



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

sid.inpe.br/mtc-m21b/2017/03.17.13.09-TDI

**MÉTODO DE AVALIAÇÃO ORIENTADA A OBJETO
APLICADO ÀS PREVISÕES DE PRECIPITAÇÃO
SOBRE A AMÉRICA DO SUL**

Arletis Roque Carrasco

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelo Dr.
Luiz Fernando Sapucci, aprovada
em 03 de março de 2017.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3NH9KMB>>

INPE
São José dos Campos
2017

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

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

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

Membros:

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

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

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

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

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

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

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

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

EDITORAÇÃO ELETRÔNICA:

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

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



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

sid.inpe.br/mtc-m21b/2017/03.17.13.09-TDI

**MÉTODO DE AVALIAÇÃO ORIENTADA A OBJETO
APLICADO ÀS PREVISÕES DE PRECIPITAÇÃO
SOBRE A AMÉRICA DO SUL**

Arletis Roque Carrasco

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelo Dr.
Luiz Fernando Sapucci, aprovada
em 03 de março de 2017.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3NH9KMB>>

INPE
São José dos Campos
2017

Dados Internacionais de Catalogação na Publicação (CIP)

Carrasco, Arletis Roque.

C23m Método de avaliação orientada a objeto aplicado às previsões de precipitação sobre a América do Sul / Arletis Roque Carrasco. – São José dos Campos : INPE, 2017.
xxiv + 92 p. ; (sid.inpe.br/mtc-m21b/2017/03.17.13.09-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

Orientador : Dr. Luiz Fernando Sapucci.

1. Precipitação. 2. Técnicas de verificação espacial. 3. Avaliação orientada a objeto. 4. Atributos Geométricos. I.Título.

CDU 551.577(8)



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

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

Aluno (a): **Arletis Roque Carrasco**

Título: "MÉTODO DE AVALIAÇÃO ORIENTADA A OBJETO APLICADO ÀS PREVISÕES DE PRECIPITAÇÃO SOBRE A AMÉRICA DO SUL".

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

Dr. Daniel Alejandro Vila



Presidente / CPTEC / Cachoeira Paulista - SP

Dr. Luiz Fernando Sapucci



Orientador(a) / CPTEC / Cachoeira Paulista - SP

Dr. Nelson Jesus Ferreira



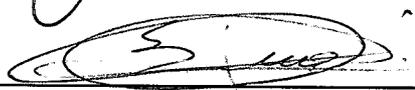
Membro da Banca / CPTEC / Cachoeira Paulista - SP

Dr. João Gerd Zell de Mattos



Membro da Banca / CPTEC / Cachoeira Paulista - SP

Dr. Edmilson Dias de Freitas



Convidado(a) / IAG/USP / São Paulo - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 03 de Março de 2017

“A ciência nunca resolve um problema sem criar pelo menos outros dez”.

GEORGE BERNARD SHAW

A meu esposo, Norlan Capote, pela confiança e amor infinito durante este tempo longe de casa, pelas dicas de programação e por não perder um detalhe deste trabalho.

AGRADECIMENTOS

Agradeço a meu orientador Dr. Luiz Fernando Sapucci que desde o começo foi ousado em aceitar a minha proposta de pesquisa, pela quantidade de conhecimento que me transferiu, as inúmeras ideias e sugestões dadas e as horas que teve que dedicar à revisão exaustiva de tudo o que eu escrevia. Pela orientação e motivação que contribuíram não só para o término deste trabalho, mas para meu crescimento profissional e como pessoa. E pela amizade construída nesses dois anos de mestrado.

A minha família e à família de meu esposo pelo apoio incondicional, carinho, atenção e condições necessárias para que eu pudesse chegar aonde cheguei. Tenho orgulho e satisfação de dizer que esta conquista é também de vocês.

Aos professores do Curso de Pós-Graduação em Meteorologia do INPE pela dedicação, acompanhamento ao longo do curso e conhecimentos transmitidos que contribuíram para meu crescimento científico; ao pessoal da secretaria da PGMET pelo apoio e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) pela concessão da bolsa de estudos.

À Maibys Sierra Lorenzo e ao Israel Borrajero Montejo, pelas sugestões proporcionadas em relação ao algoritmos de Lógica Difusa e *Fill* na identificação de regiões conectadas em campos binários e o uso de listas encadeadas em Fortran. Gostaria de agradecer também à equipe do SCANTEC pelo esforço na organização do ambiente computacional, especialmente o Dr. João Gerd de Mattos e Lucas Amarante Avanço. À Dra. Ariane Frassoni dos Santos e ao Denis Eiras pelas rodadas do modelo BRAMS usadas nesta pesquisa. A Lianet Hernández, Reynier Hernández e Roilan Hernández pelo suporte em relação ao Latex, Fortran e pelas dicas de Linux.

Aos meus colegas e amigos da turma de Mestrado e Doutorado de Meteorologia do INPE do ano 2015, por fazer-me sentir em casa desde o primeiro dia, por corrigir meus erros em português, pelas discussões acadêmicas e por tudo o que compartilhamos nestes dois anos. Todos, sem exceção, tiveram um papel muito importante no meu crescimento. Aos meus amigos, especialmente Lianet Hernández, Mylene Jaen, Lissette Rodríguez, Angel Domínguez, Roilan Hernández, Ivette Hernández e Gonzalo Ferrada, pelas palavras de incentivo e carinho para me manter batalhando dia após dia.

A todos os que contribuíram com a realização deste trabalho, muito obrigada!

RESUMO

O presente estudo tem como objetivo principal, baseado no algoritmo do *Method for Object-Based Diagnostic Evaluation* (MODE), propor e aplicar uma metodologia de avaliação diagnóstica orientada a objeto nas previsões de precipitação sobre a América do Sul. A metodologia proposta foi implementada dentro do Sistema Comunitário de Avaliação de Modelos Numéricos de Previsão de Tempo e Clima (SCANTEC) - este um software estatístico que encontra-se em constante desenvolvimento na Divisão de Modelagem e Desenvolvimento (DMD) do CPTEC/INPE. Um experimentos de casos idealizados permitiu validar a implementação do método e mostrar também as suas vantagens com relação as métricas convencionais de avaliação. Para a aplicação dessa metodologia, como prova de conceito, foram realizados experimentos usando as previsões do modelo BRAMS (*Brazilian Regional Atmospheric Modelling System*) e comparadas com as previsões do modelo GFS (*Global Forecast System*) tendo como valores de referência os dados de precipitação estimados no produto 3B42RT do *TRMM Multisatellite Precipitation Analysis* (TMPA). Duas análises foram realizadas, uma primeira usando o acumulado de precipitação de 6 horas com previsões de até 24 horas de integração e uma segunda usando o acumulado de 24 horas de precipitação com integração dos modelos de 96 horas. Ambos modelos apresentam uma ligeira tendência de degradação do desempenho com a integração no tempo, subestimando a quantidade de objetos observados errando mais por falhas do que por alarmes falsos. A aplicação da metodologia de avaliação de precipitação orientada a objeto aqui proposta, inédita para as previsões geradas no CPTEC, evidenciou a seu potencial para caracterizar os padrões espaciais das previsões de precipitação fornecidas por esse centro permitindo comparações mais justas com outros produtos disponíveis.

Palavras-chave: Precipitação. Técnicas de verificação espacial. Avaliação orientada a objeto. Atributos Geométricos.

METHOD OF OBJECT-BASED EVALUATION APPLIED TO PRECIPITATION FORECASTS OVER SOUTH AMERICA

ABSTRACT

The present study has as the main objective, based on the Method for Object-Based Diagnostic Evaluation (MODE) algorithm, to propose and apply a methodology of object-based diagnostic evaluation to precipitation forecasts over South America. The proposed methodology was implemented within code of the Community System for the Evaluation of Numerical Models of Weather and Climate Prediction (SCANTEC), which is a statistical software that is constantly in development at CPTEC/INPE. An idealized case study allowed validating the methodology implemented and also showed the advantages over conventional evaluation metrics. For the application of this methodology, as proof of concept, experiments were carried out using BRAMS (Brazilian Regional Atmospheric Modelling System) models forecasts and compared with the predictions of the GFS (Global Forecast System) model using as reference values the estimated precipitation data in the TRMM Multisatellite Precipitation Analysis (TMPA) 3B42RT product. Two analyses were performed: the first using 6-hour precipitation accumulated with forecasts up to 24 hours of integration, and the second using 24-hour precipitation accumulated with models integration of the 96 hours. Both models present a slight tendency of skill degradation in function of model integration time, underestimating the amount of observed objects. They failed more by misses than by false alarms. The application of the precipitation objective-based evaluation methodology proposed here, unpublished for CPTEC forecasts, demonstrated its potential to characterize the spatial patterns of precipitation forecasts provided by this center allowing fairer comparisons with other available products.

Keywords: Precipitation Forecasting. Spatial verification techniques. Object-Based evaluation. Geometrics Attributes.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Exemplo da aplicação do MODE na identificação de objetos em um campo de precipitação, <i>a</i>) é o campo original, <i>b</i>) é o campo obtido no processo de convolução, <i>c</i>) é a máscara binária obtida depois da limiarização e <i>d</i>) é o campo objeto.	22
3.1 Diagrama das chamadas da rotina principal do SCANTEC, responsável por integrar as diferentes etapas que compõem o processo de avaliação dos modelos: configuração do sistema, leitura dos arquivos de previsões dos modelos, acesso a dados adicionais usados na avaliação, aplicação de métricas estatísticas, totalização e disponibilização dos resultados. A subrotina <code>mode_run</code> , em azul no diagrama, é a responsável de integrar o novo módulo de avaliação orientada a objeto.	30
3.2 Diagrama das chamadas da rotina principal do módulo <code>m_mode</code> no SCANTEC.	32
3.3 Exemplo da aplicação do filtro circular no algoritmo de convolução. . . .	34
3.4 Exemplo da aplicação do algoritmo Quickhull no cálculo do casco convexo de um objeto.	36
3.5 Padrões idealizados de precipitação para ilustrar erros específicos nas previsões de chuva de cinco modelos diferentes. O objeto de precipitação previsto (vermelho) está posicionado à direita do objeto observado (azul). Note que, em (f) os objetos da previsão e da observação se sobrepõem. . .	43
3.6 Mapas de Interesse dos atributos diferença de centroide e diferença de ângulo	47
3.7 Mapas de Confiança dos atributos diferença de centroide e diferença de ângulo	47
4.1 Acumulados de precipitação na América do Sul em Janeiro 2016.	53
4.2 Transformações das previsões de acumulados de 6 horas de precipitação para às 0600 UTC do 21 de Janeiro de 2016, resultantes dos processos convolução, limiarização e restauração para os dados observados e modelos BRAMS e GFS.	56

4.3	Objetos de precipitação identificados nas previsões de acumulados de 6 horas de precipitação do BRAMS e do GFS para às 0600 UTC do dia 21 de Janeiro de 2016. As cores em (d), (e) e (f) representam os diferentes objetos delimitados nos campos de precipitação restaurados mostrados em (a), (b) e (c), respectivamente.	58
4.4	Previsões de acumulados de precipitação de 6 horas, válidas às 0600 UTC do 21 de Janeiro de 2016. As áreas de chuva coloridas iguais representam os pares de objetos observação-previsão identificados em (a)-(b) e (c)-(d), a cor cinza é usada para indicar objetos não pareados nos campos.	59
4.5	Séries Temporais do MMI para as previsões de precipitação de 06, 12, 18 e 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.	62
4.6	Histogramas normalizados da diferença dos centroides entre os objetos nas previsões de precipitação do BRAMS e o GFS para 6 horas de previsão (Janeiro de 2016).	63
4.7	Histogramas normalizados da razão da área de interseção entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para o mês de Janeiro de 2016.	64
4.8	Histogramas normalizados da razão das áreas entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016.	65
4.9	Histogramas normalizados da diferença de orientação entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016.	66
4.10	Séries Temporais do CSI (linhas sólidas) e FAR (linhas tracejadas) orientadas a objeto para as previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os valores médios do CSI e a FAR para o período aparecem à direita da figura.	67
4.11	Histogramas normalizados da diferença dos centroides, razão da área de interseção, razão da área dos pares de objetos e diferença no ângulo de orientação entre os objetos nas previsões de acumulados de 6 horas de precipitação do BRAMS e o GFS após 24 horas de integração em Janeiro de 2016.	68
4.12	Séries Temporais do CSI (linhas sólidas), a FAR (linhas tracejadas) Orientada a Objeto para as previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os valores médios do CSI e a FAR para o período aparecem a direita da figura.	71

4.13 Séries Temporais do interesse parcial dos atributos: diferença do centroide, razão da área de interseção, razão da área e diferença de orientação para as previsões do acumulado diário de precipitação com 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.	74
4.14 Séries Temporais do MMI para as previsões do acumulado diário de precipitação após 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.	75
4.15 Séries Temporais do MMI para as previsões do acumulado diário de precipitação para os diferentes dias de integração (24, 48, 72 e 96 horas) do BRAMS e o GFS para Janeiro de 2016.	76
4.16 Séries Temporais do índices estatísticos (a) CSI, (b) POD, (c) FAR e (d) BIAS orientados a objetos para as previsões do acumulado diário de precipitação em função dos dias de integração do BRAMS e o GFS para Janeiro de 2016.	77
4.17 Objetos de precipitação identificados nas previsões de acumulados de 6 horas de precipitação com 24 horas de integração do BRAMS e do GFS a partir da análise do dia 28 de Janeiro de 2016. Previsões para 00UTC do dia 29 de Janeiro de 2016. As áreas de chuva coloridas iguais representam os pares de objetos observação-previsão identificados entre (a)-(b) e (a)-(c), a cor cinza é usada para indicar objetos não pareados nos campos.	79

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Tabela de contingência.	8
2.2 Informação fornecida pelos principais métodos.	19
3.1 Definição dos limites inferior e superior para as funções de interesse de cada atributo (<i>grid_res</i> refere-se à resolução da grade em km.)	39
3.2 Exemplo da Matriz Interesse da comparação de 3 objetos previstos com 2 objetos observado para uma previsão hipotética.	42
3.3 Parâmetros utilizados na Equação 3.20 para definir os campos sintéticos de precipitação geométrica na Figura 3.5.	44
3.4 Índices de verificação tradicionais aplicados as previsões da Figura 3.5.	45
3.5 Atributos dos objetos identificados nas previsões da Figura 3.5.	46
4.1 Atributos dos três pares de objetos identificados entre as estimativas 3B42 e o BRAMS (Figuras 4.4(a) e 4.4(b)) e entre as estimativas 3B42 e o GFS apresentados em parêntesis (Figuras 4.4(c) e 4.4(d)) no dia 21 de Janeiro de 2016.	60
4.2 Tabela de Contingência do BRAMS (Figuras 4.4(a) e 4.4(b)).	60
4.3 Tabela de Contingência para o GFS (Figuras 4.4(c) e 4.4(d)).	60
4.4 Valores do Interesse Parcial Médio e do Interesse Total Médio dos quatro atributos para as previsões de precipitação de 6 horas de integração do BRAMS e o GFS em Janeiro de 2016. Os pesos de cada atributo no Interesse Total também são apresentados nessa tabela.	64
4.5 Total de sucessos, falhas e alarmes falsos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016. O total de objetos previstos e observados também é apresentado.	66
4.6 Valores de Interesse Parcial Médio dos quatro atributos para as previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os pesos de cada atributo no Interesse Total também são apresentados nessa tabela.	69
4.7 Total de sucessos, falhas e alarmes falsos nas previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.	70
4.8 Tabela de Contingência para as previsões do acumulados diário de precipitação para 24 horas de integração do BRAMS e o GFS (em parêntesis) para Janeiro de 2016.	72

4.9	Valores do CSI, POD, FAR e BIAS Orientados a Objetos obtidos a partir da Tabela 4.8 para as previsões do acumulados diário de precipitação após 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.	73
4.10	Atributos dos pares de objetos (verde) identificados entre as estimativas 3B42 e o BRAMS (Figuras 4.17(d) e 4.17(e)) e entre as estimativas 3B42 e o GFS apresentados em parêntesis (Figuras 4.17(d) e 4.17(f)) no dia 21 de Janeiro de 2016.	80

LISTA DE ABREVIATURAS E SIGLAS

AMSR-E	–	Advanced Microwave Scanning Radiometer - Earth Observing System
AMSU-B	–	Advanced Microwave Sounding Unit-B
AS	–	América do Sul
BRAMS	–	Brazilian Regional Atmospheric Modelling System
CAMS	–	Climate Assessment and Monitoring System
CEMADEM	–	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CPTEC	–	Centro de Previsão do Tempo e Estudos Climáticos
CRA	–	Contiguous Rain Areas
CSI	–	Critical Success Index
DAS	–	Displacement and Amplitud Score
DMD	–	Divisão de Modelagem e Desenvolvimento
DMSP	–	Defense Meteorological Satellite Program
ENOS	–	El Niño-Oscilação Sul
EOF	–	Empirical Orthogonal Functions
ETS	–	Equitable Threat Score
EUA	–	United State of America
FAR	–	False Alarm Ratio
FCA	–	Feature Calibration and Alignment
FSS	–	Fractions Skill Score
FQI	–	Forecast Quality Index
FQM	–	Forecast Quality Measure
GEO	–	Geosynchronous Orbit
GFS	–	Global Forecast System
GPCC	–	Global Precipitation Climatological Center
GSS	–	Gilbert Skill Score
HR	–	Hit Rate
HSS	–	Heidke Skill Score
INPE	–	Instituto Nacional de Pesquisas Espaciais
IR	–	Infrared
IS	–	Intensity Scale
LEO	–	Low Earth Orbit
MAE	–	Mean Absolute Error
MET	–	Model Evaluation Tools
MIO	–	Máximo Interesse Observado
MIP	–	Máximo Interesse Previsto
MMI	–	Média do Máximo Interesse
MODE	–	Method for Object-Based Diagnostic Evaluation
NASA	–	National Aeronautics and Space Administration
NCAR	–	National Center for Atmospheric Research

NCEP	– National Centers for Environmental Prediction
NOAA	– National Oceanic and Atmospheric Administration
OMM	– Organização Meteorológica Mundial
PBL	– Planetary Boundary Layer
PNTC	– Previsão Numérica de Tempo e Clima
POD	– Probability of detection
PR	– TRMM Precipitation Radar
RAMS	– Regional Atmospheric Modelling System
RMSE	– Root Mean Square Error
SAL	– Structure, Amplitude and Location
SAM	– Sistema de Avaliação de Modelos
SCANTEC	– Sistema Comunitário de Avaliação de Modelos Numéricos de Previsão de Tempo e Clima
SP	– São Paulo
SSMI	– Special Sensor Microwave Imager
SVN	– Suversion
TCI	– TRMM Combined Instrument
TMI	– TRMM Microwave Imager
TMPA	– TRMM Multisatellite Precipitation Analysis
TMPA-RT	– Real-Time TRMM Multisatellite Precipitation Analysis
TRMM	– Tropical Rainfall Measuring Mission
TS	– Thread Score
USP	– Universidade de São Paulo
UTC	– Universal Time Coordinated
VGM	– Variogram
ZCAS	– Zona de Convergência do Atlântico Sul
ZCIT	– Zona de Convergência Intertropical
ZCOU	– Zona de Convergência de Umidade

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Contextualização da pesquisa	2
1.2 Objetivos	4
1.3 Conteúdo do documento	5
2 AVALIAÇÃO DAS PREVISÕES DE PRECIPITAÇÃO	7
2.1 Métodos estatísticos convencionais para avaliar as previsões de precipitação	7
2.2 Métodos de Verificação Espacial	11
2.2.1 Informações fornecidas pelos métodos de verificação espacial sobre a qualidade das previsões	15
2.3 <i>Method For Object-Based Diagnostic Evaluation</i> (MODE)	20
2.3.1 Identificação das regiões de chuva	20
2.3.2 Atributos dos objetos identificados	23
2.3.3 Algoritmo de Lógica Difusa	23
3 METODOLOGIA DE AVALIAÇÃO DA PRECIPITAÇÃO ORIENTADA A OBJETO	27
3.1 Estratégia eficiente de desenvolvimento de código no CPTEC	28
3.2 SCANTEC	28
3.3 Método de avaliação orientada a objeto no SCANTEC	31
3.3.1 Processo de identificação de objetos	33
3.3.2 Cálculo das propriedades geométricas dos objetos	34
3.3.3 Cálculo dos atributos de cada um dos pares de objetos	37
3.3.4 Processo de identificação de pares de objeto	38
3.3.5 Índices calculados para à avaliação	40
3.4 Experimentos para a Validação do MODE	42
4 PROVA DE CONCEITO: APLICAÇÃO DA METODOLOGIA DE AVALIAÇÃO ORIENTADA A OBJETO ÀS PREVISÕES DE PRECIPITAÇÃO SOBRE A AMÉRICA DO SUL	49
4.1 Modelos, dados observados, área e período de estudo	49
4.1.1 Informações sobre os modelos BRAMS e GFS	50
4.1.2 Dados de precipitação usados como referência	51

4.1.3	Área e período de estudo e o padrão da precipitação observada	52
4.2	Experimento de avaliação	54
4.2.1	Identificação das áreas de precipitação	55
4.2.2	Identificação dos pares de objetos na observação e previsão	57
4.2.3	Estatística dos atributos e tabela de contingência	57
4.3	Discussão dos resultados	61
4.3.1	Avaliação das previsões do acumulado de 6 horas	62
4.3.2	Avaliação das previsões do acumulado de 24 horas	71
4.3.3	Estudo de caso: potencial do método aplicado à tempestades severas	76
5	CONSIDERAÇÕES FINAIS E CONCLUSÕES	81
5.1	Conclusões	82
5.2	Recomendações Futuras	83
	REFERÊNCIAS BIBLIOGRÁFICAS	85

1 INTRODUÇÃO

Os produtos gerados pelos modelos de Previsão Numérica de Tempo e Clima (PNTC) são uma das ferramentas mais utilizadas pelos meteorologistas no serviço meteorológico na elaboração de prognósticos do comportamento da atmosfera, com benefícios diretos para diversas áreas da sociedade. Esses modelos de PNTC para atender essa demanda, baseiam-se em equações matemáticas que buscam descrever o comportamento da atmosfera, as quais não são perfeitas e introduzem incertezas. A maioria dessas equações são não lineares e devem ser resolvidas usando aproximações numéricas para representar as taxas de variações temporais das variáveis usadas para descrever o estado atmosférico. Além da inerente imprevisibilidade desse estado (LORENZ, 1963a; LORENZ, 1963b), os métodos numéricos e as discretizações introduzem tais incertezas nos resultados. Também são geradas incertezas na formulação da condição inicial decorrentes dos inevitáveis erros nas observações como consequência de imperfeições nos equipamentos, falhas humanas e das condições ambientais nas quais se processa a mensuração. Entretanto, existem outras fontes de erros do modelo incluindo: as condições de contorno, modelos com resolução insuficiente para descrever um fenômeno meteorológico em particular, imprecisão das parametrizações dos processos que ocorrem em escala inferior a grade numérica onde são resolvidas as equações que controlam a evolução temporal dos campos meteorológicos, entre outras (WARNER, 2011). Conhecer as características destas fontes de incerteza, bem como identificar corretamente as limitações presentes nos modelos frequentemente utilizados no serviço meteorológico, pode contribuir para melhorar a qualidade das previsões. Isto só é possível através da avaliação do desempenho de cada um desses modelos, a fim de conhecer o seu grau de acerto; permitindo por sua vez, identificar qual o modelo, entre os disponíveis, que é o mais adequado para prever um determinado fenômeno.

Entre as variáveis previstas pelos modelos, a precipitação é uma das mais importantes. Gonçalves (2003) ressalta que os fenômenos naturais relacionados com a precipitação são os que provocam maior impacto na vida social e econômica de uma região. O Brasil é um dos países mais atingidos por fenômenos naturais catastróficos. Marcelino et al. (2006) indicam que do número total dos desastres naturais ocorridos entre os anos 1900 e 2000, aproximadamente 60% vinculam-se a fenômenos atmosféricos severos que provocaram inundações e tempestades e, segundo (MARENGO, 2008) em algumas regiões do Brasil a probabilidade de ocorrer eventos chuvosos extremos tende a aumentar nos próximos anos. Um dos grandes desafios na modelagem numérica nesse sentido é produzir previsões

de precipitação que levem à redução e à mitigação dos desastres provocados por tais eventos, e portanto, à proteção da vida humana, além de um melhor planejamento das atividades dos mais diversos setores econômicos e sociais. Porém, a precipitação é resultante da sinergia entre processos complexos os quais envolvem interações não lineares de diferentes fenômenos físicos sobre diversos períodos de tempo e escalas espaciais, desde grandes massas de ar até eventos convectivos extremamente localizados (GANGULY; BRAS, 2003). Além disso, a precipitação sofre forte influência das particularidades do relevo e o impacto da mesma na superfície depende da localização, duração, intensidade e condições prévias do solo. Estas características, incluindo sua descontinuidade espacial e temporal, fazem desta variável meteorológica, uma das mais difíceis de serem previstas (ANTHES et al., 1989). Nesse contexto tem-se um contra-censo, pois a variável atmosférica mais importante para a sociedade, também é a mais difícil de se obter previsões de qualidade através de modelos numéricos. Como tais modelos estão sempre em evolução visando entregar melhores produtos a sociedade, uma adequada avaliação da qualidade das previsões de precipitação é crucial para contribuir para essa evolução, e por isso esse assunto é objeto de estudo de varias investigações na busca de novos métodos de verificação (NACHAMKIN et al., 2005).

1.1 Contextualização da pesquisa

A maioria das técnicas utilizadas na avaliação da acurácia das previsões numéricas de precipitação baseiam-se principalmente em ver se uma malha de dados previstos corresponde a uma rede de observações ou um conjunto de pontos de observação. A partir dessas sobreposições, são determinados os casos onde as observações e as previsões concordam (pixel por pixel) e os casos em que nenhuma correspondência é encontrada. Uma tabela de contingência de testes de sucessos e falhas é obtida, a partir da qual são calculados vários índices estatísticos, entre eles: o *Hit Rate*, o *Critical Success Index* e o *Bias*. Embora estes índices forneçam informações valiosas sobre a qualidade das previsões, eles são muito rigorosos com os modelos penalizando-os de forma injusta, porque só fazem comparações ponto a ponto, e não descrevem padrões espaciais e o deslocamento dos sistemas. Eles não fornecem informações específicas e detalhadas sobre como, quanto e onde a previsão está correta ou errada (BALDWIN; KAIN, 2006; CASATI et al., 2008; WILKS, 2005; JOLLIFFE; STEPHENSON, 2012). Os pequenos erros nos campos espaciais previstos tanto com relação ao tempo como a localização dos eventos de precipitação, podem causar grandes diferenças entre o previsto e o observado em pontos de grade. O erro de localização espacial é geralmente a fonte dominante do erro da previsão de

precipitação em comparação com erros relacionados com o volume ou padrão da chuva (GILLELAND et al., 2009). Devido a isso, têm sido propostos novos métodos de verificação espacial com o propósito de examinar a habilidade de um modelo de PNTC em descrever a estrutura geral dos padrões meteorológicos na previsão; fornecer informações sobre a escala na qual a representatividade da previsão é melhor; quantificar o erro residual para ter uma noção mais relevante da qualidade da previsão; ponderar a coerência espacial da precipitação e dar crédito a uma previsão que não necessariamente coincide com a observação em qualquer ponto da rede particular. A maioria das novas técnicas estão agrupadas em quatro categorias: Vizinhaça, Separação da escala, Orientadas a objeto e Deformação do campo. Gilleland et al. (2009) realizaram um estudo dos métodos de verificação espacial das quatro categorias e apresentaram uma comparação entre eles, baseada no tipo de informação fornecida sobre erros de localização, intensidade, estrutura, escala e a habilidade para prever a ocorrência de precipitação (Acertos, Falhas, Alarmes Falsos). Segundo os autores, o método mais utilizado, mais completo e que melhor responde a estas questões é o *Method for Object-Based Diagnostic Evaluation* (MODE), método orientado a objeto desenvolvido por Davis et al. (2009). Esse método mostra-se bastante promissor quando empregado na avaliação das previsões de precipitação sobre a América do Sul, onde metodologias similares são ainda muito pouco exploradas nessa função.

Embora, diversos trabalhos têm abordado algumas das novas métricas de avaliação da precipitação sobre a América do Sul, por exemplo: Bender (2012), Doyle et al. (2013), Hernández et al. (2015), eles representam iniciativas isoladas na descrição da qualidade dos eventos de chuva, sem caracterizar um método robusto de avaliação que poderia ser aplicado sistematicamente para essa finalidade. O Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE) é a instituição nacional responsável por desenvolver e operacionalizar os melhores produtos de PNTC para a América do Sul, sendo essa tarefa parte de sua missão com relação a sociedade. Nesse centro não há a disponibilidade de uma metodologia de avaliação espacial da precipitação, a qual forneça uma análise completa e robusta da qualidade das previsões de precipitação. Como já mencionado, a ausência de uma metodologia adequada para a avaliação justa da qualidade das previsões é um fator limitante da evolução dos modelos de PNTC, o qual é mais crítico para as previsões de chuva. Assim, o presente estudo visa introduzir a metodologia do MODE nas avaliações das previsões de precipitação sobre a América do Sul, com o intuito de contribuir para a evolução dos modelos de PNTC ao tratar os erros dos modelos de forma mais justa e coerente com suas

limitações na representação espacial dos eventos. Para o desenvolvimento dessa metodologia será usado como framework o Sistema Comunitário de Avaliação de modelos Numéricos de previsão de Tempo E Clima (SCANTEC), desenvolvido por pesquisadores da Divisão de Modelagem e Desenvolvimento (DMD) do CPTEC. O SCANTEC é um software estatístico estruturado de forma modular, composto por um módulo para a avaliação da precipitação que fornece uma estrutura básica de leitura dos dados previstos e observados, a qual é apropriada para a implementação de novas métricas de avaliação baseada em metodologias espaciais. Esse método é aplicado na avaliação da qualidade das previsões de precipitação do Modelo BRAMS (Brazilian Regional Atmospheric Modelling System) que é um dos modelos regionais operacionais do CPTEC de mais alta resolução espacial. As previsões geradas no *National Centers for Environmental Prediction* (NCEP) utilizando o modelo GFS (*Global Forecast System*) são também avaliadas em comparação com as previsões do BRAMS. Os campos de precipitação observados pelo satélite TRMM (*Tropical Rainfall Measuring Mission*) são utilizados como verdade nessa análise.

1.2 Objetivos

O presente trabalho tem por objetivo principal propor e aplicar uma metodologia de avaliação diagnóstica orientada a objeto nas previsões de precipitação sobre a América do Sul. Para atingir essa meta é possível estabelecer como objetivos específicos os seguintes pontos:

- Propor uma metodologia para a avaliação espacial da precipitação baseada no algoritmo de verificação do MODE, utilizando para isso a estrutura de desenvolvimento disponível no SCANTEC.
- Validar a metodologia usando campos de precipitação hipotéticos, previsto e observado, e comprovar a eficiência do método na correta avaliação dos modelos no que se refere a identificação das áreas de chuva, considerando os possíveis erros na posição, extensão e morfologia dos eventos.
- Aplicação do método, como prova de conceito para avaliar as previsões de precipitação do modelo BRAMS sobre a América do Sul usando como dados de referência o produto 3B42 do TRMM Multisatellite Precipitation Analysis (TMPA) da *National Aeronautics and Space Administration* (NASA) e diagnosticar o desempenho do modelo em comparação com a precipitação prevista pelo GFS sobre essa região.

1.3 Conteúdo do documento

Considerando os objetivos traçados nessa pesquisa, o trabalho está dividido em cinco capítulos, sendo que no segundo é apresentada uma revisão bibliográfica da metodologia de avaliação geralmente utilizada para quantificar a destreza dos modelos em prognosticar os eventos de precipitação. Nessa revisão são apresentadas as métricas convencionais para avaliar a precipitação, e também diversos métodos de verificação espacial são descritos e discutidos, entre os quais o MODE é evidenciado com o objetivo de mostrar os benefícios pelos quais esse método foi escolhido. Nesse capítulo também um bom esforço foi empregado para bem caracterizar esse método em seus diversos aspectos. O capítulo 3 trata da implementação e validação do método orientado a objeto no SCANTEC, no qual as etapas em que consiste o processo são explicadas em detalhes. Um experimento baseado em dados sintéticos é organizado para validar a implementação da metodologia no SCANTEC. No capítulo 4 uma aplicação do método é feita usando os dados de precipitação sobre a América do Sul do BRAMS e do GFS, um experimento de avaliação foi organizado com esses dados como prova de conceito da metodologia proposta com base na inter-comparação dos modelos. Detalhes do experimento de avaliação são descritos nesse capítulo e os resultados são apresentados e discutidos. Visando avaliar a eficiência do método para a avaliação de eventos extremos um estudo de caso é analisado e os resultados são discutidos. No capítulo 5 as considerações finais, conclusões e recomendações de trabalhos futuros são apresentadas.

2 AVALIAÇÃO DAS PREVISÕES DE PRECIPITAÇÃO

A confiabilidade do processo de verificação das previsões numéricas depende, entre outros fatores, do método de verificação utilizado. Um elemento importante na escolha desses métodos é o tipo de variável meteorológica que pretende-se verificar (JOLLIFFE; STEPHENSON, 2012). As variáveis meteorológicas para as quais as previsões são feitas podem ser:

- **contínuas:** podem assumir qualquer valor dentro dos limites do intervalo de valores das variáveis, ou seja, entre dois valores diferentes há um número infinito de possíveis valores. Uma característica importante dessas variáveis é a forte correlação temporal e espacial dos valores assumidos. Por exemplo: pressão, temperatura, umidade, etc.)
- **categóricas ou discretas:** podem tomar apenas um valor a partir de um conjunto finito de valores predefinidos (categorias). O tipo mais simples de variável categórica é uma variável binária, que tem apenas dois valores possíveis indicando a presença ou a ausência de uma condição, por exemplo: máscara de chuva, nevoeiro ou trovoadas.

A seguir serão apresentados os principais métodos de verificação das variáveis discretas, principalmente aqueles usados tradicionalmente na avaliação das previsões numéricas de precipitação.

2.1 Métodos estatísticos convencionais para avaliar as previsões de precipitação

Desde a primeira metade da década de 1980, as técnicas convencionais utilizadas na avaliação de previsões numéricas de precipitação, foram baseadas principalmente em ver se uma malha de dados previstos corresponde a uma rede de observações ou um conjunto de pontos de observação. Vale salientar que nessa análise não se verifica a intensidade do valor, mas apenas a ocorrência ou não do fenômeno. A partir dessas sobreposições são determinados os casos onde as observações e as previsões concordam, e os casos em que nenhuma correspondência é determinada, sendo obtida uma tabela de contingência de testes de sucessos e falhas.

As características da tabela de contingência estão baseadas em Wilks (1995), na qual os elementos da amostra são classificados de acordo com pelo menos dois fatores ou critérios (sim choveu / não choveu). A tabela está formada com linhas

correspondentes a um dos critérios, e com colunas correspondentes ao outro critério. A Tabela 2.1 mostra os valores para cada uma das quatro possíveis combinações dos eventos observados e previstos; onde a é o número de eventos previstos que correspondem aos eventos observados (*sucessos*), b é o número de eventos previstos que não correspondem com os eventos observados (*alarmes falsos*), c é o número de eventos não previstos que correspondem aos eventos observados (*falhas*) e d é o número de eventos não previstos que correspondem aos não observado (*rejeições corretas*). A soma de todos os eventos anteriores é conhecida como *tamanho da amostra* ($n = a + b + c + d$).

Tabela 2.1 - Tabela de contingência.

Previstos	Observados		
	Sim	Não	Total
Sim	a	b	$a+b$
Não	c	d	$c+d$
Total	$a+c$	$b+d$	$a+b+c+d=n$

Fonte: Adatada de Jolliffe and Stephenson (2012)

Por meio dos resultados mostrados em uma tabela de contingência pode-se obter vários parâmetros úteis para a avaliação das previsões e observações. A seguir são descritas algumas medidas de verificação baseadas na Tabela 2.1:

- **Hit Rate (HR):** define a fração das previsões que foram corretas e pode ser calculado como:

$$HR = \frac{a+d}{n}$$

Os valores do *Hit Rate* estão no intervalo entre 0 e 1, onde o melhor *Hit Rate* possível é 1. Entre as principais características de este índice estatístico encontra-se que ele é simples e intuitivo, porém pode ser enganoso devido a que é fortemente influenciado pela combinação mais comum (a ou d).

- **Bias:** mede a relação entre o número de previsões de ocorrência e o número de ocorrências reais, ou seja, a relação entre a frequência de eventos previstos e a frequência de eventos observados. Ele é expresso como:

$$Bias = \frac{a+b}{a+c}$$

Uma previsão imparcial mostra um valor de $Bias = 1$, indicando que o evento foi previsto o mesmo número de vezes que foi observado. Um Bias maior do que 1 indica que o evento foi previsto mais vezes do que foi observado, o que pode-se chamar de *overforecasting*. Da mesma forma, um Bias menor do que 1 indica que um evento foi previsto menos vezes do que foi observado, o que pode-se chamar de *underforecasting*. O Bias não mede o quão bem a previsão corresponde com as observações, só mede as frequências relativas.

- ***Probability of detection (POD)***: representa a proporção de ocorrências dos eventos que foram previstos corretamente, é calculado como:

$$POD = \frac{a}{a+c}$$

Para previsões perfeitas o POD é 1 e para previsões erradas o POD é 0. Este índice é sensível aos sucessos, mas ignoram os alarmes falsos, portanto ele deve ser usado em conjunto com a *False alarm ratio*.

- ***False alarm ratio (FAR)***: define a fração dos eventos que foram previstos, mas não ocorreram. O FAR tem uma orientação negativa tanto que pequenos valores para FAR são preferidos. O melhor FAR possível é 0 e o pior é 1. O FAR é calculado como:

$$FAR = \frac{b}{a+b}$$

Este índice é sensível aos alarmes falsos, mas ignora as falhas.

- ***Critical Success Index (CSI)***: também chamado de *Thread Score (TS)*, mede a fração de eventos observados que foram corretamente previstos. Os valores do CSI estão no intervalo entre 0 e 1, sendo o $CSI = 1$ para previsões perfeitas. É definido por:

$$CSI = \frac{a}{a+b+c}$$

O CSI é sensível aos acertos, penaliza as falhas e os alarmes falsos. Porém não distingue fontes de erro na previsão.

- ***Equitable threat score (ETS) ou Gilbert skill score (GSS)***: é semelhante ao *TS*, mede o quão bem os eventos previstos se correspondem com os eventos observados, mas levando em conta os acertos que ocorreriam puramente devido ao acaso (por exemplo, é mais fácil prever corretamente

a ocorrência de chuva em um clima úmido do que em um clima seco). É definido como:

$$ETS = \frac{a - a_{acaso}}{a + b + c - a_{acaso}}$$

onde

$$a_{acaso} = \frac{(a+c)(a+b)}{n}$$

Os valores do ETS estão no intervalo entre $-1/3$ e 1, sendo o $ETS = 1$ para previsões perfeitas. Este índice é frequentemente usado na verificação da precipitação em modelos de PNTC porque sua equitabilidade permite que as pontuações sejam comparadas de forma mais justa em diferentes regimes de precipitação. De forma semelhante ao TS, o ETS é sensível aos acertos, penaliza as falhas e os alarmes falsos, porém não distingue fontes de erro na previsão.

- **Heidke Skill Score (HSS):** Mede a fração de previsões corretas depois de eliminar as previsões que seriam corretas devido puramente ao acaso. O HSS é definido como:

$$HSS = \frac{a+d-E}{n-E}$$

onde E é a razão das previsões que teriam sido corretas se as previsões e as observações foram independentes, e assumindo a mesma proporção das previsões de ocorrência que para as previsões de não-ocorrência, de modo que para uma tabela de contingência:

$$E = \frac{(a+c)(a+b) + (b+d)(c+d)}{n}$$

Os valores do HSS estão no intervalo entre -1 e 1, sendo o $HSS = 1$ para previsões perfeitas.

Esses índices estatísticos tradicionais representam métodos de verificação com uma abordagem orientada a medidas, proporcionando uma visão geral da habilidade de um modelo de PNTC, porém fornecem informação incompleta sobre a qualidade das previsões porque só fazem comparações ponto a ponto e não consideram a distribuição espacial e a intensidade da precipitação, portanto não é possível avaliar adequadamente os erros na geometria e nos deslocamentos nos sistemas e seus pontos de máxima precipitação.

Na verdade, para muitos usuários ou situações de tomada de decisão, pequenos erros de localização podem não ser importantes, no entanto, as medidas tradicionais de verificação indicam que um prognóstico com estes erros tem pouca ou nenhuma habilidade. Por exemplo, previsões espaciais de precipitação corretas em intensidade e extensão da área, mas que mostram um ligeiro deslocamento no espaço ou no tempo, serão penalizadas por não coincidirem com as observações e por dar um alarme falso. Isso é conhecido pelo termo “dupla penalização”, que tem impacto significativo no diagnóstico da destreza de modelos, em especial na inter-comparação dos mesmos.

Em resposta a estas questões, nos últimos anos, novas abordagens têm sido desenvolvidas. Os estudos mais recentes têm-se centrado no desenvolvimento de novas ferramentas que consideram especificamente a natureza espacialmente coerente dos campos de precipitação, levando em conta as características geométricas e a posição das áreas de chuva. Os novos métodos são conhecidos como Métodos de Verificação Espacial, os quais serão descritos na seção seguinte.

2.2 Métodos de Verificação Espacial

A maioria das novas técnicas de verificação espacial estão agrupadas em quatro categorias:

- Vizinhança
- Separação ou decomposição da escala
- Orientados a objeto
- Deformação do campo

As técnicas de Vizinhança (também conhecidas como *Fuzzy*) comparam os valores das previsões e observações nas vizinhanças do espaço-tempo em relação a um ponto no campo de observação. Um filtro é aplicado a cada um dos campos, calculando a média dos valores dos pontos da grade vizinhos dentro de um determinado raio entre eles. O resultado é uma versão suavizada dos campos originais. Uma vez obtidos estes novos campos, são comparados usando métricas estatísticas (a maioria das vezes, estatísticas de verificação tradicionais). Tais comparações são feitas geralmente incrementando o tamanho das vizinhanças, de modo que seja possível determinar a escala na qual a previsão alcança o nível desejado de habilidade (GILLELAND et al., 2009).

Várias técnicas foram desenvolvidas baseadas neste tipo de verificação, por exemplo: Cobertura mínima de [Damrath and Wetterdienst \(2004\)](#), Tabela de contingência multi-evento de [Atger \(2001\)](#), Intensidade-Escala (IS) de [Casati et al. \(2004\)](#), Fractions Skill Score de [Roberts and Lean \(2008\)](#), Abordagem pragmática de [Theis et al. \(2005\)](#), o método de [Theis et al. \(2005\)](#), a Raiz Quadrada Condicional do Ranked Probability Score de [Germann and Zawadzki \(2004\)](#), e os métodos de [Rezacova et al. \(2007\)](#) e [Segawa and Honda \(2007\)](#). O estudo realizado por [Ebert \(2008\)](#) apresenta um quadro comum que resume e descreve a maioria delas.

O algoritmo geral desta metodologia é bastante simples:

- a) Selecionar o conjunto de escalas com índices $s = 1, 2, \dots, S$ e limiares de intensidade do evento indexados por $k = 1, 2, \dots, K$.
- b) Para cada escala s :
 - Para cada observação (em um ponto ou uma caixa de grade) coletar as previsões dentro da janela de escala s em torno da observação.
 - Para cada limiar de intensidade k calcular as quantidades dependentes da escala, de acordo com vários modelos de decisão e os índices de verificação desejados sobre o domínio.

O resultado é uma matriz de índices ($K \times S$), com os índices que variam em intensidade e escala. Ao examinar o desempenho da previsão desta forma, pode-se determinar as combinações de escala-intensidade em que a previsão é útil.

Nesse estudo, o autor concluiu que esta forma de verificação pode ser usada na avaliação de um conjunto de previsões para examinar o desempenho típico da previsão; para monitorizar o desempenho mensal ou sazonal numa região; como uma ferramenta de diagnóstico para investigar o desempenho previsto em diferentes regiões ou para diferentes regimes; para identificar em quais escalas e intensidades a habilidade de um modelo foi melhorada; além da comparação de modelos com diferentes resoluções de grade.

Do ponto de vista do usuário da previsão, a verificação de Vizinhança fornece informações importantes sobre as escalas e intensidades em que as previsões são confiáveis. A frequência de eventos pode ser muito sensível a limiares e tamanho da vizinhança. Por esta razão, estes métodos geralmente consideram um conjunto de resoluções espaciais e limiares de intensidade.

A distribuição da intensidade de dados de alta resolução na vizinhança, pode ser tratada de uma forma categórica para avaliar a ocorrência de eventos, que podem ser definidos de forma diferente dependendo do foco do estudo. Alternativamente, as intensidades podem ser tratadas de uma forma probabilística, assumindo que os valores da fração que ultrapassem um certo limiar representam a probabilidade da sua ocorrência no centro da janela. As propriedades da distribuição de intensidade podem ser comparadas diretamente.

As abordagens de Separação da Escala fornecem informações sobre o desempenho de uma previsão em escalas distintas. As diferentes escalas são obtidas usando um filtro espacial de banda única (transformadas de Fourier, Wavelets, etc.), pelo qual se investiga prever o desempenho isolando as características em cada escala. Muitas vezes, essas escalas são representativas de características físicas, tais como sistemas frontais de grande escala ou chuvas convectivas de pequena escala.

Entre os métodos incluídos nessa categoria se encontram: A Técnica Wavelet de [Briggs and Levine \(1997\)](#), A Técnica Intensidade-Escala Modificada por [Casati \(2009\)](#), o método baseado no cálculo do Espectro Espacial de Potência de Fourier, Função de Estrutura e Análise de momento-escala de [Harris et al. \(2001\)](#), a técnicas de [Marzban and Sandgathe \(2009\)](#), [Marzban et al. \(2009\)](#) e [Lack et al. \(2010\)](#), entre outros. Todos eles têm como finalidade:

- a) avaliar a dependência da escala do erro;
- b) determinar a escala de transição habilidade-não habilidade, ou seja, avaliar a dependência de escala da previsibilidade do modelo;
- c) e avaliar a capacidade da previsão para reproduzir a estrutura da escala observada nas observações.

Ambos métodos, Vizinhança e Separação da escala, podem ser generalizados como Métodos de Filtragem, porque eles aplicam um filtro espacial a um ou mais campos e depois calculam estatísticas de verificação para cada um dos campos filtrados. Os filtros são geralmente aplicados em escalas mais espessas gradualmente para fornecer informação sobre a escala na qual a previsão tem uma determinada habilidade. Uma diferença importante entre estas duas categorias é que os métodos de Vizinhança, essencialmente, suavizam as previsões sobre uma variedade de escalas crescentes e os campos filtrados sempre assemelham-se amplamente ao campo original porque a grande escala é mantida. Ao mesmo tempo, os campos filtrados não podem ser

combinados para reproduzir o campo original porque as menores escalas são perdidas no processo de suavização. Em contraste, os métodos de Separação da Escala tratam cada escala de forma independente; os campos filtrados não podem assemelhar-se ao campo original, mas eles podem ser combinados para reproduzir o campo original.

As outras duas categorias, Orientados a objeto e Deformação do campo, tentam ajustar as previsões e as observações o melhor possível, fornecem informação sobre quanto a previsão deve ser manipulada espacialmente (deslocamento, rotação, dimensionamento, etc.) e quantificam o erro residual para obter uma noção mais significativa da qualidade da mesma. A principal diferença entre eles é que os métodos orientados a objeto identificam as áreas de interesse (objetos) e analisam cada uma separadamente, enquanto as abordagens de deformação do campo analisam o campo inteiro ou um subconjunto dele. As duas categorias são consideradas como Métodos de Deslocamento porque descrevem o movimento espacial que é necessário para encontrar uma correspondência entre a previsão e a observação.

Os métodos Orientados a objeto, conhecidos também como Métodos Orientados a Características ou Técnicas de Identificação de Células, baseiam-se principalmente sobre a forma de determinar:

- a) o que constitui um objeto;
- b) se os objetos especialmente discretos dentro de um campo devem ser tratados como uma entidade ou como entidades separadas;
- c) como combinar objetos em um campo (previsão) com os objetos de outro campo (observação).

A maioria dos métodos identificam objetos através da aplicação de um limiar para os campos. Atributos, tais como tamanho, forma, e a intensidade média de cada objecto podem ser calculados para os objetos dentro do campo da previsão ou campo da observação. Além disso, eles podem ser comparados com os objetos identificados no campo correspondente (por exemplo, com base na proximidade espacial), a partir do cálculo de estatísticas que permitem conhecer o quão bem assemelham-se as características desses objetos (GILLELAND et al., 2009). Diversos métodos orientados a objeto tem sido desenvolvidos, entre eles: *Contiguous Rain Areas* (CRA) de Ebert and McBride (2000); a técnica de Baldwin and Lakshmirarahan (2003) baseada na determinação de um conjunto de atributos que são eficazes em discriminar entre

três tipos diferentes de padrões espaciais de chuva: precipitação linear, celular e estratiforme; o *Method for Object-based Diagnostic Evaluation* (MODE) de Davis et al. (2009), baseado na identificação de objectos ou áreas de chuva através de um procedimento de convolução onde os campos são suavizados no espaço, e a seleção e aplicação de um limiar de intensidade do campo, junto com um algoritmo de correspondência de lógica difusa; a Técnica de análise de forma de Micheas et al. (2007); e o método *Structure, Amplitude and Location* (SAL) utilizadas por Wernli et al. (2008) e Wernli et al. (2009).

A abordagem de Deformação do campo, envolvem essencialmente a manipulação espacial do campo de previsão para torná-lo, quanto possível, muito parecido com o campo de observação. Nessa metodologia é gerado um campo de vectores de distorção que é então avaliado de forma diagnóstica ou analiticamente. Diversos estudos foram desenvolvidos baseados neste tipo de verificação, entre eles: *Feature Calibration and Alignment* (FCA) de Hoffman et al. (1995), *Forecast Quality Measure* (FQM) de Keil and Craig (2007), *Displacement and Amplitud Score* (DAS) de Keil and Craig (2009), e *Forecast Quality Index* (FQI) de Venugopal et al. (2005).

A maioria das técnicas incluídas nesta abordagem podem ser aplicadas às características individuais e, subsequentemente, utilizadas no âmbito dos métodos orientados a objeto. É possível tentar identificar as características de um campo, a fim de informar os procedimentos e movimentos ótimos, mas a principal distinção com os métodos orientados a objeto é que eles analisam o campo inteiro ou um subcampo, em vez de identificar e descrever características individuais dentro de um campo.

2.2.1 Informações fornecidas pelos métodos de verificação espacial sobre a qualidade das previsões

No estudo de Gilleland et al. (2009), os autores abordam algumas questões específicas de interesse e apresentam uma comparação entre os diferentes métodos de verificação espacial, tendo em conta o tipo de informação fornecida por cada um deles em relação a qualidade das previsões numéricas.

Segundo os autores, a questão de como os métodos fornecem informação sobre o comportamento de uma previsão em diferentes escalas, pode ter, pelo menos, duas interpretações possíveis: *a*) a escala espacial sobre a qual uma previsão tem um nível desejado de habilidade e *b*) as escalas espaciais onde os objetos podem ser isolados e analisados. Os métodos de Vizinhança são os que melhor fornecem

informação sobre a questão *a*) e os métodos de Separação da Escala são os que melhor respondem a questão *b*). Entretanto, os métodos fora destas categorias, geralmente não são projetados para informar sobre erros da escala, mas podem ser usados nesse sentido, por exemplo o MODE e alguns outros Métodos Orientados a Objeto. Geralmente, os métodos de Deformação do Campo não abordam questões da escala diretamente, mas eles poderiam ser aplicados aos campos de previsão em diferentes escalas. Por exemplo, os métodos FQM-DAS de [Keil and Craig \(2007\)](#) e [Keil and Craig \(2009\)](#) transformam o campo através de uma série de mudanças em diferentes resoluções, mas o escore resultante do campo vetorial obtido não informa diretamente sobre o desempenho da escala. Todos os métodos incluídos nesta categoria fornecem informações sobre erros da escala em termos de divergência e convergência localizada do campo vetorial, que pode ser interpretada como uma sub-estimativa ou super-estimativa, respectivamente. Em resumo, qualquer método proposto (incluindo as métricas tradicionais) poderiam proporcionar informação em diferentes escalas simplesmente por aplicação do método para o campo em diferentes resoluções. Embora, os métodos de Vizinhança avaliam explicitamente o desempenho das previsões em diferentes escalas.

Os erros de localização são bastante comuns nas previsões que são feitas em resoluções de grade cada vez mais finas. Como mencionado anteriormente, as medidas tradicionais não fornecem nenhuma informação direta sobre esses tipos de erros, tais métricas penalizam duplamente os erros de localização como falhas e alarmes falsos. No caso dos métodos de Separação da Escala, a maioria deles mostram que previsões com maior erro de deslocamento têm erros em escalas maiores, mas não fornece informações específicas sobre a amplitude ou a direção do deslocamento. Embora a técnica de [Lack et al. \(2010\)](#) informa diretamente sobre erros de localização para características de escalas diferentes. Entretanto, as técnicas de Deformação do campo e Orientadas a Objeto permitem obter diretamente informações sobre os erros de localização, assumindo que a previsão assemelha-se bastante às observações de modo a que os objetos correspondentes podem ser associados ou combinados. Com exceção do método de [Marzban and Sandgathe \(2006\)](#) e [Marzban and Sandgathe \(2008\)](#) que identifica erros de localização mas não retorna informações sobre eles. As abordagens de Vizinhança, bem como a técnica IS de [Casati et al. \(2004\)](#) e [Casati \(2009\)](#), não dão informações de erro de localização, mas eles mostram que a maioria das pontuações melhoram quando diminuem os erros de localização, embora eles não fornecem a direção ou magnitude de tais erros. A Decomposição Wavelet pode ser utilizada para informar sobre erros de localização dos objetos em escalas diferentes, mas ainda não foi proposto nenhum estudo na literatura.

Todos os métodos (exceto Vizinhança, Intensidade-Escala e os métodos tradicionais) fornecem informações sobre erros de intensidade. O método de [Marzban and Sandgathe \(2006\)](#), [Marzban and Sandgathe \(2008\)](#) pode ser ligeiramente modificado para obter essa informação por limiarização dos campos e o cálculo de métricas usadas como função da intensidade. Embora as métricas FQM, DAS e FQI combinam informações sobre erros de localização e intensidade, pode-se examinar os componentes do índice total separadamente.

A informação sobre a estrutura pode ser interpretada de duas formas: *a*) estruturas individuais dentro de um campo e *b*) a estrutura espacial geral de um campo. Alguns dos métodos de Decomposição da Escala, por exemplo: os métodos de [Harris et al. \(2001\)](#) e [Zepeda-Arce et al. \(2000\)](#) respondem a segunda questão, eles avaliam parâmetros invariantes da escala relacionados com a organização espaço-temporal dos campos de precipitação, mas a maioria das outras abordagens não. As técnicas que definem objetos nos campos de previsão e observação podem atribuir atributos geométricos a esses objetos e esses atributos (por exemplo, área, comprimento e orientação) resumem a estrutura dos objetos. Os únicos métodos que fornecem este tipo de informação são o MODE, CRA, os métodos de [Micheas et al. \(2007\)](#) e [Lack et al. \(2010\)](#), e todos Métodos Orientados a Objetos. Os métodos de Deformação do Campo como FQM e DAS podem ser úteis para determinar o quão bem uma previsão é capaz de capturar as estruturas das tempestades observadas.

As métricas tradicionais e os métodos de Vizinhança fornecem um caminho óbvio para calcular sucessos, falhas, alarmes falsos e rejeição correta, enquanto outros métodos são sensíveis a esses valores sem medi-los diretamente. O método FSS de [Roberts and Lean \(2008\)](#) é sensível a alarmes falsos, falhas e sucessos, mas não calcula esses valores diretamente. Geralmente, os Métodos Orientados a Objeto são capazes de fornecer esta informação, com exceção da técnica SAL de [Wernli et al. \(2008\)](#) e [Wernli et al. \(2009\)](#). O método descrito em [Micheas et al. \(2007\)](#) dá apenas informações limitadas identificando o número de células observadas contra o número de células previstas, o que pode ser útil para identificar uma sub-estimativa ou super-estimativa das áreas de precipitação. A versão implementada desse método por [Lack et al. \(2010\)](#) calcula mais diretamente os valores dos sucessos, falhas e alarmes falsos.

A Tabela 2.2 apresenta os principais métodos de verificação e resume se eles fornecem ou não informação relacionada com a escala na qual as previsões têm certa habilidade, erros de localização, erros de intensidade, erros de estrutura e

informação sobre a identificação de sucessos (S), falhas (F), alarmes falsos (AF) e rejeições corretas (RC). Segundo os autores, qualquer um dos métodos apresentados nessa tabela, pode ser utilizado no processo de verificação das previsões numéricas de precipitação. Eles representam apenas uma pequena fração das técnicas possíveis. No entanto, é impraticável gerar uma grande variedade de métodos de verificação e tentar compara-los na prática. O recomendável é considerar cuidadosamente os requisitos para uma boa previsão e, nesse sentido, concentrar-se nos métodos de verificação que abordam esses requisitos através dos seus modelos de decisão.

Como é mostrado na tabela, o método mais completo e que melhor responde a todos os requisitos considerados para obter uma avaliação consistente sobre a qualidade das previsões de chuva, é o Method for Object-Based Diagnostic Evaluation (MODE). Portanto, no presente trabalho, o MODE é o método escolhido a ser implementado no SCANTEC e aplicado às previsões de precipitação dos modelos BRAMS e GFS sobre a América do Sul. Na seguinte seção serão mostrados os detalhes do algoritmo MODE.

Tabela 2.2 - Informação fornecida pelos principais métodos.

Método	Referencia	Categoria	Escala	Erros localização	Erros Intensidade	Erros estrutura	S, F, AF e RC
Tradicionais	Jolliffe and Stephenson (2003)	Tradicionais	Não	Não	Sim	Não	Sim
Cluster Analise	Marzban and Sandgathe (2006, 2009)	Orientado-Objeto	Sim	Sim	Não	Não	Sim
Procrustes	Micheas et al. (2007)	Orientado-Objeto	Não	Sim	Sim	Sim	Sim
CRA	Ebert and McBride (2000)	Orientado-Objeto	Não	Sim	Sim	Sim	Sim
FQI	Venugopal et al. (2005)	Deformação-Campo	Não	Sim	Sim	Não	Não
FQM-DAS	Keil and Craig (2007, 2009)	Deformação-Campo	Não	Sim	Sim	Sim	Sim
FSS	Roberts and Lean (2008)	Vizinhança	Sim	Indireta	Sim	Não	Indireta
IS	Casati et al. (2004) e Casati (2009)	Separação-Escala	Sim	Indireta	Sim	Não	Indireta
Variabilidad Multiescala	Harris et al. (2001)	Separação-Escala	Sim	Indireta	Sim	Não	Não
MODE	Davis et al. (2006)	Orientado-Objeto	Sim	Sim	Sim	Sim	Sim
Vizinhança	Ebert (2008)	Vizinhança	Sim	Indireta	Sim	Não	Sim
SAL	Wernli et al. (2008, 2009)	Orientado-Objeto	<i>Não*</i>	Sim	Sim	Não	Não
VGM	Marzban and Sandgathe (2009)	Separação-Escala	Sim	Não	Não	Sim	Não

Fonte: Adatada de Gilleland et al. (2009)

2.3 Method For Object-Based Diagnostic Evaluation (MODE)

O MODE foi desenvolvido no *Research Applications Laboratory*, do *National Center for Atmospheric Research* (NCAR) / Boulder, *United States of America* (EUA) por Davis et al. (2009), em resposta a uma necessidade de métodos de verificação diagnóstica para fornecer informações mais úteis e relevantes do que a informação obtida a partir de abordagens de verificação tradicionais, especialmente na avaliação de Modelos de PNTC de alta resolução. A ferramenta MODE é uma das técnicas incluídas no Model Evaluation Tools (MET) ¹ do NCAR.

O MODE identifica regiões de chuva de interesse em campos escalares e compara as características dessas regiões nos dois campos para identificar quais se correspondem melhor entre si. Estatísticas de semelhanças dos objetos nos dois conjuntos de dados são calculadas. O grau de semelhança entre os objetos observados e previstos fornece uma medida da qualidade das previsões.

O algoritmo do MODE imita o que um especialista humano faria para encontrar uma região de chuva na previsão e decidir se apresenta características análogas na observação. A decisão sobre a correspondência de um objeto previsto com um objeto observado é geralmente feita a partir da perspectiva de um previsor ou usuário da informação. Os autores consideram a correspondência como um processo inerentemente difuso, onde é “mais provável” ou “menos provável”, mas nunca certo. Isto, simplesmente reflete o fato de que nenhuma previsão fornece uma representação perfeita de uma característica observada e há sempre incertezas nas observações. Uma vez que uma decisão sobre a correspondência é feita, métricas adicionais da qualidade da previsão podem ser calculadas, a partir das propriedades geométricas dos objetos, mas também levando em conta a intensidade determinada pela distribuição do acúmulo de chuva dentro dos mesmos.

2.3.1 Identificação das regiões de chuva

A identificação das regiões de chuva ou objetos, é feita através da aplicação de um operador de convolução, governado por um raio de convolução R e um limiar de intensidade do campo T , com a finalidade de:

- Fazer as áreas de chuva mais contíguas do que no campo original;
- Filtrar as regiões de chuva pequenas ou fracas se o usuário não está

¹Mais informação sobre o MET disponível em http://www.dtcenter.org/met/users/docs/users_guide/MET_Users_Guide_v5.2.pdf

interessado nelas.

Este processo é chamado de convolução-limiarização. A convolução suaviza e interpola os dados sem processamento, usando para isso uma função de filtro simples:

$$C(x, y) = \sum_{u,v} \phi(u, v) f(x - u, y - v) \quad (2.1)$$

onde f é o campo original, ϕ é o filtro e C é o campo obtido, (x, y) e (u, v) são as coordenadas da grade do campo original e do filtro, respectivamente.

A função ϕ é um filtro circular simples determinado por um raio de convolução R e quantidade de pontos dentro do círculo H da forma seguinte:

$$\phi(x, y) = \begin{cases} H & x^2 + y^2 \leq R^2 \\ 0 & \end{cases} \quad (2.2)$$

Os parâmetros R e H não são independentes. Eles estão relacionados pela seguinte equação:

$$\pi R^2 H = 1 \quad (2.3)$$

Assim, o raio de influência R é o único parâmetro ajustável no processo de convolução. Uma vez escolhido R , H é determinado pela equação acima.

Uma vez que o campo C é obtido, a limiarização é realizada a partir da seleção de um limiar de intensidade de precipitação segundo a expressão:

$$M(x, y) = \begin{cases} 1 & C(x, y) \geq T \\ 0 & C(x, y) < T \end{cases} \quad (2.4)$$

Onde T é o limiar. Os objetos são as regiões conectadas onde $M = 1$.

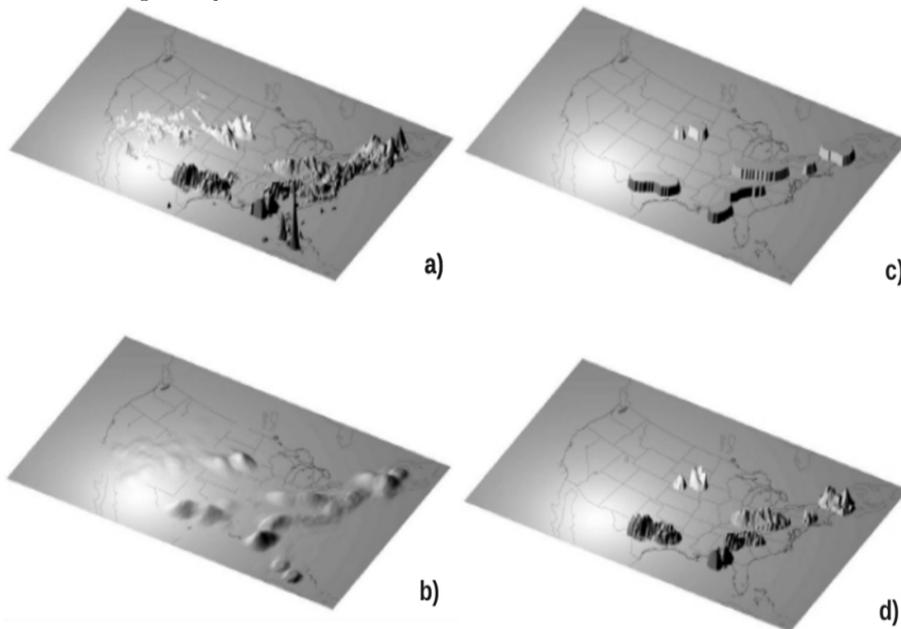
Depois da limiarização, a intensidade original do campo é restaurada nos pontos dentro dos objetos e um novo campo é obtido, chamado de Campo Objeto F :

$$F(x, y) = M(x, y)f(x, y) \quad (2.5)$$

As operações convolução e limiarização selecionam efetivamente a porção do campo que é de maior interesse para o usuário do método de avaliação, e portanto, não há necessariamente uma escolha universalmente ótima para estes parâmetros. Uma suavização mínima e um limiar muito baixo resultará em um grande número de objetos, muitos deles pequenos. Por outro lado, uma suavização forte e um limiar alto resultará em muito poucas áreas de chuva intensa. Portanto, R é definido com a escala espacial mínima de interesse (expresso em unidades de incremento de grade) e T com a intensidade mínima de chuva de interesse (expresso na unidade do campo avaliado - em mm no caso da precipitação).

A Figura 2.1 mostra um exemplo de cada um dos campos transformados nos processos convolução-limiarização para identificar áreas de chuva em um campo de precipitação.

Figura 2.1 - Exemplo da aplicação do MODE na identificação de objetos em um campo de precipitação, *a*) é o campo original, *b*) é o campo obtido no processo de convolução, *c*) é a máscara binária obtida depois da limiarização e *d*) é o campo objeto.



Fonte: Adatada de Davis et al. (2009)

2.3.2 Atributos dos objetos identificados

Após a identificação dos pixels vizinhos diferentes de zero (ou seja, os objetos), se calculam as propriedades geométricas de cada um deles que são chamadas de Atributos dos objetos, por exemplo: Área, Centroide, Ângulo de orientação, Razão de aspecto, entre outros. Uma vez determinados, eles podem ser usados para calcular atributos para pares de objetos como: Diferença de centroide, Diferença de ângulos de orientação, Área de interseção, etc. Todos eles são utilizados para agrupar objetos dentro do mesmo campo (processo chamado de *merging*), bem como para selecionar pares de objetos entre a previsão e a observação (processo chamado de *matching*), permitindo identificar relações e diferenças entre os objetos, levando à percepção dos pontos fortes e fracos da previsão.

2.3.3 Algoritmo de Lógica Difusa

O MODE emprega um sistema de lógica difusa que considera os atributos dos objetos identificados $(\alpha_1, \alpha_2, \dots, \alpha_n)$ para realizar o *merging* e o *matching* entre a previsão e a observação. A abordagem de lógica difusa está enraizada na teoria de conjuntos difusos desenvolvidos nos anos 60 (ZADEH, 1965), a qual propõe que um elemento pertence sempre em certa medida a um conjunto e nunca pertence inteiramente a ele. Isso permite uma maneira eficiente de trabalhar com incertezas, bem como para descrever um conjunto de regras que utilizaria uma pessoa para controlar um processo e dessas regras gerar ações de controle. Na lógica difusa são atribuídos graus de associação a cada uma das variáveis de entrada em relação aos conjuntos difusos, usando funções de pertinência.

O objetivo geral é imitar o processo de decisão que um ser humano exerce para concluir se existe uma correspondência entre os objetos de dois campos. No entanto, é claro que duas pessoas não usarão os mesmos critérios e aplicarão exatamente da mesma forma. Por essa razão, os autores consideram a probabilidade de que um determinado par de objetos constitua uma correspondência e utilizam a distribuição de tais valores de probabilidades entre todos os possíveis pares de objetos para obter uma avaliação do desempenho do modelo de previsão.

Para cada par de objetos (i), a lógica difusa calcula um valor de Interesse Total T_i segundo a expressão seguinte:

$$T_i(\alpha) = \frac{\sum_i w_i C_i(\alpha) I_i(\alpha_i)}{\sum_i w_i C_i(\alpha)} \quad (2.6)$$

onde:

- I_i é uma Função de Interesse aplicada aos atributos individuais para obter valores de interesse, os quais variam entre zero (não interesse) e 1 (alto interesse). Por exemplo, o mapa de interesse padrão para a diferença de centroide é 1 para pequenas distâncias e se aproxima a zero a medida que a distância aumenta. Para outros atributos como a área de intersecção, os valores baixos indicam baixo interesse e os valores elevados indicam mais interesse.
- C_i é uma Função de Confiança, definida também para atributos individuais. Essa função, com valores entre 0 e 1, reflete a confiança dos valor calculado de um atributo. No MODE todas as funções de confiança, com exceção do ângulo de orientação, são ajustadas para um valor constante de 1. Para o ângulo de orientação elas são função da relação de aspecto, onde os valores próximos de 1 representam baixa confiança e os valores longe de 1 representam alta confiança.
- w_i é um Peso escalar atribuído a cada atributo, representando uma decisão empírica sobre a importância relativa dos atributos. No desenvolvimento inicial do MODE o maior peso foi atribuído para a distância de centroide, porque a localização de sistemas de tempestades, próximos uns dos outros no espaço, parecia ser uma forte indicação que eles estavam relacionados (mais fortes do que para qualquer outro atributo).

O Interesse Total assume um valor entre 0 e 1, e pode ser interpretado como a probabilidade de uma correspondência correta. Esse valor é limiarizado e os pares de objetos com um Interesse Total acima do limiar são agrupados (se estiverem no mesmo campo) ou se correspondem (se estiverem em campos diferentes).

Uma vez feitos o *merging* e o *matching* através da lógica difusa, pode ser criada uma tabela de contingência orientada a objeto, onde todas as combinações seriam definidas da seguinte forma:

- **sucessos:** total de pares de objetos previstos-observados selecionados.
- **alarmes falsos:** total de objetos previstos que não se correspondem com os objetos observados.

- **falhas:** total de objetos na observação que não se correspondem com os objetos na previsão.

A partir dessa tabela, então podem ser escolhidos e calculados alguns índices estatísticos tradicionais como (por exemplo, GSS e CSI) para identificar correlações e diferenças entre os objetos, e fornecer algumas considerações sobre os pontos fortes e fracos da previsão.

O presente trabalho visa obter uma avaliação consistente das previsões de chuva sobre a América do Sul a partir da identificação de erros na ocorrência, intensidade e posição no espaço e no tempo dessas previsões. Para isso, uma metodologia de avaliação foi desenvolvida no SCANTEC, seguindo o algoritmo do MODE. No próximo capítulo são descritos os detalhes dessa implementação, além da aplicação de um experimento com dados sintéticos para a correta validação dessa metodologia.

3 METODOLOGIA DE AVALIAÇÃO DA PRECIPITAÇÃO ORIENTADA A OBJETO

Nos últimos anos no CPTEC tem-se discutido o desempenho de seus modelos de previsão e problemas na inter-comparação desses com outros modelos foram identificados. Por isso, a busca à sistemas robustos de avaliação de produtos de PNTC tem crescido substancialmente, em especial aqueles que possibilite uma avaliação mais justa e que seja flexível para incorporar novas funcionalidades e metodologias em um processo de evolução constante. Atualmente esse tipo de desenvolvimento, dada a complexidade e diversidade de modelos, só é obtido a partir do trabalho corporativo e integrado onde os usuários possam contribuir dentro de uma filosofia de desenvolvimento comunitário. Seguindo essa estratégia, pesquisadores da DMD do CPTEC/INPE iniciaram o desenvolvimento do SCANTEC propondo uma metodologia que explora a evolução baseada na participação ativa dos usuários do próprio sistema. A intenção é envolver tanto institutos de pesquisa como de desenvolvimento, profissionais na área acadêmica como desenvolvedores na área operacional, tanto em órgãos governamentais como na iniciativa privada. Como a intenção é envolver toda a comunidade de modelagem numérica, esse desenvolvimento precisa estar embasado por ferramentas de gerenciamento de todas as contribuições recebidas, tanto no código, como na documentação de todo o sistema. Como parte integrante da proposta o SCANTEC foi concebido dentro de um sistema de desenvolvimento eficiente adotado na DMD do CPTEC que é o SVN (*Subversion*), para o versionamento do código, e o Redmine, para o gerenciamento das contribuições e documentação de todo os processos. Dada a essa abordagem, todo tipo de iniciativa de desenvolvimento em avaliação de modelos encontra nesse sistema o melhor ambiente para contribuir com esse tema, pois torna otimizado o processo ao receber os benefícios diretos de outras iniciativas e contribuir ao disponibilizar uma ferramenta adicional para os demais usuários. Assim, com base no algoritmo desenvolvido por [Davis et al. \(2009\)](#) e a metodologia usada por [Roque et al. \(2014\)](#) e [Rodríguez et al. \(2016\)](#), a implementação de um método de avaliação orientado a objeto no SCANTEC, faz parte da metodologia proposta para ser usado como ferramenta na verificação espacial das previsões numéricas de precipitação no CPTEC.

Para melhor descrever essa proposta, a seguir é apresentada uma breve descrição da estratégia de desenvolvimento de código usada na DMD/CPTEC, detalhes gerais do SCANTEC e posteriormente as etapas do método de avaliação de precipitação orientada a objeto implementada no SCANTEC são abordadas e descritas em

detalhe. Por fim um experimento baseado em dados sintéticos de precipitação é organizado para validar essa metodologia.

3.1 Estratégia eficiente de desenvolvimento de código no CPTEC

O SVN (*Subversion*) é um sistema de controle de versão livre, o qual é usado para gerenciar arquivos e diretórios e as modificações feitas neles ao longo do tempo. Isto permite recuperar versões antigas do código ou examinar o histórico das alterações feitas. O SVN pode funcionar em rede, o que lhe possibilita ser usado por pessoas em diferentes computadores. Em certo nível, a capacidade de várias pessoas modificarem e gerenciarem o mesmo conjunto de dados de seus próprios locais é o que fomenta a colaboração. O SVN também proporciona versionamento de metadados, escolha das camadas de rede, manipulação consistente de dados, ramificações e rotulagem eficiente, e ele é implementado como um conjunto de bibliotecas compartilhadas o que o torna extremamente usável por outras aplicações e linguagens. Uma descrição mais detalhada pode ser encontrada em Collins-Sussman et al. (2007).

O SVN é usado ativamente pelo CPTEC como sistema de Gerenciamento de Projetos e Controle de Versões e ele está integrado ao sistema Redmine mediante o qual é gerenciado o desenvolvimento dos códigos de forma otimizada e compartilhada, com funcionalidades para sua documentação. O Sistema de Avaliação de Modelos (SAM), do qual faz parte o SCANTEC, é um dos projetos desenvolvidos e gerenciados através dessa plataforma na DMD do CPTEC ¹. Na mesma, podem ser encontradas páginas wiki com uma vasta e detalhada base de informações, as diferentes versões do código são gerenciadas, bem como as tarefas e um cronogramas de entrega das atividades. A partir da documentação disponível no portal do projeto foi possível o estudo da estrutura do código e a preparação do ambiente de implementação no repositório do sistema SCANTEC. O método de avaliação implementado na presente pesquisa foi incorporado diretamente na versão em uso no grupo de desenvolvedores com a finalidade de ser disponibilizada para o CPTEC, de forma que possa ser utilizada por todos os pesquisadores na avaliação dos resultados, tanto na pesquisa como na operacionalização dos produtos.

3.2 SCANTEC

O SCANTEC é um sistema computacional projetado para realizar cálculos estatísticos de forma eficiente. Ele foi desenvolvido com foco na simplicidade de uso, robustez computacional e facilidade de acesso às informações dos diversos modelos

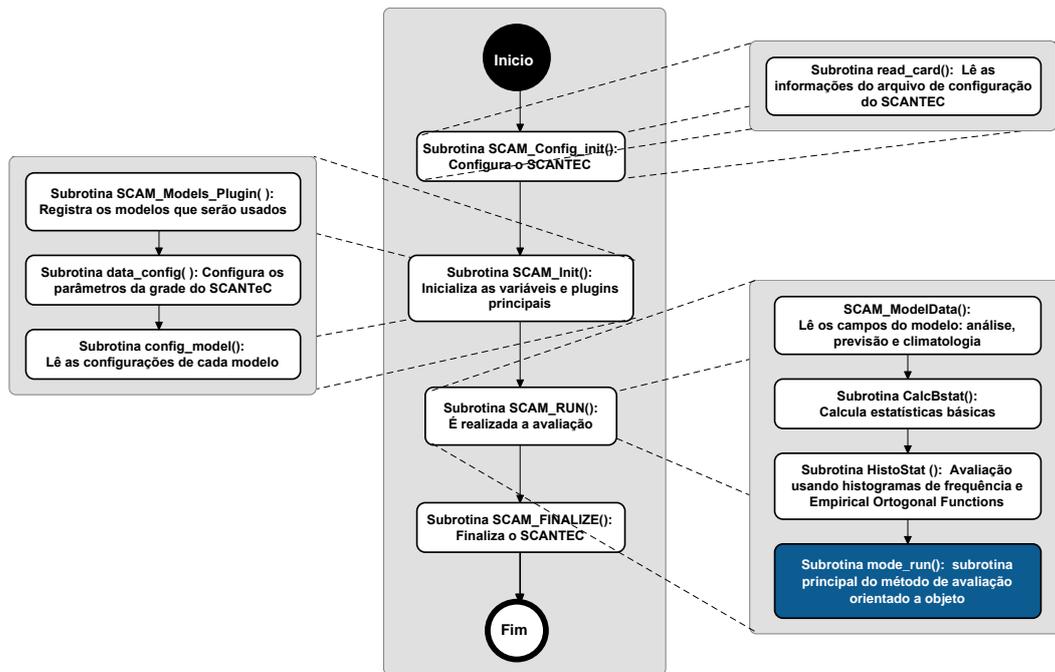
¹Disponível em <https://projetos.cptec.inpe.br/projects/scamtec>

de PNTC em uso no CPTEC e alguns tipos de dados de observação da atmosfera, sendo uma ferramenta com bom potencial para atender às necessidades dos centros regionais de previsão do tempo. A principal motivação que deu origem ao sistema foi a inter-comparação de modelos de diferentes resoluções espaciais e aplicando as mesmas métricas estatísticas. Para isso todos os modelos são levados a uma grade similar e as mesmas métricas estatísticas são neles aplicados, o que torna o processo de inter-comparação justo e coerente. Esse sistema de avaliação pode ser executado em diversas plataformas (como UNIX, Linux, Windows, MacOS), além disso está preparado para ser executado em ambientes de produção operacional, seja em clusters, supercomputadores ou mesmo em máquinas desktop. Uma interface gráfica também encontra-se em desenvolvimento para ser utilizada pelos usuários finais (não desenvolvedores), a qual facilita e torna o processo de avaliação de modelos bastante simples, permitindo que o usuário possa focar apenas nos resultados estatísticos sem se preocupar com os aspectos de programação.

O SCANTEC é composto por um núcleo central *Core* que corresponde a um conjunto de programas escritos em linguagem Fortran 90, no qual reside a rotina principal responsável por integrar as diferentes etapas que compõem o processo de avaliação dos modelos. As principais etapas são: (a) configuração do sistema; (b) leitura dos arquivos de previsões dos modelos; (c) acesso a dados adicionais usados na avaliação; (d) aplicação de métricas estatísticas; (e) totalização dos resultados depois de finalizado todo o período e (f) disponibilização dos resultados. O SCANTEC tem uma estrutura de desenvolvimento modular, onde cada uma dessas diferentes etapas estão organizadas em distintos módulos, todos integrados pelo *Core* central, o que permite que novas funcionalidades possam ser adicionados em cada etapa sem que haja a necessidade de modificar a estrutura principal do programa ou modificações nas outras etapas. Além disso, o acoplamento dos modelos com o sistema é feito através de plugins, o que permite a inclusão de novos modelos sempre que haja a necessidade do usuário, de tal forma que a mesma metodologia aplicada a um modelo seja aplicada a um outro, tornando mais justa a avaliação dos desempenhos. Essa praticidade e flexibilidade torna o desenvolvimento muito mais simples, amigável e eficiente onde diferentes desenvolvedores contribuem simultaneamente e de forma integrada (SAPUCCI et al., 2011). A Figura 3.1 apresenta um diagrama das chamadas dessa rotina principal dentro do SCANTEC.

O módulo para a leitura e escrita dos dados do SCANTEC conta com uma metodologia de processamento de forma que permite receber dados de diversos modelos, devolvendo ao usuário resultados estatísticos em formatos pré-selecionados.

Figura 3.1 - Diagrama das chamadas da rotina principal do SCANTEC, responsável por integrar as diferentes etapas que compõem o processo de avaliação dos modelos: configuração do sistema, leitura dos arquivos de previsões dos modelos, acesso a dados adicionais usados na avaliação, aplicação de métricas estatísticas, totalização e disponibilização dos resultados. A subrotina `mode_run`, em azul no diagrama, é a responsável de integrar o novo módulo de avaliação orientada a objeto.



A versão atual em desenvolvimento está preparada para ler dados binários, em suas diferentes versões, HDF4, NetCDF e GRIB1, sendo esse último o atual formato padronizado pela OMM (Organização Meteorológica Mundial), o qual é amplamente utilizado para o armazenamento de dados meteorológicos.

O módulo de estatística básica tem implementado o cálculo da *Root Mean Square Error (RMSE)*, *Mean Absolute Error (MAE)*, *BIAS* e o *Coefficiente de Correlação de Anomalia*, índices estatísticos convencionais usados na avaliação das previsões numéricas de variáveis contínuas (JOLLIFFE; STEPHENSON, 2012).

Um módulo específico para a avaliação da precipitação está implementado no SCANTEC independente do módulo de estatística básica, no qual está incluída uma métrica de avaliação usando histograma de frequência e um outra baseada em EOF (*Empirical Ortogonal Funtions*). Na primeira métrica são quantificados,

em diferentes classes de intensidades, os pontos da grade dos modelos onde as precipitações ocorrem. Um ponto principal dessa análise é que a localização da precipitação não é considerada, de tal forma que apenas a frequência de precipitações em diferentes classes é avaliada. Resultados dessa metodologia são reportados em [Avanço et al. \(2016\)](#). A metodologia baseada em EOFs, por sua vez procura avaliar os modelos capazes de capturar o padrão de variabilidade da precipitação dentro de um período de tempo, sem avaliar com precisão o posicionamento ou a intensidade dos eventos, com uma visão geral ao padrão espacial dessa variável. Resultados preliminares utilizando essa metodologia são reportados por [Baños et al. \(2016\)](#). Ambas métricas utilizam como referencia os dados observacionais compostos pela combinação de medidas pontuais produzidas pela rede pluviométrica e medidas indiretas baseadas em técnicas de sensoriamento remoto obtidas através de sensores a bordo de satélites ou radares meteorológicos. Sob o ponto de vista dos dados observacionais de precipitação, o módulo de leitura desses dados inclui uma metodologia de interpolação espacial com base nos esquemas utilizados pelo NCEP, visando manter uma boa qualidade e representabilidade espacial das próprias observações. Mais informações sobre os dados observacionais utilizados como referência na avaliação da precipitação são apresentados na próxima seção. Como pode-se notar ambos os métodos disponíveis no sistema não consideram as características espaciais dos eventos de precipitação, o que é resolvido com a inclusão de um método orientado a objeto.

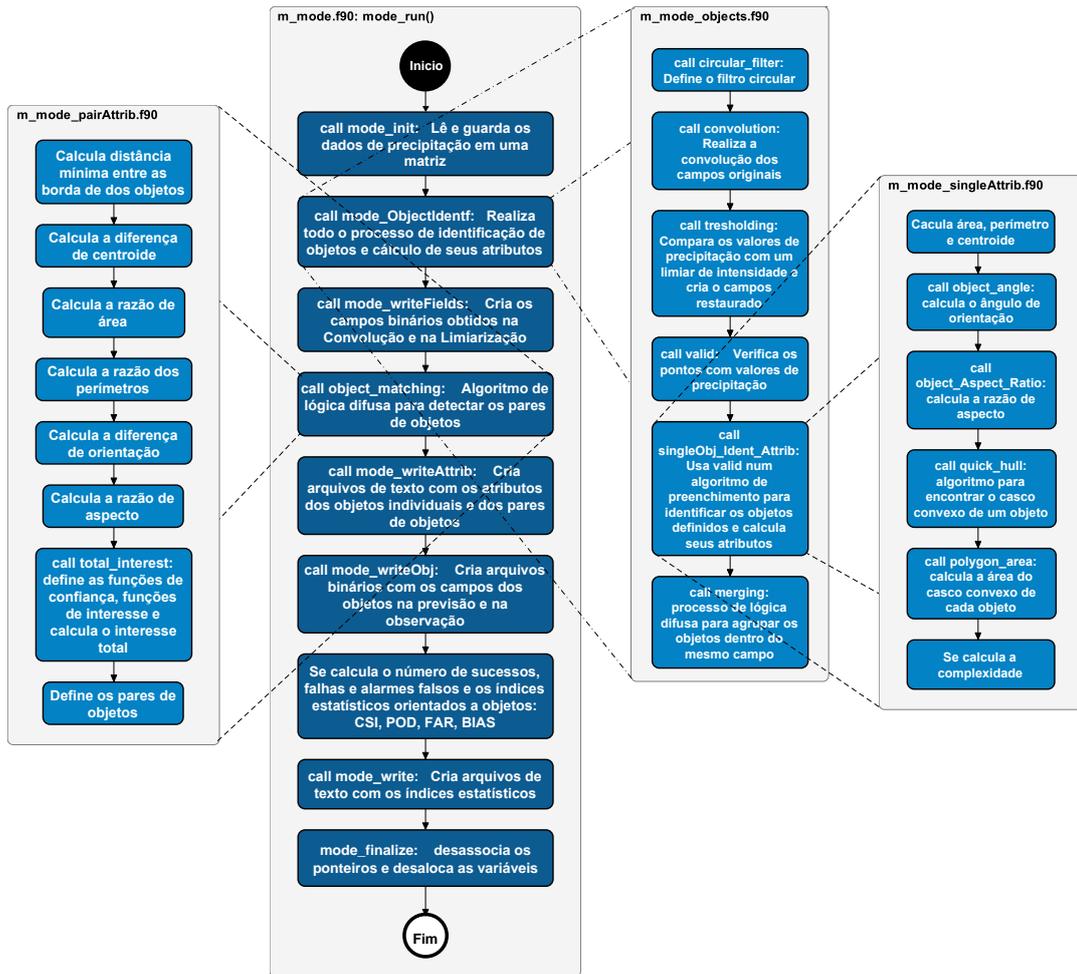
3.3 Método de avaliação orientada a objeto no SCANTEC

Para a implementação do método orientado a objeto foi criado, dentro do *Core* do SCANTEC, um módulo principal que faz a utilização das sub-rotinas de 3 módulos independentes. Cada um desses módulos foi configurado seguindo a estrutura dos outros módulos do sistema, e foram realizadas as modificações necessárias nos arquivos que armazenam as dependências de bibliotecas externas para ser feita a compilação. A Figura 3.2 apresenta o diagrama das chamadas das subrotinas dos módulos responsáveis por realizar a avaliação orientada a objeto.

Os quatro módulos criados são:

- **m_mode**: é o módulo principal da avaliação orientada a objeto, ele contém a sub-rotina responsável pela execução de todo o algoritmo do método: identificação de objetos, cálculo de atributos, agrupação de objetos dentro do mesmo campos, determinação dos pares de objetos e cálculo dos

Figura 3.2 - Diagrama das chamadas da rotina principal do módulo m_mode no SCANTEC.



índices de avaliação.

- **m_mode_objects:** nesse módulo estão definidas as sub-rotinas usadas para identificar as áreas de chuva: cálculo do filtro circular, convolução, limiarização, criação do campo objeto e o algoritmo de preenchimento.
- **m_mode_singleAttrib:** é o módulo que contém as sub-rotinas que calculam as propriedades geométricas dos objetos individuais, nele estão definidos: o centroide, o ângulo de orientação, a razão de aspecto e os algoritmos *Quickhull* e *Quicksort* usados no cálculo da complexidade.
- **m_mode_pairAttrib:** aqui estão definidas as sub-rotinas que calculam os atributos de pares de objeto, as funções de interesse e função de confiança para cada atributo, bem como a sub-rotina que calcula o Interesse Total e as sub-rotinas que realizam o *merging* e o *matching* dos objetos.

3.3.1 Processo de identificação de objetos

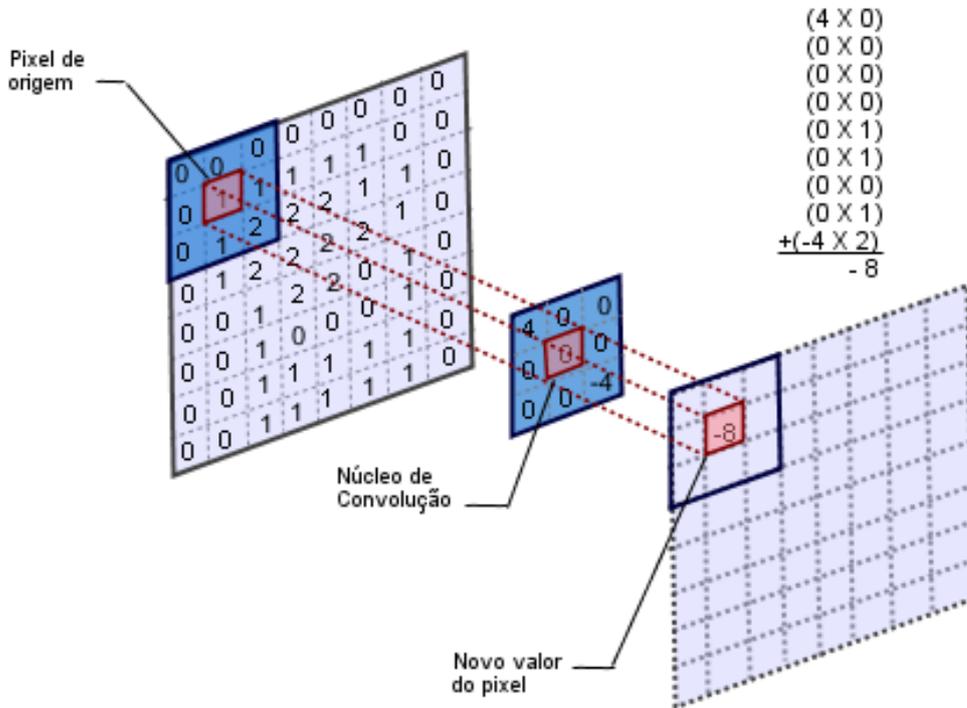
O processo de identificação de objetos ou regiões de chuva começa com a transformação dos campos originais Previsão e Observação. A primeira parte dessa transformação foi feita usando a equação 2.1, para isso se utilizou um filtro circular (dimensão 3x3) definido pela função:

$$\phi(u, v) = \begin{cases} \frac{1}{P} & (u - u_c)^2 + (v - v_c)^2 \leq R^2 \\ 0 & (u - u_c)^2 + (v - v_c)^2 > R^2 \end{cases} \quad (3.1)$$

onde P é a quantidade de pontos do filtro que se encontram dentro do círculo de raio R , centrado em (u_c, v_c) . O raio foi especificado em termos de unidades de grade, definido como $R = \frac{d}{2}$, sendo d a dimensão do filtro circular. A Figura 3.3 mostra como é realizada a convolução usando o filtro circular. O centro do filtro circular, chamado de núcleo de convolução, se sobrepõe sobre cada pixel da matriz do campo de precipitação original, de forma que o novo valor do pixel no campo de convolução é igual à soma do produto de cada pixel do filtro por o pixel correspondente no campo original.

Após a convolução, a definição dos objetos se completou segundo a comparação dos valores dos campos com um determinado limiar usando as equações 2.4 e 2.5, eliminando assim os valores muito baixos de precipitação.

Figura 3.3 - Exemplo da aplicação do filtro circular no algoritmo de convolução.



Fonte: adaptada de

<http://courses.engr.illinois.edu/ece198kl/sp2013/programs/prog6.pdf>

A identificação e classificação de cada objeto foi feita através de o *algoritmo de preenchimento* ² desenvolvido por Sierra et al. (2016) que detecta as regiões conectadas dentro do campo.

3.3.2 Cálculo das propriedades geométricas dos objetos

Depois de aplicado o algoritmo de identificação de cada objeto foi aplicado o cálculo das propriedades geométricas de cada uma das regiões de chuva. As propriedades geométricas básicas de cada eventos de precipitação considerados individualmente são: (a) área, a qual é definida como à quantidade de pontos de grade no interior do objeto; (b) perímetro, sendo entendido como a quantidade de pontos de grade que compõe a fronteira do objeto, (c) centroide, sendo as coordenadas média calculadas pela média dos valores das abscissas e das ordenadas dentro do objeto analisado.

²Os algoritmos de preenchimento ou *fill algorithms* são usados para detectar regiões conectadas em imagens digitais binárias, embora também possam ser processadas imagens em cores e dados com maior dimensionalidade. Mais informação em <https://www.codeproject.com/articles/336915/connected-component-labeling-algorithm>

A partir dessas propriedades básicas outras mais elaboradas podem ser obtidas, tais como:

- **Ângulo de orientação:** é o ângulo que o eixo longo do objeto faz com relação à direção da grade (a direção x), e foi calculado segundo o algoritmo descrito por [Chaudhuri and Samal \(2007\)](#) através da equação:

$$\tan 2\theta = \frac{2 \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n [(x_i - \bar{x})^2 - (y_i - \bar{y})^2]} \quad (3.2)$$

onde (x_i, y_i) , $i = 1, 2, \dots, n$ são os n pontos da fronteira do objeto, e (\bar{x}, \bar{y}) são as coordenadas do centroide do objeto.

- **Razão de aspecto:** é a razão definida pela largura do objeto dividida pelo seu comprimento (eixo menor/eixo maior). Usando as equações da recta descritas em [Chaudhuri and Samal \(2007\)](#) e o ângulo de orientação θ foram calculados ambos eixos dos objetos:

$$(y - \bar{y}) - \tan \theta (x - \bar{x}) = 0 \quad (3.3)$$

$$(y - \bar{y}) - \cot \theta (x - \bar{x}) = 0 \quad (3.4)$$

Com a equação 3.3 se calculou o eixo maior e com a equação 3.4 o eixo menor foi calculado.

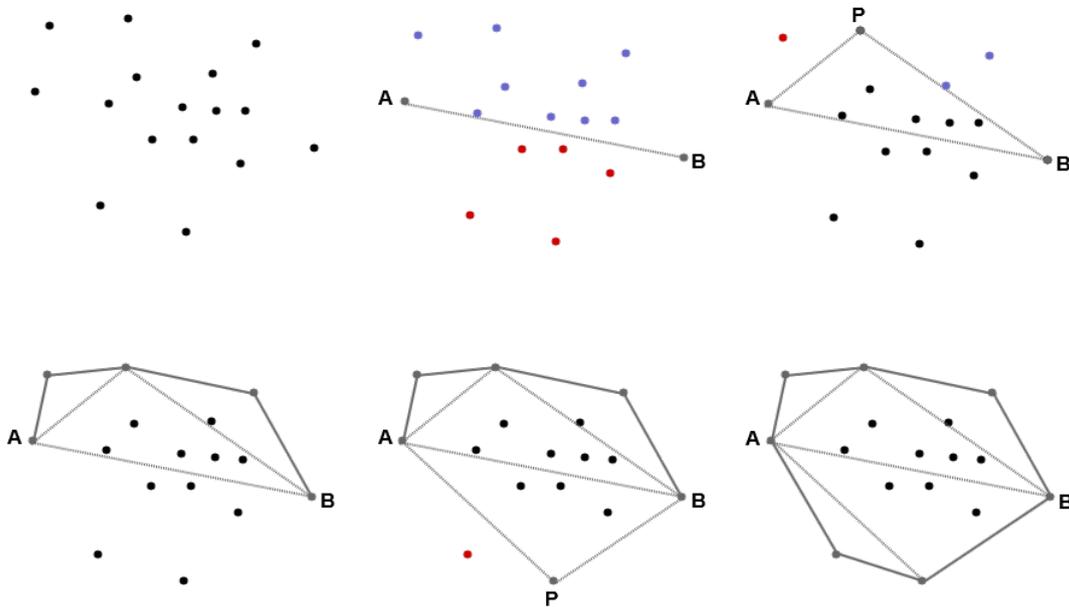
- **Complexidade:** a qual é a relação entre a área de um objeto e a área de seu casco convexo. O casco convexo de um conjunto de pontos no plano é o menor polígono convexo que os envolve ³. Desse modo, todos os pontos devem estar dentro do polígono ou sobre sua borda. Para calcular os pontos que compõem o casco convexo de cada objeto, se utilizou o algoritmo *Quickhull* descrito em [Mount \(2000\)](#) e exemplificado na Figura 3.4.

A entrada inicial para o algoritmo é o conjunto de pontos que formam o objeto:

- a) A primeira operação feita é o cálculo dos dois pontos máximos no eixo horizontal (A e B), os quais são garantidos para ser parte do polígono do casco convexo.

³Uma figura geométrica qualquer é chamada de convexa se ela incluir todos os segmentos de retas que unem os seus pontos.

Figura 3.4 - Exemplo da aplicação do algoritmo Quickhull no cálculo do casco convexo de um objeto.



- b) A linha formada por esses dois pontos é usada para dividir o conjunto em duas partes diferentes. O conjunto de pontos à esquerda da linha \overline{AB} é considerado uma parte, e o conjunto de pontos à direita dela é considerado outra. Ambas partes são processadas recursivamente.
- c) Para o conjunto de pontos à esquerda, se identifica o ponto (P) com a maior distância da linha divisória, esse ponto junto com o ponto inicial A da linha e o ponto final B forma um triângulo. Os pontos dentro do triângulo $\triangle APB$ não podem fazer parte do polígono convexo, portanto são ignorados nos próximos passos.
- d) Tendo isso em conta, o processamento recursivo pode ocorrer novamente. Os pontos à direita do triângulo são usados como um subconjunto, e os pontos à esquerda dele como um outro.
- e) O mesmo procedimento é feito para o conjunto de pontos à direita da linha divisória.

Uma vez calculado o casco convexo, a área desse polígono foi definida como o total de pontos de grade no interior do mesmo, e a complexidade foi calculada como:

$$Complex = \frac{A_{objeto}}{A_{casco_convexo}} \quad (3.5)$$

3.3.3 Cálculo dos atributos de cada um dos pares de objetos

As propriedades descritas anteriormente foram calculadas para cada um dos objetos individuais, e usadas na comparação entre objetos através do cálculo de atributos para todos os possíveis pares de objetos. Os seguintes atributos foram utilizados:

- **Distância mínima entre as bordas:** sendo definida como a distância entre os pontos mais próximos de dois objetos (equação 3.6), a qual representa uma medida da proximidade das fronteiras dos objetos.

$$d_{min} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.6)$$

- **Diferença de centroide:** sendo essa a diferença (vetorial) entre os centroides de dois objetos, foi definida como:

$$d_{centroide} = \sqrt{(x_{c_i} - x_{c_j})^2 + (y_{c_i} - y_{c_j})^2} \quad (3.7)$$

onde x_{c_i} , x_{c_j} , y_{c_i} e y_{c_j} representam as posições dos centroides dos objetos.

- **Razão das áreas:** a qual foi definida como a relação entre a área do objeto menor e a área do objecto maior segundo a equação 3.8, ela proporciona uma medida da semelhança entre os objetos, quanto ao tamanho dos mesmos.

$$r_{area} = \frac{A_{menor}}{A_{maior}} \quad (3.8)$$

Da mesma forma, foram definidas a **razão dos perímetros**, a **proporção de aspecto** e a **razão das complexidades**, através das equações 3.9, 3.10 e 3.11, respectivamente. Todos esses atributos fornecem uma medida da semelhança entre os objetos, quanto a sua forma.

$$r_{per} = \frac{P_{menor}}{P_{maior}} \quad (3.9)$$

$$p_{aspecto} = \frac{r_{menor}}{r_{maior}} \quad (3.10)$$

$$r_{complex} = \frac{C_{menor}}{C_{maior}} \quad (3.11)$$

- **Diferença de orientação:** a qual foi calculada como a diferença entre os ângulos de orientação dos dois objetos (equação 3.12), a qual representa uma medida da diferença na inclinação dos eixos dos objetos.

$$d_{angulo} = \theta_i - \theta_j \quad (3.12)$$

- **Razão da área de interseção:** definida como a área que está dentro de ambos os objetos simultaneamente e calculada segundo a equação 3.13.

$$r_{int} = \frac{A_{int}}{A_i + A_j - A_{int}} \quad (3.13)$$

onde A_i e A_j são as áreas de dois objetos e A_{int} é a área de interseção entre eles.

3.3.4 Processo de identificação de pares de objeto

O processo de identificação de pares de objetos foi dividido em duas etapas: o agrupamento ou fusão das regiões de chuva dentro dos campos (*merging*) e a seleção dos pares de objeto de campos diferentes (*matching*). Ambas etapas estão baseadas na comparação entre objetos usando os atributos descritos anteriormente, no cálculo do Interesse Total segundo a equação 2.6. O objetivo de fazer o *merging* nos campos de precipitação é determinar se os objetos ou regiões de chuva devem ser tratadas como regiões independentes ou como uma mesma região, mas sem afetar sua morfologia. Como descrito na seção 2.3.3, a identificação dos pares de objeto depende de um valor de Interesse Total o qual é calculado através de funções de interesse, funções de confiança e pesos atribuídos aos atributos dos pares de objeto, os quais são descritos a seguir:

- **Funções de interesse:** identificados por I_i elas são definidas de duas formas. Para os atributos calculados baseados nas diferenças, o interesse parcial foi obtido segundo a seguinte equação:

$$I_i(\alpha_i) = \begin{cases} 1 & \alpha_i \leq l_{inf} \\ \frac{l_{sup} - \alpha_i}{l_{sup} - l_{inf}} & l_{inf} < \alpha_i < l_{sup} \\ 0 & \alpha_i \geq l_{sup} \end{cases} \quad (3.14)$$

Para os atributos baseados nas razões, o interesse parcial se calculou da seguinte forma:

$$I_i(\alpha_i) = \begin{cases} 0 & \alpha_i \leq 0 \\ \frac{\alpha_i}{l_{sup}} & l_{inf} < \alpha_i < l_{sup} \\ 1 & \alpha_i \geq l_{sup} \end{cases} \quad (3.15)$$

Nas equações 3.14 e 3.15, α_i representa o valor do atributo (i) para o qual está sendo calculado o interesse, l_{inf} e l_{sup} representam os limites inferior e superior da função de interesse I_i . Esses limites devem ser definidos cuidadosamente para garantir um resultado correto da avaliação. A configuração escolhida para esses limites são apresentados na Tabela 3.1, os quais são os mesmos adotados como padrão na versão 5.2 do MET ⁴.

Tabela 3.1 - Definição dos limites inferior e superior para as funções de interesse de cada atributo (*grid_res* refere-se à resolução da grade em km.)

Atributos	Limite inferior	Limite superior
Distância Mínima entre as bordas	0	400km/ <i>grid_res</i>
Diferença de centroide	40km/ <i>grid_res</i>	600km/ <i>grid_res</i>
Razão das áreas	0	0.8
Razão dos perímetros	0	0.8
Diferença de ângulo	$\pi/6$	$\pi/2$
Razão de aspecto	0	0.8
Razão de complexidade	0	0.8
Razão da área de interseção	0	0.25

- **funções de confiança:** identificadas por C_i , como no algoritmo de Davis et al. (2009), elas são ajustadas com um valor constante igual a 1, com exceção do ângulo de orientação e da diferença de centroides. Segundo os autores, a função de confiança de um determinado atributo é menor do que a unidade se o atributo se torna muito sensível a pequenas alterações nos dados ou deixa de fornecer informações úteis sobre o erro da previsão em determinadas situações.

No caso do ângulo de orientação, ele torna-se muito sensível a pequenas

⁴Disponível em http://www.dtcenter.org/met/users/docs/users_guide/MET_Users_Guide_v5.2.pdf

mudanças na forma do objeto se a relação de aspecto é quase igual à unidade. Podemos então obter grandes diferenças na orientação entre dois objetos para mudanças sutis na forma deles. Assim, a confiança de que podemos atribuir um erro relacionado ao ângulo de orientação se aproxima a zero como a relação de aspecto de qualquer objeto se aproxima à unidade. Assim, a função de confiança para esse atributo foi calculada como:

$$C_i = \left[\frac{(r - 1)^2}{r^2 + 1} \right]^{0.3} \quad (3.16)$$

onde r a relação de aspecto do objeto. Para derivar a confiança de um par de objeto, calcula-se a raiz quadrada do produto dos valores de confiança obtidos para cada objeto separadamente. Quando esse valor de confiança é quase zero, remove-se a contribuição da diferença de ângulo para o Interesse Total.

Por outro lado, se dois objetos têm uma área muito diferente, ou seja, uma pequena razão das áreas, então a diferença dos centroides é uma medida menos relevante do erro de previsão do que se os objetos (previsto e observado) tiverem um tamanho similar. Portanto, a confiança para a diferença dos centroides foi definida igual à razão das áreas, de modo que se é igual a zero, a separação dos centroides não é considerada no cálculo do Interesse Total.

- **Função dos pesos:** identificada por w_i foi definida dando mais importância à proximidade dos objetos no espaço, o maior peso foi atribuído para a mínima distância entre as bordas dos objetos porque foi considerado o atributo mais representativo da qualidade das previsões. Em segundo grau de importância foram considerada a distância do centroide e a área de interseção, representando a proximidade entre os objetos previstos e observados. A diferença de orientação e a razão entre as áreas foram consideradas um pouco menos indicativas da qualidade da previsão, mas o suficiente importantes para inclui-las, atribuindo um menor peso para elas. O perímetro, a razão de aspecto e a complexidade não foram incluídos no cálculo do Interesse Total.

3.3.5 Índices calculados para à avaliação

Como apresentado no final da seção 2.3.3, o total de objetos identificados em cada campo e o total de pares de objeto, definem os sucessos (a), alarmes falsos (b) e

falhas (c) na previsão numérica da precipitação (equações 3.17, 3.18 e 3.19):

$$a = N_{par} \quad (3.17)$$

$$b = N_{prev} - N_{par} \quad (3.18)$$

$$c = N_{obs} - N_{par} \quad (3.19)$$

onde N_{obs} é o número de objetos identificados na observação, N_{prev} é o número de objetos identificados na previsão e N_{par} é o total de pares de objetos.

Esses parâmetros foram usados no cálculo de índices estatísticos para avaliar o desempenho do modelo. Foram implementados no MODE o CSI, a POD, a FAR o Bias e o ETS, todos a partir de abordagem orientada a objeto. A aplicação destes índices difere da aplicação tradicional na verificação de previsão numérica, porque aqui a avaliação é realizada para objetos e não para células da grade individualmente.

Além desses índices, o Máximo Interesse atingido em cada objeto previsto (MIP) e o Máximo Interesse atingido por cada objeto observado (MIO) foram usados no cálculo de uma métrica útil da qualidade da previsão. Essa métrica é chamada de Média do Máximo Interesse (MMI) e também poder ser usada para comparar as previsões de vários modelos. A Tabela 3.2 representa a matriz Interesse da comparação de cada objeto previsto com todos os objetos observados (linhas) e de cada objeto observado com todos os objetos previstos (colunas). O vetor do MIP se corresponde com o máximo valor de interesse de cada linha (0.9, 0.8, 0.5) e o vetor do MIO se corresponde com o máximo valor de interesse de cada coluna (0.9, 0.8). Então o MMI é definido como o valor médio do MIP mais MIO o qual é igual a 0.7 no exemplo da Tabela 3.2. Entre as principais vantagens de usar essa métrica estão: que não depende do limiar imposto para o Interesse Total, não depende do total de pares de objetos e leva em conta todos os atributos usados no cálculo do Interesse Total.

No entanto, como explicado e usado por Davis et al. (2009), para reduzir o impacto de valores atípicos, em futuras aplicações do método a mediana desses valores deve ser utilizada ao invés da média.

Tabela 3.2 - Exemplo da Matriz Interesse da comparação de 3 objetos previstos com 2 objetos observado para uma previsão hipotética.

Previstos	Observados	
	1	2
1	0.9	0.7
2	0.5	0.8
3	0.4	0.5

Fonte: Adatada de Davis et al. (2009)

3.4 Experimentos para a Validação do MODE

Como um exemplo relativamente simples para apresentar os resultados quantitativos do MODE, e também como uma forma de validar o método implementado, foram considerados seis campos idealizados de padrões elípticos de precipitação (Figura 3.5) seguindo o esquema usado por Ahijevych et al. (2009). Esses padrões retratam células simples de tempestade ou sistemas convectivos de meso-escala com um núcleo de alta intensidade em uma região de baixa precipitação. O núcleo de alta intensidade é deslocado para a direita do centro dentro de cada área de chuva. Na Figura, 3.5(a) se corresponde com o campo usado como observação, e 3.5(b), 3.5(c), 3.5(d), 3.5(e) e 3.5(f) apresentam os padrões de chuva previstos pelos modelos EXP01, EXP02, EXP03, EXP04 e EXP05, respectivamente.

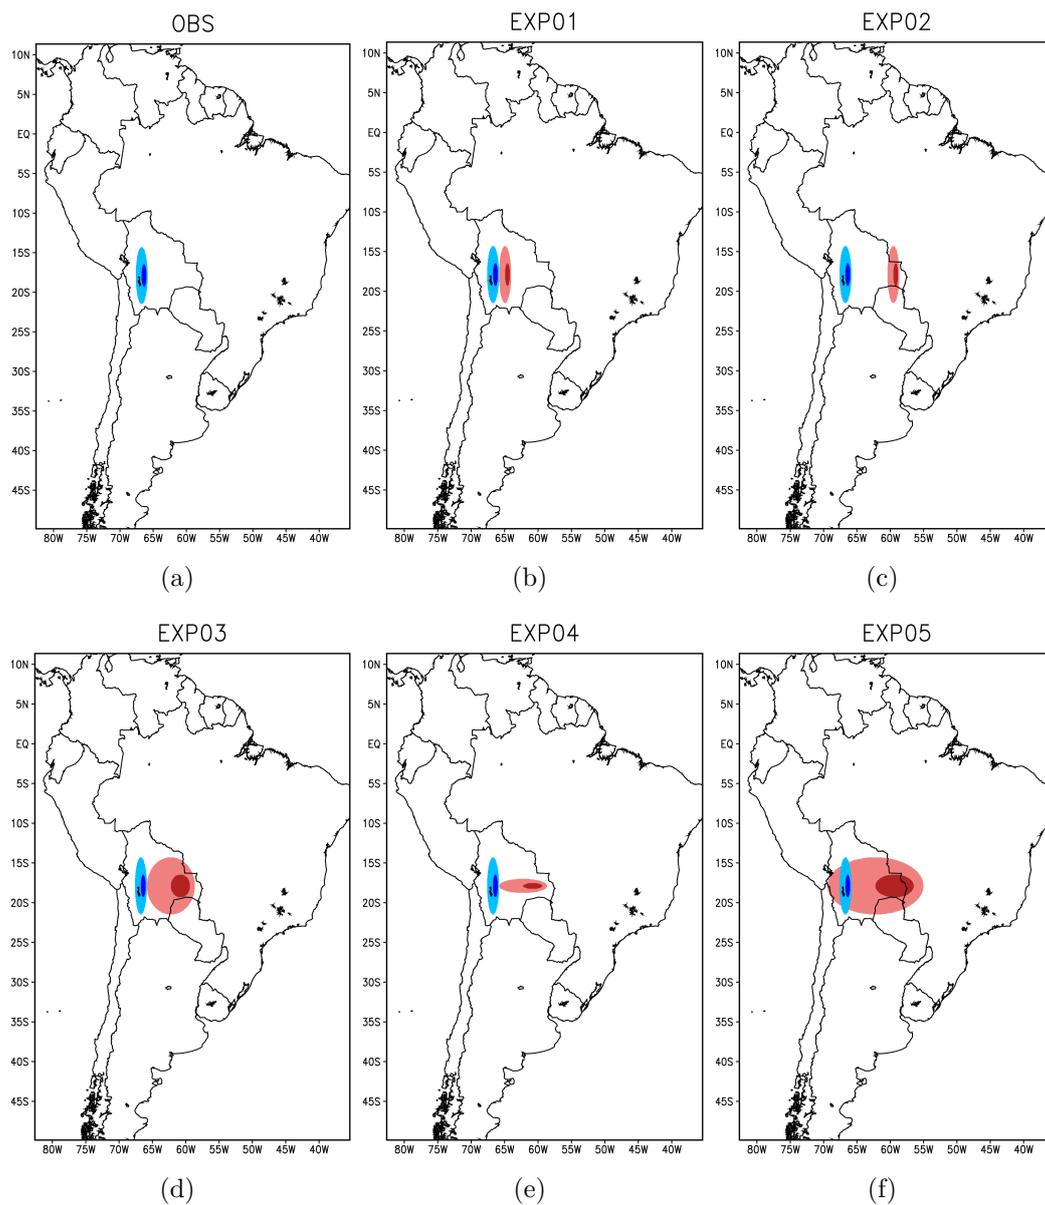
Todas as áreas geométricas de precipitação foram definidas em uma grade de 1313 x 1702 pontos com um incremento de grade de 0.036° ou $4km$, representando a região da América do Sul. A formulação exata dos campos de precipitação, baseada na equação geral da elipse, é:

$$R(x, y) = \begin{cases} 0.0 \text{ mm}, & \left(\frac{x-x_1}{a}\right)^2 + \left(\frac{y-y_1}{b}\right)^2 \geq 1 \\ 12.0 \text{ mm}, & \left(\frac{x-x_1}{a}\right)^2 + \left(\frac{y-y_1}{b}\right)^2 < 1, \quad \left(\frac{x-x_2}{0.4a}\right)^2 + \left(\frac{y-y_1}{0.4b}\right)^2 \geq 1 \\ 25.0 \text{ mm}, & \left(\frac{x-x_2}{0.4a}\right)^2 + \left(\frac{y-y_1}{0.4b}\right)^2 < 1 \end{cases} \quad (3.20)$$

com $y_1 = 884$ e $x_2 = x_1 + 0.4a$, onde x e y são os índices dos pontos da grade de 1313 x 1702, a controla a largura da elipse ao longo do eixo x e b controla a largura ao longo do eixo y ; (x_1, y_1) é o centro da elipse de baixa intensidade, e (x_2, y_1) é o centro da elipse de alta intensidade. O valor de precipitação R é zero fora da elipse de baixa intensidade, 12.0 mm dentro da elipse de baixa intensidade mas fora do núcleo de alta intensidade, e 25.0 mm dentro do núcleo de alta intensidade.

Além da localização, as únicas diferenças entre os padrões geométricos são a área de

Figura 3.5 - Padrões idealizados de precipitação para ilustrar erros específicos nas previsões de chuva de cinco modelos diferentes. O objeto de precipitação previsto (vermelho) está posicionado à direita do objeto observado (azul). Note que, em (f) os objetos da previsão e da observação se sobrepõem.



previsão e a relação de aspecto. As variáveis x_1 , a e b são definidas na Tabela 3.3. O deslocamento na direção x é governado por x_1 e a relação de aspecto da elipse é a razão sem unidade a/b .

Tabela 3.3 - Parâmetros utilizados na Equação 3.20 para definir os campos sintéticos de precipitação geométrica na Figura 3.5.

Experimentos	x_1	a	b
OBS	442	25	100
EXP01	492	25	100
EXP02	642	25	100
EXP03	567	100	100
EXP04	567	100	25
EXP05	567	200	100

O Interesse Total e o ETS são anotados em cada exemplo. Os parâmetros para o cálculo do Interesse Total foram descritos na seção anterior e são os mesmos usados para as previsões numéricas dos casos reais. Nesses casos idealizados, não foram aplicados limiares de intensidade de precipitação.

As eventos sintéticos de previsões foram idealizados geometricamente para ilustrar quatro tipos de erro: deslocamento, orientação, Viés de frequência, e relação de aspecto. Segundo [Ahijevych et al. \(2009\)](#) os erros de deslocamento e de relação de aspecto são difíceis de identificar com os métodos de verificação tradicionais, essa afirmação é comprovada no análise desses casos. O conhecimento desses erros pode ser útil para o desenvolvimento e melhoria dos modelos de PNTC e pode ser informativo para os usuários das previsões.

Observe-se que as previsões dos dois primeiros modelos EXP01 e EXP02, e o caso EXP04 (Figuras 3.5(b), 3.5(c) e 3.5(e)) ilustram erros de deslocamento. Os objetos nas previsões EXP01 e EXP04 encontram-se deslocados 2 pontos à direita do objeto observado, mas no caso do EXP02 o objeto da previsão é deslocado muito mais para a direita (200 pontos). A previsão EXP04, além do erro de deslocamento, apresenta um erro na orientação do objeto. O EXP01 é claramente mais acertado do que os EXP02 e EXP04, mas os resultados tradicionais de verificação, apresentados na Tabela 3.4, sugerem que eles são igualmente pobres mostrando valores equivalentes para esses três casos.

Quando a precipitação prevista não se sobrepõe às observações, os índices tradicionais como o CSI e o ETS são zero ou menor do que zero, indicando nenhuma habilidade ou habilidade negativa. Esse é o caso das previsões EXP01, EXP02, EXP03 e EXP04 (Figuras 3.5(b), 3.5(c), 3.5(d) e 3.5(e)). Mesmo que elas compartilham a característica de que não se sobrepõem à observação, EXP03 tem uma probabilidade ligeiramente maior de falsa detecção e menor ETS do que os outros, porque o objeto de maior tamanho aumenta a taxa de alarmes falsos e diminui as previsões nulas corretas.

Os objetos nas previsões EXP03 e EXP05 (Figuras 3.5(d) e 3.5(f)) estão esticados na dimensão x , ilustrando um Viés mais intenso. No EXP05 o Viés é maior mas a FAR, o ETS e o CSI são superiores ao resto dos casos geométricos. Esses índices consideram apenas a sobreposição das regiões de chuva e comparando os resultados de cada um deles, alguns usuários poderiam preferir a previsão do EXP05, no entanto um maior valor do CSI não indica necessariamente que a previsão é melhor; como descrito por Ahijevych et al. (2009) esses índices podem ser enganosos e não devem ser usados isoladamente.

O outro tipo de erro presente nas previsões está relacionado à razão de aspecto, a largura dos objetos previstos no EXP03 e EXP05 é demasiado grande comparada com a largura do objeto observado. As características geométricas de cada um dos objetos são mostradas na Tabela 3.5.

Tabela 3.4 - Índices de verificação tradicionais aplicados as previsões da Figura 3.5.

Índices Tradicionais	EXP01	EXP02	EXP03	EXP04	EXP05
BIAS	1.0	1.0	4.017530	1.0	8.034421
POD	0.0	0.0	0.0	0.0	0.876136
FAR	1.0	1.0	1.0	1.0	0.890952
CSI	0.0	0.0	0.0	0.0	0.107392
ETS	-0.001750	-0.001752	-0.002808	-0.001752	0.104307

A importância dos indicadores de qualidade das previsões é modificada quando é aplicado um método orientado a objeto. O modelo com maior Interesse Total é o EXP01 (Figura 3.5(b)) no qual o deslocamento da posição é pequeno e a correspondência estrutural é exata. O modelo com menor Interesse Total é o EXP02 (Figura 3.5(c)) no qual o deslocamento da posição é grande. Lembrando da equação

Tabela 3.5 - Atributos dos objetos identificados nas previsões da Figura 3.5.

Características Geométricas	EXP01	EXP02	EXP03	EXP04	EXP05
Distância mín entre as bordas	2 pts	152 pts	2 pts	2 pts	0
Diferença de centroide	50 pts	200 pts	125 pts	125 pts	125 pts
Razão das áreas	1	1	0.248909	1	0.124465
Razão de aspecto	1	1	0.250000	1	0.500000
Diferença de orientação	0°	0°	0°	90°	90°
Razão de complexidade	1	1	0.978464	0.434709	0.450015
Razão da área de interseção	0	0	0	0	0.107392
Interesse Total	0.73025	0.18586	0.57624	0.53723	0.63537

2.6 na qual indica que o Interesse Total é a relação entre a soma do produto de peso, confiança e interesse parcial e a soma do produto de peso e confiança. No EXP02 o deslocamento do centroide produz um valor nulo no interesse parcial (Figura 3.6(a)) afetando o numerador dessa equação e, portanto, o valor do Interesse Total é menor.

O modelo EXP04 (Figura 3.5(e)) tem um valor de Interesse Total mais baixo do que a previsão do modelo EXP03 (Figura 3.5(d)). A diferença entre esses dois casos vem da confiança atribuída à diferença na posição do centroide e à orientação das áreas de chuva. Para um objeto redondo como em EXP03, não temos confiança no ângulo atribuído (Figura 3.7(b)), portanto, o termo da diferença de ângulo não comparece no numerador e nem no denominador da expressão do Interesse Total. No EXP04 os ângulos estão bem definidos, a diferença de 90° na orientação produz um valor de interesse parcial de zero (Figura 3.6(a)), mas o denominador ainda mantém o peso do termo da diferença de ângulo, e esse fato tende a diminuir o valor do Interesse Total comparado com EXP03.

Na previsão do EXP05 (Figura 3.5(f)) como os objetos diferem muito em tamanho, a confiança atribuída para a separação do centroide é menor (Figura 3.7(a)) e contribuição do peso desse atributo no denominador da equação 2.6 também é

Figura 3.6 - Mapas de Interesse dos atributos diferença de centroide e diferença de ângulo

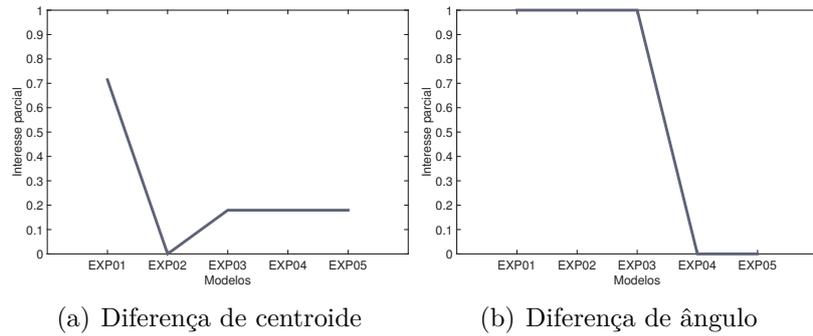
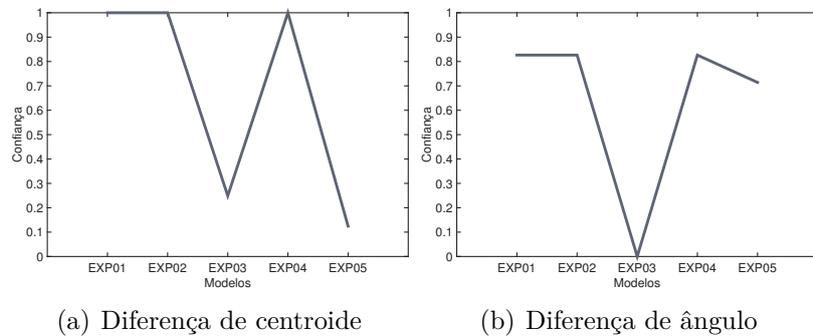


Figura 3.7 - Mapas de Confiança dos atributos diferença de centroide e diferença de ângulo



reduzida. Porém ele não é o modelo mais pobre porque o *matching*, além de estar ponderado em relação aos erros de posição também dá algum crédito à sobreposição entre as áreas. Dando um menor peso para a área de interseção e um maior peso para a razão das áreas teria permitido que o Interesse Total do EXP03 seja maior do que do EXP05.

Os resultados discutidos aqui indicam uma das sensibilidades da técnica orientada a objeto utilizada: é o usuário do método de avaliação quem define a influência dos atributos no cálculo do Interesse Total, visando representar os aspectos da previsão que são de maior importância para ele. Contudo, os resultados do método de avaliação também ilustram maior consistência do que os resultados obtidos com as métricas convencionais de avaliação.

Os parâmetros obtidos com a aplicação do método orientado a objeto, tanto os atributos dos objetos bem como as funções de interesse parcial, funções de confiança e os valores do Interesse Total em cada uma das previsões, apresentam uma semelhança com os resultados obtidos por Ahijevych et al. (2009), provando assim

o correto funcionamento do método de avaliação aqui proposto.

4 PROVA DE CONCEITO: APLICAÇÃO DA METODOLOGIA DE AVALIAÇÃO ORIENTADA A OBJETO ÀS PREVISÕES DE PRECIPITAÇÃO SOBRE A AMÉRICA DO SUL

Visando demonstrar o potencial da metodologia de avaliação de precipitação orientada à objeto nas previsões produzidas pelo CPTEC, com ênfase para a América do Sul, os campos de precipitação previstos pelo modelo BRAMS (5km de resolução) foram utilizados. Um experimento de avaliação foi organizado como prova de conceito da metodologia proposta, o qual é baseado na filosofia de aplicação do SCANTEC que tem como premissa básica a inter-comparação de modelos, pelo que também está incluído o modelo GFS para permitir uma análise de desempenho das previsões de precipitação na perspectiva da avaliação orientada a objeto. Os dados observados utilizados como referência foram campos de estimativas de precipitação por satélite. Assim, as próximas sub-seções apresentam informações sobre os dados e modelos numéricos, bem como o período e área de estudo. Em uma segunda seção são apresentados detalhes desse experimento de avaliação, no qual são exemplificados os processos de identificação dos objetos e a seleção dos pares de objetos usando campos reais de precipitação prevista e observada. O objetivo dessa seção é facilitar a compreensão da metodologia orientada a objeto para usuários iniciantes, preparando-os para bem interpretar a análise dos resultados contida nessa dissertação. Na próxima seção são discutidos os resultados da avaliação iniciando-se com as previsões de precipitação acumulada a cada 6 horas até 24 horas de previsão e depois o acumulado de 24 horas até 96 horas de previsão. Em uma última análise dos resultados um estudo de caso para eventos severos de precipitação é apresentado para demonstrar o potencial da metodologia de avaliação orientada a objeto em atividades *nowcasting* com análise de eventos de tempestades severas.

4.1 Modelos, dados observados, área e período de estudo

O experimento para realizar essa prova de conceito consiste em aplicar o módulo de avaliação orientada a objeto implementado no SCANTEC nos campos de previsões de precipitações, tanto no modelo BRAMS como no modelo GFS, usando-se como valores de referência as estimativas de precipitação observada por satélites. Informações sobre os modelos usados e sobre os dados, bem como os dados de precipitação observada pelo satélite TRMM são descritos abaixo. Informações sobre o período e a área de estudo, com uma breve descrição dos eventos responsáveis da ocorrência de precipitação nesse período são também tratadas nessa seção.

4.1.1 Informações sobre os modelos BRAMS e GFS

O modelo BRAMS é baseado no *Regional Atmospheric Modelling System* (RAMS) desenvolvido originalmente na Universidade do Estado do Colorado, nos Estados Unidos de América, a partir de um modelo de mesoescala (PIELKE, 1974) e de um modelo de nuvens (TRIPOLI; COTTON, 1982). O RAMS é um modelo de previsão numérica de tempo multi-objetivo desenhado para simular circulações atmosféricas em muitas escalas, foi construído em torno de um conjunto de equações tridimensionais e não hidrostáticas que descrevem a dinâmica, a termodinâmica e a conservação da água em suas três fases. As equações não-hidrostáticas totalmente compressíveis são resolvidas usando diferenças finitas. Quanto à estrutura de grade, utiliza grade horizontal do tipo C de Arakawa, com as componentes da velocidade intercaladas entre os pontos de grade e as demais variáveis definidas no ponto de grade. A estrutura vertical da grade é definida pela coordenada σ_z , onde o topo do modelo é plano e a base acompanha o terreno. O modelo RAMS foi inicialmente introduzido no Brasil através da Universidade de São Paulo (USP) em 1989. Desde então o RAMS tem sido constantemente usado em estudos que envolvem modelagem de sistemas de meso-escala, brisa marítima, previsão do tempo e como ferramenta de apoio à pesquisa (MARTINS, 2016). Atualmente, o BRAMS é desenvolvido e mantido pelo CPTEC/INPE, USP e outras instituições no Brasil e no exterior. Várias funcionalidades e modificações foram incluídas para melhorar a representação numérica dos principais processos físicos sobre as regiões tropicais e subtropicais (FREITAS et al., 2009), um módulo completo para a química atmosférica e os processos de aerossol (LONGO et al., 2006), bem como um complexo conjunto de módulos para simular processos como a difusão turbulenta, radiação solar e terrestre, formação de nuvens e precipitação, efeitos do terreno (solo-vegetação), convecção e troca de calor sensível e latente entre a superfície e a atmosfera. As condições iniciais podem ser definidas a partir de vários conjuntos de dados observacionais que podem ser combinados e processados com um pacote isentrópico e mesoescala de análise de dados (TREMBACK et al., 1987). Para as condições de contorno, os esquemas 4DDA permitem que os campos atmosféricos sejam aproximados aos dados de grande escala. Pacotes do BRAMS utilizados nesse sistema incluem uma versão ensemble do esquema de convecção profunda e rasa baseado no formalismo de fluxo de massa (GRELL; DÉVÉNYI, 2002) e dados de inicialização da umidade do solo (GEVAERD; FREITAS, 2006). Desde o 2013, o BRAMS é um dos modelos utilizados pelo CPTEC de forma operacional para a previsão do tempo numa grade de resolução de 5 km que cobre toda a América do Sul.

O GFS é o modelo operacional do *National Centers for Environmental Prediction* (NCEP) e é um modelo numérico espectral global, baseado nas equações dinâmicas primitivas que inclui um conjunto de parametrizações para a física da atmosfera (SELA, 1980; KANAMITSU, 1989; KALNAY et al., 1990). O GFS usa um truncamento triangular espectral na horizontal e uma coordenada Sigma na vertical a partir da superfície da terra até o topo da atmosfera. Para integração das equações é usado um esquema temporal centrado no tempo para os termos de advecção não-lineares e o esquema semi-implícito para ondas de gravidade e de advecção zonal de vorticidade e de umidade. Para os processos físicos, é usada uma integração implícita com um filtro especial de tempo (KALNAY; KANAMITSU, 1988) para a difusão vertical. A fim de incorporar tendências físicas no esquema de integração semi-implícito, é realizado um esquema de ajuste especial (KANAMITSU et al., 1991). Nas equações primitivas, a vorticidade, divergência, logaritmo da pressão superficial e a temperatura virtual da umidade específica são consideradas como variáveis dependentes. Após a difusão horizontal, um esquema escala-seletivo de segunda ordem (LEITH, 1971) é aplicado a vorticidade, divergência, temperatura virtual, umidade específica e condensado de nuvem. A difusão de temperatura, umidade específica, e condensado de nuvem são executadas em superfícies de pressão quase constante (KANAMITSU et al., 1991). Para a difusão vertical é usado o esquema não local da Camada Limite Planetária (PBL - Planetary Boundary Layer) originalmente proposto por Troen and Mahrt (1986) e implementado por Hong and Pan (1996), para calcular o transporte turbulento. A altura PBL é diagnosticada usando a abordagem *bulk-Richardson*. Uma vez que a altura de PBL é determinada, o perfil de difusividade turbulenta é especificado como uma função cúbica da altura PBL e dimensionado por parâmetros derivados de requisitos de similaridade.

4.1.2 Dados de precipitação usados como referência

Os dados de precipitação usados como referência nesse estudo são provenientes do sistema *TRMM Multisatellite Precipitation Analysis* (TMPA). O TMPA foi desenvolvido para aplicar novos conceitos na fusão de estimativas de precipitação quase Globais aproveitando o aumento crescente da disponibilidade de conjuntos de dados em tempo quase real. O TMPA combina estimativas de precipitação de vários sistemas de satélite, bem como dados de redes de pluviômetros à superfície terrestre quando possível. O objetivo é que o produto final represente a melhor estimativa da precipitação por satélite (HUFFMAN et al., 2007).

A maior parte da cobertura no TMPA depende da entrada de dois conjuntos

diferentes de sensores. Primeiro, os dados de micro-ondas passivas destinados a estimativas de precipitação, os quais são coletados por uma variedade de satélites de órbita baixa *Low Earth Orbit* (LEO), incluindo o *TRMM Microwave Imager* (TMI), *Special Sensor Microwave Imager* (SSM/I) do *Defense Meteorological Satellite Program* (DMSP), *Advanced Microwave Scanning Radiometer - Earth Observing System* (AMSR-E) no Aqua e o *Advanced Microwave Sounding Unit-B* (AMSU-B) na série de satélites da NOAA. A segunda fonte principal de dados para o TMPA, os quais são os dados do canal Infravermelho (IR - $10.7\mu m$) que são recolhidos pela Constelação Internacional de Satélites de órbita terrestre geo-sincronizada (GEO). Em contraste com a escassa amostragem temporal dos dados de micro-ondas passiva, os dados GEO-IR proporcionam uma excelente cobertura tanto espacial quanto temporal. O TMPA também utiliza três fontes de dados adicionais: a estimativa do *TRMM Combined Instrument* (TCI) que emprega dados do TMI e do *TRMM Precipitation Radar* (PR), bem como uma fonte de calibração, a análise mensal pluviométrica do *Global Precipitation Climatological Center* (GPCC) e a análise mensal pluviométrica do *Climate Assessment and Monitoring System* (CAMS).

O produto 3B42 é a versão mais sofisticada a qual espera-se a menor incerteza e por isso são utilizadas aqui como valores de referência. Esse produto é calculado de 3 em 3 horas, com uma resolução de $0.25^\circ \times 0.25^\circ$ latitude-longitude. Cada campo de precipitação do 3B42 é melhor interpretado como a taxa de precipitação efetiva no tempo de observação nominal (0000, 0300, ..., 2100 UTC) (HUFFMAN et al., 2007).

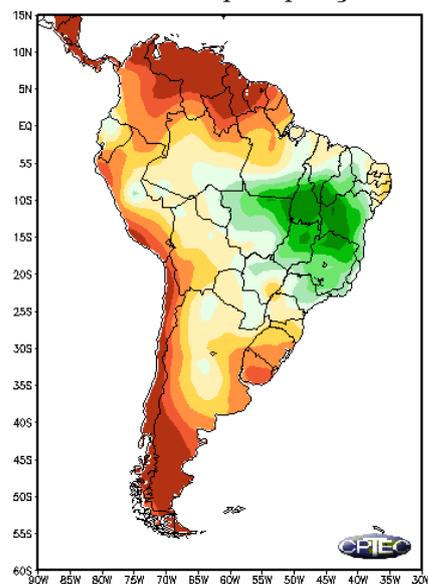
4.1.3 Área e período de estudo e o padrão da precipitação observada

Como o CPTEC tem a missão de prover a sociedade os melhores produtos de previsão de tempo sobre o país, e esse cobre a maior parte da América do Sul, há uma demanda para que os modelos regionais operacionais nesse centro tenham um domínio que atenda todo o continente. Obviamente, que para uma análise inicial da metodologia a escolha da América do Sul (AS) para essa avaliação é a mais acertada. A AS localiza-se entre os 12° N e 55° S, possui uma geografia diversificada caracterizada pela presença da Cordilheira dos Andes, de vastas planícies com enormes superfícies aquáticas e rios como o Amazonas e o Orinoco, da grande floresta equatorial Amazônica, e de uma das áreas mais áridas do planeta: o deserto do Atacama, localizado no norte do Chile. A diversidade do relevo e a distribuição das terras do continente em diferentes latitudes favorece o desenvolvimento de diferentes sistemas atmosféricos, que contribuem com a não homogeneidade climática desta região e conseqüentemente para diferentes regimes de precipitação (REBOITA et al.,

2010). O noroeste do Brasil é a região mais chuvosa da América do Sul. A bacia Amazônica está localizada nesta área onde a precipitação é superior a 2450 mm/ano. A costa da América do Sul (Chile e Peru) e o sul da Argentina são as regiões mais secas do continente, a precipitação é inferior a 350 mm/ano. O nordeste de Brasil é também uma região relativamente seca. O máximo de precipitação durante o verão é localizado na região centro-oeste do Brasil e durante o inverno no norte de Equador (SHI; CENTER, 2000).

O período em que esse estudo está focado é o mês de janeiro de 2016, pois é o mês em que em média os maiores acumulados de precipitação foram encontrados sobre a América do Sul. Nesse período os maiores acumulados de precipitação foram registrados em grande parte das regiões nordeste, centro-oeste e sudeste do Brasil, como mostra a Figura 4.1. A ocorrência de precipitação nesse período foi influenciada pela atuação de vórtices ciclônicos em altos níveis da atmosfera próximos a costa da Região Nordeste do Brasil e à formação do primeiro episódio da ZCAS (Zona de Convergência do Atlântico Sul) da temporada 2015-2016. O fenômeno El Niño-Oscilação Sul (ENOS), o qual atingiu seu auge no mês de dezembro de 2015, teve uma diminuição gradual de sua intensidade no mês de Janeiro, especialmente no setor leste do Pacífico Equatorial. Destacou-se o aquecimento anômalo das águas superficiais tanto no Atlântico Norte como no Atlântico Sul, bem como a atuação da ZCIT (Zona de Convergência Intertropical) em torno de sua posição climatológica no Atlântico Equatorial (COUTINHO; AGOP, 2016).

Figura 4.1 - Acumulados de precipitação na América do Sul em Janeiro 2016.



Fonte: Adaptada de <http://clima1.cptec.inpe.br/monitoramentoams/pt>

4.2 Experimento de avaliação

O experimento de avaliação aplicado aqui consiste basicamente de executar o SCANTEC tendo como arquivos de entrada os arquivos de previsão do BRAMS e do GFS e usando como dados de referência os campos de precipitação disponível no produto 3B42. Essa rodada do SCANTEC é configurada para acionar o módulo de avaliação de precipitação orientada a objeto com alguns parâmetros importantes modificados, tais como o período de tempo de acúmulo da precipitação a ser avaliado, o que deve ser levado em consideração na forma como cada modelo organiza os campos de precipitação nos respectivos arquivos, o que também deve ser considerado na utilização dos dados de referência. A configuração do SCANTEC é uma tarefa bastante simples, que compreende em modificar valores dentro de um arquivos de configuração antes da execução do sistema. O SCANTEC está projetado para processar simultaneamente diferentes modelos sendo comparados com os mesmos dados de referência. Como fruto de cada rodada arquivos de resultados são gerados os quais contemplam arquivos binários contendo todos os campos da precipitação nas diferentes etapas do processo, arquivos textos contendo os valores de cada um dos atributos dos pares de objetos identificados em cada dia do período avaliado e um outro arquivo texto contendo os valores das estatísticas desses pares de objetos para cada um dos modelos, tanto com a contagem dos casos em uma tabela de contingência como os valores dos índices que com eles são gerados.

O dados de precipitação do 3B42 têm 0.25° de espaçamento de grade, enquanto que as previsões do modelos BRAMS e GFS tem a resolução horizontal de 5 e 50 km, respectivamente. Seguindo a estratégia de comparação justa em que o SCANTEC se baseia, para a aplicação do método orientado a objeto, tanto as previsões de chuva como as estimativas do 3B42, foram interpoladas para o domínio do modelo de resolução mais baixa. Assim, todos os campos foram interpolados usando o módulo de interpolação bilinear do SCANTEC, numa grade com 95 pontos na direção x e 123 pontos na direção y com um incremento de grade de 0.5° . Um ponto que deve ser destacado nessa avaliação é que essas diferenças na resolução espacial dos modelos e dos dados do 3B42 não impactam nos resultados gerados pela metodologia orientada a objeto, pois nesse processo as principais características espaciais e geométricas dos objetos são mantidas inalteradas. O que se perde é o detalhamento fino nas bordas dos modelos de mais alta resolução, o que não tem peso algum nessa avaliação. Essa característica da metodologia orientada a objeto constitui uma das vantagens mais importantes dessa técnica.

Na configuração do experimento os dados de previsão da precipitação gerados a partir das análises das 00 horas desde o dia 01 até o dia 31 do mês de janeiro foram utilizados para ambos os modelos com as previsões com saídas no intervalo de 6 horas com 96 horas de integração. Duas rodadas básicas foram realizada nesse experimento:

- **Rodada com acumulado de precipitação de 6 horas com previsões de até 24 horas:** essa rodada tem o objetivo de avaliar a qualidade das previsões levando em consideração o posicionamento temporal dos eventos com o acumulado nos horários sinóticos. É uma avaliação mais rigorosa na qual o número de objetos é maior e permite uma análise mais detalhada dos resultados.
- **Rodada com acumulado de precipitação de 24 horas com previsões de até 96 horas:** ao contrário da primeira essa configuração é menos exigente com os modelos, pois avalia o desempenho de colocar os eventos de chuva durante o dia sem penaliza-lo por erros na posição temporal. Embora nesse caso o número de eventos cai significativamente, essa configuração permite a avaliação da qualidade das precipitações com a integração mais longa dos modelos.

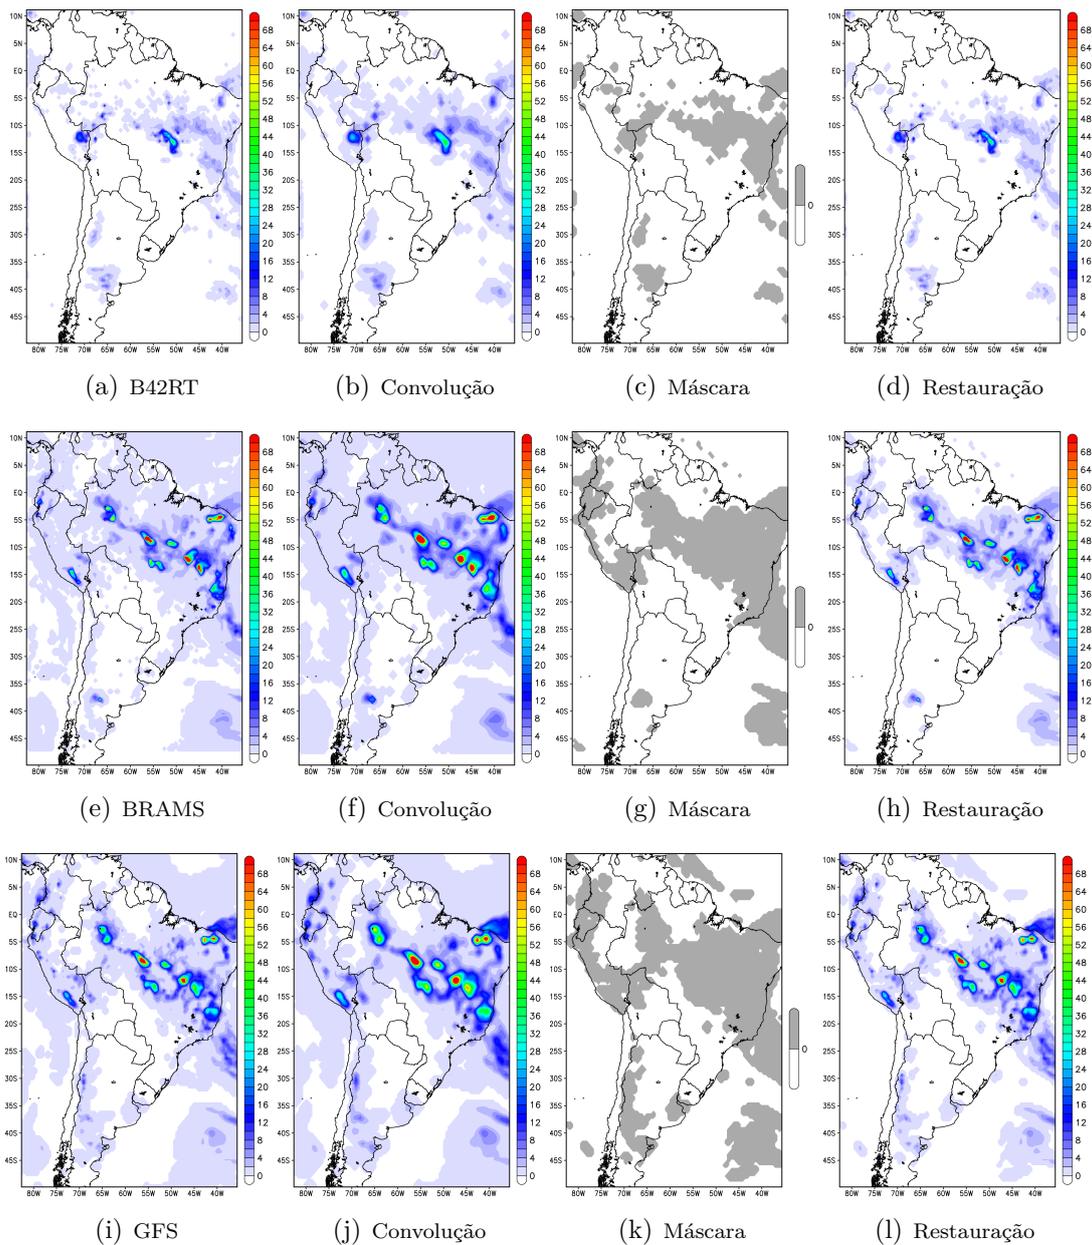
Com a aplicação do método de avaliação os objetos de precipitação foram identificados e delineados nas previsões e nas estimativas 3B42. Foram analisadas as características espaciais e geométricas das áreas de chuva identificadas nos campos da previsão, e comparadas com os objetos de precipitação detectados na referência, para obter uma avaliação do desempenho dos modelos para prever a precipitação. A seguir é apresentado um caso de estudo com o propósito de descrever e exemplificar todas as etapas da aplicação do método e também da análise dos resultados baseada na estatísticas nos atributos dos pares e na tabela de contingência orientada a objeto. O caso selecionado corresponde à previsão de precipitação para o dia 21 de janeiro de 2016, após 6 horas de integração dos modelos.

4.2.1 Identificação das áreas de precipitação

Como apresentado nos capítulos anteriores, o processo de identificação das áreas de chuva inclui várias etapas. A Figura 4.2 apresenta um exemplo dos campos transformados nas três primeiras. As Figuras 4.2(b), 4.2(c) e 4.2(d) mostram as saídas dos algoritmos convolução, limiarização e restauração dos dados usados como

referência, as Figuras 4.2(f), 4.2(g) e 4.2(h) representam as mesmas transformações no campo de previsão do BRAMS e as Figuras 4.2(j), 4.2(k) e 4.2(l) correspondem às transformações na previsão do GFS.

Figura 4.2 - Transformações das previsões de acumulados de 6 horas de precipitação para às 0600 UTC do 21 de Janeiro de 2016, resultantes dos processos convolução, limiarização e restauração para os dados observados e modelos BRAMS e GFS.



No processo de limiarização foi usado um limiar de intensidade de precipitação

de 0.5 mm. Estes três algoritmos permitiram definir as áreas de chuva e filtrar as características abaixo do limiar definido. Nos campos de precipitação restaurados, o algoritmo de *fill* e o *merging* permitiram delimitar os objetos de precipitação. As Figuras 4.3(d), 4.3(e), e 4.3(f) apresentam o total de objetos que foram identificados nos campos de precipitação restaurados do 3B42, o BRAMS e o GFS, respectivamente, no dia 21 de Janeiro de 2016. Pode-se observar nessas figuras que os objetos delineiam corretamente as áreas de precipitação da forma que o olho humano percebe nos campos, o qual representa o propósito perseguido com o algoritmo da lógica difusa.

4.2.2 Identificação dos pares de objetos na observação e previsão

Delimitados todos os objetos de precipitação nos campos assim como seus atributos, o segundo algoritmo da lógica difusa permitiu encontrar as diferenças e semelhanças entre eles e determinar para um objeto na previsão o objeto correspondente na estimativa de precipitação 3B42. No entanto, nem todos os objetos na previsão coincidem com os objetos na referência e vice-versa. A Figura 4.4 apresenta os pares de objetos encontrados por esse algoritmo nas previsões e na estimativa 3B42 para o dia 21 de Janeiro de 2016 às 0600 UTC. Cada par de objeto de precipitação é representado com a mesma cor nos dois campos, e foi atribuído a cor cinza para o resto dos objetos não pareados.

Na aplicação do algoritmo foram identificados quatro pares de objetos entre o BRAMS e 3B42, e quatro pares de objetos entre o GFS e o 3B42. Observe-se nas Figuras 4.4(a) e 4.4(c) que três das regiões de precipitação observadas que foram encontradas na previsão do BRAMS também foram encontradas no GFS.

4.2.3 Estatística dos atributos e tabela de contingência

Com o intuito de explorar as métricas estatísticas que o método orientado a objeto fornece ao sintetizar as informações na avaliação, foram calculados os atributos para cada um dos pares de objetos pareados na sub-seção anterior. Os atributos considerados foram diferença de centroide, razão da área de interseção, razão da área, diferença de orientação e o valor do Interesse Total, os quais são apresentados na Tabela 4.1. Analisando os resultados observa-se que o BRAMS apresentou menor diferença do centroide entre os objetos, maior sobreposição dos objetos, maior razão da área e menor diferença na orientação do que o GFS. Portanto, os resultados na semelhança entre os objetos na previsão nesse dia e horário, indicam que os eventos de precipitação foram melhor representados pelo BRAMS, cuja semelhança

Figura 4.3 - Objetos de precipitação identificados nas previsões de acumulados de 6 horas de precipitação do BRAMS e do GFS para às 0600 UTC do dia 21 de Janeiro de 2016. As cores em (d), (e) e (f) representam os diferentes objetos delimitados nos campos de precipitação restaurados mostrados em (a), (b) e (c), respectivamente.

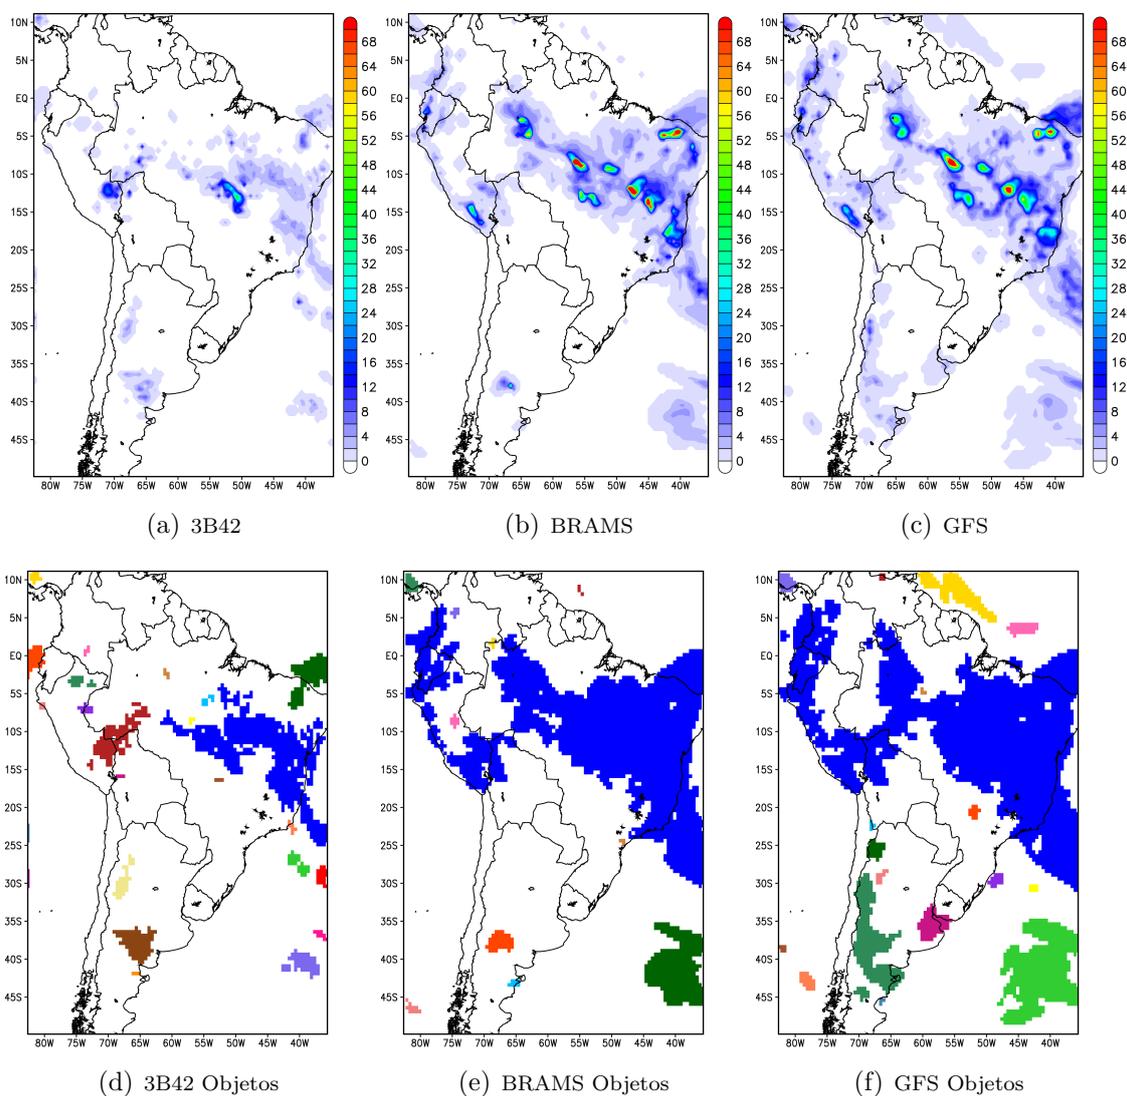
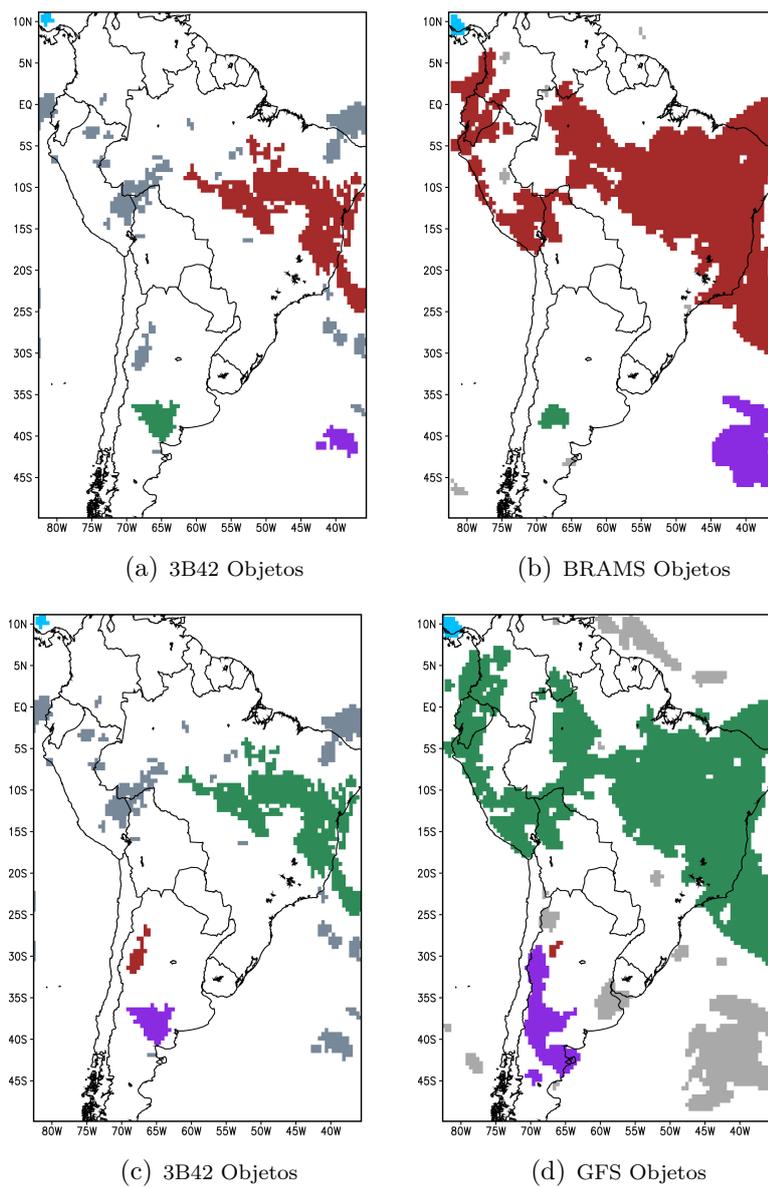


Figura 4.4 - Previsões de acumulados de precipitação de 6 horas, válidas às 0600 UTC do 21 de Janeiro de 2016. As áreas de chuva coloridas iguais representam os pares de objetos observação-previsão identificados em (a)-(b) e (c)-(d), a cor cinza é usada para indicar objetos não pareados nos campos.



se resume em um maior valor do Interesse Total. Embora, a região centrada sobre o noroeste da Argentina (região vermelha na Figura 4.4(c)) não foi pareada na previsão do BRAMS, indicando uma falha desse modelo.

Tabela 4.1 - Atributos dos três pares de objetos identificados entre as estimativas 3B42 e o BRAMS (Figuras 4.4(a) e 4.4(b)) e entre as estimativas 3B42 e o GFS apresentados em parêntesis (Figuras 4.4(c) e 4.4(d)) no dia 21 de Janeiro de 2016.

Atributos	Pares de objeto		
	BRAMS (GFS) Azul (Azul)	BRAMS (GFS) Verde (Roxo)	BRAMS (GFS) Vermelho (Verde)
Razão das áreas	0.56 (0.38)	0.50 (0.33)	0.26 (0.23)
Diferença de centroide	2 pts (1 pts)	4 pts (5 pts)	16 pts (18 pts)
Diferença de orientação	54.2° (81.4°)	46.9° (56.5°)	47.9° (48.31°)
Razão área interseção	0.27 (0.29)	0.28 (0.14)	0.25 (0.22)
Interesse Total	0.88 (0.87)	0.87 (0.75)	0.85 (0.83)

As Tabelas 4.2 e 4.3 representam as Tabelas de Contingência Orientadas a Objeto com o total de sucessos, falhas e alarmes falsos das previsões dos modelos BRAMS e GFS, no dia 21 de janeiro de 2016 nesse horário. Embora, o número de pares de objetos (sucessos) identificados nas duas previsões seja igual, apenas 12% dos objetos observados foram previstos corretamente pelo BRAMS, enquanto que esse numero foi de apenas 10% para o GFS. O BRAMS apresentou menor quantidade de regiões de chuva que não estão presentes nas observações (7 falso alarmes) do que o GFS (14 falso alarmes), valores que representam uma Taxa de Alarme Falso Orientada a Objeto de 64% e 78%, respectivamente.

Tabela 4.2 - Tabela de Contingência do BRAMS (Figuras 4.4(a) e 4.4(b)).

Previsto	Observado		
	Sim	Não	Total
Sim	4	7	11
Não	20	-	20
Total	24	7	31

Tabela 4.3 - Tabela de Contingência para o GFS (Figuras 4.4(c) e 4.4(d)).

Previsto	Observado		
	Sim	Não	Total
Sim	4	14	18
Não	20	-	20
Total	24	14	38

Algo que justifica essas diferenças entre o número de objetos previstos nos dois modelos é o fato de que no processo de limiarização algumas regiões consideradas como aglomerados independentes no BRAMS foram delimitadas como sendo uma mesma região nas previsões do GFS. É importante ressaltar que nessa técnica o número de objetos não é necessariamente indicativo de um erro na previsão, pois uma previsão de alta resolução pode produzir mais áreas de chuva do que uma previsão com resolução mais grossa. Por isso a análise dos resultados da tabela de contingência deve ser acompanhada com a avaliação dos atributos no qual a razão da área e a diferença do centroide são parâmetros importantes para concluir de forma mais acertada quais são os modelos que geram as melhores previsões. Deve-se enfatizar que os tipos de erros aqui observados e analisados são baseados nos objetos previsto durante apenas um dia, podendo não representar o padrão do modelo. Assim, é importante avaliar as estatísticas obtidas sobre uma amostra razoavelmente grande de casos para que se conclua acertadamente sobre a habilidade dos modelos avaliados.

4.3 Discussão dos resultados

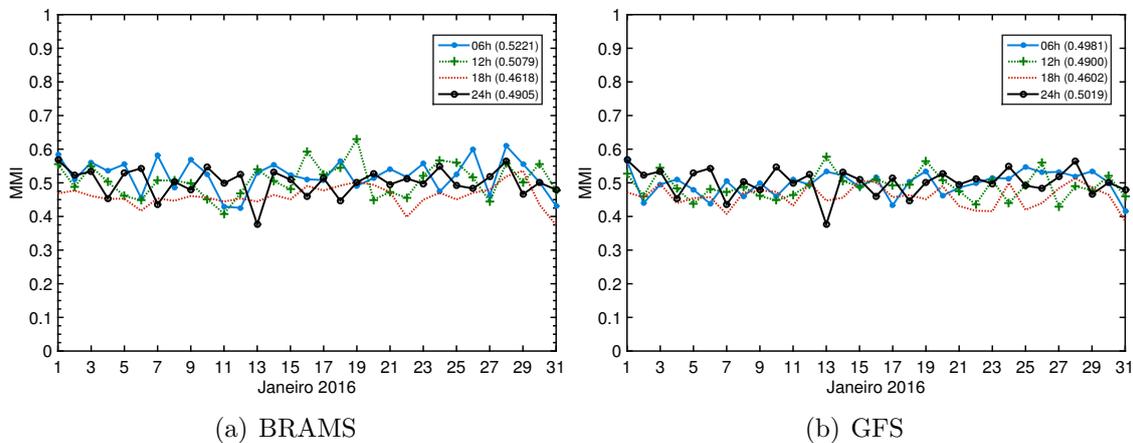
Estendendo a mesma análise realizada para o caso do dia 21 de janeiro para todos os dias do mês avaliado, nessa seção são organizados os resultados obtidos com a aplicação do módulo de avaliação orientada a objeto nos dois experimentos. Como são muitos os resultados gerados nessa análise, visando apresentá-los de forma otimizada para que as informações mais importantes sejam reveladas paulatinamente com o decorrer da análise, iniciou-se com uma avaliação refinada com características mais sutis (como o posicionamento temporal dos objetos) e posteriormente com as mais gerais (como a precipitação acumulada de 24 horas em integrações mais longas). Adicionalmente um estudo de caso para aplicações *nowcasting* é apresentado onde um caso significativo é selecionado.

Como pode-se observar, a quantidade dos parâmetros e métricas fornecidas pela metodologia orientada a objeto é relativamente grande com análises das características geométricas dos objetos, dos atributos dos pares de objetos, das tabelas de contingências e dos índices estatísticos associados. Na apresentação dos resultados procura-se explorar todos essas informações e demonstrar seu potencial utilizando alternadamente diferentes índices em cada avaliação. Isso é feito para evitar repetições nas análises e conseqüentemente torná-la mais elegante.

4.3.1 Avaliação das previsões do acumulado de 6 horas

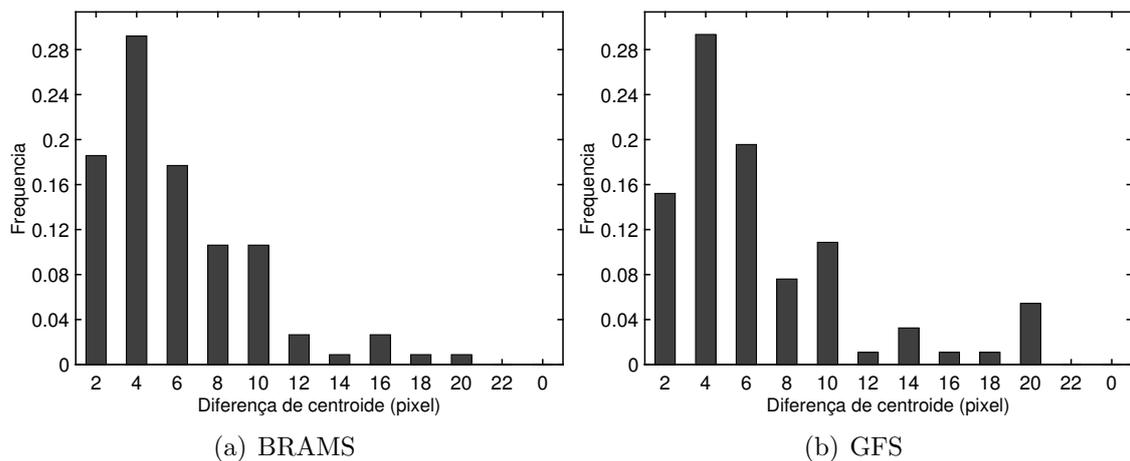
Após a aplicação do método de avaliação às previsões de 6 horas de acumulados de precipitação do BRAMS e do GFS no mês de Janeiro de 2016, os objetos de precipitação foram agrupados em pares de objetos (sucessos), falhas e alarmes falsos. Para os pares de objetos foram examinados quatro atributos geométricos chaves no cálculo do Interesse Total: distância do centroide, razão da área de interseção, razão da área e diferença de orientação. Como explicado na seção 3.3.5, a avaliação da qualidade das previsões pode ser obtida na análise da métrica MMI, que sintetiza diversas informações. Em uma análise inicial os valores do MMI para todos os 31 dias do mês avaliado são comparados entre diferentes tempos de integração (06, 12, 18 e 24 horas) para cada modelo separadamente. A Figura 4.5 apresenta as séries temporais do MMI para as previsões de precipitação do BRAMS e o GFS, sendo que o MMI para mês completo aparece em parêntesis na legenda. Considerando os valores apresentados, observa-se que, de forma geral, o BRAMS representa melhor as características espaciais e geométricas dos objetos de precipitação com 6 horas de integração, mostrando maior valor do MMI para essas previsões (MMI total de 0.52). Por outro lado o GFS teve maior MMI para as previsões com 24 horas de integração (MMI total de 0,50), o que sugere que a semelhança com os objetos de precipitação das estimativas 3B42 de 24 horas de integração do GFS é melhor que as suas previsões de integração mais curta. O padrão apresentado pelo BRAMS indica que o desempenho das previsões tende a diminuir com a integração do modelo enquanto que o GFS apresenta um comportamento contrário com previsões melhores nas integrações mais longas (24 horas).

Figura 4.5 - Séries Temporais do MMI para as previsões de precipitação de 06, 12, 18 e 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.



Visando identificar o desempenho dos modelos ao considerar os diferentes atributos dos pares de objetos, uma análise dos mesmos é realizada através de histogramas de frequência. Inicialmente essa análise é feita para as previsões de 6 horas de integração e posteriormente ela é repetida para 24 horas de previsão. Esses horários foram escolhidos porque é neles que os melhores resultados foram obtidos, sendo o BRAMS nas previsões de 6 horas e o GFS nas de 24 horas. A Figura 4.6 mostra os histogramas normalizados da distância do centroide para as previsões de ambos modelos com 6 horas de integração. No geral pode-se observar que a distribuição dos histogramas é similar nos dois modelos, com classes mais frequentes para as diferenças menores tendendo a zero para distâncias maiores que 20 pixels. Em uma análise mais rigorosa observa-se que distâncias maiores que 10 pixels de separação do centroide são mais frequentes nos pares de objetos do GFS do que no BRAMS, em especial para a classe de 20 pixels. Por outro lado o BRAMS apresentou um maior número de pares de objetos com diferenças de centroide com 2 pixels. Esses resultados são sintetizados na Tabela 4.4, na qual o BRAMS possui um maior valor do interesse parcial no atributo diferença de centroide do que o GFS, o que sugere que ele possui maior habilidade para prever o posicionamento dos objetos de precipitação com integração curta (6 horas).

Figura 4.6 - Histogramas normalizados da diferença dos centroides entre os objetos nas previsões de precipitação do BRAMS e o GFS para 6 horas de previsão (Janeiro de 2016).



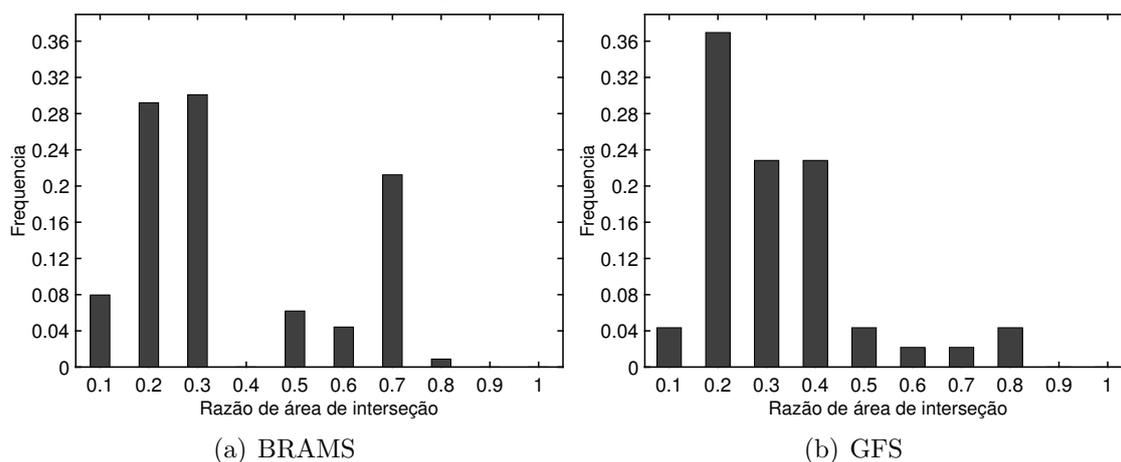
Os histogramas normalizados da razão da área de interseção estão ilustrados na Figura 4.7. A frequência das classes no histograma da razão da área de interseção com a área dos pares de objeto sugere que a maioria desses pares apresentam razão

Tabela 4.4 - Valores do Interesse Parcial Médio e do Interesse Total Médio dos quatro atributos para as previsões de precipitação de 6 horas de integração do BRAMS e o GFS em Janeiro de 2016. Os pesos de cada atributo no Interesse Total também são apresentados nessa tabela.

Atributos	BRAMS	GFS	Peso
Distância do centroide	0.5615	0.5457	2
Razão da área de interseção	0.7852	0.8004	2
Razão da área	0.5265	0.4964	1
Diferença de orientação	0.6863	0.7153	1
Interesse total	0.8369	0.8375	6

muito baixa, indicando que a área da intersecção é frequentemente muito menor que a área dos objetos previstos. Esse padrão é observado nos dois modelos sendo difícil identificar quem é o melhor pela confusão nas frequências em que cada classe ocorreu. Os valores apresentado na Tabela 4.4 indicam que sutilmente o GFS apresenta melhor desempenho do que o BRAMS na razão de intercessão da área dos objetos.

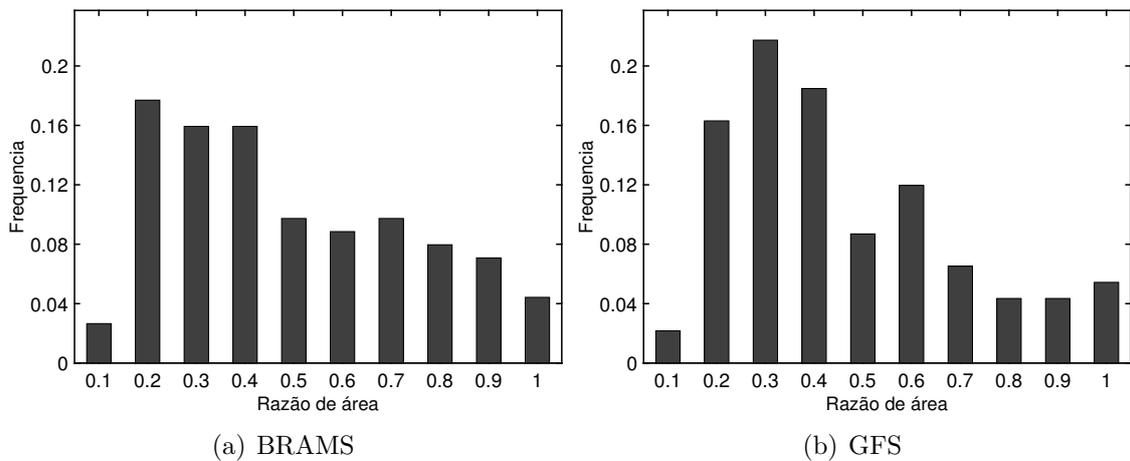
Figura 4.7 - Histogramas normalizados da razão da área de interseção entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para o mês de Janeiro de 2016.



A Figura 4.8 apresenta os histogramas normalizados da razão da área para as previsões do BRAMS e do GFS com 6 horas de integração e o mesmo para a diferença de orientação na Figura 4.9. Na análise dos resultados na razão da área vale lembrar que quanto mais frequente as classes próximas de 1 na razão da área, melhor o

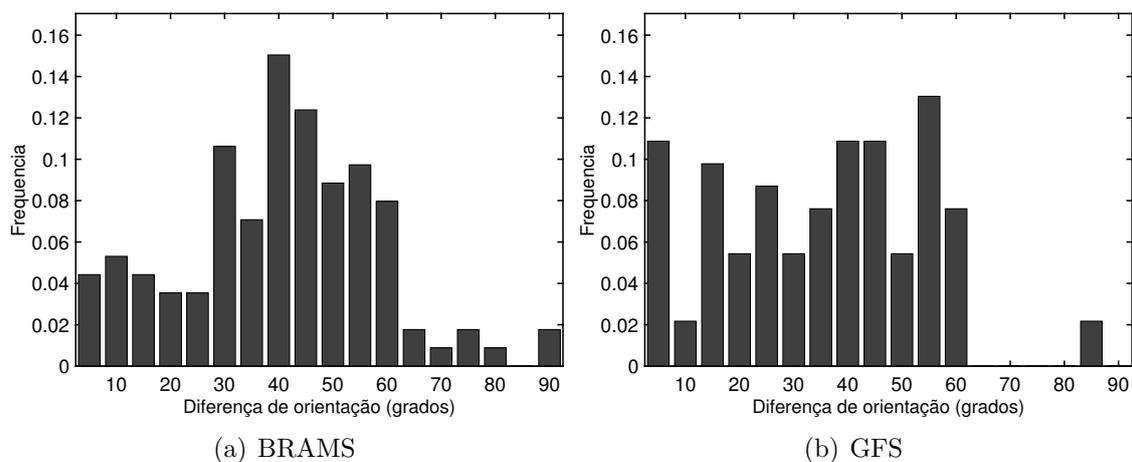
modelo em representar as áreas de precipitações. Observa-se que a quantidade de pares de objetos detectados com razão acima de 0,7 é maior no caso do BRAMS, enquanto que as classes abaixo de 0,4 são mais frequentes nas previsões do GFS do que nas do BRAMS. Esse resultado é uma indicação que as previsões de 6 horas do BRAMS caracterizam melhor a área dos objetos observado pelo 3B42 do que o GFS. A Tabela 4.4 apresenta os valores do interesse parcial médio da razão da área para os dois modelos, pode-se verificar que o BRAMS possui maior interesse parcial da razão da área entre os objetos, o que confirma a afirmação sobre o desempenho desse modelo no que diz respeito a área dos eventos de precipitação. No histograma da diferença de orientação observa-se que o BRAMS apresenta pares de objetos com diferenças elevadas de forma mais frequente do que o GFS e menos frequente os casos com diferenças menores. Nesse atributo o GFS apresenta melhor resultados com o valor de 0,72 contra 0,69 do BRAMS.

Figura 4.8 - Histogramas normalizados da razão das áreas entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016.



Uma análise dos pares de objetos identificados em relação ao número de casos observados pode ser uma forma interessante de avaliar o desempenho de ambos os modelos. Para isso, o número total de pares de objetos, alarmes falsos e falhas são mostrados nas Tabela 4.5. Considerando os valores apresentados, pode-se dizer que 28% dos objetos previstos pelo BRAMS foram observados pelo 3B42, e 72% foram considerados alarmes falsos e 85% dos objetos na referência não foram previstos. No caso do GFS, 19% dos objetos previstos foram identificados nas estimativas 3B42, enquanto que o total de alarmes falsos representa 81% dos objetos previstos e 88%

Figura 4.9 - Histogramas normalizados da diferença de orientação entre os objetos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016.



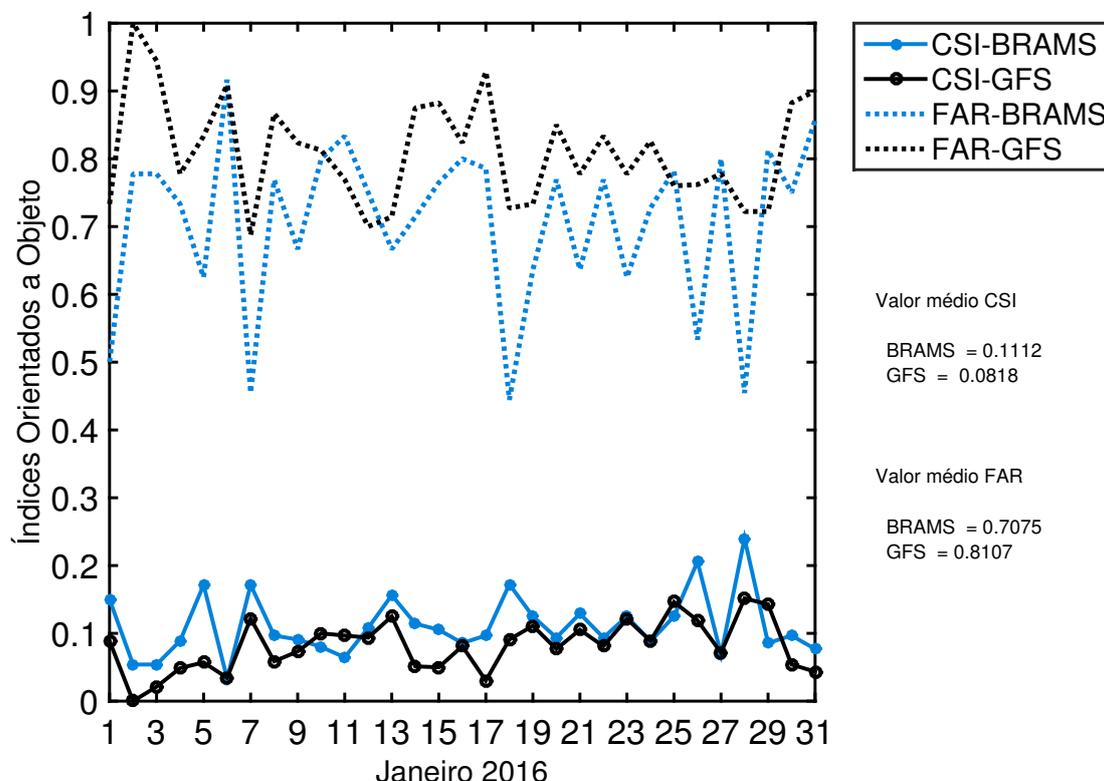
dos objetos observados não foram identificados na previsão. Esses resultados indicam que ambos os modelos erram mais por falhas do que por alarmes falsos. A Figura 4.10 ilustra o comportamento no tempo do CSI e a FAR orientados a objeto para as previsões de 6 horas dos dois modelos, e o valor médio para o período é mostrado à direita da figura. Em uma síntese dos resultados verificou-se valores de CSI muito baixos, menores do que 0.2 e valores de FAR muito altos, acima de 0.6. Em uma comparação entre os modelos se observou que o modelo BRAMS apresentou maiores valores de CSI e menores valores da FAR do que o modelo GFS. O valor médio do CSI do BRAMS foi de 0.11 contra 0.08 do GFS e o FAR foi de 0,71 contra 0,81 do GFS.

Tabela 4.5 - Total de sucessos, falhas e alarmes falsos nas previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016. O total de objetos previstos e observados também é apresentado.

Modelos	Falhas	Alarmes Falsos	Sucessos	Previstos	Observados
BRAMS	625	283	113	336	738
GFS	646	391	92	483	738

Em relação a avaliação dos interesses parciais dos atributos dos pares de objetos para as previsões de precipitação (acumuladas de 6 horas) com 24 horas de integração

Figura 4.10 - Séries Temporais do CSI (linhas sólidas) e FAR (linhas tracejadas) orientadas a objeto para as previsões de precipitação de 6 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os valores médios do CSI e a FAR para o período aparecem à direita da figura.

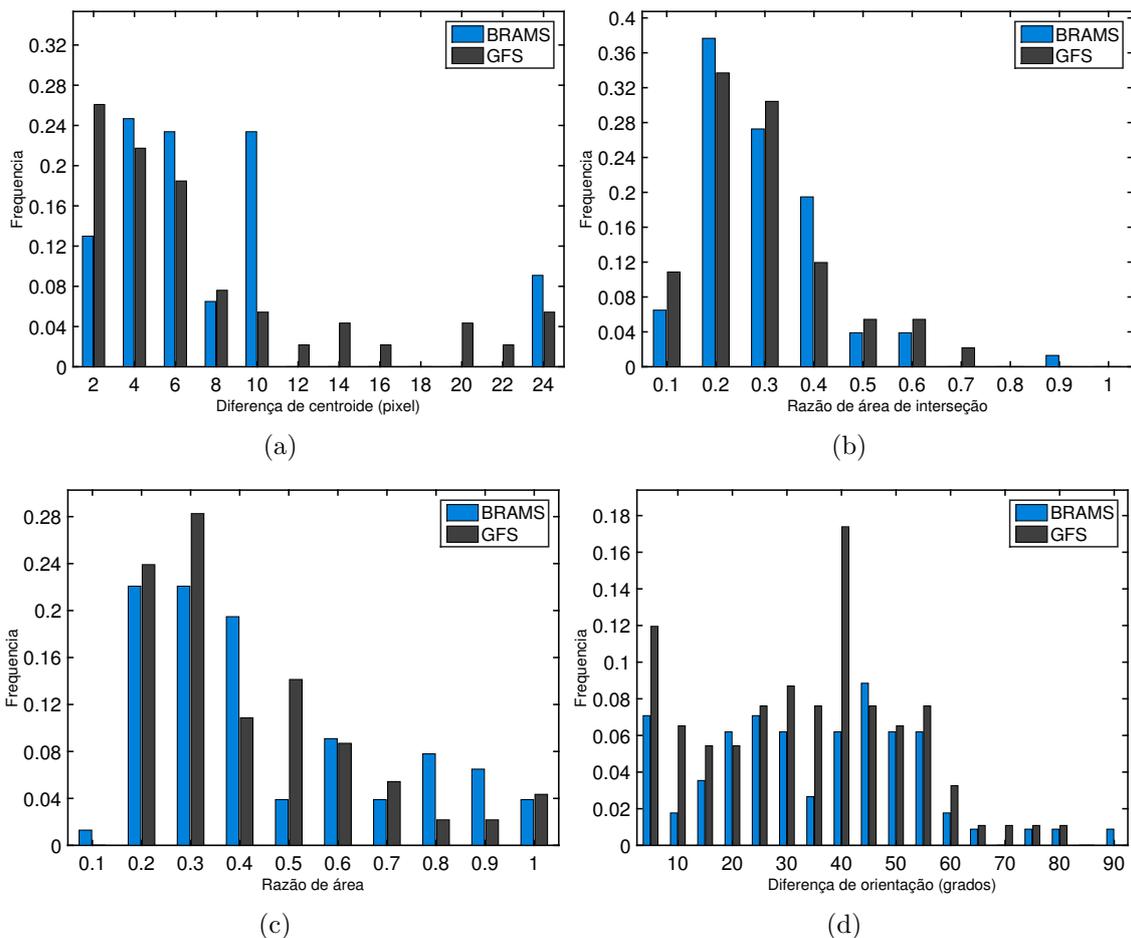


dos modelos, para tornar mais eficiente a mesma análise feita para as previsões de 6 horas, a Figura 4.11 mostra os histogramas de ambos os modelos para os quatro atributos avaliados: diferença dos centroides, razão da área de interseção, razão da área dos pares de objetos e diferença no ângulo de orientação. Para sintetizar os resultados a Tabela 4.6 mostra os valores dos interesses parciais de cada um desses atributos.

A Figura 4.11(a) mostra que no histogramas normalizados da separação do centroide para 24 horas de integração do modelo a maioria dos objetos do BRAMS apresenta distância de centroide entre 0 e 10 pontos de grade, sendo 13% dos pares de objetos menor que 2 pontos de grade, mas 9% dos pares de objetos tem uma diferença acima de 24 pontos de grade. Por outro lado, a tendência geral da distribuição para o GFS mostra que a quantidade de pares de objetos diminui quando a distância do centroide aumenta, sendo 26% desses pares com diferença de centroide abaixo de 2 pontos de grade e apenas 5% apresenta essa diferença maior que 24 pontos de grade. O valor médio do interesse parcial para esse atributo (Tabela 4.6) indica em números esse

melhor desempenho do GFS, o que significa que esse modelo representa melhor o posicionamento dos objetos de precipitação com 24 horas de integração do que o BRAMS.

Figura 4.11 - Histogramas normalizados da diferença dos centroides, razão da área de interseção, razão da área dos pares de objetos e diferença no ângulo de orientação entre os objetos nas previsões de acumulados de 6 horas de precipitação do BRAMS e o GFS após 24 horas de integração em Janeiro de 2016.



A distribuição dos histogramas da razão da área de interseção entre os pares de objetos nas previsões com 24 horas de integração, apresentados na Figura 4.11(b), mostram que a razão da área de sobreposição em relação a área dos objetos é baixa em uma grande parte dos pares de objetos em ambos os modelos. Segundo os valores médios do interesse parcial listados na Tabela 4.6, o GFS tem melhor desempenho do que o BRAMS. Isso indica que depois de 24 horas de integração a razão da área de precipitação correta pela área de precipitação prevista é melhor do que as previsões

Tabela 4.6 - Valores de Interesse Parcial Médio dos quatro atributos para as previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os pesos de cada atributo no Interesse Total também são apresentados nessa tabela.

Atributos	BRAMS	GFS	Peso
Distância do centroide	0.3355	0.5648	2
Razão da área de interseção	0.7207	0.7569	2
Razão da área	0.3919	0.4291	1
Diferença de orientação	0.8064	0.7226	1
Interesse total	0.8265	0.8266	6

fornecidas pelo BRAMS.

Com relação a razão de área dos pares de objetos, a tendência das frequências das classes dos histogramas da Figura 4.11(c) indica que de forma semelhante ao caso das previsões com 6 horas de integração, os modelos apresentam dificuldade em acertar a área de precipitação, com objetos maiores do que é estimado pelo 3B42. Razões de áreas menores do que 0.5, que deveriam ser menos frequentes, são as classes com maior ocorrência. Para esse atributo, os resultados resumidos na Tabela 4.6 indicam que o GFS obtém maior valor do interesse parcial (0.43) do que o BRAMS (0,39), o qual indica que após 24 horas de integração o GFS tem maior habilidade no dimensionamento dos objetos de precipitação do que o BRAMS.

A análise dos histogramas de frequência para a diferença de orientação (Figura 4.11(d)), indica uma certa semelhança na frequência das classes de diferenças nos histogramas dos dois modelos. Embora a quantidade de pares de objetos com menor diferença de orientação (entre 0 e 5°) é maior no GFS do que no BRAMS, observa-se uma frequência muito alta de pares de objetos com uma diferença de ângulo acima de 40°. A síntese desses resultados é obtida na Tabela 4.6 e indica que o desempenho do GFS (0,72) é inferior ao BRAMS (0,81) nesse atributo. Esse resultado sugere que o BRAMS captura melhor a orientação dos objetos do que o GFS nas previsões de 6 horas de acumulados de precipitação com 24 horas de integração.

O total de pares de objetos, alarmes falsos e falhas são listados na Tabela 4.7. Pode-se observar que o GFS identificou 92 pares de objetos, valor que representa 12% do total dos objetos observados, o 88% dos objetos na referência não foram previstos pelo GFS e 76% dos objetos previstos não foram encontrados na referência. Por

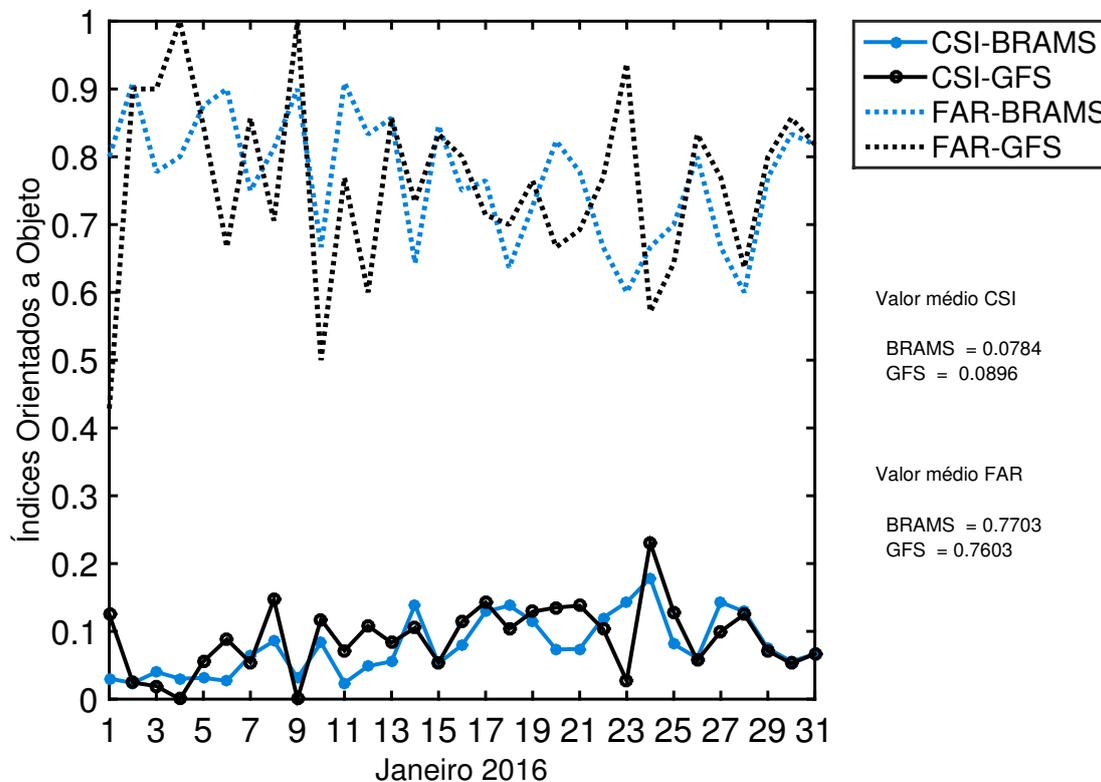
outro lado, o BRAMS identificou 77 pares de objetos, o que constitui 9% do total de objetos observados, sendo que 90% dos objetos na referência não foram previstos pelo BRAMS e 77% dos objetos previstos foram considerados como alarmes falsos. Esses valores mostram que com 24 horas de integração, os dois modelos erram mais por falhas do que por alarmes falsos, resultados que se traduzem em baixos valores de CSI e valores de FAR muito altos. A Figura 4.12 ilustra o comportamento temporal do CSI e a FAR orientados a objeto para as previsões dos dois modelos nesse período, os valores médios para o período é mostrado a direita da figura. Note-se que, no geral, o modelo GFS apresentou maiores valores de CSI (médio de 0.09) e menores valores da FAR (0,76) do que o modelo BRAMS (0,08 e 0,77, respectivamente).

Tabela 4.7 - Total de sucessos, falhas e alarmes falsos nas previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.

Modelos	Falhas	Alarmes Falsos	Sucessos	Previstos	Observados
BRAMS	698	256	77	333	775
GFS	683	298	92	390	775

Em uma análise geral dessa avaliação constata-se que é difícil avaliar qual o modelo melhor para os diferentes atributos, sendo para isso muito úteis os valores médios dos interesses parciais tabelados, os quais conseguem resumir todas as informações nos índices para cada modelo avaliado em cada um dos atributos permitindo uma comparação. E uma síntese dos resultados obtidos pode-se afirmar que o BRAMS apresenta melhores desempenho nas previsões de 6 horas de integração do modelo em função da razão da área e distância do centroide, indicando que esse modelo posiciona melhor a precipitação e dimensiona a área de precipitação de forma mais acertada do que o GFS. Com relação as previsões de precipitação acumulada de 6 horas com integração de 24 horas, os resultados indicam que o GFS apresenta os melhores resultados na distância do centroide, razão da área de interseção e também na razão das áreas do pares de objetos, o que indica que com 24 horas de integração o GFS apresenta resultados melhores do que na integração de mais curto prazo. Em uma comparação dos resultados das previsões de 6 e 24 horas de integração nos interesses parciais dos atributos observa-se que o GFS apresenta uma melhora com o processo de integração, enquanto que o BRAMS apresenta uma queda do desempenho nessa circunstância, o que seria o mais esperado uma vez que se está mais longe da condição inicial.

Figura 4.12 - Séries Temporais do CSI (linhas sólidas), a FAR (linhas tracejadas) Orientada a Objeto para as previsões de precipitação de 24 horas de integração do BRAMS e o GFS para Janeiro de 2016. Os valores médios do CSI e a FAR para o período aparecem a direita da figura.



4.3.2 Avaliação das previsões do acumulado de 24 horas

Com a análise das primeiras 24 horas de integração dos modelos feita na seção anterior, cabe ainda avaliar qual é o desempenho dos modelos com a integração mais longa. Como a incerteza na modelagem aumenta com o tempo de integração, nessa análise é considerada a precipitação acumulada nas últimas 24 horas, o que é uma análise menos rigorosa, o que pode ser considerada mais pertinente levando em consideração esse aumento da incerteza. Esse menor rigor se dá pelo fato de que nesse caso, não é avaliado o posicionamento temporal dos objetos durante um determinado dia de integração entre intervalos de 6 horas e sim durante todo o dia avaliado. O experimento realizado para esse fim utilizou as previsões de 24, 48, 72 até 96 horas de integração dos modelos, todas a partir das análises das 00 UTC em cada dia do mês de Janeiro de 2016. As estimativas de acumulados de precipitação 3B42 a cada 3 horas foram integradas para montar o acumulado de precipitação das últimas 24 horas para os mesmos dias. A análise dos resultados é feita em duas etapas. Uma primeira mais detalhada para o primeiro dia de integração do modelo, o que é uma

integração das previsões utilizadas na seção anterior. A segunda é mais generalizada e busca avaliar o desempenho dos modelos para os outros dias de integração, a fim de avaliar o comportamento dos mesmos nas previsões de mais longo prazo.

A Tabela 4.8 representa a tabela de contingência para as previsões do acumulado diário de precipitação para as previsões após 24 horas de integração dos dois modelos, onde os valores correspondentes ao GFS são mostrados em parêntesis. Os valores dos índices orientados a objetos, obtidos a partir da tabela de contingência, são listados na Tabela 4.9. Todos os casos analisados apresentam valores de CSI muito baixos, devido, fundamentalmente, a ocorrência de áreas de chuva não previstas (falhas). Note-se na Tabela 4.8 que o número de falhas, particularmente no modelo BRAMS, representa o dobro do total de alarmes falsos. Observe-se também que o total de objetos previstos pelo GFS (412) é maior do que os previstos pelo BRAMS (305). Esse fato o ajudou a acertar mais com menos casos não previstos, mas por outro lado, também teve mais alarmes falsos. Conseqüentemente, isso explica o fato de o GFS apresentar maiores valores de CSI, POD, FAR e BIAS do que o BRAMS. Esse resultados indicam que, no período analisado, ambos os modelos erraram mais por falhas do que por alarmes falsos, sendo que o GFS apresentou os melhores resultados.

Tabela 4.8 - Tabela de Contingência para as previsões do acumulados diário de precipitação para 24 horas de integração do BRAMS e o GFS (em parêntesis) para Janeiro de 2016.

Observado	Previsto		Total
	Sim	Não	
	BRAMS (GFS)	BRAMS (GFS)	BRAMS (GFS)
Sim	76 (90)	543 (529)	619 (619)
Não	229 (322)	-	229 (322)
Total	305 (412)	543 (529)	848 (941)

Em relação as características espaciais e geométricas dos pares de objetos, as séries temporais do interesse parcial dos atributos diferença do centroide, razão da área, diferença de orientação e razão da área de interseção para as previsões do acumulado diário de precipitação com 24 horas de integração do BRAMS e o GFS para Janeiro de 2016 são mostradas na Figura 4.13. A análise dos atributos dos pares de objetos de precipitação sugere que o GFS tem maior habilidade para representar o posicionamento dos objetos, pois ele apresentou maiores valores do interesse parcial para a separação do centroide dos pares de objetos (Figura 4.13(a)). Por outro lado, o

Tabela 4.9 - Valores do CSI, POD, FAR e BIAS Orientados a Objetos obtidos a partir da Tabela 4.8 para as previsões do acumulados diário de precipitação após 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.

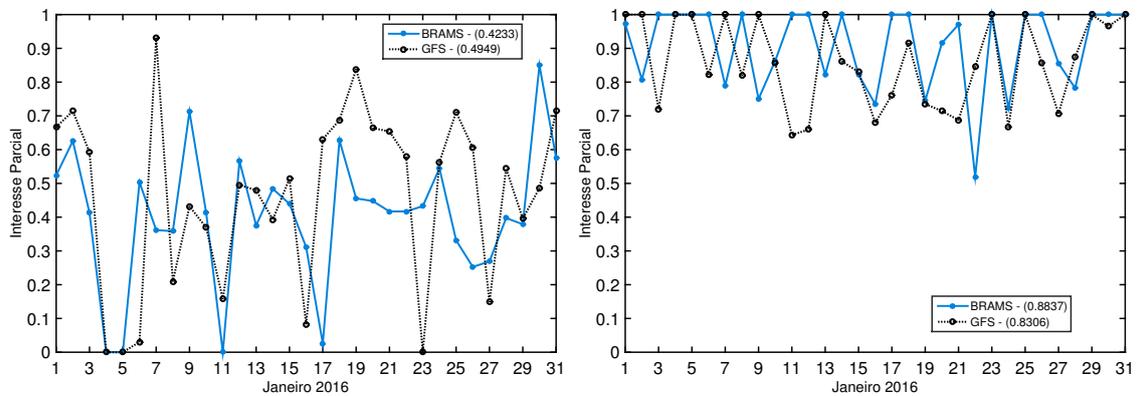
Índices Orientados a Objeto	BRAMS	GFS
CSI	0.0897	0.0956
POD	0.1227	0.1453
FAR	0.7508	0.7815
BIAS	0.4927	0.6655

BRAMS possui maiores valores do interesse parcial da razão da área de interseção, razão da área e diferença de ângulo (Figuras 4.13(b), 4.13(c) e 4.13(d)), o qual indica que ele teve melhor desempenho na representação do tamanho dos objetos, na orientação e na sobreposição com os objetos nas estimativas de precipitação. Algo que merece destaque nos resultados apresentados pelo BRAMS é o valor do interesse parcial da razão da área de interseção de 0.88, o que é um valor relativamente elevado.

Como a diferença do centroide é um dos atributos considerados de maior importância na seleção dos pares de objetos de precipitação, um maior peso é atribuído para ele no cálculo do Interesse Total. Consequentemente, mesmo o BRAMS apresentando valores melhores nos demais atributos, em uma análise geral o modelo GFS representa melhor as características das áreas de chuva observadas. Essa análise generalizada pode ser obtida ao considerar o comportamento do MMI dos dois modelos durante todos os dias do período analisado. Isso pode ser verificado na Figura 4.14, a qual mostra que os maiores valores do MMI foram atribuídos ao modelo GFS.

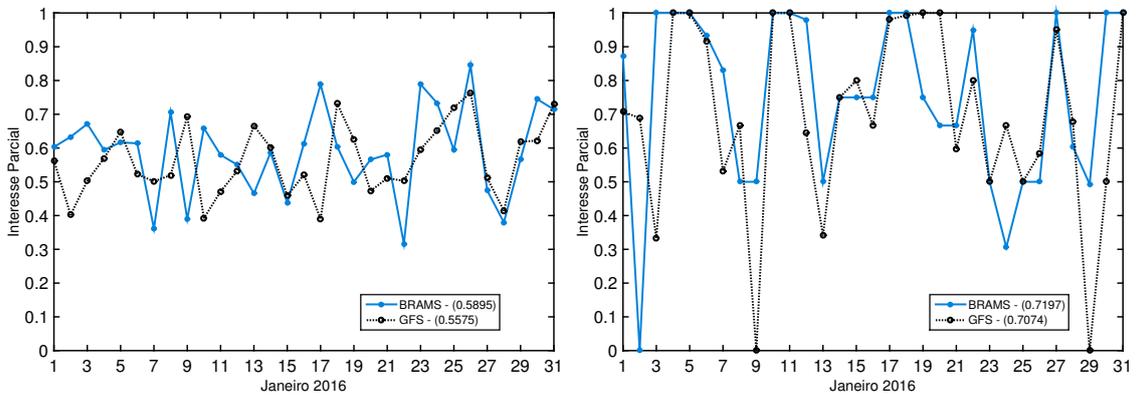
O mesmo padrão do comportamento do MMI foi observado para cada dia de integração dos modelos até 96 horas. No entanto, algumas diferenças entre os modelos foram observadas. Note-se na Figura 4.15(a) que, no caso do BRAMS, MMI aumenta ligeiramente à medida que aumenta o tempo de integração do modelo, o que sugere que o BRAMS consegue representar um pouco melhor as características espaciais e geométricas das áreas de chuva observadas quando o tempo da previsão é maior. Pelo contrário, o comportamento do MMI obtido nas previsões do GFS (ilustrado na Figura 4.15(b)), indica que a habilidade do modelo para representar as áreas de chuva observadas nas estimativas 3B42 piora conforme aumenta o tempo da previsão. Embora isso ocorra, o MMI do GFS para 96 horas de integração (MMI

Figura 4.13 - Séries Temporais do interesse parcial dos atributos: diferença do centroide, razão da área de interseção, razão da área e diferença de orientação para as previsões do acumulado diário de precipitação com 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.



(a) Diferença do centroide

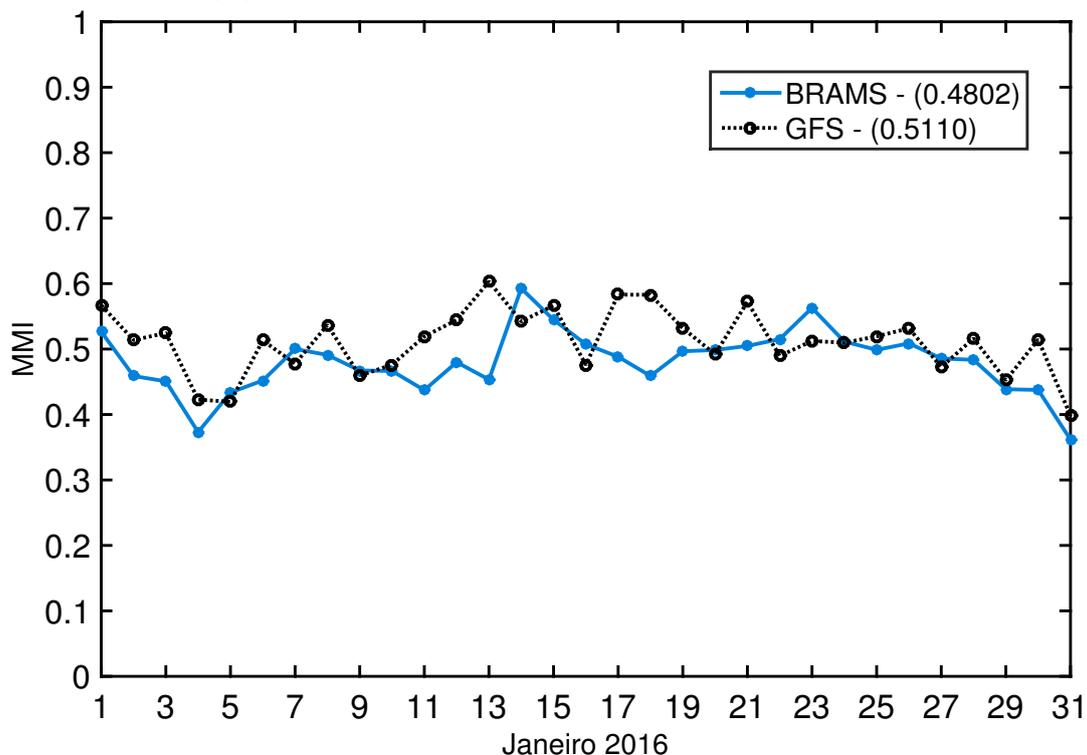
(b) Razão da área de interseção



(c) Razão da área

(d) Diferença de orientação

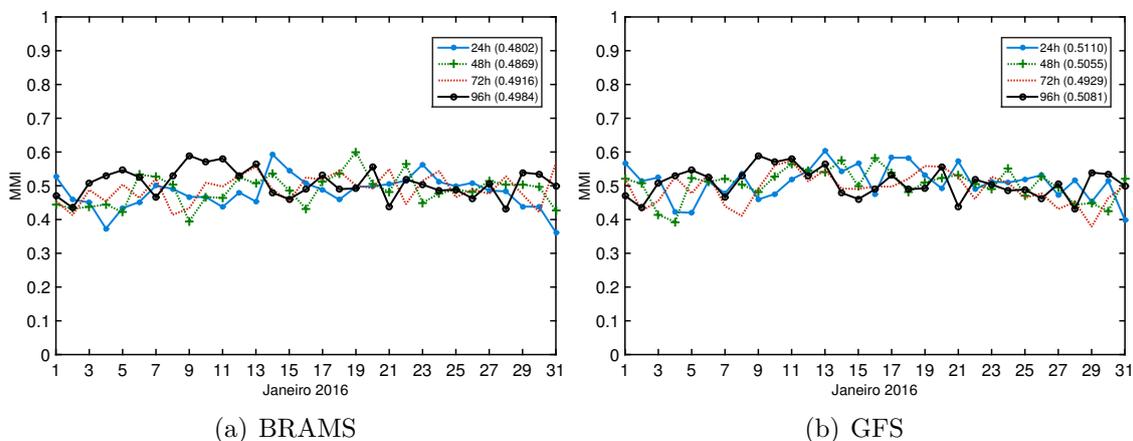
Figura 4.14 - Séries Temporais do MMI para as previsões do acumulado diário de precipitação após 24 horas de integração do BRAMS e o GFS para Janeiro de 2016.



de 0,51) ainda é ligeiramente maior do que o valor observado no BRAMS (0,50). Se essa tendência for mantida para integrações mais longas, os resultados indicam que o refinamento obtido com a resolução mais alta na integração do modelo BRAMS pode contribuir para superar a representação espacial da precipitação gerada pelo GFS sobre a região avaliada.

Para sintetizar os resultados obtidos com a integração dos modelos de forma mais resumida a Figura 4.16 apresenta o comportamento médio dos índices estatísticos orientados a objetos para cada dia de integração dos modelos. Observa-se que não há fortes modificações nos valores desses índices em função da ampliação do tempo de integração dos modelos. Observa-se apenas uma ligeira tendência de degradação do desempenho de ambos os modelos, o que é um resultado esperado quando se trata de previsões baseadas em métodos numéricos. O padrão observado nas previsões de 24 horas onde o total de alarmes falsos e de falhas é maior do que o número de sucessos é mantido nas previsões de mais longo prazo. Ambos os modelos subestimam a quantidade de objetos observados. Essas informações se traduzem em baixos valores de CSI e POD, e por outro lado altas taxas de FAR, e o BIAS menor do que 1. Um

Figura 4.15 - Séries Temporais do MMI para as previsões do acumulado diário de precipitação para os diferentes dias de integração (24, 48, 72 e 96 horas) do BRAMS e o GFS para Janeiro de 2016.

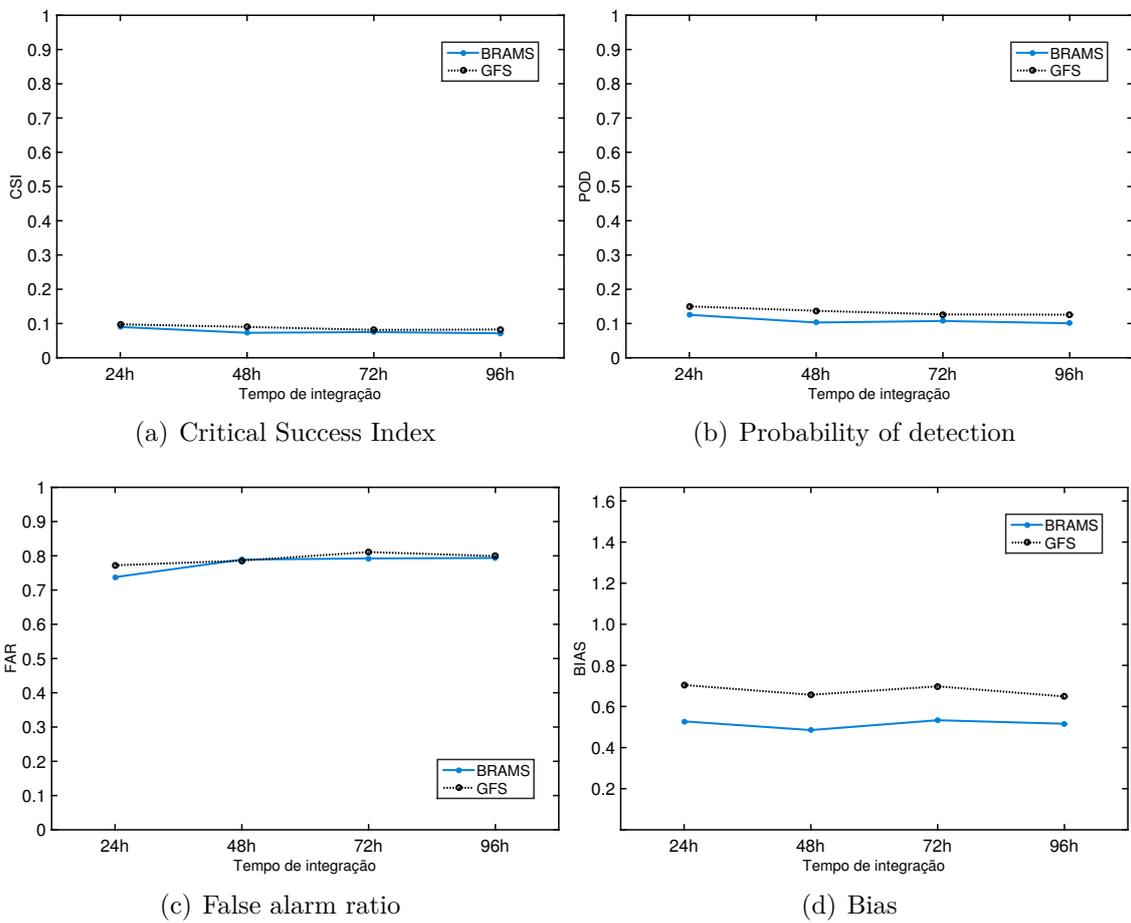


menor numero de falhas foi observado nos resultados do GFS, mas por outro lado apresentou alta índice de alarme falso e o bias das previsões desse modelo foi bem maior que as previsões geradas pelo BRAMS.

4.3.3 Estudo de caso: potencial do método aplicado à tempestades severas

Com o propósito de demonstrar o potencial da metodologia de avaliação de precipitação orientada a objeto em aplicações *Nowcasting*, na verificação da destreza dos modelo numérico em posicionar corretamente as áreas de ocorrência de chuva intensa, foi selecionado um estudo de caso para analisar as previsões dos modelos BRAMS e GFS. O caso de estudo escolhido está relacionado com os acumulados significativos de chuva registrados em várias cidades do litoral de São Paulo (SP) e do litoral sul fluminense entre as 1800 UTC do dia 28 de fevereiro de 2016 e as 0000 UTC do dia 29 de fevereiro de 2016. Segundo o análise das cartas sinóticas (superfície e altitude), a ocorrência desse evento foi influenciada pela combinação da formação de uma Zona de Convergência de Umidade (ZCOU) estendendo-se a partir do oeste da Região Centro-Oeste do Brasil até o Atlântico, com a divergência em altitude, um cavado na troposfera média e a passagem de uma frente fria pelo Oceano Atlântico nas proximidades do litoral de SP. Como consequência, grandes acumulados de precipitação foram registrados em um curto período de tempo, próximos a 200 mm em 6 horas em algumas cidades como Mongaguá (215 mm), Guarujá (194mm), Praia Grande (192mm), São Sebastião (172mm), Bertioga (161mm), entre outras, segundo

Figura 4.16 - Séries Temporais do índices estatísticos (a) CSI, (b) POD, (c) FAR e (d) BIAS orientados a objetos para as previsões do acumulado diário de precipitação em função dos dias de integração do BRAMS e o GFS para Janeiro de 2016.

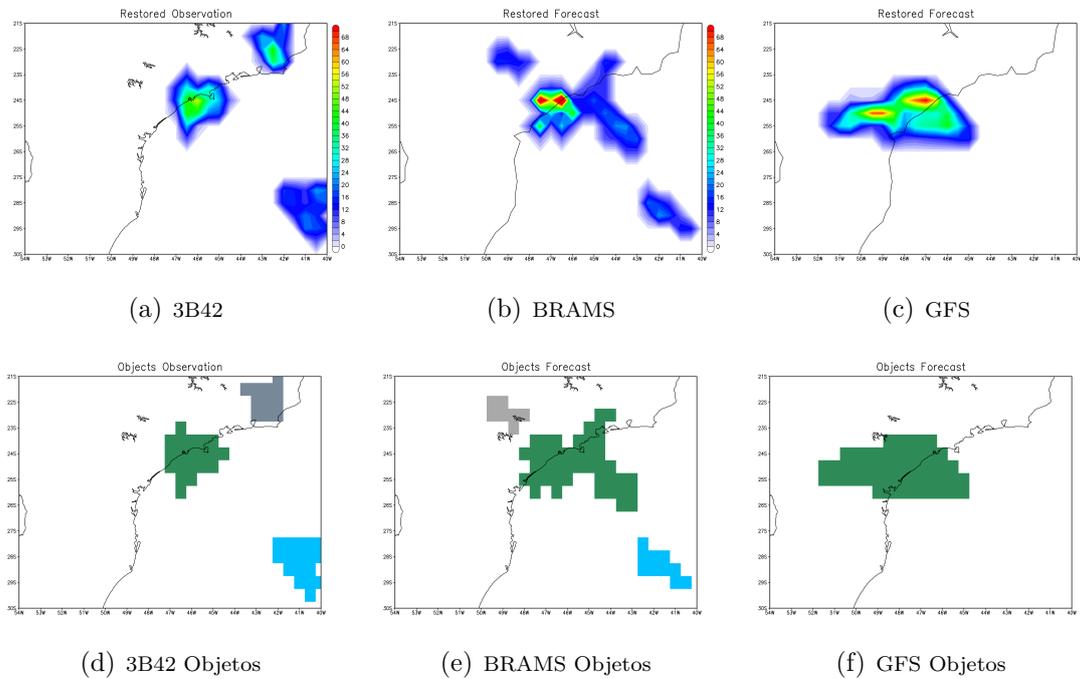


dados pluviométricos do CEMADEN do dia 28 de fevereiro (ROCHA; KONDRASKI, 2016).

Na aplicação do método em uma primeira análise dos campos de precipitação estimado pelo 3B42, observou-se que esse produto subestimou significativamente a intensidade de precipitação reportada pelos pluviômetros. O máximo de precipitação registrado pelo 3B42 foi de apenas 50 mm. No entanto esse produto os valores máximos foram colocados na região próxima do Guarujá, o que indica que embora a informação da intensidade esteve deficiente, a estrutura espacial da precipitação, mesmo que parte dela tenha sido capturada, será considerada como verdade nessa avaliação. Assim, o método foi aplicado às previsões de acumulados de precipitação de 6 horas obtidas a partir das 0000 UTC do 28 de fevereiro após 24 horas de integração, sobre a região afetada, utilizando a mesma configuração dos experimentos realizados pro mês de Janeiro de 2016, mudando apenas o domínio de estudo o limiar de intensidade da chuva no processo de limiarização para eliminar os valores muito baixos de precipitação. Foi utilizado um limiar de 15 mm. Por conseguinte, após o processo de limiarização, foram definidos objetos de menor tamanho e maior intensidade. A Figura 4.17 apresenta os campos de acumulados de precipitação analisados (observado e previstos pelos modelos) e os campos com os objetos de precipitação encontrados, onde cada par de objeto de precipitação é representado com a mesma cor nos dois campos. Foi atribuído a cor cinza para os objetos não pareados. Como ilustrado nas figuras, o algoritmo identificou 3 objetos de precipitação na estimativa 3B42 (Figura 4.17(a)), 3 objetos na previsão do BRAMS (Figura 4.17(b)) e 1 objeto na previsão do GFS (Figura 4.17(c)), sendo que foram encontrados dois pares de objetos entre o BRAMS e a referência (regiões verde e azul nas Figuras 4.17(d) e 4.17(e)) e apenas um par de objetos entre o GFS e a referência (região verde nas Figuras 4.17(d) e 4.17(f)). Isso indica que o BRAMS apresentou maior número de sucessos, enquanto que o GFS mostrou maior número de falhas. Esses valores transformados em estatísticas orientadas a objetos indicam que o BRAMS apresentou um CSI igual ao 0.5 e POD acima de 0.6, ambos valores maiores do que aqueles obtidos pelo GFS (0.3).

Nesse estudo de caso, com foco no evento de precipitação intensa, o mais importante é a avaliação do posicionamentos dos máximos de precipitação. Embora seja algo bastante exigente para uma avaliação de produtos baseados em métodos numéricos, o uso de métricas orientadas a objeto permite avaliar o desempenho do modelo de forma mais coerente e justa. Para isso a análise dos atributos associados as características geométricas dos pares de objetos de precipitação pode ser explorada,

Figura 4.17 - Objetos de precipitação identificados nas previsões de acumulados de 6 horas de precipitação com 24 horas de integração do BRAMS e do GFS a partir da análise do dia 28 de Janeiro de 2016. Previsões para 00UTC do dia 29 de Janeiro de 2016. As áreas de chuva coloridas iguais representam os pares de objetos observação-previsão identificados entre (a)-(b) e (a)-(c), a cor cinza é usada para indicar objetos não pareados nos campos.



tais como diferença de centroide, razão da área de interseção, razão das áreas e orientação. Os valores desses atributos são apresentados na Tabela 4.10 e revelam que para a região de precipitação intensa observada nesse evento o BRAMS representou muito bem o posicionamento do evento e a área de precipitação, com diferença de centroide de apenas 1 ponto e razão de área de intersecção de 0.4. Em comparação com o GFS o BRAMS , apresentou melhor desempenho em todos os atributos. Note-se que o Interesse Total é muito próximo de 1 o que confirma a semelhança entre as propriedades geométricas do par. O valor do MMI também indica que o BRAMS teve melhor desempenho na representação das áreas de chuva.

Algo que merece destaque nesse estudo é que o limiar de precipitação utilizado foi de 15 mm, mas para um limiar superior, que evidencie ainda mais a severidade do evento, os resultados podem ser diferentes modificando o score entre os modelos. Como esse estudo é apenas para exemplificar a aplicação isso não é explorado aqui, o que deve ser feito na continuidade da pesquisa. Um outro ponto que merece atenção na continuidade dos trabalho é a sub estimativa de precipitação do produto 3B42

Tabela 4.10 - Atributos dos pares de objetos (verde) identificados entre as estimativas 3B42 e o BRAMS (Figuras 4.17(d) e 4.17(e)) e entre as estimativas 3B42 e o GFS apresentados em parêntesis (Figuras 4.17(d) e 4.17(f)) no dia 21 de Janeiro de 2016.

Atributos	Valor	Interesse
	BRAMS (GFS)	BRAMS (GFS)
Diferença de centroide	1 pts (5 pts)	0.97 (0.57)
Razão das áreas	0.47 (0.38)	0.58 (0.49)
Diferença de orientação	28.9° (47.9°)	0.0 (0.0)
Razão área interseção	0.40 (0.20)	1.0 (0.81)
Interesse Total		0.94 (0.84)
MMI		0.78 (0.47)

usado como referência, pois esse tipo de erro compromete as conclusões que o método orientado a objeto podem indicar com relação ao desempenho dos modelos avaliados. Nesse aspecto, os dados de estimativas de radar podem ser muito promissores, pois suas incertezas são bem conhecidas. Essa metodologia aplicada nas atividades de previsão numérica do projeto SOS-CHUVA apresenta-se como sendo bastante pertinente, pois possui dados de radar com rigoroso controle de qualidade, modelos de previsão em alta resolução e o foco é melhoria dos modelos em prever eventos de intensa precipitação. Portanto, um bom ambiente para explorar e aprimorar a metodologia orientada a objeto aqui proposta, em trabalhos futuros.

5 CONSIDERAÇÕES FINAIS E CONCLUSÕES

Independentemente dos grandes avanços na tecnologia, incluindo a modelagem numérica de tempo e clima, Gonçalves (2003) afirma que “as sociedades ainda permanecem vulneráveis e parecem estar cada vez mais expostas aos eventos naturais extremos”, que a maioria das vezes resultam em desastres naturais com grandes perdas humanas e econômicas. Ele ressalta que desses eventos naturais, os fenômenos relacionados com a precipitação, são os que provocam maior impacto na vida social e econômica de uma região. Como no Brasil, e nos demais países da América do Sul, a precipitação é a responsável pela maioria dos desastres naturais, a qualidade das previsões de tais eventos tem especial importância nessa região. Nos serviços meteorológicos, com a evolução dos sistemas de comunicações, está disponível operacionalmente diversos produtos de modelos de PNTC, tanto os produzidos no Brasil, como os produtos do CPTEC/INPE, como os disponibilizados por centros internacionais. Essa diversidade de produtos gera aos preditores a seguinte questão: dada a divergência das previsões disponíveis qual o produto é mais confiável para a elaboração do prognóstico final e, principalmente, para a emissão de alertas, quando for o caso? Como já discutido, no caso das previsões de precipitação, dada a complexidade física envolvida, a convergência dos resultados dos modelos é muito pouco frequente, e dado o impacto dos casos severos, responder acertadamente a questão apresentada acima é imprescindível. A resposta para essa questão não é trivial, pois envolve a inter-comparação de modelos, os quais apresentam características muito diferentes entre si, em especial na resolução horizontal, nos processos físicos considerados e no domínio de abrangência. Essas características fazem com que a inter-comparação de modelos, feita normalmente ponto a ponto, seja injusta e gere uma análise mal sucedida que induza conclusões equivocadas. A iniciativa de criar um sistema de avaliação de modelos como o SCANTEC, foi justamente para contribuir na busca da resposta para essa questão, no qual a metodologia aqui proposta, baseada em análise orientada a objeto, possui um potencial significativo nessa direção, tendo em conta as principais vantagens do método. O uso dessa metodologia permite obter uma avaliação mais consistente do que a avaliação tradicional, pois permite identificar e quantificar erros na ocorrência, intensidade, e deslocamento no tempo e no espaço das regiões de precipitação nas previsões dos modelos de PNTC. Além disso o método independe da resolução espacial, portanto ele pode ser usado na intercomparação de modelos de PNTC com diferente resolução. A seguir são apresentadas as conclusões obtidas neste trabalho.

5.1 Conclusões

No que se refere a metodologia proposta, o desenvolvimento nesse trabalho permite concluir que:

- O método de avaliação orientado a objeto implementado no MODE apresenta um grande potencial para descrever as características espaciais e geométricas das áreas de precipitação. Em função dessa constatação, a metodologia aqui proposta é baseada na implementação dos algoritmos que o compõe;
- O ambiente de implementação, dentro de uma filosofia de desenvolvimento comunitário, em que o SCANTEC foi concebido e se desenvolve, foi apropriado para a inclusão da avaliação de precipitação orientada a objeto, sendo ele parte da metodologia proposta;
- Com a análises dos resultados obtidos usando dados sintéticos de precipitação conclui-se que a metodologia proposta e implementada no SCANTEC está correta e evidencias das vantagens da mesma com relação aos métodos convencionais foram obtidas.

Em relação a aplicação da metodologia proposta usando dados reais sobre a América do Sul, pode-se concluir que:

- A metodologia proposta é propícia para avaliar o desempenho dos produtos de precipitação do CPTEC sobre a América do Sul, e compará-los com outros produtos de forma justa ao levar em consideração as características geométricas dos eventos;
- O método de avaliação orientada a objeto independe da resolução espacial dos modelos permitindo comparar modelos regionais de alta resolução sobre a América do Sul com modelos globais sem perda de informações;
- As previsões de precipitação do BRAMS e do GFS permitiram demonstrar claramente as vantagens e particularidades a serem exploradas ao utilizar a metodologia orientada a objeto na avaliação da precipitação sobre a América do Sul, abrindo boas perspectivas para trabalhos futuros com outros modelos e maior período de dados. Embora o período relativamente curto de apenas 30 dias as seguintes constatações foram encontradas nessa avaliação:

- Nas previsões do acumulado de 6 horas de precipitação o desempenho do BRAMS é melhor em 6 horas diminuindo com a integração do modelo enquanto que o GFS apresenta os melhores resultados após 24 de integração;
 - As previsões do BRAMS de 6 horas de integração apresentaram melhor desempenho tanto no posicionamento como na extensão espacial dos eventos, ao comparar com as previsões do GFS;
 - As previsões do GFS após 24 horas de integração apresentaram melhores resultados do que o BRAMS tanto no posicionamento dos eventos como na razão da área de interseção dos pares de objetos.
 - Ambos modelos apresentam uma ligeira tendência de degradação do desempenho com a integração no tempo, o que é um resultado esperado quando se trata de previsões baseadas em métodos numéricos. Eles subestimam a quantidade de objetos observados errando mais por falhas do que por alarmes falsos.
 - Na comparação entre os modelos avaliados, observou-se que nessa configuração utilizada o GFS em geral apresentou um número de eventos maior do que o BRAMS, o que contribuiu para seu maior índice de acerto observado para integrações mais longas.
- Em um estudo de caso a utilização da metodologia orientada a objeto deixou evidente sua funcionalidade em aplicações *nowcasting* ao diagnosticar o desempenho dos modelos no posicionamento das áreas de ocorrência das tempestades intensas. No estudo de caso avaliado o BRAMS apresentou excelentes resultados em todos os atributos associados as características geométricas do evento avaliado.
 - O método proposto mostrou-se bastante promissor para a avaliação justa de modelos sobre a América do sul, permitindo de forma coerente intercompará-los do ponto de vista dos eventos de precipitação, considerando sua forma, extensão e localização, os quais são informações fornecidas diretamente apenas através de métodos orientado a objeto.

5.2 Recomendações Futuras

O contínuo investimento em metodologias de avaliação e diagnóstico é um processo importante para a melhoria da modelagem numérica. O desenvolvimento e evolução do SCAMTEC visando obter avaliações consistentes e unificadas entre diferentes

modelos de PNTC, com a evolução da assimilação de dados, e novas parametrizações facilita essa evolução, pois um bom diagnóstico pode otimizar o impacto de tais modificações na qualidade das previsões (SAPUCCI et al., 2011). Além da combinação de todos esses aspectos, com a iniciativa dessa pesquisa e continuidade nessa linha de trabalho, novas métricas para a avaliação da qualidade das previsões de chuva serão incluídas no SCAMTEC, visando contribuir na identificação de erros presente nas previsões quanto a ocorrência, intensidade, posição no tempo e no espaço. Com isso é possível definir as fontes de tais erro e, portanto, trabalhar diretamente nelas. Nesse contexto, os seguintes pontos podem ser futuramente trabalhados nos próximos passos dessa frente de pesquisa no CPTEC/INPE:

- Aprimorar o método para calcular a Mediana do Interesse Máximo como métrica de avaliação da qualidade das previsões e incluir análise da intensidade de precipitação na metodologia;
- Aplicação do método proposto para avaliar a posição temporal das áreas de precipitação previstas pelos modelos;
- Aplicação do método usando previsões de precipitação de todos os modelos do CPTEC, para um período maior e estabelecer uma comparação entre eles visando diagnosticar seu desempenho para prever a precipitação em diferentes épocas do ano;
- Realizar uma avaliação usando o método aqui proposto para os diferentes regimes de precipitação da América do Sul;
- Aplicação do método para altíssima resolução usando dados de precipitação por radar como valores de referência, em um estudo da avaliação de modelos aplicados em previsões a curtíssimo prazo;
- Implementar outros método de análise espacial no SCANTEC que possam complementar as informações obtidas com o método orientado a objeto.

A metodologia de avaliação orientada a objeto desenvolvida e as futuras implementações dentro do SCANTEC, como parte da filosofia de desenvolvimento comunitário, será disponibilizada para o CPTEC, de forma que possa ser utilizada por todos os pesquisadores na avaliação dos resultados, tanto na pesquisa como na operacionalização dos produtos.

REFERÊNCIAS BIBLIOGRÁFICAS

AHIJEVYCH, D.; GILLELAND, E.; BROWN, B. G.; EBERT, E. E. Application of spatial verification methods to idealized and nwp-gridded precipitation forecasts. **Weather and Forecasting**, v. 24, n. 6, p. 1485–1497, 2009. 42, 44, 45, 47

ANTHES, R. A.; KUO, Y.-H.; HSIE, E.-Y.; LOW-NAM, S.; BETTGE, T. W. Estimation of skill and uncertainty in regional numerical models. **Quarterly Journal of the Royal Meteorological Society**, Wiley Online Library, v. 115, n. 488, p. 763–806, 1989. 2

ATGER, F. Verification of intense precipitation forecasts from single models and ensemble prediction systems. **Nonlinear Processes in Geophysics**, v. 8, n. 6, p. 401–417, 2001. 12

AVANÇO, L. A.; SAPUCCI, L. F.; BAÑOS, I. H.; CARRASCO, A. R.; MATTOS, J. G. Z.; SOUZA, R. V. A. Avaliação da performance das previsões de precipitação geradas no cptec/inpe usando histograma de frequência. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, (CBMET), 19., 2016, João Pessoa, PB. **Anais...** João Pessoa: Sociedade Brasileira de Agrometeorologia, 2016. Available from: <<http://urlib.net/sid.inpe.br/mtc-m21b/2016/11.29.17.50>>. 31

BALDWIN, M.; LAKSHMIVARAHAN, S. Development of an events-oriented verification system using data mining and image processing algorithms. preprints. In: THIRD CONF. ON ARTIFICIAL INTELLIGENCE APPLICATIONS TO ENVIRONMENTAL SCIENCE, 2003, California, USA. **Proceedings...** California: American Meteorological Society, 2003. 14

BALDWIN, M. E.; KAIN, J. S. Sensitivity of several performance measures to displacement error, bias, and event frequency. **Weather and forecasting**, v. 21, n. 4, p. 636–648, 2006. 2

BAÑOS, I. H.; SAPUCCI, L. F.; BASTARZ, C. F.; AVANÇO, L. A.; MATTOS, J. G. Z. Funções empíricas ortogonais para avaliar o desempenho de modelos de previsão no cptec/inpe. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, (CBMET), 19., 2016, João Pessoa, PB. **Anais...** João Pessoa: Sociedade Brasileira de Agrometeorologia, 2016. Available from: <<http://urlib.net/sid.inpe.br/mtc-m21b/2016/11.29.17.56>>. 31

BENDER, F. D. **Verificação da previsão do tempo em São Paulo com o modelo operacional WRF**. PhD Thesis (PhD) — Universidade de São Paulo, 2012. 3

BRIGGS, W. M.; LEVINE, R. A. Wavelets and field forecast verification. **Monthly Weather Review**, v. 125, n. 6, p. 1329–1341, 1997. 13

CASATI, B. New developments of the intensity-scale technique within the spatial verification methods intercomparison project. **Weather and Forecasting**, v. 25, n. 1, p. 113–143, 2009. 13, 16

CASATI, B.; ROSS, G.; STEPHENSON, D. A new intensity-scale approach for the verification of spatial precipitation forecasts. **Meteorological Applications**, Cambridge Univ Press, v. 11, n. 02, p. 141–154, 2004. 12, 16

CASATI, B.; WILSON, L.; STEPHENSON, D.; NURMI, P.; GHELLI, A.; POCERNICH, M.; DAMRATH, U.; EBERT, E.; BROWN, B.; MASON, S. Forecast verification: current status and future directions. **Meteorological applications**, Wiley Online Library, v. 15, n. 1, p. 3–18, 2008. 2

CHAUDHURI, D.; SAMAL, A. A simple method for fitting of bounding rectangle to closed regions. **Pattern recognition**, Elsevier, v. 40, n. 7, p. 1981–1989, 2007. 35

COLLINS-SUSSMAN, B.; FITZPATRICK, B. W.; PILATO, C. M. **Controle de Versão com Subversion: Para Subversion 1.4**. [s.n.], 2007. Available from: <<https://projetos.cptec.inpe.br/projects/gdad/wiki>>. 28

COUTINHO, A. B. d. M.; AGOP, R. S. **Boletim de informações climáticas do CPTEC/INPE 29 de fevereiro de 2016**. 2016. Available from: <http://infoclima1.cptec.inpe.br/~rinfo/pdf_infoclima/201602.pdf>. Access in: 08 de março 2016. 53

DAMRATH, U.; WETTERDIENST, D. Verification against precipitation observations of a high density network—what did we learn. In: INT. VERIFICATION METHODS WORKSHOP, 2004, Montreal, Quebec, Canada. **Proceedings...** Montreal: World Meteorological Organization, 2004. 12

DAVIS, C. A.; BROWN, B. G.; BULLOCK, R.; HALLEY-GOTWAY, J. The method for object-based diagnostic evaluation (mode) applied to numerical forecasts from the 2005 nssl/spc spring program. **Weather and Forecasting**, v. 24, n. 5, p. 1252–1267, 2009. 3, 15, 20, 22, 27, 39, 41, 42

- DOYLE, M. E.; TOMASELLA, J.; RODRIGUEZ, D. A.; CHOU, S. C.
Experiments using new initial soil moisture conditions and soil map in the eta model over la plata basin. **Meteorology and Atmospheric Physics**, Springer, v. 121, n. 3-4, p. 119–136, 2013. 3
- EBERT, E.; MCBRIDE, J. Verification of precipitation in weather systems: Determination of systematic errors. **Journal of Hydrology**, Elsevier, v. 239, n. 1, p. 179–202, 2000. 14
- EBERT, E. E. Fuzzy verification of high-resolution gridded forecasts: a review and proposed framework. **Meteorological applications**, Wiley Online Library, v. 15, n. 1, p. 51–64, 2008. 12
- FREITAS, S. R.; LONGO, K. M.; DIAS, M. A. F. S.; CHATFIELD, R.; DIAS, P. S.; ARTAXO, P.; ANDREAE, M. O.; GRELL, G.; RODRIGUES, L. F.; FAZENDA, A. et al. The coupled aerosol and tracer transport model to the brazilian developments on the regional atmospheric modeling system (catt-brams)–part 1: Model description and evaluation. **Atmospheric Chemistry and Physics**, Copernicus GmbH, v. 9, n. 8, p. 2843–2861, 2009. 50
- GANGULY, A. R.; BRAS, R. L. Distributed quantitative precipitation forecasting using information from radar and numerical weather prediction models. **Journal of Hydrometeorology**, v. 4, n. 6, p. 1168–1180, 2003. 2
- GERMANN, U.; ZAWADZKI, I. Scale dependence of the predictability of precipitation from continental radar images. part ii: Probability forecasts. **Journal of Applied Meteorology**, v. 43, n. 1, p. 74–89, 2004. 12
- GEVAERD, R.; FREITAS, S. Estimativa operacional da umidade do solo para iniciação de modelos de previsão numérica da atmosfera parte i: descrição da metodologia e validação. **Revista Brasileira de Meteorologia**, v. 21, n. 3, p. 1–15, 2006. 50
- GILLELAND, E.; AHIJEVYCH, D.; BROWN, B. G.; CASATI, B.; EBERT, E. E. Intercomparison of spatial forecast verification methods. **Weather and Forecasting**, v. 24, n. 5, p. 1421–1422, 2009. 3, 11, 14, 15, 19
- GONÇALVES, N. M. S. Impactos pluviais e desorganização do espaço urbano em salvador. **Clima urbano**, p. 69–91, 2003. 1

- GRELL, G. A.; DÉVÉNYI, D. A generalized approach to parameterizing convection combining ensemble and data assimilation techniques. **Geophysical Research Letters**, Wiley Online Library, v. 29, n. 14, 2002. 50
- HARRIS, D.; FOUFOULA-GEORGIOU, E.; DROEGEMEIER, K. K.; LEVIT, J. J. Multiscale statistical properties of a high-resolution precipitation forecast. **Journal of Hydrometeorology**, v. 2, n. 4, p. 406–418, 2001. 13, 17
- HERNÁNDEZ, L.; ROQUE, A.; CHOU, S. C.; SIERRA, M.; SUEIRO, G. Avaliação orientada a objetos da previsão de precipitação acumulada em 24 horas do modelo eta. In: WORKSHOP BRASILEIRO DE MICROMETEOROLOGIA, 9., 2015, Santa Maria, RS. **Anais...** Santa Maria: Universidade Federal de Santa Maria, 2015. 3
- HOFFMAN, R. N.; LIU, Z.; LOUIS, J.-F.; GRASSOTI, C. Distortion representation of forecast errors. **Monthly Weather Review**, v. 123, n. 9, p. 2758–2770, 1995. 15
- HONG, S.-Y.; PAN, H.-L. Nonlocal boundary layer vertical diffusion in a medium-range forecast model. **Monthly weather review**, v. 124, n. 10, p. 2322–2339, 1996. 51
- HUFFMAN, G. J.; BOLVIN, D. T.; NELKIN, E. J.; WOLFF, D. B.; ADLER, R. F.; GU, G.; HONG, Y.; BOWMAN, K. P.; STOCKER, E. F. The trmm multisatellite precipitation analysis (tmpa): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. **Journal of Hydrometeorology**, v. 8, n. 1, p. 38–55, 2007. 51, 52
- JOLLIFFE, I. T.; STEPHENSON, D. B. **Forecast verification: a practitioner's guide in atmospheric science**. [S.l.]: Wiley, 2012. 2, 7, 8, 30
- KALNAY, E.; KANAMITSU, M. Time schemes for strongly nonlinear damping equations. **Monthly weather review**, v. 116, n. 10, p. 1945–1958, 1988. 51
- KALNAY, E.; KANAMITSU, M.; BAKER, W. Global numerical weather prediction at the national meteorological center. **Bulletin of the American Meteorological Society**, v. 71, n. 10, p. 1410–1428, 1990. 51
- KANAMITSU, i.; ALPERT, J.; CAMPANA, K.; CAPLAN, P.; DEAVEN, D.; IREDELL, M.; KATZ, B.; PAN, H.-L.; SELA, J.; WHITE, G. Recent changes implemented into the global forecast system at nmc. **Weather and Forecasting**, v. 6, n. 3, p. 425–435, 1991. 51

- KANAMITSU, M. Description of the nmc global data assimilation and forecast system. **Weather and Forecasting**, v. 4, n. 3, p. 335–342, 1989. 51
- KEIL, C.; CRAIG, G. C. A displacement-based error measure applied in a regional ensemble forecasting system. **Monthly Weather Review**, v. 135, n. 9, p. 3248–3259, 2007. 15, 16
- _____. A displacement and amplitude score employing an optical flow technique. **Weather and Forecasting**, v. 24, n. 5, p. 1297–1308, 2009. 15, 16
- LACK, S. A.; LIMPET, G. L.; FOX, N. I. An object-oriented multiscale verification scheme. **Weather and Forecasting**, v. 25, n. 1, p. 79–92, 2010. 13, 16, 17
- LEITH, C. Atmospheric predictability and two-dimensional turbulence. **Journal of the Atmospheric Sciences**, v. 28, n. 2, p. 145–161, 1971. 51
- LONGO, K.; FREITAS, S.; SILVA, M. A. D.; SILVA, P. D. Numerical modeling developments towards a system suitable to a real time air quality forecast and climate changes studies in south america. 2006. 50
- LORENZ, E. N. Deterministic nonperiodic flow. **Journal of the atmospheric sciences**, v. 20, n. 2, p. 130–141, 1963. 1
- _____. The predictability of hydrodynamic flow. **Transactions of the New York Academy of Sciences**, v. 25, n. 4 Series II, p. 409–432, 1963. 1
- MARCELINO, E. V.; NUNES, L. H.; KOBAYAMA, M. Banco de dados de desastres naturais: Análise de dados globais e regionais/natural disaster databases: global and regional analysis. **Caminhos de Geografia**, v. 7, n. 19, p. 130–149, 2006. 1
- MARENGO, J. A. Água e mudanças climáticas. **Estudos Avançados**, v. 22, n. 63, p. 83–96, 2008. 1
- MARTINS, J. A. **A precipitação no modelo RAMS**. 2016. Available from: <http://brams.cptec.inpe.br/~rbrams/doc/microphysics_documentation.pdf>. Access in: 11 de março 2016. 50
- MARZBAN, C.; SANDGATHE, S. Cluster analysis for verification of precipitation fields. **Weather and Forecasting**, v. 21, n. 5, p. 824–838, 2006. 16, 17

- _____. Cluster analysis for object-oriented verification of fields: A variation. **Monthly Weather Review**, v. 136, n. 3, p. 1013–1025, 2008. 16, 17
- _____. Verification with variograms. **Weather and forecasting**, v. 24, n. 4, p. 1102–1120, 2009. 13
- MARZBAN, C.; SANDGATHE, S.; LYONS, H.; LEDERER, N. Three spatial verification techniques: Cluster analysis, variogram, and optical flow. **Weather and Forecasting**, v. 24, n. 6, p. 1457–1471, 2009. 13
- MICHEAS, A. C.; FOX, N. I.; LACK, S. A.; WIKLE, C. K. Cell identification and verification of qpf ensembles using shape analysis techniques. **Journal of Hydrology**, Elsevier, v. 343, n. 3, p. 105–116, 2007. 15, 17
- MOUNT, D. M. **Lecture Notes for Computational Geometry Course**. Dpt. Of Computer Science, University of Maryland, 2000. 35
- NACHAMKIN, J. E.; CHEN, S.; SCHMIDT, J. Evaluation of heavy precipitation forecasts using composite-based methods: A distributions-oriented approach. **Monthly weather review**, v. 133, n. 8, p. 2163–2177, 2005. 2
- PIELKE, R. A. A comparison of three-dimensional and two-dimensional numerical predictions of sea breezes. **Journal of the Atmospheric Sciences**, v. 31, n. 6, p. 1577–1585, 1974. 50
- REBOITA, M. S.; GAN, M. A.; ROCHA, R. P. da; AMBRIZZI, T. Regimes de precipitação na américa do sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, SciELO Brasil, v. 25, n. 2, 2010. 53
- REZACOVA, D.; SOKOL, Z.; PESICE, P. A radar-based verification of precipitation forecast for local convective storms. **Atmospheric Research**, Elsevier, v. 83, n. 2, p. 211–224, 2007. 12
- ROBERTS, N. M.; LEAN, H. W. Scale-selective verification of rainfall accumulations from high-resolution forecasts of convective events. **Monthly Weather Review**, v. 136, n. 1, p. 78–97, 2008. 12, 17
- ROCHA, F. P. d.; KONDRASKI, L. **Cidades da faixa litorânea de SP sofreram com acumulados significativos de chuva entre os dias 28 e 29 de fevereiro de 2016**. 2016. Available from: <<http://www.cptec.inpe.br/noticias/noticia/128299>>. Access in: 13 de janeiro 2017. 78

RODRÍGUEZ, C. F.; SIERRA, M.; FERRER, A. L. Modificación e implementación del método de evaluación espacial modemod para su uso operativo en cuba. **Ciencias de la Tierra y el Espacio**, v. 17, n. 1, p. 18–31, 2016. 27

ROQUE, A.; SIERRA, M.; QUINTANA, N. Método de evaluación diagnóstico orientado a objetos modificado (modemod) utilizando la información de los satélites meteorológicos. **Ciencias de la Tierra y el Espacio**, v. 15, n. 2, p. 139–150, 2014. 27

SAPUCCI, L. F.; MATTOS, J. G. Z.; MATTOS, A. F.; GONÇALVES, L. G. G.; BASTARZ, C.; SCHUBERT, D. V. Potencialidades do scamtec (sistema de avaliação de modelos numéricos de previsão de tempo e clima) na avaliação de previsões de precipitação. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 2011, Guarapari-SP Rio de Janeiro RJ. **Anais...** [S.l.]: Sociedade Brasileira de Agrometeorologia, 2011. 29, 84

SEGAWA, T.; HONDA, Y. The verification of high-resolution precipitation forecasts of the operational jma mesoscale model. In: JOINT WORKING GROUP ON VERIFICATION WORKSHOP. [S.l.]: World Meteorological Organization, 2007. p. 31. 12

SELA, J. G. Spectral modeling at the national meteorological center. **Monthly Weather Review**, v. 108, n. 9, p. 1279–1292, 1980. 51

SHI, W.; CENTER, C. P. **The annual cycle and variability of precipitation in Brazil**. [S.l.]: NOAA, National Weather Service, National Centers for Environmental Prediction, Climate Prediction Center, 2000. 53

SIERRA, M. L.; BORRAJERO, I. M.; HINOJOSA, M. F.; ROQUE, A. C.; RODRÍGUEZ, C. F. G.; VÁSQUEZ, L. P.; FERRER, A. L. H. Herramientas de detección, reporte y evaluación para las salidas de modelos de pronóstico numérico desarrollado en cuba. **Revista Cubana de Meteorología**, v. 22, n. 2, p. 150–163, 2016. 34

THEIS, S.; HENSE, A.; DAMRATH, U. Probabilistic precipitation forecasts from a deterministic model: a pragmatic approach. **Meteorological Applications**, Wiley Online Library, v. 12, n. 3, p. 257–268, 2005. 12

TREMBACK, C. J.; POWELL, J.; COTTON, W. R.; PIELKE, R. A. The forward-in-time upstream advection scheme: extension to higher orders. **Monthly Weather Review**, v. 115, n. 2, p. 540–555, 1987. 50

TRIPOLI, G. J.; COTTON, W. R. The colorado state university three-dimensional cloud/mesoscale model-1982 part i: General theoretical framework and sensitivity experiments. **J. Rech. Atmos.**, v. 16, p. 185–219, 1982. 50

TROEN, I.; MAHRT, L. A simple model of the atmospheric boundary layer; sensitivity to surface evaporation. **Boundary-Layer Meteorology**, Springer, v. 37, n. 1-2, p. 129–148, 1986. 51

VENUGOPAL, V.; BASU, S.; FOUFOULA-GEORGIU, E. A new metric for comparing precipitation patterns with an application to ensemble forecasts. **Journal of Geophysical Research: Atmospheres**, Wiley Online Library, v. 110, n. D8, 2005. 15

WARNER, T. T. **Numerical weather and climate prediction**. [S.l.]: Cambridge University Press, 2011. 294–320 p. 1

WERNLI, H.; HOFMANN, C.; ZIMMER, M. Spatial forecast verification methods intercomparison project: Application of the sal technique. **Weather and Forecasting**, v. 24, n. 6, p. 1472–1484, 2009. 15, 17

WERNLI, H.; PAULAT, M.; HAGEN, M.; FREI, C. Sal-a novel quality measure for the verification of quantitative precipitation forecasts. **Monthly Weather Review**, v. 136, n. 11, p. 4470–4487, 2008. 15, 17

WILKS, D. Statistical methods in the atmospheric sciences. **Academic Press**, p. 467, 1995. 7

_____. Statistical methods in the atmospheric sciences. 2nd ed. **Academic Press**, p. 648, 2005. 2

ZADEH, L. A. Fuzzy sets. **Information and control**, Elsevier, v. 8, n. 3, p. 338–353, 1965. 23

ZEPEDA-ARCE, J.; FOUFOULA-GEORGIU, E.; DROEGEMEIER, K. K. Space-time rainfall organization and its role in validating quantitative precipitation forecasts. **Journal of Geophysical Research: Atmospheres**, Wiley Online Library, v. 105, n. D8, p. 10129–10146, 2000. 17