. Em todas as estações, o modelo RNA apresenta coeficientes de correlação mais elevados do que os encontrados no modelo WRF. Para a Região 03, novamente o modelo de RNA reduziu significativamente os valores dos erros, conseguindo uma diminuição significativa do viés (*ME*) nos dois períodos em estudo, além de apresentar menores valores de *RMSE* e *MSE*. Isto comprova novamente a eficiência das RNA em redução dos erros sistemáticos do WRF.

Tabela 6.15 - Índices estatísticos para a Região 03 (outono/primavera).

ÍNDICES	ME(W/m ²)		MSE(%)		RMSE(%)		r	
	WRF	RNA	WRF	RNA	WRF	RNA	WRF	RNA
OUTONO								
CAMP GRANDE	74,10	-13,15	37,72	25,11	50,80	34,05	0,81	0,88
ARAPIRACA	-20,65	-0,02	33,02	23,10	44,21	33,10	0,80	0,88
PALMARES	29,29	-4,17	36,78	26,55	49,50	36,16	0,79	0,87
CARAVELAS	77,12	4,20	38,99	29,38	55,46	41,16	0,77	0,80
BRUMADO	88,33	-34,38	39,33	30,68	54,57	42,22	0,78	0,80
UNA	17,91	-31,37	38,22	29,08	51,31	41,03	0,74	0,82
DEUFINO	52,65	-5,90	37,13	29,16	51,01	39,69	0,80	0,84
ÍNDICES								
PRIMAVERA								
ARAPIRACA	6,67	-0,83	30,30	20,53	39,51	28,52	0,80	0,88
PALMARES	26,78	-3,96	34,86	22,81	46,67	31,11	0,73	0,85
CARAVELAS	55,30	-28,20	41,19	32,47	58,05	45,73	0,76	0,78
BRUMADO	86,03	8,58	34,69	27,88	50,94	38,75	0,82	0,85
UNA	14,31	13,94	42,84	32,27	58,85	44,32	0,71	0,80
DEUFINO	39,35	-3,58	29,38	25,04	43,56	34,38	0,84	0,88

6.4.4. Região Homogênea 04 (2011)

Na Tabela 6.16 tem-se que o pior desempenho para o modelo WRF ocorre no outono. Isso pode ser explicado pelo fato de que esta época do ano, principalmente na R4, favorece a ocorrência de nuvens e precipitação convectivas. O desempenho para o modelo WRF na primavera apresenta menores erros em comparação ao outono, exceto na estação de Estreito, onde os índices na primavera foram superiores aos apresentados para o outono. Em todas as estações de medição o modelo RNA apresenta coeficiente de correlação mais elevado do que os encontrados para o modelo WRF. O modelo apresentou maiores valores de *R* tanto na primavera como para o outono. Porém os maiores valores foram encontrados na primavera. Isto pode ser explicado porque no período da primavera, ocorre uma maior incidência de irradiação solar na região, devido à baixa nebulosidade nesta época do ano.

Observa-se ainda que o modelo WRF tende a superestimar a radiação solar incidente nos dois períodos, principalmente para a primavera, enquanto que o modelo RNA tende a uma redução significativa do viés, (*ME*), *MSE* e *RMSE* e um aumento do coeficiente de correlação, em todas as estações e períodos em análise. A metodologia proposta foi eficiente em todas as regiões homogênea na tarefa de redução do erro sistemático do WRF, ou seja, é possível a utilização do modelo WRF para a previsão de radiação solar incidente usando as redes neurais artificiais no refinamento das saídas originais de irradiação solar do modelo.

Tabela 6.16 - Índices estatísticos para a Região 04 (outono/primavera).

ÍNDICES	ME(W/m ²)		MSE(%)		RMSE(%)		r	
	WRF	RNA	WRF	RNA	WRF	RNA	WRF	RNA
OUTONO								
CHAPADINHA	15,68	-0,41	38,00	24,17	50,80	31,64	0,72	0,86
ESTREITO	15,62	-3,58	37,98	26,83	51,29	36,66	0,70	0,82
PARNAÍBA	44,07	0,87	37,88	27,25	51,62	38,15	0,75	0,84
TERESINA	29,57	6,48	37,47	24,74	49,81	34,02	0,74	0,84
BARBALHA	10,39	-30,00	26,43	22,26	36,27	30,25	0,85	0,88
TAUÁ	40,77	-14,42	32,50	24,99	44,10	32,50	0,82	0,87
S J DO PIAUÍ	2,38	8,99	29,61	22,33	40,30	30,71	0,77	0,85
ITAPIOCA	98,85	5,97	47,46	35,68	66,69	51,49	0,70	0,75
ÍNDICES								
PRIMAVERA								
CHAPADINHA	86,15	8,85	32,84	14,37	40,94	20,44	0,85	0,93
ESTREITO	115,06	6,33	43,85	27,55	58,26	38,42	0,75	0,82
PARNAÍBA	69,98	2,83	24,75	11,55	31,19	18,27	0,90	0,94
BARBALHA	96,59	-5,63	24,73	16,70	33,99	23,62	0,88	0,92
TAUÁ	132,72	20,55	30,91	16,93	43,52	24,74	0,86	0,92
S J DO PIAUÍ	45,00	4,84	25,22	16,24	34,67	24,23	0,82	0,90
ITAPIOCA	115,41	-7,18	29,71	16,05	38,81	22,42	0,86	0,91

6.4.5. Análise Espacial para 2011

No intuito de analisar espacialmente e qualitativamente as saídas de irradiação solar dos modelos WRF e RNA para o ano de 2011, usaram-se os dados de todas as regiões homogêneas, totalizando 110 estações, distribuídas em todo o Nordeste do Brasil e usou-se a técnica de interpolação por krigagem. Os dados foram arranjados por médias para o outono e primavera de 2011. O mesmo procedimento adotado na seção 5.2 foi aplicado.

Os mapas da irradiação solar e da diferença entre os dados medidos e estimados para o ano de 2011 serão mostrados nas Figuras abaixo, para o outono e primavera. Na Figura 6.14 observa-se um comportamento similar entre os dados medidos e simulados pelas as RNAs, mostrando que a metodologia foi satisfatória. Isto ainda fica mais evidente se comparamos os resultados da Figura 6.14 com os resultados da Figura 5.17, verificando que os modelos de RNA são mais eficientes para simulação da irradiação solar para o NEB, obtendo valores mais próximos da realidade.

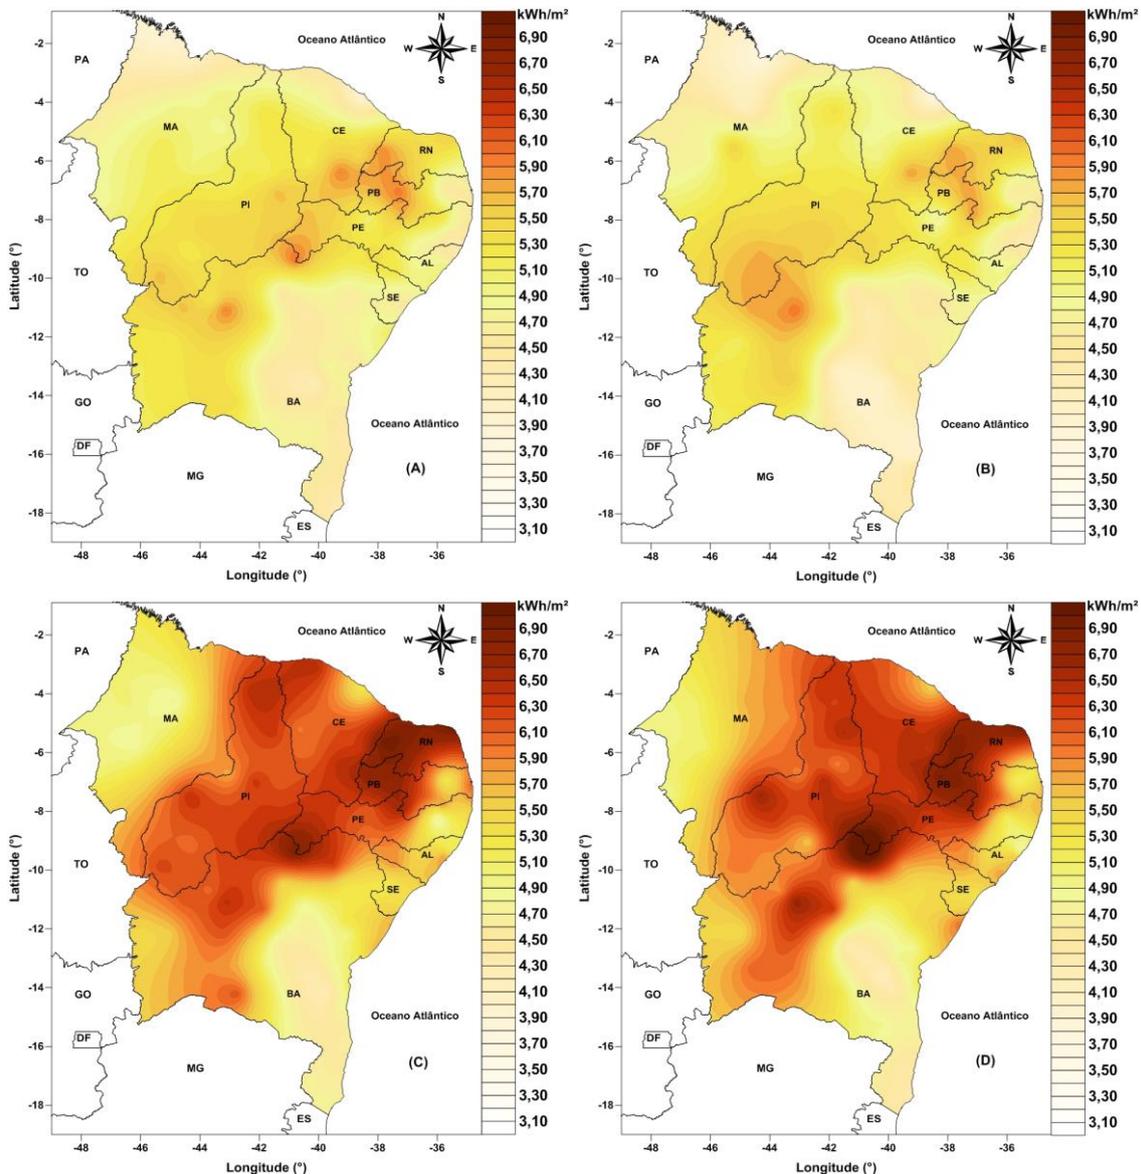


Figura 6.14 – Mapas da Irradiação Solar, (kWh/m²), para 2011. (A) dados medidos para o outono, (B) dados estimados pela RNA para o outono, (C) dados medidos para a primavera e (D) dados estimados pela RNA para a primavera.

Na Figura 6.15 têm-se os mapas da diferença entre os dados medidos e estimados pelo WRF e RNA para 2011, onde mostra-se que o modelo de RNA tende a reduzir significativamente o viés do modelo WRF, passando a superestimar no Sul do Maranhão, no Sertão do Nordeste e no Sul da Bahia, mas com valores relativamente baixos se comparado com as saídas originais

do modelo WRF, Figura 6.15(A) e 6.15(B). Para o outono de 2011 os dois modelos foram capazes de seguir a tendência dos dados medidos, porém com a utilização do modelo RNA observa-se uma redução considerável do viés. Na Figura 6.15(C) e 6.15(D) observam-se os resultados para a primavera, que evidencia a capacidade do modelo RNA em simular a irradiação solar com uma redução do viés. Ou seja, além de os valores de *ME* serem mais próximos de zero para os modelos RNAs, estes modelos apresentaram os menores valores de *RMSE* em todas as estações e para todas as épocas do ano. Os valores dos coeficientes de correlações para RNAs são maiores dos que os observados para o modelo WRF. Novamente nesta análise foi verificada diferença significativa de desempenho entre os modelos de RNA e WRF, mostrando que os modelos de RNAs promovem uma melhoria na previsão de radiação solar incidente em todas as regiões homogêneas, ou seja, em todo o Nordeste do Brasil.

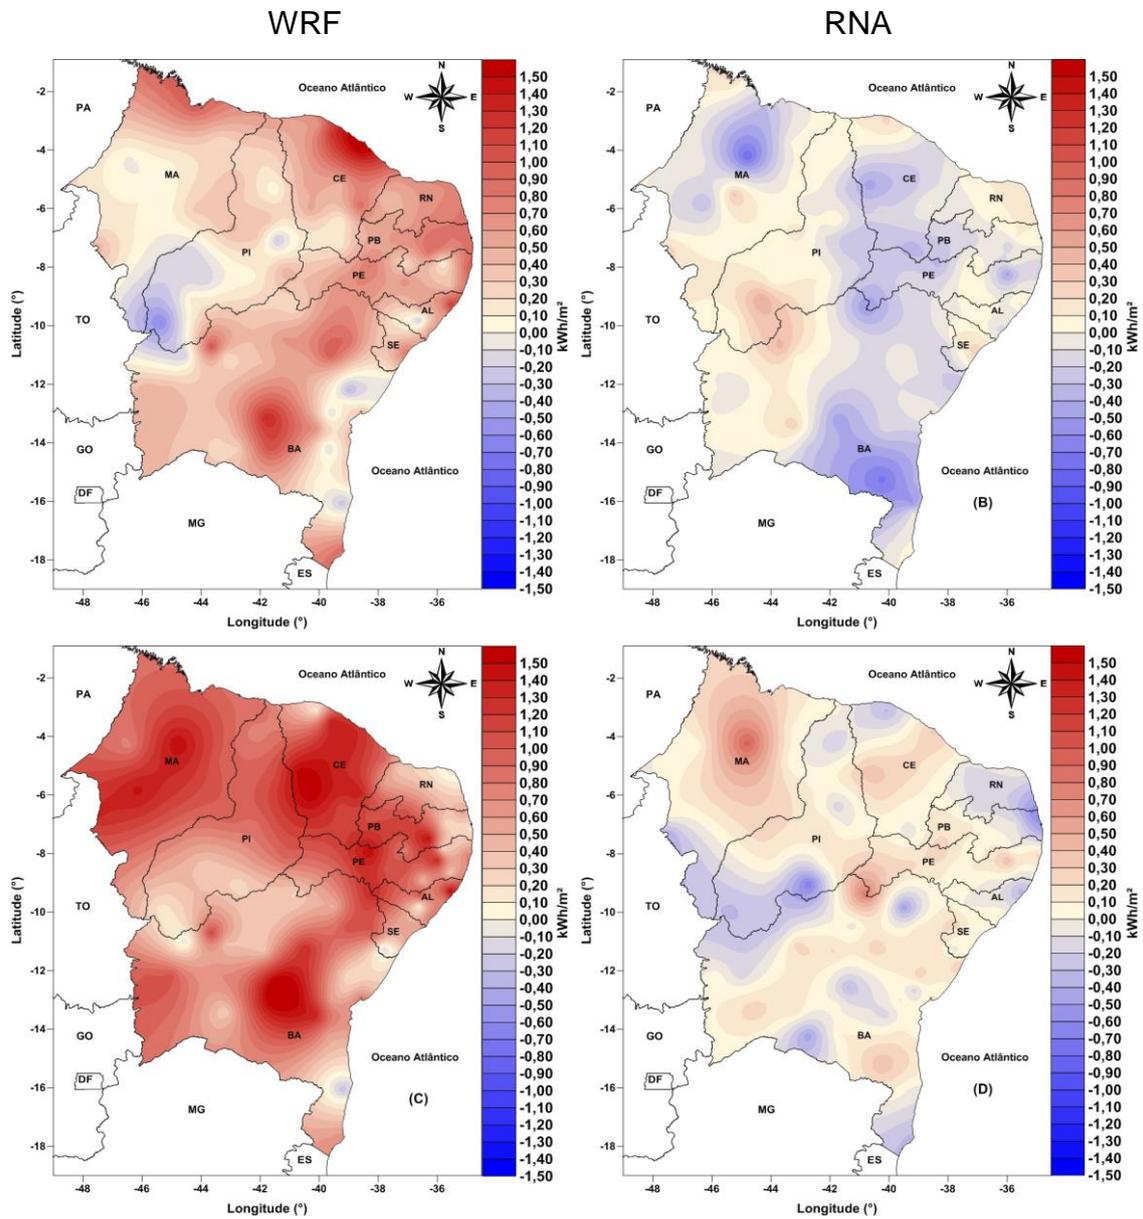


Figura 6.15 – Mapas de diferença de Irradiação Solar, (kWh/m²), para 2011. (A) entre os dados medidos e as saídas do modelo WRF, para o outono, (B) entre os dados medidos e as saídas do modelo RNA, para o outono, (C) entre os dados medidos e as saídas do modelo WRF, para a primavera e (D) entre os dados medidos e as saídas do modelo RNA, para a primavera.

7 CONCLUSÕES

Os objetivos propostos neste trabalho foram atingidos, tendo sido obtido um ganho nas previsões de irradiação solar para o Nordeste brasileiro em comparação com aquelas disponibilizadas diretamente pelo modelo WRF. Também foi verificado um ganho significativo em desempenho com o uso das RNAs em relação ao modelo ajustados por RLM.

Conclui-se claramente que o trimestre de SON, primavera no Hemisfério Sul, abriga os meses com maior incidência de irradiação solar, caracterizando o período seco no NEB. De forma contrastante, o trimestre MAM caracteriza o período com menores incidências de irradiação solar, coincidindo com o ápice da atividade convectiva na região. Este é o período com o menor índice de incidência de radiação, coincidindo com o período mais chuvoso na região. Essa diminuição da radiação solar pode estar associada à atuação direta da ZCIT, que atinge sua maior intensidade no trimestre de MAM.

Obtiveram-se quatro regiões homogêneas utilizando como entrada na AA a irradiação solar e a temperatura do ar média mensal, bem como a latitude e longitude das localidades. Este número de regiões foi considerado satisfatório, pois cada uma dessas regiões apresentou um número representativo de estações meteorológicas.

Os três primeiros dias do mês de maio de 2009 foram simulados usando diferentes esquemas de radiação (RRTMG, Dudhia/RRTM e New Goddard), microfísica (Lin, Thompson e WSM6) e convecção (Grell 3D, Kain-Fritsch e Desligada).

Em geral, não houve uma diferença significativa entre as parametrizações de radiação RRTMG, Dudhia/RRTM, exceto para a Região 4, onde o desempenho da Comb. 01 foi bem superior ao das demais. Porém a parametrização de RRTMG obteve o melhor desempenho, para todas as regiões.

Houve diferença entre as parametrizações de microfísica Thompson, WSM6 e Lin. A parametrização de WSM6 foi superior em R1 e R4, obtendo os melhores índices em um número maior de estações. Para as regiões R2 e R3, a parametrização de Thompson foi ligeiramente melhor que a configuração usando a parametrização WSM6.

Em geral houve diferença entre as parametrizações de Cúmulo Grell-3D, Kain-Fritsch e com a cúmulo desligado. Para todas as regiões 01, 02, 03 e 04 a parametrização de Grell-3D obteve um melhor desempenho em relação às demais. A parametrização de Grell-3D foi a melhor em todas as regiões. Em todas as simulações/previsões foram utilizadas a melhor combinação para cada uma das regiões. Nas regiões R1 e R4 foi usada a Comb. 04 e nas regiões R2 e R3 a Comb. 01 foi usada.

Conclui-se que para o outono e primavera de 2009 o modelo foi capaz de prever a irradiação solar de forma satisfatória em todas as regiões do NEB. Apesar de o modelo apresentar um *ME* elevado e um *RMSE* também expressivo, os coeficientes de correlação indicam bons níveis entre previsões e observações, sempre superiores a 0,60. Em todas as estações os índices foram melhores na primavera que no outono, mostrando que o modelo é mais eficiente para os meses do ano com maior incidência de radiação. Em todas as estações o modelo claramente superestima a irradiação solar, embora se observe uma boa concordância entre os dados observados e previstos.

Para o outono e primavera de 2010, em geral o modelo apresenta um alto viés, principalmente na região 04. Verifica-se que em todas as estações o modelo claramente superestima os valores de irradiação solar para a primavera. Para a região 01 em geral o modelo foi satisfatório na tarefa de simular a irradiação solar, mas apresentou um erro sistemático alto em algumas estações.

Para o outono e primavera de 2011, em geral o modelo apresentou um alto viés, como já era esperado o modelo obteve um melhor desempenho para a primavera. A localização da região 01 favorece a incidência de irradiação solar por apresentar menor nebulosidade, o que facilita a capacidade do modelo

WRF em prever/simular a radiação solar na região. Observa-se ainda que os coeficientes de correlação apresentam-se com bons níveis entre previsões e observações, sempre superiores a 0,70 para o outono e maiores que 0,80 para a primavera.

Para os anos de 2009, 2010 e 2011 o modelo foi capaz de seguir a tendência dos dados medidos, porém conclui-se que o modelo apresenta um alto viés. Com isso fica evidente que o modelo WRF é capaz de prever/simular a irradiação solar na região; contudo foi necessária a utilização de técnicas estatísticas de refinamento para a diminuição desses erros inerentes no modelo.

Conclui-se que em todas as estações, os experimentos 02 e 03 obtiveram resultados significativos em comparação com o experimento 01. Porém o Experimento 03 foi melhor em todas as estações. Não se observou uma diferença significativa em relação à quantidade de neurônios na camada oculta. Nos resultados das previsões usando os modelos WRF, RLM e RNA por regiões homogêneas para os anos de 2009 e 2010 conclui-se, que qualquer das previsões derivadas dos modelos de RLM e RNA promovem a remoção do viés, redução do *MSE* e *RMSE* e aumento dos coeficientes de correlação, para todas as estações. As previsões dos modelos de RLM e RNA possuem desempenhos superiores aos observados pelo modelo WRF, embora o modelo RNA apresente um desempenho superior ao modelo de RLM.

Enquanto o *RMSE*(%) para o modelo WRF é de aproximadamente 45%, 40%, 37% e 43% para as estações de A do Gurgeia, S R de Cassia, B J da Lapa e Irecê, respectivamente, novos modelos apresentaram valores da ordem de 33%, 34%, 29% e 31% para RLM e 30%, 32%, 22% e 28% para RNA, nas referidas estações. Revelando uma redução significativa na estimativa da irradiação solar do modelo WRF. O desempenho da RNA apresentou uma melhora significativa e superiores ao dos modelos de RLM, em todas as estações da R2. Os coeficientes de correlação e os erros médios para RLM e RNA apresentaram uma diferença significativa. Apesar de o uso de RNA

proporcionar ganhos sobre o modelo RLM, ambos os modelos apresentaram coeficiente da ordem de 0,80 em todas as estações analisadas e proporcionaram uma redução dos erros médios frente às previsões do modelo WRF.

Houve uma redução significativa para o modelo de RNA frente aos demais, enquanto que o modelo de RLM obteve uma redução em algumas estações e um aumento do viés em outra, como verificado, nas estações de Calcanhar e Aracajú. Porém em geral, ambos os modelos apresentaram erros muito baixos em comparação com as simulações do modelo WRF. Os valores de *RMSE*(%) do modelo RNA são bastante reduzidos em relação ao demais modelos. Assim, os novos modelos levam a previsões com erros reduzidos, superando as previsões já existentes.

Uma das possíveis razões para um desempenho melhor com o uso de RNA é a possibilidade de a relação entre as variáveis não ser linear. Logo como o diferencial das RNAs é justamente sua habilidade de ajuste de não linearidade, possibilita um melhor desempenho deste modelo frente a RLM. Outro fator seria a utilização de apenas quatro variáveis para a construção dos modelos de RLM, enquanto que as RNAs foram construídas com 10 variáveis.

Observa-se em ambos os períodos, outono e primavera de 2011, que o modelo de RNA obteve uma redução significativa dos erros em relação às saídas do modelo WRF. Em todas as estações o modelo RNA apresentou coeficientes de correlação mais elevados do que os encontrados no modelo WRF. Para a Região 02, o modelo de RNA reduziu significativamente os valores dos erros, conseguindo uma diminuição significativa do viés (*ME*) nos dois períodos em estudo, além de apresentar menores valores de *RMSE* e *MSE*, comprovando a eficiência da metodologia na região

A metodologia proposta foi eficiente em todas as regiões homogênea, na tarefa de redução do erro sistemático do WRF, ou seja, é possível a utilização do modelo WRF para a previsão de radiação solar incidente usando as redes

neurais artificiais para o refinamento das saídas originais de irradiação solar do modelo WRF.

8 SUGESTÕES DE TRABALHOS FUTUROS

Ao longo da realização deste trabalho e após a análise dos resultados obtidos, observou-se a necessidade de estudos complementares que poderão levar a maiores aperfeiçoamentos das previsões de irradiação solar e sua avaliação em outras regiões. Considerando que foi possível obter uma ferramenta prognóstica de irradiação baseada numa RNA com melhor desempenho que o modelo RLM e ambas superiores às saídas originais do WRF, torna-se necessário continuar com as pesquisas nesta área, já que a técnica apresentou uma potencialidade alta de previsão. Porém, para tornar mais eficiente esta ferramenta sugere-se algumas possíveis alternativas que possibilitem minimizar em parte a carência de dados:

- a) Incluir uma análise em todos os preditores disponíveis pelo modelo WRF, principalmente os que apresentarem algum embasamento físico em relação à irradiação solar, fazendo testes de sensibilidades entre os conjuntos de preditores e definindo os melhores para verificação de ganho em relação aos preditores usados nesta pesquisa. Este trabalho passaria, necessariamente por uma redefinição dos critérios para inclusão de preditores, a fim de evitar o acréscimo de informação redundante à RNA, tendo em vista que o modelo WRF disponibiliza cerca de 180 variáveis, além de incluir preditores em vários níveis.
- b) Selecionar conjuntos de preditores e ajustar modelos de RNAs individuais para cada época do ano. Neste trabalho, os modelos foram ajustados empregando dados para o outono e primavera com um conjunto fixo de preditores, mas desempenhos variados foram observados para as previsões no outono e primavera. Resultados melhores podem ser obtidos através do ajuste de modelos e uso de grupos de preditores variados para cada época do ano, ou para época

seca e época chuvosa, além de incluir nesta pesquisa o verão e o inverno.

- c) Realizar estudos de seleção de preditores e ajustes de modelos estatísticos baseados em previsões de tempo para outras regiões do Brasil, como para regiões bastante influenciadas pelos aerossóis, como o Centro-Oeste brasileiro. Testar se a metodologia proposta é eficiente para essa região, ou se é necessário a inclusão de preditores proveniente de modelos químicos. Com o emprego do modelo WRF-CHEM e refinamento de suas saídas usando redes neurais artificiais.
- d) Promover modificação no código do modelo WRF. Neste trabalho são apresentados modelos estatísticos que a partir de variáveis previstas geradas pelo modelo, levam a uma previsão de radiação solar alternativa àquela fornecida por este modelo e com erros reduzidos. Contudo, a realização de estudos diretamente sobre as parametrizações e o código de cálculo de radiação do modelo WRF, podem conduzir a aperfeiçoamentos que resultem em uma melhoria na previsão de radiação fornecida diretamente pelo modelo.
- e) Incluir preditores observados nas estações meteorológicas, tais como: temperatura do ar, pressão, umidade relativa, além de parâmetros geográficos e topográficos também podem ser importantes para caracterizar a variabilidade da irradiação solar.
- f) Utilizar bases de dados medidos com séries mais extensas.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGUIAR, R. **Climatic synthetic series for the Mediterrabean belt**, The European Commission, on Nuclear Energy Programme Joule III, Contract JOR3-CT96-0042. Lisboa, Portugal: Instituto Nacional de Engenharia e Tecnologia Industrial, 1997. Final Report.
- AL-ALAWI, S. M.; AL-HINAI, H. A. An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation, **Renewable Energy** 14, 199, 1998.
- ALLEN, R. Self-calibrating method for estimating solar radiation from air temperature. **Journal Hydrological Engineering**, v.2, p. 56 –67, 1997.
- ALVES, A. R. **Irradiância solar global em superfície de diferentes inclinações e azimutes para Viçosa, MG**. 1981. 92 p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa: Viçosa, 1981.
- AMANAJÁS, J. C.; BRAGA, C. C.; LIMA, F. J. L.; GUEDES, R. V. S. Aplicação da Análise Fatorial em Componentes Principais a dados de precipitação no estado do Amapá. **Revista de Geografia**, v. 27, n.1, p.107-119, 2010.
- ANEEL - AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, MINISTÉRIO DE MINAS E ENERGIA. **Balanco Energético Nacional – BEN**, 2011: ano base 2010: resultados preliminares. Rio de Janeiro: Empresa de Pesquisa Energética, 2011.
- ANGSTROM, A. Solar and terrestrial radiation. **Quartely Journal Research Meteorologycal Society**. p. 121-126, 1924.
- ANTHES, R. A.; SEAMAN, N. L.; WARNER, T. T. Comparisons of numerical simulations of the planetary boundary layer by a mixed-layer model. **Mon. Wea. Rev.**, v. 108, p. 365-376, 1980.
- ARGIRIOU, A.; LYKOUDIS, S.; KONTOYIANNIDIS, S.; BALARAS, C.A.; ASIMAKO-POULOS, D.; PETRADIS, M.; KASSOMENOS, P. Comparison of methodologies for TMY generation using 20 years data for Athens, Greece. **Solar Energy** 66, 33–45, 1999.
- ARTAXO, P; OLIVEIRA, P. H; LARA L. L; PAULIQUEVIS, T. M; RIZZO, L. V; PIRES JUNIOR, C; PAIXÃO, M. A; LONGO, K. M; FREITAS, S; CORREIA, A. L. Efeitos climáticos de partículas de aerossóis biogênicos e emitidos em

queimadas na Amazônia. **Revista Brasileira de Meteorologia**, v.21, n.3, p.168-22, 2006.

BARRETO, A. B. **Estudo do ciclo diário do vento à superfície no Nordeste do Brasil**. 2001. 56p. Dissertação (Mestrado em Meteorologia) – Universidade Federal da Paraíba, Campina Grande, 2001.

BECKER, C. T.; BRAGA C. C.; CEBALLOS J. C. Regionalização da precipitação e temperatura no Estado do Rio Grande do Sul a partir da análise de agrupamento. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 7., 1992, São Paulo. **Anais...** São Paulo: SBMET, v.1, p. 225 – 232, 1992.

BENNETT, I. Monthly maps of mean daily insolation for the united states. **Solar Energy**, v. 9, n. 3, p. 145 – 158, 1965.

BENTLEY, R.W. Global oil and gas depletion: an overview. **Energy Policy**, v. 30, n. 3, p. 189-205, 2002.

BOUROCHE, J- M; SAPORTA, G. **Análise de dados**. Rio de Janeiro, Zahar, 1982. 117p.

BRAGA C. C.; SILVA B. B. Determinação de regiões pluviometricamente homogêneas no Estado da Paraíba. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 6., 1990, Salvador, BA. **Anais...**, Rio de Janeiro: SBMET, 1990.

BRAGA, A. P.; CARVALHO A. C. P. F.; LUDERMIR, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: 11 a Escola de Computação/Universidade Federal do Rio de Janeiro, 1998. 246p.

BRAGA, C. C.; MELO M. L. D.; MELO, E. C. S. Análise de agrupamento aplicada à distribuição da precipitação no estado da Bahia. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 10., CONGRESSO DA FLISMET, 8., 1998, Brasília. **Anais...** Rio de Janeiro: SBMet, 1998. CL-98001. 1 CD-ROM.

BRUNI, A. L. **Estatística aplicada à gestão empresarial**. São Paulo: Atlas, 2007. 396 p.

BRUTSAERT, W. H. **Evaporation into the atmosphere: theory, history and applications**. Dordrecht: Kluwer Academic, 1982. 316p.

BUSSAB, W. O.; MIAZAKI, E. S.; ANDRADE, D. **Introdução à análise de agrupamentos**. São Paulo: Associação Brasileira de Estatística, 1990. 105p.

CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS, M. A. F. **Tempo e clima no Brasil**. São Paulo: Oficina de Textos, 2009, cap. 13, p. 197-212.

CEBALLOS, J. C.; BOTTINO, M. J. Estimativa de radiação solar por satélite: Desempenho do modelo operacional GL1.2. In: XIII Congresso Brasileiro de Meteorologia, 13, 2004, Fortaleza. **Anais...** Fortaleza: SBMET, 2004, CD-Rom.

CEBALLOS, J. C.; BOTTINO, M. J. Modelo de estimativa de radiação solar por satélite no CPTEC: Versão GL 1.2. In: XII Congresso Brasileiro de Meteorologia, 12, 2002, Foz do Iguaçu. **Anais...** Foz do Iguaçu: SBMET, 2002, CD-Rom.

CEBALLOS, J. C.; BRAGA, C. C. Missing data assessment in a solarimetric network. **Int. J. Climatol.**, v.15, p. 325-340, 1995.

CHEN, F.; DUDHIA, J. Coupling an advanced land-surface/ hydrology model with the Penn State/ NCAR MM5 modeling system. Part I: Model description and implementation. **Monthly Weather Review**, v. 129, p. 569-585, 2001.

CHEVALLIER, F.; CHÉRUY, F.; SCOTT, N. A.; CHÉDIN, A. A neural network approach for a fast and accurate computation of a longwave radiative budget. **J. of Applied Meteorology**, v. 35, p. 1385-1397, 1998.

CHOU, M. D.; SUAREZ, M. J. **An efficient thermal infrared radiation parameterization for use in general circulation models**. Washington: NASA Tech. Memo. 104606, 85 pp, 1994.

COHEN, S.; IANETZ A.; STANHILL, G. Evaporative climate changes at Bet Dagan, Israel, 1964-1998. **Agricultural and Forest Meteorology**, v.111, n.2, p. 83-91, 2002.

CORRAR, L. J; PAULO, E; DIAS FILHO, J. M. **Análise Multivariada: para os cursos de administração, ciência contábeis e economia**.. São Paulo: Ed. Atlas, 2007. ISBN 978-85-224-4707-7.

CORREIA, A, A. **Padrões de variabilidade do vento à superfície no Nordeste do Brasil**. Campina Grande, 2000. 66.p Dissertação (Mestrado em Meteorologia) – Universidade Federal da Paraíba, Campina Grande, 2000.

COTTON, W. R.; PIELKE, R. A.; WALKO R. L.; LISTON, G. E.; TREMBACK, C. J.; JIANG, H.; McANELLY, R. L.; HARRINGTON, J. Y.; NICHOLS, M. E.; CARRIO, G. G.; McFADDEN, J. P. Current Status and Future Directions. **Meteorology and Atmospheric Physycs**. v.82, n.1, p.5-29, 2003.

DANTAS, V. A.; AMORIM, A. C. B.; COSTA, M. S.; SILVA, C. M. S. *Downscaling* dinâmico sobre o Nordeste do Brasil utilizando um modelo climático regional: impacto de diferentes parametrizações na precipitação simulada. **Revista Brasileira de Geografia Física**, v. 6, n. 4, p. 995-1008, 2013.

DAVIES, J.A.; McKAY, D.C.; LUCIANI, G.; ABDEL-WAHAB, M. **Validation of models estimating solar radiation on horizontal surfaces**. Task IX Final Report to the Solar Heating and Cooling Programme of the International Energy Agency, 1988.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural network toolbox user's guide – Version 8** – for use with MATLAB®. The MathWorks Inc., 2014. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 15 ago. 2014.

DIABATÉ, L. REMUND, J. WALD, L. Linke turbidity factors for several sites in Africa. **Solar Energy**, v.75, p.111-119, 2003.

DIEKMANN, F. J.; RASCHKE, E.; WOICK H. Operational mapping of global radiation over Central Europe. **Meteorol. Rdsch.**, 39, 59-63, 1986.

DJEMAA, B.; DELORME, C. A comparison between one year of daily global irradiation from a ground-based measurements versus Meteosat images from seven locations in Tunisia. **Solar Energy** 48, 325–333, 1992.

DUDHIA, J. Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model. **Journal of Atmospheric Science**, v. 46, p. 3077-3107, 1989.

DUHDIA. J.; GILL, D.; MANNING, K.; WANG, W.; BRUYERE, C. **PSU/NCAR Mesoscale Modeling System Tutorial Class Notes and Users' Guide** (MM5 Modeling System) Version 3. 2005.

DUMORTIER D. The Satellight model of turbidity variations in Europe. In: SATELLIGHT MEETING, 6., 1998, Freiburg, Germany. **Proceedings...** Freiburg, 1998. Technical Report.

DURAN, B. S.; P. L. ODELL. **Cluster analysis**. Velarg, Asurvey Springer, 1974. 137p.

DÜRR B.; PHILIPONA, R. Automatic cloud amount detection by surface longwave downward radiation measurements. **Journal of Geophysical Research**, v. 109, n. 5, 2004.

ECHER, E.; SOUSA M. P.; SCHUCH, N. J. Lei de Beer Aplicada na atmosfera terrestre. **Revista Brasileira de Física**, São Paulo, v.23, n.3,p.276-283, 2001.

ELMINIR H.K.; AREED F.F.; ELSAYED T.S., Estimation of solar radiation components incident on Helwan site using neural networks. **Solar Energy**, v. 79, p. 270, 2005.

ESTEBAN, P.; MARTIN-VIDE, J.; MASES, M. Daily atmospheric circulation catalogue for western Europe using multivariate techniques. **Int. J. Climatol.**, v. 26, p. 1501-1515, 2006.

EVERITT, B.S. **Cluster analysis**. London, Heinemann Educational Books Ltd., 1974. 121p.

FERREIRA, N. S. Zona de convergência intertropical. **Climanálise Especial**. Comemoração dos 10 anos, 1996. Disponível em <http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/zcit_1.html>. Acesso em: 31 de outubro de 2014.

FIORIN, D. V. **Emprego de redes neurais artificiais na análise de parâmetros de radiação solar**. Santa Maria: Relatório de Estágio Supervisionado em Engenharia Química – Universidade Federal de Santa Maria, 2009. 105 p.

FRAGOSO, M.; GOMES, P. T. Classification of daily abundant rainfall patterns and associated large-scale atmospheric circulation types in Southern Portugal. **Int. J. Climatol.**, v. 28, p. 537-544, 2008.

GAMBI, W. **Avaliação de um modelo físico estimador de irradiância solar baseado em satélites geoestacionários**. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal de Santa Catarina. Florianópolis, 1998.

GELLER, H. S. **Revolução energética**: políticas para um futuro sustentável. Rio de Janeiro: Relume Dumará, 2003. 299p.

GLAHN, H. R.; LOWRY D. L. The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. **Journal Applied Meteorology**, v. 11, n. 8, p. 1203 – 1211, Dec. 1972.

GOLDEMBERG, J.; LUCON, O. **Energia, meio ambiente e desenvolvimento**. 3. ed. São Paulo: Editora da Universidade de São Paulo - EDUSP, 2008. 396 pag. ISBN 978-314-1113-7.

GOLDENBERG, J.; VILLANUEVA, L. D. **Energia, meio ambiente & desenvolvimento**. 2. ed. São Paulo: Edusp – Editora da Universidade de São Paulo, 2003. 232p

GONÇALVES, A. R. **Refinamento estatístico das previsões de vento do modelo ETA aplicado ao setor eólico-elétrico do Nordeste brasileiro**. 2011. 177 p. (sid.inpe.br/mtc-m19/2012/02.27.17.24-TDI). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.

GONG, X.; RICHMAN, M. B. On the application of analysis to growing season precipitation data in North East of the Rockies. **J. Climate**, v. 8, p. 897-924, 1995.

GREISCHAR L.; HASTENRATH. S. The Rainy Season of the 1990s in the Northeast Brazil: Real-Time Forecasts and Verification. **Journal of Climate**, v.13, n. 1, p. 3821-3826, Nov. 2000.

GRELL, G.A., DEVENYI, D. A new approach to parameterizing convection using ensemble and data assimilation techniques. **Geophysical Research Letters**. v. 29, 1693, 2002.

GU, L.; BALDOCCHI, D. D.; WOFSY, S. C.; MUNGER, J. W.; MICHALSKY, J. J.; URBANSKI, S. P.; BODEN, T.A. Response of a deciduous forest to the Mount Pinatubo Eruption: enhanced photosynthesis. **Science**, v.299, n.5615, p.2035-2038, 2003.

GUARNIERI, R. A. **Emprego de redes neurais artificiais e regresso linear múltipla no refinamento das previsões de radiação solar do modelo ETA**. 2006. 171 p. (INPE-14172-TDI/1089). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

HAIR, Jr. J. F.; ANDERSON, R E; TATHAM, R. L; BLACK, W. C. **Análise multivariada de dados.** 5. ed. Porto Alegre: Bookman, 2005. 593 p. ISBN 85-363-0482-0.

HALKIDI, M.; BATISTAKIS, Y.; VAZIRGIANNIS, M. On clustering validation techniques, **Journal of Intelligent Information Systems**, v. 17, n. 2/3, p. 107-145, 2001.

HAYKIN, S. **Neural networks: a comprehensive foundation.** New York: Macmillan College Publishing Company, 1994.

HAYKIN, S. **Redes neurais: princípios e prática.** 2. ed. Porto Alegre: Bookman Companhia Editora, 2001. 900p.

HEYMSFIELD, A. J. **Microphysical structures of stratiform and cirrus clouds: aerosols-cloud-climate interactions.** Editor: P.V. Hobbs. San Diego, Califórnia: Academic Press, 1993. p.97-121.

HONG, S. –Y; JUANG, H. –M. H.; ZHAO, Q. Implementation of prognostic cloud scheme for a regional spectral model. **Monthly Weather Review**, v. 126, p. 2621-2639, 1998.

HUANG, G.; PAES, A. T. Posso usar o teste t de Student quando preciso comparar três ou mais grupo? Einstein: **Educação Continuada em Saúde**, v. 7, n. 2, p. 63-64, 2009.

HUBBERT, M. K. **Energy Resources a report to the Committee on Natural Resources.** Washington, D. C. – USA: National Academy of Sciences, 1962. 141p

IACONO M. J.; DELAMERE J. S.; MLAWER E.J.; SHEPHARD, M. W.; CLOUGH, S.A.; COLLINS W., Radiative forcing by long-lived greenhouse gases: Calculations with the AER radiative transfer models, **J. Geophys. Res.**, 113, D13103, 2008. doi:10.1029/2008JD009944.

IQBAL, M. **An introduction to solar radiation.** New York: Academic press, 1983.

JACKS, E.; BROWER, J.; DAGOSTARO, V.; DALLAVALLE, J. New NGM-based MOS guidance for maximum/minimum temperature, probability of precipitation, cloud amount, and sea surface wind. **Weather and Forecasting**, v. 5, n. 1, p.128-138, March 1990.

JANJIC, Z. I. The step-mountain eta coordinate model: Further developments on the convection, viscous sublayer, and turbulent closure schemes. **Monthly Weather Review**, v. 122, p. 927-945, 1994.

JUANG, H. M. H.; KANAMITSU, M. The NMC Nested Regional Spectral Model. **Monthly Weather Review**, Boston v.122, n.1, p.3-26. 1994.

KAIN, J. S.; FRITSCH, J. M. A one-dimensional entraining/ detraining plume model and its application in convective parameterization. **Journal of Atmospheric Science**, v. 47, p. 2784-2802, 1990.

KAIN, J. S; FRITSCH, J. M. Convective parameterization for mesoscale models: the Kain-Fritsch scheme. The representation of cumulus in numerical models. Boston: **American Meteorological Society**, v. 46, p. 165-177, 1993.

KASTEN, F. The Linke turbidity factor based on improved values of the integral Rayleigh optical thickness. **Solar Energy**, v.56, n.3, p.239-44, 1996.

KAUFMAN, Y. J.; FRASER, R. S. Confirmation of smokeparticles effect on clouds and climate forcing. **Science**, v.277, p.1636-1639, 1997.

KAUFMAN, Y. J.; NAKAJIMA, T. Effect of Amazon smoke on cloud microphysics and albedo - Analysis from satellite imagery. **J. Applied Meteor.**, v.32, n.4, p.729-744, 1993.

KAYANO, M. T.; ANDREOLI, R. V. Clima da Região Nordeste do Brasil. In: CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS, M. A. F. S. **Tempo e clima no brasil**. São Paulo: Oficina de Textos, 2009, cap. 14, p. 213-233.

KESSLER, M. C. E CORBELLA, O. D. Mapas da Radiação Solar diária total média mensal sobre superfície horizontal para o Rio Grande do Sul para os 12 meses do ano. In: CONGRESSO LATINO-AMERICANO DE ENERGIA SOLAR, 2., 1979, João Pessoa, PB. **Atas....** João Pessoa – Paraíba, 1979. v. 1. p. 61-80.

KIMBAL, H. H. Variations in the total and luminous solar radiation with geographical position in the United States. **Monthly Weather Review**, v. 47, n.11, p.769 – 793,1919.

KONDRATYEV K. YA. **Radiation in the atmospheric**. NewYork, USA: Academic Press, 1969. 912p.

KOUSKY, V. E. Frontal influences on Northeast Brazil. **Montly Weather Review**, v. 107, p. 1140-1153, 1979.

LANDIM, P. M. B. **Introdução aos métodos de estimação espacial para confecção de mapas**. Rio Claro: DGA, IGCE, UNESP. Lab. Geomatemática, 2000. 20 p. Texto Didático.

LEAL S. S. E TIBA C. Iluminância e irradiação solar global na região nordeste do Brasil. In: VI Congresso Internacional sobre Geração Distribuída e Energia no Meio Rural, 6, 2006, Campinas. **Anais...** Campinas: AGRENER, 2006. CD-Rom.

LECKNER, B. The spectral distribution of solar radiation at the Earth's surface – elements of a model. **Solar Energy**, 20, 2, 143-150, 1978.

LEFÈVRE, M.; WALD, L.; DIABATE´, L. Using reduced data sets ISCCP-B2 from the Meteosat satellites to assess surface solar irradiance. **Solar Energy** 81, 240–253, 2007.

LESTRADE, J. P. The effect of cloud layer plane albedo on global and diffuse isolation. **Solar Energy**. Elmsford, New York, v.44, n.22, p.115-121, 1990.

LIEPERT B. G.; KUKLA, G. J. Decline in solar radiation with increased horizontal variability in Germany between 1964–1990. **J. Climate**, v.10, n.1, p.2391-2401, 1997.

LIMA, A. E.; MOLION, L. C. B.; FILHO, M. F. G.; FIRMINO, J. L. N.; SILVA, A. O. R. Variabilidade interanual da profundidade óptica da atmosfera sobre Maceió, Al. **Revista Brasileira de Engenharia Agrícola e Ambiental.**, v.11, n.5, p.509-514, 2007.

LIMA, F. J. L.; AMANAJÁS, J. C.; GUEDES, R. V. S.; SILVA, E. M. Análises de Componente Principal e de Agrupamento para estudo de ventos para a geração de energia eólica na região do Ceará, Paraíba, Pernambuco e Rio Grande do Norte, Brasil. **Revista Ambiente & Água - An Interdisciplinary Journal of Applied Science**, v.5, p:188-201, 2010. Doi:10.4136/1980-993x

LIN, Y. L.; FARLEY, R. D.; ORVILLE, H. D. Bulk parameterization of the snow field in a cloud model. **Journal of Climate Appl. Meteorol.**, v. 22, p. 1065-1092, 1983.

LINARES-RODRÍGUEZ, A.; RUIZ-ARIAS J. A.; POZO-VÁZQUEZ D.; TOVAR-PESCADOR J. Generation of synthetic daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks. **Energy**. 36(8):5356e65. 2013.

LINARES-RODRIGUEZ, A.; RUIZ-ARIAS, J. A.; POZO-VAZQUEZ, D. An artificial neural networks ensemble model for estimating global solar radiation from Meteosat satellite images. **Energy**, 61, 636-645. <http://dx.doi.org/10.1016/j.energy.2013.09.008>, 2013.

LIU, K. N. **An introduction to atmospheric radiation**. New York: Academic Press Inc., 2002. 583 p.

LIU, K. N. On the Absorption, Reflection and Transmission of Solar Radiation in Cloudy Atmospheres. **J. Atmosphere Sciences**, v. 33, n.1, p.798-804, 1976.

LIU, K. N. **Radiation and cloud processes in the atmosphere: Theory, observation and modeling**. New York: Oxford, 1992. p.486.

LIU, D. L.; SCOTT, B. J. Estimating in Australia from rainfall and temperature observations. **Agricultural and Forest Meteorology**, v. 106, p. 41-59, 2001.

LOHMANN, S.; SCHILLINGS, C.; MAYER, B.; MEYER, R. Long-term variability of solar direct and global radiation derived from ISCCP data and comparison with reanalysis data. **Solar Energy**., v.80, n.11, p.1390-1401, 2006.

LORENZ, E. N. **Empirical orthogonal functions and statistical weather prediction**. Sci. Rep. n. 1, Cambridge Masschusetts (EUA), Statistical Forecasting Project Department of Meteorology, 49p. 1p51. 1956.

LORENZ, E.; SCHEIDSTEGER, T.; HURKA, J.; HEINEMANN, D.; KURZ, C. Regional PV power prediction for improved grid integration. **Prog, Photovolt: Res. Appl.** V. 19, p. 757-771, 2010. Doi: 10.1002/pip.1033.

MARTINS, F R.; PEREIRA, E. B.; SILVA S. DE A. B.; GUARNIERI, R. A. Variabilidade e tendências regionais dos recursos de energia solar no Brasil. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 14, 2006, Florianópolis. **Anais...** Florianópolis: SBMET, 2006. CD-Rom.

MARTINS, F. R., PEREIRA, E. B. Estudo comparativo da confiabilidade de estimativas de irradiação solar para o sudeste brasileiras obtidas a partir de

dados de satélite e por interpolação/extrapolação de dados de superfície.
Revista Brasileira de Geofísica. v. 29, n 2, p. 265-276, 2011.

MARTINS, F. R., PEREIRA, E. B., SILVA, S. A. B., ABREU, S. L., COLLE, S. Solar energy scenarios in Brasil, Parto one: Resource assessment. **Energy Policy**. v. 36, p. 2843-2854, 2008.

MARTINS, F. R.; PEREIRA, E. B.; GUARNIERI, R. A. SOLAR RADIATION FORECAST USING ARTIFICIAL NEURAL NETWORKS. **International Journal of Energy Science**, v. 2, p. 217-227, 2012.

MARTINS, F.R. **Influência do processo de determinação da cobertura de nuvens e dos aerossóis de queimada no modelo físico de radiação BRASIL-SR**. 2001. Tese de Doutorado - INPE, São José dos Campos.

MENDES, D.; MARENGO, J. A. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. **Theoretical and Applied Climatology**, v. 100, n. 3-4, p. 413-421, may 2010. doi:10.1007/s00704-009-0193-y

MENEGHETTI, G. T.; FERREIRA, N. J. Variabilidade sazonal e interanual da precipitação no Nordeste Brasileiro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 1685-1689. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15939-PRE/10549).

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada**: uma abordagem aplicada. Belo Horizonte, Editora UFMG, 2005.

MLAWER, E. J.; TAUBMAN, S. J.; BROWN, P. D.; IACONO, M. J.; CLOUGH, S. A. Radiative transfer for inhomogeneous atmosphere: Rrtm, a validated correlated-k model for the longwave. **J. Geophys. Res.**, v. 102, p. 16663-16682, 1997.

MOLION, L. C. B; BERNARDO, S. O. Uma revisão da dinâmica das chuvas no Nordeste brasileiro. **Revista Brasileira de Meteorologia**, v. 17, n. 1, p. 1-10, 2002.

MONIN, A. S.; OBUKHOV, A. M. Basic turbulence mixing laws in the atmospheric surface layer. Tr. Inst. **Teor. Geofiz. Akad. Nauk. SSSR**, v. 24, p. 163-187, 1954.

NICÁCIO, R. M. **Radiação Solar global e difusa em Maceió – Alagoas: medidas e modelos.** Maceió, AL, 107p, 2002. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas, Maceió, 2002.

NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South American. **Journal of Climatology**, v. 9, p.2464-2479, 1996.

OLADE. **Atlas de climatologia solar.** V. I. Quito – Equador, 1987.

PAIXÃO, E.; AULD, H.; MIRZA, M. M. Q.; KLAASSEN, J.; SHEPHARD, M. W. Regionalization of heavy rainfall to improve climatic design values for infrastructure: case study in Southern Ontario, Canada. **Hidrolog. Sci. J.**, v. 56, n. 7, p 1067-1089, 2011.

PALIATSOS, A.G., KAMBEZIDIS, H.D., ANTONIOU, A. Diffuse solar irradiation at a location in the Balkan Península. **Renewable Energy**. v. 28, p. 2147-2156, 2003.

PEREIRA, E. B.; MARTINS, F. R.; ABREU, S. L.; RUTHER, R. **Atlas brasileiro de energia solar.** São José dos Campos: INPE, 2006. 60p. ISBN 978-85-17-00030-0.

PEREIRA, E. B.; ABREU, S. L.; STUHLMANN, R.; RIELAND, M.; COLLE, S. Survey of the incident solar radiation in Brazil by the use of the METEOSAT satellite data. **Solar Energy**, v. 57, n. 2, p. 125-132, 1996.

PEREZ, R.; SEALS, R.; ZELENKA, A. Comparing satellite remote sensing and ground network measurements for the production of site/time specific irradiance data. **Solar Energy**, v. 60, n. 2, p. 89-96, 1997.

PIELKE, R. A. **Mesoscale meteorological modeling.** Academic Press. 676 p., 2002.

PRESCOTT, J. A. Evaporation from a water surface in relation to solar radiation. **Trans. R. Soc. Science Aust.**, v. 64, p. 114-118, 1940.

REED, R. **Pruning algorithms – a survey.** **IEEE Transactions on Neural Networks**, v.4, n.5, p. 740-746, 1993.

ROBINSON, N. (ed.) **Solar radiation.** Amsterdam: Elsevier Publishing Company, 1966. 347p.

RODERICK, M. L.; FARQUHAR, G. D.; BERRY, S. L.; NOBLE, I. R. On the direct effect of clouds and atmospheric particles on the productivity and structure of vegetation. **Oecologia**, v.129, n.1, p. 21–30, 2001.

ROESCH, A.; WILD, M.; OHMURA, A.; DUTTON, E. G.; LONG, C. N.; ZHANG, T. Assessment of BSRN radiation records for the computation of monthly means. **Atmos. Meas. Tech.**, v. 4, p. 339-354, 2011.

ROSENBERG, N. J.; BLAD, B. L.; VERMA, S. B. **Microclimate**: the biological environment. 2.ed. New York: John Wiley & Sons, 1983. 495p.

SCHILLINGS, C.; MEYER, R.; MANNSTEIN, H. Validation of a method for deriving high resolution direct normal irradiance from satellite data and application for the Arabian Peninsula. **Solar Energy**, v. 76, p. 485–497, 2003.

SEGAL, M. & DAVIS, J. The impact of deep cumulus reflection on the ground-level global irradiance. **Journal Applied Meteorology**, v. 31, p. 217-222, 1992.

SFETSOS A.; COONICK A.H. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligences techniques. **Solar Energy**, v. 68, p.169, 2000.

SILVA, A. A. G.; BRAGA, C. C.; OLIVEIRA, L. S. Análise de agrupamento aplicada ao regime pluviométrico da costa leste e norte do nordeste do Brasil. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 9., 1996, Campos do Jordão. **Anais...** Rio de Janeiro: SBMet, p. 231-235, 1996.

SILVA, B. B.; LOPOES, G. M.; AZEVEDO, P. V. Balanço de radiação em áreas irrigadas utilizando imagens LANDSAT 5 – TM. **Revista Brasileira de Meteorologia**, v.20, n.2, p. 243-252, 2005.

SILVA, P. R. T. **radiação solar global mensal para o estado de Alagoas - mapeamento**. 112 p. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas, Maceió, 2007.

SILVA, R. A.; SILVA, V. P. R.; CAVALCANTI, E. P.; SANTOS, D. N. Estudo da Variabilidade da radiação solar no Nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental.**, v. 14, n. 5, p.501-509, 2010.

SILVA, V. P. R.; CAVALCANTI, E. P.; BRAGA, C. C.; VIEIRA, P.V. **Evaluating trends in solar radiation based on data fields from the NCEP/NACR**

reanalysis and measurements, 7th EMS Annual Meeting / 8th ECAM. El Escorial (Madrid, Spain), October 2007.

SKAMAROCK, W. C.; KLEMP, J. B.; DUDHIA, J. et al. **Description of the Advanced Research WRF Version 3**. Boulder: National Center for Atmospheric Research, 2008.

SKAMAROCK, W. C.; KLEMP, J. B.; DUDHIA, J.; GILL, D. O.; BARKER, D. M.; WANG, W.; POWERS, J. G. **A Description of the Advanced Research WRF Version 2**. Boulder: National Center for Atmospheric Research, 2005.

SOARES, J.; OLIVEIRA, A. P.; BOZNAR, M. Z.; MLAKAR, P.; ESCOBEDO, J. F.; MACHADO, A. J. Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, v. 79, n. 2, p.201-214, 2004.

SOUZA, J.L. Irradiância solar no litoral do Nordeste: Avaliação Preliminar. In: X Congresso Brasileiro de Agrometeorologia, 1997, Piracicaba. **Anais...** Piracicaba: Sociedade Brasileira de Agrometeorologia, 1997. p.457-459.

SOUZA, J.L., NICÁCIO, R.M., LIMA MOURA, M.A. Global solar radiation measurements in Maceió, Brazil. **Renewable Energy**, v. 30, p. 1203-1220, 2005.

STUHLMANN, R.; RIELAND, M.; RASCHKE, E. An improvement of the IGMK model to derive total and diffuse solar radiation at the surface from satellite data. **Journal of Applied Meteorology**, v. 29, n. 7, p. 586-603, 1990.

SUEHRCKE, H. On the relationship between duration of sunshine and solar radiation on the earth's surface: Angstrom's equation revisited. **Solar Energy**, v.68, n.5, p. 417-425, 2000.

TANGANG, F. T.; HSUH, H.; TANG K. Forecasting the regional sea surface temperatures of the Tropical Pacific by neural networks model, with wind stress and sea level pressure as predictors. **Journal of Geophysical Research - Oceans**, v. 103, n. c4, p. 7511 –7522, Apr. 1998.

TENNANT, W. J. HEWITSON, B. C. Intra-seasonal rainfall characteristics and their importance to the seasonal prediction problem. **Int. J. Climatol.**, v. 22, n. 9, p. 1033-1048, 2002.

THOMPSON, G.; RASMUSSEN, R. M.; MANNING, K. Explicit forecasts of winter precipitation using an improved bulk microphysics scheme. Part I: Description and sensitivity analysis. **Monthly Weather Review**, v. 132, p. 519-542, 2004.

TIBA, C. **Atlas Solarimétrico do Brasil** – banco de dados terrestres. Recife: Editora Universitária da UFPE, 2000.

TIBA, C. **O Recurso solar no Brasil**. Tese (Doutorado em Energia Nuclear) - Universidade Federal de Pernambuco -UFPE. 110p, 2000.

TIBA, C.; FRAIDENRAICH, N.; LYRA, F.J.M.; NOGUEIRA, A. M. de B.; GROSSI GALLEGOS, H.; MoSZKOWINCZ, M.; CAVALCANTI, E.S.C. **Brazilian solarimetric atlas final technical report vol I to IV**. Agreement No 004 between the Federal University of Pernambuco (UFPE) and the Center for Energy Research (CEPEL), 1997.

TWOMEY, S. The influence of pollution on the shortwave albedo of clouds. **Journal of the Atmospheric Sciences**, v.34, p.1149-1152, 1977.

UVO, C. R. B. **A Zona de Convergência Intertropical (ZCIT) e sua relação com a precipitação da Região Norte do Nordeste Brasileiro**. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Brasil, 81f, 1989.

VALVERDE RAMÍREZ, M. C.; WEIGANG, L.; FERREIRA, N. J. Aplicação de redes neurais artificiais e transformada de ondeletas para estimativas de precipitação usando imagens do satélite GOES-8 : resultados preliminares. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 4. 1999, São José dos Campos. **Anais ...** São José dos Campos: ITA, 1999. p. 888-999. 1 CD-ROM.

VISLOCKY, R. L.; FRICHT, J.M. Generalized additive models versus linear regression in generating probabilistic MOS forecasts of aviation weather parameters. **Weather and Forecasting**, v. 10, n. 4, p. 669 – 680, Dec.1995.

WARD, J. H. Hierarchical grouping of optimize na objective function. **Journal of American Statistical Association**,v. 58, p. 236-244, 1963.

WEIGANG, L.;G.; SÀ, L.D.; PRASAD, G.S.; NOWOSAD, A.G; BOLZAN, M.J. e CHANG, E.S. Neural network adaptive waveletts for prediction of the Northeastern Brazil monthly rainfall anomalies time series. In: SPIES'S AEROSPACE DEFENSE SENSING AND CONTROLS SYMPOSIUM:

APPLICATIONS AND SCIENCE OF ARTIFICIAL NEURAL NETWORKS, 2., 8-12 April, 1996, Orlando. **Proceedings ...** Orlando: 1996, p.175 - 187.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. In: WESTERN ELECTRONIC SHOW AND CONVENTION (WESCON), 1960, Los Angeles, CA, EUA. **Proceedings...** Los Angeles: Institute of Radio Engineers - IRE, v. 4, p. 96-104, 1960.

WILD, M. [Global dimming and brightening](#): a review. **J. Geophys. Res.**, v. 114, D00D16, 2009. doi:10.1029/2008JD011470.

WILKS, D. S. **Statistical methods in the atmospheric sciences**. 2. ed. London: Academic Press, 2006. 649p.

WONG, L.T.; CHOW, W.K. Solar radiation model. **Applied Energy**. v.69, p.191-244, 2001.

YUVAL. Neural network training for prediction of climatological time series regularized by minimization of the generalized cross-validation function. **Monthly Weather Review**, v. 128, n. 5, p. 1456 – 1473, May 2000.

ANEXO A - LOCALIZAÇÃO DAS ESTAÇÕES USADAS NESTA PESQUISA

ESTACÕES	ID_SINÓTICO	ID	LONGITUDE	LATITUDE	ALTITUDE(m)	UF
SÃO LUIZ	A203	1	-44,21	-2,53	56	MA
CAROLINA	A205	2	-47,46	-7,34	192	MA
CHAPADINHA	A206	3	-43,35	-3,74	91	MA
GRAJAÚ	A207	4	-46,16	-5,82	230	MA
TURIAÇU	A219	5	-45,37	-1,66	41	MA
BACABAL	A220	6	-44,79	-4,23	28	MA
B DA CORDA	A221	7	-45,24	-5,51	153	MA
COLINAS	A222	8	-44,23	-6,03	179	MA
ESTREITO	A224	9	-47,42	-6,65	180	MA
CAXIAS	A237	10	-43,34	-4,82	76	MA
BURITICUPU	A238	11	-46,45	-4,32	175	MA
RECIFE	A301	12	-34,95	-8,05	10	PE
MACEIÓ	A303	13	-35,77	-9,55	64,5	AL
NATAL	A304	14	-35,2	-5,83	48,6	RN
FORTALEZA	A305	15	-38,53	-3,8	41	CE
SOBRAL	A306	16	-40,35	-3,75	64	CE
PETROLINA	A307	17	-40,8	-9,38	370,5	PE
PARNAÍBA	A308	18	-41,78	-3,07	79,5	PI
ARCO VERDE	A309	19	-37,08	-8,43	680,7	PE
AREIA	A310	20	-35,68	-6,97	574,6	PB
FLORIANO	A311	21	-43,02	-6,77	132,3	PI
TERESINA	A312	22	-42,8	-5,03	74	PI
CAMP GRANDE	A313	23	-35,91	-7,23	548	PB
GUARAMIRANGA	A314	24	-38,93	-4,26	38,2	CE
BARBALHA	A315	25	-39,27	-7,3	409	CE
CAICÓ	A316	26	-37,08	-6,47	170	RN
MACAU	A317	27	-36,72	-5,12	4	RN
MOSSORÓ	A318	28	-37,37	-5,08	36	RN
IGUATÚ	A319	29	-39,27	-6,4	233	CE
JOÃO PESSOA	A320	30	-34,85	-7,14	44	PB
PATOS	A321	31	-37,27	-7,07	249	PB
GARANHUS	A322	32	-36,5	-8,91	822	PE
P DE AÇUCAR	A323	33	-37,45	-9,77	19	AL
TAUÁ	A324	34	-40,28	-6,02	415	CE
QUIXERAMOBIM	A325	35	-39,29	-5,17	79,5	CE
B J DO PIAUÍ	A326	36	-44,33	-9,08	297	PI

P DOS ÍNDIOS	A327	37	-36,62	-9,42	275	AL
SURUBIM	A328	38	-35,8	-7,84	418	PE
CABROBRO	A329	39	-39,31	-8,5	342	PE
PAULISTANA	A330	40	-41,14	-8,13	374	PI
S J DO PIAUÍ	A331	41	-42,25	-8,36	235	PI
MORADA NOVA	A332	42	-38,36	-5,14	43,6	CE
S GONÇALO	A333	43	-38,31	-6,84	234	PB
MONTEIRO	A334	44	-37,12	-7,89	604	PB
PIRIPIRI	A335	45	-41,79	-4,28	161	PI
A DO GURGEIA	A336	46	-43,86	-8,44	270	PI
CARACOL	A337	47	-43,32	-9,29	100	PI
ESPERANTINA	A338	48	-42,26	-3,9	65	PI
JAGUARUANA	A339	49	-37,78	-4,79	12	CE
APODI	A340	50	-37,83	-5,63	150	RN
CARUARU	A341	51	-35,99	-8,24	550	PE
CRATÉUS	A342	52	-40,67	-5,19	291	CE
PICOS	A343	53	-41,4	-7,07	233	PI
CALCANHAR	A344	54	-35,49	-5,16	17	RN
S R NONATO	A345	55	-42,7	-9,03	402	PI
URUÇU	A346	56	-44,33	-7,47	393	PI
C SALES	A347	57	-40,36	-7,08	572	CE
CABACEIRAS	A348	58	-36,29	-7,48	436	PB
IBIMIRIM	A349	59	-37,71	-8,51	448	PE
S TALHADA	A350	60	-38,29	-7,95	461	PE
CAMARATUBA	A352	61	-35,13	-6,61	136	PB
ARAPIRACA	A353	62	-36,62	-9,8	241	AL
OEIRAS	A354	63	-42,15	-6,97	156	PI
CORURIFE	A355	64	-36,29	-10,13	74	AL
S L DO QUITUNDE	A356	65	-35,57	-9,29	19	AL
PALMARES	A357	66	-35,57	-8,67	180	PE
JAGUARIBE	A358	67	-38,63	-5,91	184	CE
ITAPIPOCA	A359	68	-39,59	-3,48	102	CE
ACARAU	A360	69	-40,09	-3,12	76	CE
C DO PIAUÍ	A361	70	-41,51	-5,35	286	PI
S P DO PIAUÍ	A362	71	-42,72	-5,91	287	PI
V DO PIAUÍ	A363	72	-41,74	-6,4	301	PI
GIUBUÉS	A364	73	-45,35	-9,87	425	PI
BURITI	A365	74	-42,97	-8,12	308	PI
OURICURI	A366	75	-40,1	-7,88	464	PE
SANTA CRUZ	A367	76	-45,02	-13,02	237	RN

SALVADOR	A401	77	-38,51	-13,01	51,4	BA
BARREIRA	A402	78	-45,02	-12,15	470,4	BA
AREMBEPE	A403	79	-38,17	-12,75	10,8	BA
L E MAGALHÃES	A404	80	-45,82	-12,15	754	BA
CARAVELAS	A405	81	-39,25	-17,73	2,9	BA
C DAS ALMAS	A406	82	-39,15	-12,67	225,9	BA
ITIRUÇU	A407	83	-40,12	-13,53	755,6	BA
ITABERABA	A408	84	-40,28	-12,52	249,9	BA
ARACAJÚ	A409	85	-37,05	-10,95	4,7	SE
ILHÉUS	A410	86	-39,17	-14,65	78	BA
P AFONSO	A411	87	-38,22	-9,37	252,6	BA
MACAJUBA	A412	88	-40,35	-12,12	380	BA
F DE SNATANA	A413	89	-38,99	-12,2	231	BA
S R DE CASSIA	A415	90	-44,53	-11,02	450	BA
CORRENTINA	A416	91	-44,62	-13,33	540	BA
ITABAIANINHA	A417	92	-37,79	-11,27	208	SE
B J DA LAPA	A418	93	-43,18	-13,42	440	BA
POÇO VERDE	A419	94	-38,11	-10,74	362	SE
CARIRA	A420	95	-37,75	-10,4	308	SE
BREJO GRANDE	A421	96	-36,48	-10,47	10	SE
ABROLHOS	A422	97	-38,69	-17,96	25	BA
REMANSO	A423	98	-42,08	-9,62	401	BA
IRECÊ	A424	99	-41,86	-11,33	755	BA
LENÇÓIS	A425	100	-41,39	-12,56	439	BA
GUANAMBI	A426	101	-42,75	-14,21	882	BA
P SEGURO	A427	102	-39,18	-16,39	85	BA
Sºr DO BOM FIM	A428	103	-40,15	-10,44	548	BA
BARRA	A429	104	-43,14	-11,08	403	BA
PIATÃ	A430	105	-41,77	-13,16	1290	BA
CONDE	A431	106	-37,62	-11,81	10	BA
BURITIRAMA	A432	107	-43,65	-10,72	502	BA
BRUMADO	A433	108	-41,67	-14,18	470	BA
AMARGOSA	A434	109	-39,62	-13,01	407	BA
UAUA	A435	110	-39,5	-9,83	453	BA
QUEIMADAS	A436	111	-39,62	-10,98	315	BA
UNA	A437	112	-39,09	-15,28	82	BA
MARAU	A438	113	-38,97	-13,91	10	BA
IBOTIRAMA	A439	114	-43,21	-12,19	430	BA
JACOBINA	A440	115	-40,47	-11,21	453	BA
SERRINHA	A441	116	-39,02	-11,66	339	BA

E DA CUNHA	A442	117	-39	-10,54	432	BA
DEUFINO	A443	118	-41,21	-10,46	637	BA
IPIAU	A445	119	-39,69	-14,17	125	BA
ITAPETINGA	A446	120	-40,23	-15,24	269	BA
BELMONTE	A447	121	-39,22	-16,09	88	BA

