



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2021/02.24.18.02-TDI

**IMPACTO DA ASSIMILAÇÃO DE DADOS
CONJUNTO-VARIACIONAL NA PREVISÃO DE
EPISÓDIOS DE CHUVAS INTENSAS NO NORDESTE
BRASILEIRO**

João Pedro Gonçalves Nobre

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelos Drs.
Dirceu Luis Herdies, e Éder Paulo
Vendrasco, aprovada em 22 de
fevereiro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/448DGFE>>

INPE
São José dos Campos
2021

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2021/02.24.18.02-TDI

**IMPACTO DA ASSIMILAÇÃO DE DADOS
CONJUNTO-VARIACIONAL NA PREVISÃO DE
EPISÓDIOS DE CHUVAS INTENSAS NO NORDESTE
BRASILEIRO**

João Pedro Gonçalves Nobre

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelos Drs.
Dirceu Luis Herdies, e Éder Paulo
Vendrasco, aprovada em 22 de
fevereiro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/448DGFE>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Nobre, João Pedro Gonçalves.

N669i Impacto da assimilação de dados Conjunto-variacional na previsão de episódios de chuvas intensas no Nordeste brasileiro / João Pedro Gonçalves Nobre. – São José dos Campos : INPE, 2021.

xxvi + 145 p. ; (sid.inpe.br/mtc-m21c/2021/02.24.18.02-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientadores : Drs. Dirceu Luis Herdies, e Éder Paulo Vendrasco.

1. 3DVar. 2. 3DEnVar. 3. Sistemas Convectivos de Mesoescala. 4. Assimilação de Dados. 5. Gridpoint Statistical Interpolation. I.Título.

CDU 551.509.313.3(812/813)



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/).



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

Pós Graduação
Meteorologia

ATA DE REUNIÃO

DEFESA FINAL DE DISSERTAÇÃO: JOÃO PEDRO GONÇALVES NOBRE

No dia 22 de fevereiro, às 09h00, por videoconferência, o aluno mencionado acima defendeu seu trabalho final, intitulado "**IMPACTO DA ASSIMILAÇÃO DE DADOS ENSEMBLE-VARIACIONAL NA PREVISÃO DE EPISÓDIOS DE CHUVAS INTENSAS NO NORDESTE BRASILEIRO**" (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O aluno foi **APROVADO** pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Meteorologia.

A banca sugere incorporar as observações dos membros na dissertação, bem como mudança do título para:

Título: "IMPACTO DA ASSIMILAÇÃO DE DADOS POR CONJUNTO-VARIACIONAL NA PREVISÃO DE EPISÓDIOS DE CHUVAS INTENSAS NO NORDESTE BRASILEIRO"

Eu, Luís Gustavo Gonçalves de Gonçalves, como Presidente da Banca Examinadora, assino esta ATA em nome de todos os membros.

Membros da Banca

Dr. Dirceu Luis Herdies (**orientador**) - CPTEC – INPE

Dr. Éder Paulo Vendrasco (**orientador**) - CPTEC – INPE

Dr. Luís Gustavo Gonçalves de Gonçalves (**Presidente**)- CPTEC – INPE

Dr. Carlos Frederico Bastarz (**Convidado**) - CPTEC – INPE

Dr. Fabricio Pereira Harter (**Convidado**) - Universidade Federal de Pelotas - UFPEL



Documento assinado eletronicamente por **Luís Gustavo Gonçalves de Gonçalves, Pesquisador**, em 24/06/2021, às 13:35 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7697689** e o código CRC **4A96A2AF**.

Referência: Processo nº 01340.000653/2021-33

SEI nº 6557479

“Não existe isso de se estar completamente preparado. A vida é uma aventura através da qual aprendemos e amadurecemos. É claro que precisamos considerar todas as opções com cuidado. Mas se esperarmos ter 100 por cento de certeza, já será tarde demais”.

HAEMIN SUNIM

em “As coisas que você só vê quando desacelera”, 2012

*A meus pais **Vânia** e **Eraldo**, a meus irmãos **Gabriel** e **Gustavo**, a meus professores de graduação, em especial, **Dr. Helber Barros Gomes, Dr(a). Natalia Fedorova** e **Dr. Ricardo Amorim***

AGRADECIMENTOS

Agradeço aos pesquisadores Dr. Carlos Frederico Bastarz e Dr. Éder Paulo Vendrasco por todos os ensinamentos e suporte no aprimoramento do Sistema de Modelagem Regional do Centro de Previsão de Tempo e Estudos Climáticos e ao Dr. Dirceu Luis Herdies por ter me acolhido como orientando. Aos professores da Pós-Graduação em meteorologia, em especial ao professor Dr. Gustavo Gonçalves de Gonçalves, pelos conhecimentos fornecidos a mim através da disciplina acadêmica de assimilação de dados. A meus colegas da pós-graduação pela companhia e suporte emocional, vocês foram fundamentais para que eu superasse uma série de adversidades ao longo dos anos do mestrado e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de pesquisa concedida.

RESUMO

O Nordeste Brasileiro (NEB) encontra-se na região tropical do Brasil, limitado pelo oceano Atlântico e com um clima e vegetação fortemente influenciados pelo Planalto da Borborema. A presença desse planalto marca significativamente o clima da região ao manter a leste massas de ar com características mais úmidas e responsáveis pela ocorrência de chuvas e o lado oeste, massas de ar predominantemente secas. Este trabalho visa avaliar a performance dos diferentes sistemas de assimilação dados; 3DVar (*Three-Dimensional Variational*), EnKF (*Ensemble Kalman Filter*) e o híbrido, 3DEnVar (*Three-Dimensional Ensemble-Variational*), no estudo de episódios de SCM (Sistemas Convectivos de Mesoescala), utilizando previsões do modelo meteorológico de mesoescala WRF (*Weather Research and Forecasting*), em comparação com previsões do WRF inicializadas com dados do GEFS (*Global Ensemble Forecast System*), para dois eventos de SCM ocorridos nos dias 14 e 24 de janeiro de 2017. Para isso, será utilizada a versão V3.0.0 do SMR (Sistema de Modelagem Regional) do CPTEC (Centro de Previsão de Tempo e Estudos Climáticos) constituído de dois componentes: o modelo WRF e o sistema de assimilação de dados GSI (*Gridpoint Statistical Interpolation*). Atualmente, o SMR encontra-se configurado para fornecer condições iniciais ao modelo WRF atualizadas pelo 3DVar, que utiliza uma matriz de covariância dos erros de previsão climatológica, para ponderar os erros do modelo no processo de minimização da função custo. No presente trabalho, utilizou-se o 3DEnVar no SMR, que consiste de um sistema 3DVar, cuja matriz de covariância dos erros de previsão é calculada através da combinação linear dos membros de um conjunto de previsões que servirão para atualizar a matriz climatológica do SMR, com os erros do dia. Desse modo, o presente trabalho visa melhorar a detecção e estimativa da quantidade de chuva dos casos de SCM sobre o NEB ao utilizar a análise do 3DEnVar na previsão de chuva acumulada em 24 h. Resultados obtidos ilustram que o sistema de assimilação de dados híbrido (3DEnVar) foi capaz de gerar melhores análises, se comparado a um sistema variacional puro (3DVar), para os campos de pressão superficial e umidade ao analisar estatisticamente o desempenho dos sistemas variacionais através do BIAS e RMSE (*Root Mean Square Error*). O melhoramento obtido na representação dos campos de umidade através do 3DEnVar foi essencial para obtenção de boas previsões de chuva acumulada em 24 horas, com o modelo WRF, ao ser comparado com a precipitação registrada por estações meteorológicas em superfície, do Instituto Nacional de Meteorologia (INMET), para os dias 14 e 24 de janeiro de 2017 sobre o NEB.

Palavras-chave: 3DVar. 3DEnVar. Sistemas Convectivos de Mesoescala. Assimilação de Dados. *Gridpoint Statistical Interpolation*. Nordeste Brasileiro.

ENSEMBLE-VARIATIONAL DATA ASSIMILATION IMPACT IN HEAVY RAIN FORECASTING EPISODES IN BRAZILIAN NORTHEAST

ABSTRACT

The Brazilian Northeast (BNE) is located in the tropical region of Brazil, it is bounded by the Atlantic Ocean, and its climate and vegetation is strongly affected by the Borborema Plateau. The presence of the plateau significantly defines the climate region. It keeps the humid air masses to the east, which is responsible for the rain episodes, and at the west side (northeastern hinterland) predominantly dry air masses are observed. This work evaluates the performance obtained from different data assimilation methods, 3DVar (Three-Dimensional Variational), EnKF (Ensemble Kalman Filter), and 3DEnVar (Three-Dimensional Ensemble Variational), in the study of Mesoscale Convective Systems (MCS) episodes. The deterministic predictions was used from the GEFS (Global Ensemble Forecast System) model to compare with the WRF (Weather Research and Forecasting) numerical weather forecast model analysis updated by different data assimilation methods for January 14th and 24th, 2017 MCS episodes. For that purpose, the RMS (Regional Modeling System) 3.0.0 version from the Center for Weather Forecasting and Climate Studies was used with two components: the WRF mesoscale model and the GSI (Gridpoint Statistical Interpolation) data assimilation system. Currently, the SMR provides the WRF initial conditions using the 3DVar data assimilation methodology that uses a climatological forecast error covariance matrix to weight the model errors in the cost function minimization process. At this work, the 3DEnVar was used in the SMR, and it updates the SMR climatological covariance matrix through the forecast ensemble members with the errors of the day. To summarise, the present work studied the improvements in the detection and estimation of 24 hours rain accumulated precipitation quality in MCS cases over BNE. The statistics indexes BIAS and RMSE (Root Mean Square Error) show that the hybrid data assimilation system (3DEnVar) is the best variational system in producing better analyses for the surface pressure and humidity fields. The best humidity performances with 3DEnVar were essential in forecasting 24 hours accumulated precipitation compared with observational data from the Brazilian National Institute of Meteorology (INMET) stations, during convective storms over BNE on January 14th and 24th, 2017.

Keywords: 3DVar. 3DEnVar. Mesoscale Convective Systems. Data Assimilation. Gridpoint Statistical Interpolation. Brazilian Northeast.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Escala dos sistemas meteorológicos.	6
1.2 Esquematização dos processos dinâmicos e fenômenos adversos associados à formação dos SCM sobre o HS.	7
1.3 Distribuição espacial dos dados de observações convencionais provenientes de estações meteorológicas terrestres, de ar superior e boias oceânicas para novembro de 2019.	11
2.1 Mapa topográfico do NEB com a elevação em metros.	22
2.2 Esquema ilustrando a contabilização do número pixels e a área dos SCM utilizando as imagens do satélite GOES-13.	23
2.3 Componentes para execução do modelo WRF.	25
2.4 Domínio sobre o NEB configurado para execução do modelo WRF.	27
2.5 Disposição das variáveis meteorológicas nas grades de A a E de Arakawa.	28
2.6 Fluxograma dos processos microfísicos no esquema WSM6.	31
2.7 Esquematização completa do ciclo de assimilação e previsão no SMR utilizando o 3DVar.	37
2.8 Esquematização completa do ciclo de assimilação e previsão no SMR utilizando o 3DEnVar.	41
2.9 Localização das estações meteorológicas com dados de acumulado de chuva em 24 horas sobre MA.	43
3.1 Incremento de análise da temperatura do ar em baixos níveis (1000 hPa) para o dia 14 de janeiro de 2017, às 00 UTC, sobre o plano horizontal.	49
3.2 Incremento de análise da temperatura para o dia 14 de janeiro de 2017, às 00 UTC, sobre o plano vertical ao longo de 9°S.	52
3.3 Curva da função custo e do seu gradiente para o dia 12 de janeiro de 2017, às 00 UTC.	58
3.4 BIAS e RMSE de OMA e OMF para os campos de temperatura (T, K), vento (UV, m/s), umidade (RH, %) e pressão superficial (P, hPa) para o 3DEnVar referente aos experimentos SCM1 e SCM2.	63
3.5 BIAS e RMSE de OMA e OMF para os campos de temperatura (T, K), vento (UV, m/s), umidade (RH, %) e pressão superficial (P, hPa) para o 3DVar referente aos experimentos SCM1 e SMC2.	64
3.6 Diagrama ilustrando o BIAS e RMSE de OMA para os campos de umidade para o 3DVar e 3DEnVar referente aos experimentos SCM1 e SCM2.	66

3.7	Incremento de análise gerado pelo EnKF para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	68
3.8	Incremento de análise gerado pelo EnKF para o membro controle no dia 22 de janeiro de 2017, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	70
3.9	Incremento de análise gerado pelo 3DVar para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	72
3.10	Incremento de análise gerado pelo 3DVar para o membro controle no dia 22 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	73
3.11	Incremento de análise gerado pelo 3DEnVar para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	74
3.12	Incremento de análise gerado pelo 3DEnVar para o membro controle no dia 22 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão superficial (PSFC, hPa) e umidade específica (QVAPOR, g/kg).	76
3.13	Incremento de análise gerado pelo EnKF, 3DVar e 3DEnVar para o membro controle nos dias 12 e 22 de janeiro de 2017, às 00 UTC, referente ao campo de massa de ar seco na coluna (hPa).	78
3.14	Localização geográfica das estações meteorológicas no estado do Maranhão, onde foram identificados episódios de chuvas intensas.	79

3.15	Imagem do canal infravermelho do satélite GOES ilustrando o estágio de desenvolvimento máximo do SCM sobre o NEB (a) e a chuva acumulada em 24 horas da hidroestimativa do MERGE (b) para o dia 14 de janeiro de 2017, referente ao experimento SCM1.	80
3.16	Imagem do canal infravermelho do satélite GOES ilustrando o estágio de desenvolvimento máximo do SCM sobre o NEB (a) e a chuva acumulada em 24 horas da hidroestimativa do MERGE (b) para o dia 24 de janeiro de 2017, referente ao experimento SCM2.	81
3.17	Mapa ilustrando o ângulo da seção vertical traçada sobre o Nordeste brasileiro.	83
3.18	Análises dos campos de vento e umidade a 8 km (300 hPa) acima da superfície válidas para o dia 14 de janeiro de 2017, às 00 UTC.	84
3.19	Seção vertical da convergência de vento ($10^{-6} s^{-1}$) e temperatura para o dia 14 de janeiro de 2017, às 00 UTC.	86
3.20	Seção vertical de umidade e temperatura para o dia 14 de janeiro de 2017, às 00 UTC.	88
3.21	Análises dos campos de vento e umidade a 8 km (300 hPa) acima da superfície válidas para o dia 24 de janeiro de 2017, às 00 UTC.	90
3.22	Seção vertical da convergência de vento ($10^{-6} s^{-1}$) para o dia 24 de janeiro de 2017, às 00 UTC.	92
3.23	Seção vertical de umidade e temperatura para o dia 24 de janeiro de 2017, às 00 UTC.	94
3.24	Distribuição da instabilidade convectiva sobre o Nordeste brasileiro através do MCAPE ($J.kg^{-1}$) para o dia 14 de janeiro de 2017, às 00 UTC.	96
3.25	Distribuição da instabilidade convectiva sobre o Nordeste brasileiro através do MCAPE ($J.kg^{-1}$) para o dia 24 de janeiro de 2017, às 00 UTC.	98
3.26	MCAPE calculado para os dias 14 (SCM1) e 24 (SCM2) de janeiro de 2017, sobre estações meteorológicas de Barra da Corda ($6^{\circ}S$ e $46^{\circ}W$) e Colinas ($6^{\circ}S$ e $44^{\circ}W$), do GEFS (REF), da previsão do modelo WRF inicializada com o membro controle do GEFS (WRF) e das análises do EnKF, 3DVar e 3DEnVar.	99
3.27	Previsão de chuva acumulada em 24 horas para o SCM do dia 14 de janeiro de 2017, inicializada em 14 de janeiro de 2017, às 00 UTC (f24h), em 13 de janeiro de 2017, às 00 UTC (f48h) e em 12 de janeiro de 2017, às 00 UTC (f72h).	101

3.28	RMSE calculado para avaliar as previsões dos acumulados de chuva diário do modelo WRF inicializado com o membro controle do GEFS (WRF) e com as condições iniciais atualizadas pelo EnKF, 3DVar e 3DEnVar para o dia 14 de janeiro de 2017, inicializado 24 (f24h), 48 (f48h) e 72 horas (f72h) antes.	103
3.29	Previsão de chuva acumulada em 24 horas para o SCM do dia 24 de janeiro de 2017, inicializada em 24 de janeiro de 2017, às 00 UTC (f24h), em 23 de janeiro de 2017, às 00 UTC (f48h) e em 22 de janeiro de 2017, às 00 UTC (f72h).	105
3.30	RMSE calculado para avaliar as previsões dos acumulados de chuva diário do modelo WRF inicializado com o membro controle do GEFS (WRF) e com as condições iniciais atualizadas pelo EnKF, 3DVar e 3DEnVar para o dia 24 de janeiro de 2017, inicializado 24 (f24h), 48 (f48h) e 72 horas (f72h) antes.	106
3.31	Digrama de performance para as previsões dos acumulados de chuva diária do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 24 horas antes.	109
3.32	Digrama de performance para as previsões dos acumulados de chuva diária do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 48 horas antes.	110
3.33	Digrama de performance para as previsões dos acumulados de chuva diário do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 72 horas antes.	112
E.1	Número de observações de pressão superficial (P, em Pa), temperatura (T, em K), umidade específica (Q, em g/kg) e velocidade do vento zonal e meridional (UV, em m/s) assimilados no GSI nos dias 12 (SCM1) e 22 (SCM2) de janeiro de 2017, às 00 UTC.	142
E.2	Distribuição dos dados de pressão (PS, hPa), umidade específica (Q, g/kg), temperatura (T, K), vento zonal e meridional (UV, m/s) disponíveis para assimilação no dia 12 de janeiro de 2017 (SCM1), às 00 UTC.	144
E.3	Distribuição dos dados de pressão (PS, hPa), umidade específica (Q, g/kg), temperatura (T, K), vento zonal e meridional (UV, m/s) disponíveis para assimilação no dia 22 de janeiro de 2017 (SCM2), às 00 UTC.	145

LISTA DE TABELAS

	<u>Pág.</u>
1.1 Identificação dos CCM baseada em imagens de satélite no canal IR.	8
2.1 Configurações do modelo WRF.	26
2.2 Observações assimiladas pelo GSI.	34
3.1 Desempenho dos sistemas variacionais para os dias 14 e 24 de janeiro de 2017, em negrito, as performances mais próximas de zero.	54
3.2 Tabela de desempenho do 3DVar e 3DEnVar configurado com o peso de 0,75 para a matriz do EnKF em diferentes ciclos de assimilação de dados referente as variáveis de pressão superficial (P, hPa), temperatura (T, K), vento zonal e meridional (UV, m/s) e umidade relativa (RH, %), válida para todos os níveis de pressão entre 1000-0 hPa).	60
A.1 Espaço ocupado pelos principais componentes de dados do SMR com o 3DEnVar habilitado.	131
B.1 Tempo de execução do SMR com o WRF, EnKF+WRF, 3DVar+WRF e 3DEnVar+WRF para 72, 48 e 24 h de previsão.	134
C.1 Espalhamentos dos membros do conjunto fornecidos ao sistema de assimilação de dados híbrido (3DEnVar) referente ao experimento SCM1 obtidos através do desvio-padrão da inovação (innov) e o desvio dos membros do conjunto somado aos erros da observação para os campos de pressão superficial (ps) em Pa, temperatura (t) em K, velocidade do vento zonal e meridional (uv) em m/s e umidade específica (q) em g/kg.	136
C.2 Espalhamentos dos membros do conjunto fornecidos ao sistema de assimilação de dados híbrido (3DEnVar) referente ao experimento SCM2 obtidos através do desvio padrão da inovação (innov) e o desvio dos membros do conjunto somado aos erros da observação para os campos de pressão superficial (ps) em Pa, temperatura (t) em K, velocidade do vento zonal e meridional (uv) em m/s e umidade específica (q) em g/kg.	137
D.1 Coordenadas geográficas das estações meteorológicas, sobre o estado do Maranhão, com dados disponíveis para os dias 14 e 24 de janeiro de 2017, quando ocorreram os SCM.	139

LISTA DE ABREVIATURAS E SIGLAS

3DVar	–	Three-Dimensional Variational
3DEnVar	–	Three-Dimensional Ensemble Variational
ATOVS	–	Advanced TIROS Operational Vertical Sounder
AMSU-A	–	Advanced Microwave Sounding Unit-A
BAM	–	Brazilian global Atmospheric Model
BDMEP	–	Banco de Dados Meteorológicos para Ensino e Pesquisa
BouLac	–	Bougeault–Lacarrère
Cb	–	Cumulonimbus
CDO	–	Climate Data Operators
CEMADEN	–	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CFL	–	Courant-Friedrichs-Lewy
CLP	–	Camada Limite Planetária
CNM	–	Confederação Nacional dos Municípios
CPTEC	–	Centro de Previsão de Tempo e Estudos Climáticos
Cu	–	Cumulus
DAO	–	Data Assimilation Office
DTC	–	Developmental Testbed Center
ECMWF	–	European Centre for Medium-Range Weather Forecasts
EMC	–	Environmental Modeling Center
ENIAC	–	Electronic Numerical Integrator and Computer
EnKF	–	Ensemble Kalman Filter
ETKF	–	Ensemble Transform Kalman Filter
EOF	–	Funções Ortogonais Empíricas
EOS	–	Earth Observing System
EnSRF	–	Ensemble Square Root Filter
GEFS	–	Global Ensemble Forecast System
GFS	–	Global Forecast System
GOES	–	Geostationary Operational Environmental Satellite
GPSAS	–	Global Physical-space Statistical Analysis System
GSI	–	Gridpoint Statistical Interpolation
GTS	–	Global Telecommunication System
HIRS4	–	High-resolution Infrared Radiation Sounder 4
INMET	–	Instituto Nacional de Meteorologia
INPE	–	Instituto Nacional de Pesquisas Espaciais
IR	–	Infravermelho
LEKF	–	Local Ensemble Kalman Filter
LETKF	–	Local Ensemble Transform Kalman Filter
LI	–	Lifted Index
MCG	–	Modelos de Circulação Geral
MYJ	–	Mellor–Yamada–Janjić
METOP	–	Meteorological Operational Satellite Programme
MODIS	–	Moderate Resolution Imaging Spectroradiometer
NASA	–	National Aeronautics and Space Administration

NCAR	– National Center for Atmospheric Research
NCEP	– National Centers for Environmental Prediction
NEB	– Nordeste Brasileiro
NESDIS	– National Environmental Satellite, Data, and Information Service
NMC	– National Meteorological Center
NNEB	– Norte e Nordeste do Brasil
NOAA	– National Oceanic and Atmospheric Administration
NOMADS	– National Operational Model Archive and Distribution System
OI	– Optimal Interpolation
OMA	– Observation Minus Analysis
OMF	– Observation Minus Forecast
PNT	– Previsão Numérica do Tempo
PNTC	– Previsão Numérica de Tempo e Clima
PSAS	– Physical-space Statistical Analysis System
RMSE	– Root-Mean-Square Error
RPSAS	– Regional Physical-space Statistical Analysis System
SCM	– Sistemas Convectivos de Mesoescala
SMR	– Sistema de Modelagem Regional
SRTM	– Shuttle Radar Topography Mission
SSI	– Spectral Statistical Interpolation
TRMM	– Tropical Rainfall Measuring Mission
TSM	– Temperatura da Superfície do Mar
TT	– Total Totals
UCAR	– University Corporation for Atmospheric Research
WMO	– World Meteorological Organization
WPS	– WRF Preprocessing System
WRF	– Weather Research and Forecasting
WSM6	– WRF Single-Moment 6-Class
YSU	– Yonsei University
ZCAS	– Zona de Convergência do Atlântico Sul
ZCIT	– Zona de Convergência Intertropical

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos	4
1.1.1 Objetivo geral	4
1.1.2 Objetivos específicos	5
1.2 Hipótese	5
1.3 Revisão bibliográfica	6
1.3.1 Sistemas convectivos de mesoescala	6
1.3.2 Previsão numérica do tempo	9
1.3.3 Assimilação de dados	13
1.3.4 Método variacional	14
1.3.5 Método por conjunto-variacional	17
2 MATERIAIS E MÉTODOS	21
2.1 Área de estudo	21
2.2 Identificação dos sistemas convectivos de mesoescala	22
2.3 Identificação dos episódios de chuva	24
2.4 Modelo de mesoescala WRF	24
2.4.1 Configuração espacial do WRF para o NEB	26
2.4.2 Condições iniciais	28
2.4.3 Parametrizações de transferência radiativa	29
2.4.4 Microfísica	30
2.4.5 Parametrização de Cumulus	31
2.4.6 Parametrizações da superfície do solo, camada limite superficial e pla- netária	32
2.5 Assimilação de dados no SMR	33
2.5.1 Dados observacionais	33
2.5.2 Assimilação de dados pelo método 3DVar	34
2.5.3 Assimilação de dados pelo método 3DEnVar	38
2.5.4 Avaliação estatística dos dados	42
3 RESULTADOS	47
3.1 Teste com uma única observação sintética	47
3.2 Determinação do peso da matriz de covariâncias do EnKF	53

3.3	Função custo	56
3.4	Avaliação do BIAS e RMSE para o 3DVar e 3DEnVar nos experimentos .	59
3.5	Avaliação dos incrementos de análise	67
3.6	Análise sinótica dos SCM	79
3.6.1	Análise sinótica do dia 14 de janeiro de 2017	83
3.6.2	Análise sinótica do dia 24 de janeiro de 2017	89
3.7	Análise termodinâmica dos SCM	95
3.7.1	Análise termodinâmica do dia 14 de janeiro de 2017	95
3.7.2	Análise termodinâmica do dia 24 de janeiro de 2017	97
3.8	Verificação das previsões de chuva	100
3.8.1	Previsão de chuva para o dia 14 de janeiro de 2017	100
3.8.2	Previsão de chuva para o dia 24 de janeiro de 2017	104
3.9	Avaliação da previsão de chuva pelo diagrama de performance	108
4	CONCLUSÕES	115
4.0.1	Recomendações para trabalhos futuros	117
	REFERÊNCIAS BIBLIOGRÁFICAS	119
	APÊNDICE A - ESPECIFICIDADES DO SISTEMA	131
	APÊNDICE B - TEMPO DE EXECUÇÃO DO SMR	133
	APÊNDICE C - ESPALHAMENTO DO CONJUNTO DE MEMBROS DO 3DENVAR.	135
	APÊNDICE D - COORDENADAS GEOGRÁFICAS DAS ESTAÇÕES METEOROLÓGICAS.	139
	APÊNDICE E - NÚMERO DE OBSERVAÇÕES CONSIDERADAS PARA ASSIMILAÇÃO NO GSI.	141

1 INTRODUÇÃO

A previsão acurada dos fenômenos meteorológicos adversos que afetam a economia em todo o globo é essencial para o planejamento de curto a longo prazo de diversas atividades humanas, a fim de evitar prejuízos socioeconômicos ocasionados por desastres naturais (e.g., deslizamentos em áreas de encostas e enchentes) associados, por exemplo, a episódios de chuvas intensas em diversas localidades do planeta. Para o Nordeste Brasileiro (NEB), região de estudo deste trabalho, segundo dados do portal da Confederação Nacional dos Municípios ([CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS - CNM, 2017](#)), para um longo intervalo de tempo seco foram totalizados prejuízos na ordem de R\$ 104 bilhões entre 2012 e 2015. Para a mesma região, eventos de chuva intensos têm causado mortes, enchentes, alagamentos e rompimentos de açudes, causando prejuízos na ordem de R\$ 200 mil, em apenas um dia, em virtude de transtornos ocasionados pela ação de instabilidades convectivas sobre o município de São João do Arraial situado no estado do Piauí ([MOURA, 2019](#)). Esses dados reforçam a necessidade de utilizar ferramentas que prevejam com maior grau de confiabilidade sistemas na escala de tempo a clima, com vários dias ou meses de antecedência, respectivamente, a fim de mitigar prejuízos socioeconômicos associados a fenômenos atmosféricos.

Para a obtenção de uma previsão consistente são necessárias condições iniciais acuradas do estado da atmosfera para um dado tempo e local, que por sua vez servirão para calcular uma série de parâmetros obtidos através de um conjunto de equações da dinâmica e da termodinâmica, que compõem os modelos de previsão meteorológicos.

A geração das condições iniciais é feita, geralmente, através de dados provenientes de sensores de satélites, estações em superfície e balões meteorológicos, responsáveis por medir, por exemplo, a temperatura, pressão, ventos e umidade na superfície e em altitude.

As informações meteorológicas em diferentes regiões do globo são coletadas e usadas para definir as condições iniciais do modelo. A utilização de dados observacionais na obtenção do estado inicial da atmosfera é fonte de incertezas, em virtude da escassez de dados meteorológicos para algumas localidades do planeta, sobre os continentes e oceanos, assim como erros intrínsecos às observações, onde se enquadram os problemas associados ao funcionamento dos instrumentos (e.g., erros de calibração) e suas aferições (e.g., erros de paralaxe).

Uma alternativa empregada para o melhoramento das condições iniciais dos modelos de Previsão Numérica de Tempo (PNT) é a assimilação de dados, que prepara as informações na grade do modelo com a melhor estimativa do estado inicial da atmosfera, através da combinação de observações distribuídas irregularmente no espaço e tempo, com dados provenientes do modelo. Logo, a assimilação de dados emprega um conjunto de técnicas através das quais as observações são incorporadas em um modelo numérico (e.g. meteorológico, oceanográfico ou hidrológico), para obter a melhor condição inicial para a inicialização dos modelos de PNT.

A combinação de um modelo de PNT com as observações é feita através de procedimentos matemáticos e/ou estatísticos, tais como o executado pelo cálculo da função custo no 3DVar (*Three-Dimensional Variational*) e no híbrido, 3DEnVar (*Three-Dimensional and Ensemble Variational*).

O melhoramento das análises ao se aplicar uma metodologia de assimilação de dados como o 3DVar e o 3DEnVar, está associado a obtenção de campos (e.g., temperatura) balanceados com os erros das observações e das previsões de um modelo meteorológico, o que melhora a compreensão dos fenômenos e sistemas sinóticos influentes nas escalas de tempo e clima.

Para obtenção de bons resultados a partir de um sistema de assimilação de dados, uma combinação de fatores devem ser levados em consideração:

- a) a existência de um bom modelo de PNT, no sentido que este consiga prever com vários dias de antecedência os processos sinóticos condicionantes para a ocorrência de determinados fenômenos meteorológicos;
- b) dados observacionais de qualidade, bem distribuídos e disponibilizados com uma alta frequência temporal;
- c) o conhecimento adequado dos erros do modelo e das observações;
- d) e um bom sistema de assimilação de dados, de tal forma que este consiga diminuir os erros da previsão meteorológica, através da distribuição estatística dos erros (eg., Gaussiana) ao longo dos ciclos de assimilação de dados.

A combinação dos fatores citados anteriormente, somado a um controle de qualidade dos dados observacionais, dentro do sistema de assimilação de dados, contribui para que se tenha a melhor estimativa do estado da atmosfera. O procedimento de

controle de qualidade limita o impacto de observações individuais provavelmente inconsistentes com o estado do sistema de assimilação de dados.

A assimilação de dados divide-se basicamente em duas técnicas, a sequencial e não sequencial. Brasseur (2006) define as técnicas sequenciais (e.g. 3DVar e o EnKF) como um conjunto de métodos de assimilação onde são empregados repetidos ciclos de análises, onde em cada passo de tempo de análise é obtido um novo estado inicial do modelo. Já as técnicas não sequenciais (e.g. 4DVar) caracterizam-se por corrigirem a trajetória do modelo a medida em que novas observações são obtidas, dentro de uma janela de assimilação tipicamente de 6 horas, o que permite que as observações contidas dentro do intervalo de tempo para a geração da próxima análise possam ser utilizadas.

Bauer et al. (2015) mostram que os modelos de PNT têm conseguido prever o estado da atmosfera com maior grau de confiabilidade, sendo grande parte deste sucesso devido aos avanços científicos e tecnológicos conquistados pela PNT principalmente no último século. Dessa forma, alguns aspectos contribuíram para o melhoramento do desempenho das previsões numéricas:

- a) o aperfeiçoamento dos esquemas que simulam os processos físicos e aumento da resolução espacial dos modelos de PNT;
- b) realização de previsões por conjunto;
- c) maior disponibilidade de dados para serem assimilados, principalmente satélites, e novas técnicas para assimilar dados não convencionais;
- d) e o surgimento de metodologias de assimilação de dados capazes de incorporar os erros do dia.

O sistema de assimilação de dados utilizado neste trabalho será o *Gridpoint Statistical Interpolation* (GSI), desenvolvido pelo *National Centers for Environmental Prediction* (NCEP) do *Environmental Modeling Center* (EMC) para geração de análises para aplicações global e regional. A versão 3.4, aqui utilizada, pode ser empregada com alguns sistemas de assimilação de dados (e.g. 3DVar e o 3DEnVar), em conjunto com um modelo de PNT (e.g. *Weather Research and Forecasting Model*/WRF).

Neste trabalho, foram utilizados os métodos de assimilação de dados 3DVar (*Three-Dimensional Variational*) e o híbrido, 3DEnVar (*Three-Dimensional and Ensemble Variational*) do GSI, a fim de corrigir os erros de previsão nas condições iniciais, o

que pode auxiliar no melhoramento da previsão dos acumulados de chuva associados a episódios de SCM (Sistemas Convectivos de Mesoescala), em comparação com previsões determinísticas onde não foram utilizadas técnicas de assimilação de dados para gerar as análises do SMR (Sistema de Modelagem Regional).

A versão V3.0.0 do SMR, foi utilizada no contexto deste trabalho com duas componentes: o modelo de PNT WRF e o sistema de assimilação de dados GSI. Atualmente, o SMR encontra-se configurado para fornecer análises ao modelo WRF utilizando o 3DVar. Neste trabalho foi habilitado o EnKF dentro da estrutura computacional do 3DVar, doravante denominado 3DEnVar, cuja vantagem principal é atualizar a matriz de covariância dos erros de previsão do 3DVar, com os “erros do dia”, calculados utilizando a média de um conjunto de membros de previsão fornecidos ao EnKF. Esta metodologia tem sido utilizada ao longo dos anos em uma série de trabalhos desenvolvidos pela comunidade científica mundial, trazendo o conjunto de membros de previsões para obtenção da matriz de covariância dos erros do modelo, com os “erros do dia”, que complementam a matriz estática do 3DVar, através da combinação linear destas duas matrizes (HAMILL; SNYDER, 2000; LORENC, 2003 e BUEHNER, 2005).

Com a habilitação do 3DEnVar no SMR, deseja-se investigar o impacto da matriz de covariância dos erros de previsão na obtenção das análises para o WRF, durante os episódios de chuva associados a SCM sobre o NEB. Conforme abordado por Kleist e Ide (2015), a qualidade da análise é melhorada significativamente ao passar da assimilação de dados tridimensional variacional (3DVar) para o 3DEnVar, especialmente em termos de redução de erros para as análises dos campos de vento e umidade, principalmente nos trópicos, região onde o presente trabalho foi desenvolvido.

1.1 Objetivos

1.1.1 Objetivo geral

Incorporação dos “erros do dia” através do EnKF (*Ensemble Kalman Filter*), para obtenção de análises através do 3DEnVar, com o propósito de diminuir os erros de variáveis meteorológicas nas condições iniciais fornecidas ao modelo de mesoescala WRF, utilizadas na previsão de precipitação associada à episódios de SCM ocorridos no verão austral de 2017 (14 e 24 de janeiro de 2017), sobre o NEB.

1.1.2 Objetivos específicos

O método de assimilação de dados EnKF foi habilitado na versão V3.0.0 do SMR, resultando em um sistema híbrido (3DEnVar). Esse sistema combina as características do 3DVar e do EnKF na atualização da matriz de covariância dos erros do modelo utilizada pelo 3DVar. Dessa forma, para avaliar o impacto da matriz de covariância dos erros de previsão utilizada na geração das análises e os efeitos das condições iniciais na previsão de eventos de chuvas intensas associadas à SCM, ocorridos nos dias 14 e 24 de janeiro de 2017, será necessário:

- a) investigar o impacto das contribuições das matrizes de covariâncias dos erros de previsão estática do 3DVar e do EnKF, ao assimilar uma única observação sintética de temperatura, na distribuição espacial dos incrementos de análise obtidos pelo 3DEnVar, como forma de ilustrar a distribuição espacial dos incrementos de análise na horizontal e vertical;
- b) compreender o impacto da combinação linear da matriz de covariâncias estática do 3DVar com a matriz de covariância dos erros de previsão do EnKF, na geração das análises pelo 3DEnVar, provendo ao sistema dados observacionais de diferentes fontes (prepbufr, amsuabufr, gpsrobufr, hirs4bufr e mhsbufr) distribuídas sobre o NEB;
- c) entender o impacto das análises atualizadas pelo 3DEnVar na obtenção de previsões (72, 48 e 24 horas), utilizando o modelo WRF, para avaliar a chuva acumulada em 24 horas, associada a episódios de SCM ocorridos, no NEB, em 14 e 24 de janeiro de 2017.

1.2 Hipótese

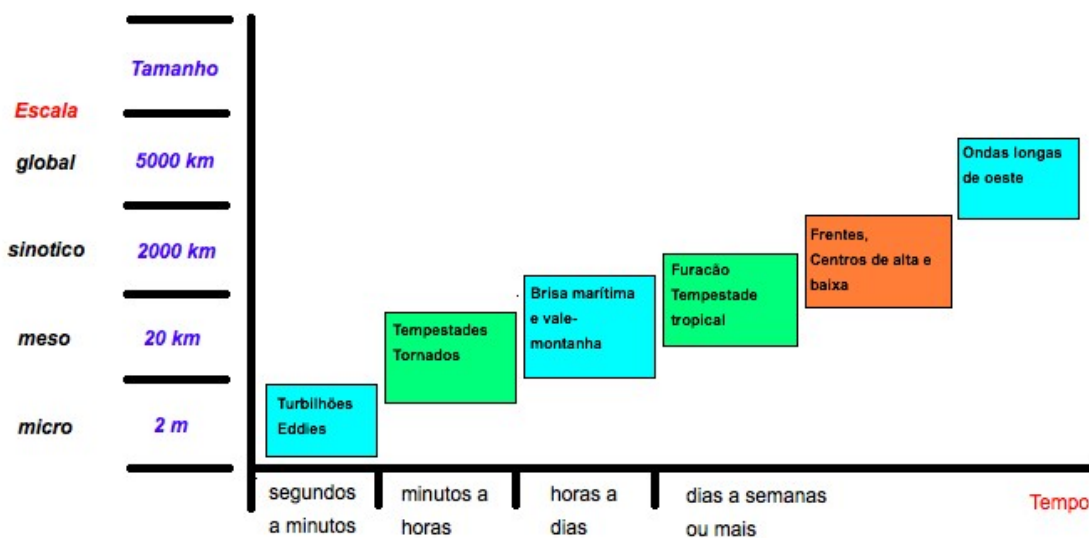
O projeto desenvolvido no âmbito do presente trabalho buscará responder a seguinte indagação: tendo em vista que o sistema híbrido (3DEnVar) pode ser melhor que o 3DVar e o EnKF para corrigir os erros de previsão do *background*, “*como a atualização da matriz de covariâncias do sistema híbrido auxiliará na representação dos acumulados de precipitação associados a episódios de SCM sobre o NEB durante as previsões executadas pelo modelo WRF?*”

1.3 Revisão bibliográfica

1.3.1 Sistemas convectivos de mesoescala

Os sistemas meteorológicos (frentes frias, ciclones, anticiclones, SCM, entre outros) formam-se a partir de um conjunto de processos dinâmicos responsáveis por gerarem fenômenos adversos, tais como chuva, neve e trovoadas, cujos efeitos podem afetar a sociedade em geral por meio de alagamentos, fechamento de aeroportos e mortes por descargas elétricas atmosféricas. Esses processos podem ocorrer isoladamente ou através da interação entre eles, determinando as condições de tempo em diversas partes do globo, abrangendo desde a microescala (que engloba todos os sistemas que atuam em escala horizontal de alguns metros e poucos minutos de duração), até a escala planetária (que envolve todos aqueles sistemas com dimensão horizontal superior a 10.000 km e com vários meses de duração). Uma ilustração das escalas de atuação dos sistemas meteorológicos pode ser observado na Figura 1.1.

Figura 1.1 - Escala dos sistemas meteorológicos.




Fonte: Adaptado de Instituto de Astronomia e Geociências - IAG (2010).

Os SCM são sistemas meteorológicos embebidos em uma região marcada por movimentos verticais ascendentes e bastante úmida (Figura 1.2), com dimensões hori-

zontais tipicamente da ordem de 100 a 200 km, recorrentes na estação quente e com menor frequência na estação fria (ZIPSER, 1981). Houze (2004) considera os SCM como nuvens formadas como uma resposta à instabilidade convectiva, com nuvens Cb cobrindo uma grande área contígua de precipitação em torno de 100 km ou mais, que por vezes ao evoluírem sobre os oceanos dão origem aos ciclones tropicais. Apesar da definição anterior ressaltar os sistemas meteorológicos predominantemente incluídos na escala meso- β , onde se encontram os conglomerados de Cb, linhas de instabilidade e circulações topograficamente induzidas com dimensões horizontais da ordem de 20 a 200 km. Fedorova (2008) realiza uma descrição detalhada das demais escalas dos SCM e dos principais sistemas sinóticos pertencentes a elas. Para isso leva-se em consideração a meso- α , cuja a dimensão horizontal é superior a 200 km e é nessa escala onde se encontram os complexos convectivos de mesoescala (CCM), linhas de instabilidade e vórtices ciclônicos do tipo vírgula e a meso- γ , que abrange os sistemas com dimensão horizontal inferior a 20 km, onde estão incluídas as Cb isoladas e as linhas de instabilidade.

Figura 1.2 - Esquemática dos processos dinâmicos e fenômenos adversos associados à formação dos SCM sobre o HS.



Fonte: Adaptado de University of British Columbia - UBC (2020)

Ferreira e Mello (2005) apontam os CCM e as linhas de instabilidade como os principais SCM influentes nas condições de tempo sobre o NEB. O NEB encontra-se na região tropical do Brasil, limitado com o oceano atlântico e com um clima e vegetação fortemente influenciados pelo planalto da Borborema. A presença deste planalto marca significativamente o clima da região ao manter a leste massas de ar

com características mais úmidas e ocorrência de chuvas orográficas e o lado oeste, massas de ar predominantemente secas (ROCHA et al., 2011).

Os CCM são sistema convectivos de tempo caracterizados por apresentarem um conjunto de nuvens Cb com uma estrutura na forma aproximadamente circular e desenvolvimento vertical explosivo num intervalo de tempo entre 6 e 12 horas de duração (MADDOX, 1980; RINALDY et al., 2017). A primeira metodologia proposta para a classificação dos CCM foi elaborada por Maddox (1980) utilizando imagens do canal infravermelho (IR) do satélite *Geostationary Operational Environmental Satellites* (GOES) com a temperatura de brilho disponibilizada em tons de cinza. As características empregadas na identificação desse sistema, em latitudes médias a partir das imagens do IR do satélite GOES, foram sintetizadas conforme ilustrado na Tabela 1.1. Na região subtropical da América do Sul, os CCM ocorrem com maior frequência durante a primavera e o verão, com formação durante a noite e dissipação entre 10 e 20 horas após a sua formação (SOUZA et al., 1998; FERREIRA; MELLO, 2005).

Tabela 1.1 - Identificação dos CCM baseada em imagens de satélite no canal IR.

Parâmetros	Características Físicas
Tamanho:	A – Cobertura de nuvens com temperaturas $\leq -32^{\circ}\text{C}$ observadas no canal IR, com área $\geq 100.000 \text{ km}^2$.
	B – Região interna da cobertura de nuvens com temperaturas $\leq -52^{\circ}\text{C}$ observadas no canal IR, com área $\geq 50.000 \text{ km}^2$.
Início:	Quando as definições de tamanho A e B forem satisfeitas.
Duração:	As definições de tamanho A e B devem persistir por um período ≥ 6 horas.
Extensão Máxima:	Quando a definição do tamanho A e B alcançarem o tamanho máximo.
Forma:	Excentricidade $\geq 0,7$ no momento de máxima extensão.
Término:	Quando as definições de tamanho não são satisfeitas.

Fonte: Adaptado de MADDOX, (1980).

Para Zipser (1977), as linhas de instabilidade são nuvens Cb organizadas de forma linear, associadas com uma região de advecção fria na superfície e com velocidade

de propagação alta em baixos níveis. Ferreira e Mello (2005) as consideram como bandas de nebulosidade, normalmente do tipo Cumulus (Cu), frequentemente associadas a eventos de chuva com máximo desenvolvimento durante a tarde e início da noite para a região tropical, quando a convecção é máxima. Em termos gerais as linhas de instabilidade são classificadas como linhas de instabilidade meso- β com extensão vertical entre 20 e 30 km e horizontal entre 10 e 100 km e linhas de instabilidade meso- γ com dimensão vertical entre 50 e 100 km e horizontal de 1.000 km, aproximadamente (FEDOROVA, 2008). Dependendo da região de formação, as linhas de instabilidade apresentam gêneses diferentes, como por exemplo a formação das linhas de instabilidade tropical e extratropical (HANE, 1986).

Trabalhos têm sido desenvolvidos para entender a natureza física dos SCM, revelando os processos sinóticos responsáveis pela sua formação. No NEB, Lyra et al. (2017, 2018, 2019) realizou uma série de estudos de casos avaliando o potencial das chuvas associadas aos CCM. Fedorova et al. (2008) investigou a gênese dos CCM sobre o NEB e observou que o aquecimento da superfície do oceano próximo ao estado de Alagoas e cavados béricos, em baixos níveis, condicionaram a formação de tempestades associadas a eventos de CCM para a maioria dos eventos. Fedorova et al. (2009) caracterizou os episódios de CCM entre 2003 a 2006, no NEB, por meio da avaliação termodinâmica da atmosfera.

A potencialidade das linhas de instabilidade na formação de eventos de chuva também conduziu uma série de estudos para o NEB. Silva et al. (2017) realizou um trabalho avaliando a relação entre a Temperatura da Superfície do Mar (TSM) com o desenvolvimento de linhas de instabilidade na região Norte e Nordeste do Brasil, e foram verificadas maiores influências para uma associação entre as áreas de instabilidade com três regiões sobre o oceano atlântico sul denominadas de TSM2, TSM5 e TSM10. Palharini e Vila (2017), ao classificar as nuvens precipitantes utilizando dados do satélite do *Tropical Rainfall Measuring Mission* (TRMM) notou, para a região do NEB, uma propagação de convecção superficial em direção ao continente entre os meses de abril a setembro. Dentre os sistemas associados a este tipo de evento foram identificadas as linhas de instabilidade.

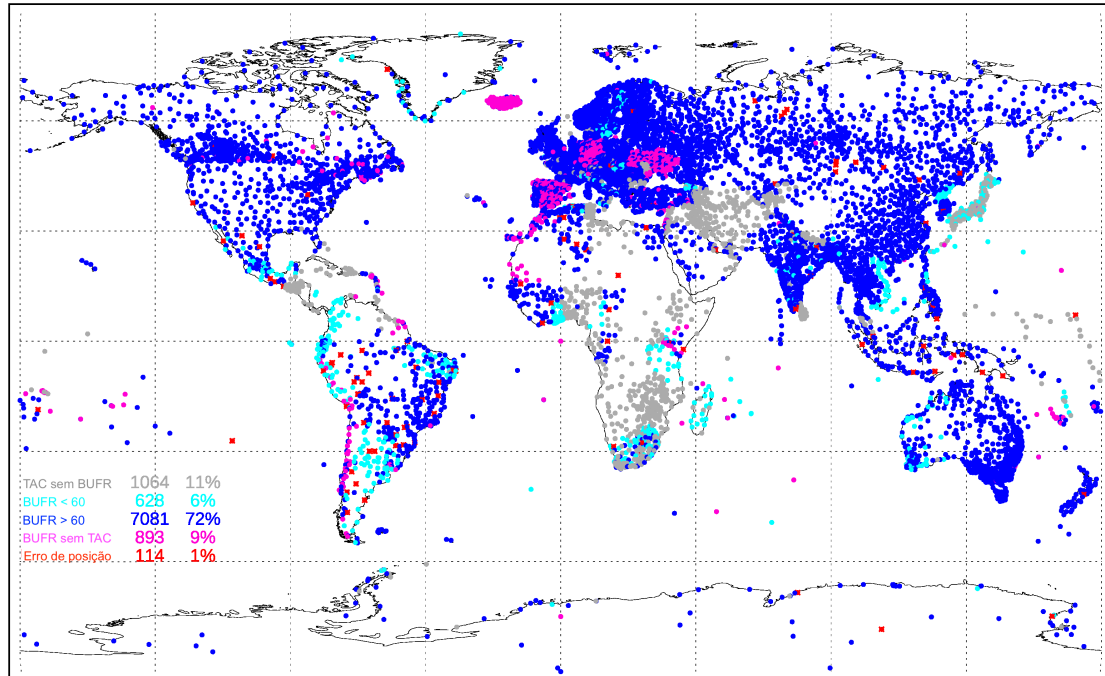
1.3.2 Previsão numérica do tempo

Para prever o estado futuro da atmosfera é preciso um conjunto de equações da dinâmica e da termodinâmica dos fluidos. As primeiras equações da mecânica dos fluidos foram introduzidas por Leonhard Euler, em 1755, tendo como base o cálculo diferencial apresentado anteriormente por Isaac Newton e Gottfried Wilhelm Leib-

niz (DEMIDOV, 2005), já a viscosidade molecular (que caracteriza a resistência dos fluidos em um escoamento) foi incluída por Claude-Louis-Navier, em 1827, e George Stokes, em 1845.

Bjerknes (1904) realizou um trabalho onde considerava que o estado da atmosfera poderia ser previsto baseando-se nas leis físicas, porém, para que os resultados fossem exitosos, ou seja, para que se chegasse a uma solução do problema da previsão meteorológica, seria imprescindível a existência de informações acuradas do estado inicial da atmosfera e conhecer as leis físicas que regem o estado da atmosfera. Porém, mesmo com o aumento do número de estações meteorológicas e com o advento dos satélites meteorológicos com dados disponíveis em alta resolução espacial e temporal, desde o período da publicação do seu artigo até os dias atuais, existe o problema associado à distribuição irregular de dados em diferentes regiões do planeta. No Hemisfério Norte, a quantidade de redes de estações meteorológicas é significativamente maior se comparada com o Hemisfério Sul, como pode ser visualizado na Figura 1.3. A escassez de dados sobre os oceanos é um outro problema comum a ambos os hemisférios (austral e setentrional) e para mitigar esta situação podem ser utilizadas informações provenientes dos sensores de satélites meteorológicos.

Figura 1.3 - Distribuição espacial dos dados de observações convencionais provenientes de estações meteorológicas terrestres, de ar superior e boias oceânicas para novembro de 2019.



Sendo TAC, o código alfanumérico tradicional e BUFR, dados de estações meteorológicas, cada um dos círculos coloridos, sobre o mapa global, representam a localização geográfica de onde as informações meteorológicas são provenientes.

Fonte: Adaptado de European Centre for Medium-Range Weather Forecasts - ECMWF (2018).

O primeiro experimento de PNT foi desempenhado por Richardson (1922), a solução das equações primitivas foi feita manualmente, um processo que levou 6 dias para a realização de uma previsão de 6 horas. Além da previsão não ter sido feita para um tempo hábil o resultado não foi bom, visto que foi verificada a tendência de pressão de 145 hPa em 6 horas para um ponto central sobre a Europa. A falha do experimento de Richardson foi devido ao desequilíbrio entre os campos de pressão e vento, em parte, devido a inadequação dos dados de vento em altitude (o que revela a necessidade por condições iniciais que representem bem o estado da atmosfera) e, de outro modo, devido a impossibilidade de usar os dados de vento observados para calcular a tendência de pressão (LYNCH, 1999). Apesar dos problemas suscitados por ele em seu experimento, o trabalho foi imprescindível para desenvolvimento da

PNT, tendo ele desenvolvido o primeiro modelo numérico de tempo a utilizar células de grade e o método de diferenças finitas para resolver as equações diferenciais (RICHARDSON, 1911). Anos mais tarde, o método proposto por Courant et al. (1928), também conhecido por Courant–Friedrichs–Lewy (CFL), foi empregado em modelos numéricos, na intenção de garantir a estabilidade computacional do método de diferenças finitas empregado na resolução de um modelo barotrópico.

Charney et al. (1950) realizaram a primeira PNT utilizando uma máquina de computação eletrônica, o *Electronic Numerical Integrator and Computer* (ENIAC), para resolver a equação da vorticidade barotrópica sobre uma área limitada da superfície terrestre. A preferência por casos que ocorrem sobre a América do Norte ou Europa foi justificada pela maior cobertura de informações meteorológicas em ambas as regiões. Na mesma década, PHILLIPS (1956) realizou um experimento numérico de previsão para um longo período de tempo, utilizando um modelo quasi-geostrófico de duas camadas, para isso, o atrito e os efeitos diabáticos foram incluídos na equação. Os resultados das previsões realizadas neste trabalho ilustram de maneira quantitativa os valores de uma série de parâmetros empregados na compreensão da circulação meridional e transformação de energia, do movimento zonal desprezando a turbulência, dos processos de transformação de energia durante a previsão realizada, entre outros. Este trabalho foi bem sucedido em vários aspectos ao conseguir prever a distribuição do vento zonal, a existência dos jatos e o transporte de energia para os polos, apesar da simplicidade do modelo.

Em geral, os modelos de previsão numérica do tempo classificam-se em globais e regionais. Os modelos globais caracterizam-se por descrever os movimentos atmosféricos para todo o planeta e são também conhecidos como modelos de circulação geral, configurados para a realização de previsões de tempo e clima. Para escala de tempo eles fornecem previsões para uma a duas semanas, já para a escala climática realizam previsões para o intervalo de meses a anos.

Os modelos regionais (e.g., o modelo WRF) permitem representar os fenômenos de mesoescala, aplicados para o estudo de previsões de tempo/clima em escala regional e/ou local, o que também lhes conferem o nome de modelos de área limitada. Estes modelos permitem simular fenômenos que são dificilmente previstos em modelos globais, tais como a evolução de sistemas de tempo em mesoescala e a influência da topografia, graças a melhor resolução do modelo, que apesar de ser mais refinada ainda não é capaz de resolver fenômenos como a formação de nuvens individuais, circulações internas dentro do sistema de nuvens e a turbulência, necessitando que

estes fenômenos sejam parametrizados. Os modelos regionais pode ser programados para serem tanto hidrostáticos como não-hidrostáticos, para o segundo tipo exige-se uma alta resolução espacial, permitindo a previsão explícita da convecção profunda, assim como as mudanças de densidade.

1.3.3 Assimilação de dados

Talagrand (1997) define a assimilação de dados como um procedimento pelo qual todas as informações disponíveis são utilizadas para determinar acuradamente o melhor estado da atmosfera ou dos oceanos. Para isso, é necessário empregar esquemas de análise objetiva que trazem, em geral, os dados contidos no espaço regular do modelo para o espaço físico e irregular das observações.

Inicialmente, um método apropriado para obtenção dos valores em grade utilizava um procedimento comum de análise, onde desenhava-se objetivamente as isopleias (linhas de mesma velocidade) e, em seguida, as interpolava subjetivamente para obter os valores nos pontos de grade. Porém, isso requeria um meteorologista sinótico experiente, além de vários dias de trabalho, que envolvia, por exemplo, a preparação dos dados para garantir a continuidade no espaço e no tempo, além da remoção de observações errôneas, o que resultava em um trabalho muito difícil de ser executado em um tempo compatível com qualquer rotina operacional de PNT (GILCHRIST; CRESSMAN, 1954).

Como as observações atmosféricas utilizadas no sistema de assimilação não são perfeitas, por incluírem erros intrínsecos aos instrumentos ou por interferência humana, faz-se necessário comparar as observações com alguma referência que pode ser baseada em uma climatologia, média obtida pelas estações vizinhas ou provenientes de uma previsão anterior (KALNAY, 2003). Logo, se a diferença entre um valor observado e o esperado é muito grande, esse dado é considerado como errôneo e não é utilizado na assimilação de dados.

No último século, vários esquemas de análise objetiva foram desenvolvidos, uma vez que a interpolação subjetiva (interpolação manual das observações para uma grade regular) demandava muito tempo e, para isso, era necessário o uso de observações meteorológicas consistentes. Panofsky (1949) e Gilchrist e Cressman (1954) introduziram o método de interpolação polinomial, Bergthórsson e Doos (1955) desenvolveram o método de correções sucessivas e um método similar também foi introduzido por Cressman (1959), este método foi utilizado durante muitos anos em sistemas operacionais para a análise objetiva de campos meteorológicos. Posterior-

mente o método de interpolação estatística ganhou maior notoriedade se comprado ao método de correções sucessivas e foi apresentado a comunidade científica por Eliassen (1954) e Gandin (1963). A assimilação de dados variacional foi introduzida por Sasaki (1958, 1970) e um sistema de assimilação de dados espectral operacional por Flaterry (1970).

O CPTEC, desde 1995, tem utilizado diferentes metodologias de assimilação de dados para o melhoramento das análises e previsões operacionais. Em 1997, iniciou-se a implementação do *Physical-Space Statistical Analysis System* (PSAS) no modelo Eta, com 40 km de resolução horizontal e 28 níveis na vertical (SAPUCCI et al., 2007, 2010), um trabalho desenvolvido em colaboração com o *Data Assimilation Office* (DAO) da *National Aeronautics and Space Administration* (NASA). O PSAS foi criado com o objetivo de ser um sistema de análise flexível para os novos tipos de dados disponíveis pela plataforma do *Earth Observing System* (EOS), além disso, ele continha um algoritmo de interpolação estatístico no espaço físico (SILVA; GUO, 1996). Desde então, o CPTEC atualizou seu sistema de assimilação de dados, empregando o *Regional Physical-space Statistical Analysis System* (RPSAS), em 1999, no modelo Eta com resolução de 40 km (FERNANDEZ et al., 2008) e o *Global Physical-Space Statistical Analysis System* (GPSAS), em 2000, no modelo global T126L28 do CPTEC para assimilação de dados convencionais e do *Advanced TIROS Operational Vertical Sounder* (ATOVS), (ANDREOLI et al., 2008). Por último, entre 2008 e 2010 foi testado o *Local Ensemble Transform Kalman Filter* (LETKF), que caracteriza-se por atualizar a matriz de covariâncias dos erros de previsão utilizando o conjunto de estados do modelo, atualizado a cada ciclo de assimilação. Como o LETKF é capaz de atualizar em cada ciclo de análise a covariância dos erros da previsão, ele consegue representar mais adequadamente os “erros do dia”, o que permite uma solução mais adequada em detrimento a matriz de covariância dos erros de previsão estática, como acontece no 3DVar (MEDEIROS, 2011).

1.3.4 Método variacional

As análises geradas pelo 3DVar apresentam métodos de solução iterativos empregados para resolver a equação da análise (FISHER, 2015). Uma formulação empregada para resolução deste método pode ser vista na Equação 1.1, conhecida como função custo. Mais detalhes sobre esta Equação 1.1 serão abordados nas subseções da metodologia.

$$J(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1}(\mathbf{x} - \mathbf{x}_b) + \frac{1}{2}[\mathbf{y}_o - H(\mathbf{x})]^T (\mathbf{R})^{-1}[\mathbf{y}_o - H(\mathbf{x})] \quad (1.1)$$

onde o vetor \mathbf{x}_b denota a previsão obtida a partir de um modelo de PNT, o vetor \mathbf{x} o estado a ser analisado, o vetor $\mathbf{x} - \mathbf{x}_b$ representa o incremento de análise e a matriz \mathbf{B} corresponde a covariância dos erros do modelo. Na mesma expressão, o \mathbf{y}_o denota a observação, \mathbf{R} é a matriz de covariância do erros observacionais, $\mathbf{y} - H(\mathbf{x})$ é a inovação, sendo H , o operador observação não linear, o responsável por trazer o vetor estado a ser analisado para o espaço físico da observação.

A matriz de covariância dos erros de previsão \mathbf{B} é estática no 3DVar, ou seja, não é atualizada ao longo dos ciclos de assimilação de dados. Sua função é localizar o incremento de análise, corrigindo, assim, eventuais erros nos campos de previsão dos modelos de PNT.

Um método comumente utilizado para o cálculo da matriz de covariância dos erros de previsão é o do NMC (*National Meteorological Center*), que considera a correlação espacial dos erros do modelo semelhante à correlação espacial das diferenças das previsões de 48 e 24 horas, conforme apresentado pela Equação 1.2 (PARRISH; DERBER, 1992).

$$\mathbf{B} = \overline{\epsilon_b \epsilon_b} = \overline{(\mathbf{x}_{T+48} - \mathbf{x}_{T+24})(\mathbf{x}_{T+48} - \mathbf{x}_{T+24})^T} \quad (1.2)$$

onde ϵ_b é o erro da previsão e a barra denota a média da diferença dos erros da previsão de uma variável x , por exemplo a temperatura, no tempo e no espaço. O produto entre os vetores, $(\mathbf{x}_{T+48} - \mathbf{x}_{T+24})(\mathbf{x}_{T+48} - \mathbf{x}_{T+24})^T$, resulta em uma matriz, que representa a covariância dos erros de previsão, obtida com base em duas previsões de curto-prazo (48 e 24 horas antes), porém, válidas para um mesmo horário de referência.

Para encontrar a máxima probabilidade de um vetor estado a ser analisado (\mathbf{x}) ocorrer dado o vetor observação (\mathbf{y}_o), é preciso que a estimativa Bayesiana do estado verdadeiro maximize a probabilidade da análise a *posteriori*, para isso, a probabilidade calculada pela Equação 1.3 deve ser máxima.

$$P(\mathbf{x}|\mathbf{y}_o) = \frac{P(\mathbf{y}_o|\mathbf{x})P(\mathbf{x})}{P(\mathbf{y}_o)} \quad (1.3)$$

onde $P(\mathbf{x}|\mathbf{y}_o)$ é a probabilidade do vetor estado a ser analisado (\mathbf{x}) ocorrer, dado o vetor observação \mathbf{y}_o , $P(\mathbf{y}_o|\mathbf{x})$ é a probabilidade do vetor observação \mathbf{y}_o acontecer

dado o vetor estado \mathbf{x} , $P(\mathbf{x})$ e $P(\mathbf{y}_o)$ representa as probabilidades de vetor estado a ser analisado \mathbf{x} e do vetor observação \mathbf{y}_o ocorrer de forma independente.

Para minimizar a função custo é necessário calcular o gradiente de J (1.1) e igualá-lo a zero ($\nabla J(\mathbf{x}) = 0$) para obtenção do mínimo da função. Considerando que o vetor estado a ser analisado é igual ao vetor análise, $\mathbf{x} = \mathbf{x}_a$, e que este é muito próximo do estado real da atmosfera, com valores em torno das observações e do *background* é possível obter a equação Equação 1.4 (BASTARZ, 2017).

$$\mathbf{x}_a = \mathbf{x}_b + (\mathbf{B}^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} [(\mathbf{H}^T \mathbf{R}^{-1})(\mathbf{y}_o - \mathbf{H}(\mathbf{x}_b))] \quad (1.4)$$

onde, o vetor análise (\mathbf{x}_a) é obtido adicionando o vetor de estado do modelo (\mathbf{x}_b) ao produto da matriz de ganho $((\mathbf{B}^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1}(\mathbf{H}^T \mathbf{R}^{-1}))$ com a inovação $(\mathbf{y}_o - \mathbf{H}(\mathbf{x}_b))$.

Na intenção de melhorar a qualidade das previsões de chuva em diferentes localidades do planeta, alguns trabalhos tem sido desenvolvidos utilizando o método de assimilação 3DVar e esta metodologia tem se mostrado satisfatória por sua capacidade em assimilar observações não convencionais de dados atmosféricos, tais como a radiância, utilizando métodos iterativos, que são vantajosos por evitarem o procedimento de seleção de dados na intenção de reduzir a dimensão da matriz de ganho, diminuindo a quantidade de procedimentos de interpolação e exige um menor custo computacional. Além disso, o 3DVar é computacionalmente mais barato que outros métodos de assimilação de dados, como o 4DVar, que acessa as observações no tempo, dentro da janela de assimilação de dados.

Inúmeros trabalhos têm mostrado resultados satisfatórios ao empregar o 3DVar na atualização das condições iniciais. Hou et al. (2013) investigou o impacto do sistema de assimilação de dados 3DVar, em eventos de chuvas intensas no sudeste da China, utilizando um sistema de previsão de tempestades em tempo real, provendo ao sistema de assimilação dados informações de radiossondas, estações meteorológicas de superfície e de radares *Doppler*. Tong et al. (2016) realizou um experimento a fim de determinar a melhor frequência horária para atualização do ciclo de assimilação empregando o 3DVar para um episódio de tempestades severas no Colorado e no Kansas durante os dias 8 e 9 de agosto de 2008 e determinou que conforme a metodologia empregada, a atualização horária (1 hora) tem desempenho pior que a feita em três horas. Vendrasco et al. (2016) apresenta um método para minimizar os resultados espúrios de precipitação ao assimilar dados em escala convectiva utili-

zando observações de radar meteorológico com o 3DVar, com o propósito de manter o equilíbrio em grande escala e evitar desbalanços entre os campos dinâmicos e microfísicos. Seus resultados ilustram que a técnica empregada conseguiu refinar a quantidade de chuva prevista pelo WRF, além de melhorar as análises das variáveis do vento, temperatura e umidade ao compará-las com as estações de superfície.

1.3.5 Método por conjunto-variacional

A assimilação de dados por conjunto-variacional consiste em uma solução alternativa aos demais sistemas de assimilação de dados, sequenciais e não-sequenciais, onde são combinados métodos variacionais e do filtro de Kalman por conjunto, para que os resultados de uma previsão feita para um intervalo de tempo se aproximem ao máximo do estado governante da atmosfera. Logo, a cada ciclo de assimilação, uma matriz atualizada da covariância dos erros de previsão é obtida, normalmente, a partir da média do conjunto de membros de previsão previamente obtidos de um modelo atmosférico. Desse modo, o 3DEnVar combina as vantagens do método por conjunto, através da matriz de covariância dos erros de previsão calculada a partir de um conjunto de membros de previsão que é atualizada a cada novo ciclo de assimilação, com as vantagens do método variacional, que utiliza um algoritmo global para minimização da função custo, evitando a seleção de dados, que é uma das desvantagens do método de Interpolação Ótima (GANDIN, 1963).

Epstein (1969) ilustra a importância de utilizar a técnica de previsão por conjunto ao compará-los com os resultados de uma única previsão de equações hidrostáticas determinísticas. Os resultados obtidos mostram que o conjunto de previsões permite conhecer as incertezas para um conjunto de situações específicas da atmosfera.

O CPTEC executa operacionalmente previsões globais por conjunto com resolução horizontal de 100 km e 28 níveis (sigma) na vertical, onde utiliza o método de funções ortogonais empíricas, EOF, na sigla em inglês, (COUTINHO, 1999), para obter um conjunto de análises que são posteriormente utilizadas na PNT. Sua aplicação é vantajosa, pois pode ser obtida uma enorme quantidade de previsões estocásticas baseando-se, por exemplo, em condições ligeiramente distintas da atmosfera (EPSTEIN, 1969).

O método de perturbação por EOF utilizado no modelo Global do CPTEC segue a metodologia proposta por Zhang e Krishnamurti (1999). Essa metodologia considera que as perturbações do modelo crescem linearmente nos primeiros dias, resultado de um conjunto de estados iniciais gerados pela adição de perturbações randômicas

de magnitudes comparáveis aos erros de previsão das análises de controle (sem perturbação). Ao final do processo, o que se obtém é um conjunto de estados iniciais gerados pela adição ou subtração das perturbações obtidas pelas EOF com relação às análises de controle. Uma outra alternativa que tem sido utilizada para a geração das perturbações iniciais, e empregada desde 2015 para geração dos membros perturbados do Global Ensemble Forecast System (GEFS), é o Ensemble Kalman Filter (EnKF) fundamentado na metodologia inicialmente proposta por Evensen (1994), esta técnica consiste de um método de assimilação de dados baseada na estatística dos erros de previsão.

Hamill e Snyder (2000) desenvolveram um dos trabalhos pioneiros na assimilação de dados híbrida, utilizando os algoritmos do EnKF e o 3DVar. Nele, os autores calcularam a matriz de covariância dos erros de previsão (\mathbf{B}) utilizando a equação 1.5.

$$\mathbf{B} = (1 - \alpha)\mathbf{P}^b + \alpha\mathbf{SCS}^T \quad (1.5)$$

onde \mathbf{P}^b representa a matriz de variâncias dos erros do conjunto de previsões, enquanto que \mathbf{SCS}^T , denota a matriz de covariância estática, em que \mathbf{S} é um operador que transforma os coeficientes espectrais em pontos de grade e \mathbf{C} é a matriz de variância diagonal dos coeficientes espectrais. O α é um peso, que tem como função ponderar os termos da combinação linear, onde estão situados os erros de previsão.

Um esquema de assimilação híbrida também foi proposto por Etherton e Bishop (2004), nele os autores aproximam a matriz de covariância dos erros de previsão \mathbf{B} combinando a matriz de covariância proveniente dos membros do conjunto de previsões obtidas pelo ETKF (*Ensemble Transform Kalman Filter*), \mathbf{P}^b , com a matriz de covariância dos erros de previsão estática proveniente do 3DVar, \mathbf{B}_{3dvar} , conforme representado na equação 1.6.

$$\mathbf{B} = (1 - \alpha)\mathbf{P}^b + \alpha\mathbf{B}_{3dvar} \quad (1.6)$$

Posteriormente, outros trabalhos testaram diferentes alternativas de atualização da matriz de covariância dos erros de previsão, a fim de avaliar a capacidade dos siste-

mas híbridos em minimizar os erros de previsão. Com o sucesso obtido em trabalhos pioneiros nesta abordagem, outros estudos científicos investigaram diferentes formas de combinação, conforme retratado nos trabalhos de [Zhang et al. \(2009\)](#), que elaborou um sistema híbrido baseado no EnKF e no 4DVar, para atualizar a matriz \mathbf{B} e [Clayton et al. \(2012\)](#) que avaliou implementação de um sistema híbrido operacional no centro de previsão meteorológica do Reino Unido, onde foi utilizado o ETKF e o 4DVar.

Resultados encorajadores vem sendo obtidos em diversos trabalhos ao longo dos anos, utilizando assimilação híbrida 3DEnVar baseada no EnKF e o 3DVar ([LI et al., 2012](#); [GAO](#); [STENSRUD, 2014](#); [BASTARZ, 2017](#)). [LI et al. \(2012\)](#) apontam que a assimilação híbrida utilizando a velocidade radial do radar conseguiu produzir uma análise e previsão melhores se comparado ao resultado sem a assimilação durante o furacão Ika (2008). [Gao e Stensrud \(2014\)](#) utilizaram a assimilação híbrida com dados de radar para melhorar as análises e previsões associadas a um evento de tempestade ocorrido no dia 20 de maio de 1977 próximo a *Dell City*, em *Oklahoma* e obtiveram resultados satisfatórios. [Bastarz \(2017\)](#) realizou um estudo detalhado utilizando o modelo global do CPTEC para avaliar a habilidade do sistema híbrido em assimilar dados de estações convencionais, de satélites e prever determinadas variáveis. A conclusão foi que o híbrido teve melhores resultados se comparado com um sistema variacional puro em todos os casos. Os benefícios obtidos ao utilizar este sistema foram devidos, à incorporação dos erros do dia à matriz de covariâncias dos erros de previsão.

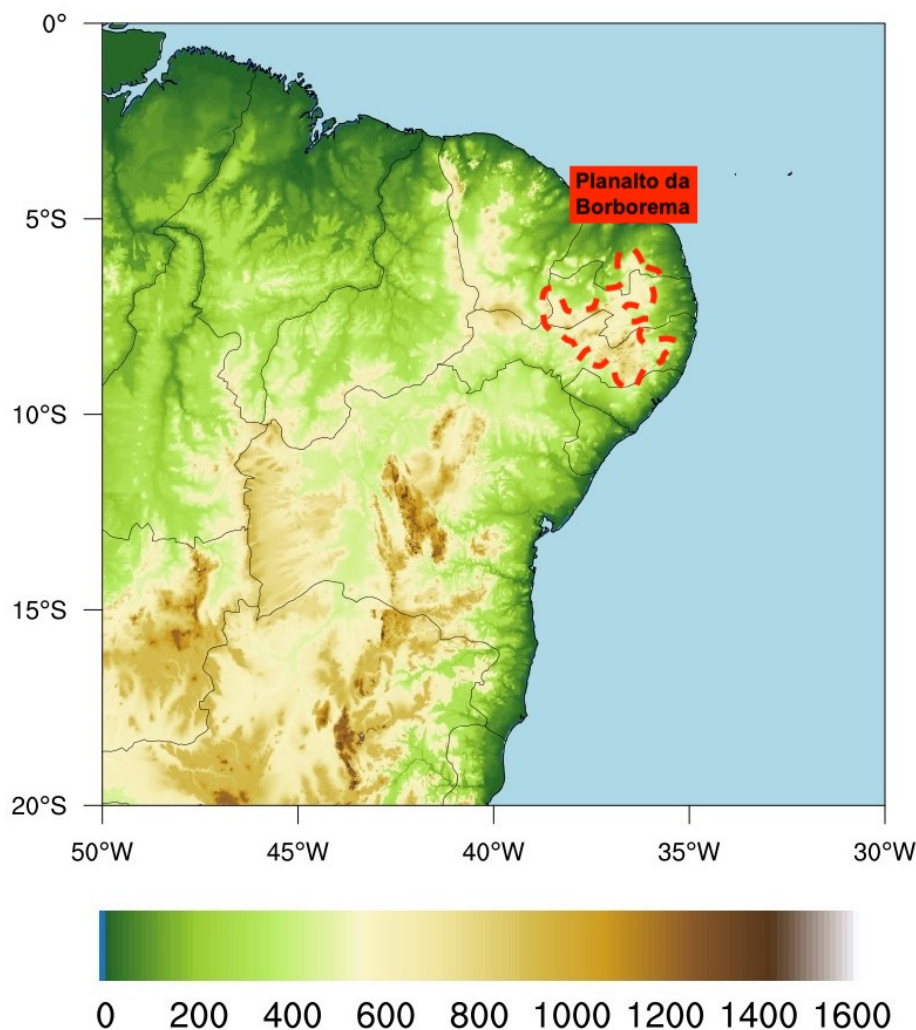
2 MATERIAIS E MÉTODOS

Os episódios de SCM escolhidos para estudo neste trabalho, ocorreram nos dias 14 e 24 de janeiro de 2017 e foram identificados conforme os métodos abordados nos próximos subtópicos deste capítulo. Uma descrição dos modelos aqui utilizados, dados observacionais obtidos, assim como a metodologia empregada para a execução do 3DVar, EnKF e 3DEnVar, também foram aqui abordados, na intenção de ilustrar o significado das principais equações envolvidas na obtenção das análises, bem como a metodologia utilizada para realização dos ciclos de assimilação de dados.

2.1 Área de estudo

O estudo dos eventos de SCM foi feito para o NEB, localizado na região tropical do Brasil entre os paralelos do Equador (0°S) e Trópico de Capricórnio (aproximadamente $23,5^{\circ}\text{S}$), caracterizado por uma temperatura média superficial em torno de 20°C (HENRY, 2005). Essa região é fortemente marcada pela heterogeneidade topográfica que abrange desde sua região litorânea, onde encontram-se as planícies costeiras banhadas pelo oceano Atlântico e se estende até áreas mais interioranas, onde está situado o planalto da Borborema, sendo este fator topográfico (Figura 2.1) um dos responsáveis pelas condições dinâmicas formadoras de chuva na região.

Figura 2.1 - Mapa topográfico do NEB com a elevação em metros.



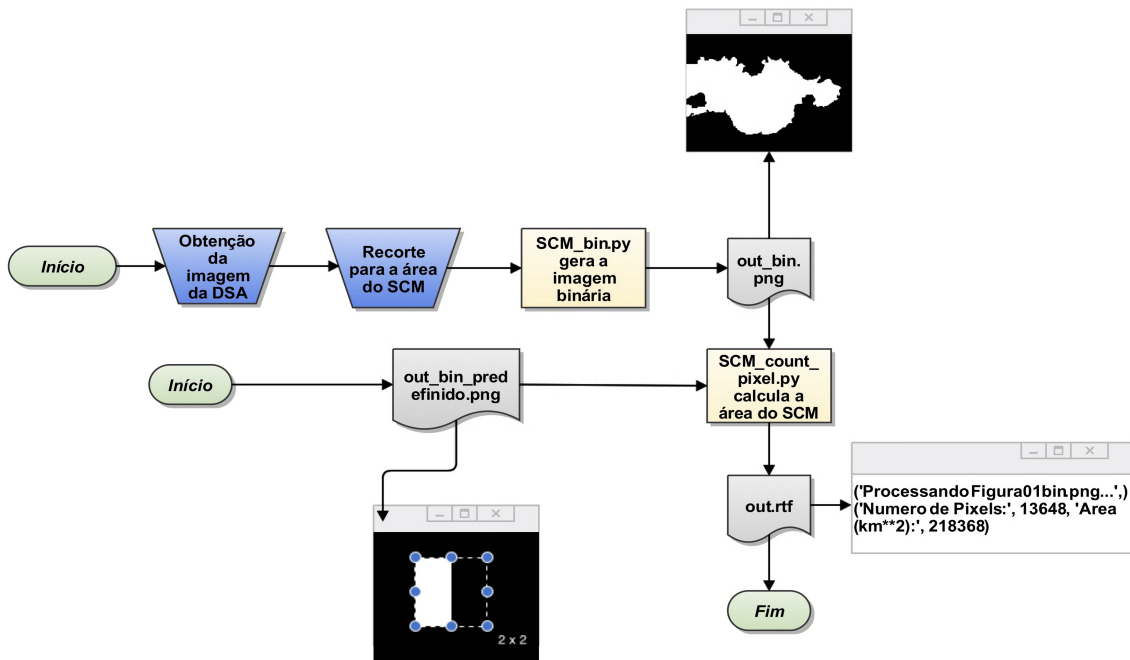
Fonte: Produção do autor.

2.2 Identificação dos sistemas convectivos de mesoescala

Como parte da análise objetiva utilizada para a identificação dos casos de SCM, foi definido como um SCM uma área igual ou superior a aproximadamente 3.500 km² e com temperatura de brilho para o topo da nuvem igual ou inferior a -38,15 °C, segundo Machado e Laurent (2004). A temperatura desses sistemas foi verificada utilizando as imagens do canal infravermelho disponibilizadas pela DSA (Divisão de Satélites Ambientais) do CPTEC/INPE. A área foi determinada através da contagem de *pixels*, tendo cada um deles uma resolução horizontal de 4 × 4 km (<https://>

www.ssec.wisc.edu/datacenter/standard_GOES8-15.html#GOES-13) referente a uma área de seleção onde encontravam-se os SCM associados a eventos de chuva intensos sobre o NEB. Para isso foi desenvolvido um algoritmo utilizando a linguagem de programação *Python* na versão 2.7.15 com os pacotes *cv2* e *numpy* para manipulação das imagens em seus respectivos diretórios (Figura 2.2).

Figura 2.2 - Esquema ilustrando a contabilização do número pixels e a área dos SCM utilizando as imagens do satélite GOES-13.



Fonte: Produção do autor.

A validação das imagens obtidas foi feita através de figuras com uma quantidade de *pixels* brancos predeterminados, a fim de atestar a capacidade do *script* na contabilização dos mesmos, conforme ilustrado na Figura 2.2. Como resultado, todos os casos testados forneceram informações coerentes na contabilização de *pixels* brancos das amostras testes e, com isso, esse *script* pôde ser empregado na determinação da área dos SCM utilizando as imagens do canal infravermelho do satélite GOES-13.

2.3 Identificação dos episódios de chuva

Para identificar os episódios de chuva intensos sobre o NEB foram obtidos dados de precipitação acumulada em 24 horas (mm) para os dias de episódios de SCM sobre o NEB, através do banco de dados meteorológicos BDMEP (<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>) do Instituto Nacional de Meteorologia (INMET). Este banco de dados disponibiliza, no formato digital, informações meteorológicas provenientes de diversas estações meteorológicas em superfície pertencentes a rede de estações do INMET. No presente estudo, deve-se interpretar episódios de chuvas intensas como aqueles eventos cujo acumulado de precipitação em 24 horas para o dia do evento foi superior a 70 mm em algum dos municípios sobre influência do SCM, conforme as taxas de precipitação acumulada em 24 horas empregadas no produto digital do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), cujo o manual encontra-se disponível no seguinte endereço eletrônico: <http://www.cemaden.gov.br/mapainterativo/arquivos/MapaInterativo.pdf>.

2.4 Modelo de mesoescala WRF


O WRF foi desenvolvido pelo *National Center for Atmospheric Research* (NCAR), administrado pela *University Corporation for Atmospheric Research* (UCAR). Este é um dos modelos numéricos de previsão do tempo e pesquisa mais utilizados do mundo, amplamente apoiado e continuamente aprimorado pela comunidade internacional de pesquisa em ciências atmosféricas global (POWERS et al., 2017).

Neste trabalho a versão utilizada será a 3.9.1.1 do *Advanced Research WRF*, a mesma versão operacional utilizada pelo CPTEC, que consiste de um sistema de previsão de tempo meteorológico estruturado para atender as necessidades de pesquisas científicas e para uso operacional. O WRF-ARW consta de dois núcleos dinâmicos, um sistema de assimilação de dados e uma estrutura de arquitetura de software, que suporta o emprego de computação paralela aplicada na resolução de uma série de problemas meteorológicos, que vão desde a escala de metros a milhares de quilômetros.

Constituído de 4 componentes (Figura 2.3) para sua execução completa, o pré-processamento, a inicialização, o módulo de execução e o pós-processamento, o WRF funciona da seguinte maneira (CARVALHO et al., 2013): com o *WRF Preprocessing System* (WPS) são preparados os dados de entrada para simulação por meio dos executáveis do *geogrid*, *ungrib* e *metgrid*. No *geogrid* ocorre a definição do domí-

nio a ser utilizado pelo WRF e a interpolação das informações da superfície para a grade regular do modelo. Com o *ungrib* se extrai os dados das variáveis meteorológicas provenientes de um modelo, por exemplo o *Global Ensemble Forecast System* (GEFS), para as grades do modelo WRF, para que ao final o *metgrid* interpole-as horizontalmente. O sistema de inicialização do modelo, tem apenas um executável, o *real*, responsável por interpolar verticalmente os campos do modelo WRF. O módulo responsável pela execução do modelo e geração dos resultados finais da previsão é constituído também de apenas um executável do WRF. A última componente do sistema é o *ARWpost*, que prepara os arquivos de previsão em um formato adequado para a manipulação das informações geradas no módulo de execução do WRF utilizando algum *software* de visualização gráfica de dados meteorológicos.

Figura 2.3 - Componentes para execução do modelo WRF.



Fonte: Adaptado de [Carvalho et al. \(2013\)](#).

Para avaliação dos campos meteorológicos e termodinâmicos dos episódios de SCM ocorridos no verão austral de 2017 sobre o NEB, será utilizado o modelo meteorológico de mesoescala WRF, com as mesmas parametrizações definidas por [Nobre et al. \(2019\)](#), exceto para a parametrização de nuvens *Cumulus*. Essa modificação se justifica, em virtude do estudo climatológico para a região tropical durante o verão boreal entre 2012-2016 usando o modelo WRF, realizado por [Sun e Bl \(2019\)](#), ter apontado o novo esquema de Tiedke combinado ao RRTMG como o melhor em produzir o ciclo diurno de precipitação entre 45°N-S, quando comparado com o esquema

de Tiedke (TIEDTKE, 1989), Kain–Fritsch (KAIN, 2004) e o novo esquema simplificado de Arakawa-Schubert (HAN; PAN, 2011). No presente trabalho, o domínio e os pontos de grade sobre o NEB também foram modificados para melhor representar os eventos de SCM, conforme ilustrado na Tabela 2.1.

Tabela 2.1 - Configurações do modelo WRF.


Parâmetro	Valor/Descrição
Modelo de mesoescala	WRF
Resolução horizontal	9 km
Base de dados meteorológicos	GEFS
Base de dados de topografia	SRTM (30 m)
Base de dados de rugosidade	MODIS (925 m)
Numero de níveis verticais da atmosfera	42
Radiação de onda longa e curta	RRTMG
Microfísica	WSM6 (HONG; LIM, 2006)
Cumulus	Tiedtke (ZHANG; WANG, 2017)
Camada superficial e camada limite planetária	YSU (HONG et al., 2006)
Modelo de superfície do solo	Noah (TEWARI et al., 2004)

Fonte: Produção do autor.

2.4.1 Configuração espacial do WRF para o NEB

A resolução espacial utilizada nas configurações iniciais do modelo WRF foi de 9 km de resolução horizontal e o domínio escolhido sobre o NEB foi centrado na latitude e longitude em torno de 9°S e 36°W. As previsões foram configuradas para simular o comportamento atmosférico discretizado em 42 níveis verticais, utilizando a coordenada híbrida sigma-pressão (σ -p) e resolução temporal de 1 hora, conforme ilustrado na Figura 2.4.

Figura 2.4 - Domínio sobre o NEB configurado para execução do modelo WRF.



Fonte: Produção do autor.


A coordenada híbrida é resultante da combinação das coordenadas σ e pressão (Equação 2.1). Ela é utilizada para simular o comportamento da troposfera em 42 níveis verticais pelo modelo WRF e se demonstrou satisfatória ao representar a turbulência de ar superior, conforme demonstrado por Park et al. (2019). Este tipo de coordenada contribui para melhorar a representação dos processos na camada limite por seguir naturalmente o terreno, permitindo o aumento da resolução próxima da superfície terrestre em todo o domínio do modelo e que os processos da Camada Limite planetária sejam representados de forma mais realística, tais como a turbulência, aquecimento diurno, vento e umidade em baixos níveis. Em altos níveis, a representação da atmosfera é feita pela coordenada de pressão.

$$\sigma = \frac{p_{ref}(z_s) - p_T}{p_{ref}(0) - p_T} \quad (2.1)$$

Onde p representa a pressão, T e S representam topo e superfície da atmosfera, respectivamente, Z_S seria a altura da superfície, p_{ref} pressão de referência e p_T a pressão no topo da atmosfera.

O domínio computacional do WRF-ARW está configurado para a grade C de Arakawa (Figura 2.5c), onde as velocidades são calculadas no ponto médio entre as células de grade e a massa na interseção. A vantagem principal desta configuração é o cálculo dos termos de pressão e convergência no centro das células de grade, o que corresponde à metade da grade A (Figura 2.5a) e implica no melhoramento da sua resolução (ARAKAWA; LAMB, 1977).

Figura 2.5 - Disposição das variáveis meteorológicas nas grades de A a E de Arakawa.



Fonte: Adaptado de Arakawa e Lamb (1977).

2.4.2 Condições iniciais

As condições iniciais foram provenientes do GEFS (*Global Ensemble Forecast System*) constituído de um conjunto de 20 membros de previsão pertur-

bados mais um membro controle determinístico, com resolução horizontal de $0,25^\circ \times 0,25^\circ$, disponibilizados a cada 6 horas para um janela de previsão de 16 dias, no seguinte endereço eletrônico: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-ensemble-forecast-system-gefs>.

Um banco de dados geofísico foi utilizado para prover as demais condições de contorno do modelo WRF, como a topografia, cobertura e uso do solo obtidos das plataformas de dados de instrumentos remotos.

Os dados de topografia foram da base do SRTM - *Shuttle Radar Topography Mission*) (<http://earthexplorer.usgs.gov/>), que conta com dados de elevação espacial de 30 m, empregados com a finalidade de gerar um banco de dados topográficos de alta resolução para as previsões executadas no modelo WRF. O SRTM é o mais completo banco de dados topográfico digital de alta resolução da Terra, elaborado pela NASA a partir de dados coletados por um sistema de radar a bordo do ônibus espacial *Endeavour*.

As informações digitais de cobertura do solo foram provenientes da base de dados do satélite MODIS (*Moderate Resolution Imaging Spectroradiometer*), que é um mapa global de cobertura territorial de 20 categorias de superfície e resolução espacial em grade regular de aproximadamente 1 km.

2.4.3 Parametrizações de transferência radiativa

A parametrização da radiação de onda longa e curta no modelo WRF foi feita utilizando o *Rapid Radiative Transfer Model for Global circulation model* RRTMG disponibilizado para a versão 3.9.1.1 do WRF. O RRTMG é um modelo de transferência radiativa que calcula fluxos de ondas longas e curtas, além de taxas de aquecimento com eficiência e precisão com aplicação, inclusive, em Modelos de Circulação Geral (MCG).

Para o RRTMG, as propriedades ópticas das nuvens líquidas são calculadas para cada banda espectral, a partir da parametrização de [Hu e Stamnes \(1993\)](#). Enquanto que os parâmetros de profundidade óptica, albedo e parâmetro de assimetria são funções do raio efetivo das gotículas da nuvem e do conteúdo da água líquida. Nas nuvens de gelo, as propriedades ópticas são obtidas para cada banda espectral utilizando o esquema paramétrico de partículas de gelo proposto por [Fu et al. \(1998\)](#). No caso específico dos aerossóis, a absorção de onda longa no RRTMG pode ser incluída inserindo a profundidade óptica do aerossol no ponto médio de cada

faixa espectral.

2.4.4 Microfísica

Hong e Lim (2006) desenvolveram o esquema microfísico *WRF Single-Moment 6-Class Microphysics scheme* (WSM6) a partir do *WRF Single-Moment 5-Class Microphysics scheme* (WSM5) e parte inicialmente do tamanho do hidrometeoro para cada classe, cuja distribuição pode ser calculada por funções do tipo exponencial ou gama. Ao final, obtém-se uma equação prognóstica, como por exemplo a do granizo, ilustrada pela Equação 2.2.

$$\frac{\partial q_G}{\partial t} = -\vec{V}\nabla_3 q_g + \frac{q_g}{\rho} \frac{\partial(\rho V_g)}{\partial z} + S_G \quad (2.2)$$

na Equação 2.2, os termos $\vec{V}\nabla_3 q_g$ e $\frac{q_g}{\rho} \frac{\partial(\rho V_g)}{\partial z}$ referem-se a advecção e sedimentação do granizo, respectivamente, enquanto que o terceiro termo (S_G) refere-se às fontes e sumidouros. Os processos microfísicos entre os 6 hidrometeoros (nuvem líquida, nuvem de gelo, vapor d'água, chuva, granizo e neve) no WSM6 seguem a parametrização de Bulk para partículas de nuvem e gotas precipitantes conforme abordado por Lin et al. (1983) e Rutledge e Hobbs (1984), sintetizados na Figura 2.6.

considera que o entranhamento organizado ocorre quando o ar flui ascendentemente para o interior da nuvem, adquirindo flutuabilidade positiva, enquanto que o desentranhamento organizado é gerado quando o ar desacelera, adquirindo flutuabilidade negativa (NORDENG, 1994). A taxa de entranhamento-desentranhamento turbulento (ϵ^T/δ^T), é calculada considerando-a inversamente proporcional ao raio da base da nuvem (R), conforme demonstrado pela Equação 2.3.

$$\epsilon^T = \delta^T = \frac{0,2}{R} \quad (2.3)$$

Uma outra mudança crucial, desempenhada no novo esquema de Tiedtke, foi o tratamento da condensação no topo das nuvens *Cumulus*, que era evaporado rapidamente no esquema inicial (ZHANG et al., 2011). Para isso é necessário calcular a fração de água e de gelo da nuvem através da Equação 2.4 a partir da temperatura (T) ao longo da estrutura vertical da nuvem.

$$f_{liq} = a + (1 - a)e^{-b(T-T_0)^2}, f_{ice} = 1 - f_{liq} \quad (2.4)$$

onde $a = 0,0059$; $b = 0,0031$ e $f_{liq} = 1$, quando $T \geq T_0$, pois nesta circunstância não existe a fração de gelo da nuvem.

2.4.6 Parametrizações da superfície do solo, camada limite superficial e planetária

O modelo de superfície terrestre Noah permite simular diversos parâmetros dentre eles a umidade e temperatura do solo, a profundidade e a densidade da camada de neve, o teor de água no dossel das plantas e os termos de fluxo de água (MITCHELL, 2005).

Em geral, os modelos desenvolvidos para a resolução da Camada Limite Planetária (CLP) são classificados em dois tipos, aqueles em que os níveis verticais adjacentes a um determinado ponto afetam as variáveis neste local diretamente (esquema de fechamento local) e aqueles cuja camada de mistura profunda cobrem vários níveis verticais através da CLP (esquema de fechamento não local). Dentre os dois métodos citados, a mistura não local é vantajosa por prever com maior precisão as taxas de variação vertical da temperatura na troposfera para o setor quente dos fenômenos meteorológicos (COHEN et al., 2015).

Para a resolução dos processos associados à CLP, foi utilizado no WRF a parametrização da *Yonsei University (YSU)* proposta por [Noh et al. \(2003\)](#). Um estudo comparativo realizado por [Xie et al. \(2012\)](#), em Hong Kong, mostra que os esquemas não locais, como o ACM2 e o *Yonsei University (YSU)* produzem uma CLP mais profunda, que os esquemas locais, como por exemplo, o *Mellor–Yamada–Janjic (MYJ)* e o *Bougeault–Lacarrère (BouLac)*, o que contribuiu para reproduzir previsões de temperatura do ar a 2 m (K) e velocidade do vento a 10 m ($m s^{-1}$) acima da superfície mais realísticas quando comparadas com as observações.

2.5 Assimilação de dados no SMR

O SMR, configurado para realização deste trabalho, utiliza a versão 3.4 do GSI para geração das análises. Assim, para atualizar as previsões, os dados do GEFS (no primeiro ciclo de assimilação) e do WRF (nos demais ciclos de assimilação) foram combinados com observações meteorológicas utilizando os sistemas de assimilação de dados 3DVar, EnKF e 3DEnVar.

Por ser um modelo global, os dados do GEFS foram inicialmente atualizados pela componente de pré-processamento do modelo WRF (WPS), para um domínio projetado sobre o NEB. A utilização do sistema híbrido, 3DEnVar, foi condicionada à habilitação do EnKF na versão 1.0, disponibilizada no pacote do GSI. Através dele foi possível assimilar as observações meteorológicas em um conjunto de 20 perturbações mais um membro controle, provenientes do GEFS e pré-processados para um domínio sobre o NEB, através do WPS, para o primeiro ciclo de análise. Para os demais ciclos, as previsões foram obtidas do modelo WRF em ciclos de análises e previsões a cada 6 horas. Em cada ciclo de análise, o conjunto de membros do EnKF foi utilizado para atualizar a matriz de covariâncias dos erros de previsão do 3DVar. Com isso, as análises do GSI foram utilizadas como condições iniciais para o WRF nas previsões dos acumulados de chuva em 24 horas para os dias dos episódios de SCM sobre o NEB.

2.5.1 Dados observacionais

Para elaboração das análises também foram utilizados dados de radiância ou temperatura de brilho do *Advanced Microwave Sounding Unit-A (AMSU-A)*, que fornece dados de temperatura de brilho dos satélites NOAA-15, 16, 17, 18, 19 e *Meteorological Operational Satellite Programme (METOP)-A/B*, dados do *Microwave Humidity Sounder (MHS)* contendo informações de sondagem de umidade por microondas dos satélites NOAA-18, 19 e METOP-A/B. Dados do *High-Resolution*

Infrared Radiation Sounder 4 (HIRS4), com a radiância dos satélites NOAA-18, 19 e METOP-A/B, dados observacionais de vento por satélite, dados de ângulo de curvatura e rádio-ocultação por GPS, além de dados provenientes de estações meteorológicas convencionais e automáticas em superfície e de radiossondagem, para os ventos zonal e meridional, temperatura, umidade específica e pressão superficial, disponíveis no endereço eletrônico: <https://rda.ucar.edu> e sintetizados na Tabela 2.2.

Tabela 2.2 - Observações assimiladas pelo GSI.

Observação	Dados
prepbufr	Observações convencionais
amsuabufr	Radiância AMSU-A 1b (temperaturas de brilho) dos satélites NOAA-15, 16, 17,18, 19 e METOP-A/B
gpsrobufr	ângulo de curvatura e rádio-ocultação por GPS
hirs4bufr	Observação de radiância do HIRS4 1b dos satélites NOAA-18, 19 and METOP-A/B
mhsbufr	Observação do sonarizador de umidade de Microondas do NOAA-18, 19 e METOP-A/B

Fonte: Produção do autor.

2.5.2 Assimilação de dados pelo método 3DVar

No 3DVar, as análises são obtidas quando o gradiente da função custo é mínimo ($\nabla J(\mathbf{x}) = 0$). Para isso, é necessário utilizar o teorema de Bayes (Equação 2.5).

$$p(\mathbf{x}|\mathbf{y}_o, \mathbf{x}_b) = \frac{p(\mathbf{y}_o, \mathbf{x}_b|\mathbf{x})p(\mathbf{x})}{p(\mathbf{y}_o, \mathbf{x}_b)}. \quad (2.5)$$

A aplicação do teorema de Bayes na função custo, conforme retratado em Fisher (2015), permite obter um função quadrática em termos do vetor estado a ser analisado, apresentado na Equação 1.1.

A obtenção da equação da análise no 3DVar é feita aplicando o operador gradiente na função custo (Equação 1.1) e igualando a expressão resultante a zero ($\nabla J(\mathbf{x}) = 0$) para obtenção do mínimo valor de $J(\mathbf{x})$. Considerando $\mathbf{x} = \mathbf{x}_a$, ou seja, que o vetor do estado a ser analisado da função custo igual ao estado da análise, obtido após a minimização de $J(\mathbf{x})$, é possível obter a Equação 2.6.

$$\mathbf{x}_a = \mathbf{x}_b + \mathbf{K}[\mathbf{y}_o - H(\mathbf{x}_b)] \quad (2.6)$$

Assim, \mathbf{x}_a , na Equação 2.6, é o vetor estado da análise, ele é igual ao vetor estado previsto \mathbf{x}_b somado à inovação $\mathbf{y}_o - H(\mathbf{x}_b)$ ponderada pela matriz de ganho de Kalman, responsável por atribuir pesos às inovações e ao mesmo tempo transformar o termo da inovação $\mathbf{y}_o - H(\mathbf{x}_b)$ para todo o espaço do modelo. Uma característica do 3DVar é que ele utiliza métodos de solução iterativos para a resolução da equação linear da análise, diminuindo o número de operações se comparado com a interpolação ótima, que utiliza métodos diretos para resolver a matriz de ganho de Kalman, definida pela Equação 2.7, o que demandaria maior custo computacional (FISHER, 2015).

$$\mathbf{K} = [(\mathbf{B})^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}]^{-1} \mathbf{H}^T \mathbf{R}^{-1} \quad (2.7)$$

onde a matriz \mathbf{B} representa a covariância dos erros de previsão, uma matriz pré-calculada por meio de previsões distribuídas ao longo do tempo. \mathbf{H}^T é a matriz transposta do jacobiano do operador observação, responsável por trazer a inovação ponderada pelos erros da observação que encontravam-se no espaço físico das observações para o espaço do modelo e \mathbf{R} é a matriz de covariância dos erros da observação.

A Equação 2.7 mostra que matriz de ganho de Kalman é calculada pela covariância dos erros das observações $\mathbf{H}^T \mathbf{R}^{-1}$ multiplicado pelo inverso da covariância de erro total, $(\mathbf{B})^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$, obtido através da soma das covariâncias do modelo com as covariâncias dos erros das observações. Observe, portanto, que quanto maior é a covariância dos erros de previsão em comparação com a covariância dos erros de observação, maior será a correção feita no *background*

Ao passar \mathbf{x}_b para o lado esquerdo da Equação 2.6, é possível calcular o incremento de análise ($\mathbf{x}_a - \mathbf{x}_b$) conforme abordado pela Equação 2.8.

$$\mathbf{x}_a - \mathbf{x}_b = (\mathbf{B}^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} [(\mathbf{H}^T \mathbf{R}^{-1})(\mathbf{y}_o - \mathbf{H}(\mathbf{x}_b))] \quad (2.8)$$

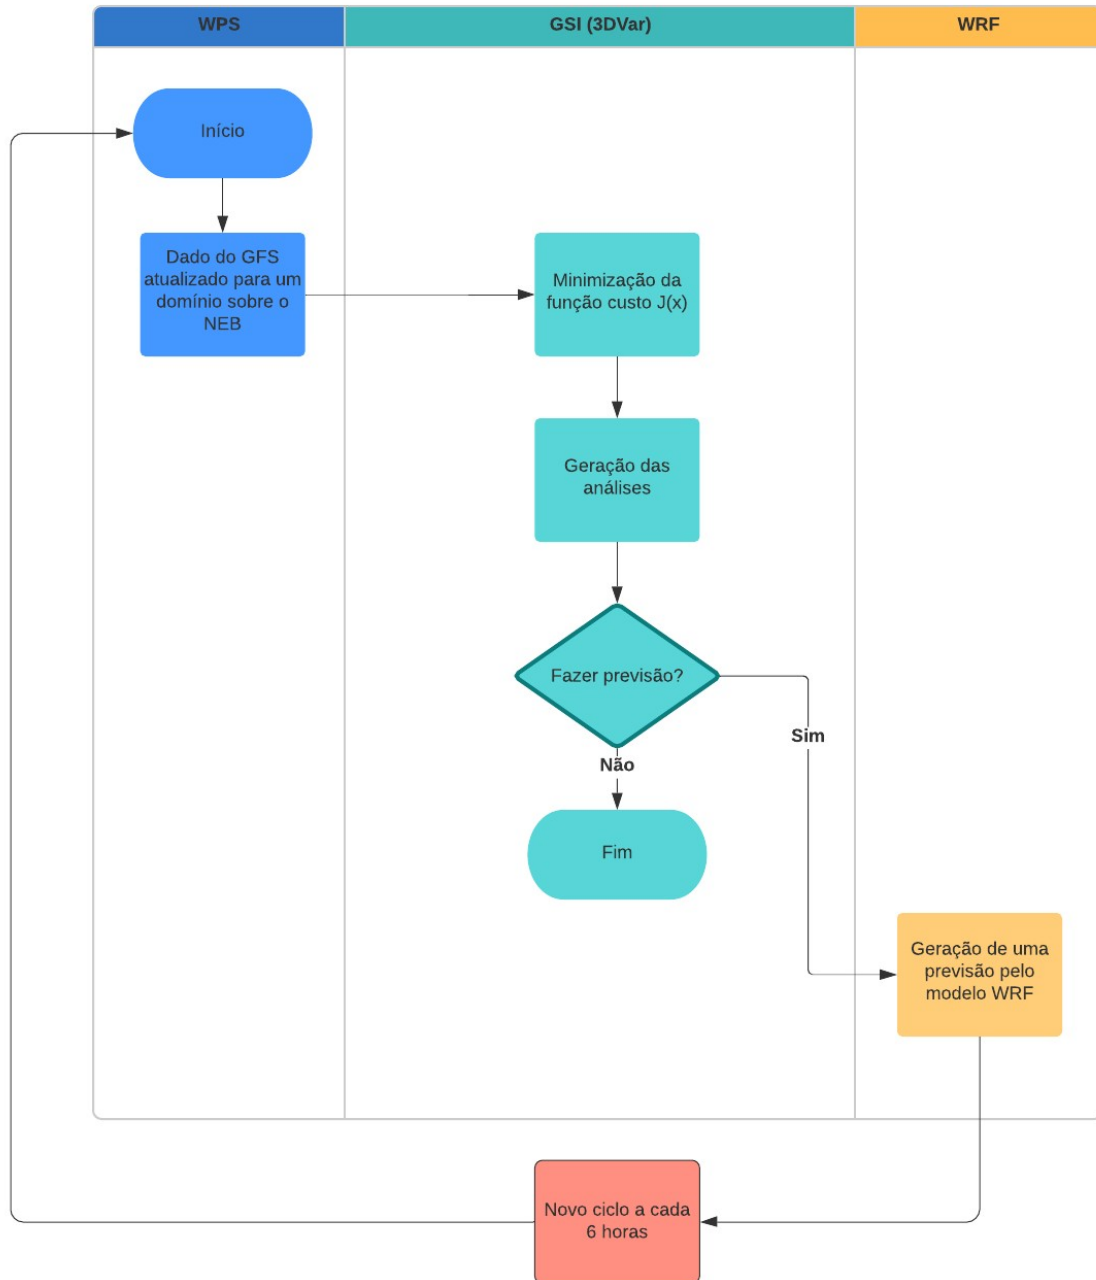
Note que em uma solução alternativa abordada por [Bastarz \(2017\)](#) é possível demonstrar que $\mathbf{x}_a - \mathbf{x}_b$ é proporcional a covariância dos erros de previsão (\mathbf{B}), conforme ilustrado pela Equação 2.9. Em suma, o papel da matriz \mathbf{B} é distribuir a inovação das observações, ponderando sua contribuição para o incremento de análise, garantindo que as análises sejam dinamicamente consistentes na horizontal e na vertical.

$$\mathbf{x}_a - \mathbf{x}_b \propto \mathbf{B} \mathbf{H}^T \quad (2.9)$$

A matriz de covariância dos erros de previsão juntamente com a matriz de ganho de Kalman formam um conjunto de informações, que quando bem determinadas, impactam de forma significativa a qualidade final das análises. Para a geração da matriz \mathbf{B} no 3DVar, utilizou-se um procedimento similar ao método NMC ([PARRISH; DERBER, 1992](#)), Equação 1.2.

Os detalhes sobre o procedimento de geração das análises a partir do 3DVar, no SMR configurado neste projeto, foram sintetizados no esquema da Figura 2.7. Observe que os procedimentos de execução foram separados em blocos, onde o “WPS” refere-se a etapa de pré-processamento dos dados do modelo, o “GSI (3DVar)” corresponde a geração das análises e o “WRF” é a etapa de execução do modelo.

Figura 2.7 - Esquematização completa do ciclo de assimilação e previsão no SMR utilizando o 3DVar.



Fonte: Produção do autor.

A etapa completa desde da geração das condições iniciais para um domínio sobre o NEB utilizando o sistema de pré-processamento do modelo WRF, geração das

análises através do 3DVar no GSI e a previsão final executada pelo modelo WRF, ilustrados na Figura 2.7, é realizada na seguinte sequência:

- a) geração das condições de contorno para um domínio com 9 km de resolução horizontal utilizando como primeira estimativa, o modelo GEFS com 0,25° de resolução horizontal por meio do sistema de pré-processamento do modelo WRF;
- b) minimização da função custo e geração de uma análise utilizando a previsão de 6 horas de um ciclo anterior;
- c) utilização da análise gerada no item anterior para produzir previsões de curto prazo (24, 48 e 72 horas) referente ao dia do episódio de SCM para o domínio sobre o NEB com 9 km de resolução horizontal.

2.5.3 Assimilação de dados pelo método 3DEnVar

Para execução do método híbrido foi utilizado o *Ensemble Square Root Filter* (EnSRF), para atualização das variáveis de análise com uma grade e domínio sobre o NEB já pré-processados pelo modelo WRF utilizando dados do GEFS. Trabalhos como os realizados por Bierman (1977) e Maybeck (1982) revelam que esta metodologia têm apresentado uma precisão numérica e estabilidade superiores em comparação com o algoritmo do filtro de Kalman padrão e evitam problemas de amostragem associados ao uso de observações perturbadas.

O EnSRF implementado pela NOAA (HU et al., 2015) e aqui empregado, utiliza as equações do membro médio do conjunto (2.10) e de atualização das análises no espaço de perturbação do conjunto (2.12) para atualização das condições iniciais. A forma como esse procedimento é feito encontra-se expresso pelas Equações 2.10, 2.11, 2.12 e 2.13, cujos significados atribuídos à cada uma das variáveis já foram descritos anteriormente. Diferentemente dos termos já apresentados em subtópicos anteriores, as barras denotam as médias na Equação 2.10 para os termos referentes as análises e ao *background*. As aspas simples, sobrescritas na Equação 2.12, representam as perturbações.

$$\bar{\mathbf{x}}_a = \bar{\mathbf{x}}_b + \mathbf{K}[\mathbf{y}_o - H(\bar{\mathbf{x}}_b)] \quad (2.10)$$

$$\tilde{\mathbf{K}} = \alpha \mathbf{K} \quad (2.11)$$

$$\mathbf{x}'_{\mathbf{a}} = \mathbf{x}'_{\mathbf{b}} + \tilde{\mathbf{K}}H(\mathbf{x}'_{\mathbf{b}}) \quad (2.12)$$

$$\alpha = \left[1 + \sqrt{\frac{R}{\mathbf{H}\mathbf{P}^{\mathbf{b}}\mathbf{H}^T + R}} \right]^{-1} \quad (2.13)$$

Observe que na Equação 2.11, a matriz $\tilde{\mathbf{K}}$, é a matriz de ganho, essencial para geração de análises para um conjunto de membros perturbados em um momento posterior à assimilação ($\mathbf{x}'_{\mathbf{a}}$) e obtidos através da Equação 2.12. Note, porém, que no procedimento de geração das análises para cada membro através do EnSRF, as observações não são perturbadas, sendo, portanto, determinadas através dos membros perturbados em um momento anterior a geração das análises (eg., conjunto de previsões do GEFS) acrescido dos ganhos obtidos ao aplicar a matriz $\tilde{\mathbf{K}}$ a este termo. Já a análise do membro médio ($\bar{\mathbf{x}}_{\mathbf{a}}$) é obtida através da média do conjunto de previsões e dos incrementos de análise ponderados pela matriz de ganho de Kalman (\mathbf{K}). As Equações 2.10 e 2.12, juntas, compõem um conjunto de análises responsáveis por atualizar o *background* pelo algoritmo do EnSRF.

A matriz do ganho de Kalman (\mathbf{K}), nas Equações 2.10 e 2.11, é uma matriz de covariância multivariada dos erros do modelo e das observações, definida conforme a Equação 2.14.

$$\mathbf{K} = \mathbf{P}^{\mathbf{b}}\mathbf{H}^T[\mathbf{H}\mathbf{P}^{\mathbf{b}}\mathbf{H}^T + \mathbf{R}]^{-1} \quad (2.14)$$

O termo $\mathbf{P}^{\mathbf{b}}$, da Equação 2.14, denota a matriz de covariância dos erros de previsão, que para o EnSRF é calculada através da média do conjunto de previsões obtidas, conforme retratado na Equação 2.15 (DEVELOPMENTAL TESTBED CENTER, 2015).

$$\mathbf{P}^{\mathbf{b}} = \frac{1}{(n-1)} \sum_{i=1}^n \mathbf{x}'_{\mathbf{n}}(\mathbf{x}'_{\mathbf{n}})^T \quad (2.15)$$

onde n denota o número de previsões e i o membro do conjunto.

No 3DEnVar, a matriz \mathbf{B} é representada pela combinação linear da matriz estática do 3DVar (\mathbf{B}) e a obtida pela média de um conjunto de previsões ($\mathbf{P}^{\mathbf{b}}$) do EnSRF, conforme apresentado na Equação 2.16, onde α é o coeficiente utilizado para pon-

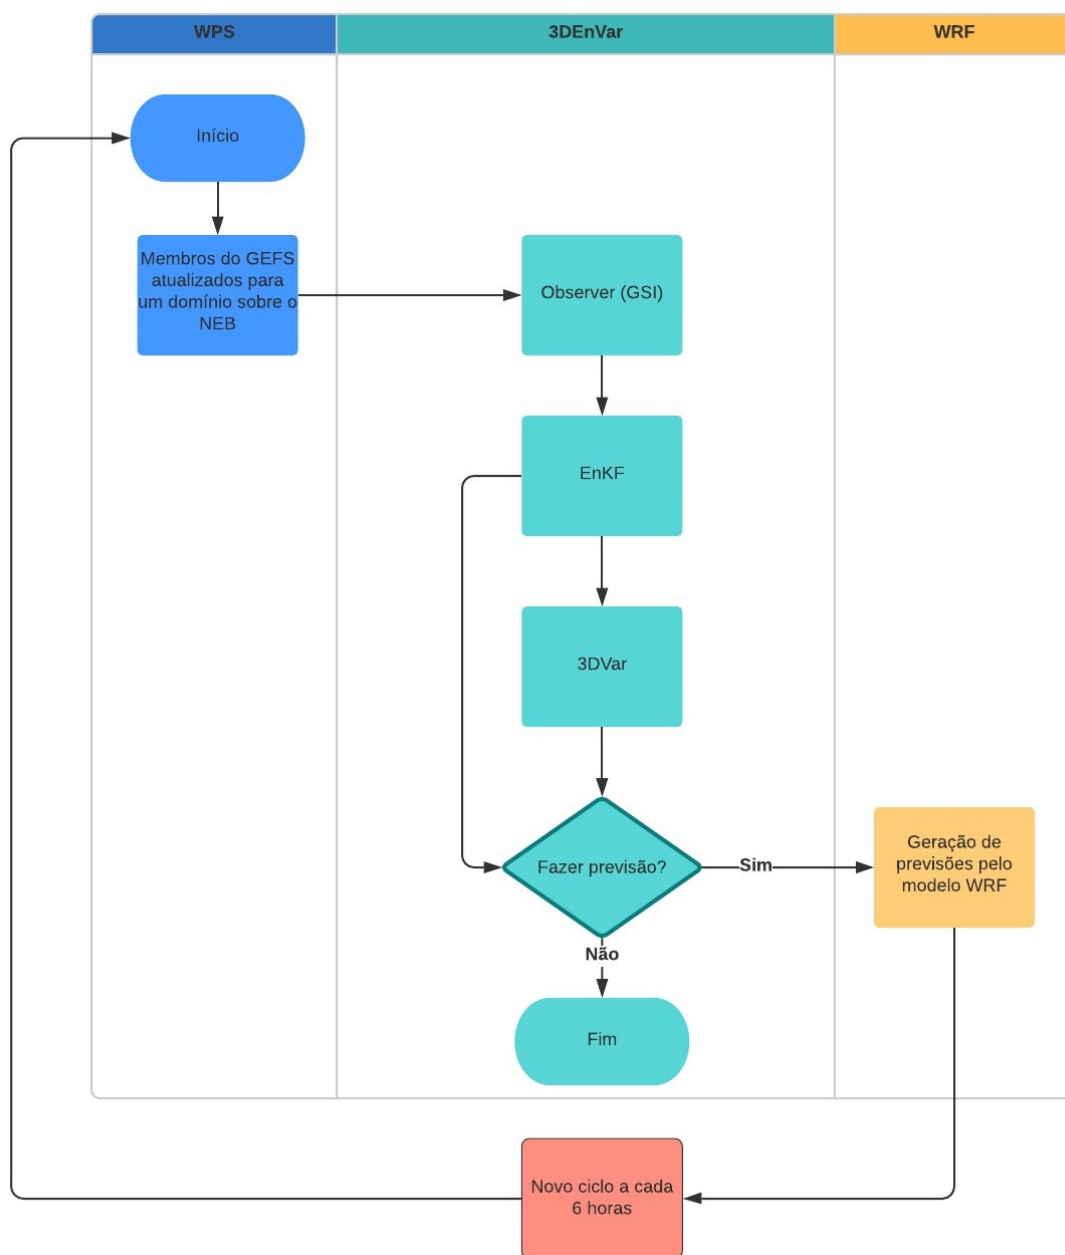
derar a contribuição das duas matrizes. A definição dos pesos da Equação 2.16 foi realizada comparando o BIAS e o RMS dos membros determinísticos obtidos ao final de cada ciclo de análise, às 00 UTC, dos dias 14 e 24 de janeiro de 2017, com diferentes pesos atribuídos em uma etapa anterior a execução do sistema. Ao final, as análises do 3DEnVar em que os pesos utilizados na combinação linear obtiveram os melhores resultados foram utilizados nos experimentos.

$$\mathbf{B} = (1 - \alpha)\mathbf{B}_{3dvar} + \alpha\mathbf{P}^b \quad (2.16)$$

onde, \mathbf{B} corresponde à matriz de covariância dos erros de previsão, resultante da combinação linear da matriz de covariância do erros de previsão estática \mathbf{B}_{3dvar} , ponderada pelo peso, $\alpha - 1$, somada à matriz de covariância dos erros dos conjunto de previsões \mathbf{P}^b , ponderado pelo peso α , definido previamente. Ao final, o somatório dos pesos atribuídos à cada um dos termos desta combinação linear deve ser igual a 1.

Uma descrição de todas as etapas executadas para a obtenção das análises através do EnKF, desde a preparação dos arquivos do GEFS em uma grade sobre NEB pelo WPS até a geração de previsões meteorológicas de curto prazo usando o modelo WRF, pode ser visualizada de forma esquemática através da Figura 2.8. Observe que as 21 previsões do modelo WRF foram inicializadas com dados do GEFS atualizadas pelo EnSRF, para o primeiro ciclo de assimilação, enquanto que para os demais ciclos, as previsões de 6 horas do modelo WRF foram atualizadas pelo EnSRF para gerar as condições iniciais do SMR aqui configurado. No final de cada ciclo de assimilação do 3DEnVar, foi obtida uma análise determinística, utilizada para avaliação dos campos meteorológicos e termodinâmicos. As previsões do modelo WRF, inicializadas com este membro determinístico do 3DEnVar, serviram para avaliar a chuva acumula em 24 horas nos dias de ocorrência de SCM, sobre o NEB.

Figura 2.8 - Esquematização completa do ciclo de assimilação e previsão no SMR utilizando o 3DEnVar.



Fonte: Produção do autor.

2.5.4 Avaliação estatística dos dados

Uma forma importante de avaliar a qualidade de qualquer assimilação de dados é obter as diferenças da observação-menos-previsão (do inglês *Observation Minus Forecast*, OMF) e observação-menos-análise (do inglês *Observation Minus Analysis*, OMA) por meio do cálculo do BIAS e da raiz do erro quadrático médio (RMSE, na sigla em inglês).

O histograma de OMF e OMA, aqui utilizado, tem sido apresentado para as escalas espaciais e temporais, mostrando resultados consistentes na ilustração do impacto das observações assimiladas (TODLING 2013, CINTRA; COCKE 2015, ZANG; WANG 2019).

Conforme abordado por Lahoz et al. (2009 citado por Cintra e Cocke, 2015. p. 190), o incremento de observação menos previsão (OMF) fornece uma estimativa inicial de quão distante as observações estão das previsões, em um momento anterior à obtenção das análises. Normalmente, um pequeno incremento do OMF indica uma previsão de alta qualidade e representa uma estimativa primária da assimilação, enquanto que a estatística observação menos análise (OMA) mostra as alterações na previsão do modelo derivadas dos algoritmos de assimilação de dados, em um momento posterior à obtenção das análises.

Nesse sentido, o BIAS e o RMSE foram utilizados para averiguar a qualidade das análises obtidas pelo sistema de assimilação de dados (3DVar e 3DEnVar). O BIAS indica como as variáveis de análise (\mathbf{x}_i) estão relacionadas com as medidas obtidas pelas observações (\mathbf{y}_o). Valores negativos de BIAS indicam que, em média, as variáveis da análise subestimam a medida obtida pelas observações, e para valores positivos significa que ocorreu uma superestimação (Equação 2.17).


$$BIAS = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \mathbf{y}_o) \quad (2.17)$$

A raiz do erro quadrático médio (RMSE, do inglês), Equação 2.18, é uma estimativa do desvio padrão dos dados, assim, quanto mais distantes de zero forem os valores do RMSE, maior será magnitude do erros. Observe que diferentemente do BIAS, que indica a direção dos erros das estimativas, o RMSE ilustra a magnitude associada às imprecisões das estimativas .

$$RMSE = \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \mathbf{y}_o)^2\right)} \quad (2.18)$$

Para avaliar a performance do modelo WRF na detecção de eventos de chuva associados aos SCM foram utilizados diferentes índices estatísticos da tabela de contingência, considerando o limiar igual/superior a 5 mm. Assim, os acumulados de chuva diários simulados pelo modelo WRF, referente ao acumulado de chuva em 24 horas foram comparados com observações registradas por estações meteorológicas em superfície do INMET, situadas sobre o estado do Maranhão (vide Apêndice D.1), local de estabelecimento do SCM e onde ocorreu os episódios de chuvas intensas nos dias 14 e 24 de janeiro de 2017. Para ambos os experimentos aqui desempenhados foram utilizados 10 pontos de grade posicionados sobre o NEB, coincidentes com a latitude e longitude das estações meteorológicas do INMET sobre o Maranhão, conforme ilustrado pela Figura 2.9.

Figura 2.9 - Localização das estações meteorológicas com dados de acumulado de chuva em 24 horas sobre MA.



Fonte: Produção do autor.

A probabilidade de detecção, falsos alarmes, erros e acertos do modelo foi quantificado através do cálculo do FAR (falsos alarmes) e POD (probabilidade de detecção) da tabela de contingência (PAZ; COLLISCHONN, 2011), descritos respectivamente pelas Equações 2.19 e 2.20. O FAR e a POD varia de 0 a 1, porém no FAR quanto menor o valor, melhor será a performance, já para a POD quanto maior o valor, melhor será a performance.

$$FAR = \frac{\text{alarme falso}}{\text{alarme falso} + \text{acertos}} \quad (2.19)$$

$$POD = \frac{\text{acertos}}{\text{acertos} + \text{erros}} \quad (2.20)$$

Uma outra forma de avaliar a performance de uma determinada estimativa, é feita utilizando a Taxa de Sucesso (TS), obtida pela razão do número de acertos pela quantidade total acertos e falsos alarmes, conforme apresentado na Equação 2.21. Assim, para valores próximo a 1, significa que a estimativa produzida é bastante acurada.

$$TS = \frac{\text{acertos}}{\text{acertos} + \text{alarme falso}} \quad (2.21)$$

O BIAS de frequência (Equação 2.22) mostra a relação entre o número de eventos estimados com o número de eventos observados. O resultado de seu cálculo retornará valores maiores que 0, dessa forma quanto mais próximo de 1, melhor será a performance, porém valores superiores ou inferiores a 1, indicam que a ocorrência de eventos foram, respectivamente, superestimados e subestimados.

$$BF = \frac{\text{alarme falso} + \text{acertos}}{\text{acertos} + \text{erros}} \quad (2.22)$$

O CSI (índice crítico de sucesso) também foi calculado (Equação 2.23) para a avaliação da performance das estimativas dos acumulados de chuva obtidos por diferentes fontes de dados. Através do CSI, é possível observar o percentual de acertos, descontando a quantidade vezes que a não ocorrência de eventos foi corretamente prevista. Valores próximos a 1 indicam boas performances.

$$CSI = \frac{\text{acertos}}{\text{alarme falso} + \text{acertos} + \text{erros}} \quad (2.23)$$

3 RESULTADOS

Nos subtópicos desta seção são apresentados os resultados das análises do 3DVar, EnKF, 3DEnVar e das previsões de campos meteorológicos obtidas do modelo WRF, com o objetivo de avaliar a situação sinótica associada aos eventos de SCM, ocorridos nos dias 14 e 24 de janeiro de 2017, assim como a performance do modelo WRF ao ser inicializado com condições iniciais provenientes de diferentes sistemas de assimilação de dados do GSI. O horário sinótico das 00 UTC, algumas horas antes do início do SCM, é usado como referência para avaliação das análises.

Para observar o comportamento dos diferentes métodos de assimilação de dados aqui investigados, foram elaborados gráficos das curvas resultantes do cálculo da função custo e de seu gradiente, diagramas *heatmap* para observar o desempenho dos sistemas de assimilação de dados em diferentes níveis verticais, conforme os resultados retornados pelas estatísticas do BIAS e RMSE. Por último, são apresentadas uma avaliação qualitativa e quantitativa dos acumulados de chuva em 24 horas obtidas do modelo WRF, inicializado 24, 48 e 72 horas antes datas de registro dos SCM, sobre o NEB.

3.1 Teste com uma única observação sintética

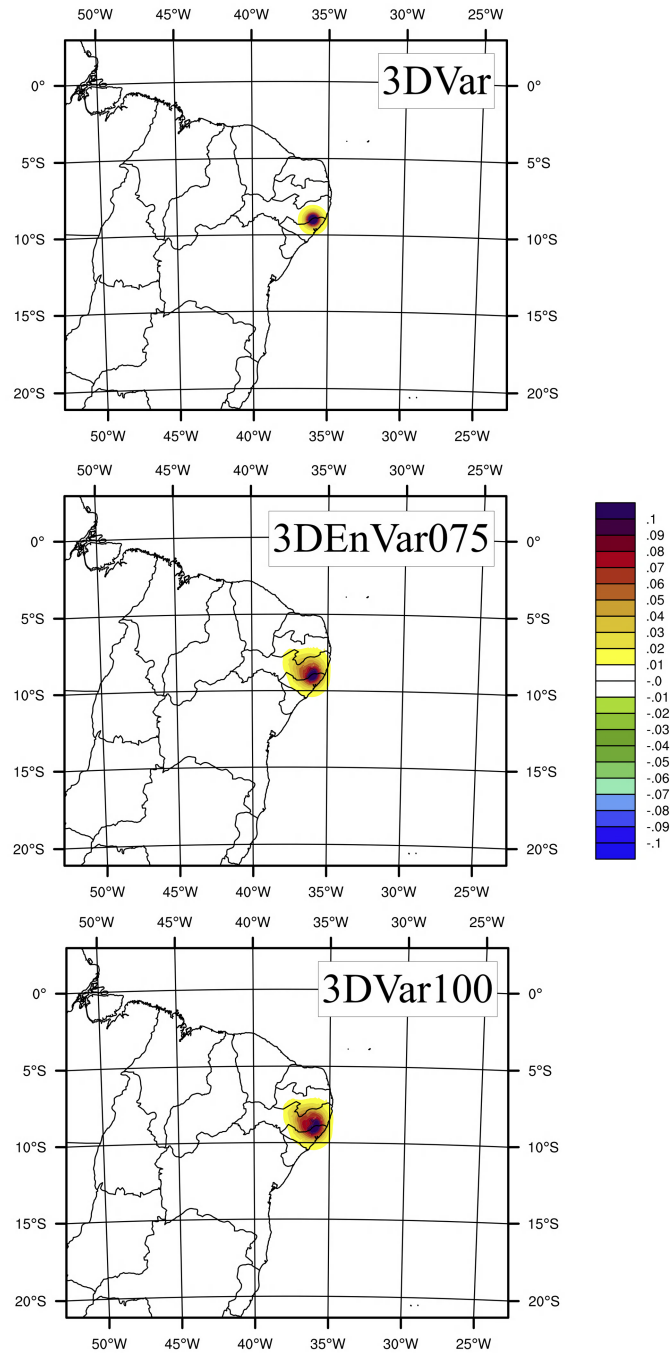
Para verificar o funcionamento do sistema híbrido 3DEnVar foi realizado um teste com uma única observação sintética da temperatura, com inovação igual a 1 K e erro observacional igual a 0,8 K, posicionada em um ponto de grade nas coordenadas geográficas de 9°S e 36°W, sobre NEB. O nível vertical escolhido foi o de 1000 hPa, próximo a superfície.

O teste com uma única observação sintética foi executado com o membro controle do GEFS obtido para um dia de atuação de SCM sobre o NEB, ocorrido em 14 de janeiro de 2017 (experimento SCM1). O objetivo deste teste foi verificar o impacto da matriz de covariância híbrida, utilizada para a geração das análises do 3DEnVar, na distribuição horizontal e vertical dos incrementos de análise, quando comparada com a matriz estática do 3DVar.

A Figura 3.1 ilustra as seções horizontais através do ponto de máximo incremento de análise, utilizando o 3DVar com filtro recursivo isotrópico e o sistema híbrido com pesos atribuídos à matriz de covariância do EnKF equivalentes 0,75 e 1 (experimentos respectivamente intitulados de 3DEnVar075 e 3DEnVar100) configurados com o filtro recursivo anisotrópico. Os demais pesos da combinação linear do sistema

híbrido foram atribuídos à matriz estática do 3DVar, segundo a Equação 2.16.

Figura 3.1 - Incremento de análise da temperatura do ar em baixos níveis (1000 hPa) para o dia 14 de janeiro de 2017, às 00 UTC, sobre o plano horizontal.



A seção horizontal mostra o incremento de análise de temperatura do ar ao assimilar uma observação sintética com o 3DVar e o 3DVar configurado com os pesos de 0,75 (3DVar075) e 1 (3DVar100) para a matriz de covariâncias dos erros de previsão obtida do EnKF.

Fonte: Produção do autor.

Analisando a Figura 3.1 para o experimento 3DVar, nota-se que o incremento de análise é espalhado de forma igual em todas as direções, o que demonstra ser um resultado consistente, pois na execução deste teste, configurou-se o GSI para que os erros de previsão possuísem espalhamento isotrópico.

O GSI pode ser configurado com os filtros recursivos isotrópico e anisotrópico, responsáveis por determinar a forma como os incrementos de análise podem ser ajustados aos gradientes representados no campo do *background*. Ao ativar o filtro recursivo anisotrópico no GSI, portanto, a matriz de covariância é ajustada com base na tendência temporal impressa nos campos de *background* utilizados para o cálculo da análise, o que representa uma vantagem para o 3DVar.

Um outro fato interessante, que pode ser constatado na Figura 3.1, é que as diferenças entre a análise e o *background* são inversamente proporcionais à distância. Isto significa que quando os pontos de grade e da observação coincidem, os termos que ponderam o erros observacionais tendem a 1 (ponto de máximo incremento de análise). Por outro lado, quando a distância entre os pontos da observação e da grade do modelo aumentam, este termo que pondera os erros observacionais tende a zero, de tal forma que as análises geradas na grade modelo são muito similares as do *background* (BERGTHÓRSSON; DOOS, 1955).


A forma como os incrementos de análise estão distribuídos no 3DEnVar, dependem também dos comprimentos de escala horizontal e vertical, parâmetros utilizados para localizar a covariância dos erros de previsão, configurados no presente trabalho, respectivamente, com os valores de 110 km e 3 unidades de grade na vertical, a mesma empregada no sistema de assimilação de dados regional *Rapid Refresh* (RAP) do *National Centers for Environmental Prediction* (NCEP) (HU et al., 2017).

Uma comparação entre os experimentos 3DVar e 3DEnVar100 (Figura 3.1) permite observar as diferenças entre as análises geradas com o GSI tendo diferentes configurações. Observe que existem distinções na forma como o incremento de análise está distribuído horizontalmente no domínio sobre NEB. De forma geral, a análise do 3DEnVAR100 produziu incrementos de análise para temperatura mais espalhados, abrangendo mais pontos de grade, quando comparado com o 3DVar.

Confrontando os incrementos de análise dos experimentos com uma única observação sintética na horizontal (Figura 3.1) e na vertical (Figura 3.2), é possível inferir que apesar da distribuição horizontal dos incrementos de análise ter sido mais espalhados para o 3DEnVar100 e 3DEnVar075 se comparado ao 3DVar (Figura 3.1), na vertical,

o 3DVar fornece incrementos de análise que se estendem para outros níveis, atingindo o topo da troposfera, se comparado aos experimentos 3DEnVar075 e 3DEnVar100, conforme ilustrado pela Figura 3.2.

Figura 3.2 - Incremento de análise da temperatura para o dia 14 de janeiro de 2017, às 00 UTC, sobre o plano vertical ao longo de 9°S.



A seção vertical mostra o incremento de análise de temperatura do ar ao assimilar uma observação sintética com o 3DVar e 3DEnVar configurado com os pesos de 0,75 (3DEnVar075) e 1 (3DEnVar100) para a matriz de covariâncias dos erros de previsão obtida do EnKF.

Fonte: Produção do autor.

Na vertical, o incremento de análise foi mais difuso para o experimento 3DVar da Figura 3.2. Nesse caso específico, essa constatação pode denotar uma inconsistência no procedimento de geração das análises pelo método variacional utilizando a matriz estática do 3DVar para o experimento SCM1, uma vez que para aquela região não existia observações a serem assimiladas, e conseqüentemente, as análises geradas para aquele nível pode apresentar uma temperatura não representativa do estado real da atmosfera, erro este, minimizado ao utilizar a matriz de covariância híbrida do 3DEnVar.

Em resumo, o experimento 3DEnVar075 produziu os melhores resultados. Esta configuração agrega as características dos sistemas por conjunto e variacional, ao obter uma análise através da combinação linear das suas matrizes. Além disso, seus incrementos de análise foram mais espalhados e, conseqüentemente, mais balanceados entre os erros da previsão e das observações sobre os planos horizontal e vertical, para o domínio projetado sobre o NEB.

3.2 Determinação do peso da matriz de covariâncias do EnKF

Para definir o peso da matriz de covariância do EnKF foram utilizadas, como referências, as datas dos eventos de SCM ocorridos nos dias 14 e 24 de janeiro de 2017. No experimento SCM1, foi adotado o dia 14 de janeiro de 2017, às 00 UTC, como referência e, para o experimento 2 (SCM2), o dia 24 de janeiro de 2017, às 00UTC. Esse procedimento de verificação foi feito dada a necessidade de determinar o peso da matriz de covariâncias do EnKF para obtenção da matriz híbrida do 3DEnVar.

Um valor conveniente a ser atribuído à matriz de covariância dos erros de previsão do EnKF é o peso correspondente à 0,75, resultado similar ao apresentado por [Hu et al. \(2017\)](#). Isso ocorre devido a capacidade do 3DEnVar retornar nesta configuração melhores análises principalmente para os campos de pressão superficial e umidade, pelo procedimento de minimização da função custo variacional, tendo como matriz de covariância dos erros de previsão uma matriz híbrida, resultante da combinação linear da matriz estática do 3DVar com a matriz de covariância dos erros de previsão do EnKF.

Analisando o BIAS e o RMSE para os dados de pressão superficial, temperatura, umidade e vento (3.1), o 3DVar gerou melhores análises do ponto de vista estatístico para as variáveis de temperatura e vento, se comparado com o BIAS e o RMSE obtidos para as mesmas variáveis pelo 3DEnVar configurado com a matriz de covariância dos erros de previsão do EnKF equivalentes a 0,5, 0,75 e 1 (experimen-

tos 3DEnVar050, 3DEnVar075 e 3DEnVar100, respectivamente). Por outro lado, as análises do sistema híbrido representaram melhor os dados de pressão superficial e umidade para ambas as datas de referência (14 e 24 de janeiro de 2017).

Tabela 3.1 - Desempenho dos sistemas variacionais para os dias 14 e 24 de janeiro de 2017, em negrito, as performances mais próximas de zero.

<i>Variável</i>	<i>Sistema</i>	14/01/2017		24/01/2017	
		<i>BIAS</i>	<i>RMSE</i>	<i>BIAS</i>	<i>RMSE</i>
Pressão Superficial (hPa)	3DVar	-0,20	1,06	-0,15	1,03
	3DEnVar100	-0,14	0,96	-0,11	0,90
	3DEnVar075	-0,14	0,97	-0,10	0,94
	3DEnVar050	-0,16	1,00	-0,11	0,97
Temperatura (K)	3DVar	0,16	1,54	0,21	1,32
	3DEnVar100	0,23	1,82	0,28	1,56
	3DEnVar075	0,20	1,69	0,26	1,45
	3DEnVar050	0,18	1,62	0,24	1,39
Velocidade do Vento (m/s)	3DVar	0,48	3,10	0,55	2,85
	3DEnVar100	0,53	3,18	0,85	3,32
	3DEnVar075	0,56	3,27	0,64	2,98
	3DEnVar050	0,73	3,59	0,60	2,91
Umidade (%)	3DVar	-2,08	12,75	-2,05	14,92
	3DEnVar100	-1,86	12,76	-1,65	15,63
	3DEnVar075	-1,94	12,67	-1,82	15,35
	3DEnVar050	-1,96	12,63	-1,91	15,17

Fonte: Produção do autor.

Observe pela Tabela 3.1, que a performance do 3DVar para as análises de temperatura nos dias 14 e 24 de janeiro de 2017 foram melhores (ou seja, BIAS e RMSE mais próximos de zero) que as do 3DEnVar, ao retornar valores após o cálculo do BIAS superestimados em 0,16 e 0,21 K e a raiz do erro quadrático médio equivalente

a 1,54 e 1,32 K. Essa melhor performance do 3DVar se comparado ao 3DEnVar, é justificada pelo fato da matriz do sistema híbrido gerar melhores análises de temperatura ao utilizar a matriz de covariância dos erros de previsão climatológica. De forma similar, a velocidade do vento no 3DVar também teve um desempenho melhor ao retornar valores de 0,48 e 0,55 m/s para o BIAS, novamente superestimando os valores observados, enquanto o RMSE com desvios mínimos equivalentes a 3,10 e 2,85 m/s referentes respectivamente aos dias 14 e 24 de janeiro de 2017.

Comparando os experimentos 3DEnVar100, 3DEnVar075 e 3DEnVar050, conforme a Tabela 3.1, estes tiveram um melhor desempenho na representação das variáveis de pressão superficial e umidade quando comparados com o 3DVar utilizando as mesmas datas de referência. Nota-se também uma melhor performance para pressão superficial obtida pelo experimento 3DEnVar100, seguido dos experimentos 3DEnVar075 e 3DEnVar050, na ordem do melhor ao pior desempenho ao analisar o BIAS e o RMSE, quando comparado com o 3DVar.

Os melhores valores apresentados pelo BIAS e RMSE para os dados pressão superficial foram respectivamente de -0,14 e 0,96 hPa para o dia 14 de janeiro de 2017, assim como de -0,11 hPa e 0,90 hPa para o dia 24 de janeiro de 2017, referentes ao experimento 3DEnVar100. Para os melhores valores obtidos pela pressão superficial referente ao BIAS, calculado para os dias 14 e 24 de janeiro de 2017, os valores subestimaram as observações, enquanto que os menores desvios das análises com relação a observação são demonstrados pelo RMSE do experimento 3DEnVar100 para ambas as datas de referência (14 e 24 de janeiro de 2017).

O sistema híbrido também teve um desempenho melhor que o 3DVar para as análises dos campos de umidade, ao utilizar uma matriz híbrida obtida por meio da combinação linear da matriz climatológica do 3DVar com a matriz atualizada pelo EnKF. Porém, o BIAS apontou menores desvios médios das observações com relação às análises com os resultados obtidos com a configuração 3DEnVar100, ao apresentar valores que subestimaram a umidade relativa em -1,86 e -1,65%, respectivamente, para os dias 14 e 24 de janeiro de 2017; enquanto que o RMSE, demonstra que as melhores análises de umidade foram geradas pelo 3DEnVar050 e pelo 3DVar, cujos desvios mínimos das observações com relação as análises foram altos e equivalentes a 12,63 e 14,92%, para as respectivas datas de 14 e 24 de janeiro 2017.

Em geral, o BIAS obtido para avaliar o desempenho das análises geradas pelo sistema híbrido e variacional puro também demonstrou que ambos os sistemas subestimaram os campos de pressão superficial e umidade, conforme ilustrado na Tabela 3.1. Ape-

sar disso, observe que os piores resultados foram apresentados pelo 3DVar quando comparado com aqueles performados pelo 3DEnVar. De outro modo, o BIAS dos campos velocidade do vento e temperatura demonstrou que os sistemas de assimilação de dados avaliados superestimaram, em geral, os campos observados. Esse fato é constatado pelos valores positivos para o BIAS em todos os experimentos dos sistemas híbrido e variacional puro retratados na Tabela 3.1, com o 3DVar retornando valores mais próximos às observações que o 3DEnVar. Assim, para gerar melhores análises para os campos de velocidade do vento e temperatura do ar ao utilizar o 3DEnVar, especula-se a necessidade de um conjunto maior de membros de previsão, de tal forma que se possa representar um conjunto maior de situações da atmosfera, o que contribui para obter uma matriz de covariância dos erros de previsão híbrida que melhor represente os erros do modelo e espalhe os incrementos de análise.

Assim como verificado para o BIAS, através do RMSE nota-se que, que os campos de pressão e umidade apresentaram desvios mínimos em relação às observações para os campos de pressão e umidade atualizados pelos sistemas híbridos na maior parte dos casos. Em contrapartida, os campos de temperatura e velocidade do vento retornaram desvios médios mínimos com relação as observações ao utilizar o 3DVar, retratados na Tabela 3.1.

O 3DEnVar, conforme ilustrado pelo BIAS e o RMSE, obteve o melhor desempenho na representação da pressão superficial e umidade se comparado com o 3DVar, porém ambas as estatísticas não demonstraram qual o melhor peso a ser atribuído à matriz de covariâncias do EnKF, ou seja, peso 0,5 ou 1 para obtenção das análises dos campos de umidade.

Para justificar o uso do sistema híbrido, conforme os resultados apresentados na Tabela 3.1, é conveniente atribuir à matriz de covariâncias do EnKF, o peso de 0,75, que complementa a matriz climatológica do 3DVar na combinação linear, ao ser configurada, esta última, com um peso equivalente a 0,25. Assim, a matriz híbrida, com os pesos definidos nesta seção, serão empregados dada a capacidade desta matriz em agregar as vantagens de ambos os sistemas e produzir melhores análises do ponto de vista estatístico.

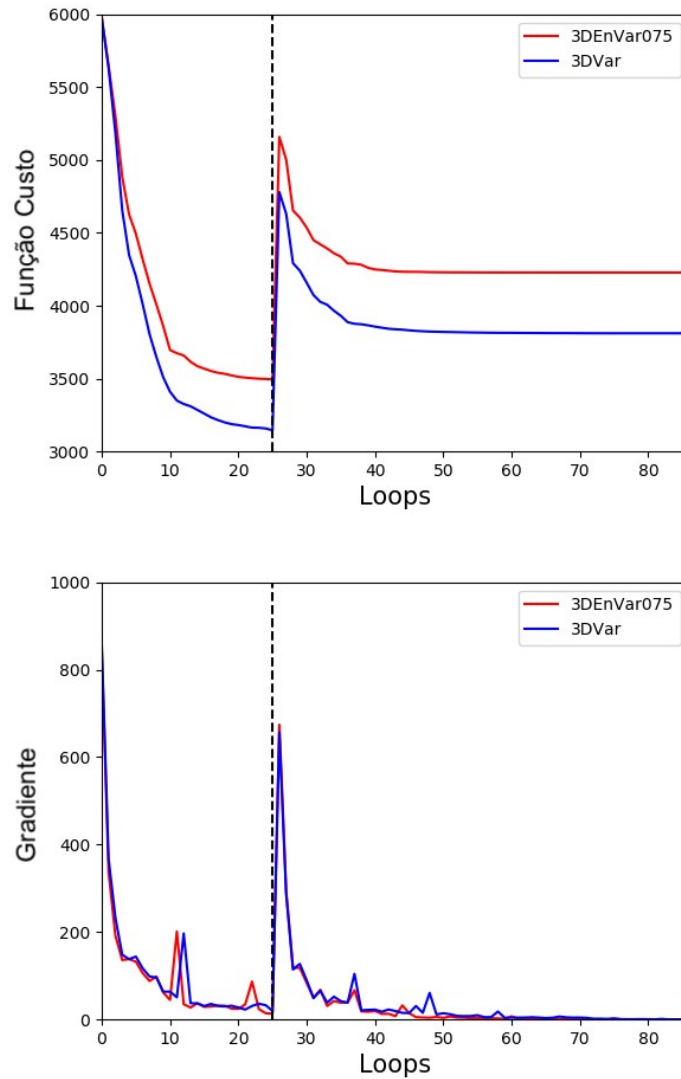
3.3 Função custo

As análises do método variacional aqui empregado, foram determinadas ao usar uma quantidade de iterações externas (*outer loops*) e internas (*inner loops*) tanto para o 3DVar quanto para o 3DEnVar, que garantiu a convergência da função custo, em

um menor intervalo de tempo. No método de assimilação de dados variacional as iterações internas são o resultado de relações lineares com o emprego do operador observação linear (\mathbf{H}), enquanto que nas iterações externas é onde são tratadas as relações não lineares entre observações não convencionais e o campo de previsão através da aplicação do operador observação não linear (H).

A minimização das funções custo do 3DVar e do 3DEnVar, foram configuradas com 25 iterações internas para a primeira iteração externa e 60 iterações internas para a segunda iteração externa. Note que esses valores foram convenientes para as observações aqui assimiladas e seguem a mesma configuração já em uso no SMR. Os valores obtidos através do cálculo da função custo e seu gradiente através do 3DVar e 3DEnVar são apresentadas na Figura 3.3 para o dia 12 de janeiro de 2017, às 00 UTC, horário de início do primeiro ciclo de assimilação de dados referente ao experimento SCM1.

Figura 3.3 - Curva da função custo e do seu gradiente para o dia 12 de janeiro de 2017, às 00 UTC.



Fonte: Produção do autor.

Observe pelos gráficos da Figura 3.3 que o GSI ao final de cada iteração externa demonstra um bom condicionamento dos sistemas variacionais em uso nos experimentos.

3.4 Avaliação do BIAS e RMSE para o 3DVar e 3DEnVar nos experimentos

Para compreender os ganhos obtidos ao empregar um sistema de assimilação de dados híbrido na atualização das análises ao longo dos ciclos de assimilação, foram avaliados o BIAS e RMSE para os campos de pressão, temperatura, velocidade do vento e umidade relativa nas análises do 3DVar e 3DEnVar, válidos para todos os níveis de pressão entre 1000-0 hPa, obtidos pela média do conjunto de dados. A Tabela 3.4 ilustra o BIAS e o RMSE para os dias 12, 13 e 14 de janeiro de 2017, às 00 UTC, referente ao Sistema Convectivo de Mesoescala do experimento SCM1 e para os dias 22, 23 e 24 de janeiro de 2017, às 00 UTC, referente ao experimento SCM2. Apenas as análises do horário sinótico das 00 UTC foi utilizada, pois elas serviram como condição inicial para as previsões de 72, 48 e 24 horas, essenciais para avaliação dos sistemas sinóticos e previsão dos acumulados de chuva.

Tabela 3.2 - Tabela de desempenho do 3DVar e 3DEnVar configurado com o peso de 0,75 para a matriz do EnKF em diferentes ciclos de assimilação de dados referente as variáveis de pressão superficial (P, hPa), temperatura (T, K), vento zonal e meridional (UV, m/s) e umidade relativa (RH, %), válida para todos os níveis de pressão entre 1000-0 hPa).

<i>Data</i>	<i>Sistema</i>	<i>P</i>			<i>T</i>			<i>UV</i>			<i>Q</i>
		<i>BIAS</i>	<i>RMSE</i>	<i>BIAS</i>	<i>RMSE</i>	<i>BIAS</i>	<i>RMSE</i>	<i>BIAS</i>	<i>RMSE</i>	<i>BIAS</i>	<i>RMSE</i>
12/01/2017 00UTC	3DVar	-0,19	0,97	0,30	1,42	0,49	3,30	-1,92	14,09		
	3DEnVar075	-0,14	0,91	0,39	1,57	0,56	3,41	-1,28	13,43		
13/01/2017 00UTC	3DVar	0,02	1,07	0,40	1,67	0,50	3,36	-1,93	14,11		
	3DEnVar075	-0,01	1,06	0,54	1,81	0,60	3,59	-2,63	15,41		
14/01/2017 00UTC	3DVar	-0,05	1,16	0,19	1,77	0,59	3,78	-3,01	15,56		
	3DEnVar075	-0,10	1,17	0,37	2,19	1,09	4,42	-3,23	15,50		
22/01/2017 00UTC	3DVar	-0,20	0,87	0,34	1,44	0,70	3,05	-1,42	15,31		
	3DEnVar075	-0,17	0,84	0,41	1,59	0,78	3,23	-0,73	14,30		
23/01/2017 00UTC	3DVar	-0,02	1,07	0,34	1,74	0,64	3,33	-2,85	16,14		
	3DEnVar075	0,03	1,02	0,58	2,18	1,00	3,45	-2,76	16,21		
24/01/2017 00UTC	3DVar	-0,20	1,12	0,35	1,67	0,81	3,72	-3,64	17,54		
	3DEnVar075	-0,20	1,11	0,41	1,62	1,25	4,61	-4,95	17,66		

Fonte: Produção do autor.

O BIAS e o RMSE mostram quanto os valores obtidos pelas análises geradas pelos diferentes sistemas de assimilação de dados contemplados na Tabela 3.4 diferem das observações. Os valores mais próximos de zero indicam as melhores performances dentre os sistemas avaliados, em oposição, os valores mais distantes de zero indicam as piores performances relativas aos experimentos. Dessa forma, dentre vários aspectos a serem discutidos analisando a Tabela 3.4, destaca-se a melhora obtida ao utilizar o sistema híbrido (3DEnVar) na geração de análises para os campos de pressão superficial e umidade para todos os níveis verticais, quando comparado com os resultados do 3DVar. Ademais, a produção de campos de umidade próximos aos valores observados, conforme retratado na Figura 3.4, quando utilizado o 3DEnVar, pode ser um elemento essencial na melhoria da representação de processos úmidos em diferentes níveis troposféricos, o que pode contribuir para melhorar a previsão dos acumulados de chuva diários associados aos SCM sobre o NEB.


Para os campos de velocidade do vento e temperatura com a assimilação de dados, o 3DVar obteve resultados mais próximos das observações quando comparado ao 3DEnVar, similar ao que foi constatado nos experimentos anteriores ao definir o melhor peso atribuído à matriz de covariâncias do EnKF. Apesar disso, não foi possível constatar deficiências no espalhamento do conjunto do 3DEnVar, ao longo dos ciclos de assimilação para as variáveis de velocidade do vento e temperatura, ou seja, um conjunto de membros de previsão com desvio padrão diferente da magnitude do espalhamento total (obtido do somatório do conjunto de membros de previsão obtidos em um etapa anterior à assimilação e das observações), o que poderia contribuir para que os erros da previsão não fossem corrigidos pelo sistema híbrido (Apêndice C.1 e C.2).

Os valores obtidos pelo cálculo do BIAS e do RMSE, pelo GSI, para as análises de temperatura geradas para o dia 24 de janeiro de 2017, às 00UTC, apontam que os sistemas 3DVar e 3DEnVar conseguiram melhorar o estado da atmosfera. A melhor análise produzida conforme os valores calculados pelo BIAS foi obtida pelo 3DVar, equivalente à 0,35 K, enquanto que o RMSE apontou o 3DEnVar como o sistema com melhor performance, apresentando um erro com magnitude de 1,62 K. Esses valores (Tabela 3.4) ilustram que o melhor resultado obtido pelas análises geradas pelo 3DVar através do cálculo do BIAS superestimou a temperatura em apenas 0,35 K, enquanto o valor do RMSE revela que o menor erro apresentado foi obtido com as análises de temperatura geradas pelo sistema híbrido. Entretanto, para os demais dias, ambas as estatísticas, BIAS e RMSE, apontaram o 3DVar como o sistema com melhor performance na atualização dos campos de temperatura, vento zonal

e meridional, justificado pelo fato da matriz climatológica do 3DVar ter sido mais eficiente na correção dos erros de previsão nos campos de temperatura e vento.

Uma comparação entre o BIAS e o RMSE, obtidos em uma etapa anterior (OMF) e posterior (OMA) à assimilação de dados, mostram que ambos os sistemas variacionais, 3DVar e 3DEnVar, conseguiram melhorar as previsões fornecidas aos algoritmos de assimilação de dados, ao obter valores para o BIAS e RMSE mais próximos das observações ao final de cada um dos 9 ciclos de assimilação. Porém, para o campo de umidade, diferente dos campos obtidos em uma etapa anterior a assimilação de dados para a pressão, temperatura e vento, observa-se pelo BIAS e o RMSE, que ao utilizar o 3DVar e 3DEnVar, seus valores apresentam maior distanciamento das observações ao longo dos nove ciclos de assimilação, conforme retratado na Figura 3.4 para o 3DEnVar, por exemplo.

Figura 3.4 - BIAS e RMSE de OMA e OMF para os campos de temperatura (T, K), vento (UV, m/s), umidade (RH, %) e pressão superficial (P, hPa) para o 3DnVar referente aos experimentos SCM1 e SCM2.

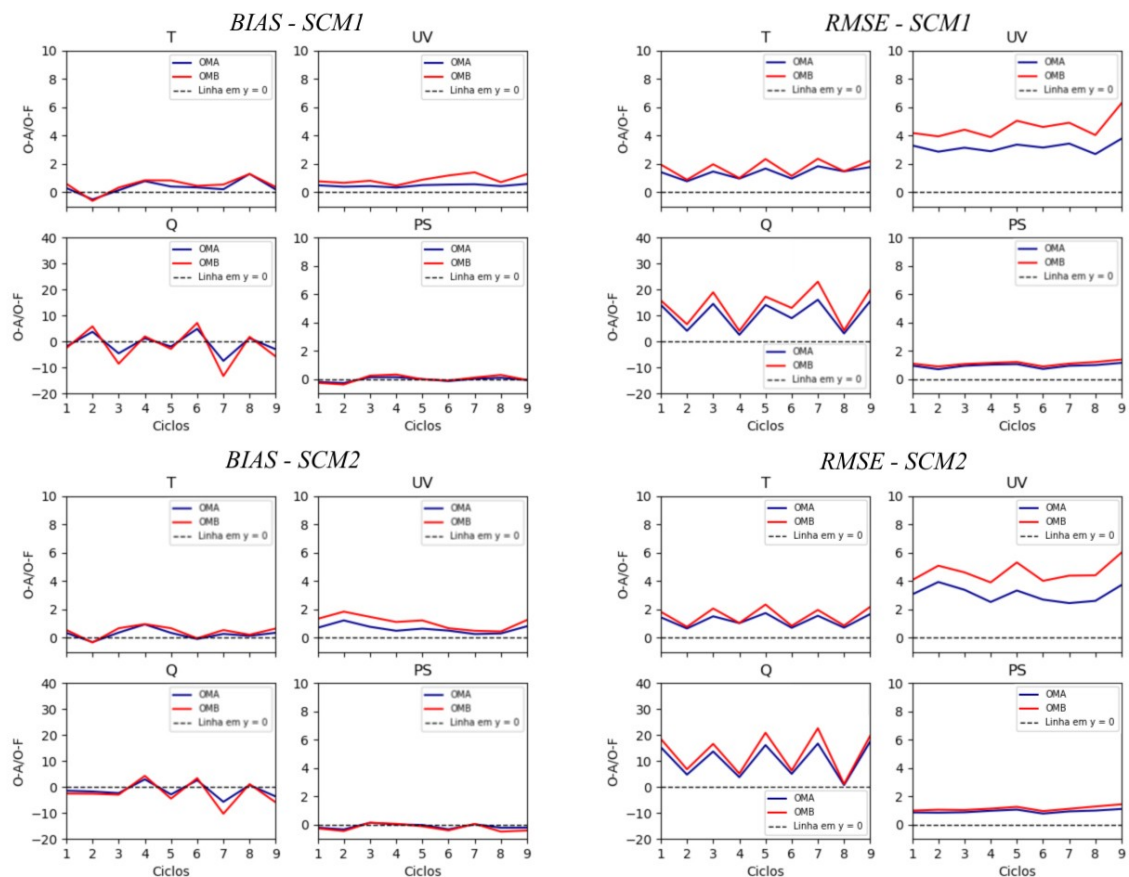


Fonte: Produção do autor.

Assim, enquanto o BIAS e o RMSE variam em uma escala entre 2 a -2 para as respectivas unidades de temperatura (k), velocidade do vento (m/s) e pressão superficial (mb) ao longo dos ciclos de assimilação, os campos de umidade relativa oscilaram em torno de 10 a -10%, conforme ilustrado nas Figuras 3.4 e 3.5. Isso demonstra que mesmo sendo utilizado os sistemas 3DVar e 3DnVar para atualização das condições iniciais fornecidas ao modelo WRF, existe uma dificuldade destes sistemas em reduzir de forma significativa os erros das previsões do modelo em um momento posterior a obtenção das análises, de forma que a diferença entre as análises e observações para os campos de umidade fiquem mais próximas a zero do que os resultados apresentados nesta seção. Essa discrepância entre os campos de umidade

das análises em relação as observações pode influenciar significativamente as previsões de chuva nas equações do modelo, já que pequenas oscilações nos campos de umidade afetam diretamente a formação de chuva nos modelos numéricos, ou seja, normalmente uma condição inicial mais mais seca (menos úmida) irá prever menos chuva para o NEB. Por outro lado, se as condições iniciais denotam uma atmosfera mais úmida, o modelo numérico poderá prever mais chuva. A dificuldade em assimilar dados de umidade por ambos os sistemas (3DVar e 3DEnVar) era esperada, consequência de uma série de fatores, dentre eles, a extensa variabilidade espaço-temporal desta variável, que em escalas espaciais menores tornam a interpolação dos dados de umidade difícil, conforme abordado por Liu e Kalnay (2005).

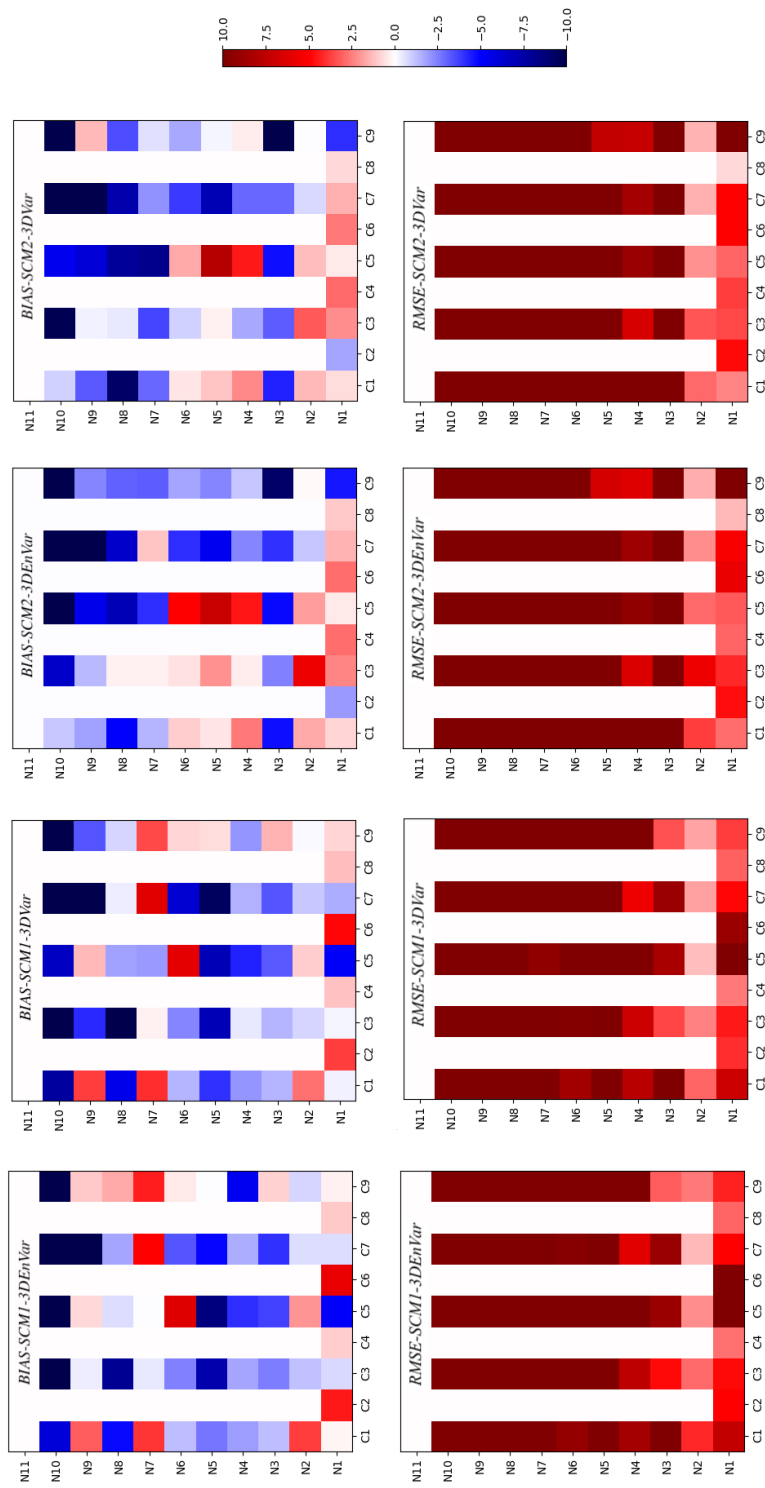
Figura 3.5 - BIAS e RMSE de OMA e OMF para os campos de temperatura (T, K), vento (UV, m/s), umidade (RH, %) e pressão superficial (P, hPa) para o 3DVar referente aos experimentos SCM1 e SCM2.



Fonte: Produção do autor.

Como complemento às Tabelas 3.4 e 3.5, foram analisados os diagramas apresentados na Figura 3.6 para o BIAS e o RMSE referente aos experimentos SCM1 e SCM2, produzidos para avaliar a performance do 3DVar e 3DEnVar, verticalmente, para os nove ciclos de assimilação de dados. Com isso, foi constatado que as maiores diferenças entre observação e análise são mostradas por essas estatísticas basicamente em todos os níveis troposféricos (1000-0 hPa) para a variável de umidade relativa, demonstrando que existe uma dificuldade de ambos os sistemas variacionais na geração de análises para os campos de umidade, principalmente para os níveis imediatamente superiores às superfícies N1 e N2, aproximadamente equivalentes a 1000 e 900 hPa, respectivamente. Essa dificuldade em gerar campos mais próximos das observações, principalmente em níveis superiores, é justificada em grande parte devido a pouca disponibilidade de dados de umidade para estas regiões.

Figura 3.6 - Diagrama ilustrando o BIAS e RMSE de OMA para os campos de unidade para o 3DVar e 3DEnVar referente aos experimentos SCM1 e SCM2.



C1 a C9 representa os 9 ciclos de assimilação de dados e os níveis (N), são as camadas N1(1200-1000 mb), N2 (1000-900 mb), N3 (900-800 mb), N4 (800-600 mb), N5 (600-400 mb), N6 (400-300 mb), N7 (300-250 mb), N8 (250-200 mb), N9 (200-150 mb), N10 (150-100 mb) e N11 (100-50 mb).

Fonte: Produção do autor.

Esta seção demonstrou que os sistemas 3DVar e 3DEnVar produziram ao longo dos ciclos de assimilação campos mais próximos das observações, quando comparados com a previsão, demonstrando a importância da assimilação na correção dos erros do modelo. Além disso, foi observado, assim como retratado em seções anteriores, que ao longo dos ciclos de assimilação de dados, o 3DEnVar conseguiu obter análises, cujos campos de pressão superficial e umidade foram mais próximos de zero, referente ao BIAS e RMSE, quando comparado ao 3DVar. Porém, apesar das melhoras obtidas ao utilizar o 3DEnVar para geração das análises de umidade, existe uma distância significativa entre observações e análises, superiores a 10%, resultado da pouca disponibilidade de dados de umidade utilizados para assimilação em diferentes níveis verticais entre 1000-0 hPa, que nos experimentos deste trabalho, foram, em geral, provenientes de estações meteorológicas de superfície e radiossondagens.


3.5 Avaliação dos incrementos de análise

A performance dos sistemas de assimilação de dados para geração de análises dos campos de temperatura, vento zonal e meridional, pressão superficial e umidade foram aqui avaliados através das diferenças entre as análises e o *background*. Uma análise comparativa entre os campos permite observar que além da vantagem de utilizar um sistema híbrido por meio da incorporação dos erros do dia, a atualização dos campos de temperatura e umidade pelo 3DEnVar produziram incrementos de análise horizontalmente mais largos se comparado com o 3DVar, tendo em vista que no 3DEnVar foi aplicado um filtro recursivo anisotrópico ao GSI. Isso contribuiu para que as análises do 3DEnVar obtenham campos com incrementos de análise ajustados aos gradientes representados no *background*, que resulta em incrementos mais espalhados sobre uma região maior ao redor da vizinhança das observações, o que pode fazer com que o 3DEnVar influencie pontos de grade mais distantes e trazer um benefício importante nos campos das condições iniciais, os erros do dia, para localidades mais distantes, o que depende da qualidade das observações e da resolução do modelo.

A Figura 3.7 revela que pelo EnKF, as análises geradas para os campos de temperatura do ar, velocidade do vento zonal, velocidade do vento meridional e umidade referente ao primeiro ciclo de assimilação do experimento SCM1, do dia 12 de janeiro de 2017, tiveram maiores incrementos de análise sobre o continente que no oceano. Os pontos de máximo incremento de análise para estes campos encontram-se distribuídos sobre diversas partes do NEB, performando valores superiores a 1, em suas respectivas unidades de medida, com exceção dos incrementos de análise

para a pressão superficial.

Figura 3.7 - Incremento de análise gerado pelo EnKF para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).

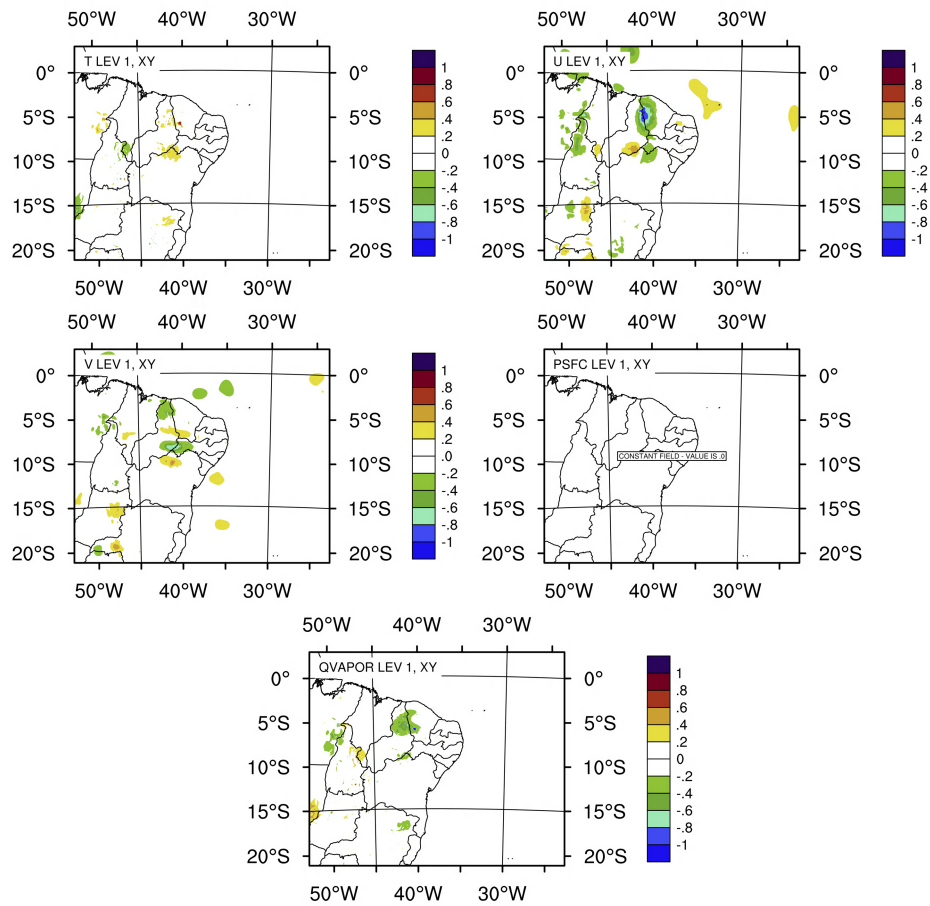


Fonte: Produção do autor.

Analogamente à Figura 3.7, o primeiro ciclo de análise do experimento SCM2 re-

ferente ao dia 22 de janeiro de 2017 (Figura 3.8) retornou maiores incrementos de análise (superiores a 1, nas respectivas unidades de medida) sobre o continente para os diferentes campos meteorológicos. Porém, observe que nesse dia os incrementos de análise foram menores que aqueles obtidos para o primeiro ciclo de análise referente ao experimento do dia 12 de janeiro de 2017, em todos os campos avaliados, exceto para os campos de pressão superficial, onde também não foi possível constatar nenhum incremento.

Figura 3.8 - Incremento de análise gerado pelo EnKF para o membro controle no dia 22 de janeiro de 2017, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).



Fonte: Produção do autor.


Em ambos os experimentos do dia 12 e 22 de janeiro de 2017 para o EnKF, ilustrados pelas Figuras 3.7 e 3.8, não foi possível observar incrementos de análise significativos para os campos de pressão superficial em nenhuma localidade do NEB. Conforme será retratado nos demais experimentos, essa não foi uma particularidade apenas do EnKF, mas também dos demais sistemas de assimilação de dados (3DVar e

3DEnVar) investigados.

O incremento de análise para o primeiro ciclo do experimento SMC1, referente ao dia 12 de janeiro de 2017 (Figura 3.9), ilustra que as análises do 3DVar foram responsáveis por gerar campos com incrementos maiores (superiores a 1 m/s), se comparados com o EnKF, para as variáveis de vento zonal e meridional, principalmente sobre o oceano.

Para as análises dos campos de temperatura e umidade geradas pelo 3DVar, os incrementos foram menores se comparados com o EnKF para diferentes localidades do NEB, um indicativo de que as análises do EnKF podem ser melhores que as do sistema variacional na representação dos processos úmidos. Nesse sentido, isso ajuda a justificar o uso do EnKF, pois, considerando um incremento de análise mais espalhado obtido ao utilizar uma matriz de covariância atualizada com os erros do dia, pode implicar em uma análise, cujos erros das previsões são melhor ponderados.

Figura 3.9 - Incremento de análise gerado pelo 3DVar para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).

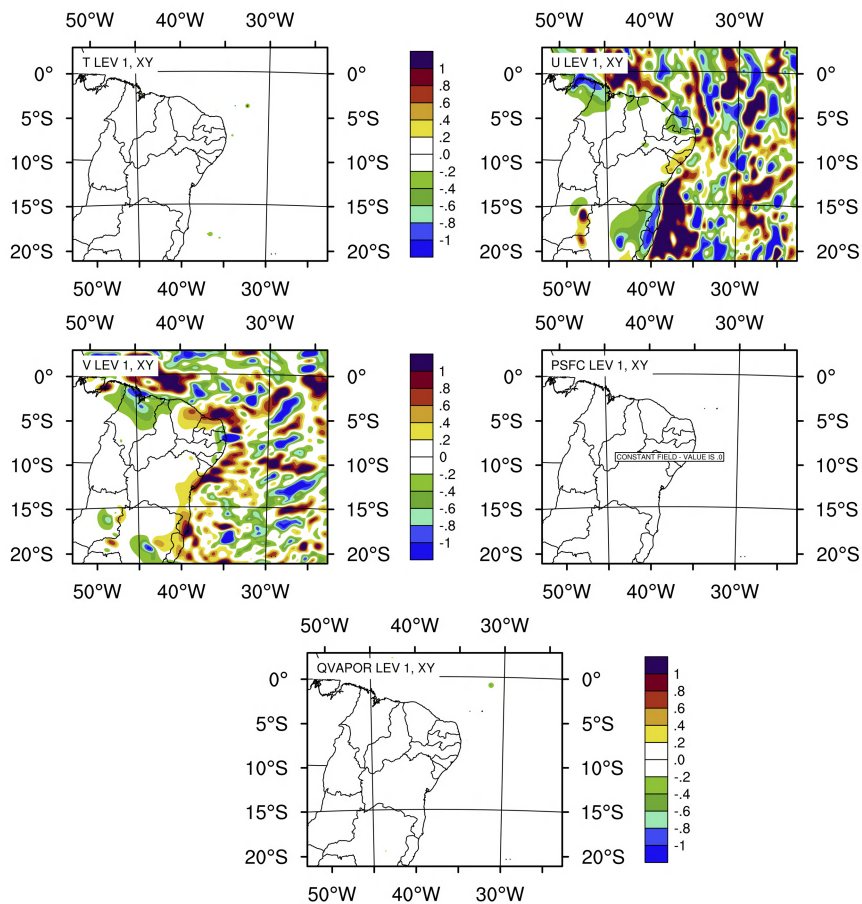


Fonte: Produção do autor.

Em 22 de janeiro de 2017 (Figura 3.10), para o primeiro ciclo do experimento SCM2, as análises do 3DVar representaram uma atmosfera com incrementos de análise muito similares ao apresentado pela Figura 3.9, ou seja, com incrementos de análise sobre o oceano superiores a 1 m/s para os campos de vento zonal e meridional,

enquanto que para as variáveis de temperatura e umidade, praticamente nenhum incremento de análise pôde ser detectado. A justificativa dessa constatação, reside no fato da quantidade de observações consideradas para assimilação de dados, para estas variáveis, ter sido menores para este dia, comparadas àquelas utilizadas pelo GSI no dia 12 de janeiro de 2017 (vide Apêndice E.1).

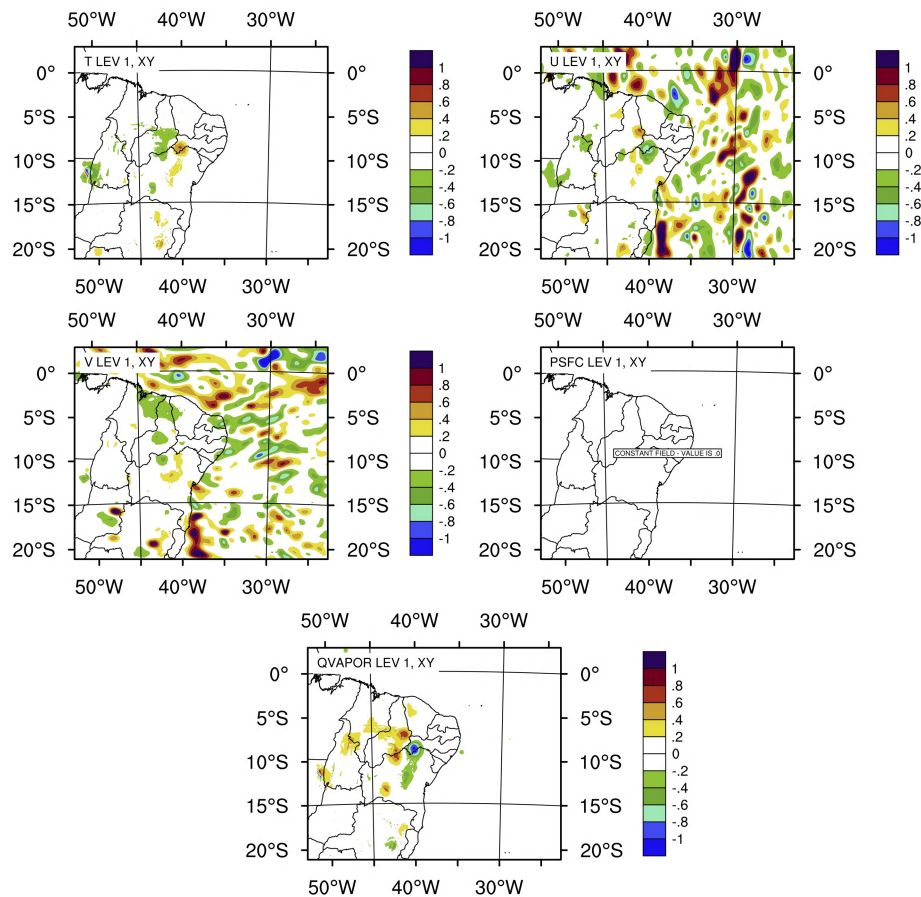
Figura 3.10 - Incremento de análise gerado pelo 3DVar para o membro controle no dia 22 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).



Fonte: Produção do autor.

A análise da Figura 3.11, apresenta as características do sistema 3DEnVar, em que foram combinadas as matrizes de covariâncias dos sistemas 3DVar e EnKF. Esse sistema, como já fora mencionado, combina as características do sistema variacional e por conjunto, de forma que a análise variacional resultante é calculada com base na matriz de covariâncias híbrida (calculada segundo a Equação 2.16).

Figura 3.11 - Incremento de análise gerado pelo 3DEnVar para o membro controle no dia 12 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão (PSFC, hPa) e umidade específica (QVAPOR, g/kg).

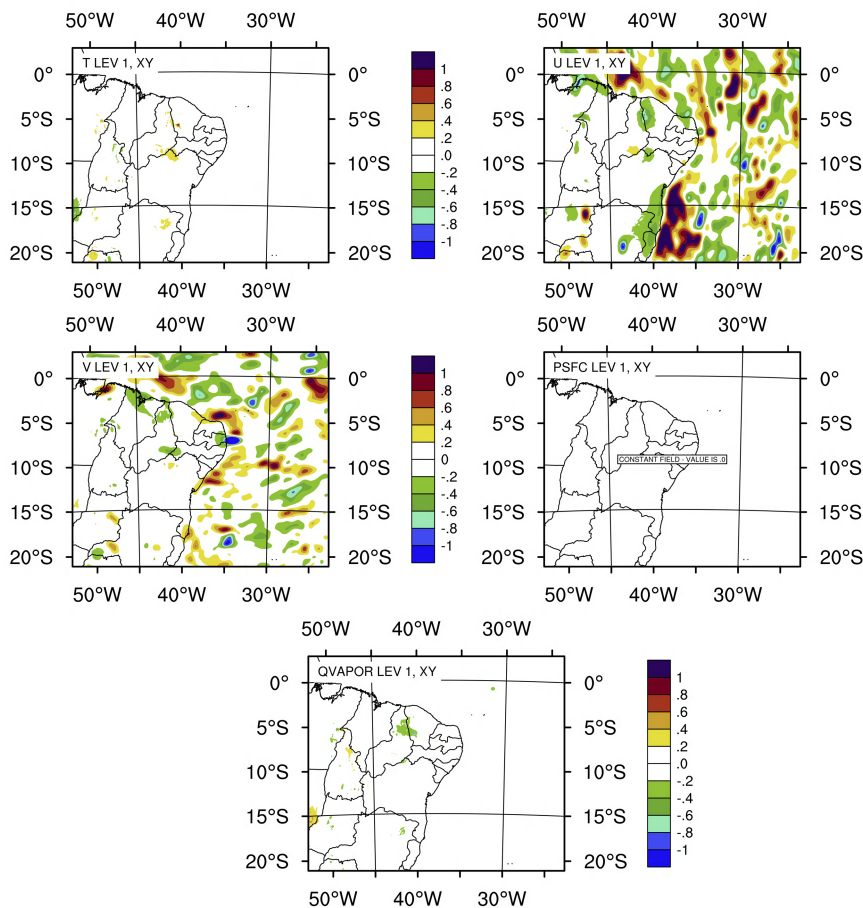


Fonte: Produção do autor.

Para o experimento do dia 12 de janeiro de 2017, referente ao primeiro ciclo de assimilação do evento SCM1 (Figura 3.11), as análises de temperatura e umidade obtidas pelo 3DEnVar apresentaram pontos com incrementos de análise em diversas regiões do NEB, assim como representado pelo EnKF, com valores superiores a 1 K e 1 g/kg, respectivamente. De outro modo, para os campos de vento zonal e meridional, o 3DEnVar conseguiu reproduzir maiores incrementos de análise (superiores a 1 m/s) sobre o oceano similar ao apresentado pelo 3DVar para os primeiros ciclos de assimilação dos experimentos SCM1 e SCM2. Esta última constatação representa uma das vantagens da utilização do 3DEnVar, tendo em vista que maiores incrementos de análise sobre o oceano para os campos de vento zonal e meridional pode contribuir para obtenção de condições iniciais com valores próximos aos observados, o que pode consequentemente minimizar eventuais erros de previsão.

Em 22 de janeiro de 2017 (Figura 3.12), campos análogos ao experimento da Figura 3.11 foram observados, porém análises de temperatura e umidade com incrementos de análise menores que 0,4 K e 0,4 g/kg, respectivamente, foram constatados. Essa era uma situação esperada, pois os incrementos de análise do EnKF também não retornaram valores expressivos, superiores respectivamente a 1 K e 1 g/kg, para a mesma data. Uma alternativa para minimizar esta situação seria aumentar o número de membros fornecidos ao sistema, de tal forma que um maior conjunto de situações atmosféricas pudessem ser utilizadas para representar os erros do modelo.

Figura 3.12 - Incremento de análise gerado pelo 3DEnVar para o membro controle no dia 22 de janeiro de 2017, às 00 UTC, referente ao nível sigma 1, para os campos de temperatura (T, K), velocidade do vento zonal (U, m/s), velocidade do vento meridional (V, m/s), pressão superficial (PSFC, hPa) e umidade específica (QVAPOR, g/kg).



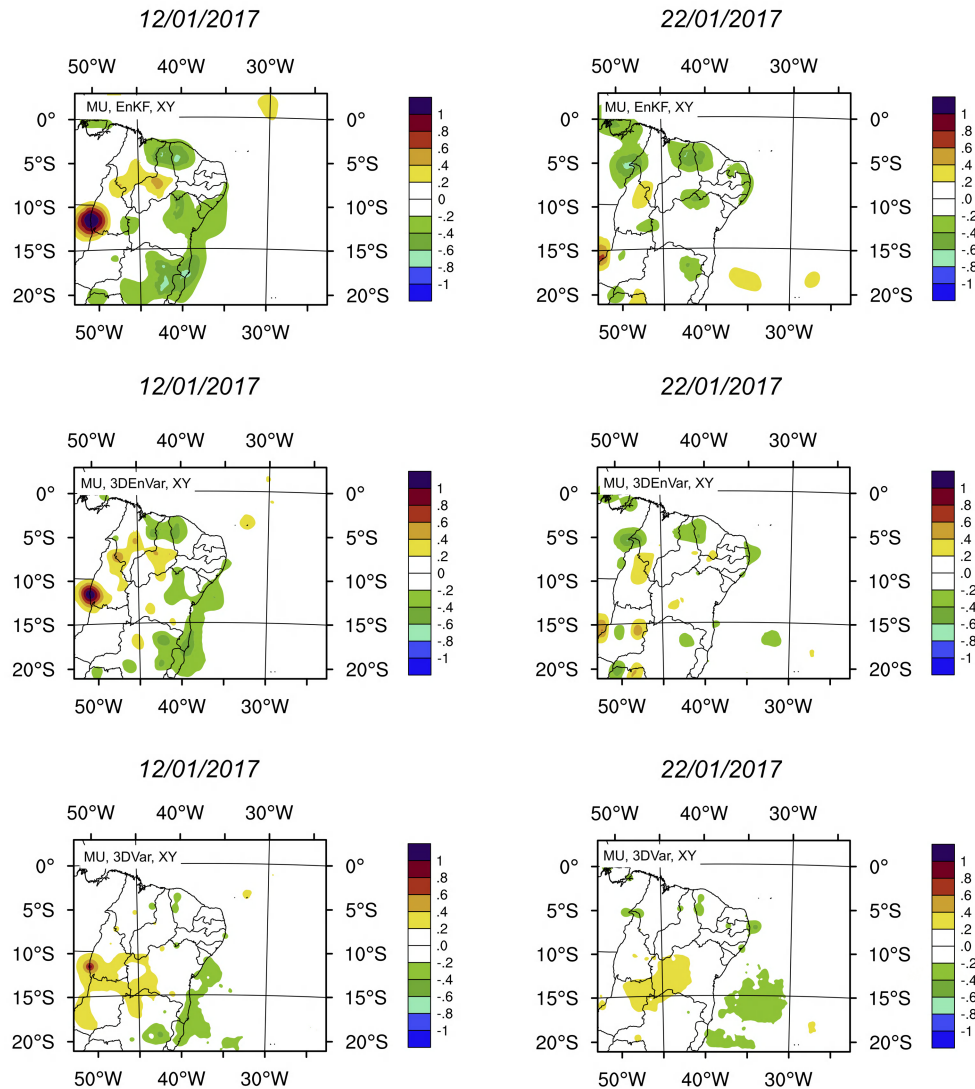
Fonte: Produção do autor.

Os incrementos de análises para os campos de pressão em superfície, obtidos pelos diferentes sistemas de assimilação de dados, foi igual a zero para os dias 12 e 22 de janeiro, apesar da disponibilidade de observações em superfície para esta variável. Conforme apresentado pelos dados do Apêndice E.1, para os dias 12 e 22 de janeiro

de 2017, os dados de pressão superficial foram assimilados pelo GSI, porém seus impactos não foram visíveis ao obter as análises. Uma justificativa para isso seria a variável pressão superficial (PSFC), do modelo WRF, não ser atualizada diretamente pelo GSI.

Nesse sentido, uma forma de avaliar se os dados de pressão superficial de fato estão sendo assimilados pelo GSI é observar os incrementos de análise para a variável MU do modelo WRF, que representa o campo de massa de ar seco na coluna (medido em hPa). No GSI, MU é atualizada utilizando dados de pressão superficial, conforme abordado por [Shao e Newman \(2019\)](#) e, na Figura 3.13, é possível verificar que os incrementos de análise para esta variável existem e são diferentes de zero.

Figura 3.13 - Incremento de análise gerado pelo EnKF, 3DVar e 3DEnVar para o membro controle nos dias 12 e 22 de janeiro de 2017, às 00 UTC, referente ao campo de massa de ar seco na coluna (hPa).



Fonte: Produção do autor.


Analisando os campos de MU provenientes das análises do 3DVar, EnKF e 3DEnVar, retratados na Figura 3.13, são verificados incrementos de análise superiores a 1 hPa sobre o continente, que são mais intensos no dia 12 de janeiro de 2017, ao utilizar o EnKF e o 3DEnVar. Para ambos os dias representados na Figura 3.13 (12 e 22 de janeiro de 2017), também foi verificado que para as áreas sobre o continente, onde a quantidade da dados de pressão superficial são maiores, os incrementos de análise

foram mais distribuídos nesta região sobre o NEB, pelo EnKF e 3DEnVar quando comparado com o 3DVar. Essa constatação pode ser atribuída ao fato de que as matrizes de covariâncias do EnKF e 3DEnVar consideram os erros do dia, sendo isso particularmente importante em termos de correção dos erros do *background* do modelo.

3.6 Análise sinótica dos SCM

Os episódios de chuvas intensas sobre o NEB, avaliados neste trabalho, ocorreram nos dias 14 e 24 de janeiro de 2017, respectivamente, nas cidades de Barra da Corda (5,51°S e 45,24°W) e Colinas (6,03°S e 44,23°W), ambas situadas na porção mais continental do estado do Maranhão, conforme ilustrado na Figura 3.14.

Figura 3.14 - Localização geográfica das estações meteorológicas no estado do Maranhão, onde foram identificados episódios de chuvas intensas.




As cidades de Barra da Corda e Colinas estão localizadas, respectivamente, nas coordenadas geográficas de 5,51°S e 45,24°W e em 6,03°S e 44,23°W.

Fonte: Produção do autor.

O evento SCM1, ocorrido em 14 de janeiro de 2017 abrangeu uma área de aproximadamente 218.000 km² durante o estágio de desenvolvimento máximo, com temperaturas no topo das nuvens inferiores a -80°C. Esse sistema (Figura 3.15a) foi responsável por causar eventos de chuvas intensas, principalmente sobre a região central do Maranhão, em torno de 6°S e 46°W, onde foi registrada precipitação acumulada em 24 horas pela estação convencional do INMET, em Barra da Corda (MA), equivalente a 72,5 mm.

Figura 3.15 - Imagem do canal infravermelho do satélite GOES ilustrando o estágio de desenvolvimento máximo do SCM sobre o NEB (a) e a chuva acumulada em 24 horas da hidroestimativa do MERGE (b) para o dia 14 de janeiro de 2017, referente ao experimento SCM1.



O círculo pontilhado em preto, nas figuras (a) e (b), representa a área de atuação do sistema convectivo de mesoescala.

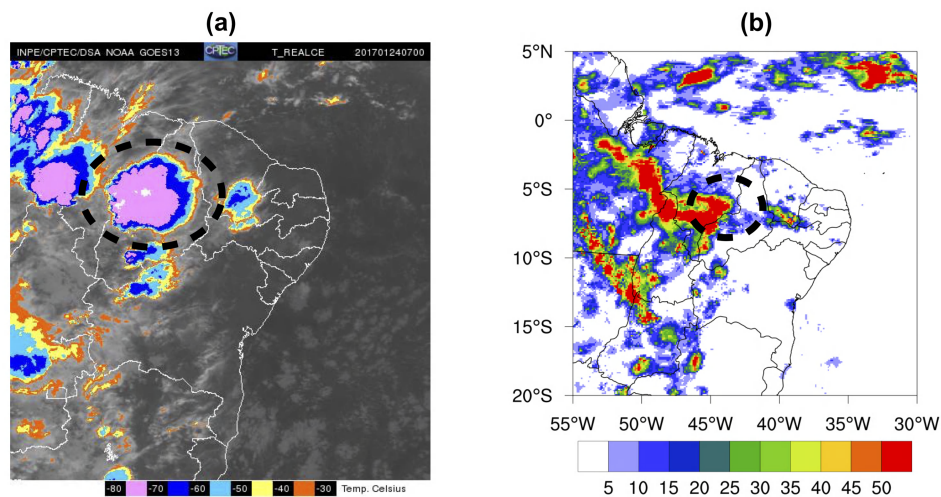
Fonte: Produção do autor.

O dados do MERGE (Figura 3.15b) foram utilizados para representar as chuvas intensas sobre o NEB. Ele é um produto operacionalmente distribuído pelo CPTEC, que combina a precipitação observada com a estimativa de precipitação por satélite (ROZANTE et al., 2010). Em virtude da descontinuidade dos dados do *TRMM Multisatellite Precipitation Analysis* (TRMM-TMPA), os produtos do MERGE vem sendo gerados utilizando os dados do *Integrated Multi-satellite Retrievals for GPM* (IMERG) e disponibilizados com resolução horizontal de 0,1°.

Através da Figura 3.15b é possível observar uma área com episódios de chuvas intensas sobre o estado do Maranhão, superiores a 50 mm. Essa região, conforme ilustrado pela Figura 3.15a, estava sob influência de um sistema convectivo, que ocasionou a chuva de forte intensidade, superior a 70 mm, reportada pela estação meteorológica em superfície do INMET, para a região de Barra da Corda (6°S e 46°W), situada na porção central do estado do Maranhão.

O evento SCM2 (Figura 3.16a), ocorrido em 24 de janeiro de 2017, abrangeu uma área menor, equivalente a 143.000 km², quando o desenvolvimento do sistema era máximo e a temperatura referente ao topo da nuvem era inferior a -80°C, sobrepondo principalmente os estados do Piauí e uma pequena porção do estado do Maranhão. Esse sistema foi responsável por provocar chuvas intensas no Município de Colinas (MA), em torno de 6°S e 44°W, com registro de precipitação acumulada em 24 horas pela estação meteorológica do INMET equivalente a 72 mm.

Figura 3.16 - Imagem do canal infravermelho do satélite GOES ilustrando o estágio de desenvolvimento máximo do SCM sobre o NEB (a) e a chuva acumulada em 24 horas da hidroestimativa do MERGE (b) para o dia 24 de janeiro de 2017, referente ao experimento SCM2.



O círculo pontilhado em preto, nas figuras (a) e (b), representa a área de atuação do sistema convectivo de mesoescala.


Fonte: Produção do autor.

Para o dia 24 de janeiro de 2017, o campo de chuva acumulada em 24 horas obtido do MERGE (Figura 3.16b), ilustra sobre o município de Colinas (6°S e 44°W) chuvas superiores a 50 mm, para a área de influência do SCM, retratado na Figura 3.16a. Dessa forma, para os dois dias com registros de chuvas intensas sobre os municípios de Barra da Corda e Colinas, no estado do Maranhão, as estimativas do MERGE indicavam um grande volume de chuva, mostrando ser um produto particularmente eficaz na caracterização da precipitação acumulada em 24 horas durante os episódios de SCM sobre o NEB ocorridos em 14 e 24 de janeiro de 2017.

A análise dos campos meteorológicos foi feita utilizando um experimento de referência, ou seja, aquele em que o membro controle do modelo GEFS é apenas pré-processado para um domínio e grade sobre o NEB e nenhuma previsão com o modelo WRF é desempenhada, conforme sintetizado na Tabela 2.1. O experimento de referência é imprescindível para comparar os dados provenientes do NCEP com os dados de previsões do modelo WRF inicializadas com o membro controle do GEFS e atualizadas pelo EnKF, 3DVar e 3DEnVar.

Para ambos os dias de atuação dos SCM, 14 e 24 de janeiro de 2017, foram plotadas seções verticais dos campos de umidade, temperatura e divergência conforme ilustrada pela Figura 3.17. Os episódios de chuvas intensas ocorridos nos municípios de Barra da Corda e Colinas, situados na porção mais interiorana do estado do Maranhão, bem como as regiões de máximo desenvolvimento vertical dos episódios de SCM encontravam-se situadas ao longo da linha traçada em preto, sobre o mapa.

Figura 3.17 - Mapa ilustrando o ângulo da seção vertical traçada sobre o Nordeste brasileiro.

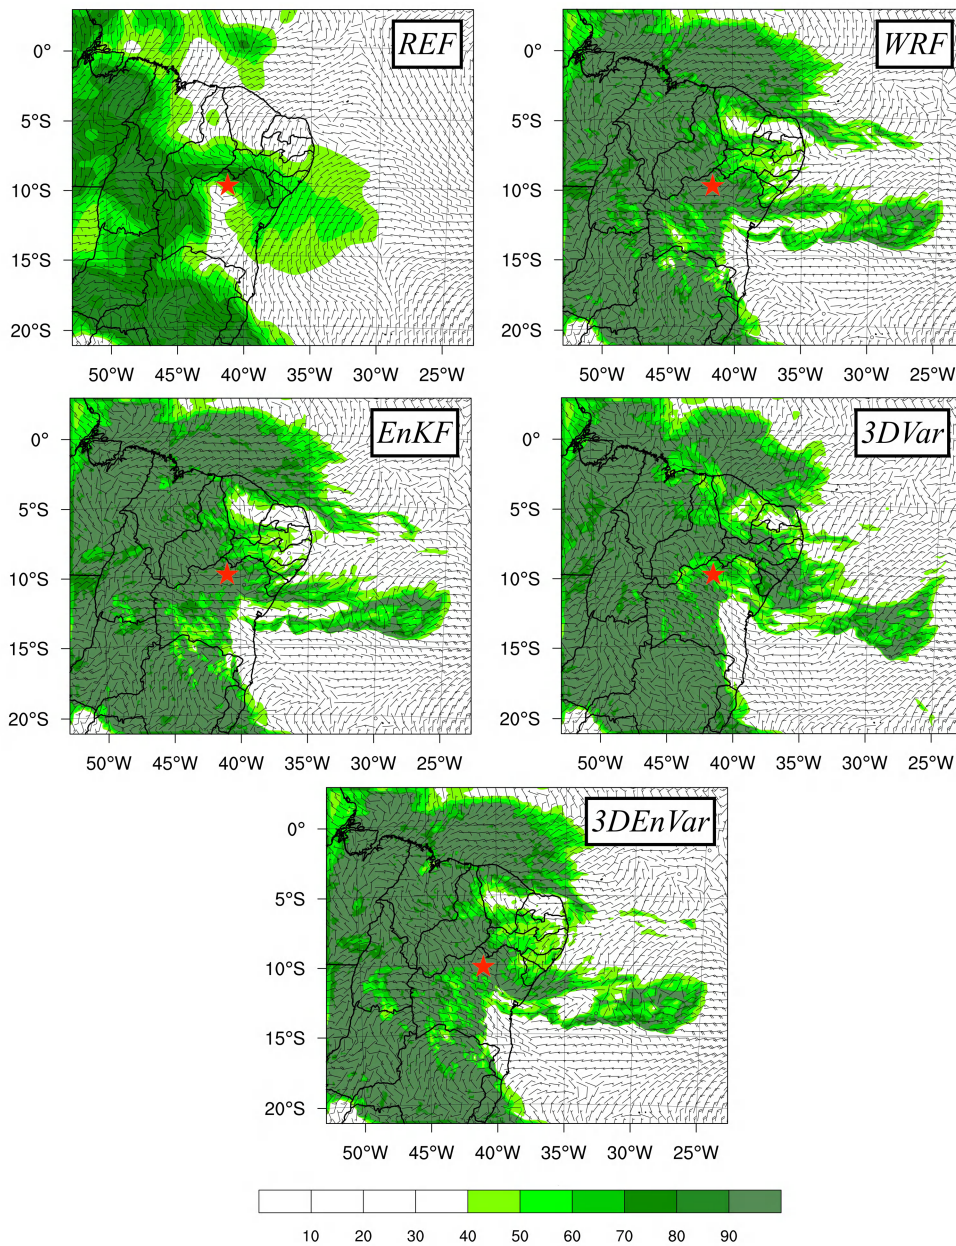


Fonte: Produção do autor.

3.6.1 Análise sinótica do dia 14 de janeiro de 2017

O SCM do dia 14 de janeiro de 2017 formou-se pela ação de um Vórtice Ciclônico de Altos Níveis (VCAN) localizado sobre o nordeste da Bahia, retratado pelo giro ciclônico representado pelas barbelas de vento do campo de referência, em torno de 10°S e 40°W da Figura 3.18. Esse VCAN, proporcionou a formação de instabilidades convectivas e eventos de chuva sobre os estados do Maranhão e Piauí. A região central do VCAN caracteriza-se por favorecer movimentos descendentes que inibem a formação de nebulosidade, enquanto que a periferia é demarcada por uma região de convergência, que traz o fluxo de umidade de baixos para altos níveis pela ação de movimentos ascendentes intensos, sendo considerado um importante mecanismo para a distribuição de chuvas sobre NEB (MORAIS; GAN, 2006).

Figura 3.18 - Análises dos campos de vento e umidade a 8 km (300 hPa) acima da superfície válidas para o dia 14 de janeiro de 2017, às 00 UTC.



As figuras representam os campos de umidade e vento em altos níveis da atmosfera (8 km) obtidos do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar. A estrela em vermelho denota a posição do VCAN.

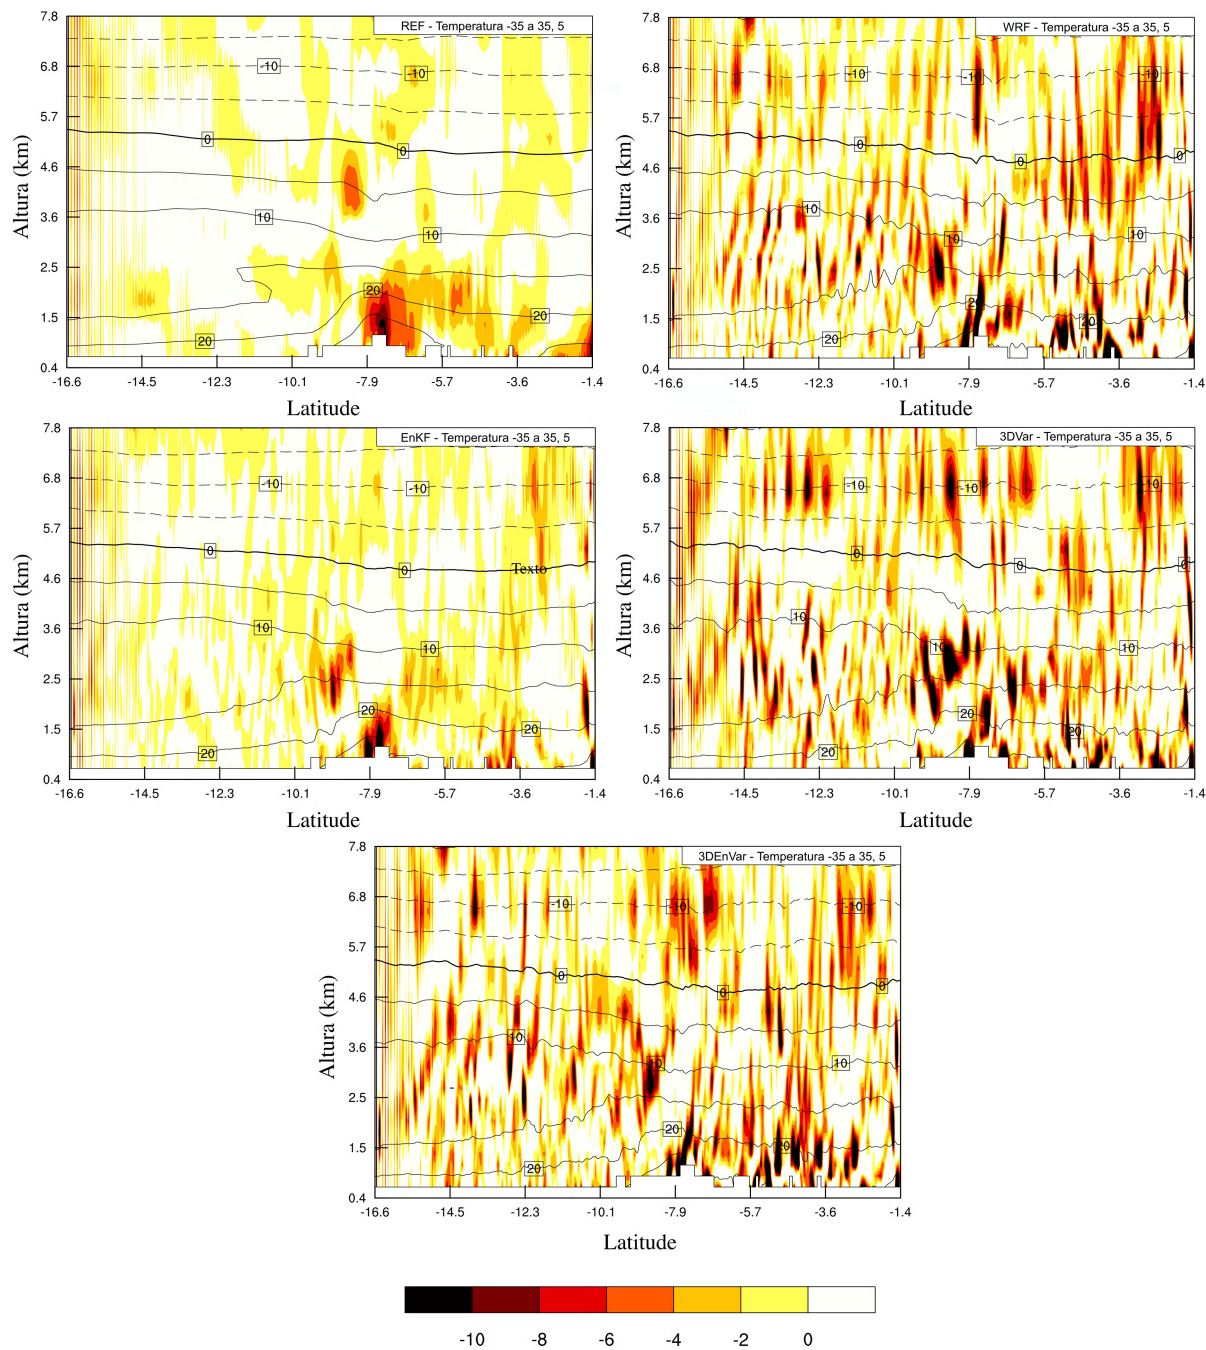
Fonte: Produção do autor.

Analisando os campos de vento da Figura 3.18, é possível notar a presença do VCAN situado sobre o nordeste da Bahia através das barbelas de vento geradas pelas análises do EnKF, 3DVar e 3DEnVar. Para as previsões feitas diretamente pela análises obtidas do modelo WRF, válidas para os mesmos dias e horários das análises geradas pelos sistemas de assimilação de dados, portanto, sem um procedimento de atualização das análises, não foi possível detectar o VCAN sobre o nordeste da Bahia. Esse fato demonstra que a assimilação de dados auxiliou na representação do VCAN ao corrigir os erros de previsão do modelo WRF em altos níveis.

A umidade representada pelas análises geradas através das previsões do modelo WRF, válida para os mesmos dias e horários das análises obtidas pelo EnKF, 3DVar e 3DEnVar reproduziram campos em altos níveis mais úmidos se comparado com o experimento de referência ilustrado na Figura 3.18. Em altos níveis (8 km), as análises obtidas pelos sistemas de assimilação de dados ao representaram uma situação atmosférica úmida (campos com umidade superior a 90%). Esse fato não foi uma característica intrínseca somente aos dados atualizados por um dos procedimentos de assimilação de dados investigados, uma vez que as previsões desempenhadas pelo modelo WRF também tiveram uma performance similar na representação da umidade em altos níveis, o que atesta o bom desempenho do modelo na representação da umidade na alta troposfera (8 km).

Os campos de divergência em baixos níveis apontam a existência de ventos convergentes em torno de 5-8°S, conforme apresentado na Figura 3.19. Para esta mesma região, observe que os campos de divergência tanto do experimento de referência (REF) como do WRF, além das seções verticais obtidas do EnKF, 3DVar e 3DEnVar apontam valores mais intensos, em baixos níveis, para a porção periférica do VCAN. Essa intensidade se torna mais evidente em baixos níveis pelos dados de previsão do modelo WRF e nas análises do EnKF, 3DVar e 3DEnVar, em torno de 3,6-7,9°S, onde são verificados valores de convergência em baixos níveis inferiores a $-10 \times 10^{-6} \text{ s}^{-1}$. Conforme mostrado pelas figuras, todos os campos plotados apontam para a presença de convergência em baixos níveis, para região onde foi detectado SCM, que combinado com a convergência de vento para os demais níveis troposféricos, influenciou a ascensão de ar quente e úmido para a região periférica do VCAN, contribuindo para formar o sistema responsável por ocorrência de chuva intensa em Barra da Corda, no Maranhão.

Figura 3.19 - Seção vertical da convergência de vento (10^{-6} s^{-1}) e temperatura para o dia 14 de janeiro de 2017, às 00 UTC.

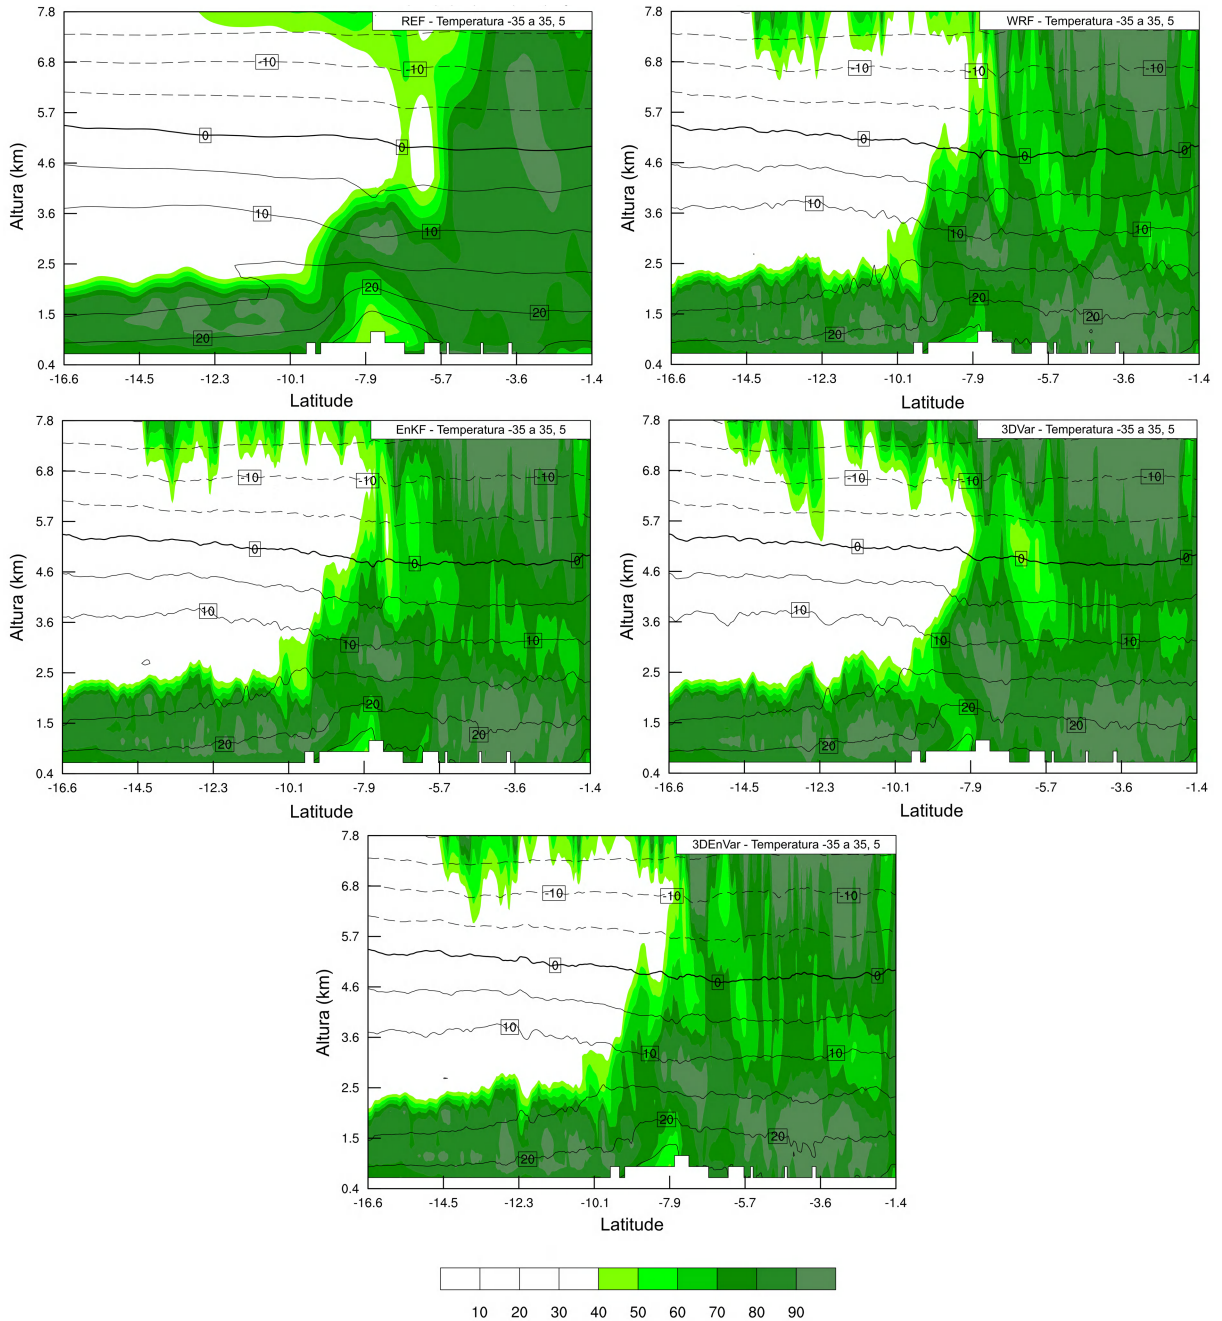


As figuras representam a seção vertical da divergência desde a superfície até 8 km de altura, obtidas do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DVar.

Fonte: Produção do autor.

As seções transversais de umidade sobre a área de atuação do VCAN ilustram, sobre a região central do sistema (10°S), uma atmosfera mais seca, enquanto que sua a porção periférica mais úmida, conforme ilustrado pelas previsões do modelo WRF e análises do EnKF, 3DVar e 3DEnVar (Figura 3.20). Em torno de 5°S , por exemplo, onde foi verificado pelas estações de superfície do INMET um evento de chuva intenso sobre a cidade de Barra da Corda (MA), o aporte de umidade para o desenvolvimento de SCM é muito maior e mais distribuído ao longo da coluna atmosférica se comparado com a região central do VCAN, conforme ilustrado na Figura 3.20.

Figura 3.20 - Seção vertical de umidade e temperatura para o dia 14 de janeiro de 2017, às 00 UTC.



As figuras representam a seção vertical da umidade desde a superfície até 8 km de altura, obtidas do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

Pelos contornos de temperatura também foi possível identificar os padrões do VCAN conforme registrado na literatura. A região central do VCAN é mais fria e a periferia é mais quente, em torno de 2,5 km, resultante respectivamente da presença de movimentos descendentes responsáveis por trazer ar frio dos níveis superiores para baixos níveis troposféricos e movimentos ascendentes, transportando ar quente confinado em baixos níveis para níveis imediatamente superiores da atmosfera, para a região periférica do VCAN, conforme ilustrado pela Figura 3.20.


Uma comparação entre os resultados apresentados na Figura 3.20, mostra que assim como as previsões do modelo WRF, as análises do EnKF, 3DVar e 3DEnVar produziram uma atmosfera mais úmida se comparado com o experimento de referência, principalmente para os níveis mais baixos da troposfera, entre 1 e 2 km acima da superfície, o que pode representar uma melhora na previsão de processos úmidos.

Em suma, apesar das performances para os campos aqui avaliados através das análises obtidas do EnKF, 3DVar e 3DEnVar, terem sido satisfatórias ao representar as condições sinóticas associadas ao VCAN, notou-se que o centro com curvatura ciclônica em altos níveis, associado a este sistema, foi melhor definido pelas análises do 3DEnVar.

3.6.2 Análise sinótica do dia 24 de janeiro de 2017

Em 24 de janeiro de 2017, apesar da presença do VCAN em altos níveis posicionado sobre a região litorânea do leste do NEB em 10 km acima da superfície, o que subsidiou a formação do SCM foi a combinação de uma região de confluência de vento em baixos níveis (2 km) que contribuiu para transportar a umidade da superfície para altos níveis da troposfera sobre a região centro-oeste do Piauí, próximo ao estado do Maranhão. A presença da vanguarda de um cavado em altos níveis (8 km), sobre a mesma região, também foi identificada em torno 5°S e 40°W, conforme ilustrado pelas barbelas de vento na Figura 3.21. A presença de cavados béricos, ou seja, ondas tropicais com curvatura ciclônica, como mecanismo influenciador na formação de SCM sobre o NEB é um processo muito comum, com possibilidade de ocorrência em qualquer época do ano, conforme retratado por [Cordeiro et al. \(2018\)](#).

Figura 3.21 - Análises dos campos de vento e umidade a 8 km (300 hPa) acima da superfície válidas para o dia 24 de janeiro de 2017, às 00 UTC.




As figuras representam os campos de umidade e vento em altos níveis da atmosfera (8 km) obtidos do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

Em níveis superiores (8 km) é possível constatar valores altos de umidade relativa (maiores que 90%), com campos mais distribuídos para o domínio sobre o NEB, principalmente com o 3DVar e o 3DEnVar se comparado com a análise de referência (REF). Para o dia 24 de janeiro de 2017, as análises obtidas das previsões do modelo WRF tendo como condições iniciais dados do GEFS, também aumentaram o conteúdo de umidade em altos níveis, similar ao experimento do dia 14 de janeiro de 2017, às 00 UTC.

As seções verticais da Figura 3.22 ilustram a presença de uma região distribuída por toda a troposfera dominada por convergência de vento bastante intensa (com valores inferiores a $-10 \times 10^{-6} \text{ s}^{-1}$) entre 2-8°S, denotada pelos tons em vermelho-escuro, e que se torna menos evidente entre 10-16°W. Observe que a região marcada por convergência intensa em baixos níveis, coincide com a área demarcada por um conteúdo de umidade expressivo em altos níveis, retratada na Figura 3.21. Apesar da similaridade identificada nos experimentos apresentados na Figura 3.22, nota-se que os resultados das previsões do modelo WRF e das análises do EnKF, 3DVar e 3DEnVar, denotam maior quantidade de regiões dominadas pela convergência dos ventos ao longo da coluna troposférica desde baixos a altos níveis, se comparado com experimento de referência (REF). Fato que contribui para impactar a distribuição de umidade por toda a atmosfera.

Figura 3.22 - Seção vertical da convergência de vento (10^{-6} s^{-1}) para o dia 24 de janeiro de 2017, às 00 UTC.

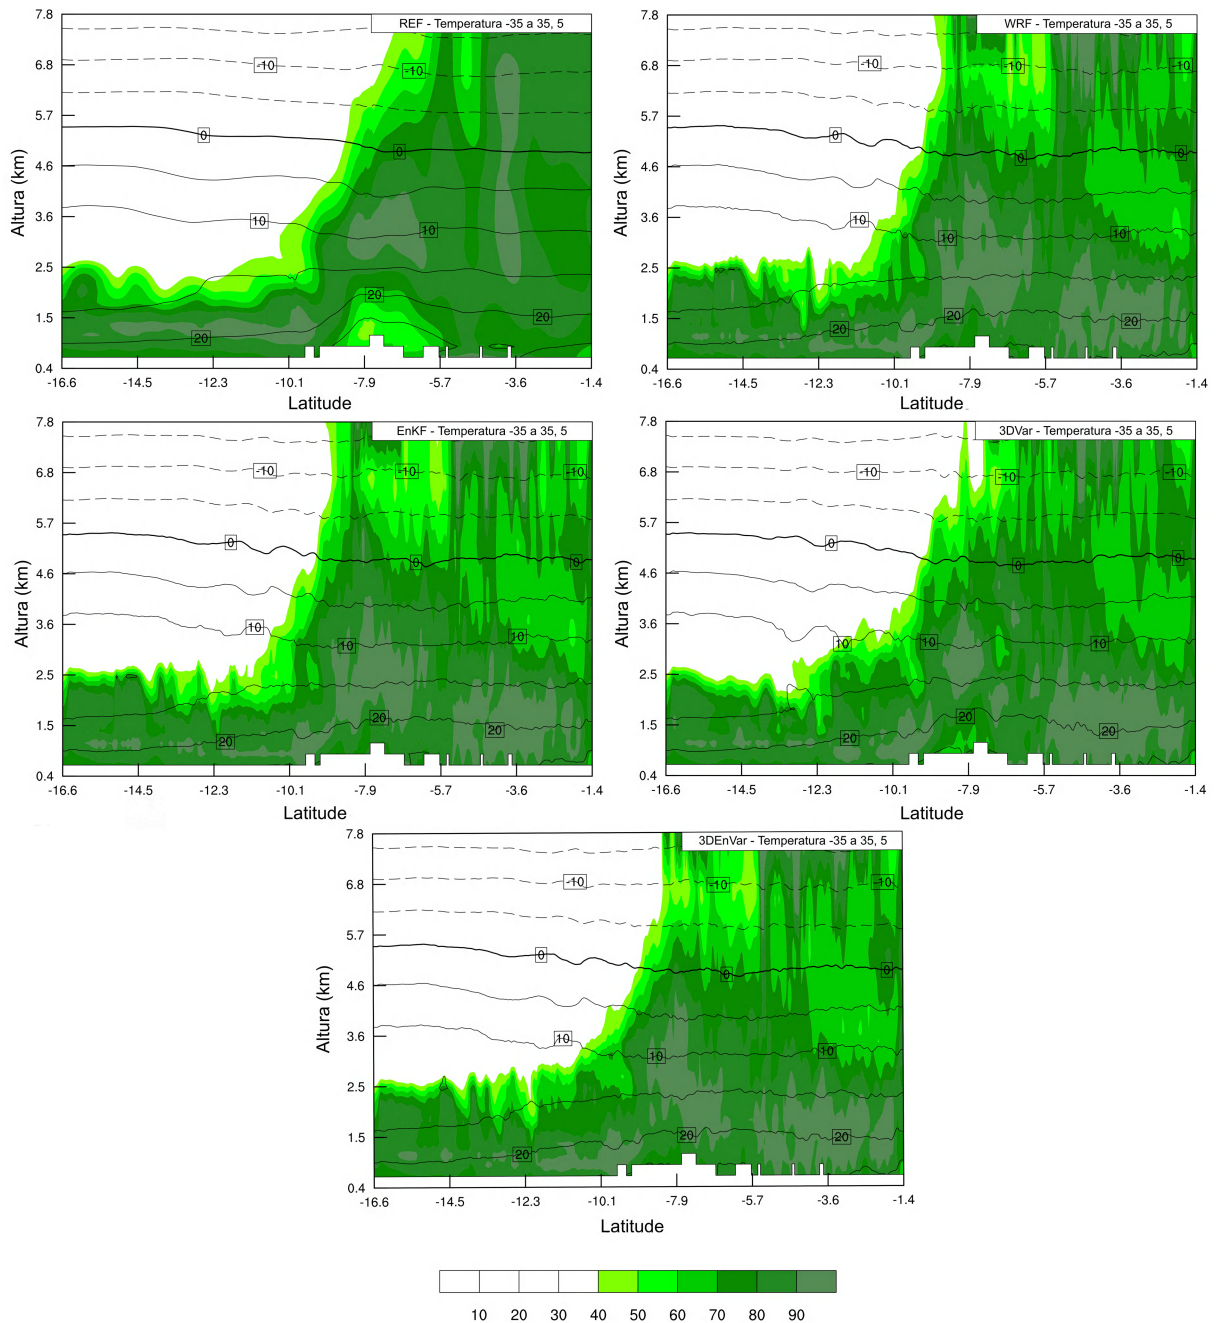


As figuras representam a seção vertical da divergência desde a superfície até 8 km de altura, obtidas do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

Apesar de não ser verificada a atuação do VCAN sobre a região de formação do SCM, uma distribuição vertical similar aos campos de umidade e temperatura observada no dia 14 de janeiro de 2017 (Figura 3.23), às 00 UTC, foi obtida. Porém associados à atuação de um cavado b́arico e a retaguarda de uma crista subsequente que influenciou a atmosfera neste dia, conforme ilustrado na Figura 3.21. Similar ao experimento do dia 14 de janeiro de 2017, é possível observar um aumento da umidade sobre a principal região de atuação do cavado, entre 1,4 e 7,9°S, e uma área entre 10,1 e 16,6°S mais seca, referente à área de influência da retaguarda da crista.

Figura 3.23 - Seção vertical de umidade e temperatura para o dia 24 de janeiro de 2017, às 00 UTC.



As figuras representam a seção vertical da umidade desde a superfície até 8 km de altura, obtidas do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com o membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

Os campos de temperatura da Figura 3.23 ilustram que para região de atuação do cavado há temperaturas mais quentes, associadas ao transporte de calor da superfície para regiões imediatamente superiores, entre 0,4 e 3,6 km em 1,4 a 7,9°S, enquanto que para a mesma camada sobre 10,1 e 16,6°S, região de atuação da crista, temperaturas mais frias. Este padrão atmosférico é comumente verificado durante a formação de SCM, conforme mostrado na Figura 1.2.

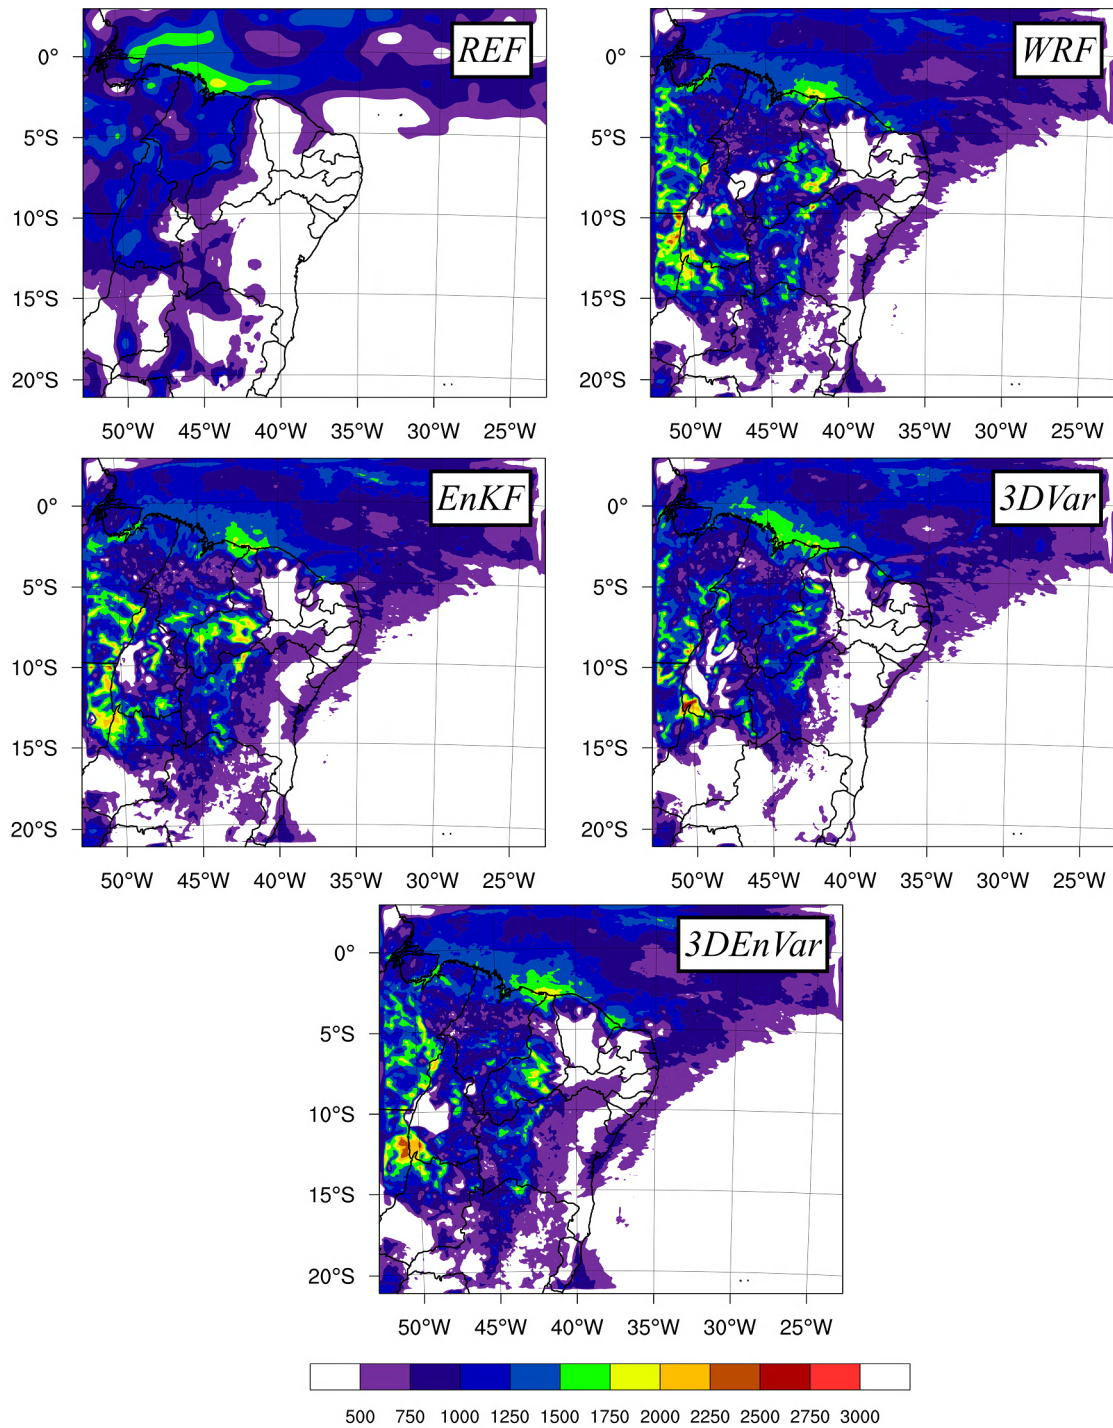
3.7 Análise termodinâmica dos SCM

A análise dos campos termodinâmicos foi feita através do índice *Most-unstable Convective Available Potential Energy* (MCAPE) que retrata uma atmosfera instável quando retornados valores superiores a 1000 J.kg^{-1} . O MCAPE é um índice que leva em consideração a parcela de ar mais instável localizada nos primeiros 300 hPa da atmosfera, em virtude das parcelas que ascendem a partir da superfície terem um CAPE superior se comparado com aquelas que ascendem de níveis superiores (CLARK et al., 2010).

3.7.1 Análise termodinâmica do dia 14 de janeiro de 2017

O índice MCAPE retratado na Figura 3.24 ilustra sobre a região do Município de Barra da Corda (6°S e 46°W), onde ocorreu o episódio de chuva intensa, valores superiores a 1000 J.kg^{-1} , o que indica a possibilidade de formação de instabilidades convectivas. Dentre os experimentos ilustrados na Figura 3.24, a análise do 3DENVar representou a atmosfera sobre a região de Barra da Corda com valores superiores aos demais experimentos, ao retornar valores de MCAPE superiores a 1200 J.kg^{-1} sobre a região de ocorrência do episódio de chuva intensa associada ao SCM.

Figura 3.24 - Distribuição da instabilidade convectiva sobre o Nordeste brasileiro através do MCAPE ($J.kg^{-1}$) para o dia 14 de janeiro de 2017, às 00 UTC.



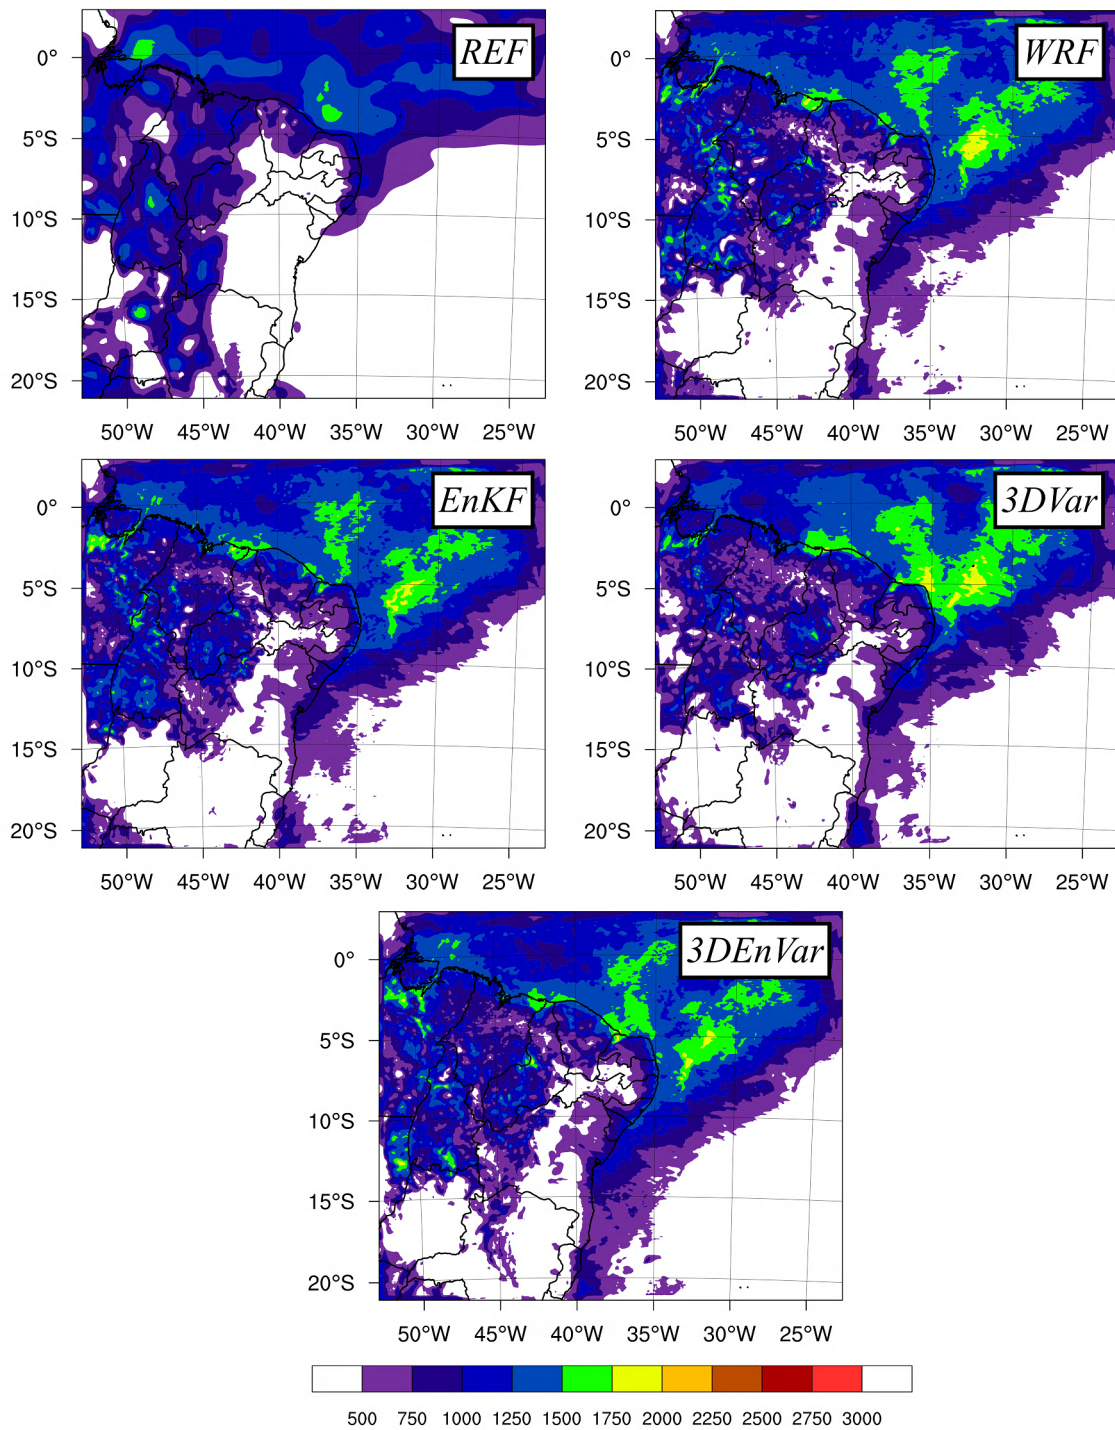
As figuras representam o índice MCAPE obtido pelo membro controle do GEFS (REF), pela previsão do modelo WRF inicializada com membro controle GEFS (WRF), pela média das análises do EnKF e análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

3.7.2 Análise termodinâmica do dia 24 de janeiro de 2017

Os campos apresentados na Figura 3.25, para os experimentos REF, WRF e 3DVar, referentes ao MCAPE sobre a região de Colinas (6°S e 44°W), no Maranhão, retornaram valores inferiores a 1000 J.kg^{-1} , similar ao valor obtido para o experimento de referência (REF), o que indica um potencial maior para inibição da atividade convectiva, que por sua vez impede a formação de tempestades. Dentre os experimentos da Figura 3.25, apenas as análises do 3DEnVar e EnKF indicaram um potencial de convecção significativo sobre o Município de Colinas, que ocasionou a ocorrência de chuvas intensas para esta região do NEB, ao apresentar valores de MCAPE superiores a 1000 J.kg^{-1} .

Figura 3.25 - Distribuição da instabilidade convectiva sobre o Nordeste brasileiro através do MCAPE ($J.kg^{-1}$) para o dia 24 de janeiro de 2017, às 00 UTC.




As figuras representam o índice MCAPE obtido do membro controle do GEFS (REF), da previsão do modelo WRF inicializada com membro controle do GEFS (WRF), da média das análises do EnKF e das análises determinísticas do 3DVar e 3DEnVar.

Fonte: Produção do autor.

A Figura 3.26 ilustra os valores de MCAPE obtidos para os experimentos do dia 14 e 24 de janeiro de 2017 apresentados nas Figuras 3.24 e 3.25, sobre os pontos onde foram registrados episódios de chuvas intensas pelas estações de Barra da Corda (6°S e 46°W) e Colinas (6°S e 44°W) nos dias de ocorrência de SCM. Conforme observado nas Figuras 3.24 e 3.25, para os pontos de grade sobre as estações meteorológicas de Barra da Corda e Colinas, foram constatados maiores potenciais de formação de instabilidades convectivas, com MCAPE superior a 1000 J.kg^{-1} , para os dias 14 de janeiro de 2017 (SCM1) e 24 de janeiro de 2017 (SCM2), pelas análises obtidas do EnKF e 3DVar. Os experimentos que consideram o conjunto de previsões do modelo WRF, podem ter performado melhor devido à amostragem da atmosfera e a incorporação dos erros do dia no cálculo das suas respectivas análises.

Figura 3.26 - MCAPE calculado para os dias 14 (SCM1) e 24 (SCM2) de janeiro de 2017, sobre estações meteorológicas de Barra da Corda (6°S e 46°W) e Colinas (6°S e 44°W), do GEFS (REF), da previsão do modelo WRF inicializada com o membro controle do GEFS (WRF) e das análises do EnKF, 3DVar e 3DVar.



Fonte: Produção do autor.

Em resumo, no experimento SCM1, não foi possível verificar diferenças significativas entre o 3DVar, 3DVar e EnKF em denotar instabilidades convectivas sobre a região de ocorrência do SCM. No experimento SMC2, a maior diferença referente

ao valores de MCAPE entre o 3DVar e o EnKF ocorreu em virtude da matriz climatológica do 3DVar não ter sido eficaz em corrigir os erros do modelo, quando comparada com a matriz híbrida do 3DEnVar. Dessa forma, o EnKF corrigiu os erros de previsão nas variáveis de análise e conseguiu representar bem a instabilidade convectiva associada ao MCAPE sobre a região de atuação do SCM.

3.8 Verificação das previsões de chuva

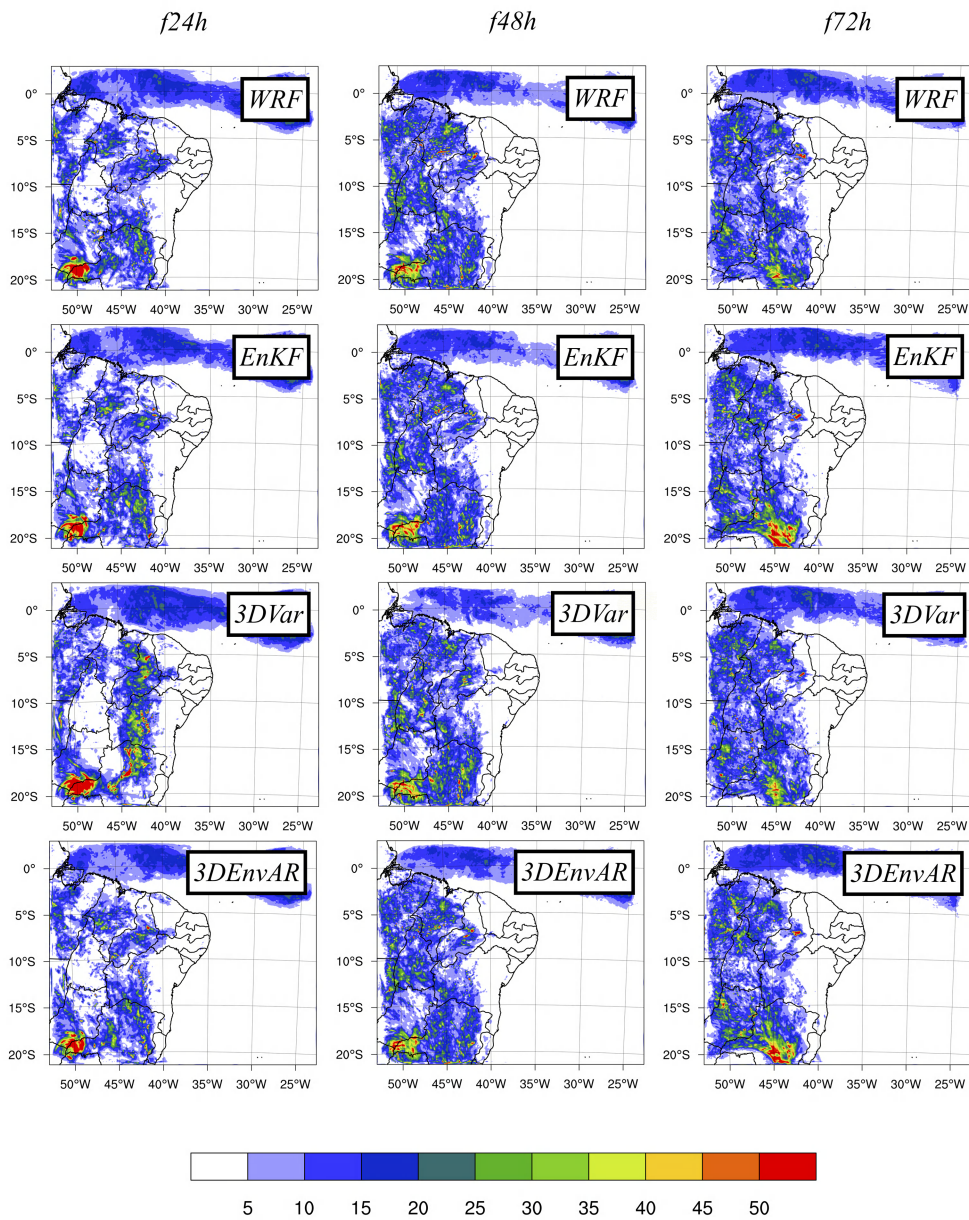
As previsões do modelo WRF inicializado com as análises do GEFS, EnKF, 3DVar e 3DEnVar, foram realizadas para 24, 48 e 72 h antes das datas de registro dos SCM (14 e 24 de janeiro de 2017). Através dessas previsões, foram extraídos os acumulados de chuva em 24 horas (mm) para os dias dos eventos de SCM, que foram comparados com dados observacionais provenientes das estações meteorológicas em superfície do INMET, sobre o estado do Maranhão, local onde ocorreu eventos de chuvas intensas, superiores a 70 mm.

A avaliação da performance do modelo WRF foi feita comparando-o com observações meteorológicas em superfície do INMET, sobre o estado do Maranhão. Para isso foi utilizado um diagrama de performance contendo quatro índices da tabela de contingência: BIAS de frequência, FAR, POD e ICS, e, como complemento à avaliação qualitativa dos mapas de chuva acumulada em 24 horas obtidos do modelo WRF, foi utilizado a raiz do erro quadrático médio (RMSE).

3.8.1 Previsão de chuva para o dia 14 de janeiro de 2017

As previsões executadas pelo modelo WRF referente à chuva acumulada em 24 horas para o dia 24 de janeiro de 2017, ilustradas pela Figura 3.27, revelam que de forma geral todos os experimentos conseguiram produzir eventos de chuva superiores à 5 mm sobre a região de Barra da Corda (6°S e 45°W), no Maranhão, onde ocorreu o episódio de chuva intensa. Essa constatação é importante, pois mostra uma similaridade com a distribuição espacial dos campos de chuva acumulada em 24 horas obtidos da hidroestimativa do MERGE (Figura 3.15), que apesar das semelhanças, em termos de distribuição espacial subestimou a chuva acumulada em 24 h.

Figura 3.27 - Previsão de chuva acumulada em 24 horas para o SCM do dia 14 de janeiro de 2017, inicializada em 14 de janeiro de 2017, às 00 UTC (f24h), em 13 de janeiro de 2017, às 00 UTC (f48h) e em 12 de janeiro de 2017, às 00 UTC (f72h).



Acumulados de chuva em 24 h obtidos do modelo WRF inicializado com membro controle GEFS (WRF), pelo membro controle do EnKF e análises determinísticas do 3DVar e 3DEnvAR.


Fonte: Produção do autor.

Apesar da similaridade entre os campos de chuva acumulada em 24 horas, as previsões do experimento f24h, em geral, apresentam uma grande área recobrando o estado do Maranhão, com acumulados diários de chuva superiores a 5 mm, ao utilizar as condições iniciais do GEFS, EnKF e 3DVar, correspondentes, respectivamente, aos experimentos f24h-WRF, f24h-EnKF e f24h-3DVar. De outro modo, os dados de precipitação provenientes do modelo WRF inicializado com as análises do 3DVar (experimento f24-3DVar, na Figura 3.27), apresentam uma atmosfera mais seca, ou seja, como menos áreas de precipitação superiores a 5 mm abrangendo o estado do Maranhão em comparação com os demais experimentos (f24h-WRF, f24h-EnKF e f24h-3DVar), um indicativo de que o experimento f24h-3DVar obteve um desempenho inferior em relação às demais configurações.

Avaliando a raiz do erro quadrático médio (Figura 3.28) do experimento f24h, em geral, nota-se que entre os experimentos avaliados no dia 14 de janeiro de 2017, o f24h-3DVar obteve o pior desempenho quando comparado ao f24h-WRF, f24h-EnKF e f24h-3DVar. Assim, enquanto os erros do modelo com relação às observações do INMET sobre o estado do Maranhão foram em torno de 22 mm para os experimentos f24h (WRF, EnKF e 3DVar), para o experimento f24h-3DVar, o erro do modelo foi superior a 25 mm. Uma das justificativas para que a configuração f24h-3DVar tenha apresentado um desempenho inferior às demais configurações do SMR, está no fato do 3DVar utilizar uma matriz de covariância dos erros de previsão estática no tempo, com isso, os erros do modelo representados por esta matriz pode não representar bem os erros dos campos impressos no *background* para uma determinada época do ano e/ou na presença de SCM na região tropical, o que pode resultar em previsões de chuvas que diferem das observações.

Especula-se também, que os resultados da chuva acumulada em 24 horas foram distantes daqueles observados nas estações meteorológicas, em virtude das parametrizações de microfísica de nuvem utilizada no modelo WRF terem subestimado a umidade prevista, associada ao SCM, conseqüentemente contribuindo para que a chuva acumulada em 24 horas não conseguisse representar eventos de chuvas intensas, em geral.

Figura 3.28 - RMSE calculado para avaliar as previsões dos acumulados de chuva diário do modelo WRF inicializado com o membro controle do GEFS (WRF) e com as condições iniciais atualizadas pelo EnKF, 3DVar e 3DEnVar para o dia 14 de janeiro de 2017, inicializado 24 (f24h), 48 (f48h) e 72 horas (f72h) antes.



Fonte: Produção do autor.

A melhor performance na previsão de chuva acumulada em 24 horas foi obtida pelos experimentos f24h-3DEnVar e f24h-EnKF. Observe na Figura 3.28, que os erros das previsões obtidas nestas configurações são em torno de 22 mm, os menores entre os experimentos. A boa performance dos experimentos f24h-3DEnVar e f24h-EnKF é explicada, em parte, pelo fato das análises no EnKF e 3DEnVar serem obtidas usando uma matriz de covariâncias dos erros de previsão que é atualizada a cada ciclo de assimilação com os erros do dia, que por sua vez são calculados a partir de um conjunto de membros de previsão, conforme apresentado na Equação 2.15, o que contribui para obtenção de condições iniciais que minimizam os erros sistemáticos do *background* utilizado na assimilação de dados, o que pode contribuir para obter previsões de chuvas mais próximas das observadas nas estações meteorológicas.

Para os experimentos f48h e f72h da Figura 3.27, as melhores previsões do modelo WRF foram desempenhadas com as análises do 3DEnVar, cujos erros das previsões

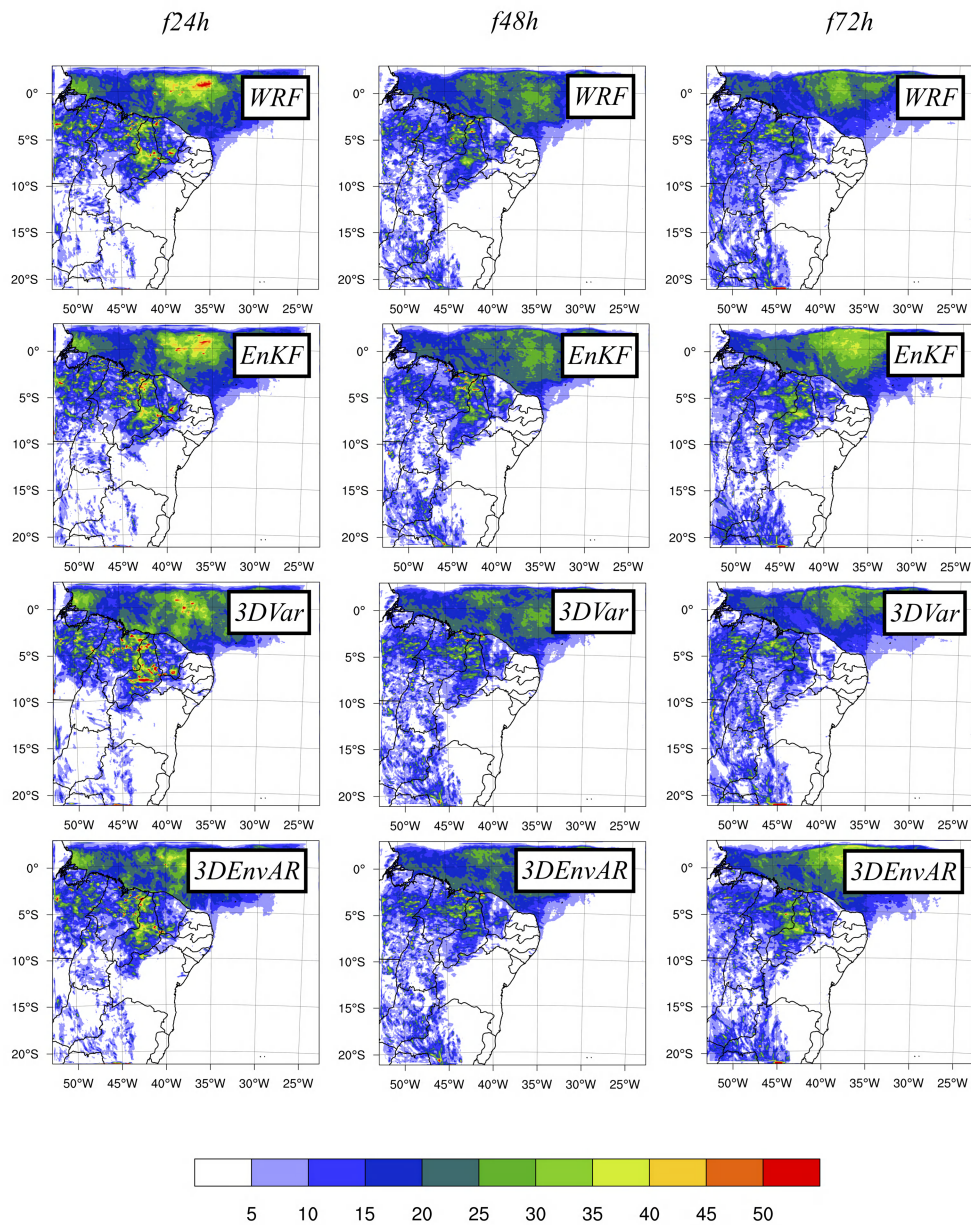
com relação observações meteorológicas do INMET sobre o estado do Maranhão foram em torno de 23 mm para ambos os experimentos. De outro modo, as previsões do modelo WRF inicializado com as análises do EnKF, para os experimentos f48h e f72h, obtiveram os maiores erros dentre as configurações avaliadas, conforme ilustrado pela raiz do erro quadrático médio apresentado na Figura 3.28, com erros superiores a 25 mm em ambos os experimentos. Esse desempenho do modelo WRF inicializado com as análises do EnKF, nos experimentos f48h e f72h, pode ser explicado pelo fato do conjunto de previsões utilizadas para obtenção da matriz de covariâncias dos erros de previsão do EnKF ser muito pequeno, fazendo com que as análises do EnKF consiga representar apenas um conjunto muito pequeno de situações da atmosfera, o que resulta em uma matriz do EnKF com um potencial limitado em termos de compreensão dos erros de previsão nestes experimentos.

Em resumo, dentre os experimentos avaliados, o que apresentou a melhor performance na previsão de chuva acumulada em 24 horas, para o dia 14 de janeiro de 2017, foi o modelo WRF inicializado com as análises do 3DEnVar. Para os experimentos do dia 14 de janeiro de 2017, portanto, essa matriz híbrida do 3DEnVar contribuiu para minimizar os erros de previsão, ao fornecer para o modelo WRF análises que contribuíram para melhor representar o estado inicial da atmosfera na previsão de chuva, para este dia.

3.8.2 Previsão de chuva para o dia 24 de janeiro de 2017

As previsões do modelo WRF para o dia 24 de janeiro de 2017, apresentadas na Figura 3.30, ilustram que para todos os experimentos foi possível prever eventos de chuva com um limiar superior a 5 mm sobre a região Colinas (6°S e 44°W), onde ocorreu o episódio SCM. Além disso, uma distribuição espacial similar aos campos de chuva acumulada em 24 horas do MERGE (Figura 3.15) pôde ser verificada pelas diferentes previsões do modelo WRF retratadas na Figura 3.30, porém, de forma geral, os valores previstos subestimaram a chuva diária obtida pelo MERGE.

Figura 3.29 - Previsão de chuva acumulada em 24 horas para o SCM do dia 24 de janeiro de 2017, inicializada em 24 de janeiro de 2017, às 00 UTC (f24h), em 23 de janeiro de 2017, às 00 UTC (f48h) e em 22 de janeiro de 2017, às 00 UTC (f72h).




Acumulados de chuva em 24 h obtidos do modelo WRF inicializado com membro controle GEFS (WRF), pelo membro controle do EnKF e análises determinísticas do 3DVar e 3DEnvAR.

Fonte: Produção do autor.

Os campos de chuva acumulada em 24 horas apresentam uma similaridade em relação a distribuição de precipitação sobre o NEB, conforme ilustrado na Figura 3.29. A raiz do erro quadrático médio mostra que as maiores diferenças das análises com relação as observações das estações meteorológicas do INMET sobre o estado do Maranhão, no experimento f24h, foram obtidas pelo f24h-WRF (Figura 3.29). Para este experimento, os erros foram maiores que 35 mm, o que demonstra a necessidade de atualizar as análises do GEFS através de um sistema de assimilação, tais como o 3DVar, EnKF e 3DEnVar no SMR, no sentido que estes corrijam os erros sistemáticos do modelo ao fornecerem para o WRF condições iniciais com campos meteorológicos atualizados pelos sistemas de assimilação de dados habilitados no SMR, que por sua vez, podem auxiliar a melhorar previsões de chuva.

Figura 3.30 - RMSE calculado para avaliar as previsões dos acumulados de chuva diário do modelo WRF inicializado com o membro controle do GEFS (WRF) e com as condições iniciais atualizadas pelo EnKF, 3DVar e 3DEnVar para o dia 24 de janeiro de 2017, inicializado 24 (f24h), 48 (f48h) e 72 horas (f72h) antes.



Fonte: Produção do autor.

A melhor performance do modelo WRF inicializado 24 horas antes do dia do evento

foi obtida pelo experimento f24h-EnKF. O experimento f48h-EnKF também obteve os menores erros de previsão ao ser comparado com as estações meteorológicas do INMET, sobre o estado do Maranhão. Assim, os experimentos f24h-EnKF e f48h-EnKF, retratam um conjunto de previsões inicializadas com análises provenientes do EnKF que obtiveram os menores erros de previsão, conforme apresentado pelo valor da raiz do erro quadrático médio com valores em torno de 28 mm (Figura 3.30).

O pior desempenho do experimento f48h, foi obtido com o modelo WRF inicializado com as análises do 3DVar, apresentando um erro de 35 mm referente ao RMSE (Figura 3.30). Conforme já abordado em seções anteriores, uma das causas para que isso aconteça está no fato das análises do 3DVar serem geradas a partir de uma matriz de covariâncias dos erros de previsão climatológica, ou seja, os erros representados nesta matriz podem funcionar bem na representação dos erros das variáveis de análise do modelo em determinadas épocas do ano ou em condições específicas de sistemas meteorológicos típicos de determinadas latitudes, o que pode resultar em análises utilizadas na inicialização do modelo WRF, com erros de *background* que não foram corrigidos pelo sistema de assimilação. Como resultado, as condições iniciais podem apresentar erros que contribuem para que o WRF tenha um desempenho inferior na previsão de chuva para o NEB, em comparação com as demais configurações do SMR.

No experimento f72h, inicializado com as análises do 3DVar, EnKF e 3DEnVar, os erros foram maiores (em torno de 33 mm) do que os erros do modelo WRF inicializado com a análise do GEFS, com valores referentes à raiz do erro quadrático médio em torno de 28 mm (Figura 3.30). Isso pode ter particularmente acontecido, devido os campos das análises geradas no SMR através do 3DVar, EnKF e 3DEnVar não terem conseguido minimizar os erros de *background* ao atualizar as análises, justificado pelo fato da matriz de covariância dos erros de previsão climatológica do 3DVar e matriz de covariância do EnKF atualizada com os erros do dia não terem sido capazes de corrigir os erros do modelo na etapa de geração das análises, o que pode implicar em um desempenho ruim do modelo WRF nas previsões de chuva quando comparado com as observações.

No experimento f72h-WRF, foi utilizada como condição inicial o membro controle do GEFS. Como este membro controle é obtido de um sistema de assimilação de dados utilizado pelo NCEP para a geração de análises (o EnKF), os resultados obtidos no experimento f72h-WRF tiveram um bom desempenho, em parte, atribuído


às condições iniciais obtidas do EnKF, que foram capazes de reduzir os erros de *background* e consequentemente auxiliar o modelo WRF na obtenção de uma melhor performance na previsão de chuva, em comparação com os demais experimentos avaliados na Figura 3.27.

Em resumo, para as previsões do modelo WRF válidas para o dia 24 de janeiro de 2017, nota-se a importância da assimilação de dados por conjunto no melhor desempenho do modelo WRF inicializado com o GEFS e o EnKF. O desempenho inferior do modelo WRF inicializado com as análises do 3DVar e 3DEnVar, em alguns experimentos, sugere uma deficiência da matriz de covariância dos erros de previsão de ambos os sistemas em corrigir os erros do *background* usado na assimilação de dados, que poderia ser mitigado atribuindo um peso maior a matriz de covariância do EnKF, no 3DEnVar, e obtenção de uma nova matriz estática no 3DVar. Além desse fato, as parametrizações de microfísica de nuvens utilizadas pelo modelo WRF configurado neste trabalho podem ter contribuído para que o conteúdo de umidade fosse subestimado durante as previsões e consequentemente um menor acumulado de chuva em 24 horas fosse previsto neste experimento, quando comparado com os valores registrados pela estação meteorológica em superfície.

3.9 Avaliação da previsão de chuva pelo diagrama de performance

O diagrama de performance referente aos acumulados de chuva diário do modelo WRF inicializados com 24 horas de antecedência ilustram que nos dias com episódios de chuvas intensas, ocorridos nos dias 14 e 24 de janeiro de 2017, a probabilidade em detectar eventos de chuva com limiar superior a 5 mm pelo modelo WRF inicializado com as análises do 3DEnVar foi a maior dentre os experimentos avaliados, retornando uma POD equivalentes a 100%. Igualmente, pelo diagrama da Figura 3.31 a taxa de sucesso dos experimentos do WRF inicializados com análises do 3DEnVar comportou-se de forma satisfatória, chegando a apresentar taxa de sucesso equivalente a 80%, a maior dentre os experimentos avaliados. Isso demonstra que as previsões do experimento WRF tendo como condição inicial as análises do 3DEnVar, portanto, detectaram bem a chuva acumulada em 24 horas, para um limiar superior a 5 mm, ao apresentar alta probabilidade de prever o evento sobre o estado do Maranhão, assim como uma baixa probabilidade, em geral, em prever falsos eventos de chuva se comparados com os dados observacionais de estações meteorológicas do INMET sobre a principal área de atuação do SCM.


Figura 3.31 - Digrama de performance para as previsões dos acumulados de chuva diária do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 24 horas antes.



Fonte: Produção do autor.

O BIAS de frequência do diagrama de performance da Figura 3.31 e 3.32 ilustram que os experimentos do WRF inicializados 24 h antes com condições iniciais geradas por um dos sistemas de assimilação de dados avaliados, em geral, superestimaram as observações, assim como as previsões do modelo WRF inicializadas com o membro controle do GEFS.

Figura 3.32 - Digrama de performance para as previsões dos acumulados de chuva diária do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 48 horas antes.




Fonte: Produção do autor.

Similar ao acumulado de chuva diária desempenhado pelo modelo WRF inicializado 24 horas antes com as condições iniciais do 3DEnVar, as previsões inicializadas 48 h antes, com as mesmas configurações, conseguiram retornar uma alta POD para os eventos de chuva, equivalente a 100%, a melhor dentre os experimentos avaliados (Figura 3.32). As análises atualizadas pelo 3DEnVar também tiveram um bom desempenho associado a taxa de sucesso (superiores a 60%), onde revelou que esta configuração também se comportou bem em detectar ausência de chuva quando estas não foram registradas pelas estações de superfície do INMET. Um dos motivos para que a configuração do WRF inicializado com as análises do 3DEnVar tenha obtido uma boa performance, é justificado pelo fato do 3DEnVar produzir campos

ponderados com os erros das observações e do modelo, que quando aliado a um bom esquema paramétrico de microfísica na representação das nuvens convectivas para o NEB, auxiliam na obtenção de melhores previsões de chuva.

A previsão dos acumulados de chuva em 24 horas do modelo WRF inicializado 72 horas antes com as análises do 3DEnVar (Figura 3.33) apresentaram uma POD superior a 70% para os dias de ocorrência de chuvas intensas sobre o estado do Maranhão. Apesar disso, elas não tiveram as melhores performances dentre as configurações avaliadas referente a POD, que para os demais experimentos (WRF, 3DVar e EnKF) foram superiores a 80%. A taxa de sucesso para as previsões cujas as condições iniciais foram atualizadas pelo 3DEnVar se comportou como verificado nos experimentos anteriores, ou seja, com valores superiores a 60%, enquanto que os valores previstos, conforme ilustrado pelo BIAS de frequência, superestimaram as observações do dia 14 de janeiro de 2017 e subestimaram os acumulados de chuva observados no dia 24 de janeiro de 2017 quando comparados com os dados das estações meteorológicas do INMET.

Figura 3.33 - Digrama de performance para as previsões dos acumulados de chuva diário do modelo WRF inicializado com o GEFS e com as condições iniciais do EnKF, 3DVar e 3DEnVar, para os dias 14 e 24 de janeiro de 2017, inicializadas 72 horas antes.



Fonte: Produção do autor.

Para a maioria dos experimentos avaliados, as previsões do modelo WRF tendo como condições iniciais análises atualizadas pelo 3DEnVar e inicializadas 24, 48 e 72 horas antes obtiveram o CSI superior a 60%. Para os demais experimentos, o CSI em geral oscilou entre valores superiores a 50% e inferiores a esse limiar. Indicando que de forma geral, os experimentos do WRF inicializados com as análises do 3DEnVar tiveram um melhor desempenho na detecção de episódios de chuva associados aos SCM ocorridos nos dias 14 e 24 de janeiro de 2017.

Pode-se concluir através da avaliação do digrama de performance das Figuras 3.31, 3.32 e 3.33, que a inicialização do modelo WRF com as análises do 3DEnVar apre-

sentaram, em geral, performance satisfatória na detecção de eventos de chuva sobre o estado do Maranhão, local onde ocorreram chuvas intensas associadas aos SCM, contribuindo para obtenção de melhores previsões quando comparado com as condições iniciais provenientes dos demais sistemas de assimilação de dados.

4 CONCLUSÕES

Este trabalho avaliou o impacto dos sistemas de assimilação de dados 3DVar, EnKF e 3DEnVar na geração de análises, na intenção de verificar suas contribuições na reprodução de dois sistemas meteorológicos responsáveis por ocasionar eventos de chuvas intensas sobre o NEB. Concomitantemente, foi habilitado e avaliado o desempenho dos sistemas de assimilação de dados por conjunto-variacional (3DEnVar) dentro do projeto do Sistema de Modelagem Regional (SMR), a fim de melhorar as condições iniciais fornecidas ao modelo WRF, por meio da incorporação dos erros do dia na matriz de covariâncias do 3DVar, atualmente em operação no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC).

Em todos os ciclos de assimilação de dados aqui desempenhados, destacou-se a dificuldade dos sistemas em gerar análises para os campos de umidade consistentes com as observações meteorológicas. Esse problema é recorrente em centros de pesquisa de todo o mundo, conforme retratado por [Liu e Kalnay \(2005\)](#), que atribuem à extensa variabilidade espaço-temporal dos dados de umidade em pequenas escalas espaciais como um dos principais desafios para sua representação numérica dentro dos modelos de PNT. Apesar disso, de forma geral, os resultados do sistema de assimilação de dados por conjunto-variacional apresentou performances satisfatórias, quando comparado ao 3DVar, na atualização dos campos de umidade, conforme já constatado por [Kleist e Ide \(2015\)](#).

A versão do SMR utilizada no escopo deste trabalho testou as configurações para um sistema de assimilação híbrido, conforme o empregado no sistema de assimilação de dados meteorológico regional ou de previsões meteorológicas de curtíssimo prazo *Rapid Refresh*, RAP, ([HU et al., 2017](#)), atualizado de hora em hora pela NOAA/NCEP usando, também, o sistema GSI.

Devido as limitações computacionais (espaço disponível para armazenamento dos dados, Apêndice A.1, e tempo de execução do SMR com o 3DEnVar equivalente a aproximadamente 8,5 horas, Apêndice B.1), as análises foram geradas a cada seis horas.

Para obtenção das análises do 3DEnVar utilizadas como condições iniciais para previsão de chuva no modelo WRF foi atribuído à matriz de covariância do EnKF o peso de 0,75, resultado similar ao adotado por [Hu et al. \(2017\)](#).

O 3DEnVar, assim como os demais sistemas de assimilação de dados aqui empre-

gados, desempenhou bem a atualização das análises geradas a partir das previsões do modelo WRF, enquanto que as previsões do modelo WRF inicializadas com o membro controle do GEFS, não conseguiu reproduzir o VCAN responsável pela formação de tempo severo sobre o estado do Maranhão, no dia 14 de janeiro de 2017, ao analisar as barbelas de vento em altos níveis (8 km). Apesar disso, o modelo teve um bom desempenho na reprodução da temperatura e umidade associada à formação de um SCM, conforme descrito por Machado e Laurent (2004).

Na avaliação dos processos termodinâmicos, o 3DEnVar e o EnKF foram os únicos sistemas dentre os avaliados a indicar possibilidade de ocorrência de instabilidades convectivas para ambos os dias de atuação dos SCM (14 e 24 de janeiro de 2017) através do índice MCAPE. As demais configurações do SMR conseguiram indicar a possibilidade de ocorrência de instabilidades convectivas através do MCAPE, ao apresentarem valores superiores a 1000 J.kg^{-1} (CLARK et al., 2010), para o evento de SCM ocorrido no dia 14 de janeiro de 2017, enquanto que para a área do SCM do dia 24 de janeiro de 2017, o MCAPE simulado retornou valores a baixo de 1000 J.kg^{-1} , o que indicava uma baixa possibilidade de ocorrência de tempestades severas.

Para os dias 14 e 24 de Janeiro de 2017, as melhores performances obtidas na previsão de chuva acumulada em 24 horas foram desempenhadas, em geral, pelo modelo WRF inicializado com as análises do 3DEnVar e EnKF sobre os pontos das estações meteorológicas do INMET, sobre o estado do Maranhão (Tabela D.1), conforme retratado pelo cálculo do RMSE e dos índices da tabela de contingência. Apesar disso, nenhuma das previsões executadas com as análises dos sistemas de assimilação de dados aqui avaliados e experimentos sem atualização das condições iniciais, indicaram a possibilidade de chuvas intensas, apenas de intensidade moderada. Dentre os fatores que justificam a subestimativa das previsões de precipitação por meio dos diferentes experimentos sobre os municípios de Barra da Corda e Colinas, no Maranhão, destaca-se a escolha de um esquema de microfísica das nuvens e parametrizações da CLP que melhor simulasse os eventos extremos de chuva sobre o NEB, que no presente trabalho, foram escolhidas baseando-se nos trabalhos de Nobre et al. (2019) e Sun e Bl (2019).

Assim, como resposta a hipótese da Seção 1.2, **os resultados dos experimentos realizados no âmbito do presente trabalho, mostram a sensibilidade e o benefício de incorporar os erros do dia em uma análise variacional através de um algoritmo híbrido como o 3DEnVar. Conforme demonstrado nos resultados, quando as previsões de chuvas pelo modelo WRF inicializado**

com as análises provenientes do EnKF, 3DVar e do GEFS apresentaram performance em geral inferiores, os experimentos inicializados com as análises do 3DEnVar foram capazes de produzir acumulados de chuva diário sobre as áreas com registro de chuvas intensas, mais próximos das observações, para os dois casos de SCM analisados. Essa constatação, permite concluir que a incorporação dos erros do dia, provenientes de um conjunto de análises geradas pelo EnKF ao 3DVar, por meio de um sistema de assimilação híbrido, mostrou-se como um mecanismo importante na amostragem das variações diárias dos erros do modelo durante as previsões de eventos de chuvas intensas associadas a SCM sobre o NEB.

4.0.1 Recomendações para trabalhos futuros

No presente trabalho, as limitações computacionais e tempo de integralização da dissertação contribuíram para que alguns aspectos dos sistemas de assimilação de dados fossem abordados superficialmente, porém, isso não minimiza o caráter relevante dos mesmos. Dessa forma, a realização de mais estudos que complementem o projeto, aqui, desenvolvido, contribuirá para criar um vasto material de consulta, assim como novas metodologias e/ou mecanismos de avaliação complementares aos expostos no presente trabalho. Dessa forma, como sugestão para trabalhos futuros, recomenda-se:

- explorar o uso de diferentes parametrizações de microfísica do modelo WRF, no sentido de verificar quais são as melhores na reprodução de eventos de chuva sobre o domínio escolhido;
- criar um algoritmo para o sistema híbrido que possua capacidade de atualizar os pesos das matrizes envolvidas na combinação linear do 3DEnVar de forma adaptativa, ou seja, ao longo dos ciclos de assimilação e avaliar seu impacto;
- obtenção de uma nova matriz climatológica para o 3DVar que represente melhor os erros do modelo para o período a ser estudado;
- verificar a sensibilidade do sistema híbrido ao ser executado com diferentes quantidades de membros de previsão do modelo GEFS;
- realizar testes para entender o impacto dos parâmetros de inflação e localização no 3DEnVar;

- avaliar o impacto da assimilação de dados de superfície no modelo WRF para o estudo de episódios de chuvas intensas;
- utilizar outros índices estatísticos, como o *Fractions Skill Score* (FSS), para avaliar a performance das previsões de chuva obtidas pelos modelos atmosféricos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDREOLI, R. V.; FERREIRA, S. H. S.; SAPUCCI, L. F.; SOUZA, R. A. F.; MENDONÇA, R. W. B.; HERDIES, D. L.; AARAVÉQUIA, J. A. Contribuição de diversos sistemas de observação na previsão de tempo no CPTEC/INPE. **Revista Brasileira de Meteorologia**, v. 23, n. 2, p. 219–238, 2008. 14
- ARAKAWA, A.; LAMB, V. R. Computational design of the basic dynamical process of the ucla general circulation model. **Methods Computational Physics**, v. 17, p. 173–265, 1977. 28
- BASTARZ, C. F. **Assimilação de dados global híbrida por conjunto-variacional no CPTEC**. 122 p. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017. 16, 19, 36
- BAUER, P.; THORPE, A.; BRUNET, G. The quiet revolution of numerical weather prediction. **Nature**, v. 525, n. 7567, p. 47–55, 2015. 3
- BERGTHÓRSSON, P.; DOOS, B. R. Numerical weather map analysis. **Tellus**, v. 7, n. 3, p. 329–340, 1955. 13, 50
- BIERMAN, G. **Factorization methods for discrete sequential estimation**. New York: Academic Press, 1977. 38
- BJERKNES, V. Das problem der wettervorhersage, betrachtet vom standpunkte der mechanik und der physik. **Meteorologische Zeitschrift**, v. 21, p. 1–7, 1904. 10
- BRASSEUR, P. Ocean data assimilation using sequential methods based on the Kalman filter. **Ocean Weather Forecasting**, p. 271–216, 2006. 3
- BUEHNER, M. Ensemble–derived stationary and flow–dependent background–error covariances: evaluation in a quasi–operational nwp setting. **Quarterly Journal of the Royal Meteorological Society**, v. 131, n. 607, p. 1013–1043, 2005. 4
- CARVALHO, M. A. V. D.; ABRUNHOSA, M. L.; LOPES, J. R. O. **Manual de instalação, compilação e execução do modelo de mesoescala WRF no ICEA (versão 3.4.1)**. São José dos Campos: PBCA/ICEA, 2013. 24, 25
- CHARNEY, J. G.; FJÖRTOFT; NEUMANN, J. R. Numerical integration of the barotropic vorticity equation. **Tellus**, v. 2, n. 4, p. 237–254, 1950. 12

- CINTRA, R.; COCKE, S. A local ensemble transform Kalman filter data assimilation system for the global FSU atmospheric model. **Journal of Mechanics Engineering and Automation**, p. 186–196, 2015. 42
- CLARK, A. J.; GALLUS, W. A.; XUE, M.; KONG, F. Convection-allowing and convection-parameterizing ensemble forecasts of a mesoscale convective vortex and associated severe weather environment. **Weather And Forecasting**, v. 25, n. 4, p. 1052–1081, 2010. 95, 116
- CLAYTON, A. M.; LORENC, A. C.; BARKER, D. M. Operational implementation of a hybrid ensemble/4D–var global data assimilation system at the Met Office. **Quarterly Journal of the Royal Meteorological Society**, v. 139, n. 675, p. 1445–1461, 2012. 19
- COHEN, A. E.; CAVALLO, S. M.; CONIGLIO, M. C.; BROOKS, H. E. A review of planetary boundary layer parameterization schemes and their sensitivity in simulating southeastern U.S. cold season severe weather environments. **Weather and Forecasting**, v. 30, p. 591–612, 2015. 32
- CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS - CNM. **Situação de emergência: seca e chuva trazem danos à população de 19 Municípios**. 2017. Disponível em: <<https://www.cnm.org.br/>>. Acesso em: 15 jan. 2020. 1
- CORDEIRO, E. S.; FEDOROVA, N.; LEVIT, V. Análise sinótica e termodinâmica dos eventos com trovoadas para o Estado de Alagoas no período de 15 anos 1998-2012. **Revista Brasileira de Meteorologia**, v. 33, n. 4, p. 686–694, 2018. 89
- COURANT, R.; FRIEDRICHS, K.; LEWY, H. Ber die partiellen differenzgleichungen der mathematischen physik. **Mathematische Annalen**, v. 100, n. 1, p. 32–74, 1928. 12
- COUTINHO, M. M. **Previsão por conjuntos utilizando perturbações baseadas em componentes principais**. 136 p. Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999. 17
- CRESSMAN, G. P. An operational objective analysis system. **Monthly Weather Review**, v. 87, n. 10, p. 367–374, 1959. 13
- DEMIDOV, S. S. **Leonhard Euler, Treatise on the differential calculus**. 2. ed. Amsterdam: Elsevier, 2005. Cap. 14. 10

- DEVELOPMENTAL TESTBED CENTER. **EnKF User's Guide**. 2015. Disponível em: <https://dtcenter.ucar.edu/EnKF/users/docs/enkf_users_guide/EnKF_UserGuide_v1.0.pdf>. Acesso em: 15 jan. 2021. 39
- ELIASSEN, A. Provisional report on calculation of spatial covariance and autocorrelation of the pressure field. **Weather And Climate**, v. 5, p. 10, 1954. 14
- EPSTEIN, E. S. Stochastic dynamic prediction. **Tellus**, v. 21, n. 6, p. 739–759, 1969. 17
- ETHERTON, B. J.; BISHOP, C. H. Resilience of hybrid ensemble/3dvar analysis schemes to model error and ensemble covariance error. **Monthly Weather Review**, v. 132, n. 5, p. 1065–1080, 2004. 18
- EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS - ECMWF. **Data availability**. 2018. Disponível em: <<https://confluence.ecmwf.int/display/TCBUF/Data+availability>>. Acesso em: 02 de janeiro 2021. 11
- EVENSEN, G. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte-Carlo methods to forecast error statistics. **Journal of Geophysical Research**, v. 99, n. C.5, p. 10, 1994. 18
- FEDOROVA, N. **Sinótica IV - sistemas e processos sinóticos**. Maceió: EDUFAL, 2008. 7, 9
- FEDOROVA, N. N.; LEVIT, V. I.; RODRIGUES, L. R. L.; COSTA, S. B. Mesoscale convective complex genesis and forecast in Alagoas State of Brazil. **Journal of the Georgian Geophysical Society**, v. 12, p. 36–44, 2008. 9
- FEDOROVA, N. N.; LEVIT, V. I.; SILVEIRA, M. H. D. S.; SILVA, B. F. P.; AMIRANASHVILI, A. G. Mesoscale convective complex genesis and forecast in Alagoas State of Brazil. **Journal of the Georgian Geophysical Society**, v. 13, p. 36–49, 2009. 9
- FERNANDEZ, J. P. R.; HERDIES, D. L.; BASTARZ, C. F. Inclusão de precipitação no sistema regional de assimilação de dados do CPTEC/INPE. In: CONGRESSO BRASILEIRO DE METEOROLOGIA. **Anais...** [S.l.], 2008. p. 5. 14
- FERREIRA, A. G.; MELLO, N. G. D. S. Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos oceanos Pacífico e

Atlântico no clima da região. **Revista Brasileira de Climatologia**, v. 1, n. 1, p. 15–28, 2005. 7, 8, 9

FISHER, M. **Introduction to data assimilation**. 2015. Disponível em: <https://gmao.gsfc.nasa.gov/events/adjoint_workshop-10/presentations/Fisher.tutorial.pdf>. Acesso em: 21 jan. de 2020. 14, 34, 35

FLATERRY, T. Spectral models for global analysis and forecasting. **Air Weather Service Techn**, p. 12, 1970. 14

FU, Q.; YANG, P.; SUN, W. B. An accurate parameterization of the infrared radiative properties of cirrus clouds for climate models. **Journal of Climate**, v. 11, p. 2223–2237, 1998. 29

GANDIN, L. S. The objective analysis of meteorological fields: Israel program for scientific translations. **Hydrometeoro Press.**, v. 5, p. 10, 1963. 14, 17

GAO, J.; STENSRUD, D. J. Some observing system simulation experiments with a hybrid 3DEnVar system for storm-scale radar data assimilation. **Monthly Weather Review**, v. 142, n. 9, p. 3326–3346, 2014. 19

GILCHRIST, B.; CRESSMAN, G. An experiment in objective analysis. **Tellus**, v. 6, n. 4, p. 309–318, 1954. 13

HAMILL, T. M.; SNYDER, C. A hybrid ensemble kalman filter–3D variational analysis scheme. **Monthly Weather Review**, v. 128, n. 8, p. 2905–2919, 2000. 4, 18

HAN, J.; PAN, H. L. Revision of convection and vertical diffusion schemes in the NCEP global forecast system. **Weather and Forecasting**, v. 26, n. 4, p. 520–533, 2011. 26

HANE, C. E. **Extratropical squall lines and rainbands**. 2. ed. Boston: AMS, 1986. Cap. 16. 9

HENRY, J. **Encyclopedia Of world climatology**. Netherlands: Springer, 2005. 21

HONG, S.; LIM, J. The wrf single-moment 6-class microphysic: song-you hong. **Journal of the Korean Meteorological Society**, v. 2, n. 42, p. 129–151, 2006. 26, 30, 31

HONG, S.-Y.; NOH, Y.; DUDHIA, J. A. New vertical diffusion package with an explicit treatment of entrainment processes. **Monthly Weather Review**, v. 134, n. 9, p. 2318–2341, 2006. 26

HOU, T.; KONG, F.; CHEN X.AND LEI, H. Impact of 3DVar data assimilation on the prediction of heavy rainfall over southern China. **Advances in Meteorology**, v. 2013, p. 17, 2013. 16

HOUZE, R. A. Mesoscale convective systems. **Reviews of Geophysics**, p. 42, 2004. 7

HU, M.; BENJAMIN, S. G.; LADWIG, T. T.; DOWELL D, C.; WEYGANDT, S. S.; ALEXANDER, C. R.; WHITAKER, J. S. Gsi three-dimensional ensemble–variational hybrid data assimilation using a global ensemble for the regional rapid refresh model. **Monthly Weather Review**, v. 145, p. 4205–4225, 2017. 50, 53, 115

HU, M.; GE, G.; ZHOU, C.; STARK, D.; SHAO, H.; NEWMAN, K.; BECK, J.; ZHANG, X. **Developmental Testbed Center - DTC, 2015: Gridpoint Statistical Interpolation(GSI) user’s guide for version 3.4**. 2015. Disponível em: <<http://www.dtcenter.org/com-GSI/users/docs/index.php>>. Acesso em: 15 jan. 2020. 38

HU, Y. X.; STAMNES, K. An accurate parameterization of the radiative properties of water clouds suitable for use in climate models. **Journal of Climate**, v. 6, p. 728–742, 1993. 29

INSTITUTUTO DE ASTRONOMIA E GEOCIÊNCIAS - IAG. **O que é meteorologia Sinótica?** 2010. Disponível em: <<http://master.iag.usp.br/pr/ensino/sinotica/aula01/>>. Acesso em: 31 de janeiro 2021. 6

KAIN, S. J. The kain–fritsch convective parameterization: an update. **Journal of Applied Meteorology and Climatology**, v. 42, n. 1, p. 170–181, 2004. 26

KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. New York: Cambridge, University Pres, 2003. 13

KLEIST, D. T.; IDE, K. An OSSE-based evaluation of hybrid variational–ensemble data assimilation for the NCEP GFS. part i: system description and 3D-hybrid results. **Monthly Weather Review**, v. 143, n. 2, p. 433–451, 2015. 4, 115

- LAHOZ, W.; KHATTATOV, B.; MENARD, R. **Data Assimilation**: Making sense of observations. New York: Springer, 2009. 42
- LI, Y.; WANG, X.; XUE, M. Assimilation of radar radial velocity data with the WRF hybrid ensemble–3DVar system for the prediction of hurricane Ike (2008). **Monthly Weather Review**, v. 140, n. 11, p. 3507–3524, 2012. 19
- LIN, Y.; FARLEY, R. D.; ORVILLE, H. D. Bulk parameterization of the snow field in a cloud model. **Journal of Climate and Applied Meteorology**, v. 22, n. 6, p. 1065–1092, 1983. 30
- LIU, J.; KALNAY, E. Assimilating specific humidity observations with local ensemble transform Kalman filter. In: 11TH SYMPOSIUM ON INTEGRATED OBSERVING AND ASSIMILATION SYSTEMS FOR THE ATMOSPHERE, OCEANS, AND LAND SURFACE (IOAS-AOLS). **Anais...** [S.l.], 2005. p. 9. 64, 115
- LORENC, A. C. The potential of the ensemble Kalman filter for NWP — a comparison with 4D-Var. **Quarterly Journal of the Royal Meteorological Society**, p. 3183–3203, 2003. 4
- LYNCH, P. Richardson’s marvelous forecast. **American Meteorological Society**, p. 61–73, 1999. 11
- LYRA, M. J. A.; BONFIM, T. O. E.; FEDOROVA, N.; LEVIT, V. Diagnóstico de um complexo convectivo de mesoescala observado no semiárido do nordeste brasileiro. **Revista Brasileira de Geografia Física**, v. 11, n. 6, p. S.I, 2018. 9
- _____. Connection between frontal extremity and intertropical convergence zone on the northeast Brazil. **Anuário do Instituto de Geociências**, v. 42, n. 1, p. S.I, 2019. 9
- LYRA, M. J. A.; CAVALCANTE, L. C. V.; LEVIT, V.; FEDOROVA, N. Complexos convectivos de mesoescala sobre o nordeste do Brasil e fenômenos adversos associados. **Revista Ibero-Americana de Ciências Ambientais**, v. 9, n. 3, p. 95–103, 2017. 9
- MACHADO, L. A. T.; LAURENT, H. The convective system area expansion over Amazônia and its relationships with convective system life duration and high-level wind divergence. **Monthly Weather Review**, v. 132, n. 3, p. 714–725, 2004. 22, 116

MADDOX, R. A. Mesoscale convective complexes. **Bulletin of the American Meteorological Society**, p. 1374–1387, 1980. 8

MAYBECK, P. S. **Stochastic models, estimation, and control**. New York: Academic Press, 1982. 38

MEDEIROS, M. D. S. **Impacto do uso de radiância na assimilação de dados usando 4D-LETKF na região da América do Sul**. 113 p. Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. 14

MITCHELL, K. **The community: noah Land-Surface Model (LSM)**. 2005. Disponível em:
<ftp://ftp.emc.ncep.noaa.gov/mmb/gcp/ldas/noahlsm/ver_2.7.1>. Acesso em: 20 fev. 2020. 32

MORAIS, M. D. C. d.; GAN, M. A. Vórtices ciclônicos em altos níveis sobre o nordeste do Brasil. **Revista Climanálise**, p. 31–36, 2006. 83

MOURA, D. **Fortes chuvas no nordeste causam mortes e transtornos**. 2019. Disponível em: <<https://www.tempo.com/noticias/actualidade/fortes-chuvas-no-nordeste-causam-mortes-e-transtornos.html>>. Acesso em: 20 jan. 2020. 1

NOBRE, J. P. G.; FEDOROVA, N.; LEVIT, V.; SANTOS, A. S.; LYRA, M. J. A. Nova metodologia para previsão de eventos de nevoeiro para o Aeroporto Zumbi dos Palmares em Maceió (Alagoas). **Anuário do Instituto de Geociências - UFRJ**, v. 42, n. 3, p. 527–535, 2019. 25, 116

NOH, Y.; CHEON, W. G.; HONG, S. Y.; RAASCH, S. Improvement of the k-profile model for the planetary boundary layer based on large eddy simulation data. **Boundary-Layer Meteorology**, v. 107, n. 2, p. 401–427, 2003. 33

NORDENG, T. E. Extended versions of the convective parametrization scheme at ecmwf and their impact on the mean and transient activity of the model in the tropics. **ECMWF**, n. 206, p. 41, 1994. 32

PALHARINI, R. S. A.; VILA, D. A. Climatological behavior of precipitating clouds in the northeast region of Brazil. **Advances In Meteorology**, p. 11, 2017. 9

PANOFSKY, R. A. Objective weather-map analysis. **Journal of Meteorology**, v. 6, n. 6, p. 386–392, 1949. 13

PARK, S.-H.; KLEMP, J. B.; KIM, J. H. Hybrid mass coordinate in WRF-ARW and its impact on upper-level turbulence forecasting. **Monthly Weather Review**, v. 147, n. 3, p. 971–985, 2019. 27

PARRISH, D. F.; DERBER, J. C. The national meteorological center's spectral statistical-interpolation analysis system. **Monthly Weather Review**, v. 120, n. 8, p. 1747–1763, 1992. 15, 36

PAZ, A. R. da; COLLISCHONN, W. Avaliação de estimativas de campos de precipitação para modelagem hidrológica distribuída. **Revista Brasileira de Meteorologia**, v. 26, n. 1, p. 109–120, 2011. 44

PHILLIPS, N. A. The general circulation of the atmosphere: A numerical experiment. **Quarterly Journal of the Royal Meteorological Society**, v. 82, n. 352, p. 123–164, 1956. 12

POWERS, J. G.; KLEMP, J. B.; SKAMAROCK W, C.; DAVIS, C. A.; DUDHIA, J.; GILL, D. O.; COEN, J. L.; GOCHIS, D. J. The weather research and forecasting model: overview, system efforts, and future directions. **Bulletin of the American Meteorological Society**, v. 98, n. 8, p. 1717–1737, 2017. 24

RICHARDSON, L. F. The approximate arithmetical solution by finite differences of physical problems involving differential equations, with an application to the stresses in a Masonry Dam. **Philosophical Transactions of the Royal Society of London. Series A**, v. 210, p. 307–357, 1911. 12

_____. The problem of weather prediction, considered from the viewpoints of mechanics and physics. **Quarterly Journal of the Royal Meteorological Society**, v. 48, n. 203, p. 282–284, 1922. 11

RINALDY, N.; SARAGIH, I. J. A.; PUTRA, A. W.; NUGRAHENI I, R.; YONAS, B. W. **Identification of Mesoscale Convective Complex (MCC) phenomenon with image of Himawari 8 Satellite and WRF ARW Model on Bangka Island (case study: 7-8 February 2016)**: Iop conference series: Earth and environmental science. S.I: IOP Publishing, 2017. 8

ROCHA, A. P. B.; DANTAS, E. M.; MORAIS, I. R. D.; OLIVEIRA, M. S. D. **Geografia do Nordeste**. Rio Grande do Norte: EDUFRN, 2011. 8

ROZANTE, J. R.; MOREIRA, D. S.; GONÇALVES, L. G. G. de; VILA, D. A. Combining TRMM and surface observations of precipitation: technique and

validation over South America. **American Meteorological Society**, v. 25, p. 885–893, 2010. 80

RUTLEDGE, S. A.; HOBBS, P. V. The mesoscale and microscale structure and organization of clouds and precipitation in midlatitude cyclones. **Journal of the Atmospheric Sciences**, v. 41, n. 20, p. 2949–2972, 1984. 30

SAPUCCI, L. F.; HERDIES D. L. AND MATTOS, J. G. Z.; GONÇALVES, L. G. G.; FERNÁNDEZ, J. P. R.; LIMA, S. S. T.; ARAVEQUIA, J. A. Reanálise regional do CPTEC de 2000-2009 com resolução de 20 km sobre a América do Sul. In: CONGRESSO BRASILEIRO DE METEOROLOGIA. **Anais...** [S.l.], 2010. p. 4. 14

SAPUCCI, L. F.; MONICO J. F. G. AND MACHADO, L. A. T.; HERDIES, D. L.; SOUZA, R. A. F. Assimilação do IWV-GPS no Brasil: otimização das estimativas do atraso zenital troposférico em tempo real. **Revista Brasileira de Geofísica**, v. 25, n. 3, p. 268–279, 2007. 14

SASAKI, Y. An objective analysis based on the variational method. **Journal of the Meteorological Society of Japan**, v. 36, n. 3, p. 77–88, 1958. 14

_____. Some basic formalisms in numerical variational analysis. **Monthly Weather Review**, v. 98, n. 12, p. 875–883, 1970. 14

SHAO, H.; NEWMAN, K. **Task 3.3.2: GSI testing and evaluation**. 2019. Disponível em: <https://dtcenter.ucar.edu/eval/data_assim/reports/fy13_DTC_3_3_2_hs.pdf>. Acesso em: 20 jan. 2020. 77

SILVA, A. D.; GUO, D. J. **Documentation of the Physical-space Statistical Analysis System (PSAS) Part I: The Conjugate Gradient Solver Version PSAS-1.00**. 1996. Disponível em: <<http://dao.gsfc.nasa.gov/subpages/office-notes.html>>. Acesso em: 18 de janeiro de 2020. 14

SILVA, M. T.; ALCÂNTARA, C. R.; SOUZA, E. P. D.; OLINDA, R. A.; GONÇALVES, W. A. Influência da temperatura da superfície do mar na ocorrência de linhas de instabilidade na costa norte e nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 32, n. 2, p. 260–268, 2017. 9

- SOUZA, E. B.; ALVES, J. M. B.; REPELLI, C. A. Um complexo convectivo de mesoescala associado à precipitação intensa sobre Fortaleza-CE. **Revista Brasileira de Meteorologia**, v. 13, n. 2, p. 13, 1998. 8
- SUN, B. Y.; BL, X. Q. Validation for a tropical belt version of wrf: sensitivity tests on radiation and cumulus convection parameterizations. **Atmospheric and Oceanic Science Letters**, v. 12, n. 3, p. 192–200, 2019. 25, 116
- TALAGRAND, O. Assimilation of observations, an introduction (gtspecial issueltdata assimilation in meteorology and oceanography: theory and practice). **Journal of the Meteorological Society of Japan**, v. 75, n. 1, p. 191–209, 1997. 13
- TEWARI, M. F.; CHEN, W.; WANG, J.; DUDHIA, M. A.; LEMONE, K.; MITCHELL, M. E.; GAYNO, G.; WEGIEL, J.; CUENCA, R. H. Implementation and verification of the unified noah land surface model in the WRF model. **Conference on Weather Analysis and Forecasting**, p. 11–15, 2004. 26
- TIEDTKE, M. A. A comprehensive mass flux scheme for cumulus parameterization in larger- scale model. **Monthly Weather Review**, v. 117, p. 1779–1800, 1989. 26, 31
- TODLING, R. Comparing two approaches for assessing observation impact. **Monthly Weather Review**, v. 1484, p. 1484–1505, 2013. 42
- TONG, W.; LI, G.; SUN, J.; TANG, X.; ZHANG, Y. Design strategies of an hourly update 3DVar data assimilation system for improved convective forecasting. **Weather and Forecasting**, v. 31, n. 5, p. 1673–1695, 2016. 16
- UNIVERSITY OF BRITISH COLUMBIA - UBC. **Mesoscale Convective Systems**. 2020. Disponível em: <<https://www.eoas.ubc.ca/>>. Acesso em: 02 de janeiro 2021. 7
- VENDRASCO, E. P.; SUN, J.; HERDIES, D. L.; ANGELIS, C. F. Constraining a 3DVar radar data assimilation system with large-scale analysis to improve short-range precipitation forecasts. **Journal of Applied Meteorology and Climatology**, v. 55, n. 3, p. 673–690, 2016. 16
- XIE, B.; FUNG, J. C.-H.; CHAN, A.; LAU, A. K.-H. Evaluation of nonlocal and local planetary boundary layer schemes in the wrf model. **Climate and Dynamic**, v. 117, p. 26, 2012. 33

ZHANG, S.; WANG, J. Considering the impact of observation error correlation in ensemble square-root Kalman filter. **Brazilian Journal of Oceanography**, v. 5, p. 14, 2019. 42

ZHANG, C.; WANG, Y. Projected future changes of tropical cyclone activity over the western north and south pacific in a 20-km-mesh regional climate model. **Journal of Climate**, v. 30, n. 15, p. 5923–5941, 2017. 26, 31

ZHANG, C.; WANG, Y.; HAMILTON, K. Representation of boundary layer clouds over the southeast pacific in ARW-WRF using a modified tiedtke cumulus parameterization scheme. **Monthly Weather Review**, v. 139, n. 11, p. 3489–3513, 2011. 31, 32

ZHANG, F.; ZHANG, M.; HANSEN, J. Coupling ensemble kalman filter with four-dimensional variational data assimilation. **Advances in Atmospheric Sciences**, v. 26, n. 1, p. 1–8, 2009. 19

ZHANG, Z.; KRISHNAMURTI, T. N. A. Perturbation method for hurricane ensemble predictions. **Monthly Weather Review**, v. 127, n. 4, p. 447–469, 1999. 17

ZIPSER, E. J. Mesoscale and convective–scale downdrafts as distinct components of squall-line structure. **Monthly Weather Review**, v. 105, n. 12, p. 1568–1589, 1977. 8

_____. Life cycle of mesoscale convective systems. In: NOWCASTING: MESOSCALE OBSERVATIONS AND SHORT-RANGE PREDICTION, PROCEEDINGS OF AN INTERNATIONAL SYMPOSIUM. **Proceedings...** [S.l.], 1981. p. 381–386. 7

APÊNDICE A - ESPECIFICIDADES DO SISTEMA

A Tabela A.1 refere-se ao espaço ocupado pelos principais arquivos de dados e pastas essenciais para o funcionamento do Sistema de Modelagem Regional (SMR). Essas informações são úteis para eventuais adaptações no código, bem como na otimização do espaço em máquina ocupado pelos principais arquivos de dados do sistema. Observe que o asterisco (*) denota o espaço ocupado pelos arquivos individualmente, durante a execução do SMR. Dependendo da quantidade de membros inicialmente fornecidos, assim como a quantidade de ciclos de assimilação e previsão desempenhados pelo SMR, estes valores poderão aumentar substancialmente.

Tabela A.1 - Espaço ocupado pelos principais componentes de dados do SMR com o 3DEnVar habilitado.

Pasta/ arquivo no sistema*	Espaço ocupado no sistema
Dado do GEFS*	26 Mb
Dado pré-processado pelo WRF*	359 Mb
Dado da Análise Gerada pelo WRF*	359 Mb
Dados de saída da previsão de 72 h*	26 Gb
Dados de saída da previsão de 48 h*	18 Gb
Dados de saída da previsão de 24 h*	8,8 Gb
Sistema de Modelagem Regional	4 Gb

APÊNDICE B - TEMPO DE EXECUÇÃO DO SMR

A Tabela B.1 refere-se ao tempo de execução do SMR para diferentes configurações, observe que com 720 processadores o tempo de execução dos sistemas que usam a assimilação e previsões por conjunto de 72 horas, o caso do EnKF+WRF e 3DEnVar+WRF, ultrapassam 8,5 horas, o que demonstra que para operacionalizar um sistema de assimilação de dados por conjunto será necessário contar com uma maior quantidade de processadores a fim de obter previsões meteorológicas dentro de um tempo hábil para ser utilizado pelos meteorologistas na operação. Igualmente, dependendo da quantidade de trabalhos (*jobs*) submetidos na Tupã proveniente de diversos projetos esses valores podem oscilar para mais ou para menos, conforme retratado na Tabela (B.1) para os experimentos do EnKF e 3DEnVar, onde o SMR+EnKF superou o tempo de execução do SMR+3DEnVar ao realizar previsões de 72 horas.

Tabela B.1 - Tempo de execução do SMR com o WRF, EnKF+WRF, 3DVar+WRF e 3DEnVar+WRF para 72, 48 e 24 h de previsão.

Configuração do SMR + HH (horas)	Tempo de execução completa sistema
WRF + 24 h	00h16m33s
WRF + 48 h	00h23m17s
WRF + 72 h	00h28m23s
EnKF + WRF + 24 h	04h02m17s
EnKF + WRF + 48 h	05h23m04s
EnKF + WRF + 72 h	09h47m17s
3DVar + WRF + 24 h	00h29m30s
3DVar + WRF + 48 h	00h34m53s
3DVar + WRF + 72 h	00h42m43s
3DEnVar + WRF + 24 h	04h35m51s
3DEnVar + WRF + 48 h	05h55m27s
3DEnVar + WRF + 72 h	08h31m05s

APÊNDICE C - ESPALHAMENTO DO CONJUNTO DE MEMBROS DO 3DENVAR

Uma forma de verificar o espalhamento do conjunto de membros de previsão fornecidos ao sistema de assimilação de dados é comparar o desvio padrão da inovação ($innov$) com a raiz quadrada do espalhamento total ($\sqrt{S+R}$), na Tabela C.1, este último, é definido como a raiz quadrada da soma do espalhamento do conjunto com o erro da observação. Na prática, esse procedimento está verificando se há alguma deficiência substancial no espalhamento do conjunto, tendo em vista que ao longo dos ciclos de assimilação, espera-se que os erros do modelo sejam corrigidos e, conseqüentemente, as diferenças entre a inovação e o espalhamento total se aproximem.

Conforme observado pela Tabela C.1, em geral, os dados de pressão superficial, temperatura e velocidade do vento apresentaram uma inovação próxima à raiz quadrada do espalhamento total, e ao evoluírem no tempo, as diferenças entre as inovações e o espalhamento adquiriram um equilíbrio, indicando a obtenção de análises bem condicionadas em representar os erros do modelo. Nos campos de umidade, ocorreu exatamente o oposto, ocorreram discrepâncias consideráveis entre as inovações e o espalhamento total e, além disso, diferenças entre as inovações e o espalhamento, ao longo dos ciclos de assimilação, não obtiveram um equilíbrio conforme constatado nos campos de pressão, temperatura e velocidade do vento, e isso pode resultar em análises deficientes em termos de correção dos erros de previsão.

Tabela C.1 - Espalhamentos dos membros do conjunto fornecidos ao sistema de assimilação de dados híbrido (3DEnVar) referente ao experimento SCM1 obtidos através do desvio-padrão da inovação (innov) e o desvio dos membros do conjunto somado aos erros da observação para os campos de pressão superficial (ps) em Pa, temperatura (t) em K, velocidade do vento zonal e meridional (uv) em m/s e umidade específica (q) em g/kg.

Desvio Padrão dos Campos				
Ciclos	innov (ps)	sqrt(S+R) (ps)	innov (t)	sqrt(S+R) (t)
1	0,916E+00	0,113E+01	0,177E+01	0,357E+01
2	0,854E+00	0,103E+01	0,968E+00	0,106E+01
3	0,101E+01	0,104E+01	0,170E+01	0,313E+01
4	0,978E+00	0,105E+01	0,119E+01	0,280E+01
5	0,101E+01	0,108E+01	0,189E+01	0,333E+01
6	0,803E+00	0,102E+01	0,112E+01	0,267E+01
7	0,991E+00	0,100E+01	0,203E+01	0,228E+01
8	0,101E+01	0,106E+01	0,152E+01	0,540E+01
9	0,118E+01	0,110E+01	0,187E+01	0,335E+01
Ciclos	innov (uv)	sqrt(S+R) (uv)	innov (q)	sqrt(S+R) (q)
1	0,231E+01	0,463E+01	0,133E+00	0,206E+03
2	0,177E+01	0,444E+01	0,586E-01	0,518E-01
3	0,249E+01	0,430E+01	0,139E+00	0,162E+03
4	0,168E+01	0,428E+01	0,354E-01	0,393E-01
5	0,252E+01	0,437E+01	0,159E+00	0,241E+03
6	0,180E+01	0,408E+01	0,122E+00	0,412E-01
7	0,248E+01	0,414E+01	0,158E+00	0,101E+03
8	0,186E+01	0,431E+01	0,416E-01	0,484E-01
9	0,294E+01	0,447E+01	0,162E+00	0,227E+03

Similar aos experimentos ilustrados na Tabela C.1, os resultados obtidos ao longo dos ciclos de assimilação de dados referente ao experimento SCM2 (Tabela C.2) apresentaram diferenças pequenas entre as inovações e a raiz quadrada do espalhamento total para a pressão superficial, temperatura e vento, que foram estáveis ao longo dos ciclos de assimilação, indicando que o sistema obteve análises bem condicionadas em corrigir os erros do modelo. Para os campos de umidade, similar ao que foi constatado na Tabela C.1, verificou-se uma situação oposta, ou seja, diferenças significativas entre a inovação e a raiz quadrada do espalhamento total do conjunto

e das observações, além de diferenças pouco equilibradas entre as inovações e o espalhamento total, ao longo dos ciclos de assimilação, o que pode contribuir para que os erros associados a previsão do modelo WRF se reproduzam nas análises do experimento SCM2.

Tabela C.2 - Espalhamentos dos membros do conjunto fornecidos ao sistema de assimilação de dados híbrido (3DEnVar) referente ao experimento SCM2 obtidos através do desvio padrão da inovação (innov) e o desvio dos membros do conjunto somado aos erros da observação para os campos de pressão superficial (ps) em Pa, temperatura (t) em K, velocidade do vento zonal e meridional (uv) em m/s e umidade específica (q) em g/kg.

Desvio Padrão dos Campos				
Ciclos	innov (ps)	sqrt(S+R) (ps)	innov (t)	sqrt(S+R) (t)
1	0,847E+00	0,116E+01	0,173E+01	0,359E+01
2	0,968E+00	0,103E+01	0,917E+00	0,294E+01
3	0,911E+00	0,109E+01	0,176E+01	0,365E+01
4	0,953E+00	0,107E+01	0,128E+01	0,618E+01
5	0,101E+01	0,110E+01	0,185E+01	0,407E+01
6	0,855E+00	0,102E+01	0,544E+00	0,346E+01
7	0,972E+00	0,105E+01	0,166E+01	0,375E+01
8	0,101E+01	0,109E+01	0,649E+00	0,160E+01
9	0,115E+01	0,115E+01	0,168E+01	0,377E+01
Ciclos	innov (uv)	sqrt(S+R) (uv)	innov (q)	sqrt(S+R) (q)
1	0,219E+01	0,504E+01	0,140E+00	0,235E+03
2	0,208E+01	0,549E+01	0,645E-01	0,486E-01
3	0,245E+01	0,470E+01	0,137E+00	0,256E+03
4	0,178E+01	0,479E+01	0,454E-01	0,504E-01
5	0,257E+01	0,504E+01	0,158E+00	0,289E+03
6	0,181E+01	0,457E+01	0,590E-01	0,480E-01
7	0,234E+01	0,435E+01	0,183E+00	0,227E+03
8	0,200E+01	0,452E+01	0,132E-01	0,417E-01
9	0,276E+01	0,452E+01	0,188E+00	0,262E+03

APÊNDICE D - COORDENADAS GEOGRÁFICAS DAS ESTAÇÕES METEOROLÓGICAS

As coordenadas geográficas das estações meteorológicas do INMET sobre o estado do Maranhão, utilizadas para avaliar a performance dos acumulados de chuva pelo modelo WRF são ilustradas na Tabela D.1.


Tabela D.1 - Coordenadas geográficas das estações meteorológicas, sobre o estado do Maranhão, com dados disponíveis para os dias 14 e 24 de janeiro de 2017, quando ocorreram os SCM.

Cidade	Latitude	Longitude
Alto Parnaíba	-9,10	-45,93
Bacabal	-4,21	-44,76
Balsas	-7,53	-46,03
Barra da Corda	-5,50	-45,23
Carolina	-7,33	-47,46
Caxias	-4,86	-43,35
Chapadinha	-3,73	-43,35
Colinas	-6,03	-44,25
São Luís	-2,53	-44,21
Zé Doca	-3,26	-45,65

APÊNDICE E - NÚMERO DE OBSERVAÇÕES CONSIDERADAS PARA ASSIMILAÇÃO NO GSI

A Figura E.1 ilustra a quantidade típica de observações em superfície consideradas para assimilação no GSI. Note que o número de observações consideradas para assimilação no dia 12 de janeiro de 2017, às 00 UTC (SCM1) foi superior à do dia 22 de janeiro de 2017 (SCM2), às 00 UTC para os campos de pressão superficial (hPa), temperatura (K), umidade específica (g/kg) e vento zonal e meridional (m/s).

Figura E.1 - Número de observações de pressão superficial (P, em Pa), temperatura (T, em K), umidade específica (Q, em g/kg) e velocidade do vento zonal e meridional (UV, em m/s) assimilados no GSI nos dias 12 (SCM1) e 22 (SCM2) de janeiro de 2017, às 00 UTC.

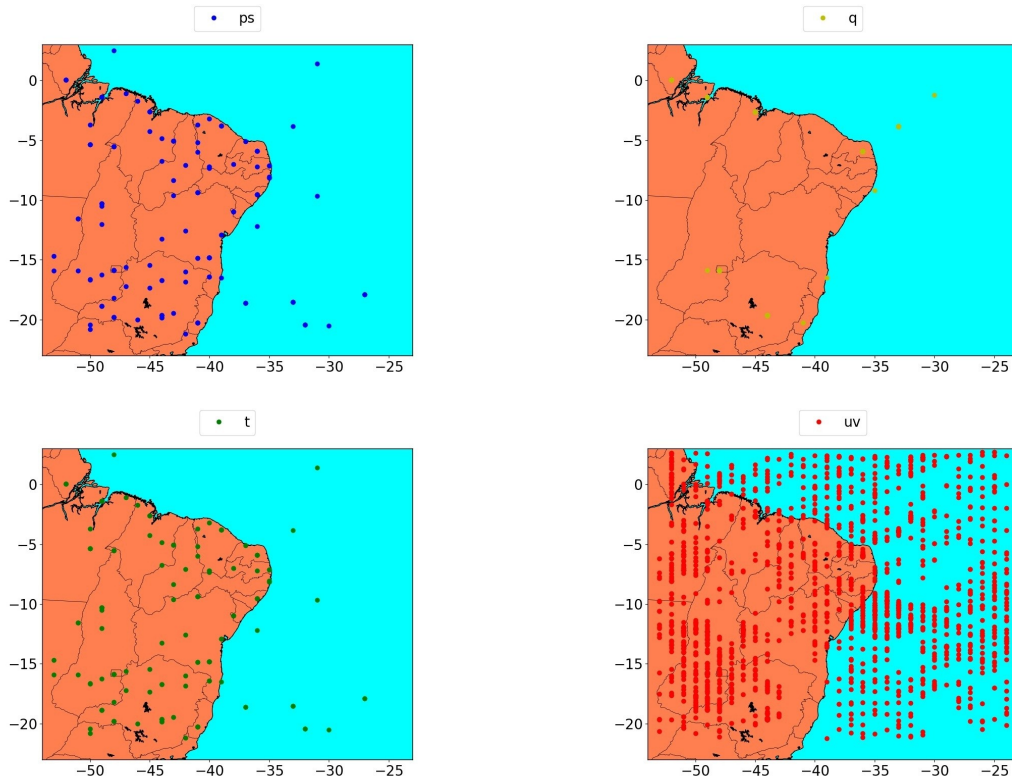


No dia 12 e 22 de janeiro de 2017, às 00 UTC, a quantidade de dados assimilados referente à pressão superficial, umidade específica e temperatura foram as mesmas para todos os sistemas de assimilação de dados (3DVar, EnKF e 3DEnVar). Por outro lado, o número de dados de velocidade do vento assimilados pelo 3DEnVar foi o maior dentre os sistemas avaliados, com um valor superior a 4000 observações, para o dia 12 de janeiro de 2017, às 00 UTC (experimento SCM1), e em torno de 3000 observações, para o dia 22 de janeiro de 2017, às 00 UTC, pelo 3DEnVar e o EnKF.

A maior quantidade de dados de velocidade do vento assimilados pelo 3DEnVar, 3DVar e EnKF, se comparado com as demais observações de temperatura, pressão superficial e umidade específica, é justificado pela maior cobertura de dados para esta variável sobre os continentes e oceanos, que incluem observações provenientes de estações meteorológicas em superfície, radiossondagens e dados de vento estimados por satélites meteorológicos.

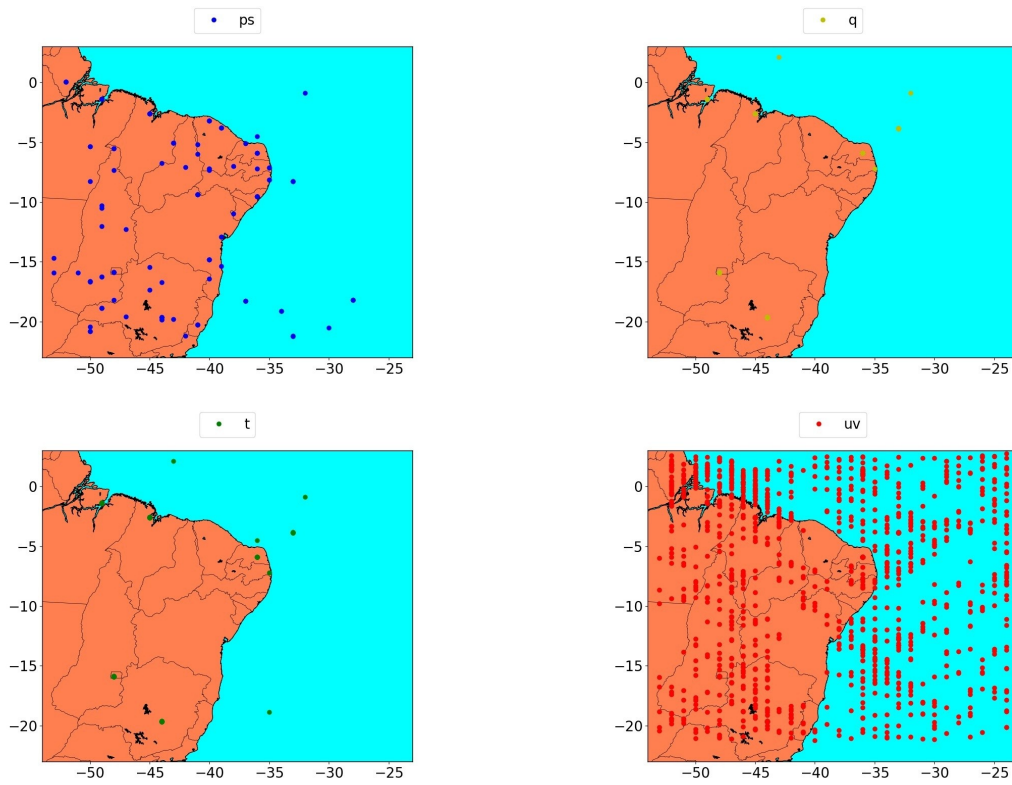
A Figura E.2 ilustra a quantidade de observações convencionais assimiladas pelo GSI no dia 12 de janeiro de 2017, às 00 UTC, para todos os níveis na vertical (1000-0 hPa).

Figura E.2 - Distribuição dos dados de pressão (PS, hPa), umidade específica (Q, g/kg), temperatura (T, K), vento zonal e meridional (UV, m/s) disponíveis para assimilação no dia 12 de janeiro de 2017 (SCM1), às 00 UTC.



A Figura E.3 ilustra a quantidade de observações convencionais assimiladas pelo GSI no dia 22 de janeiro de 2017, às 00 UTC, para todos os níveis na vertical (1000-0 hPa). Observe que em geral, as os dados assimilados no dia 12 de janeiro de 2017, às 00 UTC, Figura E.2, encontravam-se mais uniformemente distribuídos para o domínio sobre o NEB, quando comparado com o dia 22 de janeiro de 2017, às 00 UTC, Figura E.3.

Figura E.3 - Distribuição dos dados de pressão (PS, hPa), umidade específica (Q, g/kg), temperatura (T, K), vento zonal e meridional (UV, m/s) disponíveis para assimilação no dia 22 de janeiro de 2017 (SCM2), às 00 UTC.



PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Contam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.