



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/11.30.10.55-TDI

## **IMPACTO DO AJUSTE DA MATRIZ DE COVARIÂNCIA DOS ERROS DO BACKGROUND NA ASSIMILAÇÃO DE DADOS DE RADAR**

André Muniz Marinho da Rocha

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Meteorologia, orientada pelo Dr.  
Dirceu Luis Herdies, aprovada em  
03 de outubro de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3MSRH7H>>

INPE  
São José dos Campos  
2017

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO  
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

**Membros:**

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial (ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

**EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/11.30.10.55-TDI

## **IMPACTO DO AJUSTE DA MATRIZ DE COVARIÂNCIA DOS ERROS DO BACKGROUND NA ASSIMILAÇÃO DE DADOS DE RADAR**

André Muniz Marinho da Rocha

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Meteorologia, orientada pelo Dr.  
Dirceu Luis Herdies, aprovada em  
03 de outubro de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3MSRH7H>>

INPE  
São José dos Campos  
2017

Dados Internacionais de Catalogação na Publicação (CIP)

---

Rocha, André Muniz Marinho da.

R582i Impacto do ajuste da matriz de covariância dos erros do background na assimilação de dados de radar / André Muniz Marinho da Rocha. – São José dos Campos : INPE, 2017.  
xxiv + 59 p. ; (sid.inpe.br/mtc-m21b/2016/11.30.10.55-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.  
Orientador : Dr. Dirceu Luis Herdies.

1. Assimilação de dados de radar. 2. Precipitação. 3. 3D-VAR.  
I.Título.

CDU 551.509.3

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

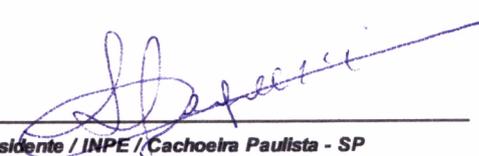
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **André Muniz Marinho da Rocha**

Título: "IMPACTO DO AJUSTE DA MATRIZ DE COVARIÂNCIA DOS ERROS DE BACKGROUND NA ASSIMILAÇÃO DE DADOS DE RADAR"

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Meteorologia**

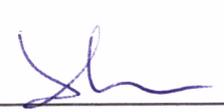
Dr. Luiz Fernando Sapucci



---

Presidente / INPE / Cachoeira Paulista - SP

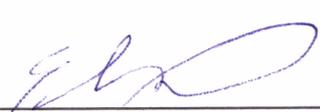
Dr. Dirceu Luis Herdies



---

Orientador(a) / INPE / Cachoeira Paulista - SP

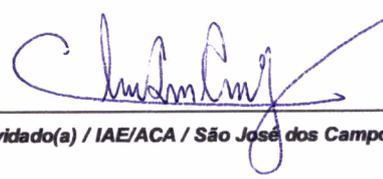
Dr. Éder Paulo Vendrasco



---

Membro da Banca / INPE / Cachoeira Paulista - SP

Dr. Cleber Souza Correa



---

Convidado(a) / IAE/ACA / São José dos Campos - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 03 de outubro de 2016



*“Graças Te rendemos, Grande Arquiteto do Universo, porque, por Tua Bondade e Misericórdia, nos tem sido possível vencer as dificuldades interpostas em nosso caminho, para nos reunirmos aqui, em Teu Nome, e prosseguirmos em nosso labor. Faz, Senhor, com que nossos corações e inteligências sejam sempre iluminados pela Luz que vem do Alto e que, fortificados por Teu Amor e Bondade, possamos compreender que para nosso trabalho ser coroado de Êxito, é necessário que em nossas deliberações, subjuguemos paixões e intransigências, à fiel obediência dos sublimes princípios da Fraternidade”.*

*Autor desconhecido.*



*A Minha Esposa Valeria, aos meus filhos Pedro Emanuel e Gabriel Kadosh, e a minha filha Sara Elizabete que me acompanharam nesta jornada.*



## **AGRADECIMENTOS**

Agradeço a Deus por ter me concedido Saúde, Sabedoria e Segurança durante esta caminhada.

Ao meu orientador, Dr. Dirceu Luis Herdies, e ao Dr. Éder Paulo Vendrasco, pela cordialidade, orientação e incentivo no tema escolhido para estudo.

Ao meu Cordial Real Amigo e incentivador Coronel Especialista em Meteorologia Cleber Souza Corrêa.

Aos meus amigos Claudio Montalvão Rodrigues, Leonardo Nascimento Lima e Rute Costa Ferreira que me apoiaram durante o curso de Mestrado.

Ao Departamento de Controle do Espaço Aéreo (DECEA), por ter possibilitado o acesso ao Mestrado em Meteorologia.

Ao INPE, pela oportunidade do aumento de conhecimento.

Ao Instituto de Controle do Espaço Aéreo (ICEA), em especial às pessoas do Coronel Aviador Manoel Araujo da Costa Junior, do Tenente Coronel Aviador Alexandre de Barros Barreto, do Tenente Coronel Especialista em Meteorologia Gerson Gabriel da Silva, Tenente Coronel Especialista em Meteorologia José Avanir Machado Nogueira Filho e do Capitão Especialista em Meteorologia José Hélio Abreu Nogueira, pelo apoio durante o período do Programa de Mestrado.



## RESUMO

A assimilação de dados combina as informações de modelos numéricos e as observações meteorológicas, através de um processo físico-estatístico, gerando a melhor representação possível do estado da atmosfera em um dado instante de tempo. O objetivo deste trabalho é ajustar a matriz covariância do erro de *background* dentro do ciclo de assimilação de dados de radar Doppler, a fim de melhorar a análise e, como consequência, as previsões de precipitação de curto prazo. O modelo atmosférico e o sistema de assimilação utilizados são o *Weather Research and Forecasting* (WRF) e o *WRF Data Assimilation* (WRFDA) 3D-Var. O domínio abrange o oeste do sul do Brasil, incluindo os estados do Paraná, Santa Catarina e Rio Grande do Sul e parte do Paraguai com resolução horizontal de 2 km e 45 níveis. O período de estudo é de 15 de outubro a 15 de novembro de 2014, com a avaliação da precipitação feita comparando os resultados da modelagem com os dados do *Tropical Rainfall Measuring Mission* (TRMM) 3B42, usando os índices estatístico *Root Mean Square Error* (RMSE). Os outros campos meteorológicos também foram avaliados usando o mesmo índice estatísticos comparando-o com as observações de superfície. Observações das Estações meteorológicas de superfície foram usadas para comparação com os resultados do modelo com e sem assimilação de dados do radar. As estações selecionadas foram Curitiba, Bacacheri, Londrina e Foz do Iguaçu. Durante o processo de assimilação, os dados convencionais do *Global Telecommunication System* também foram assimilados. A matriz de covariância do erro de *background* foi gerada utilizando um utilitário do WRFDA aplicando o método NMC com 03 meses de simulações de 24 h a partir de 00UTC e 12UTC. O processo de geração da matriz B espalha horizontalmente as informações de uma determinada observação usando um filtro recursivo, em seguida, o ajuste da matriz de covariância do erro de *background* foi aplicado, ajustando os parâmetros *variance scaling*, relacionada com a intensidade com que cada observação irá influenciar as variáveis de estado nos pontos da grade do modelo, e o *length scaling*, relacionada com a influência do erro em escala de distância nos valores dos pontos da grade das variáveis de estado do modelo, de modo a ajustá-los para a região de estudo, os dados assimilados e o sistema meteorológico estudado. Foram testados diversos valores dos dois parâmetros e os resultados baseado no índice estatístico mostrou melhorias na previsão da localização e intensidade da precipitação quando aplicado os ajustes na matriz de covariância do erro de *background*.

Palavras-chave: Assimilação de dados de radar. Precipitação. 3D-VAR.



# **THE IMPACT OF TUNING THE BACKGROUND COVARIANCE ERROR MATRIX ON THE RADAR DATA ASSIMILATION**

## **ABSTRACT**

Data assimilation combines the information from numerical models and meteorological observations through a physical-statistical process generating the best representation of atmospheric state in a moment of time. The goal of this work is to tune the background error covariance matrix while assimilating Doppler radar data in order to improve the analysis and then the short-term precipitation forecast. The atmospheric model and the assimilation system used are the Weather Research and Forecasting (WRF) and the WRF Data Assimilation (WRFDA) 3D-Var. The domain covers the west of Southern Brazil, including the state of Parana, Santa Catarina and Rio Grande do Sul and part of Paraguay with horizontal resolution of 2-km and 45 levels. The period of study is from October 15 to November 15, 2014, and the evaluation of the precipitation was made by comparing the results from modeling against the Tropical Rainfall Measuring Mission (TRMM) 3B42 data, using statistical index such the Root Mean Square Error (RMSE). The other meteorological fields were also evaluated using the same statistical indice comparing them to the surface observations. Observations of the surface weather stations were used for comparison with the model results with and without radar data assimilation. The selected stations were Curitiba, Bacacheri, Londrina and Foz do Iguaçu. During the assimilation process, the conventional data from Global Telecommunication System was also assimilated. The background error covariance matrix was generated using utility WRFDA applying the NMC method with 03 months of simulations of 24-h starting at 00UTC and 12UTC. The process of generating the matrix B horizontally spreads the information from a specific observation using a recursive filter, and then setting the error covariance matrix background was applied by adjusting the parameters variance scaling related to the intensity at each observation will influence the state variables in the model grid points, and the length scaling, related to the influence of the error in distance scale the values of the grid points of the model state variables, in order to adjust them to the region study, the assimilated data and the weather system studied. Different values of the two parameters were tested and the results based on statistical indicator showed improvements in predicting the location and intensity of precipitation when applied adjustments to the covariance matrix of background error.

Key words: Radar data assimilation. Precipitation. 3D-VAR.



## LISTA DE FIGURAS

**Pág.**

Figura 3.1: Localização dos radares e estações de controle e a grade do modelo. ....	14
Figura 3.2: Localização dos radares, estações de controle e a grade do modelo. ....	15
Figura 3.3: Representação esquemática do sistema de modelagem. Adaptado de ARW V3 <i>Modeling System User's Guide</i> , 2011. ....	16
Figura 3.4: Amplitude da variável <i>length scaling</i> e o quanto em quilômetros cada observação irá influenciar nos pontos da grade do modelo.....	20
Figura 3.5: Amplitude da variável <i>variance scaling</i> e a intensidade com que cada observação irá influenciar nos pontos da grade do modelo.....	20
Figura 3.6: Ciclo de assimilação de dados de 01 hora.....	24
Figura 3.7: Ciclo de assimilação de dados de GTS e SPINUP. ....	25
Figura 3.8: Ciclo de assimilação de dados de radar com previsão para as 12 e 18 horas. ....	25
Figura 4.1: Precipitação acumulada das últimas 06 horas para às 12 horas (a) e 18 horas (b).....	34
Figura 4.2: Imagem de satélite (visível) do dia 07/11/2014 às 12 horas (a) e 18 horas(b).....	35
Figura 4.3: Imagem de satélite (realçada) do dia 07/11/2014 às 12 horas (a) e 18 horas (b).....	36
Figura 4.4: Imagem de satélite (infravermelho) do dia 07/11/2014 às 12 horas (a) e 18 horas (b).....	36
Figura 4.5: Carta sinótica de superfície do Grupo de Previsão do Tempo (GPT/CPTEC) do dia 07/11/2014 às 00:00 horas Z. ....	37
Figura 4.6: CAPPI em 3km dos radares de Cascavel e Assunção dia 07/11/2014 às 12 horas.....	38
Figura 4.7.: Resultados da previsão de precipitação acumulada em 06 horas entre 06 e 12 horas do dia 07/11/2014, com as rodadas sem spin up, Figura 4.7.b, com spin up Figura 4.7.c, com assimilação de dados GTS (com as variações de <i>variance scale</i> e <i>length scaling</i> ), Figura 4.7.d com <i>variance scale</i> = 0.5 e <i>length scaling</i> = 2.0, Figura 4.7.e com <i>variance scale</i> = 1.0 e <i>length scaling</i> = 1.0 e Figura 4.7.f com <i>variance scale</i> = 2.0 e <i>length scaling</i> = 0.5, e com a assimilação de dados de radar (com as variações de <i>variance scale</i> e <i>length scaling</i> ), Figura 4.7.g com <i>variance scale</i> = 0.5 e <i>length scaling</i> = 2.0, Figura 4.7.h com <i>variance scale</i> = 1.0 e <i>length scaling</i> = 1.0 e Figura 4.7.i com <i>variance scale</i> = 2.0 e <i>length scaling</i> = 0.5 e comparação com o <i>Tropical Rainfall Measuring Mission</i> (TRMM), 3B42, versão 07, Figura 4.7.a como controle. ....	41
Figura 4.8: Resultados da previsão de precipitação acumulada em 06 horas entre 12 e 18 horas do dia 07/11/2014, com as rodadas sem spin up, Figura 4.8.b, com spin up Figura 4.8.c, com assimilação de dados GTS (com as	

variações de <i>variance scale</i> e <i>lenght scaling</i> ), Figura 4.8.d com <i>variance scale</i> = 0.5 e <i>lenght scaling</i> = 2.0, Figura 4.8.e com <i>variance scale</i> = 1.0 e <i>lenght scaling</i> = 1.0 e Figura 4.8.f com <i>variance scale</i> = 2.0 e <i>lenght scaling</i> = 0.5, e com a assimilação de dados de radar (com as variações de <i>variance scale</i> e <i>lenght scaling</i> ), Figura 4.8.g com <i>variance scale</i> = 0.5 e <i>lenght scaling</i> = 2.0, Figura 4.8.h com <i>variance scale</i> = 1.0 e <i>lenght scaling</i> = 1.0 e Figura 4.8.i com <i>variance scale</i> = 2.0 e <i>lenght scaling</i> = 0.5 e comparação com o <i>Tropical Rainfall Measuring Mission</i> (TRMM), 3B42, versão 07, Figura 4.8.a como controle. ....	45
Figura 4.9: Comparação do RMSE da precipitação com 40 km das 12:00 horas. ....	46
Figura 4.10: Comparação do RMSE com 40 km das 12:00 horas sem <i>spin up</i> e com <i>spin up</i> . ....	47
Figura 4.11: Comparação do RMSE com 40 km das 12:00 horas com <i>spin up</i> , com assimilação de dados de GTS e variações de <i>variance scale</i> e <i>lenght scaling</i> . ....	47
Figura 4.12: Comparação do RMSE com 40 km das 12:00 horas com <i>spin up</i> , com assimilação de dados de GTS, com assimilação de dados de radar e variações de <i>variance scale</i> e <i>lenght scaling</i> . ....	48
Figura 4.13: Comparação do RMSE com 40 km das 18:00 horas. ....	48
Figura 4.14: Comparação do RMSE com 40 km das 18:00 horas sem <i>spin up</i> e com <i>spin up</i> . ....	49
Figura 4.15: Comparação do RMSE com 40 km das 18:00 horas com <i>spin up</i> , com assimilação de dados de GTS e variações de <i>variance scale</i> e <i>lenght scaling</i> . ....	50
Figura 4.16: Comparação do RMSE com 40 km das 18:00 horas com <i>spin up</i> , com assimilação de dados de GTS, com assimilação de dados de radar e variações de <i>variance scale</i> e <i>lenght scaling</i> . ....	50

## LISTA DE TABELAS

	<b><u>Pág.</u></b>
Tabela 3.1: Dados GTS assimilados. ....	13
Tabela 3.2: Variação da configuração dos valores admencionais de <i>variance scale</i> e <i>lenght scaling</i> . ....	29
Tabela 4.1: Dados horários de precipitação em mm de Curitiba – PR (SBCT).31	31
Tabela 4.2: Dados horários de precipitação em mm de Foz do Iguaçu – PR (SBFI). ....	32
Tabela 4.3: Dados horários de precipitação em mm de Bacacheri – PR (SBBI). ....	32
Tabela 4.4: Dados horários de precipitação em mm de Londrina – PR (SBLO). ....	33



## LISTA DE SIGLAS E ABREVIATURAS

3D-VAR	Análise Variacional Tridimensional
4D-VAR	Análise Variacional Quadridimensional
AFWA	<i>Air Force Weather Agency</i>
B	Matriz de Covariâncias dos erros do <i>Background</i>
CAPPI	<i>Constant Altitude Plan Position Indicator</i>
CI	Condição Inicial
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
DECEA	Departamento de Controle do Espaço Aéreo
DINAC	<i>Dirección Nacional de Aeronáutica Civil</i>
DSA/CPTEC	Divisão de Satélites
DTC	<i>Developmental Testbed Center</i>
FSL	<i>Forecast Systems Laboratory</i>
FK	<i>Filtro de Kalman</i>
GFS	<i>Global Forecast System</i>
GTS	<i>Global Telecommunications System</i>
ICEA	Instituto de Controle do Espaço Aéreo
INPE	Instituto Nacional de Pesquisas Espaciais
IO	Interpolação Ótima
LF	Data final da análise mais o tempo de previsão
LI	Data inicial da análise
MMQ	Método dos Mínimos Quadrados
METAR	<i>Meteorological Aerodrome Report</i>
NCAR	<i>National Center for Atmospheric Research</i>
NCEP	<i>National Center for Environmental Prediction</i>
NCIC	Número total de ciclos
NMC	<i>National Meteorological Center</i>
NMM	<i>Nonhydrostatic Mesoscale Model</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
PNT	Previsão Numérica do Tempo
PPI	Indicador de Posição no Plano

RADAR	<i>Radio Detection and Ranging</i>
RDA	<i>Research Data Archive</i>
RMSE	<i>Root Mean Square Error</i>
SID	Sistema de Informação e Documentação
SIMEPAR	Sistema Meteorológico do Paraná
SYNOP	<i>Surface Synoptic Observations</i>
SPG	Serviço de Pós-Graduação
TCIC	Tempo de ciclos
TDI	Teses e Dissertações Internas
TRMM	<i>Tropical Rainfall Measuring Mission</i>
WRF	<i>Weather Research and Forecasting model</i>
WRFDA	<i>Weather Research and Forecasting model Data Assimilation system</i>

## LISTA DE SÍMBOLOS

	<b><u>Pág.</u></b>
$\varepsilon$ Verdadeiro erro do <i>background</i>	22
$\rho$ Densidade	23
$\alpha$ Filtro recursivo	24



## SUMÁRIO

	<b><u>Pág.</u></b>
<b>1 INTRODUÇÃO .....</b>	<b>1</b>
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>5</b>
<b>3 MATERIAL E MÉTODOS .....</b>	<b>11</b>
3.1. Dados utilizados .....	11
3.2. Modelo atmosférico wrf .....	15
3.2.1 WRFDA .....	18
3.2.2 Método 3D-VAR .....	20
3.3 Radar.....	26
3.4 Metodologia de avaliação.....	29
3.4.1 Avaliação.....	30
<b>4 RESULTADOS .....</b>	<b>31</b>
4.1 Análise sinótica .....	31
4.2 Resultados para precipitação .....	38
4.3 Resultados do RMSE para precipitação.....	46
<b>5 CONCLUSÃO .....</b>	<b>51</b>
5.1 Sugestões para trabalhos futuros.....	53
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>55</b>



## 1 INTRODUÇÃO

Diversas áreas da sociedade são extremamente afetadas por tempestades severas, tais como linhas de instabilidade e convecções profundas. Esses eventos apresentam grandes desafios à meteorologia na capacidade de fornecer uma previsão detalhada com antecedência suficiente que auxilie as autoridades competentes na hora da tomada de decisão, com medidas preventivas contra os eventuais danos econômicos e sociais. Portanto, para previsão desses eventos meteorológicos severos, são utilizados modelos de previsão numérica do tempo (PNT), como *nowcasting*, para simulação e previsão do comportamento atmosférico em escala global, regional e local.

A obtenção de uma PNT com qualidade é uma tarefa complexa que tem como uma das dificuldades a solução das equações diferenciais, a qual depende de uma condição inicial, para que se tenha uma solução única. A PNT é, portanto, considerada como um problema de condição inicial, no qual uma maior precisão das informações iniciais poderá levar a uma maior probabilidade de se obter a solução mais próxima da realidade. No modelo, para que seja gerada a análise, é preciso contar com duas informações essenciais: o *background*, que tanto pode ser a climatológica, quanto uma previsão gerada anteriormente e as observações. Sabe-se que o verdadeiro estado da atmosfera jamais poderá ser totalmente representado, uma vez que o modelo não é perfeito e as observações são insuficientes. A análise final é dita como o verdadeiro estado do modelo, sendo a melhor representação possível alcançada na resolução do modelo, pois mesmo se as observações não possuísem erros e a análise fosse igual ao estado verdadeiro, ainda assim existiria diferença entre os valores observados e seus equivalentes na análise, em virtude dos erros de representatividade.

Dentro desta perspectiva, o processo de assimilação de dados é o método pelo qual as observações são combinadas com um modelo de PNT, visando uma melhor aproximação do estado inicial da atmosfera de forma mais completa e realista, melhorando a condição inicial dos modelos e a previsão. A importância deste processo acontece em virtude das observações meteorológicas serem

distribuídas no espaço e no tempo de modo irregular e para suprir essa deficiência tais informações são reunidas e combinadas com os dados do modelo, atribuindo para cada uma pesos conforme características e confiabilidade. Os avanços nas técnicas de assimilação de dados permitem também a extração de informações a partir de observações indiretamente correlacionadas com as variáveis prognósticas do modelo. Dentre os dados que podem ser assimilados pelo modelo têm-se os dados de radar Doppler, que usa ondas eletromagnéticas para investigar as propriedades atmosféricas, sendo que a amplitude estima a refletividade e a fase estima o vento radial.

No Brasil, apesar de existirem radares com cobertura em várias regiões do país, estes dados não são assimilados na modelagem de mesoescala de forma operacional devido ao incipiente conhecimento sobre o procedimento da assimilação bem como os impactos causados por essas medidas. O Brasil contará em 2016 com pelo menos 40 radares em operação e a assimilação desses dados seria possível na maior parte do território nacional. Assim, tal estudo torna-se de grande importância para as pesquisas em assimilação de dados de radar nos centros operacionais como o Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), com possíveis aplicações nas atividades operacionais a elas associadas, visando uma melhora dos prognósticos e para seu uso mais efetivo.

O desenvolvimento de um esquema eficiente de assimilação de dados de radar em um modelo necessita de um grande conhecimento sobre as informações do radar, do modelo e das técnicas de assimilação de dados. Neste sentido busca-se o ajuste da matriz de covariância dos erros de *background* dentro do ciclo de assimilação de dados do radar Doppler, visando uma melhoria da qualidade da análise e, como consequência, das previsões de curto prazo de precipitação provenientes de tais análises. Vários autores indicam a necessidade de ajustes na matriz de covariância dos erros do *background*, visando o melhor ajuste desta matriz com a região, escala horizontal e tipo de sistema a ser estudado (HA e LEE, 2012; TONG et al., 2014), além de

questões relacionadas ao balanço dos campos dinâmicos e microfísicos da análise (GUO et al., 2007; MING et al., 2009).

Vendrasco (2015) mostrou que o sistema de assimilação de dados WRFDA/3D-VAR, a assimilação direta de refletividade do radar apresenta algumas limitações, mas que podem ser amenizadas com o emprego da assimilação indireta desta variável, confirmando os resultados de Wang et al. (2013). Conforme Vendrasco (2015) a assimilação de dados de radar indireta reproduz relativamente bem os sistemas de precipitação e sua intensidade, ao passo que quando a assimilação de refletividade é usada de maneira direta, apesar do bom posicionamento, não é capaz de desenvolver-se e produzir a precipitação observada pelo radar. Ainda no trabalho de Vendrasco (2015) os melhores resultados foram obtidos quando foram utilizadas duas variáveis: refletividade e vento radial (ao mesmo tempo).

O presente trabalho buscou o uso indireto de dados de umidade e velocidade dos hidrometeoros contidos na atmosfera para melhora da previsão do posicionamento dos núcleos convectivos e precisão da localização da precipitação, bem como fornecer melhores resultados aos centros operacionais de previsão do tempo de curto prazo. Assim, buscou-se um melhor desempenho na assimilação de dados de radar e uma melhor previsão da precipitação, bem como um estudo mais acurado destes sistemas visando uma previsão de curto prazo, 06 horas, de forma que os resultados deste trabalho possam ser utilizados de forma operacional, uma vez que estas implementações ainda não existem no país.

Para isto no Capítulo 2, neste trabalho, será feita uma revisão bibliográfica da assimilação de dados e o sistema 3D-VAR. Já no Capítulo 3 há a apresentação dos materiais e métodos utilizados na obtenção dos resultados. No Capítulo 4 será realizada a análise dos resultados com a variação dos parâmetros de *variance scaling* e *length scaling* e seus respectivos impactos na assimilação de dados de radar meteorológico. Por fim no Capítulo 5 apresenta-se as conclusões sobre o impacto do ajuste da matriz covariância do erro do *background* dentro do ciclo de assimilação de dados do radar Doppler com o

ajuste dos parâmetros *variance scaling* e *length scaling*, bem como as sugestões para trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

As técnicas de assimilação de dados em mesoescala evoluíram muito durante os últimos anos, impulsionada pelo avanço tecnológico e maior disponibilidade de dados observacionais, principalmente de satélite e radar.

A melhor estimativa do estado da atmosfera é a análise, obtida pela combinação da informação inicial da atmosfera, *background*, com as observações, visando à combinação otimizada, em que se faz necessário o uso das informações estatísticas dos erros dos conjuntos de dados. Com isto, tem-se o desenvolvimento das técnicas estatísticas de assimilação de dados, como Interpolação Ótima (IO), 3D-VAR, 4D-VAR e Filtro de Kalman (FK) (KALNAY, 2003). A análise é usada como condição inicial para os modelos numéricos de tempo. A principal informação para produzir a análise é o conjunto de valores observados do verdadeiro estado da atmosfera em um determinado instante de tempo. Caso haja observações suficientes que definam a atmosfera, então a análise é apenas uma interpolação, porém não é o que ocorre, uma vez que as observações são esparsas e relacionadas às variáveis meteorológicas de forma indireta (LORENC, 1986). Para gerar uma análise faz-se necessário o uso das informações de *background*, na forma de uma estimativa de curto prazo, em geral de 6 horas de previsão do modelo.

No Brasil é recente a assimilação de dados de radares meteorológicos nos modelos de previsão meteorológicas em virtude da dificuldade da disponibilização de dados de radar (refletividade e vento radial). Neste cenário pode-se citar o trabalho de Silva et al. (2012), como também o estudo de caso da assimilação de refletividade de radar (SANTOS et al., 2012), que usaram o 3D-VAR no MBAR operado pelo Instituto Nacional de Meteorologia (INMET). Pode-se citar também o trabalho de Vendrasco et al. (2012) que usou a assimilação de dados de radar para melhorar a previsão de curto prazo de precipitação no Vale do Paraíba.

Uma questão importante sobre o uso de observações de radar para PNT é a possibilidade de se derivar as variáveis de estado atmosféricos necessários

para a inicialização de um modelo de alta resolução a partir das observações de um único radar Doppler, uma vez que o espaçamento de redes de radar Doppler operacional não é suficiente para fornecer cobertura por mais de um radar no mesmo local (SUN, 2006). Segundo Aksoy et al. (2009) observações com radar Doppler de refletividade e as componentes do vento radial, têm sido utilizadas em sistemas complexos de assimilação de dados com o intuito de melhorar as condições iniciais de modelos de alta resolução, uma vez que estes dados são em grande parte a única fonte de informação tridimensionais nesta escala. As principais variáveis para a inicialização de um modelo numérico de escala convectiva são recuperadas a partir das informações de vento radial e refletividade, que são observados pelo radar, onde no processo de assimilação é realizado através de um operador observação que faz a relação entre estas variáveis e as variáveis prognósticas do modelo. Assim, a recuperação de vento em baixos níveis, torna-se importante por ser mais simples do que um parâmetro de recuperação completa, uma vez que a convergência de vento na camada limite desempenha um papel importante na inicialização da convecção (WILSON; SCHREIBER, 1986). As técnicas de recuperação dos campos termodinâmicos e microfísicos, de mais de um radar no mesmo local, dos ventos sintetizados foram desenvolvidos no passado (GAL-CHEN, 1978; ROUX, 1985; ZIEGLER 1985). Portanto, se os campos de vento 3D podem ser determinados a partir de observações de um único radar Doppler, os outros campos podem ser recuperados mediante a aplicação destas técnicas.

Conforme Bouttier (2009) o ponto mais desafiador da assimilação de dados em alta resolução é a ocorrência de estruturas na atmosfera que são intermitentes, complexas e extremamente sensíveis às condições iniciais com grande tendência ao rápido crescimento dos erros. Neste sentido, as observações de radar Doppler, de refletividade e velocidade radial, são usadas em sistemas complexos de assimilação de dados, visando melhorar as condições iniciais de modelos de alta resolução. Os resultados obtidos com a assimilação de velocidade radial do vento e refletividade, por um sistema 3D-VAR, mostraram

resultados positivos para previsão do deslocamento de um tufão, conforme Xiao et al. (2005).

No Japão, com o intuito da melhoria do sistema de assimilação de dados, Shimizu et al. (2011) implementaram um sistema de previsão de curto prazo que assimila o vento radial observado pelo radar e a água precipitável com Global Position System, com um esquema de assimilação 3D-VAR. Em tal sistema implementado percebeu-se uma considerável melhora na localização de tempestades severas, quando comparado com os resultados sem o emprego da assimilação de dados.

Nos trabalhos de Guo et al. (2007), Ming et al. (2009) e Sun e Wang (2013), há o relato da dificuldade na assimilação de dados de radar no sistema 3D-Var, na inclusão de grande quantidade de dados em altíssima resolução fornecidos pelo radar que podem, na maioria das vezes, destruir as características de grande escala existentes no *background*, resultando em uma análise desbalanceada entre as variáveis dinâmicas e microfísicas.

Na tentativa de melhores resultados um modelo adjunto de precipitação quente e um operador de observação para refletividade do radar foi desenvolvido para ser usado em um modelo de nuvem não hidrostático (KAWABATA et al., 2011). Nesta abordagem foi usada a metodologia para o conjunto de dados sintéticos e foi observado que o modelo conseguiu aumentar os núcleos de precipitação ao elevar a refletividade assimilada. Assim, conseguiram utilizar dados reais e reproduziram uma banda de precipitação com boa acurácia na quantidade de precipitação bem como a localização e a retirada das regiões onde não houve a observação de precipitação pelo radar.

Sobre o trabalho de Xiao et al. (2007), que considerava o baixo impacto da assimilação de refletividade, foi feita uma revisão do método de assimilação desta variável no WRFDA, em que Wang et al. (2013) apontaram problemas com esta forma, de assimilação de refletividade, no uso da linearização da relação  $Z - qr$  (refletividade-razão de mistura de água de chuva) no operador observação. Tais problemas causam redução da umidade no resultado final,

principalmente quando  $qr$  é pequeno, dada a forma não linear desta relação. Tal problema afeta a partição da microfísica durante a minimização da função custo. Desta forma, foi desenvolvida uma forma de assimilação de refletividade, na qual a razão de mistura da água de chuva derivada da refletividade é assimilada ao invés da assimilação direta da refletividade (WANG et al., 2013). Neste esquema um termo extra é adicionado à função de custo relativa a razão de mistura de vapor, em que a razão de mistura de vapor é obtida pela hipótese do ar estar saturado, quando a refletividade fosse maior que um valor limite acima da base da nuvem. Os resultados desta nova metodologia foram melhores do que o esquema de assimilação direta e confirmados através de estudos durante eventos convectivos por Sun e Wang (2013) nos Estados Unidos e Vendrasco et al. (2013) no Brasil. Em um sistema de assimilação de dados o uso de dados de radar necessita de um controle de qualidade rigoroso pois a inserção de dados ruins resultará no aumento do erro e na formação ou inibição de células convectivas.

Ainda com a assimilação de dados de radar testes recentes mostraram que a refletividade do radar é capaz de melhorar a previsão de precipitação no início da integração, no qual a vantagem com a velocidade radial é menor, porém com maior robustez e maior constância ao longo do tempo, não apresentando variações bruscas como no caso da refletividade (VENDRASCO, 2015). Assim, a assimilação de dados de radar implica em um ganho maior nas primeiras horas de previsão, sendo importante para a previsão de curtíssimo prazo.

Vendrasco (2015) em seu trabalho com sistema de assimilação de dados WRFDA/3D-VAR, mostrou que a assimilação direta de refletividade do radar apresenta algumas limitações, mas que podem ser amenizadas com o emprego da assimilação indireta desta variável, confirmando os resultados de Wang et al. (2013). Conforme Vendrasco (2015) a assimilação de dados de radar indireta reproduz relativamente bem os sistemas de precipitação e sua intensidade, ao passo que quando a assimilação de refletividade é usada de maneira direta, apesar do bom posicionamento, não é capaz de desenvolver-se e produzir a precipitação observada pelo radar. Ainda no trabalho de

Vendrasco (2015) os melhores resultados foram obtidos quando foram utilizadas as duas variáveis de refletividade e velocidade ao mesmo tempo.

Ferreira (2016) em seu trabalho indicou que embora a assimilação de dados de radar não possua os melhores resultados em todas as etapas dos sistemas quando comparados aos perfis verticais, estas forneceram um bom indicativo do perfil atmosférico de temperatura, diversas vezes melhor representado do que a assimilação apenas de dados convencionais. Conforme Ferreira (2016) a assimilação dos dados de razão de mistura de água de chuva (a partir da refletividade) e de vento radial produzem modificações representativas nas análises de altos e baixos níveis, bem como no perfil vertical do modelo e que, portanto esta diferença na nova condição inicial propaga-se durante a previsão. Segundo Ferreira (2016) a previsão utilizando a assimilação de dados de radar apresenta o campo de precipitação mais semelhante ao observado obtendo-se melhores resultados da posição dos núcleos de precipitação intensa, demonstrando a importância e o ganho ao assimilar os dados de radar. No trabalho de Ferreira (2016) as alterações no campo de precipitação de modo geral ficaram concentradas nas áreas de cobertura dos dados de radar.



### **3 MATERIAL E MÉTODOS**

#### **3.1. Dados utilizados**

O modelo atmosférico e o sistema de assimilação utilizados são o Weather Research and Forecasting (WRF) e o WRF Data Assimilation (WRFDA) 3D-Var. A matriz de covariância do erro de background foi gerada usando o utilitário do WRFDA aplicando o método NMC com 03 meses de simulações de 24 h a partir de 00UTC e 12UTC. O sistema espalha horizontalmente as informações de uma determinada observação usando um filtro recursivo, em seguida, o ajuste da matriz de covariância do erro de background é aplicado, ajustando os parâmetros variance scaling, relacionada com a variância das variáveis de controle, ou seja, com que intensidade cada observação irá influenciar nos pontos da grade do modelo, que afetam a amplitude, mas não a escala espacial do resultado, e length scaling, relacionada com a influência do erro em escala de distância nos valores dos pontos da grade do modelo, que dependem da resolução e configurações gerais do modelo (domínio do modelo e latitude), ou seja, o quanto em quilômetros cada observação irá influenciar nos pontos da grade do modelo, de modo a ajustá-los para a região de estudo, os dados assimilados e o sistema meteorológico estudado. Já na vertical a representação da componente horizontal do erro do background acontece através de um filtro recursivo isotrópico, onde a componente vertical é obtida pela projeção dos auto vetores do erro vertical.

O domínio abrange o oeste do sul do Brasil, incluindo os estados do Paraná, Santa Catarina e Rio Grande do Sul e parte do Paraguai com resolução horizontal de 02 km e 45 níveis. Dentro do ciclo de assimilação de dados, foi utilizado o período de 15 de outubro de 2014 até 15 de novembro de 2014, onde serão utilizados os eventos de precipitação dos dias 06, 07 e 08 de novembro de 2014. Tal estudo utilizou a matriz de erro das covariâncias do background (B), com os valores de 01 de outubro de 2014 até 31 de dezembro de 2014, onde o modelo foi inicializado às 12 UTC, com condição inicial e fronteira do GFS-NCEP, gerando condição inicial (background) para o primeiro ciclo de assimilação às 15 UTC, com a avaliação da precipitação feita

comparando os resultados da modelagem com os dados do Tropical Rainfall Measuring Mission (TRMM) 3B42, usando o índice estatístico Root Mean Square Error (RMSE). Além dos dados de radar, também foram assimilados dados convencionais provenientes do Global Telecommunication System (GTS), Tabela 1.1, que é um sistema global de telecomunicação coordenado para rápida coleta, troca e distribuição de observações e informações. Os dados usados foram obtidos no endereço eletrônico <http://rda.ucar.edu/datasets>, mantido pela seção de suporte a dados do National Center for Atmospheric Research (NCAR) (Research Data Archive (RDA)). Os dados convencionais disponíveis e usados foram, METAR, SYNOP, boias, navios, aeronaves, sondagens e outras estações de superfície.

Foram utilizados os dados das estações meteorológicas de altitude (radiosondagens) dentro da área de estudo. Quatro estações de superfície foram usadas como representação das condições atmosféricas em superfície durante o evento, para a comparação pontual do modelo com e sem assimilação. As estações selecionadas foram Curitiba (SBCT: latitude 25°31'42"S, longitude 49°10'32"W), Bacacheri (SBBI: latitude 25°24'12"S, longitude 49°14'01"W), Londrina (SBLO - latitude: 23°20'0"S, longitude: 51°7'48"W) e Foz do Iguaçu (SBFI - latitude: 25°35'46"S, longitude: 54°29'13"W). Além dos dados de radar, também foram assimilados dados convencionais provenientes do *Global Telecommunication System* (GTS), tabela 3.1, que é um sistema global de telecomunicação coordenado para rápida coleta, troca e distribuição de observações e informações. Os dados usados foram obtidos no endereço eletrônico <http://rda.ucar.edu/datasets>, mantido pela seção de suporte a dados do *National Center for Atmospheric Research* (NCAR) (*Research Data Archive* (RDA)). Os dados convencionais disponíveis e usados foram, METAR, SYNOP, boias, navios, aeronaves, sondagens e outras estações de superfície.

Tabela 3.1: Dados GTS assimilados.

<b>GTS</b>	06:00	09:00	12:00
METAR	22	****	39
SYNOP	19	****	42
AIREP	8	****	8
BUOY	1	****	1
SOUND	****	****	7

Para comparação e análise dos resultados de modelagem, foram utilizados dados de 03 em 03 horas do *Tropical Rainfall Measuring Mission* (TRMM), 3B42, versão 07, que é uma estimativa baseada em dados do infravermelho de satélites geoestacionários e dados de micro-ondas passiva, descritos por Huffman et al. (2002).

Os radares usados no presente estudo, Figuras 3.1 e 3.2, foram os Radares Doppler Polarimétricos do Sistema Meteorológico do Paraná (SIMEPAR) e da *Dirección Nacional de Aeronáutica Civil* (DINAC). O radar do SIMEPAR localiza-se em Cascavel- PR (Latitude: 24.87°S, longitude: 53.52°W, altitude: 719.8m), possui abertura de feixe de 1.0° e 15 elevações, com dados no raio de 240 ou 480 km, com largura do pulso de respectivamente, 0.8 e 2.0µs, banda S, resolução de 125 m e banda S – e o radar da DINAC está localizado em Asunción, no Paraguai (Latitude: 25.33°S, longitude: 57.52°W, altitude: 118.0m) e tem comprimento de onda de 5.4cm (banda C), 11 elevações, e largura de pulso de 0.8µs, resolução de 250 m e raio de cobertura dos dados de 250 km. Os dados foram disponibilizados pelo SIMEPAR em formatos volumétricos e a partir deste foram gerados *Plan Position Indicator* (PPI), campo de refletividade, e conversões para o formato *little\_r* para assimilação no modelo. Para gerar o PPI foi realizada uma interpolação linear simples, constituída da transformação dos dados de coordenadas polares para cartesiana. Estes dados foram originados através de varreduras volumétricas, onde o feixe do radar foi apontado para um ângulo de elevação definido e mantido constante durante uma rotação em azimute completa (giro em torno do eixo vertical), em velocidade constante. Os dados foram disponibilizados pelo SIMEPAR em formato volumétrico, onde as varreduras foram feitas em

elevações fixas e com variação do azimute. O relevo da região dificultou a obtenção dos dados devido a ecos e pontos persistentes de refletividade.

Neste estudo os dados dos radares Doppler foram assimilados pelo sistema de assimilação de dados, usando o mesmo método utilizado por Vendrasco (2015), em que as variáveis dos dados de radar foram refletividade ( $Z$ ) e velocidade radial ( $V$ ). A assimilação de PPI gera melhores resultados, quando comparados com a assimilação de dados interpolados verticalmente, resultado de erros cometidos na interpolação causados pela baixa resolução na vertical dos dados do radar (SUN; CROOK, 2001).

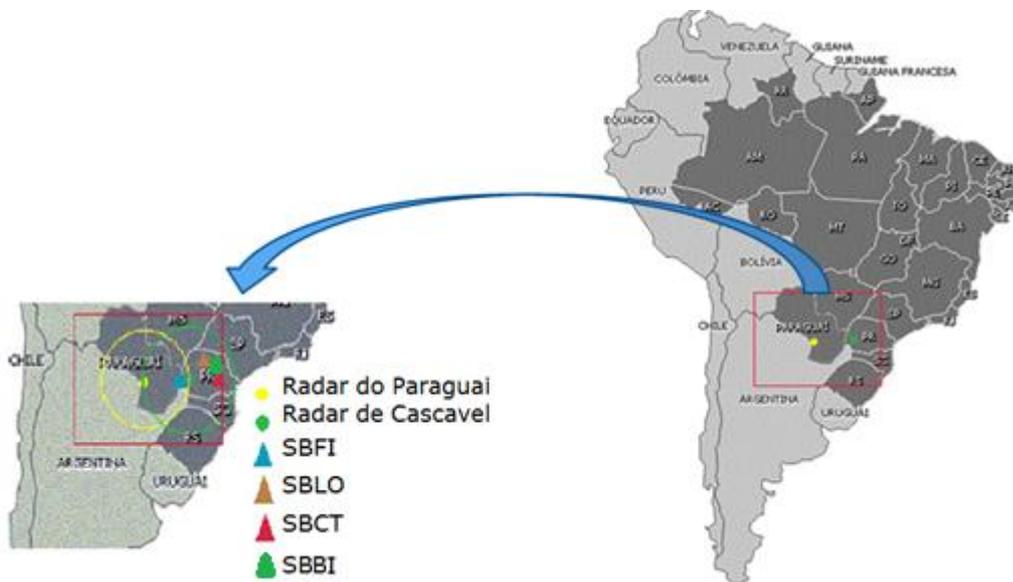


Figura 3.1: Localização dos radares e estações de controle e a grade do modelo.



- Radar do SIMEPAR localizado em Cascavel – PR.
- Radar da DINAC localizado em Assunção – Paraguai.

Figura 3.2: Localização dos radares, estações de controle e a grade do modelo.

Foi rodado o modelo WRF para o período de 07 e 08 de novembro de 2014 com resolução 02 x 02 km, sem a assimilação de dados de radar, centralizada nas coordenadas do radar de Cascavel, com 500 pontos de latitude e 800 pontos de longitude, conforme grade em destaque na cor vermelha da Figura 3.1 e 3.2 Para comparação foi rodado o modelo com a mesma resolução com a assimilação de dados de radar, para a mesma área de interesse, entre as latitudes de 20-30°S, e longitudes 46-62°W. O número de níveis na vertical foi de 45 níveis.

### 3.2. Modelo atmosférico wrf

No presente trabalho foi usado o *Weather Research and Forecasting model* (WRF), versão 3.4, modo ARW (*Advanced Reseach WRF*), possuindo uma ampla comunidade nacional e internacional de usuários, entre outros motivos, por ter o núcleo e o sistema de assimilação de dados desenvolvidos para diferentes plataformas, diretivas de paralelismo e compiladores. O WRF foi

desenvolvido através de uma parceria entre diversos órgãos, entre eles o *National Center for Atmospheric Research* (NCAR), *National Oceanic and Atmospheric Administration* (NOAA), *National Center for Environmental Prediction* (NCEP), *Forecast Systems Laboratory* (FSL), *Air Force Weather Agency* (AFWA), e outros órgãos de pesquisa e desenvolvimento.

As características do modelo WRF são os múltiplos núcleos dinâmicos, sistema variável de assimilação de dados tridimensional e uma estrutura de software que permite o paralelismo computacional, bem como a extensibilidade do sistema, Figura 3.3. Portanto, pode ser instalado em diversas plataformas computacionais, sendo portátil, flexível, de domínio público e disponibilizado gratuitamente. O modelo pode ser executado tanto para situações atmosféricas idealizadas como situações reais, em um espectro amplo de aplicações em escalas horizontais que variam de milhares de quilômetros a poucos metros.

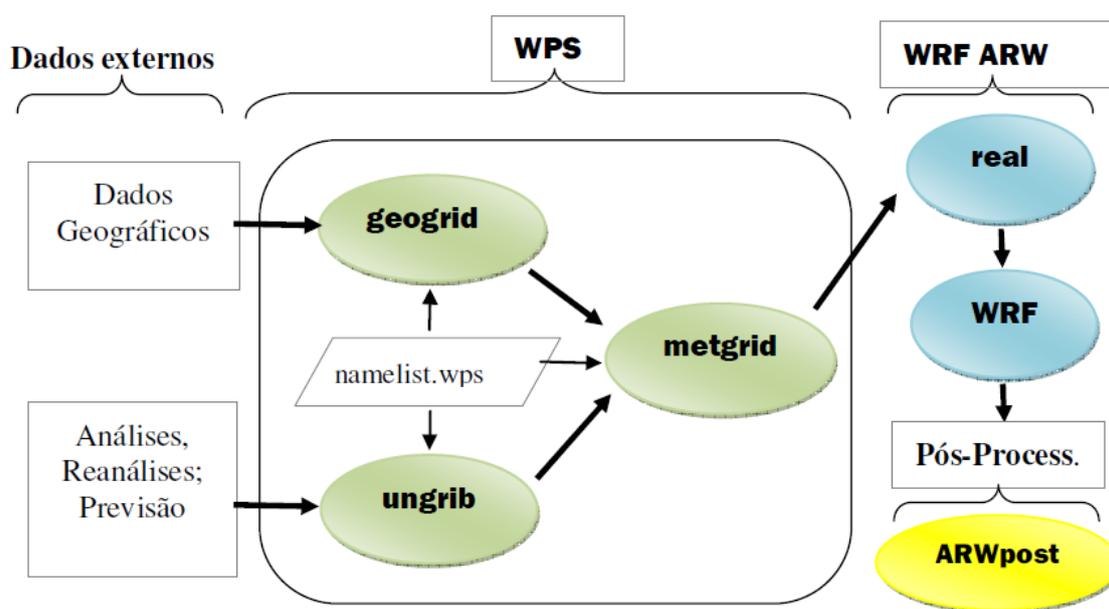


Figura 3.3: Representação esquemática do sistema de modelagem. Adaptado de ARW V3 *Modeling System User's Guide*, 2011.

Há duas versões do WRF, com as diferenças de uma possuir núcleos dinâmicos distintos, o *Advanced Research WRF* (ARW), mantido pela divisão de mesoescala e microescala do NCAR, e outra versão é o *Nonhydrostatic*

*Mesoscale Model* (NMM), mantido pela comunidade do *Developmental Testbed Center* (DTC) (UCAR; DTC, 2013).

Neste trabalho foi utilizada a versão ARW. As equações do ARW representam escoamento totalmente compressível, com formulação Euleriana e não hidrostática, apresentando uma opção hidrostática, sendo conservativo para as variáveis escalares. Portanto, o modelo usou coordenadas *sigma* como a coordenada vertical em níveis de pressão hidrostática, em que o topo apresenta uma superfície de pressão constante. O passo de tempo do modelo foi configurado como adaptativo, variando apenas no intervalo de 06 a 16 segundos, onde as rodadas com e sem assimilação foi feito um ciclo de 06 horas iniciando 02 dias antes da fase mais intensa do caso em estudo.

O modelo também apresenta opções de aninhamento *one-way*, *two-way* e *moving*. E ainda é capaz de ser executado em computadores com memória compartilhada ou distribuída, (SKAMAROCK et al., 2008).

O pré-processamento do WRF possui 04 processos, o Geogrid (gera para os pontos da grade do modelo os parâmetros estáticos, como a vegetação, relevo, etc), Ungrib (muda o formato das variáveis meteorológicas do GFS), Metgrid (realiza interpolações dos dados para a grade do modelo) e o Real (gera a análise na grade do modelo e condições da camada limite).

Quando a rodada do modelo WRF é feita com a assimilação de dados, os processos são feitos considerando a ordem do Update Inferior (atualiza a fronteira inferior, da superfície, do modelo no modo cíclico), Run WRFDA (assimilação de dados variacional em 03 dimensões), Update Lateral (atualiza as fronteiras laterais do modelo) e o Run Model (faz a previsão a partir da nova análise gerada nos processos anteriores).

As condições iniciais e de contorno usadas são as disponibilizadas pelo modelo atmosférico *Global Forecast System* (GFS), com resolução de 2 km, dividido no módulo de assimilação de dados, do *Global Assimilation System* (GDAS), e o segundo módulo do modelo espectral *Medium Range Forecast* (MRF). O

cálculo da maioria das derivadas horizontais é feito espectralmente a partir dos harmônicos, sendo extremamente acurados. Atualmente o modelo GFS é rodado quatro vezes ao dia com início de previsão começando às 00, 06, 12 e 18 horas UTC e disponibilizados com uma resolução horizontal de 0,5°, essa saída é utilizada como condição de contorno e inicial do modelo WRF.

### 3.2.1 WRFDA

O *Weather Research and Forecasting model Data Assimilation system* (WRFDA) é o componente de assimilação de dados do WRF, em seu código está implementado o método variacional de assimilação de dados, tanto em 3 dimensões (3D-VAR) como em 4 dimensões (4D-VAR). A matriz dos erros de *background* (B) é quadrada e simétrica em que seus autovalores são todos reais e seus autovetores são ortogonais. O WRFDA é um sistema de assimilação de dados de uso livre e mantido pelo NCAR, composto das partes de pré-processamento das observações, o *generate background error* (gen\_be) que gera a matriz com a covariância do erro do *background* com base em uma série de previsões pelo método NMC. O WRFDA combina as observações com o *background* através da minimização de uma função custo; e o *Update Boundary Conditions* (UPDATE\_BC) que atualiza as condições de contorno (atualiza o wrfbdy\_d01 gerado pelo real.exe). O gen\_be é uma ferramenta distribuída juntamente com o WRFDA e foi desenvolvida para ler dados de uma variedade de modelos (WRF, MM5, KMA e outros), processá-los e gerar as estatísticas das covariâncias dos erros. A matriz B gerada pelo gen\_be é uma representação climatológica das covariâncias dos erros e ajustes.

O objetivo do sistema variacional de assimilação de dados é produzir uma estimativa ótima do verdadeiro estado da atmosfera no tempo da análise através da solução iterativa da função de custo  $J(x)$  (IDE, et al. 1997). O algoritmo de assimilação de dados variacional adotado no WRFDA é a formulação de incrementos do problema variacional (COURTIER et al., 1994). Nesta aproximação, observações, previsões anteriores, seus erros e as leis

físicas são combinados para produzir o incremento o qual é adicionado ao *background* ( $x_b$ ) para resultar em uma análise atualizada.

O WRFDA assimila os dados de radar através do formato *little\_r*, que é um arquivo intermediário facilitador da assimilação de várias fontes de dados, uma vez que estão disponíveis diversos formatos como ASCII, BUFR, HDF, MADIS, PREPBUFR e outros. Assim, o WRFDA assimila a informação do radar como perfis verticais de refletividade e velocidade radial do vento.

No WRFDA existem variáveis que são fatores que foram multiplicados à matriz B alterando as variâncias dos campos das variáveis de controle e a extensão em que a análise é afetada por uma determinada observação em um dado local. Estas variáveis são chamadas de *variance scale* e *length scale*. A variável *length scale* está relacionada com a influência do erro em escala de comprimento nos valores dos pontos da grade do modelo, que dependem da resolução e configurações do modelo (domínio do modelo e latitude), ou seja, o quanto em quilômetros cada observação irá influenciar nos pontos da grade do modelo, Figura 3.4. A variável *variance scale* está relacionada com a variância das variáveis de controle, ou seja, com que intensidade cada observação irá influenciar nos pontos da grade do modelo, que afetam a amplitude, mas não a escala espacial do resultado (CHOU; HUANG, 2011), Figura 3.5. Desta forma, o ajuste da variável *variance scale* representa o peso que se dá ao *background* em detrimento do peso dado às observações. Portanto, foi feita a variação do ajuste das variáveis de *length scaling* e *variance scale* (para as cinco variáveis de controle: a perturbação da função de corrente, a velocidade potencial, a temperatura, a pseudo umidade relativa e a pressão da superfície) dentro do ciclo de assimilação de dados do Radar Doppler. Vários autores indicaram a necessidade de ajustes das variáveis *variance scaling* e *length scaling* visando a melhora do ajuste do *background* às observações (HA; LEE, 2012; TONG et al., 2014).

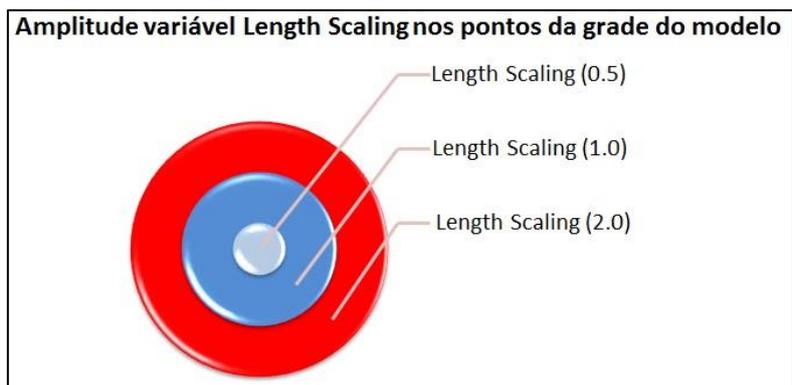


Figura 3.4: Amplitude da variável *length scaling* e o quanto em quilômetros cada observação irá influenciar nos pontos da grade do modelo.

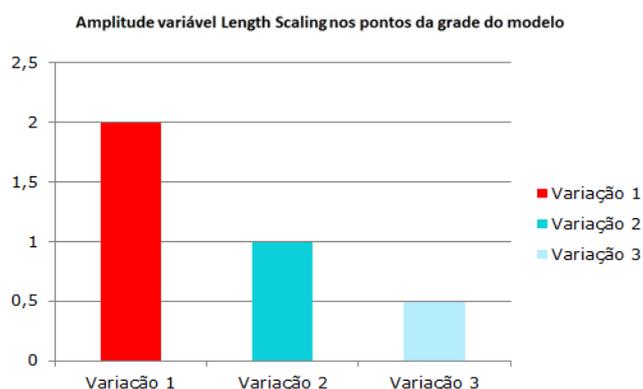


Figura 3.5: Amplitude da variável *variance scaling* e a intensidade com que cada observação irá influenciar nos pontos da grade do modelo.

### 3.2.2 Método 3D-VAR

A análise variacional tridimensional (3D-VAR) tenta resolver a dificuldade de se conseguir a melhor representação da atmosfera, onde procura um vetor de análise que diminua a função custo, com a medida da distância da análise em relação ao *background* e em relação à observação. A primeira diferença é ponderada pela covariância do erro do *background* e a segunda pela covariância do erro da observação. Resolver o problema da análise em ambas as formas é equivalente, conforme Warner (2011). Matematicamente tem-se que a função custo pode ser representada por:

$$J(x) = J_b(x) + J_0(x) = \frac{1}{2}(x - x_b)^T B^{-1}(x - x_b) + \frac{1}{2}(H(x) - y)^T R^{-1}(H(x) - y) \quad (3.1)$$

Primeiramente  $J_b(x)$  representa o *background* e  $J_0(x)$  representa o termo das observações regulares. No desenvolvimento da expressão tem-se que o primeiro termo do lado direito corresponde à diferença entre a variável de estado e a estimativa inicial (*background*) ponderada pelo erro das covariâncias do *background* (B). O segundo termo refere-se à diferença entre o vetor de estado e as observações (no espaço das observações) ponderadas pelas covariâncias das observações (R). Ambos os termos são escalares e a análise será o mínimo valor possível para a função custo  $J(x)$ . Tem-se também o operador da observação (H), que transforma um vetor no espaço do modelo (n) para o espaço das observações (p). Tem-se ainda que (y) é a observação e ( $x_b$ ) é o campo de *background* (integração curta do modelo ou climatologia, que pode ser como campo suporte).

A utilidade da minimização da função custo se dá pelas várias simplificações feitas na interpolação ótima, levando a uma análise mais compatível, uma vez que utiliza uma aproximação mais adequada da realidade.

A matriz de covariância (B) é encontrada pelo método proposto por Parrish e Derber (1992), denominado por *National Meteorological Center* (NMC), baseado inteiramente em diferenças entre simulações numéricas para um mesmo tempo (24 horas menos 12 horas). A matriz de covariância do erro do *background* é definida como:

$$B = \overline{\epsilon\epsilon^T} \cong \overline{x'x'^T} \quad (3.2)$$

As variáveis que estão abaixo da barra indicam a média no tempo ou no espaço. O verdadeiro erro do *background*  $\epsilon$  é desconhecido, mas adota-se que sua representação é dada pela perturbação do estado do modelo  $x'$ . Para o sistema de assimilação de dados variacional em que trabalha no espaço do modelo  $x'$ , as covariâncias dos erros de *background* estão no espaço das variáveis de controle  $v$ , relacionadas com as variáveis do modelo pela transformada  $U$  dada por:

$$x' = Uv = U_p U_v U_{hv} \quad (3.3)$$

Em que  $U_p$ ,  $U_v$  e  $U_{hv}$  são as transformações da variável ( $p$ ), em que ( $v$ ) é a componente vertical e ( $h$ ) a componente horizontal das covariâncias espaciais dos erros.

O 3D-VAR ainda tem a vantagem de assimilar os dados de medidas indiretas, como a refletividade do radar, de modo direto, implicando em menores covariâncias na matriz ( $R$ ). O operador de observação para a velocidade radial ( $V_r$ ) é definido pela equação de Sun et al. (1997):

$$V_r = \frac{1}{r} [(x_d - x_r)u + (y_d - y_r)v + (z_d - z_r)(w - V_t)]$$

Onde: (3.4)

$$r = \sqrt{(x_d - x_r)^2 + (y_d - y_r)^2 + (z_d - z_r)^2}$$

Em que  $(x_d, y_d, z_d)$  é a posição do dado de radar e  $(x_r, y_r, z_r)$  representam a localização do radar. As componentes  $u$ ,  $v$  e  $w$  compõem o campo do vento tridimensional e  $V_t$  é a velocidade terminal da precipitação (no caso, gotas de chuva).

Já o operador de observação para a refletividade  $Z$  é dado por Sun et al. (1997):

$$Z = 43,1 + 17,5 \log(\rho qr) \quad (3.5)$$

onde  $\rho$  é a densidade do ar e  $qr$  é a razão de mistura de água de chuva. A relação (3.5) é comumente chamada de relação  $Z - qr$  e é derivada supondo uma distribuição de tamanho de gotas de chuva de Marshall-Palmer (SUN et al., 1997). Na prática outras relações empíricas além da de Marshall-Palmer são encontradas, e pode-se citar o trabalho de Santos (2014) que usou de dados sobre o Estado do Paraná, mas que no WRF3D-VAR essa relação não pode ser controlada pelo usuário (LIU et al., 2013).

Para minimizar a função custo  $J(x)$  no WRF 3D-VAR, a disseminação da informação observada é determinada por filtros recursivos, na horizontal (HAYDEN; PURSER, 1995). Para a componente vertical da transformada U do WRFDA é feito um cálculo estatístico. O filtro recursivo de primeira ordem consiste de uma etapa de avanço:

$$F_i = (1 - \alpha)D_i + \alpha F_{i-1} \quad (3.6)$$

Onde  $D$  é a entrada e  $F$  é a saída do passo de avanço. O índice de ponto de grade é dado por  $i$  e deve ser tratado como incremento, de modo que a quantidades do membro direito da equação já sejam conhecidas. O passo seguinte da etapa é dado por:

$$R_i = (1 - \alpha)F_i + \alpha R_{i+1} \quad (3.7)$$

Em que  $R$  é a saída final do filtro recursivo, e  $i$  deve ser tratado como incremento negativo, decrescente. O parâmetro de suavização  $\alpha$  é o coeficiente do filtro e possui a seguinte relação com o parâmetro  $e$ :

$$\alpha = (1 + e) - \sqrt{e(e + 2)} \quad (3.8)$$

Onde  $e = N(\Delta x)^2/4s^2$ , em que  $N$  é o número de interações do filtro, com  $N \rightarrow \infty$  (a resposta aproxima-se da Gaussiana). Tem-se ainda que  $\Delta x$  representa a resolução horizontal do modelo de previsão e  $s$  é a variável *length scaling* do filtro. No filtro recursivo os valores de  $N$  e  $\Delta x$  são constantes e o valor de  $e$  varia de acordo com a variável *length scaling*. O parâmetro de suavização  $\alpha$ , que se encontra entre os valores de 0 e 1, está relacionada com a variável *length scaling* do filtro recursivo.

Neste estudo, dentro do ciclo de assimilação de dados, foi utilizado o período de 15 de outubro de 2014 até 15 de novembro de 2014, onde foram utilizados os eventos de precipitação dos dias 06, 07 e 08 de novembro de 2014. Tal estudo utilizou a matriz de erro das covariâncias do *background* (B), com o período de 01 de outubro de 2014 até 31 de dezembro de 2014, onde o modelo foi inicializado às 12 UTC, com condição inicial e fronteira do GFS-NCEP,

gerando condição inicial (*background*) para o primeiro ciclo de assimilação às 15 UTC. A assimilação para o *spin up* gerou melhorias do modelo, na área da grade, assimilando dados do GTS a cada 06 horas. Depois dos dados convencionais e de radar serem assimilados, foi inicializada com a análise uma nova previsão de 01 hora que gerou a condição inicial para o próximo ciclo. A matriz de covariância (B) foi encontrada pelo método proposto por Parrish e Derber (1992), denominado por *National Meteorological Center* (NMC), baseado inteiramente em diferenças entre simulações numéricas para um mesmo tempo (24 horas menos 12 horas). A matriz B foi necessária para que a assimilação fosse feita e para que o modelo tivesse uma ponderação quando comparado ao dado em um ponto. Todavia, no caso do 3D-VAR a matriz (B) não depende do regime da atmosfera, o que é uma desvantagem. A assimilação dos dados de radar e convencionais foi feita separadamente, conforme Figura 3.6 a 3.8

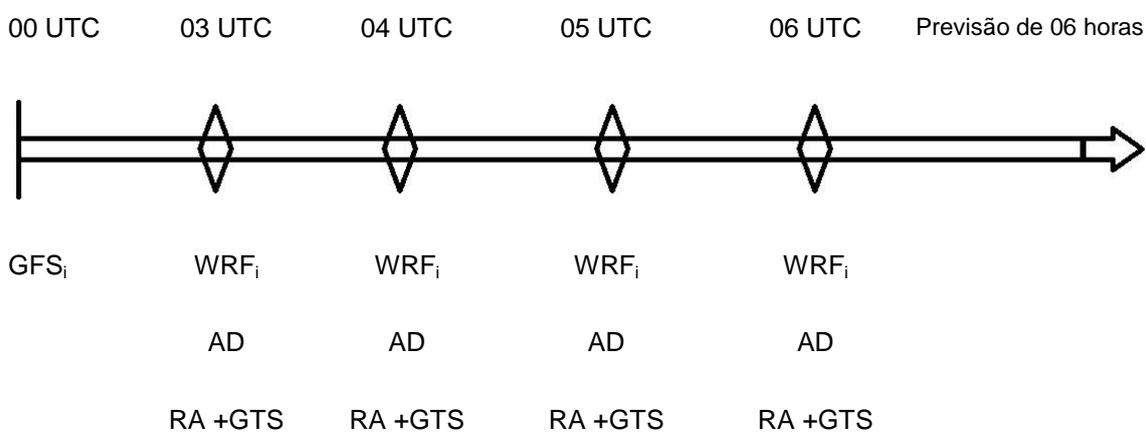


Figura 3.6: Ciclo de assimilação de dados de 01 hora.

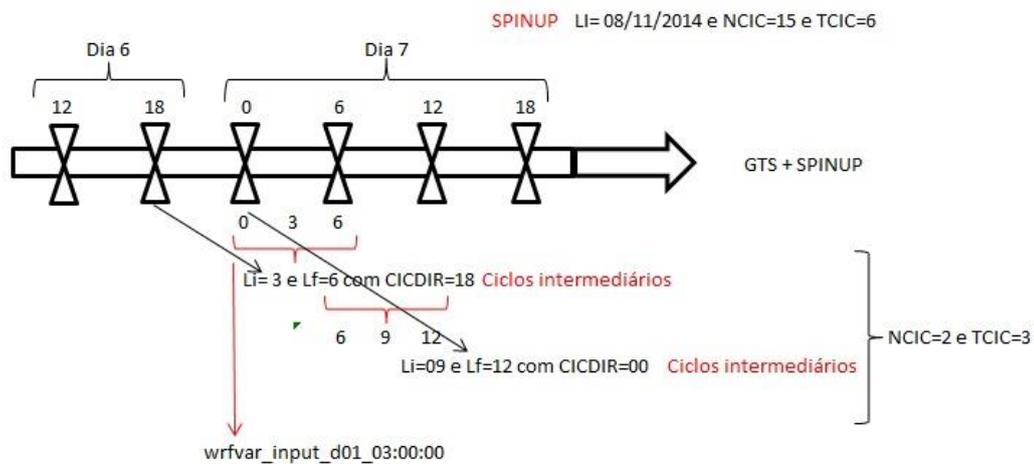


Figura 3.7: Ciclo de assimilação de dados de GTS e SPINUP.

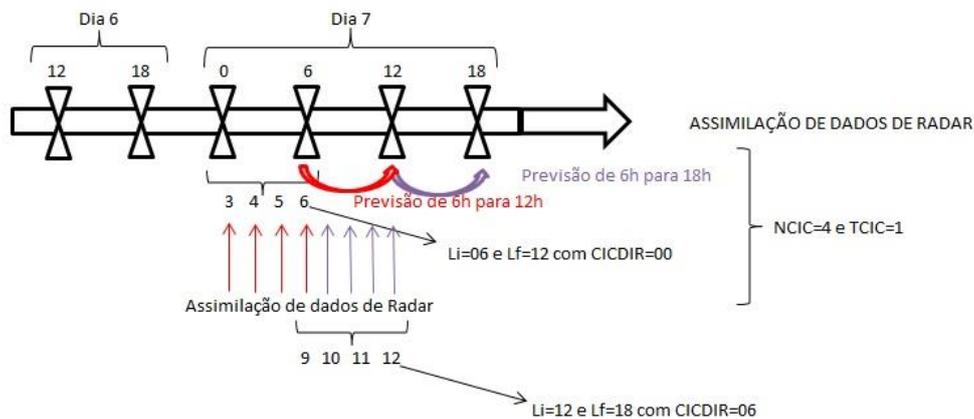


Figura 3.8: Ciclo de assimilação de dados de radar com previsão para as 12 e 18 horas.

Neste ciclo de assimilação de dados de radar tem-se que o *Label* Inicial (LI) seria a data inicial da análise e *Label* Final (LF) seria a data final da análise mais o tempo de previsão. Tem-se também que o Tempo dos Ciclos (TCIC) seria o tempo do ciclo em horas e Número de Ciclos (NCIC) seria o número total de ciclos.

Baseado na assimilação de dados de superfície e altos níveis, dados de GTS, foi possível verificar qual foi a contribuição da assimilação dos dados de radar em comparação a assimilação dos demais dados disponíveis. A assimilação de dados de radar foi realizada de modo independente, onde o impacto desta assimilação não foi analisado conjuntamente com a assimilação dos demais

dados, em que cada ciclo de assimilação de dados de radar foi rodado isoladamente.

### **3.3 Radar**

O *Radio Detection and Ranging* (Radar) é um sistema eletromagnético para detecção e localização de objetos por meio de ecos de rádio. O Radar teve seu principal desenvolvimento durante os anos 30, quando a Inglaterra se preparava para a Segunda Guerra Mundial, sendo usado para detectar e monitorar navios e aviões na guerra. Nesse cenário o fenômeno da chuva obscurecia os alvos e causava grande dificuldade para os operadores de radar militar. Assim, surgiu o uso do radar para outros fins, como o da Meteorologia com a caracterização e monitoramento de tempestades. O radar passou a ser usado em meteorologia como uma técnica de sensoriamento remoto ativo, enviando pulsos de micro-ondas e medindo a energia retroespalhada que retorna.

Nos primeiros anos da década de 1960, teve-se o desenvolvimento das técnicas do Radar Doppler, capazes de quantificar, além da potência retroespalhada pelo alvo, obtidas pelos radares convencionais, a sua velocidade radial. São ditos radares Doppler aqueles que emitem um sinal de referência pelo qual mudanças na fase na frequência dos pulsos recebidos é reconhecida. Tais radares são ditos “coerentes”, isto é, eles mantêm uma relação contínua entre as fases e as frequências das ondas. Esse fato faz com que o radar seja capaz de medir a velocidade radial (de aproximação ou afastamento em relação ao radar) dos alvos. As medidas de velocidade radial são assimiladas diretamente por meio do operador definido na equação.

Sobre os dados de radar, sabe-se que o controle de qualidade dos dados são de responsabilidade do usuário e que a formatação do arquivo do radar é própria para o WRFDA. Sabe-se, também, que um dos pontos mais difíceis é a determinação do erro associado à medida. Na assimilação, outra metodologia

usualmente adotada é usar o desvio padrão dos pixels adjacentes, como no trabalho de Vendrasco et al. (2012).

Há que se destacar que umas das principais fontes de dados observacionais para a escala convectiva são os dados de radar Doppler, enquanto dados de radiossondagens e de satélite são indispensáveis para a PNT de grande escala (SUN, 2006).

A questão fundamental sobre o uso de observações de radar para PNT é a viabilidade de se derivar as variáveis de estado atmosféricos necessários para a inicialização de um modelo de alta resolução a partir das observações de um único radar Doppler, uma vez que o espaçamento de redes de radar Doppler operacional não é suficiente para fornecer cobertura por mais de um radar no mesmo local (SUN, 2006). Segundo Aksoy et al. (2009) observações com radar Doppler de refletividade e velocidade radial, têm sido utilizadas em sistemas complexos de assimilação de dados com o intuito de melhorar as condições iniciais de modelos de alta resolução, uma vez que estes dados são em grande parte a única fonte de informação tridimensionais nesta escala.

As principais variáveis para a inicialização de um modelo numérico de escala convectiva precisam ser recuperadas, onde, portanto novas técnicas para recuperação de vento precisam ser desenvolvidas a fim de produzir uma análise de alta resolução para ser usada para o modelo de inicialização (SUN, 2006). Assim, a recuperação de vento de baixo nível, torna-se importante por ser mais simples do que um parâmetro de recuperação completa, mas também porque a convergência de vento na camada limite desempenha um papel importante na iniciação de convecção (WILSON; SCHREIBER, 1986). As técnicas para recuperar campos termodinâmicos e microfísicas por mais de um radar no mesmo local e ventos sintetizados foram desenvolvidos no passado (GAL-CHEN, 1978; ROUX, 1985; ZIEGLER, 1985). Portanto, se os campos de vento 3D podem ser determinados a partir de observações de um único radar Doppler, os outros campos podem ser recuperados mediante a aplicação destas técnicas.

As variáveis primárias obtidas por um radar são refletividade, velocidade radial do vento e largura espectral. Neste trabalho as variáveis que foram utilizadas são:

- Refletividade (Z): Fator da refletividade entre a irradiância emitida pelo radar e a recebida por ele depois de retroespalhadas pelos hidrometeoros presentes na atmosfera. A unidade utilizada é o dBZ, que é uma escala logarítmica da refletividade. Os valores variam de zero a 60 dBZ e quanto maior forem os valores, maiores serão os diâmetros das gotas presentes no volume medido e, assim, maiores serão as intensidades de precipitação.
- Velocidade Radial do Vento (V): Velocidade de aproximação ou afastamento dos hidrometeoros em relação ao radar na direção do feixe. Valores positivos indicam que os alvos que se afastam e valores negativos são para os alvos que se aproximam do radar.

Calculando o incremento, como resultado da assimilação da velocidade radial do vento, leva-se em conta a equação de balanço de Richardson, combinando a equação da continuidade, a equação da termodinâmica adiabática e a relação hidrostática (SKAMAROCK et al., 2008). Na assimilação de dados de refletividade do radar, o total de água líquida de chuva é usado como variável de controle, onde uma divisão entre incrementos do vapor de água e hidrometeoros na minimização da função de custo  $J(x)$ , (3.6). Utiliza-se também o operador observação para a velocidade radial Doppler e para a refletividade.

Neste estudo os dados de radar foram originados através de varreduras volumétricas, onde o feixe do radar foi apontado para um ângulo de elevação definido e mantido constante durante uma rotação em azimute completa (giro em torno do eixo vertical), em velocidade constante. Cada campo de refletividades obtido dessa maneira é chamado de PPI. O feixe é então movido para um novo ângulo de elevação e nova rotação é executada. Após um número definido de rotações, o espaço varrido pelo feixe é formado por um

conjunto de “casacas” cônicas sobrepostas, cada uma com espessura determinada pela abertura do feixe principal do radar.

### 3.4 Metodologia de avaliação

As rodadas foram feitas sem *spin up*, com um *spin up* inicial, com assimilação de dados (GTS) e com assimilação de dados de radar, com três variações dos valores de *variance scale* e *length scaling*, conforme Tabela 3.1.

Tabela 3.2: Variação da configuração dos valores admencionais de *variance scale* e *length scaling*.

<b>Tipo</b>	<b>Variance scale</b>	<b>Length scaling</b>
<b>Varição 01</b>	0,5	2,0
<b>Varição 02</b>	1,0	1,0
<b>Varição 03</b>	2,0	0,5

Foram feitas integrações sucessivas, com *spin up* de 36 horas antes da formação do evento em estudo, com 03 ciclos diferentes. Assim, no ciclo A as simulações numéricas tiveram como data inicial dos ciclos o dia 05/11/2014, data final dos ciclos 08/11/2014, com tempo entre cada ciclo de 06 horas e 15 minutos, para as 03 variações da Tabela 3.1. O ciclo A não apresenta a saída necessária para realização da ligação do ciclo do GTS (de 06 em 06 horas) e o ciclo de assimilação de dados de radar (de 01 em 01 hora).

Foi feito um ciclo B para criação do *first guess* para o ciclo C, chamado ciclo intermediário. O ciclo B foi feito com 03 horas entre cada ciclo, com 02 ciclos e 02 rodadas com datas iniciais e finais diferentes, para as 03 variações da Tabela 3.1.

O ciclo C, com a assimilação de dados de radar, foi feito com rodadas independentes, de maneira que cada ciclo de assimilação de dados de radar é

rodado isoladamente, com 01 hora entre cada ciclo, 04 ciclos e 02 rodadas com datas iniciais diferentes, para as 03 variações da Tabela 3.1.

Para efeito de controle, foi feita a rodada sem assimilação de dados no mesmo período das rodadas do GTS, onde a análise e o background foram idênticos, com a mesma condição inicial para cada rodada foi a previsão de 06 horas do ciclo anterior, exceto na data inicial dos ciclos, em que o GFS foi usado como condição inicial e de fronteira.

### 3.4.1 Avaliação

Foram utilizados dados de 03 em 03 horas do TRMM 3B42 versão 7. O 3B42-v7 (*TRMM and Other Satellites*) é uma estimativa baseada em dados do infravermelho de satélites geoestacionários e dados de microondas passiva, descritos mais detalhadamente em Huffman et al. (2002).

Também foi utilizado o RMSE (Root Mean Square Error), para medir a magnitude do erro nos valores de precipitação previsto. O RMSE é calculado pela equação:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{M} - \bar{O})^2} \quad (3.9)$$

Em que  $N$  seria o número total de pontos de grade do domínio analisado,  $\bar{M}$  as médias de precipitação previstas pelo modelo e  $\bar{O}$  são as médias de precipitação observadas pelo modelo. RMSE é portanto a raiz quadrada da média das diferenças individuais entre as precipitações previstas pelo modelo e as observadas pelo modelo.

## 4 RESULTADOS

Os resultados foram elencados, onde em um primeiro momento foram colocadas as condições sinóticas atuantes, imagens de satélite e radar. Em um segundo momento foram colocadas as rodadas sem spin up, com spin up, com assimilação de dados GTS (com as variações de *variance scale* e *length scaling*) e com a assimilação de dados de radar (com as variações de *variance scale* e *length scaling*).

### 4.1 Análise sinótica

Áreas e linhas de instabilidade ocorreram na região de estudo no dia 07 de novembro de 2014, tanto às 12:00 horas como às 18 horas. No período considerado, houve o registro de mais de 20 mm de precipitação acumulada em 03 horas em algumas localidades, com rajadas de vento acima de 100 km/h e granizo.

Foram obtidos dados horários de precipitação do Banco de Dados Climatológicos da Aeronáutica (BDC), instalado no Instituto de Controle do Espaço Aéreo (ICEA) das estações meteorológicas de superfície de Curitiba-PR (SBCT), Tabela 4.1, de Foz do Iguaçu – PR (SBFI), Tabela 4.2, de Bacacheri – PR (SBBI) Tabela 4.3, de Londrina – PR (SBLO) Tabela 4.4.

Tabela 4.1: Dados horários de precipitação em mm de Curitiba – PR (SBCT).

Estação	Ano	Mês	Dia	Hora	Precipitação
SBCT	2014	11	7	7	0
SBCT	2014	11	7	8	0
SBCT	2014	11	7	9	0
SBCT	2014	11	7	10	0,1
SBCT	2014	11	7	11	0,1
SBCT	2014	11	7	12	0,6
SBCT	2014	11	7	13	0,4
SBCT	2014	11	7	14	0,1
SBCT	2014	11	7	15	0
SBCT	2014	11	7	16	0
SBCT	2014	11	7	17	0,1
SBCT	2014	11	7	18	6,3
SBCT	2014	11	7	19	3,7

SBCT	2014	11	7	20	0,8
SBCT	2014	11	7	21	0
SBCT	2014	11	7	22	0
SBCT	2014	11	7	23	0

Tabela 4.2: Dados horários de precipitação em mm de Foz do Iguazu – PR (SBFI).

Estação	Ano	Mês	Dia	Hora	Precipitação
SBFI	2014	11	7	7	0
SBFI	2014	11	7	8	0,1
SBFI	2014	11	7	9	2,7
SBFI	2014	11	7	10	12,5
SBFI	2014	11	7	11	5,8
SBFI	2014	11	7	12	5,2
SBFI	2014	11	7	13	1,0
SBFI	2014	11	7	14	1,9
SBFI	2014	11	7	15	0,8
SBFI	2014	11	7	16	0
SBFI	2014	11	7	17	0,9
SBFI	2014	11	7	18	1,1
SBFI	2014	11	7	19	0,5
SBFI	2014	11	7	20	0
SBFI	2014	11	7	21	0
SBFI	2014	11	7	22	0
SBFI	2014	11	7	23	0

Tabela 4.3: Dados horários de precipitação em mm de Bacacheri – PR (SBBI).

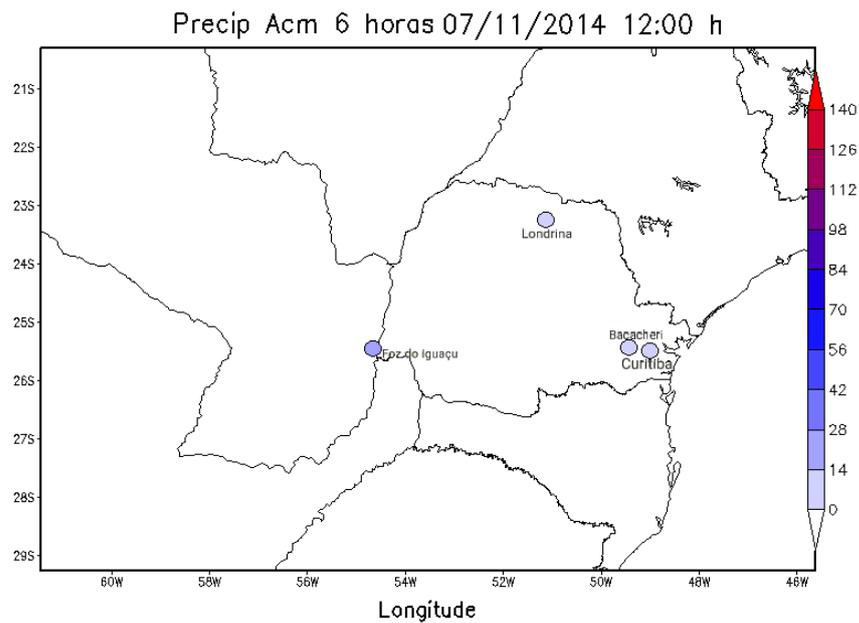
Estação	Ano	Mês	Dia	Hora	Precipitação
SBBI	2014	11	7	7	0
SBBI	2014	11	7	8	0,1
SBBI	2014	11	7	9	0,1
SBBI	2014	11	7	10	0,1
SBBI	2014	11	7	11	0,1
SBBI	2014	11	7	12	0,2
SBBI	2014	11	7	13	0
SBBI	2014	11	7	14	0
SBBI	2014	11	7	15	0
SBBI	2014	11	7	16	0
SBBI	2014	11	7	17	0,4
SBBI	2014	11	7	18	5,0
SBBI	2014	11	7	19	1,1
SBBI	2014	11	7	20	0,8
SBBI	2014	11	7	21	0

Tabela 4.4: Dados horários de precipitação em mm de Londrina – PR (SBLO).

Estação	Ano	Mês	Dia	Hora	Precipitação
SBLO	2014	11	7	7	0
SBLO	2014	11	7	8	0
SBLO	2014	11	7	9	0
SBLO	2014	11	7	10	0
SBLO	2014	11	7	11	0,7
SBLO	2014	11	7	12	0
SBLO	2014	11	7	13	0
SBLO	2014	11	7	14	0
SBLO	2014	11	7	15	0
SBLO	2014	11	7	16	0
SBLO	2014	11	7	17	0,1
SBLO	2014	11	7	18	1,0
SBLO	2014	11	7	19	0,1
SBLO	2014	11	7	20	3,3
SBLO	2014	11	7	21	7,2
SBLO	2014	11	7	22	1,2
SBLO	2014	11	7	23	0,1

Através dos dados horários de precipitação do Banco de Dados Climatológicos da Aeronáutica (BDC) das estações meteorológicas de superfície de Curitiba-PR (SBCT), Tabela 4.1, de Foz do Iguaçu – PR (SBFI), Tabela 4.2, de Bacacheri – PR (SBBI) Tabela 4.3, de Londrina – PR (SBLO) Tabela 4.4, obteve-se as Figuras 4.1.a para as 12:00 horas e Figuras 4.1.b para as 18:00 horas com a distribuição espacial da precipitação observada, acumulada das últimas 06 horas.

a)



b)

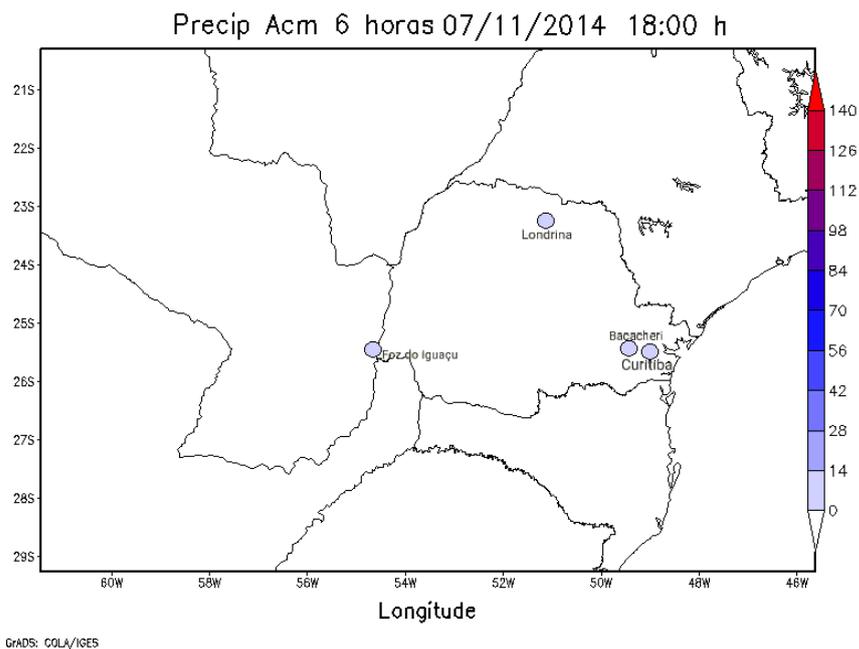


Figura 4.1: Precipitação acumulada das últimas 06 horas para às 12 horas (a) e 18 horas (b).

Foram obtidas imagens da Divisão de Satélites e Sistemas Ambientais (DSA/CPTEC) do Satélite GOES 13, no visível, Imagem de satélite (visível) do

dia 07 de novembro de 2014, às 12 horas, Figura 4.2.a, e 18 horas Figura 4.2.b. Realçada, Imagem de satélite (realçada) do dia 07 de novembro de 2014, às 12 horas, Figura 4.3.a e 18 horas Figura 4.3.b. Infravermelho, Imagem de satélite (infravermelho) do dia 07 de novembro de 2014, às 12 horas, Figura 4.4.a e 18 horas, Figura 4.4.b.

a)

b)

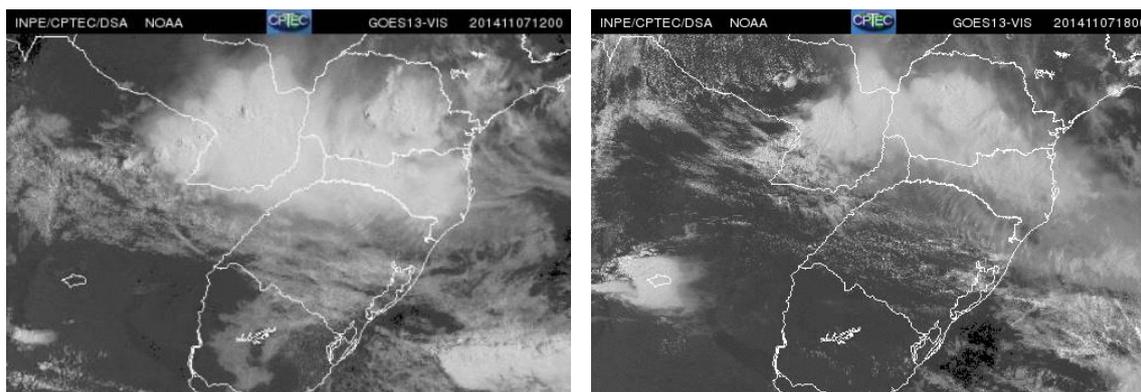
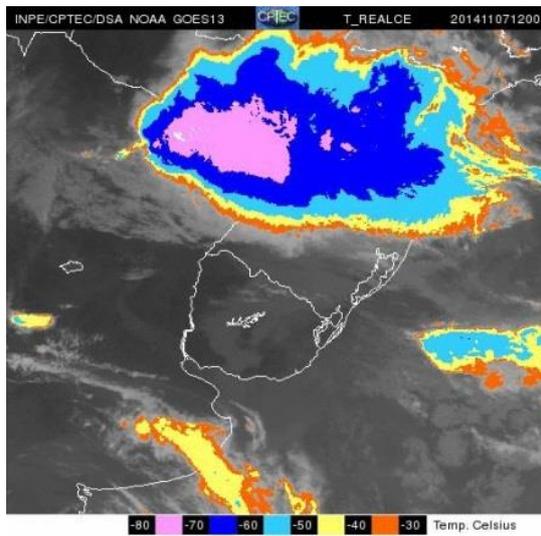


Figura 4.2: Imagem de satélite (visível) do dia 07/11/2014 às 12 horas (a) e 18 horas(b).

As observações realizadas de maneira indireta através de sensoriamento remoto foram importantes para a análise dos sistemas precipitantes, levando em consideração a área de atuação, evolução e identificação dos núcleos atuantes. Para os dois eventos selecionados foram analisadas as imagens de satélite para um melhor posicionamento dos núcleos e melhor posicionamento do sistema. Nos horários da 12 e 18 horas do dia 07 de novembro de 2014, o sistema apresentou temperaturas de brilho que atingiram temperaturas em torno de  $-80\text{ }^{\circ}\text{C}$ , indicando a possibilidade de condições meteorológicas severas, com tempestades e ocorrência de granizo, Figura 4.3.a e 4.3.b e Figura 4.4.a e 4.4.b.

a)



b)

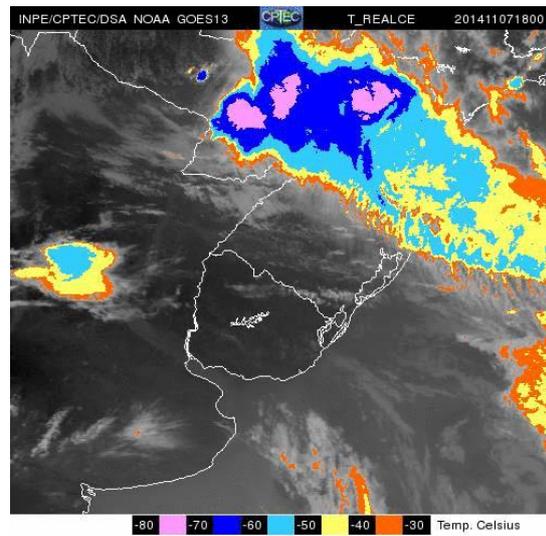
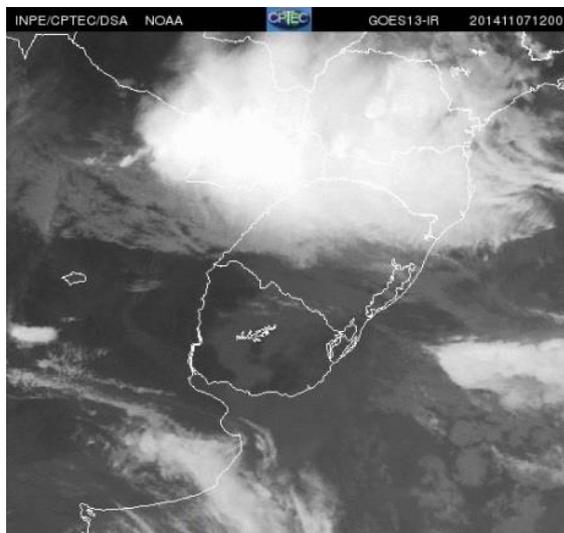


Figura 4.3: Imagem de satélite (realçada) do dia 07/11/2014 às 12 horas (a) e 18 horas (b).

a)



b)

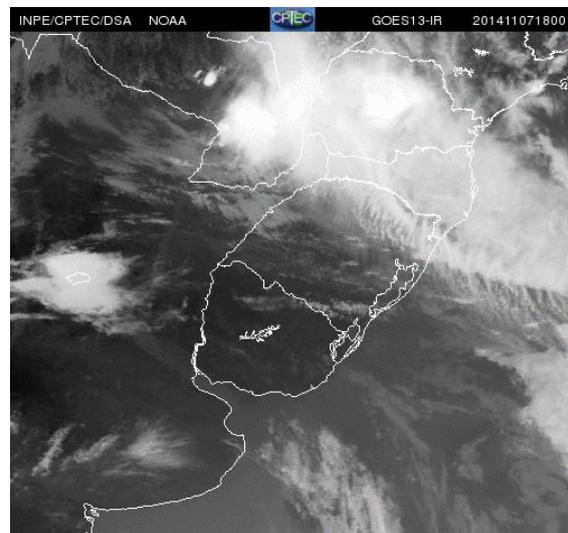


Figura 4.4: Imagem de satélite (infravermelho) do dia 07/11/2014 às 12 horas (a) e 18 horas (b).

Na análise da carta sinótica de superfície das 00Z do dia 07 de novembro, identificou-se uma frente estacionária no Atlântico afastado do continente em direção ao sul do estado de São Paulo, onde um sistema de baixa localizou-se ao leste de 10°W. Na retaguarda deste sistema formou-se o Anticiclone

Subtropical do Atlântico Sul (ASAS) com valor de 1032 hPa centrado em torno de 44°S/24°W deslocado para sul. No estado do Rio Grande do Sul observou-se um cavado invertido, associado ao padrão observado entre 850 e 500 hPa. A Alta Subtropical do Pacífico Sul (ASPS) apresentou um pulso de 1024 hPa alongado em torno da latitude de 30°S. Um sistema frontal com baixa pressão (em oclusão) estava posicionada em torno de 59°S/62°W, cujo ramo frio se estendeu em direção ao sul da Província de Buenos Aires Argentina. Um sistema frontal atuou no Pacífico ao sul de 50°S, com baixa pressão em torno de 55°S/89°W e com valor de 972 hPa, aproximadamente, Figura 4.5.

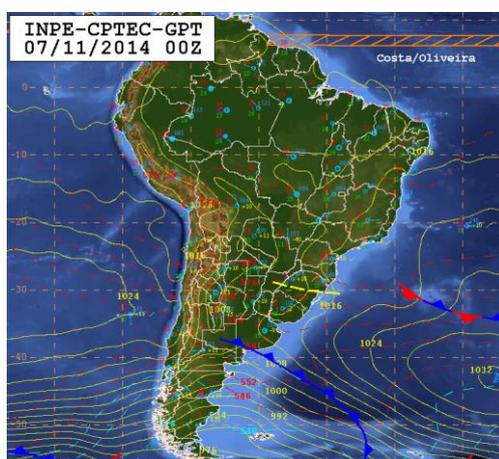


Figura 4.5: Carta sinótica de superfície do Grupo de Previsão do Tempo (GPT/CPTEC) do dia 07/11/2014 às 00:00 horas Z.

Assim, o sistema formou-se às 12:00 horas do dia 06 de novembro de 2014 no Rio Grande do Sul e Santa Catarina, intensificou-se na direção do oceano e Paraná e depois dividiu-se em dois núcleos, fundindo-se novamente no dia 07 de novembro de 2014 por volta das 12:00 horas, configurando um Sistema Convectivo de Mesoescala. Posteriormente dissipou-se na direção norte.

Os CAPPI de refletividade em 3km dos Radares de Assunção e Cascavel, Figura 4.6, mostram uma medida instantânea da refletividade para o horário das 12:00 horas GMT, Figura 4.6.

Nos dados de radar assimilados durante o evento foi possível observar os valores de refletividade entre médios e altos. A presença de obstáculos e

construções aparecem nas imagens do radar de Assunção no Paraguai, e atuaram como ruído.

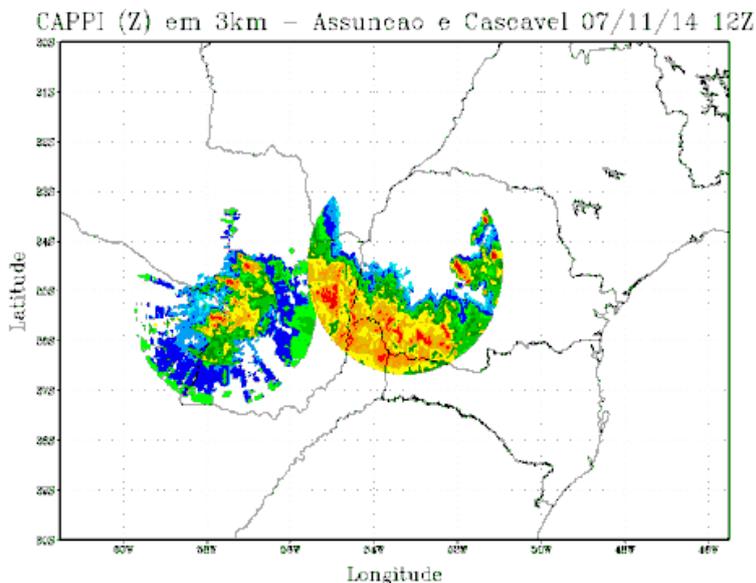


Figura 4.6: CAPPI em 3km dos radares de Cascavel e Assunção dia 07/11/2014 às 12 horas.

## 4.2 Resultados para precipitação

Com a assimilação de dados de radar foi feita a previsão de 06 horas de precipitação acumulada, considerado as três variações dos valores de *variance scale* e *length scaling*, conforme Tabela 3.1. Os resultados obtidos no posicionamento da precipitação para um horário de grande acumulado de precipitação das 12:00 horas do dia 07 de novembro de 2014, foram comparados com os resultados das rodadas sem spin up, Figura 4.7.b, com spin up Figura 4.7.c, com assimilação de dados GTS (com as variações de *variance scale* e *length scaling*), Figura 4.7.d com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.7.e com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.7.f com *variance scale*= 2.0 e *length scaling*= 0.5, e com a assimilação de dados de radar (com as variações de *variance scale* e *length scaling*), Figura 4.7.g com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.7.h com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.7.i com *variance scale*= 2.0

e *length scaling*= 0.5 em comparação com o *Tropical Rainfall Measuring Mission* (TRMM), 3B42, versão 07, Figura 4.7.a.

Com estimativa de precipitação acumulada de 06 horas do TRMM para as 12:00 horas, tem-se a Figura 4.7.a. para o controle. O modelo foi inicializado sem *spin up*, inicialização fria, para comparação com o experimento de controle, onde mostrou um posicionamento da precipitação do grande acúmulo de precipitação em uma área visualmente diferente, tanto quantitativamente como em posicionamento, Figura 4.7.b. Fato também observado por Ferreira (2016).

Com uma inicialização, ainda sem assimilação de dados GTS e sem assimilação de dados de Radar, foi feita uma rodada com *spin up* na busca da estabilização do modelo e que reduzisse as precipitações irrealis, Figura 4.7.c. Nesta rodada foi observado uma previsão da precipitação mais adequada e superior quando comparada à rodada sem *spin up*, mas ainda subestimando a quantidade de precipitação bem como o posicionamento dos núcleos convectivos quando comparado com o controle, demonstrando a importância da inicialização do modelo com *spin up*.

A inicialização com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.7.d, demonstrou a subestimação da quantidade de precipitação, bem como a diminuição da área de abrangência da precipitação em relação ao controle.

Com a rodada com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 1.0 e *length scaling*= 1.0, Figura 4.7.e, obteve-se uma melhora no posicionamento da precipitação em relação à configuração de *variance scale*= 0.5 e *length scaling*= 2.0, mas ainda distante do controle.

Para a rodada com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 2.0 e *length scaling*= 1.0, Figura 4.7.f, houve uma melhora no posicionamento da precipitação e quantidade de precipitação,

quando comparado com as rodadas anteriores com , Figuras 4.7.d e 4.7.e e com o controle.

Já com a rodada com *spin up*, com a assimilação de dados GTS e de radar, com a variação de *variance scale= 0.5* e *length scaling= 2.0*, Figura 4.7.g, observou-se subestimação da quantidade de precipitação, porém com um melhor posicionamento dos núcleos em relação às rodadas com *spin up* e assimilação de dados de GTS. A assimilação de dados de radar demonstrou um ganho no posicionamento dos grandes núcleos do grande acúmulo de precipitação.

Com a rodada com *spin up*, com a assimilação de dados GTS e de radar, com a variação de *variance scale= 1.0* e *length scaling= 1.0*, Figura 4.7.h, conseguiu-se o melhor posicionamento dos núcleos convectivos com relação a todas as rodadas anteriores, porém com uma superestimação da quantidade de precipitação, quando comparado com o controle. Com a variação de *variance scale= 1.0* e *length scaling= 1.0* obteve-se a melhor estimativa do posicionamento dos grandes acumulados de precipitação quando comparado com o controle, Figura 4.7.a.

A rodada com *spin up*, com a assimilação de dados GTS e de radar, com a variação de *variance scale= 2.0* e *length scaling= 0.5*, Figura 4.7.i, observou-se um melhor posicionamento em parte dos núcleos convectivos com relação a todas as rodadas anteriores, porém com uma superestimação da quantidade de precipitação e má localização em um dos núcleos convectivos, quando comparado com o controle.

Com base na análise subjetiva e visual das rodadas com suas variações, percebe-se que com o *spin up* e com a assimilação de dados de radar houve uma melhora no posicionamento dos núcleos convectivos, detectando o núcleo sobre o sudeste do Paraguai chegando mais próximos dos resultados estimados pelo controle, Figura 4.7.a.

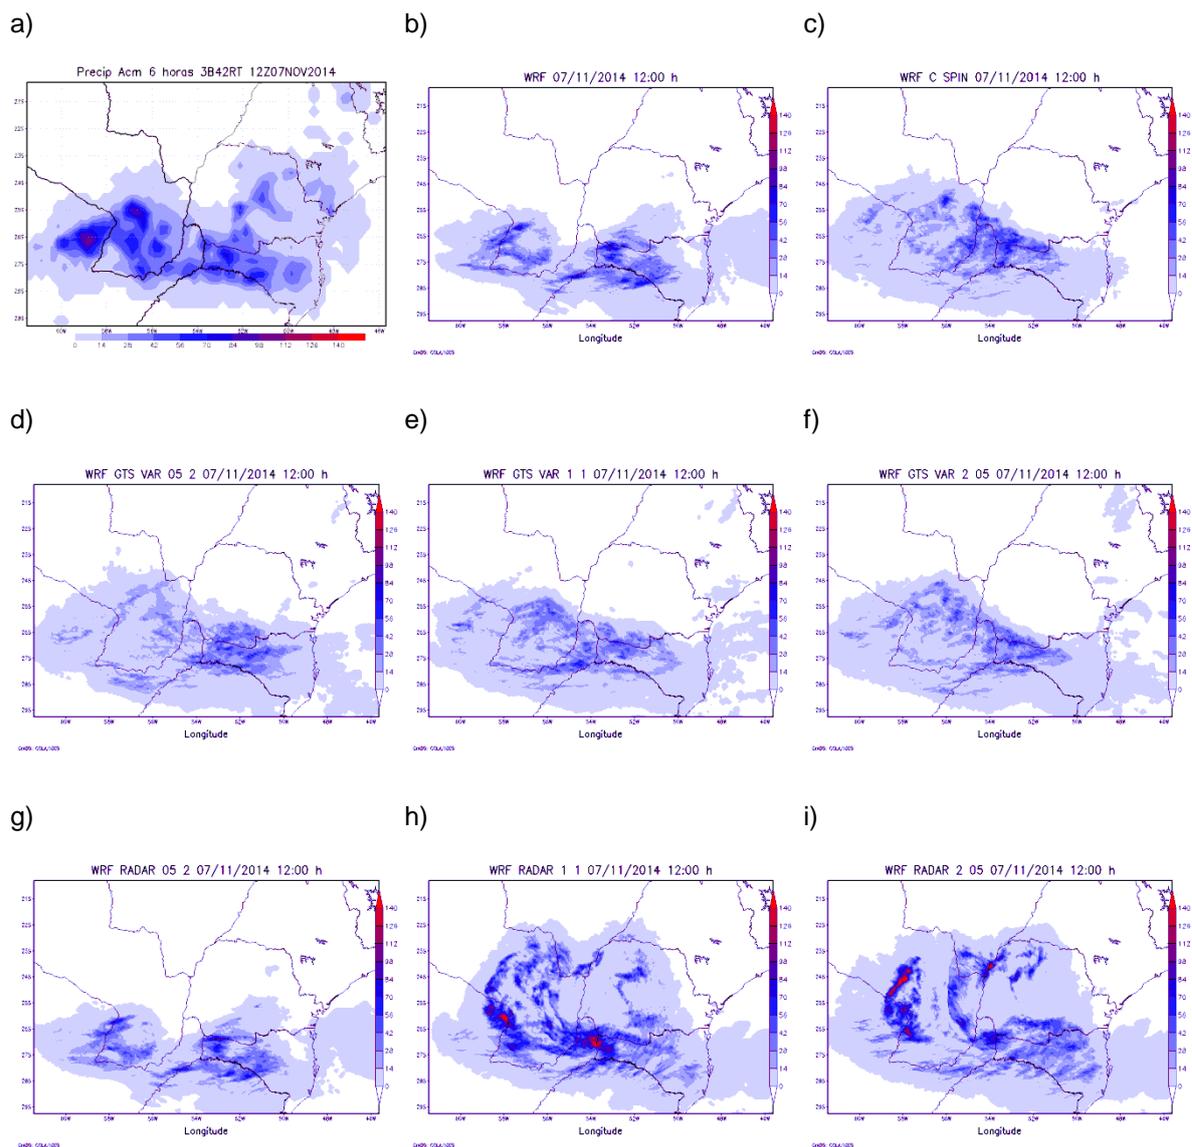


Figura 4.7.: Resultados da previsão de precipitação acumulada em 06 horas entre 06 e 12 horas do dia 07/11/2014, com as rodadas sem spin up, Figura 4.7.b, com spin up Figura 4.7.c, com assimilação de dados GTS (com as variações de *variance scale* e *length scaling*), Figura 4.7.d com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.7.e com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.7.f com *variance scale*= 2.0 e *length scaling*= 0.5, e com a assimilação de dados de radar (com as variações de *variance scale* e *length scaling*), Figura 4.7.g com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.7.h com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.7.i com *variance scale*= 2.0 e *length scaling*= 0.5 e comparação com o *Tropical Rainfall Measuring Mission* (TRMM), 3B42, versão 07, Figura 4.7.a como controle.

Os resultados obtidos no posicionamento da precipitação para um horário de grande acumulado de precipitação das 18:00 horas do dia 07 de novembro de 2014, foram comparados com os resultados das rodadas sem spin up, Figura

4.8.b, com spin up Figura 4.8.c, com assimilação de dados GTS (com as variações de *variance scale* e *length scaling*), Figura 4.8.d com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.e com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.8.f com *variance scale*= 2.0 e *length scaling*= 0.5, e com a assimilação de dados de radar (com as variações de *variance scale* e *length scaling*), Figura 4.8.g com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.h com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.8.i com *variance scale*= 2.0 e *length scaling*= 0.5 em comparação com o *Tropical Rainfall Measuring Mission* (TRMM), 3B42, versão 07, Figura 4.8.a.

Com estimativa de precipitação acumulada de 06 horas do TRMM para as 18:00 horas, tem-se a Figura 4.8.a. para o controle. O modelo foi inicializado sem *spin up*, inicialização fria, para comparação com o experimento de controle, onde mostrou um posicionamento da precipitação do grande acúmulo de precipitação em uma área visualmente diferente, tanto quantitativamente como em seu posicionamento, Figura 4.8.b.

Com uma inicialização, ainda sem assimilação de dados GTS e sem assimilação de dados de Radar, foi feita uma rodada com *spin up* na busca da estabilização do modelo e que reduzisse as precipitações irreais, Figura 4.8.c. Nesta rodada foi observado uma previsão da precipitação mais coerente e superior quando comparada à rodada sem *spin up*, mas ainda subestimando a quantidade de precipitação bem como o posicionamento dos núcleos convectivos quando comparado com o controle, mostrando a importância da inicialização do modelo com *spin up*. A inicialização do modelo com *spin up* foi importante para que o modelo pudesse estabilizar-se e não produzisse precipitações irreais, quando comparada à inicialização fria do modelo.

A inicialização com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.d, demonstrou a subestimação da quantidade de precipitação, bem como a diminuição da área de abrangência da precipitação em relação ao controle, com um ressecamento e um mau posicionamento do acumulado de grande precipitação.

Com a rodada com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 1.0 e *length scaling*= 1.0, Figura 4.8.e, obteve-se uma melhora na quantidade da precipitação em relação à configuração de *variance scale*= 0.5 e *length scaling*= 2.0, mas ainda com dificuldade no posicionamento dos grandes acumulados de precipitação.

Para a rodada com *spin up* e com somente a assimilação de dados GTS, com a variação de *variance scale*= 2.0 e *length scaling*= 1.0, Figura 4.8.f, houve um aumento da estimativa de precipitação acumulada, com pouca diferença em relação a rodada com variação de *variance scale*= 1.0 e *length scaling*= 1.0, com dificuldade no posicionamento dos grandes acumulados de precipitação.

Já com a rodada com *spin up*, com a assimilação de dados GTS e com a assimilação de dados radar, com a variação de *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.g, observou-se uma superestimação da quantidade de precipitação, e um mau posicionamento dos núcleos em relação às rodadas com *spin up* e assimilação de dados de GTS. A assimilação de dados de radar não demonstrou ganho no posicionamento dos grandes núcleos do grande acúmulo de precipitação.

Com base na análise subjetiva e visual das rodadas com suas variações, percebe-se que com o *spin up* e com a assimilação de dados de radar houve uma melhora no posicionamento dos núcleos convectivos, detectando o núcleo sobre o sudeste do Paraguai chegando mais próximos dos resultados estimados pelo controle, Figura 4.8.a.

Com a rodada com *spin up*, com a assimilação de dados GTS e com a assimilação de dados de radar, com a variação de *variance scale*= 1.0 e *length scaling*= 1.0, Figura 4.8.h, conseguiu-se o melhor posicionamento dos núcleos convectivos com relação a todas as rodadas anteriores, porém com uma superestimação da quantidade de precipitação, quando comparado com o controle. Com a variação de *variance scale*= 1.0 e *length scaling*= 1.0 obteve-se a melhor estimativa do posicionamento dos grandes acumulados de precipitação quando comparado com o controle, Figura 4.8.a.

A rodada com *spin up*, com a assimilação de dados GTS e com a assimilação de dados de radar, com a variação de *variance scale= 2.0* e *length scaling= 0.5*, Figura 4.8.i, observou-se um melhor posicionamento em parte dos núcleos convectivos com relação às rodadas com assimilação de dados anteriores, porém com resultados inferiores quando comparado com a variação de *variance scale= 1.0* e *length scaling= 1.0* com a assimilação de dados de radar.

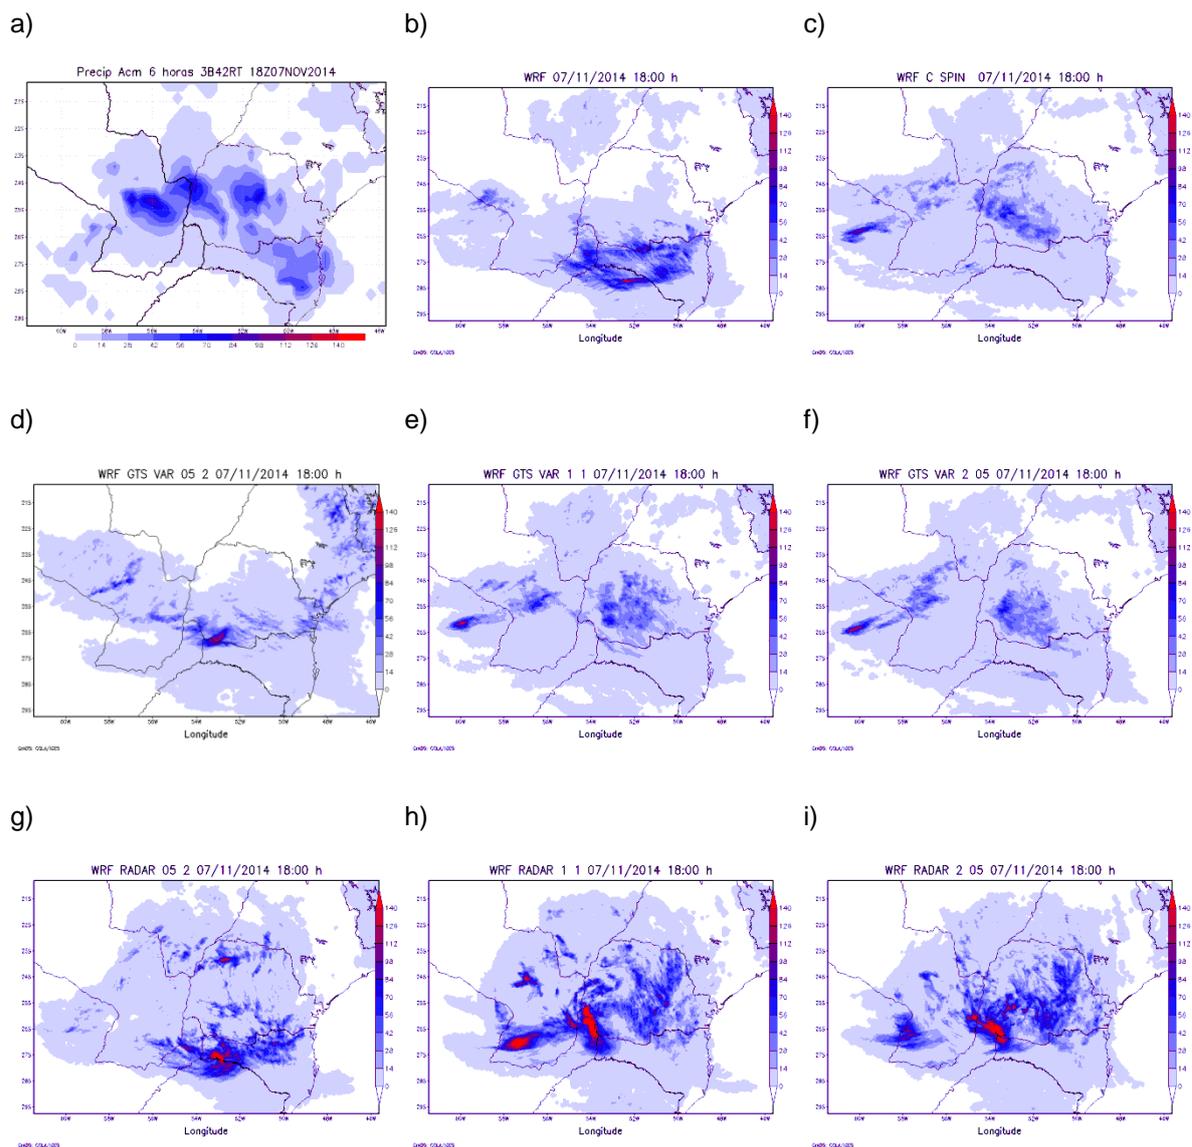


Figura 4.8: Resultados da previsão de precipitação acumulada em 06 horas entre 12 e 18 horas do dia 07/11/2014, com as rodadas sem spin up, Figura 4.8.b, com spin up Figura 4.8.c, com assimilação de dados GTS (com as variações de *variance scale* e *length scaling*), Figura 4.8.d com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.e com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.8.f com *variance scale*= 2.0 e *length scaling*= 0.5, e com a assimilação de dados de radar (com as variações de *variance scale* e *length scaling*), Figura 4.8.g com *variance scale*= 0.5 e *length scaling*= 2.0, Figura 4.8.h com *variance scale*= 1.0 e *length scaling*= 1.0 e Figura 4.8.i com *variance scale*= 2.0 e *length scaling*= 0.5 e comparação com o *Tropical Rainfall Measuring Mission* (TRMM), 3B42, versão 07, Figura 4.8.a como controle.

### 4.3 Resultados do RMSE para precipitação

O RMSE foi aplicado para indicar a magnitude do erro nos valores de precipitação acumulada previstos pelo modelo para estimar qual a configuração com ou sem assimilação de dados obteve melhor desempenho. Assim, o RMSE foi calculado para quantificar o quanto o modelo errou em prever os valores da precipitação acumulada para os dois horários, das 12:00 horas e 18:00 horas, considerando um raio de 40 km ao redor de cada estação meteorológica de superfície da qual foi obtido os dados observacionais para comparação com o modelo. Na figura 4.9 foram mostrados, para comparação, todos os resultados para as 12:00 horas sem *spin up*, com *spin up*, com assimilação de dados de GTS e com assimilação de dados de radar meteorológico, com os devidos ajustes dos parâmetros de *variance scale* e *length scaling* para comparação direta.

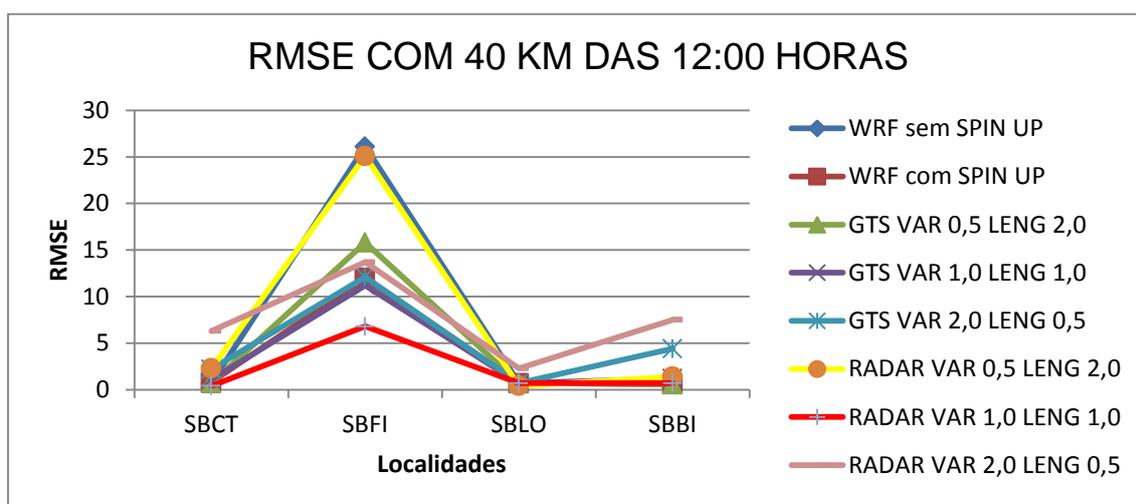


Figura 4.9: Comparação do RMSE da precipitação com 40 km das 12:00 horas.

A comparação das rodadas do WRF sem *spin up* e com *spin up* mostraram a importância do *spin up* para estabilização do modelo para que não produzisse precipitações irreais, quando comparado à inicialização fria do modelo, Figura 4.10.

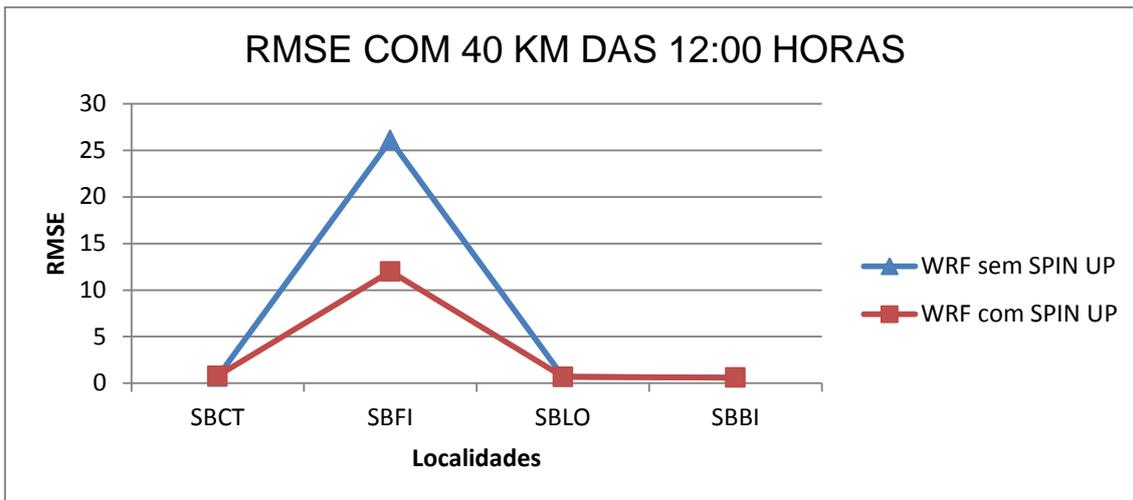


Figura 4.10: Comparação do RMSE com 40 km das 12:00 horas sem *spin up* e com *spin up*.

As rodadas do WRF com *spin up*, com a assimilação de dados de GTS e com o ajuste dos parâmetros *variance scale* e *length scaling* em suas 03 variações mostraram valores relativamente semelhantes, com pequena superioridade quando comparados com os valores do WRF sem *spin up* e com *spin up*, Figura 4.11.

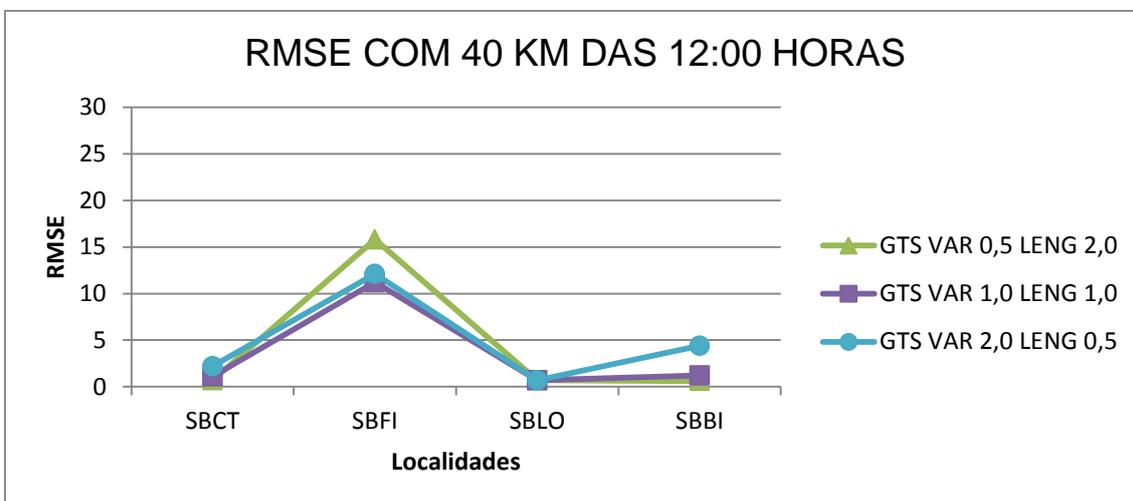


Figura 4.11: Comparação do RMSE com 40 km das 12:00 horas com *spin up*, com assimilação de dados de GTS e variações de *variance scale* e *length scaling*.

As rodadas do WRF com *spin up*, com a assimilação de dados de GTS, com assimilação de dados de radar meteorológico e com o ajuste dos parâmetros *variance scale* e *length scaling* em suas 03 variações mostraram valores que levam a uma superestimação da precipitação dos ajustes de *variance*

$scale=2.0$  e  $length\ scaling=0.5$  e uma leve melhora quando comparados com os resultados anteriores do ajuste de  $variance\ scale=1.0$  e  $length\ scaling=1.0$ , ou seja, quando foi dado o mesmo peso as observações e ao modelo, Figura 4.12.

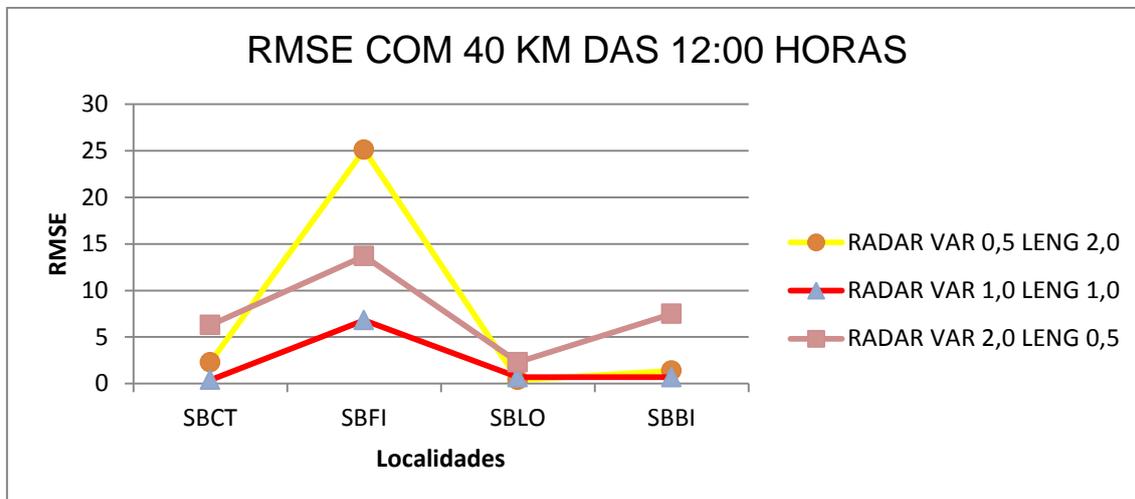


Figura 4.12: Comparação do RMSE com 40 km das 12:00 horas com *spin up*, com assimilação de dados de GTS, com assimilação de dados de radar e variações de *variance scale* e *length scaling*.

Na figura 4.13 foram mostrados, para comparação, todos os resultados para as 18:00 horas sem *spin up*, com *spin up*, com assimilação de dados de GTS e com assimilação de dados de radar meteorológico, com os devidos ajustes dos parâmetros de *variance scale* e *length scaling* para comparação direta.

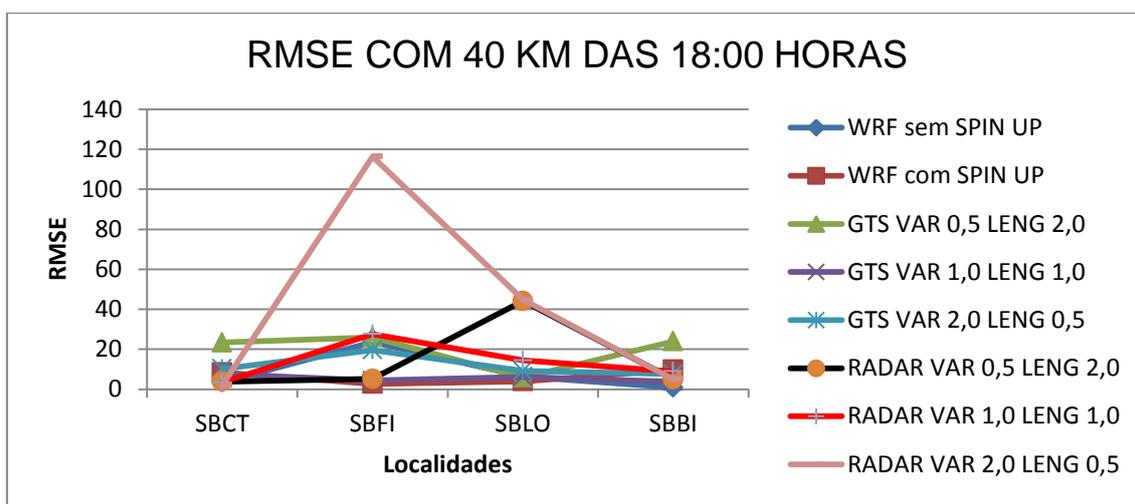


Figura 4.13: Comparação do RMSE com 40 km das 18:00 horas.

A comparação das rodadas do WRF sem *spin up* e com *spin up* também mostrou a importância do *spin up* para estabilização do modelo para que não produzisse precipitações irreais, neste caso, com pequena superioridade à inicialização fria do modelo, Figura 4.14.

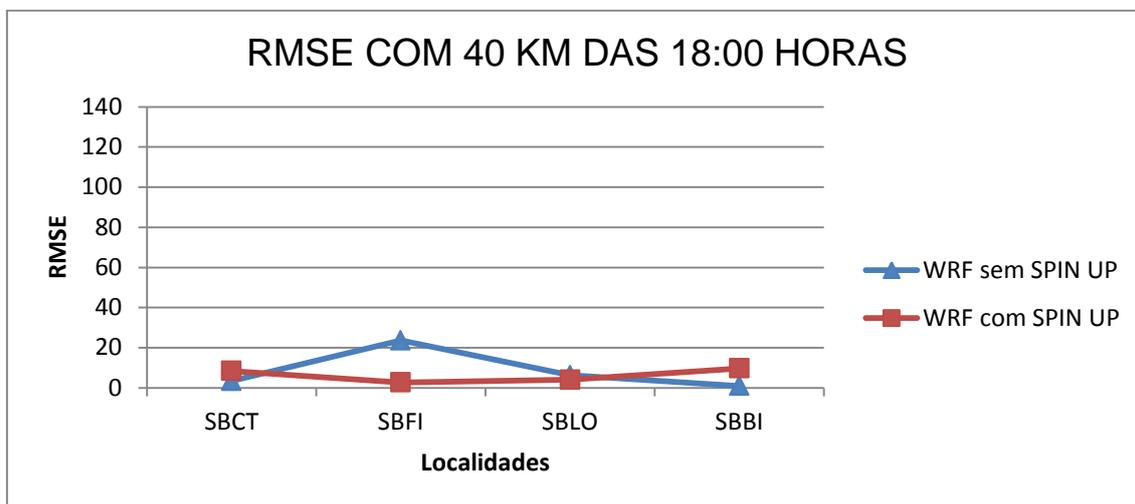


Figura 4.14: Comparação do RMSE com 40 km das 18:00 horas sem *spin up* e com *spin up*.

As rodadas do WRF com *spin up*, com a assimilação de dados de GTS e com o ajuste dos parâmetros *variance scale* e *length scaling* em suas 03 variações mostraram valores relativamente semelhantes, com pequena superioridade quando comparados com os valores do WRF sem *spin up* e com *spin up*, Figura 4.15. Os ajustes dos parâmetros *variance scale=1.0* e *length scaling=1.0* tiveram pequena superioridade quando comparados com os resultados anteriores, mostrando que quando dado o mesmo peso para as observações e o modelo contribuíram para melhores resultados.

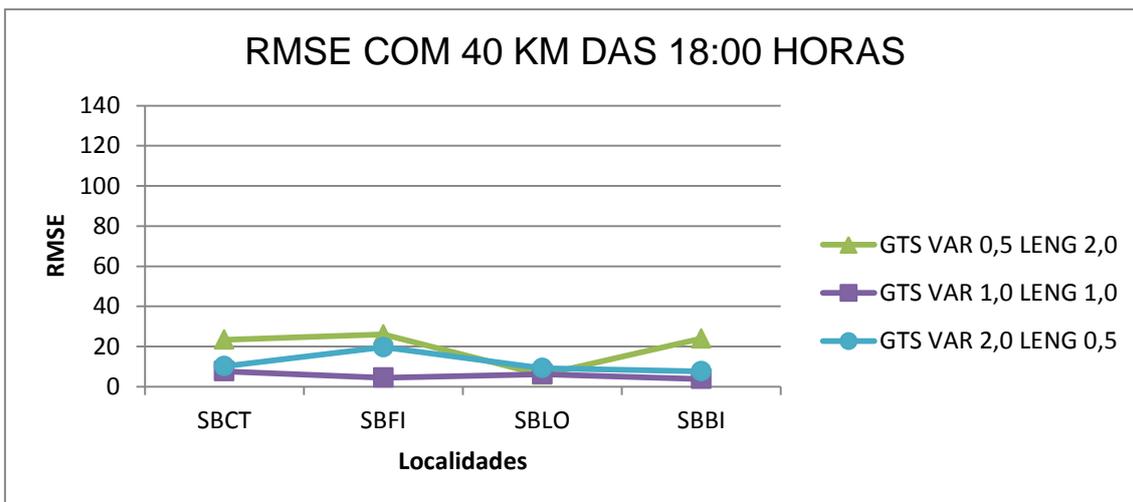


Figura 4.15: Comparação do RMSE com 40 km das 18:00 horas com *spin up*, com assimilação de dados de GTS e variações de *variance scale* e *lenght scaling*.

As rodadas do WRF com *spin up*, com a assimilação de dados de GTS, com assimilação de dados de radar meteorológico e com o ajuste dos parâmetros *variance scale* e *lenght scaling* em suas 03 variações mostraram valores que levam a uma superestimação da precipitação dos ajustes de *variance scale=2.0* e *lenght scaling=0.5*. Para os ajustes dos parâmetros de *variance scale=1.0* e *lenght scaling=1.0* houve uma pequena melhora quando comparados com os resultados anteriores, ou seja, também quando foi dado o mesmo peso as observações e ao modelo, Figura 4.16.

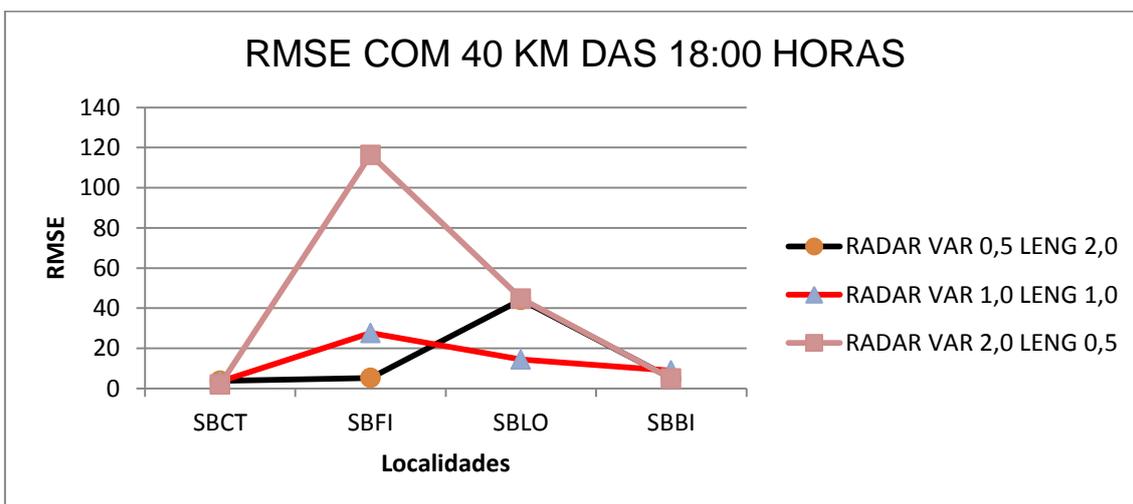


Figura 4.16: Comparação do RMSE com 40 km das 18:00 horas com *spin up*, com assimilação de dados de GTS, com assimilação de dados de radar e variações de *variance scale* e *lenght scaling*.

## 5 CONCLUSÃO

O objetivo do presente trabalho foi o ajuste do uso da matriz covariância do erro do *background*, ou matriz B, dentro do ciclo de assimilação de dados do radar Doppler, a fim de melhorar a análise e, como consequência, as previsões de precipitação de curto prazo. Neste sentido, a matriz de covariância do erro de *background* foi gerada aplicando o método NMC com 03 meses de simulações de 24 h a partir de 00UTC e 12UTC. O utilitário do WRF utilizado para a geração da matriz B espalhou horizontalmente as informações de uma determinada observação usando um filtro recursivo, em seguida, o ajuste da matriz de covariância do erro de *background* foi aplicado, ajustando os parâmetros *variance scaling* e *length scaling*, com três variações, de modo a ajustá-los para a região de estudo, os dados assimilados e o sistema meteorológico estudado. Os resultados baseados nos índices estatísticos mostraram melhorias na localização da precipitação quando aplicado o ajuste na matriz de covariância do erro de *background*. Este estudo utilizou a matriz de erro das covariâncias do *background* (B), com os valores de 01 de outubro de 2014 até 31 de dezembro de 2014, onde o modelo foi inicializado às 12 UTC, com condição inicial e fronteira do GFS-NCEP, gerando condição inicial (*background*) para o primeiro ciclo de assimilação às 15 UTC, com a avaliação da precipitação feita comparando os resultados da modelagem com os dados do *Tropical Rainfall Measuring Mission* (TRMM) 3B42, usando os índices estatísticos como o *Root Mean Square Error* (RMSE). Além dos dados de radar, também foram assimilados dados convencionais provenientes do *Global Telecommunication System* (GTS).

O uso indireto de dados de umidade e velocidade dos hidrometeoros contidos na atmosfera resultou na melhora da previsão do posicionamento dos núcleos convectivos e na precisão da localização da precipitação, bem como forneceram melhores resultados na previsão do tempo de curto prazo. Com esta metodologia, buscou-se a um melhor desempenho na assimilação de dados de radar e uma melhor previsão da precipitação, o que permitiu um

estudo mais preciso destes sistemas visando uma previsão de curto prazo, 06 horas.

Especificamente, buscou-se o melhor ajuste dos parâmetros *length scaling* e *variance scaling* da matriz de covariância dos erros de *background* dentro do ciclo de assimilação de dados, definindo, também, a importância dos ajustes destes parâmetros e quais valores são mais apropriados para a região de estudo e para o sistema estudado, ou seja, sistemas convectivos de mesoescala.

Dada a análise feita percebe-se que com a assimilação de dados de radar houve uma superestimação dos valores de precipitação com todas as variações dos parâmetros de *length scaling* e *variance scaling* em virtude da entrada dos valores como observações, mesmo quando há a variação do peso dado as observações e a previsão do modelo. Porém há um melhor posicionamento pelo modelo dos grandes núcleos quando se iguala os pesos entre as observações e o modelo. Quando é dado maior peso ao modelo há uma superestimação da precipitação e os núcleos de grande precipitação não são bem localizados.

Os resultados baseados no índice estatístico utilizado, mostraram pequenas melhorias na quantificação dos valores de precipitação quando aplicado o ajuste na matriz de covariância do erro de background. Através de uma análise subjetiva e estatística do RMSE, constatou-se que o melhor ajuste dos parâmetros *length scaling* seria o valor de 1.0 e da *variance scaling* seria o valor de 1.0, da matriz de covariância dos erros de *background* dentro do ciclo de assimilação de dados.

Com os valores de *length scaling* = 1.0 e *variance scaling* = 1.0, através de uma análise subjetiva, estimou-se uma melhor localização dos grandes núcleos de precipitação acumulada de 06 horas, porém ainda são necessários maiores estudos para os valores de quantidade de precipitação.

Com isso, chegou-se a um melhor desempenho na assimilação de dados de radar e uma melhor previsão de curto prazo da precipitação, o que permitiu um estudo mais acurado destes sistemas, com um melhor posicionamento do sistema quando comparado à estimativa de satélite, portanto, uma melhor localização dos núcleos mais intensos de precipitação, ressaltando que os dados de radar assimilados não foram tratados.

Portanto com o desenvolvimento deste trabalho, que envolve a assimilação de dados de radar e ajuste das variáveis dos parâmetros da matriz de covariância do erro de *background*, obtiveram-se melhores resultados na previsão de curto prazo da localização dos núcleos de precipitação.

### **5.1 Sugestões para trabalhos futuros**

Propõe-se para continuidade deste trabalho, outros testes com novas combinações que busquem uma melhor combinação do ajuste dos parâmetros *length scaling* e *variance scaling* da matriz de covariância dos erros de *background* dentro do ciclo de assimilação de dados como:

- a) Outras parametrizações de microfísica, pois também influem nos valores de precipitação do modelo.
- b) Assimilação de um maior número de radares meteorológicos para que se possa ter uma maior área de cobertura da grade do modelo.
- c) Testes com outros ciclos de assimilação de dados de radares meteorológicos para que se consigam melhores resultados do modelo e implementações operacionais.
- d) Outras configurações de *spin up* que melhorem a inicialização do modelo e sua estabilização.



## REFERÊNCIAS BIBLIOGRÁFICAS

AKSOY, A.; DOWELL, D. C.; SNYDER, C. A multi-case comparative assessment of the ensemble kalman filter for assimilation of radar observations. part i: Storm-scale analyses. **Mon. Wea. Rev.**, v. 137, p. 1805–1824, 2009.

BARKER, D. et al. **A three-dimensional variational (3DVAR) data assimilation system for use with MM5**. Boulder, CO: MMM Division, NCAR, 2001.

BARKER, D. et al. A three-dimensional variational data assimilation system for mm5: Implementation and initial results. **Monthly Weather Review**, v. 132, p. 897–914, 2004.

BERGTHORSSON, P.; DOOS, B. Numerical weather map analysis. **Tellus**, v. 7, p. 329–340, 1955.

BJERKNES, V. et al. **Dynamic meteorology and hydrography**: kinematics. Carnegie Institution of Washington, 1911. (Carnegie Institution of Washington. Publication no. 88).

BOUQUIER, F. Fine scale versus large scale data assimilation - a discussion. In: CAWCR WORKSHOP ON ENSEMBLE PREDICTION AND DATA ASSIMILATION, 5., 2009, Melbourne, Australia. **Proceedings...** Melbourne: WMO, 2009.

CHARNEY, J. G. **Dynamical forecasting by numerical process**. In: MALONE, T. F. (ed.). **Compendium of meteorology**. Boston: American Meteorological Society, 1951.

CHARNEY, J. G.; FJÖRTOFT, R.; NEUMANN, J. V. Numerical integration of the barotropic vorticity equation. **Tellus, Blackwell Publishing Ltd**, v. 2, n. 4, p. 237–254, 1950. ISSN 2153-3490.

CHOU, C.-B.; HUANG, H.-P. 2011: the impact of assimilating atmospheric infrared sounder observation on the forecast of typhoon tracks. **Adv. Meteorol.**, v. 2011 (2011), n. ID 803593, 2011. doi:10.1155/2011/803593.

COURTIER, P.; THEPAUT, J. N.; HOLLINGSWORTH, A. A strategy for operational implementation of 4d-var, using an incremental approach. **Quart. J. Roy. Meteor. Soc.**, v. 120, p. 1367–1387, 1994.

CRESSMAN, G. P. An operational objective analysis system. **Monthly Weather Review**, v. 87, p. 367–374, 1976.

DALEY, R. **Atmospheric data analysis**. Cambridge: University Press, 1993. (Cambridge Atmospheric and Space Science Series). ISBN 9780521458252.

DOWELL, D. C.; SNYDER, C. A multi-case comparative assessment of the ensemble kalman filter for assimilation of radar observations. part i: storm-scale analyses. **Mon. Wea. Rev.**, v. 137, p. 1805–1824, 2009.

ELIASSEN, A. **Provisional report on calculation of spatial covariance and autocorrelation of the pressure field**. Oslo: Wea. and Climate Res., 1954. Report No. 5. 13.

EVENSEN, G. Sequential data assimilation with a nonlinear quasi-geostrophic model using monte carlo methods to forecast error statistics. **J. Geophys. Res.**, v. 99 (C5), p. 10143–10162, 1994.

GAL-CHEN, T. A method for the initialization of the anelastic equation: Implication for matching models with the observations. **Mon Wea. Rev.**, 106, 587-66. 1978.

GANDIN, L. **Objective analysis of meteorological fields**. Leningrad: Hydromet Press, 1963. 13.

GILCHRIST, B.; CRESSMAN, G. P. An experiment in objective analysis. **Tellus, Blackwell Publishing Ltd**, v. 6, n. 4, p. 309–318, 1954. ISSN 2153-3490.

GUO, Y.-R.; FAN, S.-Y.; WANG, W.; CHEN, M.; HUANG, X.-Y.; WANG, Y.-C.; KUO, Y.-H. Application of wrfvar (3dvar) to a high resolution (3-km) model over Beijing area. In: WRF Users' Workshop, 8., 2007, Boulder, CO. **Extended Abstracts...** Boulder: [s.n.], 2007.

GUO, Y.; LI, R. Observation pre-processor for wrfda. In: **WRFDA Tutorials**. Boulder, CO: NCAR, 2012.

HA, J.-H.; LEE, D.-K. Effect of length scale tuning of *background* error in wrf-3dvar system on assimilation of high-resolution surface data for heavyrainfall simulation. **Advances in Atmospheric Science**, v. 29, 6, p. 1142–1158, 2012.

HAYDEN, C. M.; PURSER, R. J. Recursive filter objective analysis of meteorological fields: applications to NESDIS operational processing. **J. Appl. Meteor.**, v.34, p. 3–15, 1995.

HUFFMAN, G. J. et al. Analysis of TRMM 3-hourly multi-satellite precipitation estimates computed in both real and post-real time. In: CONFERENCE SATELLITE AND METEOTOLOGY AND OCEANOGRAPHY, 12., 2003, Lonf Beach, CA. **Proceedings...** Long Beach: AMS, 2002.

HOKE, J.; ANTHES, R. The initialization of numerical models by a dynamic relaxation technique. **Monthly Weather Review**, v. 104, p. 1551–1556, 1976.

IDE, K. et al. Unified notation for data assimilation: operational, sequential and variational. [Journal of the Meteorological Society of Japan](#), v.75, n. 1B, Sept., 1997.

KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. Cambridge: University Press, 2003. ISBN 9780521796293.

KAWABATA, T.; KURODA, T.; SEKO, H.; SAITO, K. A cloud-resolving 4dvar assimilation experiment for a local heavy rainfall event in the tokyo metropolitan area. **Mon. Wea. Rev.**, v. 139, p. 1911–1931, 2011.

LIU, J.; BRAY, M.; HAN, D. A study on wrf radar data assimilation for hydrological rainfall prediction. **Hydrology and Earth System Sciences**, v. 17, n. 8, p. 3095–3110, 2013.

LORENC, A. C. Analysis methods for numerical weather prediction. **Quarterly Journal of the Royal Meteorological Society**, v. 112, p. 1177–1194, 1986.

MING, C.; FAN, S.-Y.; ZHONG, J.; HUANG, X.-Y.; GUO, Y.-R.; WANG, W.; WANG, Y.; KUO, B. A wrf-based rapid updating cycling forecast system of bm band its performance during the summer and Olympic games 2008. In: WORLD METEOROLOGICAL ORGANIZATION SYMPOSIUM ON NOWCASTING AND VERY SHORT TERM FORECASTING, 2009, Whistler, British Columbia. **Proceedings...** Whistler: World Meteorological Organization /World Weather Research Programme, 2009.

NATIONAL CENTER FOR ATMOSPHERIC RESEARCH (NCAR). **The climate data guide**: simplistic overview of reanalysis data assimilation methods. Boulder, CO, 2013.

PARRISH, D. F.; DERBER, J. C. The national meteorological center's spectral statistical-interpolation analysis system. **Monthly Weather Review**, v. 120, p. 1747–1763, 1992.

RABIER, F. et al. The ecmwf implementation of three-dimensional variational assimilation (3d-var). ii: Structure function. **Quart. J. Roy. Meteor. Soc.**, v. 124, p. 1809–1830, 1998.

RICHARDSON, L. **Weather prediction by numerical process**. Cambridge: University Press, 1922.

ROUX, F. Retrieval of thermodynamic fields from multiple Doppler radar data, using the equations of motion and the thermodynamic equation. **Mon. Weather Rev.**, v.113, p. 2142–2157, 1985.

SANTOS, R. R. et al. Resultados preliminares do sistema de assimilação de dados 3d-var no MBAR do INMET. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 17., 2012, Gramado. **Anais...** Rio de Janeiro: SBMet,, 2012.

SHIMIZU, S.; MAKI, M.; MAESAKA, T.; IWANAMI, K.; S., S. Short-range forecast using mpradar network and 3dvar assimilation for the heavy rain- fall in north tokyo on july 5th 2010. In: JAPAN GEOSCIENCE UNION MEETING, 2011, Chiba, Japan. **Proceedings...** [s.n.], 2011.

SILVA, G. L. D.; SILVA, A. S. D.; YAMASAKI, Y. Validação da assimilação de dados na inferência da refletividade de um radar com o sistema mm5 . **Revista Brasileira de Meteorologia**, n. 1993, p.75–84, 2012.

SKAMAROCK, W. C. et al. **A description of the advanced research WRF - Version 3.** Boulder, Colorado, USA, June 2008.

SNYDER, C.; ZHANG, F. Assimilation of simulated doppler radar observations with an ensemble kalman filter. **Mon. Wea. Rev.**, v. 131, p. 1663–1677, 2003. 17.

Sugimoto, S. et al. An examination of WRF 3DVAR radar data assimilation on its capability in retrieving unobserved variables and forecasting precipitation through observing system simulation experiments. **Monthly Weather Review**, v. 137, n. 11, p. 4011–4029, 2009.

SUN, J.; CROOK, N. A. Dynamical and microphysical retrieval from doppler radar observations using a cloud model and its adjoint. part i: model development and simulated data experiments. **Journal of the Atmospheric Sciences**, v. 54, n. 12, p. 1642–1661, jun. 1997.

JUANZHEN, S.;CROOK, N. A . Real-time low-level wind and temperature analysis using single wsr-88d data. **Wea. Forecasting**, v. 16, p. 117–132, 2001. 16, 34.

SUN, J. Convective-scale assimilation of radar data: progress and challenges. **Quart. J. Roy. Meteor. Soc.**, v. 131, p. 3439–3463, 2005. 11, 13, 16, 19, 34.

\_\_\_\_\_. Convective-scale assimilation of radar data: progress and challenges, **Q. J. R. Meteorol. Soc.**, 131, p. 3439–3463, 2005. doi: 10.1256/qj.05.149 Revisid in 2006.

SUN, J.; WANG, H. Radar data assimilation with wrf 4d-var: Part ii. Comparison with 3d-var for a squall line case. **Mon. Wea. Rev.**, v. 141, p. 2245–2264, 2013.

TONG, W.; SUN, J.; LI, G.; WANG, H. A study on the assimilation cycling configuration for convective precipitation forecast using wrf 3dvar. In: WRF USERS' WORKSHOP, 2014, Boulder, CO. **Proceedings...** Boulder: WRF, 2014.

UCAR; DTC. **The weather research and forecast model**. 2013.

VENDRASCO, E. P.; HERDIES, D. L.; ANGELIS, C. F. Avaliação do impacto da assimilação de dados de radar na previsão de precipitação a curtíssimo prazo. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 17., 2012, Gramado. **Anais...** Rio de Janeiro: SBMet, 2012. p. 1–5.

VENDRASCO, E. P. **Impacto da assimilação de dados de radar na previsão de curto prazo**. 2015. 208 p. (sid.inpe.br/mtc-m18/2015/04.30.17.42-TDI). Tese (Doutorado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2015. Disponível em: <<http://urlib.net/8JMKD3MGP8W/3JD.JQU2>>. Acesso em: 12 set. 2016.

XIAO, Q.; KUO, Y. H.; SUN, J.; LEE, W. C.; LIM, E.; GUO, Y.; BARKER, D. M. Assimilation of doppler radar observations with a regional 3dvar system: Impact of doppler velocities on forecasts of a heavy rainfall case. **J. Appl. Meteor.**, v. 44, p. 768–788, 2005.

WANG, H. et al. Indirect assimilation of radar reflectivity with wrf 3d-var and its impact on prediction of four summertime convective events. **Journal of Applied Meteorology and Climatology**, v. 52, n. 4, p. 889–902, 2013.

WANG, W. et al. **ARW version 3 modeling system user's guide January 2014**. [S.I.]: NCAR, 2014.

WARNER, T. T. **Numerical weather and climate prediction**. Cambridge: University Press, 2011. ISBN 9780521513890.

WILSON, J. W., SCHREIBER, W. E. Initiation of convective storms at radar-observed boundary-layer convergence lines. **Mon. Weather Rev.**, v. 114, p. 2516–2536, 1986.

ZIEGLER, C. Retrieval of thermal and microphysical variables in observed convective storms. I: model development and preliminary testing. **J. Atmos. Sci.**, v. 42, 1487–1509, 1985.