



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2021/04.21.18.47-TDI

**RASTREIO E PREVISÃO DE SISTEMAS  
PRECIPITANTES E CONVECTIVOS NA BACIA  
AMAZÔNICA UTILIZANDO APRENDIZADO DE  
MÁQUINA NÃO-SUPERVISIONADO**

Helvécio Bezerra Leal Neto

Dissertação de Mestrado do Curso  
de Pós-Graduação em Computação  
Aplicada, orientada pelo Dr. Alan  
James Peixoto Calheiros, aprovada  
em 21 de maio de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/44HGF8E>>

INPE  
São José dos Campos  
2021

**PUBLICADO POR:**

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

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA N° 176/2018/SEI-INPE):**

**Presidente:**

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

**Membros:**

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

**BIBLIOTECA DIGITAL:**

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

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

**EDITORAÇÃO ELETRÔNICA:**

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



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2021/04.21.18.47-TDI

**RASTREIO E PREVISÃO DE SISTEMAS  
PRECIPITANTES E CONVECTIVOS NA BACIA  
AMAZÔNICA UTILIZANDO APRENDIZADO DE  
MÁQUINA NÃO-SUPERVISIONADO**

Helvécio Bezerra Leal Neto

Dissertação de Mestrado do Curso  
de Pós-Graduação em Computação  
Aplicada, orientada pelo Dr. Alan  
James Peixoto Calheiros, aprovada  
em 21 de maio de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/44HGF8E>>

INPE  
São José dos Campos  
2021

Dados Internacionais de Catalogação na Publicação (CIP)

---

Leal Neto, Helvécio Bezerra.

L473r Rastreo e previsão de sistemas precipitantes e convectivos na Bacia Amazônica utilizando aprendizado de máquina não-supervisionado / Helvécio Bezerra Leal Neto. – São José dos Campos : INPE, 2021.

xxvi + 144 p. ; (sid.inpe.br/mtc-m21c/2021/04.21.18.47-TDI)

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

Orientador : Dr. Alan James Peixoto Calheiros.

1. Previsão em curto prazo. 2. Rastreo. 3. Aprendizado de máquina. 4. Clusterização. 5. Geoprocessamento. I.Título.

CDU 004.85:551.511.61

---



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

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



## INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

### DEFESA FINAL DE DISSERTAÇÃO DE HELVÉCIO BEZERRA LEAL NETO BANCA Nº 121/2021, REG 281215/2019

No dia 21 de maio de 2021, as 14:30h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Computação Aplicada. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

**Novo Título: "Rastreo e Previsão de Sistemas Precipitantes e Convectivos na Bacia Amazônica utilizando Aprendizado de Máquina Não-supervisionado. "**

Eu, Stephan Stephany, como Presidente da Banca Examinadora, assino esta ATA em nome de todos os membros, com o consentimento dos mesmos.

Dr. Stephan Stephany - Presidente - INPE  
Dr. Alan James Peixoto Calheiros - Orientador - INPE  
Dr. Daniel Alejandro Vila - Membro Interno - INPE  
Dra. Rachel Ifanger Albrecht - Membro Externo - USP



Documento assinado eletronicamente por **Stephan Stephany, Pesquisador Titular**, em 31/05/2021, às 14:31 (horário oficial de Brasília), com fundamento no art. 6º do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7369599** e o código CRC **28B175F9**.



*“Quem é mais humilde? O cientista que olha para o universo com uma mente aberta e aceita tudo o que o universo tem para nos ensinar, ou alguém que diz tudo neste livro deve ser considerado a verdade literal e não importa a falibilidade de todos os seres humanos envolvidos?”*

CARL SAGAN  
em “Um Mundo Infestado de Demônios”, 1995.



*À floresta, aos rios, animais, e a todos os que a defendem, à Amazônia.*



## AGRADECIMENTOS

Agradeço primeiramente a meus pais e irmãos pelo apoio e carinho em minha jornada de vida, em especial agradeço a meus tios Barroso e Maria Antônia por sempre me incentivar desde a infância em buscar o conhecimento através da ciência. Agradeço também a Universidade Federal do Oeste do Pará e a todos que fizeram parte do meu desenvolvimento durante o período de graduação e iniciação científica, em especial ao Dr. Júlio Tota pelo incentivo em aplicar ciência para Amazônia. Ao Instituto Nacional de Pesquisas Espaciais pela oportunidade, e a meus colegas de trabalho do LAC por momentos excepcionais. Aos amigos de minha cidade natal Santarém, especialmente aos companheiros do grupo do doce, à Carolinze, aos novos amigos em São José dos Campos, especialmente para Augusto e Juliana por compartilhar diariamente alegrias, experiências e companheirismo.

Ao Dr. Alan James Peixoto Calheiros, pelos ensinamentos e orientação em minha trajetória acadêmica, pela atenção excepcional no desenvolvimento desta pesquisa e compreensão perante as dificuldades.

Agradeço ao projeto GoAmazon e CPTEC-INPE pelos dados disponibilizados que foram utilizados neste trabalho.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos durante o período de pós-graduação.

Aos membros da banca pela avaliação desta pesquisa. E a todos que utilizarem os conhecimentos aqui apresentados para o desenvolvimento da ciência em nosso país.



## RESUMO

Compreender a dinâmica de propagação e as características morfológicas das células de chuva e nuvens são fundamentais para desenvolver métodos computacionais com intuito de auxiliar na tomada de decisões. Tais ferramentas servem para atenuar possíveis impactos socioeconômicos causados por tempestades severas. Neste trabalho foi apresentada uma nova metodologia para identificação, rastreamento e previsão de células de chuva e os chamados sistemas convectivos de mesoescala, atuantes na região da bacia amazônica. Por meio de um conjunto de procedimentos que reúnem técnicas de aprendizado de máquina e geoprocessamento, foi desenvolvido um algoritmo que utiliza informações de multi-sensores (radar ou satélite) para identificar regiões de interesse em células de chuva e nuvem por meio de um processo denominado multi-limiarização. Tal processo faz a segmentação dos valores de refletividade e temperatura de brilho em dados de radar e imagens de satélite, respectivamente. Após o processo de identificação das regiões de interesse, o método de clusterização DBSCAN foi utilizado para classificar *clusters* (agrupamento de píxeis associados a nuvens em imagens de satélite ou taxa de chuva em radares). Em seguida aplicou-se métodos de geoprocessamento para definir a trajetória dos *clusters* por meio da técnica de rastreamento baseada no centroide das geometrias. Algumas incertezas relacionadas ao vetor de deslocamento abstraídos da trajetória dos *clusters* podem ocorrer com o uso de técnicas que utilizam o centroide, com base nisso, aplicou-se quatro métodos de correção do deslocamento que levaram em consideração as características físicas que ocorrem na propagação de células de chuva e nuvem. Os métodos de correção foram avaliados por meio da previsão por extrapolação temporal dos eventos ocorridos em imagens consecutivas para períodos relativos a estação chuvosa (IOP1) e seca (IOP2) durante o experimento GoAmazon. A aplicação dos métodos de correção do deslocamento apresentaram um ganho em torno de 22,5% na precisão das previsões. O método que utiliza os limiares internos mostrou-se o mais representativo, principalmente para ajuste dos vetores quando a extensão de área das células apresenta grandes regiões com núcleos mais intensos embebidos. Com relação a área e o ciclo de vida dos sistemas observado durante os IOPs, constatou-se que sistemas maiores, com maior duração e mais intensos foram melhor previstos. As propagações observadas dos sistemas rastreados via radar e satélite foram condizentes aquelas apresentadas na literatura para região da bacia amazônica.

Palavras-chave: Previsão em curto prazo. Rastreamento. Aprendizado de máquina. Clusterização. Geoprocessamento.



# TRACKING AND PREDICTION OF PRECIPITATING AND CONVECTIVE SYSTEMS IN THE AMAZON BASIN USING UNSUPERVISED MACHINE LEARNING

## ABSTRACT

Understanding the propagation dynamics and morphological characteristics of rain and cloud cells are important to develop computational methods to make decisions. Such tools is used to mitigate possible socio-economic impacts caused severe storms events. In this work a new methodology for identification, tracking and forecasting of rain cells of mesoscale convective systems, operating in Amazon basin region, was presented. Through procedures that bring together using machine learning and geoprocessing techniques, one algorithm was developed that uses information from multi-sensors (radar or satellite) to identify regions of interest in rain and cloud cells, using a process called multi-threshold. This process make segmentation of images in reflectivity and brightness temperature into radar and satellite data, respectively. After this process, identifying regions of interest, we used a clustering method DB-SCAN to classify clusters (cluster of pixels associated with clouds in satellite images or rainfall rate in radar). Geoprocessing methods are applied to define trajectory of clusters using centroid-based technique and geometries tracking. Some uncertainties related to the displacement vector abstracted from the trajectory of clusters can occur, based on centroid tracking we propose four methods of correction of the displacement, were applied that adjust displacement vector using physical characteristics that occur in spread of rain and cloud cells. Correction of displacement vector methods were evaluated through prediction by temporal extrapolation of occurred events in consecutive images, for periods related rainy season (IOP1) and dry season (IOP2) during GoAmazon experiment. The algorithm developed in this research obtained a good performance to forecasting ability after applying methods to correct the displacement of rain and cloud cells. Displacement vector correction methods led to a 22.5 % gain in algorithm skills, the method that uses internal thresholds to correct displacement proved to be most effective, mainly for adjusting the vectors when cell area extension presents large stratified regions with more intense nuclei. Regarding area and the life cycle of systems observed during IOPS, it was found that larger systems were better predicted, duration life cycle and size tendence to positively impact at statistical indicators used for forecast analysis. Regarding the propagation of systems tracked by radar and satellite, it was found that their displacement followed trends found in literature for the Amazon basin region.

Keywords: Nowcasting. Tracking. Machine learning. Clustering. Geoprocessing.



## LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Fluxograma dos conceitos de ciência dos dados proposta por O’Neil e Schutt (2013). . . . .	8
2.2 Escalas meteorológicas e suas extensões de duração e tamanho. . . . .	10
2.3 Densidade da gênese dos SCMs sobre a bacia Amazônica entre os anos 2000 e 2013. . . . .	12
2.4 (a) Distribuição do tamanho das células de chuva com base no Radar SIPAM de Banda - S para estações seca e chuvosa; (b) Distribuição do tamanho das células de chuva com base no Satélite GOES, para estações seca e chuvosa. . . . .	13
2.5 Seção transversal esquemática de uma LI pelo echo radar. . . . .	14
2.6 Estágios de desenvolvimento de um SC rastreado por um algoritmo sobre a Amazônia, com informações do canal infravermelho do satélite GOES-13. . . . .	16
3.1 Área de cobertura do Radar do SIPAM localizado na região de Manaus-AM.	22
3.2 Área para os dados pré-processados correspondentes à cobertura da bacia Amazônica com o satélite GOES-13. . . . .	24
3.3 Fluxograma do algoritmo. . . . .	26
3.4 Estrutura de células de precipitantes em varredura azimutal radar. . . . .	29
3.5 Processo de agrupamento e classificação realizado pelo DBSCAN. . . . .	32
3.6 Representações espaciais sobre dados de Radar. Os Pontos brancos, representam a localização geográfica de um determinado valor de refletividade; os Polígonos vermelhos, representam o contorno limite da região que envolve os pontos; a região em Azul representa os valores de refletividade do radar. . . . .	33
3.7 Exemplo de aplicação da sobreposição de polígonos para determinar o vetor de deslocamento entre dois tempos consecutivos. . . . .	36
3.8 Esquema para representar ocorrências de Continuidades, Divisões e Fusões entre células. . . . .	37
3.9 Exemplo para técnica de extrapolação Ctvo. . . . .	39
3.10 Exemplo para as técnicas de extrapolação. a) Mdd2: utiliza a extrapolação média dos vetores $\vec{V}_{1(xy)}$ e $\vec{V}_{2(xy)}$ para calcular o vetor resultante previsto $\vec{V}_p$ . b) Mdd3: utiliza a extrapolação média dos vetores $\vec{V}_{1(xy)}$ , $\vec{V}_{2(xy)}$ e $\vec{V}_{2(xy)}$ para determinar o vetor resultante previsto $\vec{V}_p$ . . . . .	39

3.11	(a) São registrados dois eventos (Evento 1 e Evento 2) com valores de refletividade em 35 dBZ respectivamente, (b) Evento 1 foi classificado como célula preferencial devido aos seus critérios de sobreposição e tamanho, (c) Apresenta como estão dispostos os vetores de deslocamento entre o tempo anterior ao evento de Fusão (vetores pretos) e os vetores gerados pela Fusão (laranja) e o real vetor de deslocamento (cinza). . . . .	40
3.12	Exemplo de correção pelo método de média vetorial (VET) . . . . .	42
3.13	Exemplo de correção pelo método da média dos Limiar Interno (LIM). . . . .	44
3.14	Exemplo de correção pelo método baseado na Fusão (FUS). . . . .	45
3.15	Exemplo de criação de vetor auxiliar com método baseado na Divisão de células (DIV). . . . .	45
4.1	Habilidade para os métodos de extrapolação com base nos seus parâmetros de rastreamento para o modo operacional básico com dados de radar. . . . .	53
4.2	<i>Skill Score</i> para os diferentes métodos de correção vetorial, limiares e extrapolação com referência ao Ctvo-BASE-20-15 para o IOP1. . . . .	55
4.3	<i>Skill Score</i> para os diferentes métodos de correção vetorial, limiares e extrapolação com referência ao Ctvo-BASE-20-15 para o IOP2. . . . .	57
4.4	a) Resultados de POD para métodos de correção para o limiar 20 dBZ no IOP1. b) Valores de POD para os métodos de correção aplicados ao limiar de 20 dBZ no IOP2. . . . .	59
4.5	a) Resultados dos métodos de correção para o limiar 35 dBZ no IOP1. b) Valores de POD para os métodos de correção aplicados ao limiar de 35 dBZ no IOP2. . . . .	60
4.6	<i>Skill Score</i> para os diferentes métodos de correção vetorial, limiares e extrapolação com referência ao Ctvo-BASE-20-15 para o IOP1+IOP2 . . . . .	61
4.7	Ocorrência de <i>cluster</i> chuva por tipo (contínuos, fusão e divisão) durante os IOPs 1 (a) e 2 (b). . . . .	63
4.8	Ocorrência de famílias (sistemas precipitantes) por tipo (contínuos, fusão e divisão) durante os IOP1 (a) e IOP2 (b). . . . .	64
4.9	Duração em horas para os tipos de famílias no IOP1 (a) e IOP2 (b) do Radar. Tamanho médio dos sistemas precipitantes com base em suas famílias no IOP1 (c) e IOP2 (d) do Radar. . . . .	67
4.10	Propagação dos grupos de famílias durante o IOP 1 (a) e IOP 2 (b) para o rastreamento via radar. . . . .	69
4.11	Distribuição das ocorrências para famílias com os melhores e piores casos durante os IOP1 (a) e IOP2 (b). . . . .	71

4.12	Duração do ciclo de vida das famílias para os melhores e piores casos rastreados via radar para durante o IOP1 (a) e IOP2 (b). c) Área média para os melhores e piores casos durante o IOP1. d) Área média para os melhores e piores casos durante o IOP2. . . . .	73
4.13	a) Refletividade média para os melhores casos durante o IOP1. b) Valores de refletividade média do radar nos melhores e piores casos durante IOP2.	74
4.14	a);b) Propagação dos sistemas classificados com FAR < 0,5 durante os IOPs 1 e 2. c);d) Propagação dos sistemas como piores casos (FAR > 0,5).	75
4.15	Resultados dos rastreios para o satélite e métodos de correção do deslocamento para os parâmetros de 235k com 150 píxeis nos IOP1 (a) e IOP2 (b). . . . .	78
4.16	Área de estudos do satélite. Imagem do satélite GOES13 no canal infravermelho para o dia 16 de Agosto de 2014 às 17 horas (GMT). . . . .	79
4.17	Duração do ciclo de vida das famílias para o rastreio com dados do satélite GOES-13. a) Duração dos eventos nos grupos no IOP1. b) Duração no IOP2. . . . .	81
4.18	Comparativo entre as áreas dos <i>clusters</i> de nuvem nos melhores e piores casos para o IOP1 (a) e IOP2 (b) dos dados de satélite. . . . .	82
4.19	Limiares de temperatura de brilho nos melhores e piores casos. a) Distribuição dos limiares para IOP1. b) Distribuição dos limiares de temperatura de brilho durante IOP2. . . . .	83
4.20	Percentual de classificação dos sistemas com base no ciclo de vida e tamanho de área. a) Grupos de famílias com curta duração durante os IOPs 1 e 2. b) Famílias de sistemas com longa duração durante os IOPs 1 e 2.	84
4.21	Histograma de frequência relativa do FAR para diferentes classes de tamanho e duração durante os IOP1 (a) e 2 (b). . . . .	85
4.22	Trajetória dos sistemas com curta duração durante o IOP1 (a) e IOP2 (b). Sistemas com longa duração durante o IOP1(c) e IOP2(d). . . . .	87
4.23	Eventos ao longo do dia 16 de agosto de 2014 identificados pelo algoritmo via dados do radar. . . . .	89
4.24	Eventos ao longo do dia 16 de agosto de 2014 identificados pelo algoritmo via dados do satélite GOES-13 no canal infravermelho. . . . .	90
4.25	a) Desenvolvimento dos limiares de refletividade e número de <i>clusters</i> internos para o SCM com UID 135 rastreado via radar. b) Desenvolvimento dos limiares de temperatura de brilho e número de <i>clusters</i> internos para o SCM com UID 143 rastreado via satélite. . . . .	92

4.26	Representação das trajetórias para rastreo via radar e satélite em: a) ;b) ;c) ;d) ;e) ;f) . Linhas pretas mostram as trajetórias para o radar e a linhas vermelhas mostram as trajetórias pelo satélite. . . . .	94
4.26	Conclusão. . . . .	95
B.1	Habilidade dos métodos de extrapolação com base nos seus parâmetros de rastreo para o modo operacional básico com dados de Satélite. . . . .	127
B.2	Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiars e extrapolação com referência ao Ctvo-BASE-235-150 para o IOP1. . . . .	128
B.3	Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiars e extrapolação com referência ao Ctvo-BASE-235-150 para o IOP2. . . . .	128
B.4	Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiars e extrapolação com referência ao Ctvo-BASE-235-150 para oIOP1+IOP2. . . . .	129
B.5	Ocorrência de cluster de nuvem por tipo (contínuos, fusão e divisão) durante os IOPs 1 (a) e 2 (b) do satélite. . . . .	129
B.6	Ocorrência de famílias nuvem por tipo (contínuos, fusão e divisão) durante os IOP1 (a) e IOP2 (b). . . . .	130
B.7	Figura 8 Satélite. . . . .	130
B.8	Duração em horas para os tipos de famílias no IOP1 e IOP2 do satélite. . . . .	131
B.9	Tamanho médio dos sistemas com base em suas famílias no IOP1 e IOP2 do satélite. . . . .	131
C.1	Propagação satélite curta duração. . . . .	133
C.2	Propagação satélite longa duração. . . . .	134
D.1	Rastreo UID 135 RADAR - Data: 16/08/2014. . . . .	136
D.2	Continuação. . . . .	137
D.3	Continuação. . . . .	138
D.4	Continuação. . . . .	139
D.5	Conclusão. . . . .	140
E.1	Rastreo UID 143 SATELITE - Data: 16/08/2014. . . . .	142
E.2	Continuação. . . . .	143
E.3	Conclusão. . . . .	144

## LISTA DE TABELAS

	<u>Pág.</u>
3.1 Limiares utilizados por outros autores. . . . .	27
3.2 Parâmetros de rastreio do algoritmo para análise dos períodos de observação (IOP1 e IOP2). . . . .	28
4.1 Performance geral do algoritmo. . . . .	50
4.2 Velocidade média dos grupos de famílias durante os IOPs 1 e 2. . . . .	68
4.3 Grupos dos melhores e piores casos cujo centroide cruzou a região de estudos nos IOPs 1 e 2. . . . .	80
D.1 Resultados dos parâmetros de rastreio com o modo operacional BASE sem aplicação dos métodos de correção vetorial. . . . .	113
D.2 Índices estatísticos do IOP1 para os métodos de correção vetorial, extração e parâmetros de rastreio. . . . .	113
D.3 Índices estatísticos do IOP2 para os métodos de correção vetorial, extração e parâmetros de rastreio. . . . .	119
D.4 Precipitação registrada no sítio T3 - Manacapuru(AM). . . . .	124



## LISTA DE ABREVIATURAS E SIGLAS

BIAS	– Viés
CAPPI	– Constant Altitude Plan Position Indicator
CD	– Ciência de Dados
CEMADEN	– Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CPTEC	– Centro de Previsão de Tempo e Estudos Climáticos
Ctvo	– Técnica de extrapolação conservativa
DBSCAN	– Density Based Spatial Clustering of Applications with Noise
DBZc	– Variável para refletividade do radar
DIV	– Método de correção vetorial por divisões
EDA	– Exploratory Data Analysis
ELAT	– Grupo de Eletricidade Atmosférica
FAR	– False alarm ratio
ForTraCC	– Forecast and Tracking the Evolution of Cloud Clusters
FUS	– Método de correção vetorial por fusões
GMS	– Geostationary Meteorological Satellite
GoAmazon	– Green Ocean Amazon
GOES	– Geostationary Operational Environmental Satellite
INMET	– Instituto Nacional de Meteorologia
INPE	– Instituto Nacional de Pesquisas Espaciais
IOP	– Intense Observing Period
KLT	– Kanade–Lucas–Tomas
LI	– Linha de Instabilidade
LIM	– Método de correção vetorial por limiares internos
Mdd2	– Técnica de extrapolação de dois deslocamentos
Mdd3	– Técnica de extrapolação de três deslocamentos
NASA	– National Aeronautics and Space Administration
NCAR	– National Center for Atmospheric Research
NEXRAD	– Next-Generation Radar
NOAA	– National Oceanic and Atmospheric Administration
NWP	– Numerical Weather Prediction
POD	– Probability of detection
SC	– Sistema Convectivo
SCIT	– Storm Cell Identification and Tracking
SCM	– Sistema Convectivo de Mesoescala
SIPAM	– Sistema de Proteção da Amazônia
TEMP	– Variável de temperatura de brilho
TIROS-1	– Television and Infrared Observation Satellite
TITAN	– Thunderstorm Identification, Tracking, Analysis and Nowcasting
VET	– Método de correção vetorial por ciclo de vida
WGS84	– World Geodetic System

WSR-88D – Weather Surveillance Radar 1988 Doppler  
ZR – Radar reflectivity to rain rate relationships

## LISTA DE SÍMBOLOS

dBZ	–	Decibéis de refletividade em nível Z
K	–	Índice para temperatura de brilho em Kelvin
$\Delta t$	–	Intervalo temporal
Max	–	Máximo
Min	–	Mínimo
$\mu\text{m}$	–	Micrômetro
mm/h	–	Milímetro por hora
$Q(x_2, y_2)$	–	Ponto final de um vetor no plano cartesiano
$P(x_1, y_1)$	–	Ponto inicial de um vetor no plano cartesiano
km	–	Quilômetros
km/h	–	Quilômetros por hora
Z	–	Refletividade de radar em um nível
p	–	Unidade para pixels
$\vec{V}_{ajustado}$	–	Vetor ajustado por um método de correção
$\vec{V}_t$	–	Vetor de deslocamento em uma unidade temporal



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Tempestades na Amazônia . . . . .	3
1.2 Objetivos . . . . .	4
1.3 Estrutura da pesquisa . . . . .	6
<b>2 REFERENCIAL TEÓRICO</b> . . . . .	<b>7</b>
2.1 Ciência de dados . . . . .	7
2.2 Os objetos do rastreo: sistemas convectivos e a precipitação na região Amazônica . . . . .	9
2.3 O rastreo de fenômenos meteorológicos . . . . .	15
<b>3 DADOS E METODOLOGIA</b> . . . . .	<b>21</b>
3.1 Dados . . . . .	21
3.1.1 Radar . . . . .	21
3.1.2 Satélite . . . . .	23
3.2 Metodologia . . . . .	25
3.2.1 O algoritmo de rastreo e previsão . . . . .	25
3.2.1.1 Parâmetros de rastreo . . . . .	26
3.2.1.2 Limiarização . . . . .	29
3.2.1.3 Clusterização . . . . .	30
3.2.1.4 Vetorização . . . . .	31
3.2.1.5 A tabela de rastreo . . . . .	34
3.2.2 Identificação e rastreo . . . . .	35
3.2.3 Previsão por extrapolação . . . . .	38
3.3 Problemas relacionados ao uso do centroide . . . . .	39
3.3.1 Métodos de correção do deslocamento . . . . .	41
3.3.1.1 Correção por média vetorial (VET) . . . . .	42
3.3.1.2 Correção por limiar interno (LIM) . . . . .	43
3.3.1.3 Correção por fusão (FUS) . . . . .	44
3.3.1.4 Correção por divisão (DIV) . . . . .	44
3.3.1.5 Avaliação dos métodos . . . . .	46
<b>4 RESULTADOS</b> . . . . .	<b>49</b>

4.1	Performance do algoritmo . . . . .	49
4.2	Rastreo via radar . . . . .	51
4.2.1	Análise dos parâmetros e técnicas de extrapolação: modo operacional básico . . . . .	51
4.2.2	Análise dos métodos de correção vetorial . . . . .	53
4.2.3	As características médias dos sistemas precipitantes rastreados durante os IOPs . . . . .	62
4.2.4	Características morfológicas que impactam na performance da previsão	70
4.3	Rastreo via satélite . . . . .	76
4.3.1	Análise dos métodos de correção do deslocamento . . . . .	77
4.3.2	Área de estudo para o rastreo via satélite . . . . .	78
4.3.3	Parâmetros que impactam na previsão dos SCMs . . . . .	80
4.4	Estudo de caso: tempestade no dia 16 de agosto de 2014 . . . . .	88
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>97</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>101</b>
	<b>APÊNDICE A - TABELA COM PARÂMETROS ESTATÍSTICOS .</b>	<b>113</b>
	<b>APÊNDICE B - FIGURAS AUXILIARES PARA RASTREIO VIA SATÉLITE . . . . .</b>	<b>127</b>
	<b>APÊNDICE C - ROSA DOS VENTOS PARA RASTREIO VIA SATÉLITE . . . . .</b>	<b>133</b>
	<b>APÊNDICE D - FIGURAS PARA O ESTUDO DE CASO - RA- DAR . . . . .</b>	<b>135</b>
	<b>APÊNDICE E - FIGURAS PARA O ESTUDO DE CASO - SATE- LITE . . . . .</b>	<b>141</b>

# 1 INTRODUÇÃO

As tempestades são fenômenos meteorológicos que causam inúmeros impactos socioeconômicos em diversas partes do globo. Impulsionado pelas mudanças climáticas, os eventos extremos (tempestades severas, vendavais, geadas, granizo, etc) estão cada vez mais frequentes (NOBRE, 2010). No Brasil, os impactos climáticos gerados pelos eventos extremos já vem causando grandes prejuízos, na economia por exemplo, um dos mais afetados é setor agroindustrial, que é um dos principais motores econômicos do país, e que nos últimos anos já vem sendo afetado fortemente por eventos climáticos extremos como o aumento na média pluviométrica em algumas regiões e o surgimento de secas em que se estendem além dos períodos sazonais (MARTINS et al., 2010).

Outro fator associado às tempestades são as descargas elétricas (i.e. raios), onde o Brasil ocupa uma posição em destaque no ranking de países com maior incidência desses fenômenos (ALBRECHT et al., 2016). Segundo o Grupo de Eletricidade Atmosférica (ELAT) do Instituto Nacional de Pesquisas Espaciais (INPE) o Brasil apresenta uma média anual de aproximadamente 77.8 milhões de raios (ELAT, 2015). Com isso, a importância dos estudos relacionados ao monitoramento de tempestades são fundamentais, uma vez que os danos causados tanto por tempestades quanto por raios associados possam ser mitigados.

No Brasil, alguns órgãos prestam serviços de previsão de tempo e clima para o país. O CPTEC (Centro de Previsão de Tempo e Estudos Climáticos)<sup>1</sup> do INPE<sup>2</sup>, o Instituto Nacional de Meteorologia (INMET) e o CEMADEN (Centro Nacional de Monitoramento e Alertas de Desastres Naturais)<sup>3</sup>, tem papel fundamental na prestação de serviços de previsão de tempo, monitoramento de eventos meteorológicos para o território nacional. Tais órgãos são fundamentais pois, a partir de seus sistemas de alerta ações podem ser tomadas em curto e longo prazo para diminuir os impactos causados por eventos severos.

Devido a dinâmica temporal e espacial das tempestades, onde há uma alta variabilidade, a utilização de métodos para identificação e rastreamento do ciclo de vida das tempestades são essenciais para os sistemas de previsão em curtíssimo prazo (*now-casting*, em inglês) (WILSON et al., 1998). Tais sistemas são compostos por conjuntos de técnicas aplicadas na previsão de tempo para um período de até 6 horas, de

---

<sup>1</sup><https://www.cptec.inpe.br>

<sup>2</sup><https://www.inpe.br>

<sup>3</sup><https://www.cemaden.gov.br>

modo a estimar o estado de tempo futuro utilizando fontes de dados como satélites meteorológicos e radares, o mais rápido possível (CALHEIROS et al., 2016).

Os dados utilizados para os previsores dos sistemas de *nowcasting* são baseados, em sua maioria, por sensores como radar e satélite meteorológicos. As técnicas mais aplicadas visam geralmente a extrapolação espaço-temporal das informações que são rastreadas (e.g. Nuvens, Chuva e Raios), uma vez que sua performance nas primeiras horas são consideradas satisfatórias, quando comparadas ao uso dos Modelos de Previsão Numérica de Tempo (NWP - *Numerical Weather Prediction*, em inglês) em mesoescala e escala sinóticas.

Em 1975, de um esforço entre a NASA (Agência Espacial Americana) e a NOAA (Administração Nacional Oceânica e Atmosférica), que são agências Norte Americanas que cuidam de assuntos relacionados à atmosfera, oceanos e espaço, surgiu os satélites GOES (*Geostationary Operational Environmental Satellite*, em inglês). Tais Satélites fazem parte de um sistema para monitoramento constante das condições de tempo sobre a área de atuação. Seus instrumentos são capazes de gerar informações sobre o estado atual da atmosfera como, temperatura do topo de nuvens e descargas atmosféricas em tempo real (GOODMAN et al., 2012), este último só disponível na versão derradeira.

Outro instrumento comumente utilizado em pesquisas e no desenvolvimento de produtos operacionais para o *nowcasting* são os radares meteorológicos. Estes equipamentos são ferramentas essenciais para o estudo de precipitação, pois, possibilitam a varredura volumétrica de objetos por meio de ecos de radar. Em Diversos estudos, os radares meteorológicos são utilizados para identificar características morfológicas e microfísicas dos sistemas precipitantes (QUEIROZ, 2009). Principalmente aqueles associados aos sistemas convectivos de mesoescala (SCMs) devido a suas características de gerar grandes volumes precipitação sobre as regiões tropicais (MACHADO et al., 1998).

Monitorar o deslocamento e evolução dos SCMs assim como a extração de informações de suas estruturas, permite investigar os processos de formação desses fenômenos e por sua vez colaborar com estudos e ferramentas de previsão para descrever o ciclo de vida desses sistemas. De acordo com Williams e Houze Junior (1987) o deslocamento de alguns dos SCMs é lento e pode gerar grandes volumes de precipitação, assim como a presença de ventos fortes (ascendentes e descendentes) que em alguns casos podem estar associado a raios e granizo. Ou seja, a partir dos parâmetros característicos da morfologia dos SCMs é possível alimentar modelos de

previsão que usam essas informações para determinar o deslocamento e tempo de vida dos SCMs (MACHADO; LAURENT, 2004).

O uso das características morfológicas de células individuais em tempestades presentes em dados de radar e satélite, possibilita ainda classificar cada tempestade de forma individual. Suas zonas com maior convecção podem ser categorizadas a partir de multi-limiar nos valores de refletividade (radar) ou temperatura de topo de nuvens para satélites (CRANE, 1979). As áreas com maiores valores de refletividade ou menor temperatura de topo de nuvem possibilita a identificação de células convectivas na tempestade, essas características podem ser usadas como parâmetros para rastreamento destes sistemas meteorológicos, onde, o ponto central de cada célula são chamados de centroides.

O rastreamento e a previsão de deslocamento das regiões mais severas dentro das tempestades são essenciais em um sistema de *nowcasting*. Tal monitoramento é útil pois pode prover aos tomadores de decisão informações importantes sobre a severidade desses eventos. Atualmente existem diversas técnicas que usam rastreamento das áreas associadas a tempestades (DIXON; WIENER, 1993; VILA et al., 2008; LAKSHMANAN et al., 2009; MATTHEWS; TROSTEL, 2010).

Modelos de previsão baseados em técnicas computacionais mais sofisticadas (e.g. Inteligência Artificial) vem ganhando cada vez mais espaço. Ferramentas que utilizam não só métodos estatísticos tradicionais, mas novas técnicas de aprendizado de máquina vem sendo amplamente difundidas, principalmente para resolver problemas associados ao rastreamento de tempestades (MINOTTA-ZAPATA; RODRÍGUEZ-SOLÍS, 2019; KHANDAN et al., 2018; KURIHANA et al., 2019; GAGNE et al., 2017).

## 1.1 Tempestades na Amazônia

Devido as implicações relacionadas ao atual cenário das mudanças climáticas, a Amazônia é um dos principais palcos de diversos debates e estudos envolvendo seus aspectos ambientais (CHENG et al., 2013). A interação entre floresta e atmosfera na Amazônia é um tema com bastante relevância, isso porque a floresta serve como um grande regulador do clima, principalmente para porção continental da América do Sul (NOBRE, 2014).

Eventos extremos relacionados as mudanças climáticas já podem estar afetando diretamente o bioma Amazônico, em 2005 uma tempestade com extensões de aproximadamente 1000 quilômetros de comprimento e 200 de largura, causou estragos

entre as cidades de Santarém (PA) e Manaus (AM), ventos fortes de até 145 km/h chegaram a abrir clareiras de até 30 hectares no meio da floresta (NEGRÓN-JUÁREZ et al., 2010). Esses fenômenos estão relacionados com as chamadas linhas de instabilidade (LI), que são tempestades dispostas em forma de linha e que são frequentes na região Amazônica (COHEN et al., 1989; FISCH et al., 1998). Estes sistema atmosférico fazem parte da família dos SCMs (LOUREIRO et al., 2014), além das LI, os eventos associados aos SCM são compostos principalmente por nuvens *Cumulusnimbus* (CBs) organizadas em escalas meteorológicas de tempo e espaço descritas por (ORLANSKI, 1975) como mesoescala.

Monitorar o deslocamento e evolução dos SCMs permite investigar os processos envolvidos na sua formação, e por sua vez colaborar com estudos e ferramentas de previsão capazes de descrever o ciclo de vida desses sistemas. Ou seja, a partir dos parâmetros característicos dos sistemas atmosféricos supracitados, é possível alimentar modelos de previsão em curto prazo que utilizam informações de sua morfologia para determinar o deslocamento e tempo de vida das células de tempestades. Determinar o ciclo de vida dos sistemas atmosféricos é de suma importância pois a partir de sua análise é possível estipular os momentos de maior severidade das tempestades, melhorando assim a previsão dos eventos severos e mitigando seus impactos.

Como dito anteriormente, os satélites e radares meteorológicos são utilizados para identificar características morfológicas e microfísicas dos sistemas precipitantes (QUEIROZ, 2009). Compreender as essas características e o comportamento dos principais sistemas atuantes sobre a região Amazônica é um passo fundamental para o desenvolvimento de sistemas para rastreamento de tempestade na região.

## 1.2 Objetivos

O objetivo principal deste trabalho foi compreender a dinâmica de deslocamento e propagação dos sistemas precipitantes e dos SCMs sobre a região da bacia Amazônica durante o experimento de campo GoAmazon (*Green Ocean Amazon*) (MARTIN et al., 2017). Para tanto, neste estudo foi levado em consideração as características morfológicas e físicas que impactam em sua previsão a partir de diversas correções no vetor deslocamento. Para este fim, foi desenvolvido um novo algoritmo capaz de identificar e prever o deslocamento de sistemas meteorológicos a partir de técnicas não-supervisionadas para o processamento de imagens espaciais. Esta nova ferramenta que será disponibilizada ao INPE e seus parceiros, tem a capacidade de utilização para diferentes sensores, uma vantagem, já que algoritmos que envolvem análise multi-sensor não são frequentes. Esta pesquisa tomou proveito do experi-

mento de campo do projeto internacional GoAmazon para desenvolver análises mais profundas sobre os sistemas ali atuantes. Durante este projeto, diversas informações coletadas a respeito da física das nuvens e precipitação foram realizadas, dados de radares meteorológicos, estações de superfície, radiossondagens atmosféricas e observações feitas por satélites meteorológicos. Tais informações passaram por processos de controle de qualidade. Apesar de algumas dessas informações serem restritas a região amazônica, a metodologia desenvolvida e seus resultados podem ser aplicadas a outras regiões e dados.

Logo, para atingir o objetivo principal foi necessário realizar uma série de propósitos específicos, dentre estes podemos citar:

- a) Construir um algoritmo de rastreamento com base na utilização de ferramentas computacionais robustas com intuito de corroborar na previsão em curtíssimo prazo. Para tanto, aplicou-se metodologias para rastreamento de chuva e nuvens utilizando aplicações de geoprocessamento e método de aprendizado não-supervisionado. Com relação a este último foi utilizada a técnica DBSCAN (Clusterização Espacial Baseada em Densidade com Ruído, em inglês “*Density Based Spatial Clustering of Applications with Noise*”) em conjunto a multi-limiarização para melhor definir as propriedades morfológicas dos sistemas rastreados. Em Conjunto as técnicas não-supervisionadas, foram utilizadas operações espaciais por meio de metodologias que usam o centroide e sobreposição de quadros, para rastrear a trajetória de cada objeto deste estudo (i.e. chuva e nuvens);
- b) Aplicar técnicas de correção vetorial que visaram diminuir o erro do rastreamento com base no centroide, de modo a melhor representar as características morfológicas e físicas dos sistemas. Um problema associado ao formato não-rígido das células de chuva e nuvens.
- c) Utilizar técnicas de extrapolação linear para prever o possível vetor de deslocamento dos diferentes tipos de informações do sistemas de nuvem e chuva utilizados como “entrada” no rastreamento. Aplicando a performance da previsão como métrica para verificar se as modificações realizadas nas diferentes modificações do algoritmo;
- d) Estudar as trajetórias dos sistemas precipitantes e SCM para entender os padrões médios encontrados sobre a região em específico e definir as melhores estratégias de monitoramento e previsão;

- e) Definir as características morfológicas que impactam na previsão dos sistemas meteorológicos rastreados.

### **1.3 Estrutura da pesquisa**

A elaboração deste documento foi dividido em cinco capítulos, uma breve descrição do conteúdo de cada um destes é apresentada nos tópicos a seguir:

- **Capítulo 1:** Introdução para contextualização das questões relacionadas à importância dos sistemas de previsão em curtíssimo prazo, quais entidades são responsáveis pelo monitoramento e estudos de tempo, e características relacionadas ao rastreamento de tempestades e precipitação.
- **Capítulo 2:** Revisão bibliográfica e trabalhos relacionados necessários para compreender a metodologia de execução desta pesquisa.
- **Capítulo 3:** Descreve os dados utilizados neste trabalho e a metodologia proposta para identificação, rastreamento e previsão de sistemas atmosféricos atuantes na bacia amazônica.
- **Capítulo 4:** Contém os resultados alcançados após a aplicação do algoritmo para rastreamento de sistemas atmosféricos em dois períodos de observação, rastreados via radar e satélite, também são descritas as principais características que impactam na habilidade de previsão do algoritmo, e demonstra-se por meio de um estudo de caso sua aplicabilidade para investigação de eventos individuais.
- **Capítulo 5:** Conclusões e sugestões de melhorias para o algoritmo em trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

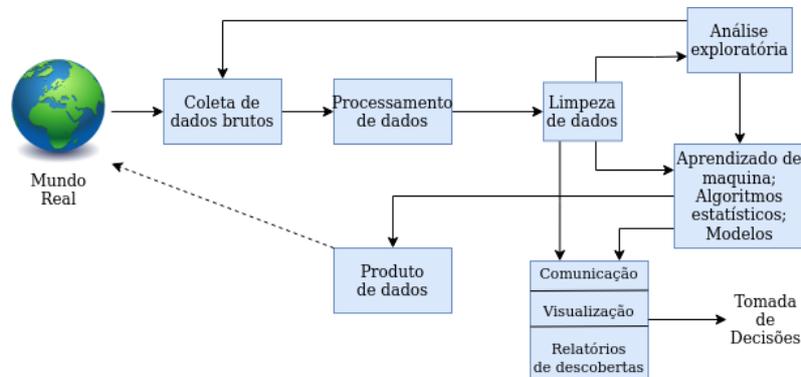
Neste capítulo são abordados os conceitos relacionadas ao tema deste trabalho. Os temas foram divididos em seções, na primeira Seção 2.1 são apresentadas visões gerais sobre ciência de dados e como utilizar seus conceitos para resolução de problemas no mundo real. Tópicos relacionados aos sistemas atmosféricos que atuam sobre a região Amazônica e estudos envolvendo seu rastreo são apresentados na Seção 2.2. Na Seção 2.3 são apresentadas metodologias para rastreo de fenômenos meteorológicos e os principais trabalhos.

### 2.1 Ciência de dados

Atualmente questões envolvendo estudos e análises de grandes volumes de dados estão em profusão para diversas áreas. A Ciência de dados (CD) (em inglês, *Data Science*) é uma expressão utilizada para descrever um novo campo da ciência que visa extrair conhecimento a partir da interpretação de informações por meio da análise de dados (AALST, 2016). Logo, uma análise exploratória dos dados AED (em inglês, *Exploratory Data Analysis*), é de suma importância para determinar as relações entre as diferentes informações que podem ser extraídas em um determinado conjunto de dados. Por sua vez a AED é uma expressão que teve origem por volta dos anos 60, quando John Tukey propôs que a análise estatística não era uma nomenclatura adequada quando se examinava dados reais e com probabilidades associadas às investigações estatísticas (TUKEY et al., 1977).

Os conceitos envolvidos com CD corroboram para diversas áreas da ciência. O’Neil e Schutt (2013) propuseram uma sequência de etapas que podem ser seguidas com intuito de resolver problemas do mundo real por meio de CD. Estas etapas podem ser vistas no fluxograma da Figura 2.1 que tem o objetivo de descrever de forma sistemática a aplicação dos conceitos em torno da CD. Inicialmente defini-se uma questão a ser respondida, e em seguida são levantadas perguntas em torno dessa questão com objetivo de traçar uma estratégia. Um processo de planejamento também pode ser utilizado corroborar com o desenvolvimento das estratégias. A coleta de dados pode ser incluída no processo de desenvolvimento das estratégias. Em alguns casos é necessário realizar um processo de adaptação na estrutura dos dados para um posterior processamento. Uma vez realizada a leitura e interpretação dos dados, diversas técnicas podem ser aplicadas com intuito de construir modelos e ferramentas para os mais variados propósitos.

Figura 2.1 - Fluxograma dos conceitos de ciência dos dados proposta por O'Neil e Schutt (2013).



Fonte: Adaptado de O'Neil e Schutt (2013).

O chamado Aprendizado de Máquina (em inglês, *Machine Learning* ou ML) é um ramo da engenharia e da ciência da computação que envolve questões relacionadas desde o reconhecimento de padrões até inteligência artificial. Diversas técnicas podem ser utilizadas para extração de informações em dados. Suas aplicações podem ser divididas em grupos, destacando-se: aprendizado supervisionado e não-supervisionado, e também o aprendizado por reforço. O primeiro dos grupos é o aprendizado supervisionado, nesta aplicação um modelo aprende a partir da análise de resultados previamente definidos. É feito um processamento que cria um fluxo de interações entre os dados de entrada e saída. Esta função realiza um chamado "treinamento", que recebe informações de entrada previamente rotuladas e a partir disso faz-se um mapeamento da correlação entre entrada e saída. No caso do aprendizado não-supervisionado, o conjunto de dados não apresenta nenhum tipo de rotulação ou classificação prévia. Objetivo deste aprendizado visa encontrar similaridades entre os objetos analisados, porém, aplica técnicas que buscam por padrões e anomalias que possibilitam a inferência de possíveis grupos nos dados. Por final, o aprendizado por reforço é caracterizado pela tentativa de aprendizado, onde a máquina busca pelas melhores ações a serem tomadas de acordo com as circunstâncias impostas (BISHOP, 2006; MONARD; BARANAUSKAS, 2003; DUDA et al., 2012).

O algoritmo desenvolvido neste trabalho utiliza aprendizado o não-supervisionado para identificar e classificar objetos meteorológicos (células de chuva/nuvem). O algoritmo para identificação dos objetos consiste no agrupamento (em inglês, *clustering*) de pontos relacionado a distribuição espacial dos valores de refletividade

(radar) e temperatura de brilho (satélite). O algoritmo DBSCAN foi utilizado para classificar células de chuva/nuvem de acordo com parâmetros pré-definidos, que serão discutidos na Seção 3.2.1.1. Uma abordagem mais direta sobre o método de clusteração será tratada na Seção 3.2.1.3. As demais técnicas utilizadas neste trabalho consistem na limiarização (Seção 3.2.1.2) e vetorização 3.2.1.4.

O fluxo de processamento do algoritmo emprega uma metodologia baseado na identificação de características morfológicas dos SCMs e células precipitantes, para em seguida aplicar técnicas de geoprocessamento para traçar a trajetória de deslocamento de células individuais. O conjunto de técnicas utilizadas neste trabalho tem como objetivo rastrear e prever os sistemas gerados de precipitação na região amazônica.

Com intuito de compreender as características físicas e dinâmicas dos sistemas atmosféricos atuantes na amazônia, e aplicar os conceitos sobre ciência de dados aqui abordados, discorre-se na próxima seção as principais peculiaridades dos sistemas geradores de precipitação na amazônia, ou seja, os objetos do rastreo.

## **2.2 Os objetos do rastreo: sistemas convectivos e a precipitação na região Amazônica**

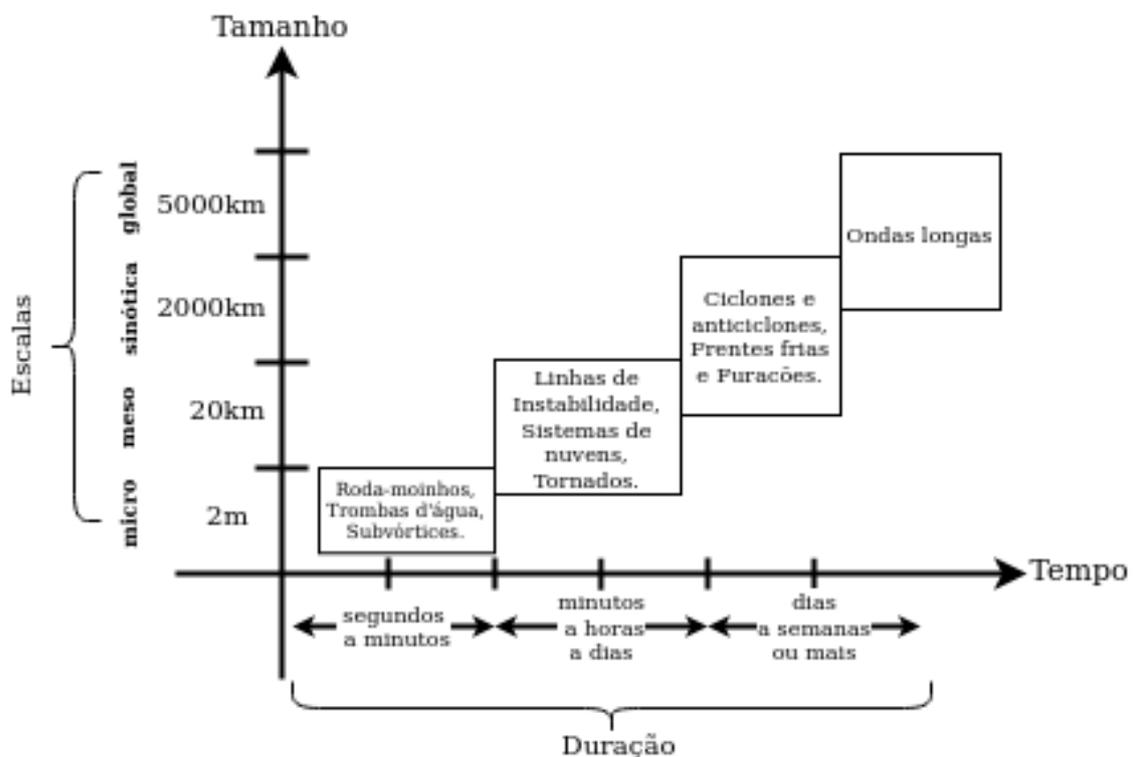
A técnica para rastrear células de chuva/nuvem utilizada neste trabalho, transmite a ideia de acompanhar a trajetória com base nas feições de contorno das células precipitantes e das nuvens associadas a SCM. Entretanto, mesmo sabendo que as métricas de rastreo tratam as células como objetos não-rígidos, faz-se necessário compreender que o alvo de rastreo possui processos dinâmicos e físicos distintos. Geralmente associados as características atmosféricas dos sistemas na região de estudo, neste caso a bacia Amazônica.

Na área de estudo deste trabalho encontra-se a maior floresta tropical úmida do planeta, a Amazônia. Com aproximadamente 7 milhões de quilômetros quadrados. A bacia do rio Amazonas é o principal sistema hidrográfico dessa floresta, e seus afluentes estão localizados nos dois hemisférios terrestres (norte e sul), percorrendo uma vasta região entre alguns países da América do Sul (Equador, Peru, Colômbia, Bolívia, Venezuela, Guiana, Suriname e Brasil). Uma das principais características relacionadas à Amazônia é o seu clima, predominantemente quente e úmido, ocasionados por uma alta disponibilidade de energia solar que incide sobre a região e grandes quantidade de vapor na atmosfera provenientes do oceano e por processos de evapotranspiração.

A energia que atinge a superfície terrestre é devolvida para a atmosfera na forma de fluxo de calor sensível (aquecimento) e latente (evapotranspiração). Desta forma, o balanço de energia e umidade interagem, sendo que o saldo de radiação é particionado em termos de calor sensível e/ou latente, dependendo das condições ambientais e de água no solo. (FISCH et al., 1998, p.4)

Os sistemas atmosféricos relacionados a precipitação na Amazônia são modulados por eventos em escalas micro, meso e sinótica (CORREIA et al., 2007). A Figura 2.2 exhibe os eventos e suas escalas correspondentes. Sistemas com dinâmica de modulação em microescala, com dimensão entre 1 metro à 1 quilometro, geralmente são base para estudos com objetivo de compreender a variabilidade de precipitação e suas relações com as demais escalas, exemplo: processos de formação das gotas de chuva, dispersão de poluentes e principalmente os processos de interações entre a floresta e atmosfera (CAVALCANTI, 2016).

Figura 2.2 - Escalas meteorológicas e suas extensões de duração e tamanho.



Fonte: Adaptado de Torn (2014).

Os Sistemas Convectivos são aglomerados de nuvens normalmente associados a fortes chuvas. Nas regiões tropicais, os SCs são fundamentalmente importantes devido a sua capacidade de transferência energética (FERREIRA, 2016). Uma vasta diversidade de condições relacionadas a dinâmica e microfísica dos SCs são os responsáveis pelas condições de desenvolvimento e ciclos de vida destes sistemas. Neste trabalho buscou-se associar as dinâmicas de propagação dos SCs a criação dos métodos de correção do deslocamento.

A precipitação em um SC pode ser classificada de acordo com a região de intensidade no seu interior, uma vez que características convectivas e estratiformes são encontradas nestes sistemas (HOUZE JUNIOR, 1997). Regiões com maior intensidade de precipitação, relacionadas a núcleos convectivos, são designadas como região convectiva. Já onde ocorre a precipitação mais fraca, em áreas estratificadas, denota-se como região estratiforme (HOUZE JUNIOR, 2004). Em maiores escalas espaciais e temporais, os SCs podem ser classificados com base na região em que sua iniciação ocorre. Sobre o continente sua designação é dada como sistemas continentais, e se sua fase de iniciação surge sobre o oceano, denomina-se como sistema oceânico (VELASCO; FRITSCH, 1987).

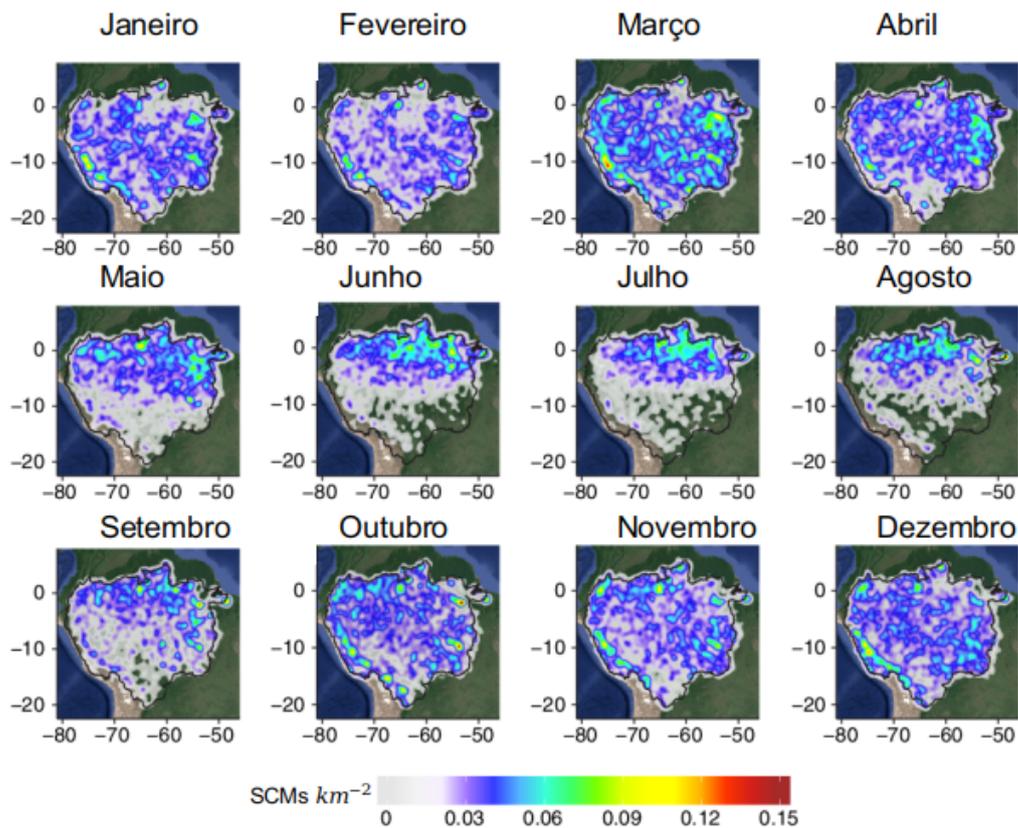
O processo para formação de um SC depende do movimento vertical do ar e áreas com maior flutuabilidade causadas pela estratificação termodinâmica, que são as responsáveis por gerar as regiões convectivas. Diversos fatores estão ligados a direção de movimento e propagação dos SCs, um desses é a dinâmica das ondas e fluxo ascendente, e devido a isto, novas células podem ser incorporadas a região convectiva, assim como podem gerar espontaneamente células no entorno das regiões estratiformes em desenvolvimento (HOUZE JUNIOR, 2004)).

A medida que esses sistemas se organizam e crescem, adquirindo características de mesoescala, sua severidade pode aumentar ainda mais, podendo ser denominados como Sistemas Convectivos de Mesoescala (SCM). Os SCMs ocorrem entre os trópicos e latitudes médias, e são responsáveis por ocasionar tempestades convectivas de longa duração (HOUZE JUNIOR, 2004). De acordo com Williams e Houze Junior (1987) o deslocamento dos SCMs é geralmente lento e pode gerar grandes volumes de precipitação, assim como pode apresentar ventos fortes (ascendentes e descendentes).

Os SCMs possuem extensões de 20 à 200 km. Na Amazônia a maturação de SCMs de curta duração pode levar em média de 2 à 3 horas, em alguns casos, sistemas maiores podem ter seu ciclo de duração de 5 à 6 horas (MACHADO et al., 1998; REH-

BEIN; AMBRIZZI, 2016). Os SCMs representam as maiores tempestades convectivas existentes (HOUBE JUNIOR, 2014). Além disto, estes sistemas são responsáveis pelas maiores quantidades de precipitação sobre os trópicos e regiões de latitudes médias na parte continental. O Desenvolvimento dos SCMs sobre a bacia Amazônica foi abordado no trabalho de (REHBEIN et al., 2018), onde foi feita uma análise para os períodos entre os anos 2000 à 2013. No mesmo estudo, a autora notou que os SCMs de curta duração entre Janeiro e Abril foram mais espalhados sobre a bacia Amazônica, na Figura 2.3 são apresentadas a distribuição de densidade e gênese dos SCMs. Rehbein et al. (2018) concluiu que na região central para o sul e por toda a faixa a oeste, houve pouca atividade nos meses de inverno, e em setembro a gênese dos SCMs voltou para parte sul da bacia, porém com menor densidade.

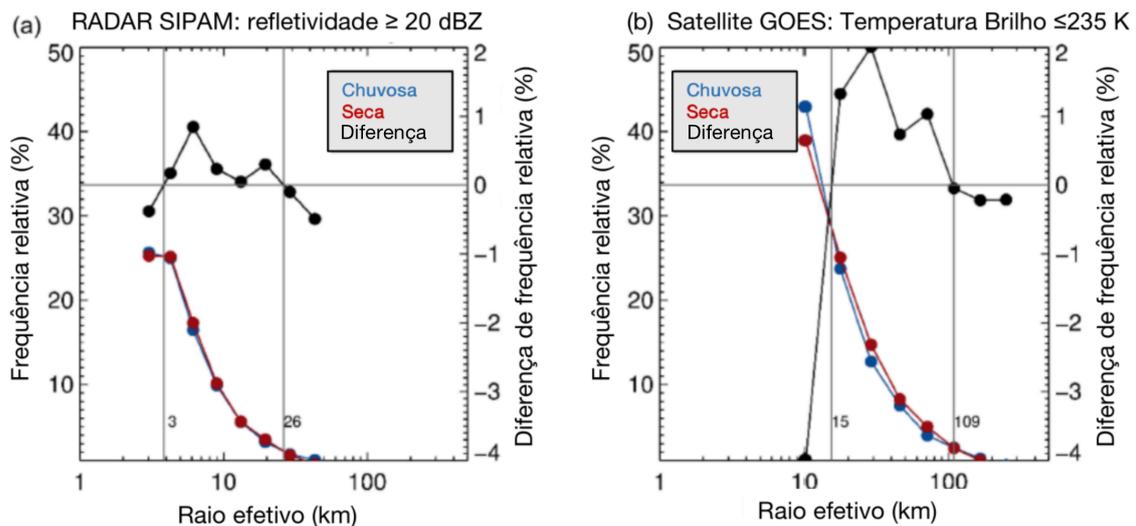
Figura 2.3 - Densidade da gênese dos SCMs sobre a bacia Amazônica entre os anos 2000 e 2013.



Fonte: Adaptado de Rehbein et al. (2018).

Estudos mais recentes sobre os SCMs feitos por Machado et al. (2018), utilizaram informações do canal infravermelho do satélite GOES-13 e valores de refletividade do radar meteorológico sobre a região de Manaus-AM. Neste estudo foi utilizado o algoritmo ForTraCC (VILA et al., 2008) para rastrear o desenvolvimento dos *clusters* de nuvens em dois períodos distintos (estação seca e chuvosa). Nesse estudo, foram utilizados os parâmetros de refletividade de  $\geq 20$  dBZ no CAPPI (sigla em português para, Indicador de posição do plano de altitude, do inglês, *Constant Altitude Plan Position Indicator*) em 2,5 km para o radar e temperatura de brilho  $\leq 235$  K para o satélite. Um dos resultados (Figura 2.4) mostra que os *clusters* de nuvens na estação seca e úmida junto a distribuição do tamanho das células possuem diferentes distribuições. Essas diferenças mostram que os sistemas durante a estação mais seca são mais intensos e geram chuvas mais fortes, apesar de serem menos frequentes.

Figura 2.4 - (a) Distribuição do tamanho das células de chuva com base no Radar SIPAM de Banda - S para estações seca e chuvosa; (b) Distribuição do tamanho das células de chuva com base no Satélite GOES, para estações seca e chuvosa.



Fonte: Adaptado de Machado et al. (2018).

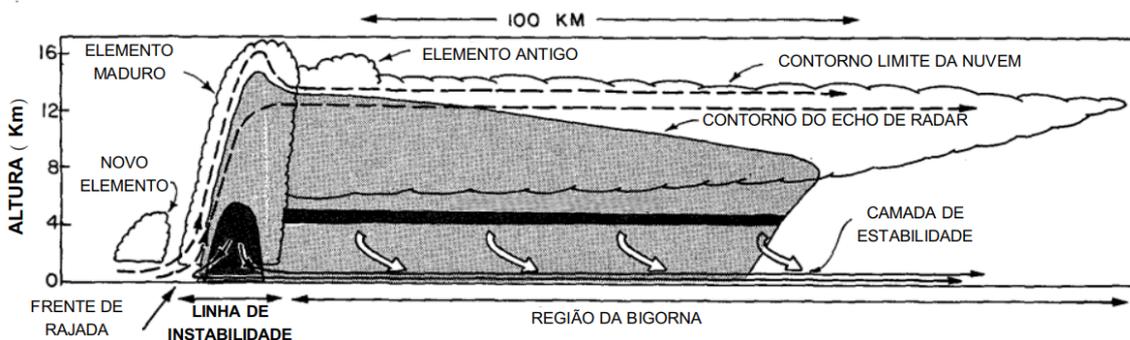
As Linhas de Instabilidade (LI) são sistemas de mesoescala atuantes na bacia amazônica, estes sistemas são responsáveis por um número significativo de tempestades e formam-se principalmente na região costeira nordeste da América do Sul. As LIs propagam-se para o interior do continente com velocidades médias de 45-55 km/h

(KOUSKY, 1980; MOLION, 1987), e possuem estruturas convectivas com uma complexa dinâmica de propagação. Seu deslocamento acaba provocando o desenvolvimento de múltiplos sistemas no decorrer de seu ciclo de vida, onde uma parcela dessas estruturas são impulsionadas a frente das tempestades a partir de um mecanismo conhecido como frentes de rajada (*gust front*, em inglês) (GAMACHE; HOUZE JUNIOR, 1982).

Na Amazônia, as LI são responsáveis pela formação de grande parte dos eventos de precipitação próximo ao litoral dos estados do Pará e Amapá. Nas estações de seca esses sistemas podem propagar-se por maiores extensões, chegando até a parte central da bacia Amazônica (MOLION, 1987; COHEN et al., 1989). Em Greco et al. (1990) foram utilizadas imagens de satélites para diversos estudos, e descobriu-se que as LI costeiras em geral possuem comprimento que podem variar entre 1000 à 2000 km, e em alguns casos estes eventos podem ultrapassar 3500 km de comprimento.

As estruturas dinâmicas e termodinâmicas presentes nas LI foram descritas por diversos autores (NEWTON, 1950; CHALON et al., 1988; HOUZE JUNIOR, 2014). No geral as LIs em tempestades multicelulares são compostas por uma linha de torres de nuvens do tipo Cbs em diferentes níveis de maturação, seguida por uma região posterior com características estratiformes, como pode ser visto na Figura 2.5. De acordo com Houze Junior (1997) embora as LI estejam associadas com a presença de convecção madura, estes sistemas podem apresentar uma vasta área estratiforme, ou seja, nuvens com grande desenvolvimento horizontal e de baixo potencial precipitante.

Figura 2.5 - Seção transversal esquemática de uma LI pelo echo radar.



Fonte: Adaptado de Houze Junior (1977).

O surgimento das células convectivas em uma LI está associado ao levantamento vertical de massas de ar em um ambiente termodinamicamente estratificado (HOUZE JUNIOR, 1997). O desenvolvimento das LI está associado a presença de instabilidade termodinâmica e de cisalhamento vertical do vento em baixos níveis (NEWTON; NEWTON, 1959). No geral a propagação das LIs sobre a Amazônia ocorre com velocidade média entre 43 à 57  $km.h^{-1}$  (GARSTANG et al., 1994; PEREIRA FILHO et al., 2015). Durante a propagação e desenvolvimento, as estruturas convectivas das LIs apresentam uma alta dinâmica de movimento entre suas áreas de convergência, e com isso podem ocorrer o surgimento de novos sistemas convectivos no seu entorno, e células convectivas mais antigas são espalhadas para sua retaguarda (GAMACHE; HOUZE JUNIOR, 1982). Estes sistemas costumam possuir um tempo de vida mais longo se comparados ao tempo de vida de suas células convectivas. Segundo Greco et al. (1990) o tempo de vida destes sistemas está entre 24 à 48 horas de duração. Já Houze Junior (2014) aborda que as LIs podem possuir ciclos de vida com até 72 horas.

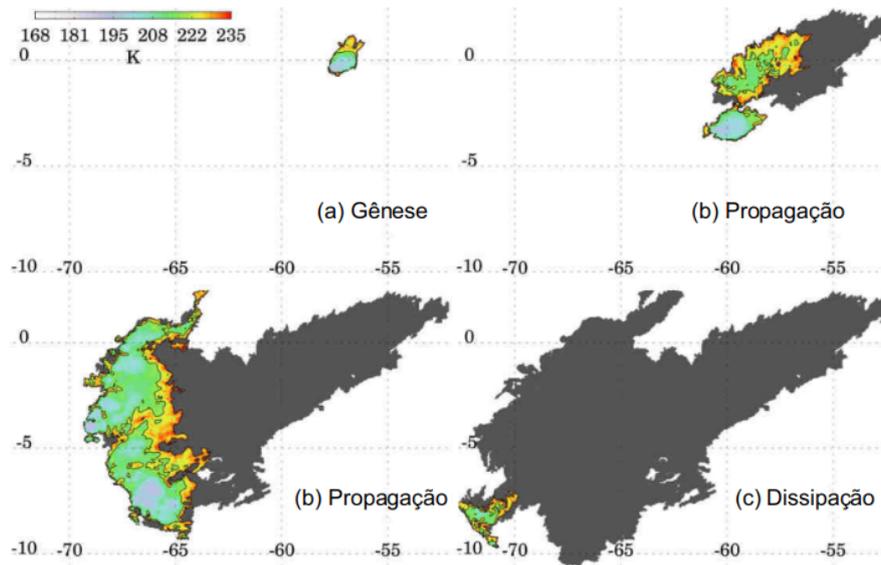
Na Figura 2.6 é ilustrado o processo de desenvolvimento e a trajetória (cor cinza) de um SCM rastreado a partir de um algoritmo desenvolvido por Anselmo et al. (2019). No mesmo trabalho, são abordadas as características de desenvolvimento dos SCs rastreados por meio de dados de satélite na Amazônia dentro do mesmo período de análise desta pesquisa, o projeto GoAmazon. Sistemas como estes apresentam ciclo de vida complexos (KESSLER, 1982; BROWNING, 1986), onde é possível notar a junção de áreas precipitantes e a divisão de células convectivas associados a vários núcleos embebidos em áreas estratiformes (parte cinza da figura). Contudo, o objeto deste trabalho não são apenas as LIs, mas todos os sistemas que podem gerar precipitação, atendendo a um certo critério de tamanho, como será verificados na metodologia e resultados. Desde sistemas puramente estratiformes, a células convectivas isoladas e grande sistemas de mesoescala (ANSELMO et al., 2021).

Na próxima seção será apresentada uma abordagem geral sobre os algoritmos desenvolvidos para rastreamento e previsão de sistemas semelhantes a estes aqui apresentados.

### **2.3 O rastreamento de fenômenos meteorológicos**

Muitos trabalhos focaram no rastreamento de um tipo específico de fenômeno meteorológico, as tempestades. O uso de ferramentas computacionais para detecção e rastreamento automático de células de tempestades fornece diversas informações para estudos sobre a dinâmica destes eventos. Crane (1979) desenvolveram um algoritmo capaz de identificar e rastrear células de tempestades automaticamente. No mesmo trabalho,

Figura 2.6 - Estágios de desenvolvimento de um SC rastreado por um algoritmo sobre a Amazônia, com informações do canal infravermelho do satélite GOES-13.



Fonte: Adaptado de Anselmo et al. (2019).

foram utilizadas técnicas baseadas no limiar de contorno de células convectivas a partir dos valores de refletividade radar, e a partir deste limiar, extraiu-se os atributos morfológicos para rastrear o movimento das células de tempestuosas.

Seguindo a metodologia de detecção automática de tempestades baseado em dados de radar, o algoritmo TITAN (abreviação em inglês para *Thunderstorm Identification, Tracking, Analysis and Nowcasting*, traduzido para português como identificação, rastreamento, análise e previsão em curtíssimo prazo) desenvolvido por (DIXON; WIENER, 1993) do Centro Nacional de Pesquisas Atmosféricas nos Estados Unidos da América (NCAR, abreviação em inglês para *National Center for Atmospheric Research*) é um sistema bastante utilizado para estudos relacionados ao deslocamento de tempestades. Atualmente seus módulos suportam dados provenientes de multiplataformas como satélites, sensores de raios, estações de superfície e modelos numéricos de previsão de tempo.

Para estimar a trajetória e o ciclo de vida dos Sistemas Convectivos de Mesoescala (SCM), o algoritmo ForTraCC (em inglês, *Forecast and Tracking the Evolution of Cloud Clusters*), desenvolvido por Vila et al. (2008) rastreia esses fenômenos através de dados de satélite (no canal infravermelho - 10.8  $\mu\text{m}$ ). O ForTraCC processa

informações sobre as características físicas e morfológicas dos SCMs que são identificados a partir dos limiares de temperatura do topo das nuvens. O algoritmo define um centro de massa com base na análise dos *píxeis* classificados por um limiar de temperatura igual ou menor que 235 K (adaptável), em seguida utilizando a sobreposição de imagens sucessivas, o ForTraCC faz a estimativa de trajetória e desenvolvimento dos SCMs de forma individual ou baseado na circunvizinhança.

Outra abordagem bem conhecida para a identificação e rastreamento de tempestades é o algoritmo SCIT (abreviação em inglês, *Storm Cell Identification and Tracking*, traduzido para português como identificação e rastreamento de células de tempestade), desenvolvido por Johnson et al. (1998). Este algoritmo faz a identificação tri-dimensional de tempestades e as processa em módulos de maneira uni-dimensional. Sua métrica de rastreamento é baseada no centroide das células convectivas identificadas pelos limiares de refletividade. O SCIT é a base para o WSR-88D (abreviação em inglês de, *Weather Surveillance Radar 1988 Doppler*, em português, Radar Doppler De vigilância meteorológica 1988). O conjunto entre o SCIT e WSR-88D fazem parte do sistema NEXRAD (abreviação em inglês, *Next-Generation Radar*). A NEXRAD é uma rede de 158 radares doppler de alta resolução operados pelo Serviço Nacional de Meteorologia dos Estados Unidos para monitoramento de tempestades (ATLAS, 2015).

Um método, relativamente mais recente, para identificação e rastreamento baseado no algoritmo SCIT é apresentado por Matthews e Trostel (2010). Nesta nova abordagem, o algoritmo é introduzido ao método de agrupamento não supervisionado DBSCAN e cada célula de tempestade é identificada a partir de multi-limias. Além disso, o algoritmo permite a associação das células de tempestades a outros fenômenos meteorológicos, como raios e tornados. Um esquema de associação probabilística é introduzido para associar as células de tempestade em diferentes tempos de observação.

Identificar e rastrear o deslocamento de tempestades é uma tarefa que demanda um certo conhecimento relacionado aos seus aspectos físicos. Sensores como satélites e radares meteorológicos observam o comportamento da atmosfera e podem ser utilizados para registrar tempestades severas. O registro destes fenômenos pode ser utilizado para estimar o comportamento, trajetória e o ciclo de vida das tempestades. Os dados observacionais relacionados ao deslocamento de uma tempestade, em sua grande maioria, são armazenados no formato de imagens ou matrizes. As informações registradas por estes sensores podem ser utilizadas para identificar a dinâmica

relacionada as interações entre células tempestuosas. A análise da cinemática dos eventos de células de tempestades pode ser usada para compreender seu comportamento ao longo do seu ciclo de vida em diferentes regiões do globo (EICHHOLZ, 2017). Tais estudos são de suma importância na criação de um sistema de *nowcasting*. Onde conhecer as características da região pode se um fator decisivo na resposta a eventos mais severos.

Usuários de sistemas de previsão à curto prazo normalmente necessitam de informações em tempo quase real, isto porque uma avaliação rápida é necessária para tomadas de decisão em tempo hábil (WMO, 2017). Neste sentido, o tempo para processamento de informações dos modelos de previsão à curtíssimo prazo é bastante limitado, o que pode ser um problema para prever eventos com potencial de dano a sociedade. Para resolver isso, algumas alternativas podem ser utilizadas com intuito de prever o deslocamento de tempestade com um menor custo de processamento e menor tempo. Dentre as alternativas para realizar previsões em curto prazo incluem-se os algoritmos baseados em lógica difusa (em inglês, *Fuzzy logic*. O *NowCastMIX* (JAMES et al., 2018) é um sistema de orientação para previsões em curto prazo utilizado pelo serviço meteorológico Alemão. Este algoritmo monitora automaticamente diversos sistemas que capturam eventos convectivos de mesoescala com potencial de alto impacto e rápido desenvolvimento. Baseado em lógica difusa o algoritmo desenvolvido por James et al. (2018) faz a categorização dos eventos e aplica métricas de extrapolação em células precipitantes detectadas via radar meteorológico. O rastreamento das células convectivas é feito por meio de dois processos de identificação (clusterização e geração de polígonos), permitindo que células individuais sejam rastreadas e previstas.

Outra alternativa para rastrear eventos meteorológicos em curtíssimo prazo é por meio de técnicas aprendizado de máquina. Estas técnicas são uma boa alternativa para auxiliar em previsões onde o tempo para tomada de decisões é reduzido, e também não requer alta capacidade computacional para realizar previsões. A partir de modelos criados previamente por algoritmos de aprendizado de máquina, as estruturas presentes em SCMs ou sistemas precipitantes podem ser identificadas e previstas.

Em Su et al. (2020) um algoritmo baseado em aprendizado de máquina foi desenvolvido para rastrear sistemas convectivos. O algoritmo de Su et al. (2020) faz a identificação do campo vetorial por meio da técnica de fluxo óptico (em inglês, *optical flow*), em seguida as informações de cada píxel são inseridas em uma rede neu-

ral de aprendizado profundo, do tipo ConvLSTM (em inglês, *Convolutional Long Short-Term Memory*). A rede de neural do algoritmo (SU et al., 2020) é treinada para abstrair características dinâmicas como rotação, convergência e divergências no campo vetorial abstraído do fluxo óptico. A partir do modelo gerado pelo treinamento que combina duas técnicas de aprendizado de máquina, que são as redes convolucionais (Conv) para identificação das características, e as redes de memória a curto prazo LSTM (em inglês, *Long Short Term Memory*) para previsão, o algoritmo desenvolvido em Su et al. (2020) demonstra a aplicabilidade de novas abordagens para previsão em curtíssimo prazo.

Baseado na combinação de alternativas para previsão em curtíssimo prazo, nesta pesquisa apresenta-se uma mistura de técnicas que partem de metodologias mais tradicionais, até métodos mais atuais aplicadas. Para uma boa compreensão das técnicas utilizadas neste trabalho, veremos sobre as principais questões em torno da identificação e rastreamento dos sistemas convectivos e precipitantes. A dinâmica de propagação e o próprio comportamento das células de tempestade remete a um problema encontrado no rastreamento de objetos não-rígidos. Segundo Aggarwal et al. (1994, p. 2) o movimento de objetos não-rígidos pode ser classificado em três grupos: movimento de partes rígidas, movimento de objetos coerentes e movimento de fluídos. No mesmo trabalho, Aggarwal et al. (1994) demonstraram exemplos e aplicações, por meio de uma revisão dos métodos e modelos que podem ser aplicados para resolução de problemas relacionados ao rastreamento deste tipo de objeto.

Algoritmos com propósitos de rastrear objetos em imagens são problemas amplamente estudados, as principais abordagens que definem questões relacionadas ao rastreamento podem ser classificadas em três categorias segundo Yilmaz et al. (2006, p.16), sendo:

- (a) O rastreamento por pontos: Utilizam informações baseadas em estados anteriores para determinar a posição e movimento de um objeto. Esta abordagem necessita de mecanismos mais complexos para detectar objetos em imagens consecutivas. Os principais métodos são: Filtro de Kalman (KALMAN, 1960); *Joint probabilistic data-association filter* (JPDAF) (BAR-SHALOM et al., 1990); e o Rastreador probabilístico de múltiplas hipóteses (em inglês, *The probabilistic multi-hypothesis tracker*) (STREIT; LUGINBUHL, 1994).
- (b) Rastreamento por densidades: Os métodos baseados em densidade possuem associação com a forma e aparência do alvo. Neste modelo utiliza-se o histograma de densidades como métrica de rastreamento para determinar o mo-

vimento de objetos. Os principais métodos são: *Mean Shift* (COMANICIU et al., 2003); Rastreador de recursos Kanade–Lucas–Tomas (KLT) (SHI et al., 1994); e o Rastreador de Eigen (em inglês, *Eigentracking*) (BLACK; JEPSON, 1998).

- (c) Rastreio baseado na silhueta (em inglês, *Shape-based*): Nesta abordagem é utilizada a região da borda de objetos para cada imagem. Informações sobre os limites exteriores são codificados com o intuito de determinar o deslocamento dos objetos entre imagens consecutivas. As principais técnicas são: Métodos de Hausdorff (HAUSDORFF, 1991) e Heurística baseada em contorno ativo (em inglês, *Heuristic active contour models*) (RONFARD, 1994).

A abordagem aplicada neste trabalho optou pelo rastreio baseado na silhueta de células de chuva e nuvem. Este método utiliza regiões previamente identificadas por uma técnica de segmentação para determinar o contorno de células precipitantes e nuvens. A correlação entre as feições de contorno das células é feita por meio de operações espaciais de sobreposição entre tempos consecutivos. A trajetória é extraída a partir da junção dos centroides de cada geometria. Maiores detalhes serão dados no capítulo de metodologia.

Logo, levando em consideração os temas abordados no referencial teórico deste trabalho, apresenta-se uma abordagem para rastreio e previsão de *clusters* de chuva e nuvem sobre a região da bacia amazônica. Nas seções seguintes serão descritos os dados utilizados nesta pesquisa, bem como as técnicas utilizadas para identificação, rastreio e previsão de *clusters* precipitantes e nuvens de SCM via dados de radar e satélite, respectivamente.

### 3 DADOS E METODOLOGIA

Neste capítulo são apresentados procedimentos metodológicos desenvolvidos para rastreamento dos fenômenos meteorológicos. Na Seção 3.1 são descritos os dados utilizados. Em seguida, a seção metodologia 3.2 discorre sobre os procedimentos realizados para desenvolvimento do algoritmo de rastreamento 3.2.1, questões relacionadas às técnicas utilizadas para identificação e acompanhamento dos sistemas 3.2.2, além da validação das técnicas utilizadas 3.3.1.5.

#### 3.1 Dados

Nesta seção são apresentados detalhes relacionados à origem dos dados e suas descrições técnicas em geral. Dentre os dados utilizados estão as observações volumétricas do radar meteorológico do SIPAM e dados do imageador infravermelho do satélite GOES-13. Os períodos de observação de maior intensidade durante o projeto GoAmazon denotados como IOP (acrônimo em inglês, *Intense Observing Period*), foram aqueles onde aconteceram as medidas com menor latência e maior densidade instrumental. Tomando proveito deste período, selecionamos os dados de radar e satélite para analisar as características dos sistemas atmosféricos em diferentes ocasiões no ano de 2014 sobre a região da bacia Amazônica.

Os IOPs foram divididos em dois períodos de observações. O primeiro destes (IOP1), corresponde às observações entre os dias 01 de Fevereiro à 31 de Março de 2014 (*59 dias de observações*). Já o segundo período (IOP2), representa observações do 15 de Setembro à 15 de Outubro (*61 dias de observações*). Estes períodos estão relacionados ao final da estação chuvosa na Amazônia (IOP1) e a estação seca (IOP2) (NOBRE et al., 2009).

##### 3.1.1 Radar

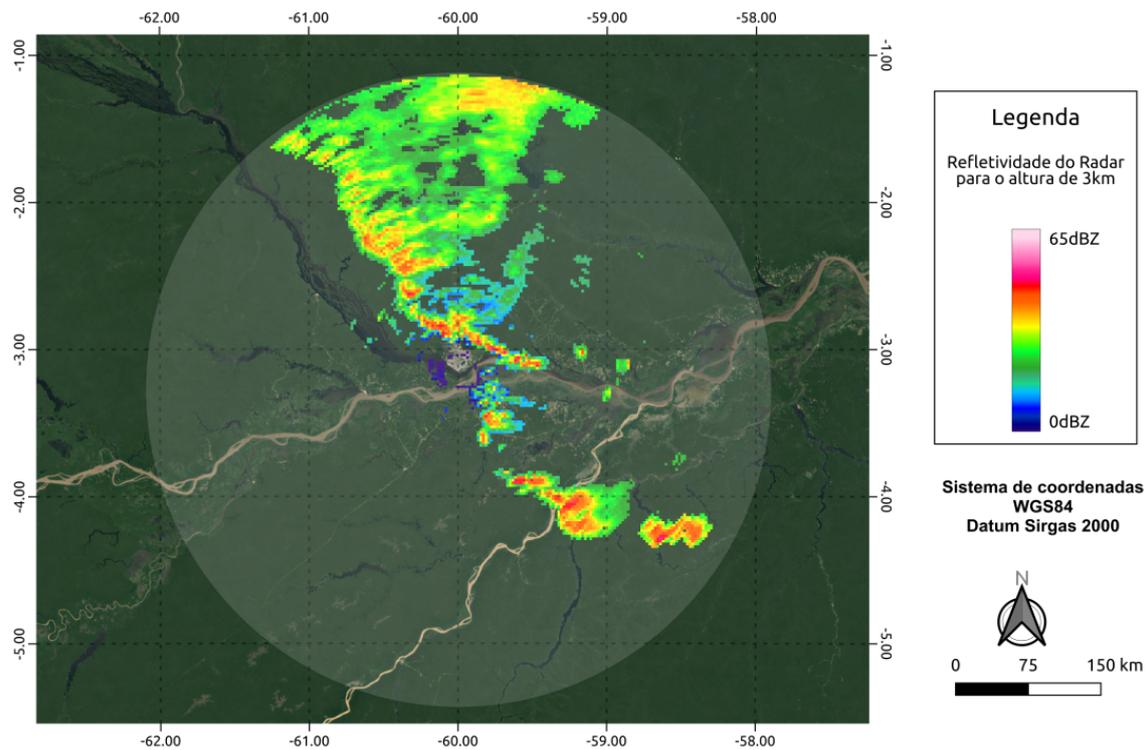
O radar de banda S do SIPAM (sigla para, Sistema de Proteção da Amazônia)<sup>1</sup> está localizado em Manaus-AM, e foi utilizado durante o período das campanhas do GoAmazon para medir estimativas de taxa de precipitação a partir dos dados de refletividade radar. Os dados deste experimento foram processados, corrigidos e disponibilizados na plataforma ARM (sigla em inglês, *The Atmospheric Radiation Measurement*) no link: [https://iop.archive.arm.gov/arm-iop/2014/mao/goamazon/T1/schumacher-sband\\_rr/](https://iop.archive.arm.gov/arm-iop/2014/mao/goamazon/T1/schumacher-sband_rr/). As varreduras feitas pelo radar correspondem à uma região de aproximadamente  $\sim 150,333 \text{ km}^2$ , sua localização está nas

---

<sup>1</sup>SIPAM - <http://www.sipam.gov.br/noticias/apresentacao-do-censipam>

coordenadas 3,15°S 60°O no destacamento de controle do espaço aéreo de Manaus - AM. Na Figura 3.1 exibe-se um exemplo de uma varredura feita pelo radar no CAPPI 2.2 3 km.

Figura 3.1 - Área de cobertura do Radar do SIPAM localizado na região de Manaus-AM.



Fonte: Produção do autor.

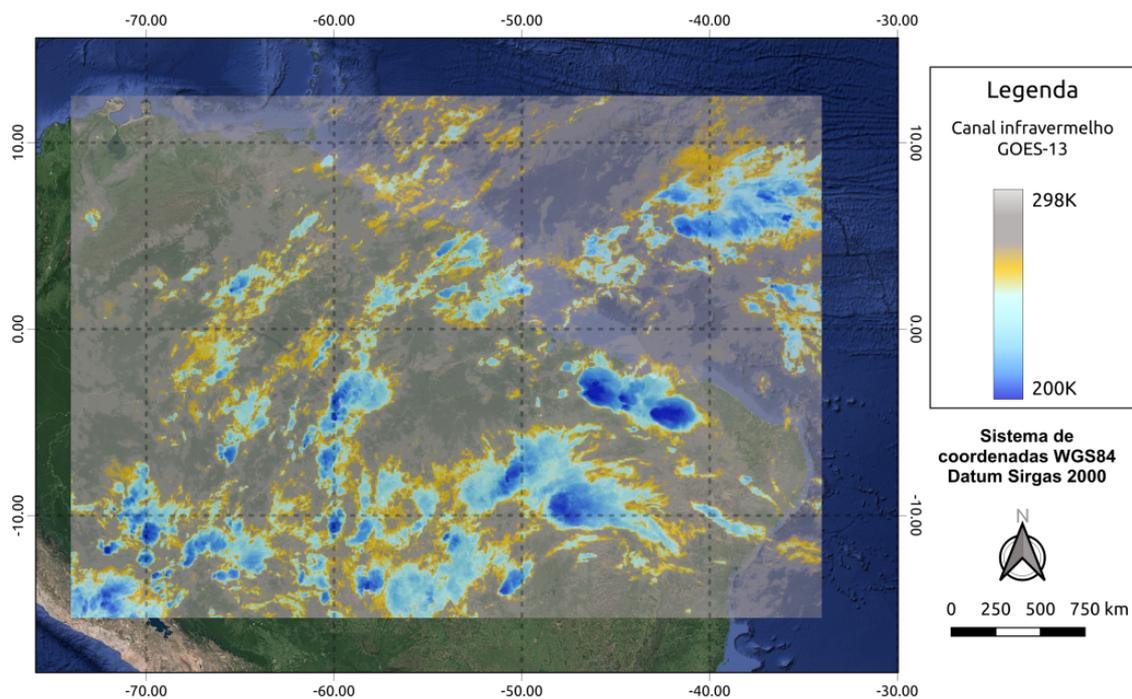
O produto CAPPI 2.2 utilizado corresponde a varreduras volumétricas referentes à altitude de 3 km. Este nível foi escolhido devido a sua melhor representatividade da chuva observada em superfície. Além disso, é possível acompanhar de modo fidedigno o desenvolvimento e propagação da precipitação dos SCMs na região Amazônica, como vistos na Seção 2.2. O intervalo de tempo entre as varreduras do radar é de 12 minutos. Os dados foram processados e passaram por um algoritmo de controle de qualidade desenvolvido por Schumacher e Funk (2018) com intuito de remover anomalias relacionadas a ruídos de solo, falta de amostragens, problemas relacionados a antena do radar e etc. No geral os dados estão dispostos da seguinte forma:

- Dimensões gerais:  $X = 241$ ,  $Y = 241$ ,  $Z = 40$ .
- Resolução espacial: 2 km.
- Dimensão Z: Correspondente aos 40 níveis de observações, cada um com 0,5 km.
- Intervalo de observações: 12 min.
- Longitude do radar: -59,9920.
- Latitude do radar: -3,1493.
- Raio do radar: 240 km.
- Nome da variável: dBZc.
- Tipo de projeção: Azimutal equidistante.
- Sistema de coordenada: WGS84.

### 3.1.2 Satélite

Os dados de satélite utilizados são do GOES-13, referentes aos períodos do IOP1 e IOP2. Estes dados correspondem ao canal infravermelho ( $10.2 \mu\text{m}$ ) com informações associadas a Temperatura de Brilho  $T_b$  no topo das nuvens. Os dados estão disponíveis no formato binário no repositório do INPE no link: <http://ftp.cptec.inpe.br/goes/goes13/>. A resolução temporal dos dados correspondem a observações em intervalos de 30 minutos. Um pré-processamento foi realizado nos dados com intuito de padronizar as entradas para o algoritmo de rastreamento. Neste pré-processamento foram gerados arquivos no formato netCDF com estrutura baseada nos dados do radar meteorológico como visto na Seção anterior 3.1.1. Um recorte que corresponde a porção continental da América do Sul cobrindo a região da bacia Amazônica foi gerado neste pré-processamento, como pode ser visualizado no exemplo da Figura (3.2).

Figura 3.2 - Área para os dados pré-processados correspondentes à cobertura da bacia Amazônica com o satélite GOES-13.



Fonte: Produção do autor.

Outras informações sobre os dados de satélite podem ser notadas abaixo.

- Dimensões gerais:  $X = 1000$ ,  $Y = 700$ ,  $Z = 1$ .
- Resolução espacial: 4 km.
- Dimensão Z: Nível correspondente ao topo das nuvens  $\sim 10$  km.
- Intervalo de observações: 30 min.
- Longitude: Min (-73,994), Max (-34,057).
- Latitude: Min (-15,479), Max (12,494).
- Nome da variável: TEMP.
- Tipo de projeção: Azimutal equidistante.
- Sistema de coordenada: WGS84.

## 3.2 Metodologia

Neste capítulo é apresentado todo o processo de desenvolvimento do novo algoritmo para rastreamento e previsão das células de chuva e nuvens. Cada tópico faz o levantamento dos temas e requisitos utilizados neste trabalho, partindo da leitura dos dados, processamento baseado nos parâmetros de rastreamento, clusterização, vetorização, rastreamento da trajetória, metodologias para correções vetorial e técnicas de extrapolação temporal dos vetores (previsão). Os procedimentos aplicados neste algoritmo foram baseados em técnicas bastante difundidas, porém, buscou-se aplicar melhorias, sinergias e correções com intuito de aprimorar as métricas de rastreamento baseadas no centroide das células de chuva e nuvem.

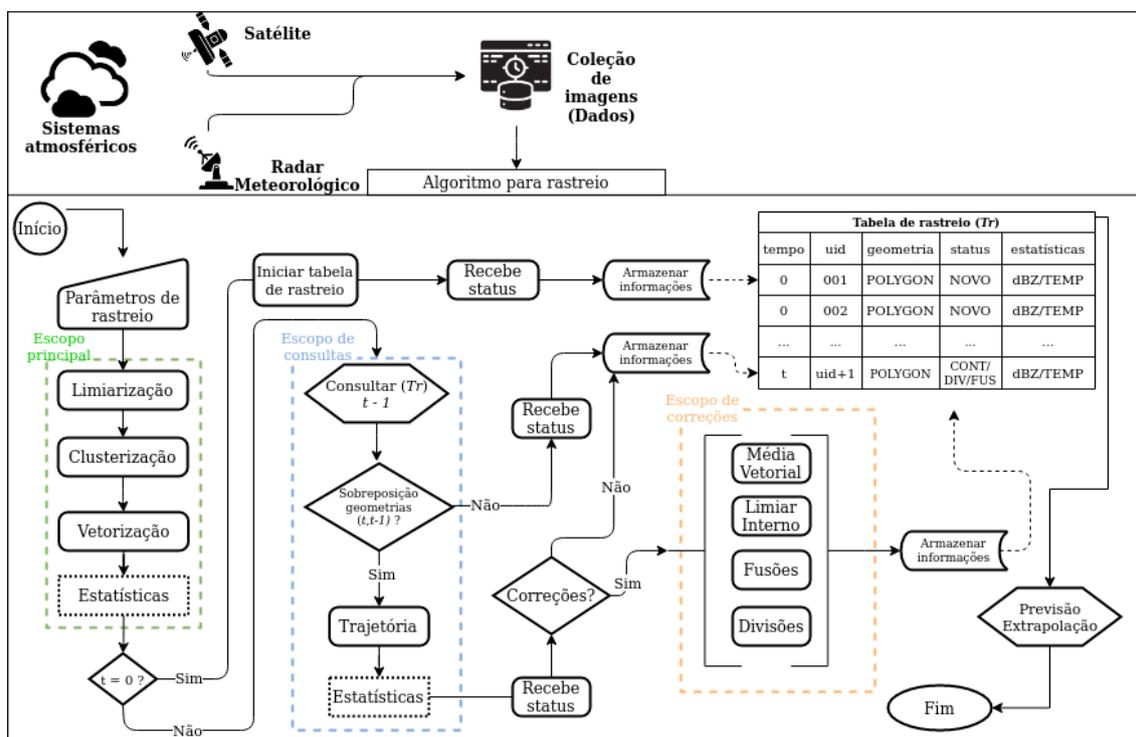
### 3.2.1 O algoritmo de rastreamento e previsão

Algoritmos com propósito de rastrear objetos geralmente são problemas computacionais bastante desafiadores. Não existem soluções unificadas para rastreamento de células de chuva ou nuvens, pois diferentes abordagens podem ser utilizadas com o mesmo propósito. Neste trabalho, foram utilizadas técnicas baseadas no centroide de células como o parâmetro para definir sua trajetória de deslocamento. As técnicas baseadas no centroide são bastante eficientes para identificar a trajetória de objetos com formato rígidos, ou seja, em imagens consecutivas o objeto permanece com as mesmas feições. Porém, células de chuva e nuvem possuem uma dinâmica de movimento, expansão, retração, eventos de fusões e divisões entre células com uma frequência elevada, o que implica em diversas incertezas para determinar uma trajetória correta. Para contornar ou mitigar estes problemas, foi desenvolvido um algoritmo (Figura 3.3) que aplica diferentes abordagens com objetivo de reduzir as incertezas, principalmente sobre o regime de chuva e nuvens na região Amazônica.

O algoritmo deste trabalho tem como objetivo identificar, rastrear e prever o movimento das células associadas à chuva e nuvens. Para isso, diferentes estágios de processamento foram desenvolvidos, onde, uma combinação de processos tem como saída uma Tabela de Rastreamento *Tr*. Nesta tabela são armazenadas as informações sobre as trajetórias das células de chuva ou nuvem. Os processos utilizados pelo algoritmo foram divididos em processos que aplicam diferentes abordagens, cada um destes serão apresentados nas Seções 3.2.1.1, 3.2.1.2, 3.2.1.3, 3.2.1.4, 3.2.1.5, 3.2.2, 3.3.1.

A linguagem de programação para desenvolvimento do algoritmo foi Python na versão 3.7. Bastante difundida e com diversas bibliotecas, o Python permite a operaci-

Figura 3.3 - Fluxograma do algoritmo.



Fonte: Produção do autor.

análise dos processos de forma escalável, ou seja, o desenvolvimento dos processos deste algoritmo foram divididos em módulos. Cada um destes módulos processa o fluxo de dados e ao final adiciona informações relacionadas ao rastreamento das células de chuva/nuvens a uma saída ( $Tr$ ).

### 3.2.1.1 Parâmetros de rastreamento

Os parâmetros de rastreamento são informações utilizadas pelo algoritmo em suas rotinas de processamento. Estas informações podem ser ajustadas de acordo com as características dos estudos desejados. Neste trabalho, os parâmetros foram ajustados para a identificação e rastreamento de chuva ou nuvens nos dois períodos de observação (IOP1 e IOP2) para os dados de radar e satélite meteorológicos. Para selecionar os parâmetros de rastreamento mais adequados, levou-se em consideração estudos de sensibilidade relacionados sobre a propagação de células de chuva e nuvens sobre a região da bacia Amazônica. As definições dos parâmetros aos limiares iniciais estão

descritas nas Tabelas 3.1 e 3.2. Note que as referências aqui utilizadas definem o que seriam os limiares iniciais de rastreamento. No caso do radar, uma célula de chuva com 20 dBZ, se convertido em precipitação por uma relação ZR de Marshall-Palmer (MARSHALL; PALMER, 1948), está associado a uma taxa de precipitação de  $\sim 0,5$  mm/h, considerada uma chuva fraca. Enquanto que o limiar de 235 K, associado a nuvens em SCM, está relacionado a eventos mais intensos. Logo, cabe ressaltar que ambos podem rastrear sistemas meteorológicos bem diferentes, não correlacionados. No entanto, correções foram realizadas no intuito de englobar também eventos severos nos dados de radar, como veremos nas seções posteriores, e estes sim podem estar ligados aqueles rastreados via satélite. Contudo, este algoritmo não utiliza as duas fontes de dados ao mesmo tempo, mas modificações podem ser inseridas para tal propósito.

Tabela 3.1 - Limiares utilizados por outros autores.

Sensor	Limiar	Referências
Radar	$\geq 20$ dBZ	(EICHHOLZ, 2017; KOBER; TAFFERNER, 2009), (REHBEIN et al., 2018; MACHADO et al., 2018)
Satélite	$\leq 235$ K	(MACHADO et al., 2002; VILA et al., 2008), (KOBER; TAFFERNER, 2009; MACHADO et al., 2018)

Fonte: Produção do Autor.

Os principais identificadores de parâmetros de rastreamento dentro do algoritmo:

- **START**: Define o tempo inicial do rastreamento.
- **END**: Define o tempo final do rastreamento.
- **INT**: Define o intervalo entre as observações.
- **VAR**: Nome da variável presente no arquivo netCDF.
- **THR**: Limiares para rastreamento.
- **AREA**: Número mínimo de pixels em um cluster.
- **OVRLP**: Porcentagem de sobreposição mínima entre polígonos.
- **EPS**: Parâmetro de distância que define o tamanho do raio para o algoritmo de clusterização.
- **FLAG**: Parâmetros baseadas nos métodos de correção vetorial 3.3.1.

Tabela 3.2 - Parâmetros de rastreo do algoritmo para análise dos períodos de observação (IOP1 e IOP2).

<b>NOME</b>	<b>START_TIME</b>	<b>END_TIME</b>	<b>VAR</b>	<b>INT</b>	<b>THR</b>	<b>AREA</b>	<b>EPS</b>	<b>OVRLP</b>	<b>FLAG</b>
IOP1	01/02/2014	30/03/2014	DBZc	12min	[20,30,35]	15,30	1	20	True,False
IOP1	01/02/2014	30/03/2014	DBZc	12min	[30,35,40]	15,30	1	20	True,False
IOP1	01/02/2014	30/03/2014	DBZc	12min	[35,40,50]	15,30	1	20	True,False
IOP2	15/08/2014	15/10/2014	DBZc	12min	[20,30,35]	15,30	1	20	True,False
IOP2	01/02/2014	15/10/2014	DBZc	12min	[30,35,40]	15,30	1	20	True,False
IOP2	01/02/2014	15/10/2014	DBZc	12min	[35,40,50]	15,30	1	20	True,False
IOP1	01/02/2014	30/03/2014	TEMP	30min	[235,220,210]	150	1	20	True,False
IOP2	15/08/2014	15/10/2014	TEMP	30min	[235,220,210]	150	1	20	True,False

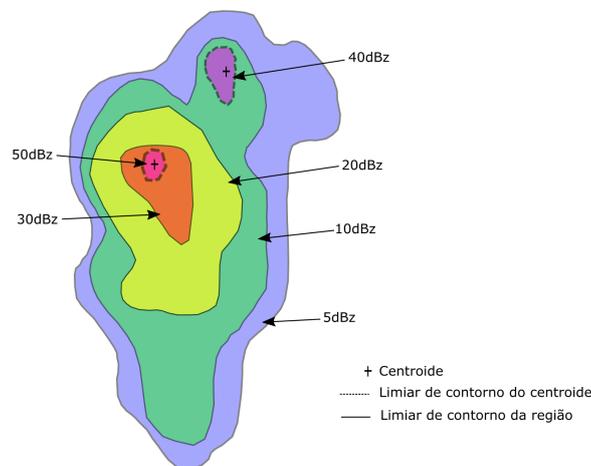
Fonte: Produção do Autor.

### 3.2.1.2 Limiarização

Existem diversas técnicas de segmentação que podem ser utilizadas com os mais diversos propósitos. Uma das abordagens voltadas a segmentação de imagens, é a filtragem por valores de interesse, onde, a partir do processamento de níveis de intensidade diferentes, os pontos mais intensos ou menos intensos são destacados do restante (DOYLE, 1962). Neste trabalho foram aplicadas a técnica de filtragem por valores, para destacar regiões de interesse nas imagens de radares e satélites com base nas informações de refletividade (radar) e temperatura de brilho do topo das nuvens (satélite). Aqui neste trabalho a limiarização é processo que realiza esta segmentação nas imagens.

Esta segmentação possibilita a identificação dos pontos de coordenada referentes a zonas com diferentes intensidades. Na Figura 3.4 cada região é delimitada por um limiar de intensidade, neste exemplo, o limiar é baseado nos valores de refletividade do radar, onde regiões com diferentes magnitudes foram destacadas de acordo com seu limiar.

Figura 3.4 - Estrutura de células de precipitantes em varredura azimuthal radar.



Fonte: Adaptado de Crane (1979).

O processo de segmentação utiliza os parâmetros de limiar (em inglês, *Threshold*) pré-definidos na *Tr* para identificar diferentes regiões de interesse e descartar valores dentro dos limites desejados. Os valores de saída do processo de limiarização são repassados para o próximo módulo como um vetor de coordenadas.

### 3.2.1.3 Clusterização

Os métodos de agrupamento são técnicas utilizadas para identificar grupos dentro de uma distribuição de dados multivariados. As técnicas de clusterização fazem parte dos métodos de aprendizado de máquina não-supervisionado e são responsáveis por grande parte da classificação de grupos nos problemas de mineração de dados (MAIMON; ROKACH, 2005). De acordo (CASSIANO, 2014) “A Clusterização é uma técnica mais “primitiva” na qual nenhuma suposição é feita a respeito dos grupos“. As técnicas de clusterização não utilizam de classes predefinidas ou classes previamente rotuladas, ou seja, desta maneira o aprendizado para agrupamento ocorre de maneira não-supervisionada. Os métodos de clusterização geralmente são realizados quando não há uma informação disponível sobre uma associação entre os elementos ou alguma classe predefinida (GRIRA et al., 2004).

O método de clusterização aplicado no algoritmo é um processo cujo objetivo é categorizar os grupos de pontos segmentados após o processo de limiarização. Neste processo são identificadas as células de chuva ou nuvem de acordo com sua distribuição de densidades. Regiões que possuem distribuição de pontos mais densas são agrupadas e recebem um rótulo de classificação. Este rótulo é um número que corresponde a identificação das células para um único tempo de observação. O DBSCAN (abreviação em inglês para, *Density-based spatial clustering of applications with noise* cuja tradução é Clusterização Espacial Baseada em Densidade de Aplicações com Ruído) é o algoritmo utilizado para identificar os *clusters* correspondentes as células de chuva e nuvem, este algoritmo faz parte dos métodos não-supervisionado baseados em densidade.

O DBSCAN é bastante utilizado no tratamento de ruídos em distribuições de dados, foi proposto inicialmente por Ester et al. (1996) e é um dos algoritmos de clusterização mais utilizados pois requer poucos parâmetros. Este método possui diversas variações com propósitos distintos, a versão revista e atualizada do DBSCAN (SCHUBERT et al., 2017) foi a implementação utilizada, sendo está associada a biblioteca *scikit-learn* da linguagem Python.

Uma das características do DBSCAN é a utilização do centroide como métrica para encontrar os grupos de distribuição por densidade. Essa métrica parte da ideia que cada ponto distribuído em uma certa densidade de dados possua uma vizinhança dentro dos limites de proximidade delimitadas por um raio com valor fixado, e uma quantidade mínima de vizinhos. O raio de distância que corresponde a relação de proximidade dos vizinhos é descrito na fórmula 3.1 e representado como  $Eps$ , o

número mínimo de vizinhos é simbolizado por  $MinPts$ , que é a quantidade mínima de elementos com proximidade a ser considerado como grupo com alguma relação de distância entre seus pares, esta relação é descrita como  $d(x_i, x_j)$  (ESTER et al., 1996; OLIVEIRA, 2008).

$$X_{Eps}(x_i) = \{x_j \in X | d(x_i, x_j) \leq Eps\} \quad (3.1)$$

Ao identificar as regiões mais densas, o algoritmo classifica cada grupo levando em consideração à distância entre os pontos, onde:

- (a)  $x_i$  é dado como ponto central caso  $X_{Eps}(x_i) \geq MinPts$ .
- (b)  $x_i$  é dado como ponto periférico na vizinhança de um ponto central  $x_j$ , isto é,  $x_i \in N_{Eps}(x_j)$ .
- (c) Caso  $x_i$  não satisfaça os valores de  $Eps$  dos pontos periféricos pertencentes a um ponto central, então este será considerado como ponto ruidoso.

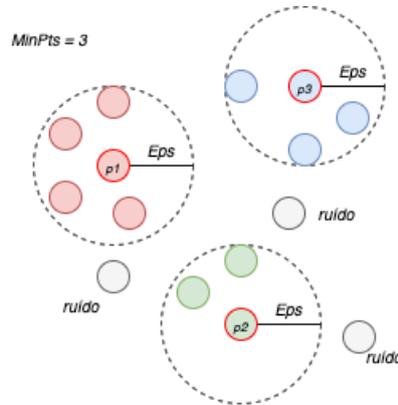
Na Figura 3.5 cada ponto central (contorno vermelho), avalia a distância entre os pontos de sua vizinhança levando em consideração o tamanho do raio ( $Eps$ ). Após verificar todos os pontos centrais de acordo com o valor mínimo de pontos da sua vizinhança, o algoritmo rotula os pontos de adjacentes. Os pontos que estão fora do raio de distância são classificados como ruído, desta forma, tais pontos ficam de fora de qualquer *cluster*. Esse processo se repete até que não existam mais pontos alcançáveis, e aqueles que não possuem uma vizinhança dentro dos limites de distância  $Eps$  ou o número mínimo de vizinhos  $Min Pts$ , serão considerados ruído.

#### 3.2.1.4 Vetorização

O processo de representação espacial faz parte do módulo que transforma os dados matriciais em dados vetoriais. Esse processo deve ocorrer apenas após a clusterização. Os valores de saída deste módulo são utilizados para identificar cada objeto em tempos distintos e servem para identificar a trajetória de movimento das células como vetores. Os vetores de deslocamento serão classificados após a identificação de níveis de sobreposição entre os polígonos que representam o limiar externo de cada célula.

O processo de vetorização é responsável por transformar os pontos dos *clusters* que estão no formato matricial em informações vetoriais correspondentes aos limi-

Figura 3.5 - Processo de agrupamento e classificação realizado pelo DBSCAN.



Fonte: Adaptado de Valêncio et al. (2013).

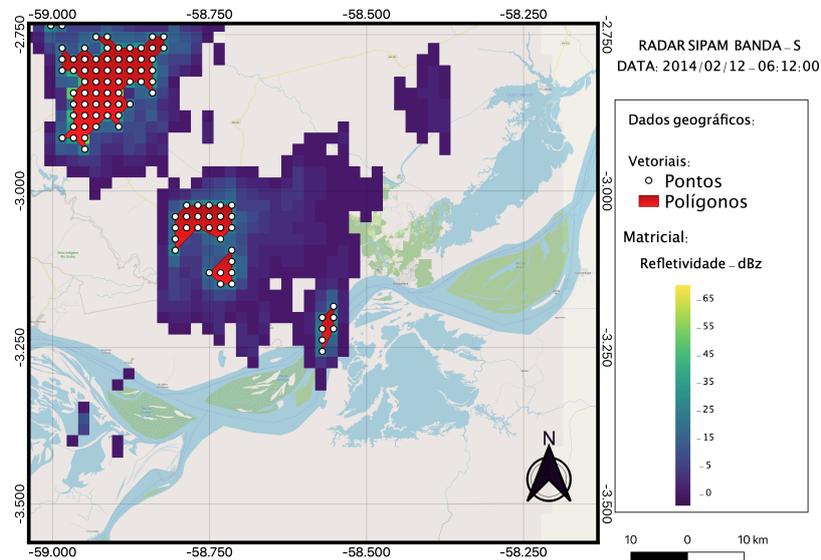
tes exteriores de cada célula. A localização individual de cada objeto vetorizado está relacionado a uma célula de chuva ou nuvem sobre uma região. O processo de vetorização permite a utilização das propriedades geométricas e topológicas dos polígonos. As propriedades geométricas descrevem as características métricas de um objeto e as topológicas, relacionadas as estruturas mais primitivas (pontos, linhas e polígonos) (LAURINI; THOMPSON, 1992).

O processo utilizado para representar as entidades envolvidas neste ponto do algoritmo são representadas nas duas formas, matriciais e vetoriais. Para as representações matriciais (*rasters*) o seu formato é caracterizado por elementos de tamanho regular que compõem uma matriz, cada elemento possui um valor de coordenada e um valor que representa informações sobre a variável analisada (refletividade ou temperatura de brilho). Na Figura 3.6 as entidades envolvidas são apresentadas como componentes vetoriais e matriciais, onde, os polígonos representam os limites da região de interesse com base no limiar utilizado, e os pontos como a localização dos índices de refletividade do radar.

As entidades relacionadas aos dados no formato matricial e vetorial são:

- (a) **Matricial:** A representação dos dados de cada sensor é feita por matrizes, para os dados de radar devem ser utilizados os pontos que representam as coordenadas geográficas e valores de refletividade. Para os dados do satélite, coordenadas e grandezas de temperatura de brilho.

Figura 3.6 - Representações espaciais sobre dados de Radar. Os Pontos brancos, representam a localização geográfica de um determinado valor de refletividade; os Polígonos vermelhos, representam o contorno limite da região que envolve os pontos; a região em Azul representa os valores de refletividade do radar.



Fonte: Produção do autor.

(b) **Vetoriais:**

- **Pontos:** Para cada sensor, um ponto será a representação geográfica referente a sua unidade. O ponto também será utilizado para descrever o centroide de densidade para cada polígono que representa a área de chuva ou o aglomerado de nuvens.
- **Polígonos:** Os polígonos serão utilizados para representar o limite de cada *cluster* e são usados no processo de rastreamento aplicando as operações espaciais, aquelas relacionadas a sobreposição de polígonos entre tempos consecutivos.
- **Linhas:** Outra representação a ser utilizada, são as linhas (em inglês, *Linestrings*), que indicam o vetor de deslocamento para cada célula baseadas nos centroides.

### 3.2.1.5 A tabela de rastreo

A tabela de rastreo é a entidade responsável por armazenar as informações e estatísticas do algoritmo. Esta tabela será utilizada por outros processos do algoritmo, onde, uma interação ocorre a cada ciclo de leitura e processamento. Ao final de todos os ciclos de leitura dos dados, a *Tr* será a saída do algoritmo. Uma das principais consultas realizadas na tabela tem como objetivo retornar a geometria das células de chuva e nuvem. Neste processo, as informações e estatísticas são carregadas para memória do computador e utilizadas para identificação da trajetória das células.

As informações contidas na *Tr* são compostas por campos que armazenam informações para cada tempo e célula individual. Estes campos são fundamentais para designar quais operações devem ser tomadas nas próximas etapas do algoritmo. Uma destas etapas é o processo de sobreposição entre as geometrias. Este processo identifica a trajetória das células com base no deslocamento de seus centroides. Outra informação contida na *Tr* está relacionada à classificação da célula no tempo decorrente de rastreo. A classificação de cada célula é designada por um "*status*" que indica uma tipificação relacionada ao evento ocorrido. Esta classificação é feita a partir da correlação com o tempo anterior  $t-1$ .

Os principais componentes da *Tr* estão:

- **tempo**: Valor referente ao tempo em que a célula foi identificada.
- **uid**: Identificador unitário da célula, gerado após o processo de sobreposições.
- **geometria**: Armazena a geometria da célula no formato vetorial.
- **status**: Classificação da célula para o tempo atual.
- **estatísticas em geral**: Estatísticas referentes ao tamanho, taxa de sobreposição, taxa de crescimento, intensidade média, direção e velocidade das células também são armazenados.

De modo geral, a *Tr* possui um comportamento dinâmico para o preenchimento das informações de rastreo ao longo do processamento dos dados. Outras informações também são adicionadas à *Tr* como, geometrias internas, vetores de deslocamento, pontos de centroide, níveis de intensidade, áreas, duração do ciclo de vida e etc. Estas informações podem ser úteis na descrição dos objetos rastreados, além de adaptável as necessidades do usuário.

### 3.2.2 Identificação e rastreio

O processo de identificação e rastreio é realizado para definir quais células deslocam-se entre duas imagens consecutivas. A identificação das células ocorre quando o algoritmo de rastreio passa pelos processos de Limiarização 3.2.1.2, Clusterização 3.2.1.3 e Vetorização 3.2.1.4. Após estes módulos, são verificadas a sobreposição entre os polígonos correspondentes a células em tempos consecutivos. Cada polígono possui informações estatísticas associadas ao seu tamanho e ponto central (centroide). Estas informações podem ser utilizadas para descrever a trajetória das células caso ocorram sobreposições com níveis percentuais mínimos entre as geometrias de duas ou mais células em tempos sucessivos.

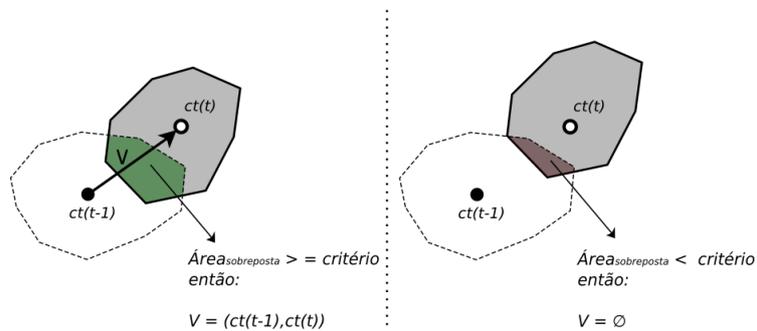
A aplicação de técnicas relacionadas ao rastreio de células de chuva e nuvens são temas bastante discutido em diversos estudos (DIXON; WIENER, 1993; VILA et al., 2008; JOHNSON et al., 1998; MATTHEWS; TROSTEL, 2010). Um dos principais problemas relacionados à identificação e rastreio é determinar quais características utilizar para descrever de forma mais assertiva à física do movimento das componentes dinâmicas que envolvem o deslocamento das células. A técnica de rastreio aplicada neste trabalho foi baseada nas metodologias propostas por Mathon e Laurent (2001) e Vila et al. (2008).

O rastreamento de nuvens convectivas é baseado em um método de sobreposição de área. Essa técnica simplesmente assume que uma nuvem em um momento posterior corresponde àquela em um momento anterior quando, considerando as restrições anteriores de tamanho e temperatura, existem píxeis comuns em imagens consecutivas. Vila et al. (2008, p.235).

Técnicas baseadas no centroide para determinar o deslocamento de objetos podem ser utilizadas para encontrar o vetor de deslocamento entre tempos consecutivos de observações. O vetor de deslocamento estimado  $V$  ocorre quando é considerado o deslocamento do centroide da geometria do tempo anterior  $ct(t-1)$  e o centroide da geometria no tempo atual  $ct(t)$  (VILA et al., 2008). Esta metodologia considera um valor de área mínima sobreposta para determinar o vetor de deslocamento entre os centroides de duas geometrias consecutivas. O valor de área mínima sobreposta é dado pelo percentual de área entre a intersecção de duas geometrias, na Figura 3.7 é demonstrado como o vetor de deslocamento é criado caso os critérios de área mínima sobreposta seja verdadeiro. Este parâmetro é de suma importância quando aplicado em alvos meteorológicos, principalmente nuvens de tempestades. A precipitação associada a estes eventos pode sofrer processos microfísicos e dinâmicos que

possibilitam um rápido desenvolvimento ou decaimento. Correntes ascendente dentro da nuvem podem carregar hidrometeoros para áreas superiores e o processo de precipitação pode ser intensificado pelas correntes descendentes. Toda essa dinâmica pode ocorrer entre imagens consecutivas e interferir no rastreamento de um determinado sistema. Espera-se que o processo de clusterização e definição de polígonos minimize alguns desses erros, junto com uma melhor definição dos processos de sobreposição baseados nestes percentuais.

Figura 3.7 - Exemplo de aplicação da sobreposição de polígonos para determinar o vetor de deslocamento entre dois tempos consecutivos.



Fonte: Produção do autor.

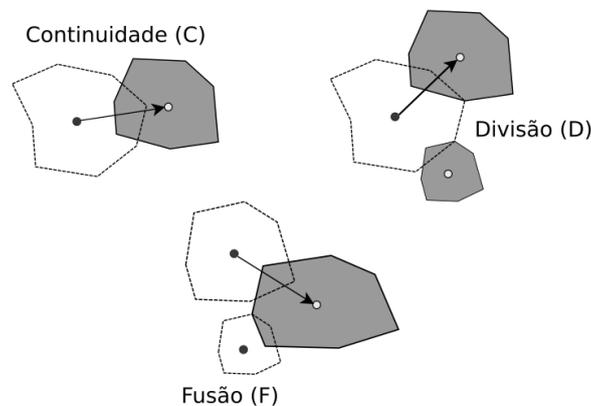
O deslocamento das células de chuva e nuvem apresenta uma dinâmica de movimento em que algumas situações podem ocorrer em metodologias baseadas na sobreposição de geometrias para tempos consecutivos. Tais situações foram descritas por Vila et al. (2008) como possíveis para descrever à dinâmica de movimento das células, são estas:

- (a) **Geração Espontânea (N)**: Na comparação entre dois tempos sucessivos não ocorre sobreposição de áreas entre geometrias das células nos tempos  $t-1$  e  $t$ , nesta situação é considerado que houve a geração espontânea de um novo sistema e um novo ciclo de vida é iniciado a partir da célula no tempo  $t$ .
- (b) **Dissipação Natural (DN)**: É semelhante ao caso anterior (N), porém, não há sobreposição entre as áreas dos tempos  $t$  e  $t+1$ , essa situação pode ser considerada como uma dissipação natural e remete ao final do ciclo de vida de uma célula.

- (c) **Continuidade (C)**: Comparando dois tempos sucessivos  $t-1$  e  $t$  existe a sobreposição única entre as geometrias de duas células.
- (d) **Divisão (D)**: Essa situação ocorre quando duas ou mais células no tempo  $t$  se sobrepõem a geometria de uma célula no tempo  $t-1$ . Neste caso, a célula com maior área no tempo  $t$  é classificada como (D) e um vetor de deslocamento partindo do centroide da célula  $t-1$  é adicionado ao rastreamento. A célula com menor área no tempo  $t-1$  tem o seu ciclo de vida encerrado ou segue como um novo sistema no tempo seguinte.
- (e) **Fusão (F)**: Situação inversa à divisão (D) onde duas células no tempo  $t-1$  se sobrepõem a apenas uma única célula no tempo  $t$ . Neste caso, a célula no tempo  $t$  recebe as mesmas entidades relacionais da célula com maior área no tempo  $t-1$ , já a outra célula finaliza o seu ciclo de vida.

Para melhor representar as situações de eventos com Continuidade, Divisões e Fusões, como descritas por Vila et al. (2008), a Figura 3.8 representa as eventuais ocorrências de classificação do rastreamento e geração dos vetores de deslocamento. Representado as células no tempo  $t-1$  os polígonos com bordas tracejadas, já as células do tempo  $t$  são representadas pelos polígonos na cor cinza. O vetor de deslocamento (seta) representa o vetor de deslocamento gerado a partir do tipo de classificação recebido pela célula.

Figura 3.8 - Esquema para representar ocorrências de Continuidades, Divisões e Fusões entre células.



Fonte: Adaptado de Vila et al. (2008).

A combinação entre os tipos de ocorrências (Divisões e Fusões, Continuidades e Fusões, e etc.) ao longo do ciclo de vida podem impactar em uma má representação do deslocamento do sistema. Outro problema que pode ocorrer está relacionado ao formato da geometria utilizada para rastreamento. No trabalho de Vila et al. (2008) o critério de sobreposição foi feito com base na excentricidade dos pontos relacionados aos limites de rastreamento, e caso exista um nível de sobreposição entre as circunferências, utiliza-se o centroide da excentricidade para determinar o vetor de deslocamento. Na metodologia proposta neste trabalho, a geometria selecionada para rastreamento representa o exterior das células, como um polígono, o que pode ter melhor representatividade espacial do eventos. Contudo, em alguns casos, o formato destas células pode apresentar características de geometrias concavas ou convexas, o que pode aumentar as incertezas ao determinar o vetor de deslocamento.

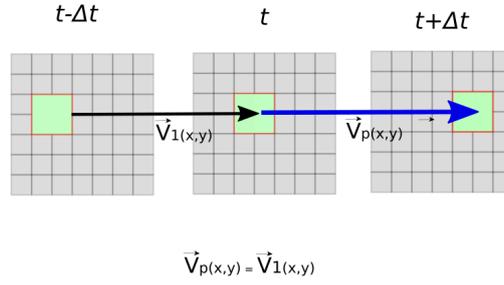
### 3.2.3 Previsão por extrapolação

Para prever o deslocamento destas células, técnicas de extrapolação podem ser utilizadas para encontrar o vetor de deslocamento futuro. Essas técnicas utilizam informações dos componentes morfológicos das células e os extrapolam linearmente para prever seu movimento (TSONIS; AUSTIN, 1981). Neste trabalho foram utilizados as informações dos valores de refletividade (radar) e temperatura de brilho (satélite) associados ao *cluster* no tempo  $t$  e seu vetor de deslocamento final para realizar a previsão do mesmo. Ou seja, é mantida as características morfológicas do sistemas em sua derradeira forma. Apenas três métodos foram utilizados para realizar a previsão.

O primeiro método de extrapolação usa apenas o vetor de deslocamento determinado no último intervalo de tempo. Este método descrito por Fazolo (2019) foi aqui denominada de conservativo (Ctvo). Uma vez que todos os parâmetros morfológicos e o vetor deslocamento são conservados na previsão. A Figura 3.9 mostra a disposição do esquema de previsão.

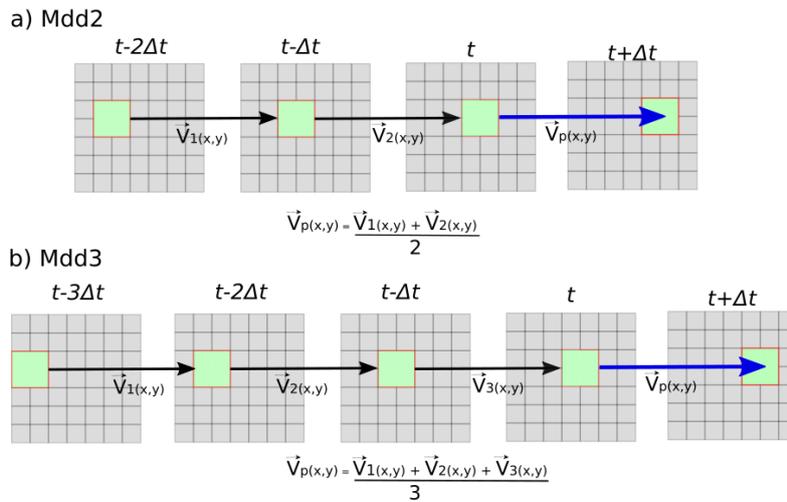
O segundo e o terceiro método de previsão foram baseados na média entre dois e três vetores respectivamente e são chamados de "Média de dois deslocamentos"(Mdd2) e "Média de três deslocamentos"(Mdd3). Ambos os métodos são baseados na abordagem descrita por Fazolo (2019) para previsão de raios. Estes métodos objetivam utilizar o vetor médio ( $\vec{V}_p$ ) para extrapolar as componentes  $x, y$  das células observadas em  $t$  baseando-se nos tempos  $t-3\Delta t$ ,  $t-2\Delta t$  e  $t-\Delta t$ . Ambos métodos foram representados na Figura 3.10.

Figura 3.9 - Exemplo para técnica de extrapolação Ctvo.



Fonte: Adaptado de Fazolo (2019).

Figura 3.10 - Exemplo para as técnicas de extrapolação. a) Mdd2: utiliza a extrapolação média dos vetores  $\vec{V}_{1(xy)}$  e  $\vec{V}_{2(xy)}$  para calcular o vetor resultante previsto  $\vec{V}_p$ . b) Mdd3: utiliza a extrapolação média dos vetores  $\vec{V}_{1(xy)}$ ,  $\vec{V}_{2(xy)}$  e  $\vec{V}_{3(xy)}$  para determinar o vetor resultante previsto  $\vec{V}_p$ .



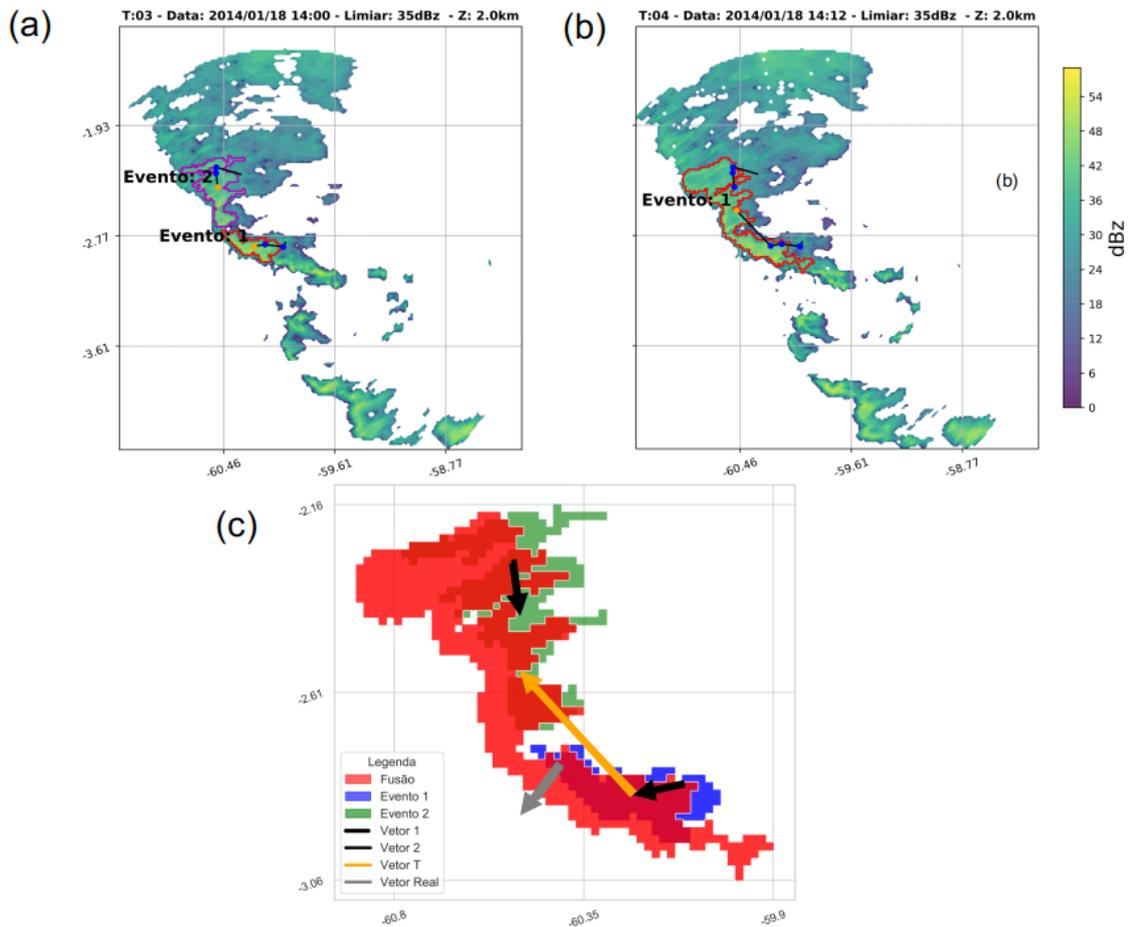
Fonte: Adaptado de Fazolo (2019).

### 3.3 Problemas relacionados ao uso do centroide

Como dito anteriormente, o uso do centroide como parâmetro para determinar o deslocamento das células pode apresentar problemas relacionados a estimativas incorretas de velocidade e direção. Este problema está associado ao uso do centroide com técnicas baseadas em rastreamento de objetos não-rígidos associados a múltiplos eventos de fusões e divisões entre as células (STORLIE et al., 2009). A geometria

das células é outro fator que pode ocasionar resultados incertos, pois, células com características geométricas concavas ou mais esparsas podem corroborar para uma estimativa incorreta do vetor de deslocamento. Para caracterizar este problema a Figura 3.11 demonstra como um vetor de deslocamento poderia ser classificado erroneamente em um evento real de LI sobre a região Amazônica.

Figura 3.11 - (a) São registrados dois eventos (Evento 1 e Evento 2) com valores de refletividade em 35 dBZ respectivamente, (b) Evento 1 foi classificado como célula preferencial devido aos seus critérios de sobreposição e tamanho, (c) Apresenta como estão dispostos os vetores de deslocamento entre o tempo anterior ao evento de Fusão (vetores pretos) e os vetores gerados pela Fusão (laranja) e o real vetor de deslocamento (cinza).



Fonte: Adaptado de: Leal Neto et al. (2020).

Neste exemplo, a Fusão de duas células de chuva em uma LI ocasionou a geração de um vetor de deslocamento equivocado (seta laranja). O formato destas células em linha normalmente apresentam características geométricas concavas e esparsas, com isso, faz-se necessário aplicar heurísticas para correção dos vetores de deslocamento. Caso as células rastreadas apresentem tais características morfológicas, correções podem ser aplicadas com objetivo de diminuir as incertezas relacionadas. Tais correções podem ser realizadas não só as LIs ou eventos relacionados a Fusões, mas também a todo rastreo de células de chuva ou nuvens em geral. Neste sentido, foram aplicadas diversas correções vetoriais com o intuito de definir melhor o vetor deslocamento ao longo do ciclo de vida.

### 3.3.1 Métodos de correção do deslocamento

Se analisarmos as nuvens de tempestade, existem diversos fatores que podem modificar sua trajetória. Segundo Cotton e Anthes (1992) os mecanismos atuantes no movimento das células podem ser classificados como: a) o movimento de translação ou advecção quando a tempestade segue o vento médio durante seu ciclo de vida; b) Propagação forçada que ocorre quando uma célula tempestuosa tem seu desenvolvimento associado a alguma forçante externa; c) Autopropagação ocorre quando a dinâmica da tempestade provoca mecanismos de múltiplas interações gerando sua propagação. Logo, de modo a diminuir alguns problemas gerados pela má representatividade de alguns deslocamentos, seja ele associado a uma tempestade ou não, algumas ajustes foram implementados no algoritmos de rastreo. As técnicas de correção vetorial desenvolvidas neste trabalho são métodos baseados nos eventos característicos dos tipos de ocorrências abordados na Seção 3.2.2. Estes métodos tem como proposito corrigir os vetores de deslocamento das células, e com isso diminuir as incertezas relacionadas ao rastreo de sua trajetória.

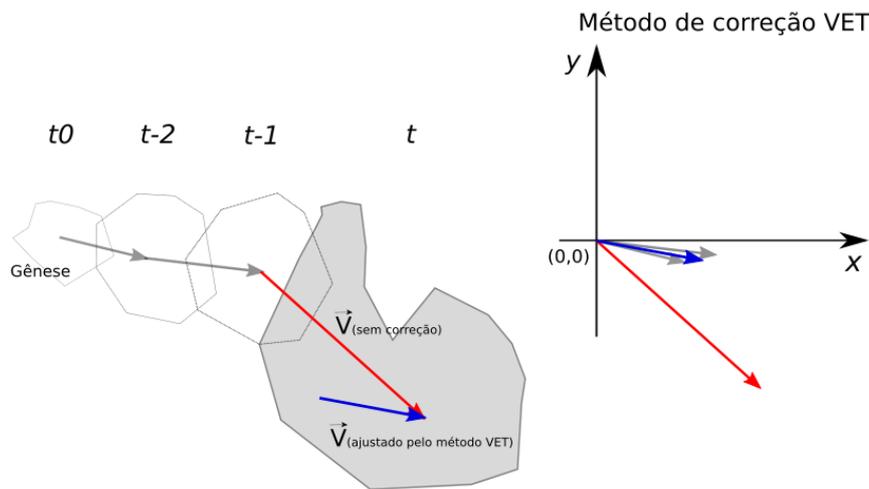
Para melhor caracterizar o objetivo dos métodos de correção vetorial foi definido o vetor de deslocamento no tempo de observação atual como  $\vec{V}_t$ . As componentes do plano cartesiano  $x$  e  $y$  do segmento de reta orientado representam o ponto inicial  $P(x_1, y_1)$  do centroide de uma célula no tempo  $t-1$ , e a extremidade final  $Q(x_2, y_2)$  o centroide da célula no tempo atual  $t$ , ou seja, podemos representar este vetor com a Equação 3.2:

$$\vec{V}_t = PQ \tag{3.2}$$

### 3.3.1.1 Correção por média vetorial (VET)

A primeira das técnicas de correção vetorial é o método baseado na Média Vetorial (VET) do ciclo de vida completo de uma célula. Este método utiliza os vetores relacionados a todas as observações do ciclo de vida para corrigir um possível vetor incorreto. Um vetor médio de todos os vetores relacionados ao limiar de rastreamento principal será o vetor que substituirá um possível vetor incorreto. Para definir quais observações serão corrigidas com este método, um critério limite relacionado à velocidade e a direção de propagação da célula deve ser ultrapassado. Para delimitar o valor de critério que inicializa o método VET, foi definido que caso a componente de velocidade ou direção do vetor  $\vec{V}_t$  seja superior a 60% (exemplo dado pela seta vermelha) do vetor  $\vec{V}_{t-1}$  a correção vetorial será aplicada (exemplo dado pela seta azul), na Figura 3.12 temos o exemplo que demonstra o método VET para ajuste de um vetor de deslocamento. Note que o valor de 60% é arbitrário e sugere apenas uma mudança grande no deslocamento. Uma análise mais profunda sobre erros no deslocamento será proposto em trabalhos futuros.

Figura 3.12 - Exemplo de correção pelo método de média vetorial (VET)



Fonte: Produção do Autor.

No exemplo da Figura 3.12 o método VET foi aplicado e o  $\vec{V}_t$  ajustado de acordo com o vetor médio baseado no ciclo de vida das células partindo do vetor em  $t_0$  (Gênese) até o tempo  $t-1$ . O Polígono cinza representa uma célula no tempo atual  $t$  e seu vetor associado antes da correção (seta vermelha). Na mesma figura, células

de observações posteriores a  $t$  são representadas por polígonos pontilhados com seus respectivos vetores de deslocamento. Para determinar  $\vec{V}_{ajustado}$  (em azul) todos os vetores anteriores à  $t$  são deslocados para o ponto de origem (0,0) e o vetor corrigido será a média dos vetores até o tempo  $t$ . A Equação seguinte 3.3 representa esta operação.

$$\vec{V}_{ajustado} = \frac{\sum_{i=0}^{n-1} \vec{V}_{i(xy)}}{n} \quad (3.3)$$

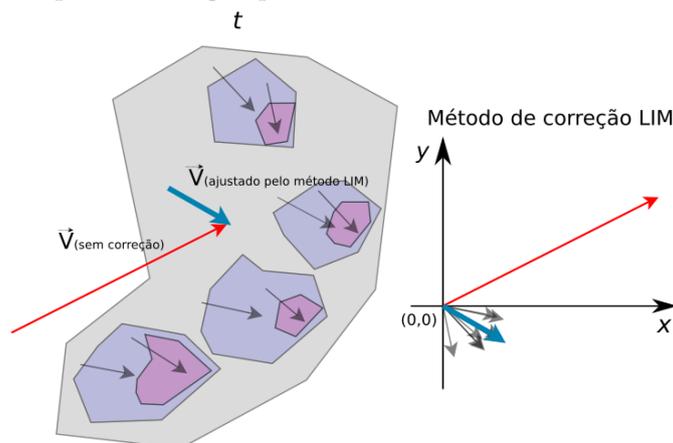
Onde, o vetor corrigido  $\vec{V}_{ajustado}$  será a média da soma entre as componentes vetoriais  $xy$  no plano cartesiano deslocadas para o ponto de origem (0,0) e  $n$  o número de vetores de todo o ciclo de vida da célula.

### 3.3.1.2 Correção por limiar interno (LIM)

O segundo método de correção utiliza os vetores associados aos multi-limiarres internos das células de chuva e nuvens. Esse método foi denominada como correção por Limiar Interno (LIM) . O resultado deste método faz à correção do vetor associado ao deslocamento da célula classificada pelo primeiro limiar no tempo  $t$ . Esta correção é baseada na média dos vetores de deslocamento de suas células internas. A Figura 3.13 ilustra como este método ajusta o vetor de deslocamento, o polígono (cinza) representa a geometria do limiar principal (ou limiar externo), enquanto os polígonos menores (roxos) estão relacionados as geometrias internas (limiares mais intensos para radar e mais frios para o satélite) e seus respectivos vetores de deslocamento.

Embora os vetores utilizados para correção estejam associados a limiares diferentes do principal, o vetor corrigido (vetor azul na Figura 3.13) é o vetor médio dos vetores internos de uma célula individual, também descrito na Fórmula 3.3. Está operação será mais efetiva na correção dos vetores de deslocamento das células com uma alta dinâmica convectiva, ou seja, quanto maior o número de células baseadas nos limiares internos que possuam vetores de deslocamento, maior será a efetividade de correção deste método. Este tipo de correção supõe que os núcleos mais internos (e.g. células convectivas embebidas em um sistema maior) seguem um trajetórias mais uniforme, definindo um deslocamento associado ao propagação dominante.

Figura 3.13 - Exemplo de correção pelo método da média dos Limiar Interno (LIM).



Fonte: Produção do Autor.

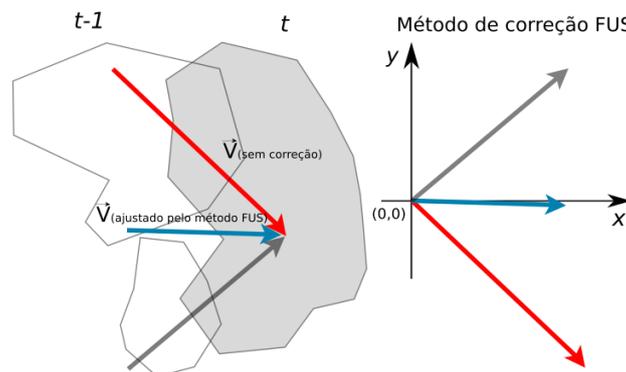
### 3.3.1.3 Correção por fusão (FUS)

Uma grande quantidade de processos dinâmicos ocorre no núcleos de sistemas tempestuosos, este comportamento pode levar a fusões entre as células no decorrer do seu ciclo de vida. Tal comportamento pode estar relacionados com a transição para o estágio de maturação de uma tempestade (HOUBE JUNIOR, 1997). Com base nesta característica, o método de correção por Fusão (FUS) visa retificar o vetor de deslocamento para eventos de fusão entre células. Neste método são utilizados os vetores associados ao evento que levou a fusão de múltiplas células nos tempos  $t-1$  e  $t$  para ajustar o vetor de deslocamento no tempo  $t$ . Na Figura 3.14 o ajuste feito pelo método FUS utiliza a Equação 3.3 para correção do vetor em eventos de fusão. O vetor ajustado com o FUS é o vetor resultante (seta azul) entre o somatório dos vetores em  $t$  após o deslocamento de suas componentes  $(x,y)$  para um ponto de origem  $(0,0)$ . Neste caso o vetor sem correção (seta vermelha) é substituído pelo vetor ajustado (azul) no tempo  $t$ .

### 3.3.1.4 Correção por divisão (DIV)

O último método de correção vetorial aqui listado é baseado nos eventos de Divisão (DIV) entre células. Com base nos eventos de divisão entre as células, o método de correção por Divisão (DIV) adiciona um vetor para uma nova célula gerada após um evento de divisão. O vetor de propagação criado por este método, substitui um vetor sem correção anteriormente associados aos centroides em  $t-1$  e  $t$ , por um novo vetor que parte do centroide da intersecção entre a célula em  $t-1$  em direção a nova

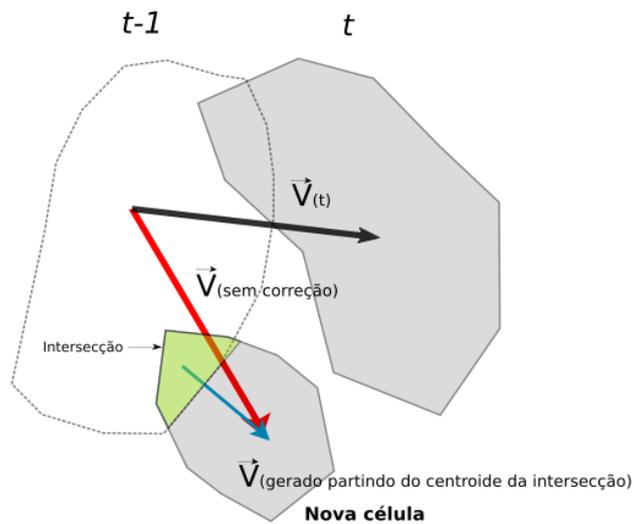
Figura 3.14 - Exemplo de correção pelo método baseado na Fusão (FUS).



Fonte: Produção do Autor.

célula em  $t$ . O esquema de retificação pode ser visto na Figura 3.15.

Figura 3.15 - Exemplo de criação de vetor auxiliar com método baseado na Divisão de células (DIV).



Fonte: Produção do Autor.

### 3.3.1.5 Avaliação dos métodos

De acordo com [Murphy \(1993\)](#), existem diferentes opiniões sobre abordagens relacionadas as metodologias de previsão automática e uma previsão feita por humanos, essas diferenças são acrescidas por uma falta de clareza ou compreensão sobre a natureza do que significa obter uma boa previsão. Ou seja, falta de clareza e compreensão é um óbice para tarefas relacionadas à avaliação dos sistemas de previsão e seus métodos previsores. Baseado nessas dificuldades [Murphy \(1993\)](#) classificou três aspectos relacionados que podem ser levados em consideração para avaliar sistemas de previsão, sendo: 1) a correspondência entre o julgamento de dados analisados e previstos; 2) correspondência entre previsões e observações; 3) benefícios incrementais obtidos por tomadores de decisão para determinar previsões.

Como pode ser notado até esta etapa, diversos métodos de correção vetorial do deslocamento e de previsão dos sistemas foram implementados. Neste sentido, a metodologia usada neste trabalho para verificar os impactos das diversas implementações na performance de rastreamento e previsão deste algoritmo foi baseada na simples comparação entre o previsto, para o passo de tempo seguinte, e sua respectiva observação. Cabe ressaltar que todos os métodos de previsão susoditos em seção anterior foram analisados. Este tipo de abordagem é bastante conhecida e pode ser aplicada com intuito de validar tanto os métodos de correção vetorial quanto os métodos de extrapolação.

A validação dos métodos de extrapolação tem como objetivo determinar qual das técnicas é mais adequado para prever o deslocamento das células em um único período de observação  $t+\Delta t$ . Utilizar apenas uma única observação a frente do tempo  $t$  visou também avaliar as metodologias de correção vetorial propostas por este trabalho na Seção 3.3.1.

Como a qualidade das previsões é um fator que pode ser levado em consideração na avaliação, para isso, parâmetros estatísticos podem ser utilizados para definir qual a previsão obteve uma melhor performance comparando-as entre si. Estes parâmetros estatísticos definem a capacidade de um método em prever a ocorrência de um determinado evento. Em [Wilks \(2011\)](#) foram descritos os parâmetros estatísticos para avaliação dos previsores, sendo:

- (a) **Acerto**: Parâmetro relacionado com eventos que foram previstos e ocorreram.
- (b) **Erro**: Parâmetro para os eventos não previstos, no entanto, ocorreram.

- (c) **Falso Positivo:** Parâmetro relacionado à eventos previstos, porém, não ocorreram.
- (d) **Falso Negativo:** Previsão dos eventos que não foram previstos e que também não ocorreram.

A combinação entre os parâmetros estatísticos podem fornecer outros índices relacionados aos aspectos probabilísticos dos métodos de previsão. Neste trabalho, foram utilizados os índices de probabilidade de detecção (POD) para determinar a relação entre o total eventos observados e previstos, e a taxa de falsos alarmes (FAR) foi usada não só em correspondência ao POD, mas também para a previsão de deslocamento de células individuais ao longo do seu ciclo de vida. Para melhor descrever as peculiaridades desses índices, temos que:

- (a) **POD:** É a razão entre o número de eventos previstos corretamente e o número de eventos observados. Caso todas estimativas estejam corretas, o resultado da operação será 1, e caso todas as previsões sejam incorretas, o resultado é zero.

$$POD = \frac{Acerto}{(Acerto + Erro)} \quad (3.4)$$

- (b) **FAR:** Para calcular o FAR, é utilizada a razão entre alarmes falsos e o número total de eventos previstos. O melhor caso para o FAR é quando seu resultado é igual a 0.

$$FAR = \frac{FalsoPositivo}{(Acerto + FalsoPositivo)} \quad (3.5)$$

Os índices estatísticos são utilizados para avaliação quantitativos dos resultados do algoritmo de rastreamento desenvolvido neste trabalho. Com intuito de avaliar estes índices, a função de pontuação *Skill Score* foi utilizada para mensurar os valores probabilísticos (*POD* ou *FAR*) associados as previsões. Esta função agrega uma pontuação de habilidade associadas aos métodos de correção vetorial e extrapolação dos vetores de deslocamento. Os valores utilizados na função *Skill Score* (Equação 3.6) são correlacionados com um valor de referência que será a base de comparação para os demais métodos de correção vetorial e extrapolação. Portanto, a função para avaliar a habilidade dos métodos é descrita da seguinte forma:

$$Skill\_Score = \frac{SCORE_{previsto} - SCORE_{referência}}{SCORE_{previsão-perfeita} - SCORE_{referência}} * 100 \quad (3.6)$$

As metodologias de avaliação visam mensurar quantitativamente os resultados do algoritmo de rastreamento. Estas metodologias foram utilizadas com intuito de avaliar os melhores parâmetros de rastreamento e métodos de extrapolação. Os resultados desta avaliação serão discutidos no próximo capítulo, demonstrando qual o método mais adequado ao rastreamento e previsão com dados de Radar e Satélites meteorológicos nos dois períodos de observação (IOP1 e IOP2) na bacia Amazônica. Além disso, será possível definir as condições físicas que favorecem ou não uma melhor previsão dos sistemas ali observados.

## 4 RESULTADOS

Este capítulo explora os resultados obtidos no desenvolvimento desta pesquisa. O processo de criação do algoritmo não foi trivial e dado o tempo de pesquisa de um mestrado foi um grande desafio. As análises aqui apresentadas partem de sua versão inicial. Neste sentido, foram avaliadas as informações de saída do algoritmo após cada nova implementação na tentativa de melhor caracterizar os sistemas que foram rastreados via radar meteorológico, a partir dos valores de refletividade, assim como, pelo satélites GOES-13 e suas medidas de temperatura de brilho. As análises aqui apresentadas mostram o processamento dos dados relacionados aos períodos de observação IOP1 e IOP2 do projeto GoAmazon. Cabe ressaltar que as avaliações foram divididas nestes IOPs devido ao fato que existem processos físicos predominantes em cada período que definem as características médias dos sistemas de precipitação e nuvens na região e devem ter impacto nos resultados desta pesquisa sobre rastreo (MACHADO et al., 2018). Com base nestes resultados, a primeira avaliação trata sobre a performance geral do algoritmo no processamento das informações dos sensores. Em seguida as avaliações e análises foram divididas em dois blocos, o primeiro, para avaliar as particularidades dos resultados para o radar meteorológico, e o segundo bloco, avaliou a capacidade do algoritmo e seu funcionamento para classificação de informações em maior escala, isto é, via satélite.

### 4.1 Performance do algoritmo

Um ponto importante em um sistema de *nowcasting* é o tempo de resposta. Todos os algoritmos utilizados devem ser rápidos, de modo a entregar as informações necessárias para a tomada de decisão. Neste sentido, a primeira análise determina se a performance do algoritmo teve custo temporal elevado ou não para o processamento dos dados. Esta avaliação tem como objetivo demonstrar os indicativos de performance alcançados após aplicação dos parâmetros de rastreo. Estes valores não indicam quais os melhores resultados, mas sim o tempo computacional gasto para o processamento dos dados de cada sensor. Estes valores estão dispostos na Tabela 4.1, e são listados os parâmetros de rastreo relacionados ao período de observação, sensor, limiares, quantidade de observações e tempo decorrido para processamento. Os valores apresentados na Tabela 4.1 foram obtidos após o termino de cada rodada do algoritmo. Estes valores representam o tempo dispendido para processamento do algoritmo no modo básico, ou seja, em sua versão inicial, sem aplicação dos métodos de correção vetorial e extrapolação. Essas estimativas foram realizadas em um micro-computador de uso pessoal com processador *Intel Core™i7-8700T CPU 2.40GHz* ×

6. Devido ao grande volume de dados e o *hardware* utilizado, o tempo despendido deve ser apenas considerado como uma estimativa de processamento relacionado aos parâmetros de rastreo, período de observação e sensores.

Nota-se na Tabela 4.1 que para o radar o tempo gasto variou entre 32 min 58 segundos (IOP1, com 35dBZ de limiar inicial e área mínima de 15 píxeis) e 2 h 11 min 53 segundos (IOP2, com 20 dBZ de limiar inicial e área mínima de 15 píxeis). Já para o satélite, como utilizou-se apenas um configuração de limiar, com 235 K e 150 píxeis de área mínima, o tempo variou de 8h 02 min 50s (IOP2) e 14 h 15min 46 segundos (IOP1). Logo, observa-se que, como esperado, a performance deve variar pela quantidade de sistemas observados para rastreia, que depende dos limiares de tamanho e de rastreo. No caso do radar, o IOP1 (IOP2) foi o mais rápido (lento) na configuração apresentada devido ao fato que sistemas com 35 dBZ (mais convectivos) não são mais frequentes que os de 20 dBZ (mais estratiformes), o que limitou o número de observações. Além disso, no IOP2 existe uma maior fragmentação dos eventos (como veremos em seção posterior), tempestades mais isoladas, o que requer mais tempo de processamento do que o IOP1. Já o satélite, mostra que IOP1 apresentar maior tempo para processamento, um resultado que pode ser associado mais ao limiar de tamanho, onde os sistemas durante a estação chuvosa são maiores em área do que aqueles observados na estação seca.

Tabela 4.1 - Performance geral do algoritmo.

<b>IOP</b>	<b>Sensor</b>	<b>Limiar-Área</b>	<b>Qtd. Observações</b>	<b>Tempo decorrido</b>
IOP1	Radar	20dBZ-15p	6022	01:27:56
IOP1	Radar	30dBZ-15p	6022	00:35:58
IOP1	Radar	35dBZ-15p	6022	00:32:11
IOP1	Radar	20dBZ-30p	6022	01:18:20
IOP1	Radar	30dBZ-30p	6022	00:40:26
IOP1	Radar	35dBZ-30p	6022	00:14:19
IOP1	Satélite	235k-150p	2736	14:15:46
IOP2	Radar	20dBZ-15p	6893	02:11:53
IOP2	Radar	30dBZ-30p	6893	00:52:43
IOP2	Radar	20dBZ-30p	6893	01:36:52
IOP2	Radar	30dBZ-15p	6893	01:33:53
IOP2	Radar	35dBZ-15p	6893	00:56:33
IOP2	Radar	35dBZ-30p	6893	00:38:02
IOP2	Satélite	235k-150p	2346	08:02:50

Fonte: Produção do Autor.

## 4.2 Rastreo via radar

Como susodito, o primeiro bloco de análise de rastreo e previsão pelo algoritmo desenvolvido para a região Amazônica foi endereçado as medidas feitas pelo radar banda-S do SIPAM. Nesta etapa iremos verificar a performance de previsão e rastreo dos eventos para cada IOP. O objetivo destas análises foi, não só avaliar a capacidade do algoritmo em rastrear e prever sistemas precipitantes, mais também de caracterizar os sistemas precipitantes observados sobre a região. Apresentando-se uma nova alternativa a estudos sobre a propagação da chuva e outros fenômenos identificados via radar.

Alguns dos gráficos aqui apresentados mostram em seu eixo-x as configurações apresentadas para execução do algoritmo. De modo a facilitar a identificação dos métodos, foi criada uma nomenclatura que diz: "Método de extrapolação-"Método(/s) de correção vetorial-"Limiar de rastreo (dBZ ou Tb)-"Limiar mínimo de tamanho (píxel)". Exemplo, o método de base do radar foi "Ctvo-BASE-20-15", que significa que usamos o Conservativo (Ctvo) como método de extrapolação, sem nenhuma correção vetorial (BASE), com limiar de refletividade de rastreo em 20 dBZ e cada *cluster* teve no mínimo 15 píxeis.

### 4.2.1 Análise dos parâmetros e técnicas de extrapolação: modo operacional básico

Nesta seção avaliou-se os parâmetros de rastreo e as técnicas de extrapolação classificadas pelo modo operacional básico (BASE) do algoritmo. Neste modo não implementa-se nenhuma das correções de deslocamento das células. O objetivo desta análise visa apresentar o que seria modo operacional mais simples do algoritmo e avaliar a performance dos parâmetros de rastreo: limiares e número mínimo de píxeis por *cluster*. Note que em sistemas de *nowcasting* que partem dessas informações de limiares é de suma importância defini-las bem. Tais valores podem ser afetados por diversas causas, como o próprio mal-funcionamento dos sensores que medem aquilo que será rastreado, e com a física e dinâmica que envolve a gênese do fenômeno (objeto) que se pretende rastrear sobre uma determinada região (CRANE, 1979; DIXON; WIENER, 1993; JOHNSON et al., 1998; VILA et al., 2008). Lembrando que a métrica de avaliação do rastreo é a previsão. Partindo do princípio que não deveria haver mudanças bruscas no deslocamento do sistemas em um curto período de tempo (próximos 12 minutos). Ou seja, se o sistema apresenta um bom *skill* de previsão para uma determinada configuração, isso significa que o modo de rastreo foi mais eficiente e melhor representou o vetor deslocamento no instante de obser-

vação antes da previsão. Contudo, para evitar problemas associados justamente a previsão, duas técnicas de extrapolação também foram avaliadas, a Mdd2 e Mdd3, o que traria mais robustez a análise em diferentes aspectos, não só ao rastreo, mas previsão também.

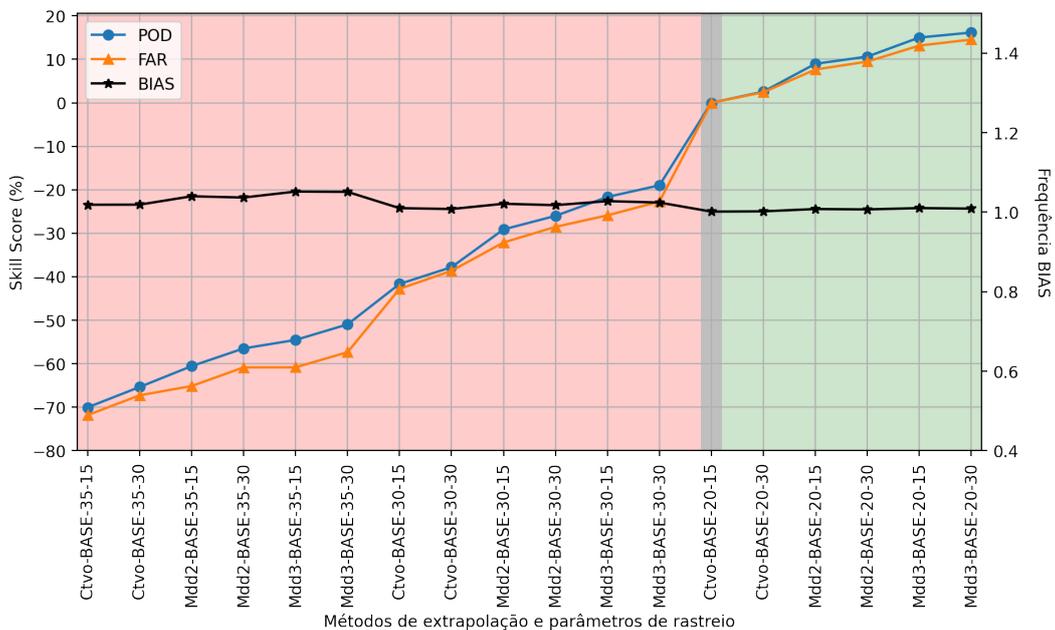
Para avaliar a habilidade do algoritmo alcançada no modo básico, foram utilizados os parâmetros estatísticos (*Acerto*, *Erro* e *Falso Positivo*) referente as observações do radar no IOP1 e IOP2. Com base nos indicadores estatísticos, foram computados os índices probabilísticos (*POD* e *FAR*) para avaliação de habilidade do algoritmo sem correções vetoriais. A Tabela com os parâmetros estatísticos do modo básico está disponível nos anexos deste trabalho D.1.

Os índices estatísticos foram utilizados para encontrar o método mais eficiente em comparação ao modo básico. Para isso, utilizou-se os indicadores de POD e FAR (Anexo D.1) selecionando o método inicial Ctvo-BASE-20-15 como valor de referência para aferição das habilidades do algoritmo com melhoramentos em seu rastreo. Esse valor de referência é usado pela função de pontuação *Skill Score*, como vista no capítulo sobre validação 3.3.1.5, para performar os resultados de ganho ou perda de habilidades de um sistema previsor. Note que nenhuma melhoria de rastreo foi realizada neste momento, apenas a comparação entre os métodos de extrapolação e os limiares que definem os parâmetros básicos de entrada do algoritmo. O objetivo deste estudo foi verificar qual limiar é mais representativo e qual método de extrapolação seria melhor aplicável para análises de rastreo.

A Figura 4.1 exhibe o comportamento do índice de habilidade (eixo *Skill Score*) de cada técnica de extrapolação e parâmetros de rastreo tomando como base o valor de referência (POD e FAR) do método Ctvo-BASE-20-15 (barra cinza). A esquerda (em rosa) são representados os métodos com perda de performance, e a direita (em verde) os métodos com as melhores habilidades. O eixo frequência BIAS é associado aos índices de viés de cada método. Ao analisar a classificação das habilidades (Figura 4.1), nota-se que o método que melhor performou foi Mdd3-BASE-20-30. Neste método utiliza-se a técnica de extrapolação com três vetores antecedentes ao tempo de observação, e deslocam-se as células de chuva um tempo a frente. Ainda, na mesma figura, nota-se que os parâmetros de rastreo de 20 dBZ e 30 píxeis foram aqueles que melhor se adequaram aos dois IOPs, o que mostra que esses limiares são representativos aos eventos em ambas estações chuvosa e seca. O viés (BIAS) foi utilizado para analisar a correspondência entre a previsão média e observação média.

Em todos os métodos com ganho de performance (verde), o valor do BIAS permanece próximo ao valor ideal (BIAS igual à 1), isto indica que estes métodos estão com uma boa performance no que diz respeito às tendências de subestimação (termo em inglês, *underforecast*)  $BIAS < 1$ , e superestimação (termo em inglês, *overforecast*)  $BIAS > 1$  (WILKS, 2011).

Figura 4.1 - Habilidade para os métodos de extrapolação com base nos seus parâmetros de rastreo para o modo operacional básico com dados de radar.



No gráfico os melhores métodos demarcados são denotados na região em verde, os piores em rosa. A região em cinza representa o método de referência.

Fonte: Produção do Autor.

#### 4.2.2 Análise dos métodos de correção vetorial

Um dos focos principais deste trabalho é a aplicação de métodos que visam definir melhor o vetor de deslocamento dos sistemas rastreados. Logo, após avaliação dos parâmetros de rastreo, aplica-se os métodos de correção vetorial com intuito de aumentar os níveis de performance do algoritmo, para assim definir aquele conjunto de ajustes que melhor representem a física dos sistemas precipitantes rastreados via radar. Nesta seção são abordadas as peculiaridades dos métodos de correção vetorial aplicados para processamento durante os IOPs. Além das avaliações de cada período de observação, buscou-se determinar também um método generalizado, que

une os índices estatísticos de ambos os períodos para determinar aquele que seria o sistemas mais próximo de um algoritmo operacional. Neste último é validado a capacidade do algoritmo de ser utilizado em períodos cujas físicas do sistemas são distintas, condição necessárias para algoritmos que precisam ser usados em diferentes localidades sem antes especificar as condições daquele local.

A primeira avaliação leva em consideração todos os métodos de correção vetorial, extrapolação e parâmetros de rastreios do IOP1. A Figura 4.2 exhibe a performance dos métodos de correção tomando como referência os índices de POD do método Ctvo-BASE-20-15. Contabilizaram-se 24 métodos que foram aplicados as três diferentes técnicas de extrapolação, Ctvo, Mdd2 e Mdd3, totalizando 67 modificações ao método de referência. Além disso, são testados também os diferentes limiares de refletividade e tamanho mínimo dos sistemas rastreados, o que ao final totalizam 288 diferentes configurações ao algoritmo. Observa-se na Figura 4.2 que nenhum dos métodos com ganho de performance possui parâmetros de refletividade maiores que 20 dBZ (Métodos de correção na região em verde). O que mostra que os sistemas precipitantes foram fisicamente representativos ao regime de chuva naquele período. Com relação a combinação dos métodos de correção vetorial, destaca-se o método de correção LIM esteve presente em 43 métodos com ganho maior ganho de performance, salientando os 16 métodos com maior performance (24,15% superior ao método de referência). Lembrando que este método usa os limiares internos, mais intensos, para corrigir o vetor de deslocamento. Tal resultado pode estar relacionado com a dinâmica observada na precipitação, que é dependente dos núcleos internos em sistemas precipitantes (HOUZE JUNIOR, 1977; HOUZE JUNIOR, 1997). Isso mostra que possíveis células convectivas embebidas em sistemas estratiformes podem melhor representar a propagação do sistema precipitante .

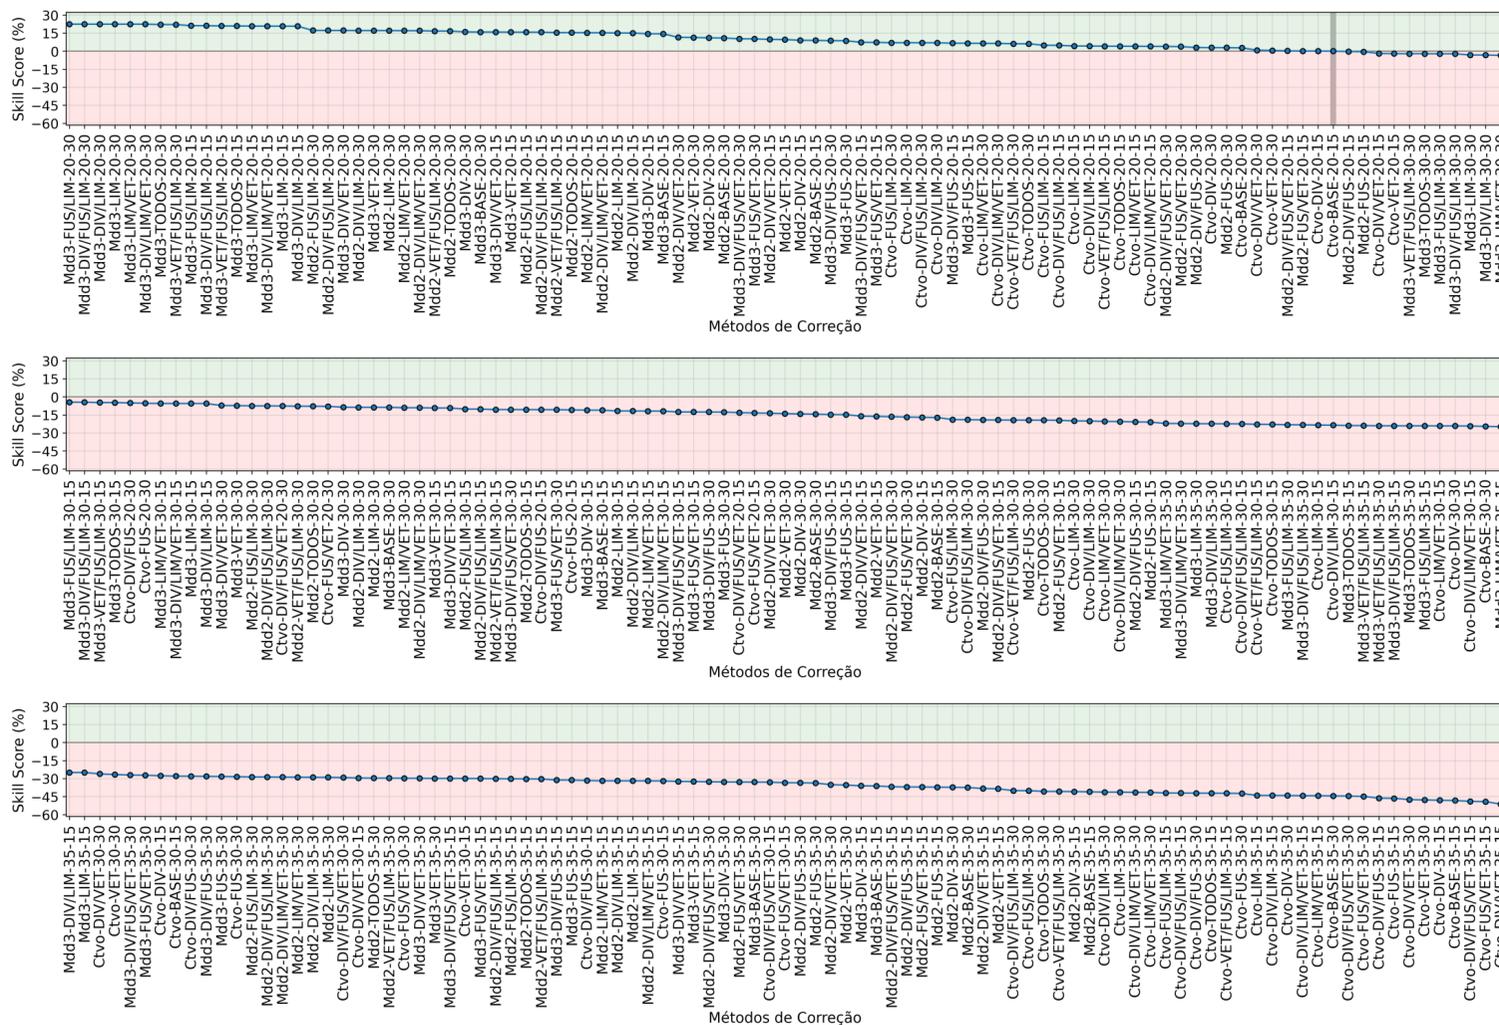
A configuração de ajustes com maior pontuação de habilidade durante o IOP1 foi o Mdd3-DIV/LIM-20-30. As correções vetoriais DIV e LIM para os parâmetros de rastreio com 20 dBZ e 30 píxeis mostraram melhor desempenho na definição do vetor deslocamento. O incremento do DIV deve estar relacionado ao fato de muitas células durante este período terem sido geradas a partir do processo de fragmentação durante a dissipação dos sistemas estratiformes, comum neste período (MACHADO *et al.*, 2018). Cabe ressaltar que o IOP1 é caracterizado como o período chuvoso na Amazônia (NOBRE *et al.*, 2009). Neste período a quantidade de eventos com células precipitantes com grandes regiões estratiformes é bastante conhecido. Uma Tabela D.2 com os índices estatísticos de todos os métodos para o IOP1 foi anexada ao apêndice.



Já para o IOP2, o valor considerado como índice de referência foi o POD do método Ctv0-BASE-20-15 neste período. Na Figura 4.3 foram dispostas as pontuações (*Skill Score*) obtidas por todos os métodos de correção vetorial durante o IOP2. Assim como no IOP1, foram observados que as técnicas de extrapolação Mdd2 e Mdd3 se destacaram, destas, 30 métodos com uso de dois vetores de extrapolação (Mdd2) e 32 métodos com três vetores de extrapolação (Mdd3). A extrapolação conservativa esteve presente em apenas 21 dos melhores métodos de correção. Novamente nenhum parâmetro com limiares de refletividade acima de 20dBZ obteve pontuação superior ao método de referência. O método de correção vetorial que mais foi observado dentre os métodos com ganho de performance novamente foi o método LIM (43 ocorrências), seguido dos métodos DIV e VET com 37 ocorrências e o método FUS com 32 ocorrências. O método de correção com melhor pontuação no IOP2 foi Mdd3-FUS/LIM-20-30, no entanto, a diferença entre os 8 melhores métodos foram ínfimas, sendo estas menor que 1% em ganho de performance.

O IOP2 é descrito como o período dentro da estação seca (NOBRE et al., 2009). A formação de células de chuva mais intensas é uma das características deste período (MACHADO et al., 2018). Como o método LIM utiliza as células convectivas internas mais intensas para corrigir o vetor de deslocamento e o método FUS corrigi os vetores com base em eventos de fusão entre células. Entende-se que os melhores rastreo durante o IOP2 foram obtidos devido a taxas mais elevadas de eventos dinâmicos que ocorrem em células de chuva mais intensas, onde processos de junção por eventos entre multiplas células podem são mais comuns (HOUZE JUNIOR, 2014). Para determinar se o método Mdd3-FUS/LIM-20-30 é realmente o mais adequado para o IOP2, faz-se necessário aprofundar à análise e verificar se parâmetros de rastreo correlacionados aos limiares de refletividade deste método são mais efetivos para o período, o que será visto também na próxima figura.

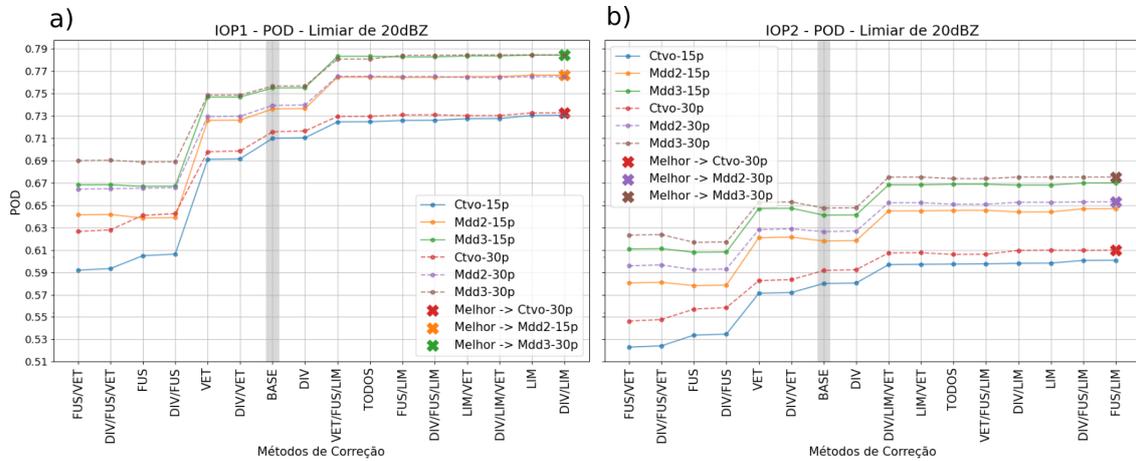
Figura 4.3 - Skill Score para os diferentes métodos de correção vetorial, limiares e extrapolação com referência ao Ctvo-BASE-20-15 para o IOP2.



Como notado anteriormente, o limiar de 20 dBZ foi aquele que melhor representou as chuvas no IOP1. Focando neste limiar e analisando os métodos separadamente nota-se na Figura 4.4 que o processo de extrapolação por MDD3 geralmente apresenta resultados melhores em relação ao MDD2, que por sua vez é melhor que o Ctvo, para a mesma metodologia de correção vetorial. A Figura 4.4 demonstra o comportamento dos índices estatísticos POD nos dois IOPs, para os métodos de correção e técnicas de extrapolação. As linhas contínuas e tracejadas representam a evolução do POD para cada método de correção, partindo do índice mais baixo (esquerda), para o melhor POD (direita). A diferença entre as técnicas de extrapolação fica evidente ao analisar o comportamento do POD para as três técnicas (Ctvo, Mdd2 e Mdd3), no entanto, o parâmetro relacionado ao número mínimo de píxeis por *cluster* apresenta uma dissimetria nos métodos de correção com índices estatísticos mais baixos, principalmente no primeiro IOP (Figura 4.4a). Verificou-se que nestes métodos, os parâmetros relacionados ao número mínimo de píxeis induziu a melhorias significativas ao aplicar as correções no vetor deslocamento, como verificado nos resultados anteriormente. Todas as técnicas de extrapolação (Ctvo, Mdd2 e Mdd3) com 30 píxeis foram as melhores abordagens para método de correção DIV/LIM para o IOP1. Contudo, nos melhores métodos essas diferenças foram ínfimas. No IOP2 (Figura 4.4b), foi observado o mesmo padrão, entretanto, as diferenças um pouco mais perceptíveis entre 30 e 15 píxeis. Nota-se ainda pela Figura 4.4 que os valores de POD foram superiores para o IOP1 em relação ao IOP2. Tal resultado deve estar associado a uma dinâmica mais complexa na propagação de sistemas convectivos profundos e uma maior ocorrência de células isoladas durante a estação seca.

De modo a analisar também os efeitos de limiares de refletividade mais intensos, como aqueles associados a iniciação convectiva, importantes ao rastreamento de tempestades severas que produzem descargas elétricas. A Figura 4.5, assim como a figura anterior, mostra o POD para um limiar de 35 dBZ no CAPPI de 3 km. Este limiar representa células de chuva com características convectivas (HOUZE JUNIOR, 1997; BROWNING, 1980). Os resultados apresentados na Figura 4.5 mostram que o padrão de comportamento das linhas que representam o valor de POD para os métodos de correção, demonstraram características um pouco diferentes para as técnicas de extrapolação Ctvo e Mdd2 com 30 e 15 píxeis. Apenas poucos métodos (12 métodos) foram superiores ao modo operacional BASE (linha cinza) no IOP1 (Figura 4.5a). Além disso, o POD em ambos os IOPs não apresentou valores acima de 56%, e isto caracteriza-se por uma taxa de precisão regular. Tal resultado mostra que, para células convectivas a dinâmica de propagação é mais complexa e processos de rastreamento

Figura 4.4 - a) Resultados de POD para métodos de correção para o limiar 20 dBZ no IOP1. b) Valores de POD para os métodos de correção aplicados ao limiar de 20 dBZ no IOP2.

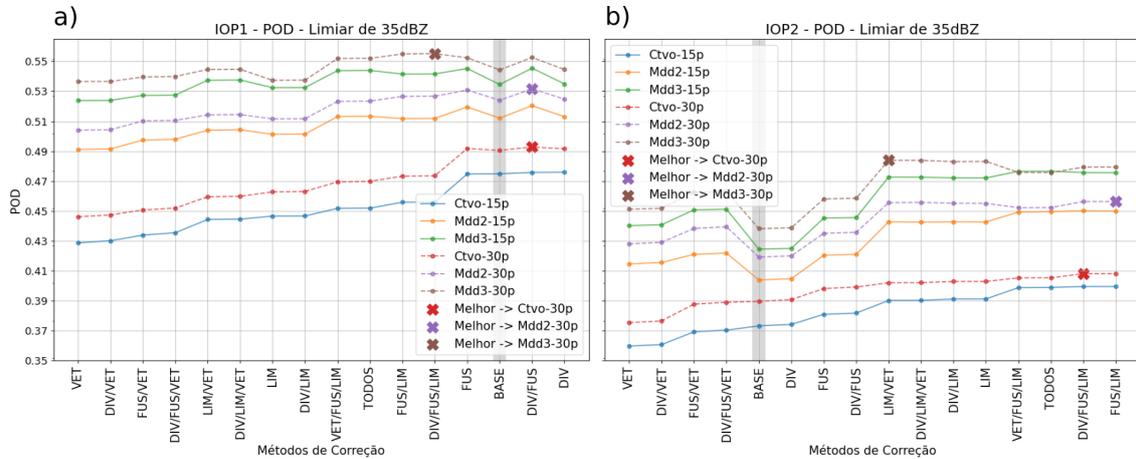


Fonte: Produção do Autor.

precisam levar em consideração ainda mais informações e correções. Como pode ser observado nos resultados para o IOP1, foram necessárias todas as correções vetoriais para no mínimo 30 píxeis de áreas para conseguir o melhor POD (i.e. 56%). Para o IOP2 (Figura 4.5b) os resultado foram ainda mais insatisfatórios, onde um POD de aproximadamente 50% foi observado para uma combinação de LIM e VET para área mínima de 30 píxeis. Em ambas populações, o melhor método de extrapolação foi o MDD3.

Como notamos nas análises anteriores, existem combinações específicas para cada IOP, inerentes aos sistemas que ali de desenvolvem. A próxima figura mostra o que seria um conjunto de dados que representa a junção de ambos IOPs. O objetivo desta análise é determinar um método generalizado que possa ser utilizado como configuração global de rastreo de sistemas precipitantes sobre a região da bacia amazônica. Tal metodologia deveria englobar características estratiformes e convectivas associada a gênese das chuvas na região (BROWNING, 1980; HOUZE JUNIOR, 1997; GARSTANG et al., 1994). Tal abordagem é geralmente utilizada por uma vasta gama de algoritmos de rastreo (DIXON; WIENER, 1993; VILA et al., 2008), onde raramente existe a possibilidade de alterar padrões de monitoramento de modo simples, ou seja, sem a necessidade de grande modificações no código ou da ajuda do desenvolvedor/especialista. Que neste algoritmo pode ser habilitado em seu *namelist*.

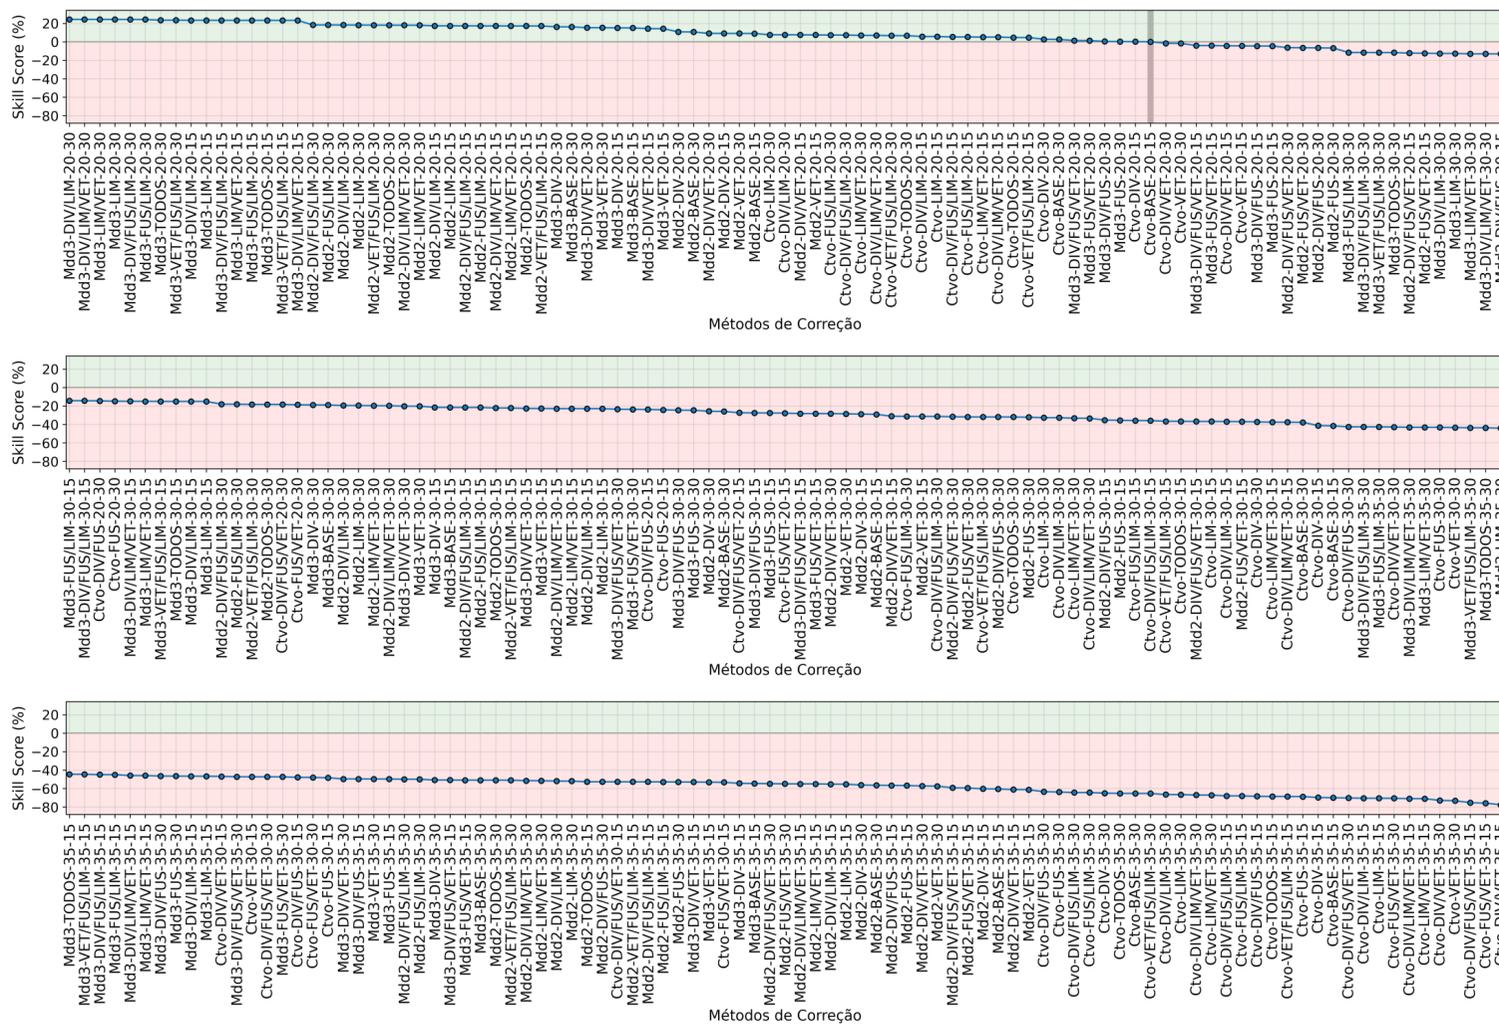
Figura 4.5 - a) Resultados dos métodos de correção para o limiar 35 dBZ no IOP1. b) Valores de POD para os métodos de correção aplicados ao limiar de 35 dBZ no IOP2.



Fonte: Produção do Autor.

Para isso, utilizou-se a agregação dos parâmetros estatísticos (*Acerto e Falso Positivo*) de ambos os IOPs para calcular os indicadores estatísticos de POD dos dois períodos concatenados. Levando em consideração o método base (Ctvo-BASE-20-15) para esta nova população, A Figura 4.6 ilustra o comportamento dos métodos de correção do vetor deslocamento. Dentre todos os métodos de correção combinados (totalizando 288 combinações) 73 apresentaram pontuação de habilidade maior que o método de referência. O melhor ajuste foi observado para a combinação Mdd3-DIV/LIM-20-30, com 24,248% superior ao método de referência. A diferença entre os 16 melhores combinações, todas com método de extrapolação Mdd3, foi de apenas 1,07%. O valor de POD para o método Mdd3-DIV/LIM-20-30 foi de 74%, o que mostra uma boa taxa de precisão. Principalmente quando se leva em conta que este é o índice generalizado de dois períodos de observação concatenados, que englobam uma grande variabilidade de ocorrências de sistemas precipitantes com diversas dinâmicas de propagação.

Figura 4.6 - Skill Score para os diferentes métodos de correção vetorial, limiares e extrapolação com referência ao Ctvo-BASE-20-15 para o IOP1+IOP2



Os resultados aqui apresentados mostram que os três conjuntos de dados apresentaram características distintas. Apesar de todas as melhores combinações levarem em consideração a correção por limiar interno, as características do IOP1 foram predominantes e método de correção por divisão foi mais importantes no período concatenado. Talvez uma consequência da maior frequência de divisões do que fusões nos eventos de chuva durante a estação chuvosa. Neste sentido, como as características observadas entre ambas estações são distintas, um único método de rastreamento não representaria a realidade local. Neste sentido, as melhores combinações foram escolhidas para definir o rastreamento em cada IOP.

### 4.2.3 As características médias dos sistemas precipitantes rastreados durante os IOPs

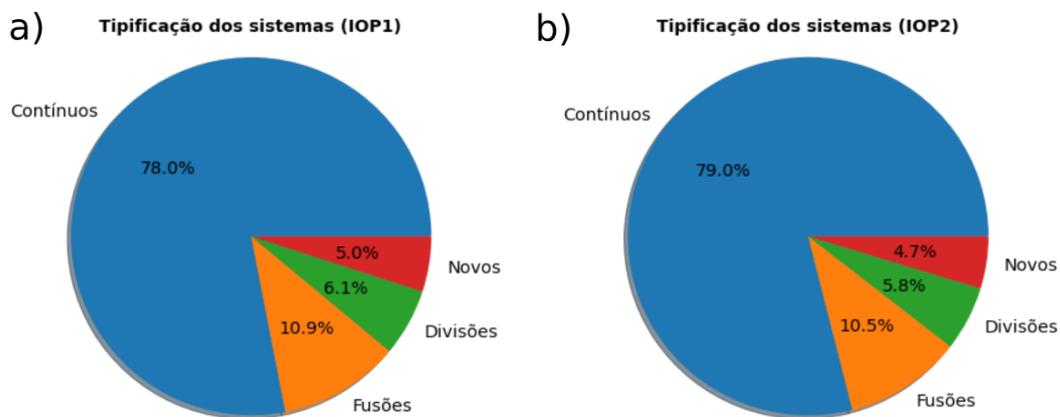
De modo entender como os sistemas precipitantes se comportaram ao longo do experimento GoAmazon, análises baseadas na contabilização dos rastreios foram realizadas. O intuito é definir as características de tempo de vida, área e trajetória desses sistemas durante o seu ciclo de vida. Tais informações podem servir de subsídio para outros estudos de modo a definir os padrões de tempo que influenciam nos processos atmosféricos e de superfície, como distribuição de aerossóis, balanço de gases do efeito estufa e queima de biomassa. Tais características podem ajudar a definir as condições necessárias a formação de eventos mais severos, como tempestades, e ajudar em seu monitoramento e previsão por órgãos de tomada de decisão. Logo, nesta seção foi utilizado os resultados dos métodos com as melhores habilidades no modo de rastreamento e previsão, sendo estes os métodos:

- Mdd3-DIV/LIM-20-30 no IOP1.
- Mdd3-FUS/LIM-20-30 no IOP2.

Para investigar as características médias dos sistemas precipitantes rastreados durante os períodos estudados, utilizou-se dos tipos de ocorrências para designar o que aqui neste trabalho chamou-se grupos de famílias. Um grupo de família relaciona os identificadores (UID) das células rastreadas durante o seu ciclo de vida com base nos eventos de continuidade, fusão e divisão entre as células de chuva. Durante o rastreamento foram observados 20829 (IOP1) e 21683 (IOP2) *clusters* para todas as famílias observadas. Na Figura 4.7 exibe-se o percentual de classificação dos tipos de ocorrência. Nota-se que a distribuição apresenta que os tipos Contínuos são a maioria dos eventos classificados em ambos os IOPs, seguidos de eventos de Fusões,

Divisões e Novos. Nota-se uma semelhança na proporção de distribuição dos tipos de eventos ocorridos por *cluster* nos IOPs. Contudo, para entender as características físicas de um sistemas é preciso garantir que as famílias, ou seja, o conjunto de *clusters* do mesmo sistema precipitante ao longo do seu ciclo de vida, tenham a mesma tipificação. Uma vez que a dinâmica dos sistemas que são contínuo diferem daqueles que apresentam junção e divisão (VILA et al., 2008).

Figura 4.7 - Ocorrência de *cluster* chuva por tipo (contínuos, fusão e divisão) durante os IOPs 1 (a) e 2 (b).

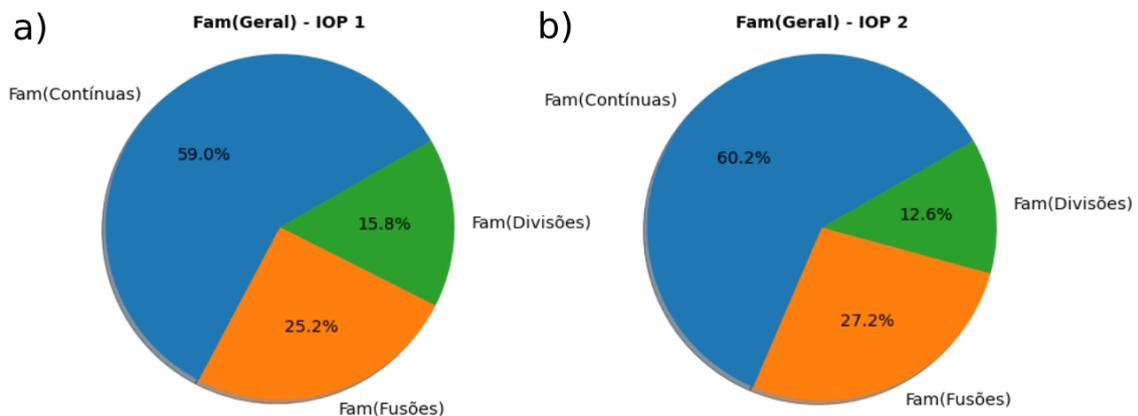


Fonte: Produção do Autor.

Com base tipificação dos *clusters* ao longo do seu ciclo de vida foram categorizados os grupos de famílias. O primeiro destes representa o grupo Fam(Contínuas), que está relacionado apenas à eventos tipificados como contínuos no decorrer do seu ciclo de vida. Os grupos de famílias com eventos mais dinâmicos aqui são descritos como Fam(Divisões) e Fam(Fusões), são os grupos de famílias que apresentam um ou mais eventos de divisões ou fusões ao longo do seu ciclo. Nestes grupos apenas são agrupadas as ocorrências relacionadas a tipificação referente ao grupo, por exemplo: No grupo Fam(Divisões) consideram-se pertencentes as ocorrências tipificadas como Novos, Contínuos e Divisões, de modo que, eventos de Fusões não pertencem à este grupo. Para o grupo Fam(Fusões) são aplicadas as mesmas regras que o grupo anterior, alterando as ocorrências de divisões por fusões. Um quarto grupo foi designado como Fam(Geral) e engloba todas os tipos de famílias e dá uma ideia do comportamento médio geral dos sistemas em cada IOP. Nesta classe podem ocorrer

sistemas não contabilizados nesta figura, que são aqueles que apresentam todas as tipificações listadas. Na Figura 4.8 exibe-se o percentual relacionado aos grupos de famílias após sua classificação, estes grupos são a base para as próximas análises e sua distribuição é fundamental para compreender as características médias rastreadas pelo algoritmo. Nota-se na Figura que o número de eventos de fusões são maiores no IOP2 (Figura 4.8a) do que no IOP1 (Figura 4.8b), principalmente em detrimento as divisões. O que mostra que as técnicas de correção vetorial corroboraram com a dinâmica de cada período. Uma vez que eventos mais convectivos, comuns no IOP2, podem aumentar o número de fusões ao longo do seu ciclo de vida. Enquanto que, o processo de fragmentação de nuvens mais estratiformes, frequentes no IOP1, pode ser comum devido a sua dinâmica que não promove mecanismos de alto alimentação, como as frentes de rajada (COTTON; ANTHERS, 1992). Durante o IOP1 foram observadas 1050 famílias, enquanto o IOP2 teve 1127. O maior número de família no IOP2 pode se dever ao fato que na estação seca os eventos convectivos mais frequentes geralmente apresentam ciclo de vida menor, a medida que o IOP2 apresenta eventos mais estratiformes que geralmente apresentam ciclo de vida mais longo. Maiores detalhes serão apresentados a seguir.

Figura 4.8 - Ocorrência de famílias (sistemas precipitantes) por tipo (contínuos, fusão e divisão) durante os IOP1 (a) e IOP2 (b).



Fonte: Produção do Autor.

A Figura 4.9 mostra os *boxplots* para os grupos de famílias classificados anteriormente associados a ciclo de vida e tamanho dos médio dos sistemas. A Figura 4.9ab mostra que a duração do ciclo de vida dos eventos no grupo Fam(Geral)

(cinza) apresentou valores médios (linhas tracejadas vermelhas) de  $\sim 1,95$ h de duração ( $\sim 01h54m47s$ ) para o IOP1 e  $\sim 1,97$  horas de duração ( $\sim 01h58m11segundos$ ) no IOP2, e a mediada (chanfro dos boxplots) em ambos os IOPs para este grupo de famílias foi de  $\sim 1,12$ h. Estes índices retratam a duração média dos eventos de modo geral, os valores encontrados estão dentro dos índices esperados para os períodos de observação, no trabalho Pereira (2019, p.70). Naquela pesquisa as autoras utilizaram os mesmos dados e períodos de observação, no entanto, para rastreamento foi aplicado o algoritmo ForTraCC (VILA et al., 2008) com as configurações de limiares para 20dBZ no nível de 2,5 km. Na Figura 4.9cd são exibidos os valores de tamanho médio das células por grupo de família, avaliando o grupo Fam(Geral) nota-se uma diferença significativa no tamanho médio das células para os IOPs estudados, onde, a área das células no IOP 1 apresentou maiores proporções. Como citado anteriormente, na avaliação das correções do vetor deslocamento do algoritmo, sabe-se que este é um período marcado por grandes áreas de precipitação sobre a região da bacia Amazônica associadas a regiões estratiformes detectáveis por limiares de 20 dBZ.

Com relação ao grupo de famílias que ocorrem pelo menos uma fusão, Fam(Fusões) (cor laranja), que abrange eventos dinâmicos de propagação mais complexa, com fusão de células adjacentes. Nota-se na Figura 4.9 que o ciclo de vida para o IOP1 foi muito similar ao encontrado no grupo Fam(Geral), variando apenas em sua média e limites superiores,  $\sim 2,03$  horas e  $\sim 3,7$  horas, respectivamente. Este é um indicativo de que os eventos que sofreram fusões em algum momento do seu ciclo de vida foram frequentes no IOP1, contudo, não dominantes como visto em resultados anteriores. Já no IOP2, o grupo com fusões apresentou duração superior aquelas de outras classes, mas menor do que aqueles no IOP1. Além disso, os eventos contínuos foram também mais longos do que aqueles observados no IOP1 (Figura 4.9a). O grupo Fam(Divisões) (diagrama de caixa verde) na Figura 4.9 exibe o comportamento médio entre as classes observadas. Os resultados para o ciclo de vida deste grupo de famílias mostra que os comportamentos médios de duração foram sutilmente diferentes entre os IOPs, sendo estes  $\sim 1,76$  horas (IOP1) e  $\sim 1,59$  horas (IOP2) (Figura 4.9b). A maior diferença entre os ciclos de vida dos sistemas com divisão foi constatada apenas nos limites superiores no IOP2, onde um maior número de sistemas apresentou duração superior a 3h (desconsiderando os *outliers*). Do ponto de vista geral, a duração média entre os períodos foi próxima, com leve vantagem para o IOP2.

No que diz respeito as áreas médias dos sistemas rastreados, a Figura 4.9 mostra que na média os sistemas precipitantes são maiores no IOP1 (Figura 4.9c) do que

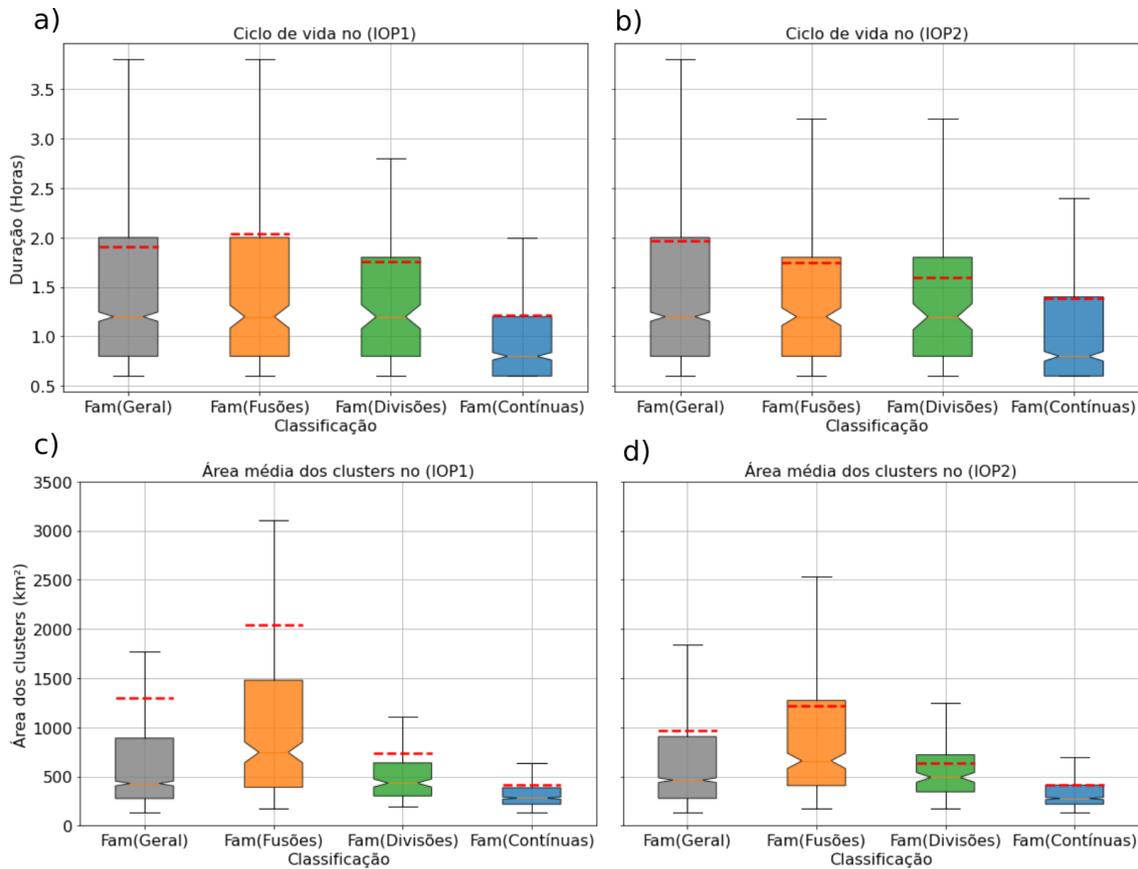
no IOP2 (Figura 4.9d) para todas as classes, como esperado pela frequência de sistema estratiformes. Com relação ao grupo Fam(Fusões), nota-se uma discrepância na média de tamanho dos *clusters* entre os IOPs, sendo os valores médios com aproximadamente  $\sim 2041\text{km}^2$  no IOP1 e  $\sim 1218\text{km}^2$  para o IOP2. A diferença no tamanho dos *clusters* para este grupo indica que durante o IOP1 os eventos de fusão provocaram um aumento ainda maior na área do sistema, uma consequência do tamanho médio maior dos *clusters*. Já os eventos de divisão, os tamanhos médios encontrados para as áreas foi de  $\sim 733\text{km}^2$  no IOP1 e  $\sim 636\text{km}^2$  para o IOP2. Sabe-se que um maior processo de divisão entre as células precipitantes representa maiores taxas de fragmentação dos indivíduos, logo uma diminuição no tamanho de área dos *clusters* é esperado para este grupo, e possivelmente associada à dissipação dos sistemas atuantes na Amazônia.

Eventos de continuidade representam a maior parcela de ocorrências e caracterizam os indivíduos do grupo Fam(Contínuas). A duração média deste grupo foi de aproximadamente  $\sim 1,21$  horas (IOP1) e  $\sim 1,38$  horas (IOP2) com áreas médias de seus *clusters* em torno de  $\sim 420\text{km}^2$  (IOP1) e  $\sim 421\text{km}^2$ . Contudo os indivíduos do grupo Fam(Contínuas) não representam as famílias com maior duração ou maiores áreas em ambos os IOPs. Isto porque, a propagação das células de chuva na região Amazônica sofre interações de diversos mecanismos como, brisas marinhas (KOUSKY, 1980), brisas fluviais (OLIVEIRA; FITZJARRALD, 1994), circulação de grande escala (GARSTANG et al., 1994) e etc. Estas interações acabam provocando um alto índice de eventos mais dinâmicos (Fusões e Divisões) e por isso, o desenvolvimento do grupo Fam(Contínuas) não apresentou índices maiores de duração do ciclo de vida e tamanho das células.

De maneira geral, os resultados obtidos demonstram que os sistemas precipitantes rastreados que possuem maior duração em seu ciclo de vida também apresentam as maiores áreas. O comportamento médio observado nos grupos de família indica que a física envolvida nos eventos com dinâmicos mais complexa (i.e. Fusão e Divisão) influencia diretamente no tempo de vida e tamanho da área. Constata-se que eventos de fusão notoriamente influenciaram nos resultados para os maiores ciclos de vida e maiores áreas dentre todos os grupos, por outro lado, sistemas com baixos Contínuos representam aqueles sistemas com as menores durações e menores áreas.

A propagação de sistemas precipitantes é um assunto abordados por diversos autores (NEWTON; FANKHAUSER, 1975; MONCRIEFF, 1978; COTTON; ANTHES, 1992; CORFIDI et al., 1996; LAURENT et al., 2002). Questões sobre os aspectos relacionados

Figura 4.9 - Duração em horas para os tipos de famílias no IOP1 (a) e IOP2 (b) do Radar. Tamanho médio dos sistemas precipitantes com base em suas famílias no IOP1 (c) e IOP2 (d) do Radar.



Fonte: Produção do Autor.

as forçantes envolvidas no movimento de células de chuva são temas em plena discussão no meio científico. De maneira generalizada a literatura sobre este assunto limita-se a responder questões envolvendo principalmente aspectos de propagação de sistemas mais organizados ou em maior escala. No entanto, o algoritmo desenvolvido neste trabalho possibilita a extração dos vetores de deslocamento dos *clusters* permitindo que uma análise de propagação das células precipitantes possa ser realizada para cada grupo de família. Na Figura 4.10 exibe-se os esquemas (Rosa dos Ventos) de propagação para os grupos de famílias classificados anteriormente para os IOPs. Durante a estação chuvosa (Figura 4.10a) a propagação média dos *clusters* ocorreu de Nordeste para Sudoeste com velocidades médias de  $\sim 30,7$  km/h. Todas as classes tiveram direção predominantes semelhante, contudo, cabe ressaltar que os eventos de divisão apresentaram uma maior variação. Tal resultado pode indicar

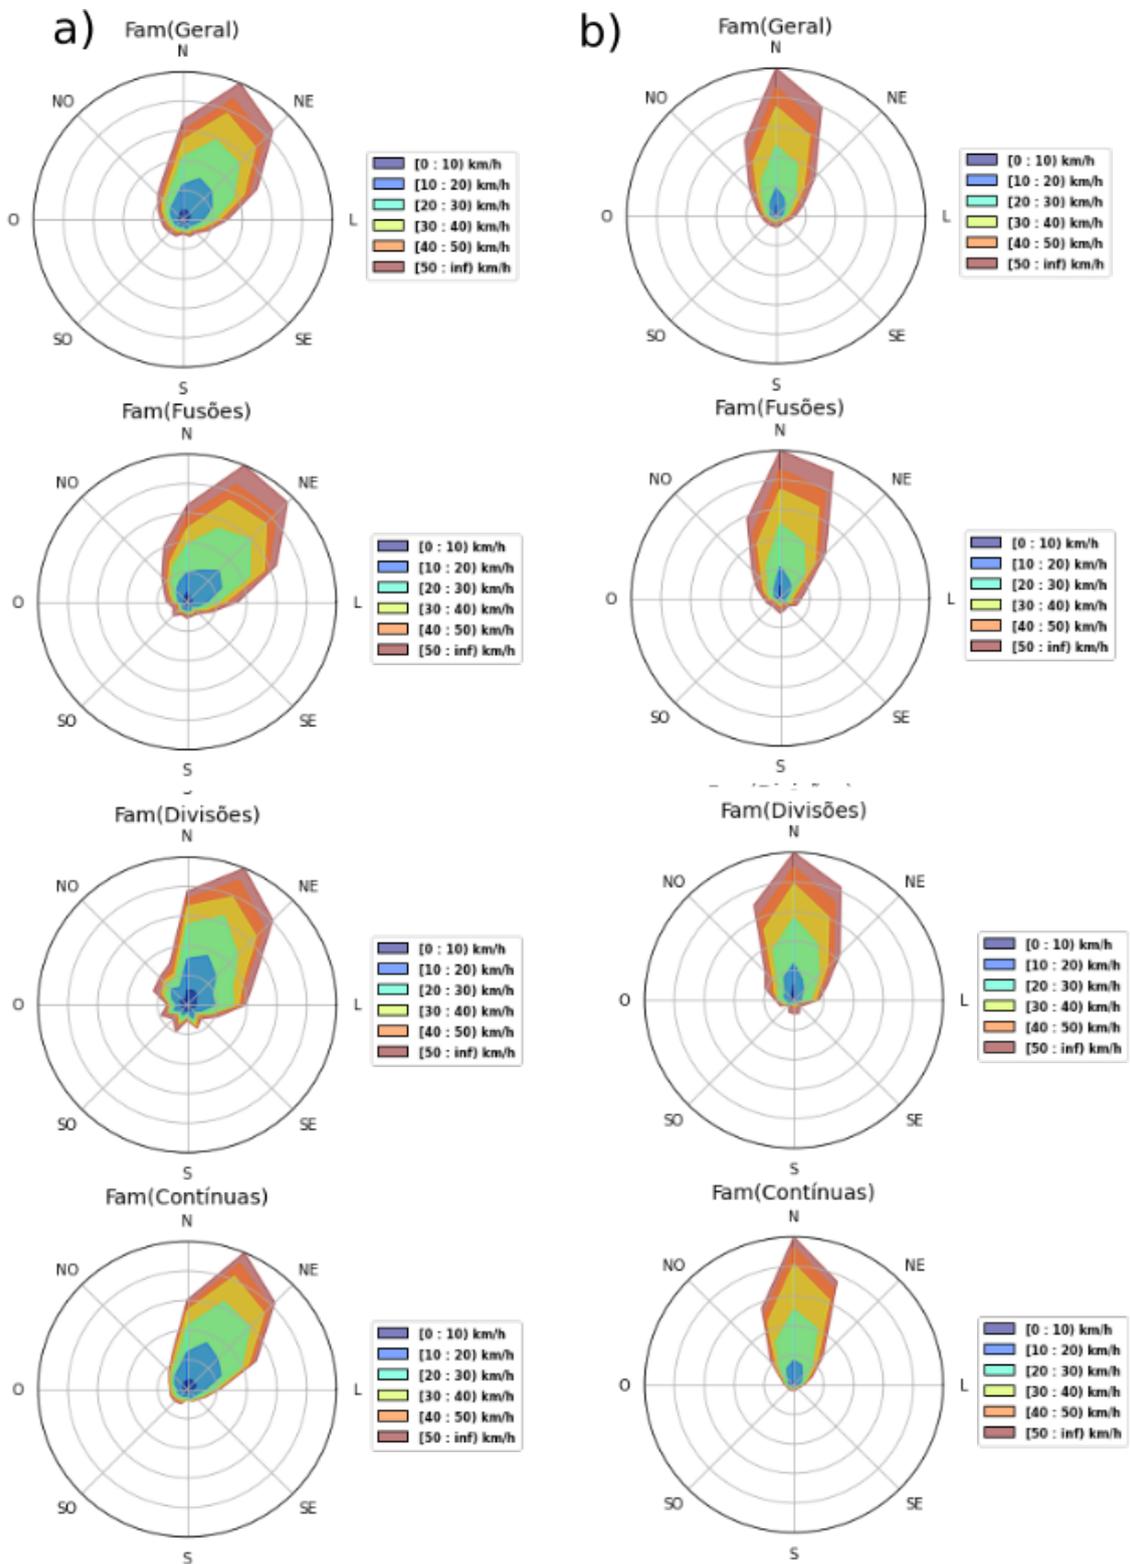
que na divisão os *clusters* podem adquirir direções diferentes. Já no IOP2 (Figura 4.10b), a direção média dos sistemas ocorreu de Norte para Sul, com uma leve inclinação de Nordeste, com velocidades médias de  $\sim 35.14$  km/h. Os demais grupos de famílias apresentaram dinâmicas distintas entre si, característica que pode ser associada as diferentes dinâmicas de propagação. Como notado na Tabela 4.2, onde são observadas as velocidades médias para cada classe, os sistemas que ocorrem durante a estação seca apresentam velocidades mais altas do que aqueles na estação chuvosa. Tal resultado pode estar associados a mecanismos de propagação mais eficientes, alimentados por correntes ascendentes e descendentes intensas dentro de nuvens convectivas profundas (COTTON; ANTHES, 1992). Dentre os sistemas tipificados, aqueles que apresentam fusão são os mais rápidos, com velocidade média de  $\sim 36,6$  km/h. Nota-se ainda que os sistemas contínuos, além de serem menores, mais curtos em tempo de vida, também são mais lentos. Tal informação pode servir de referência para limitar os deslocamentos dos sistemas precipitantes em modelos de previsão de tempo, evitando comportamento não realísticos.

Tabela 4.2 - Velocidade média dos grupos de famílias durante os IOPs 1 e 2.

<b>Grupo</b>	<b>Vel. média IOP1 (km/h)</b>	<b>Vel. média IOP2 (km/h)</b>
Fam(Geral)	30,69	36,89
Fam(Fusões)	34,34	36,59
Fam(Divisões)	28,89	35,82
Fam(Contínuas)	24,73	31,32

Fonte: Produção do Autor.

Figura 4.10 - Propagação dos grupos de famílias durante o IOP 1 (a) e IOP 2 (b) para o rastreo via radar.



Fonte: Produção do Autor.

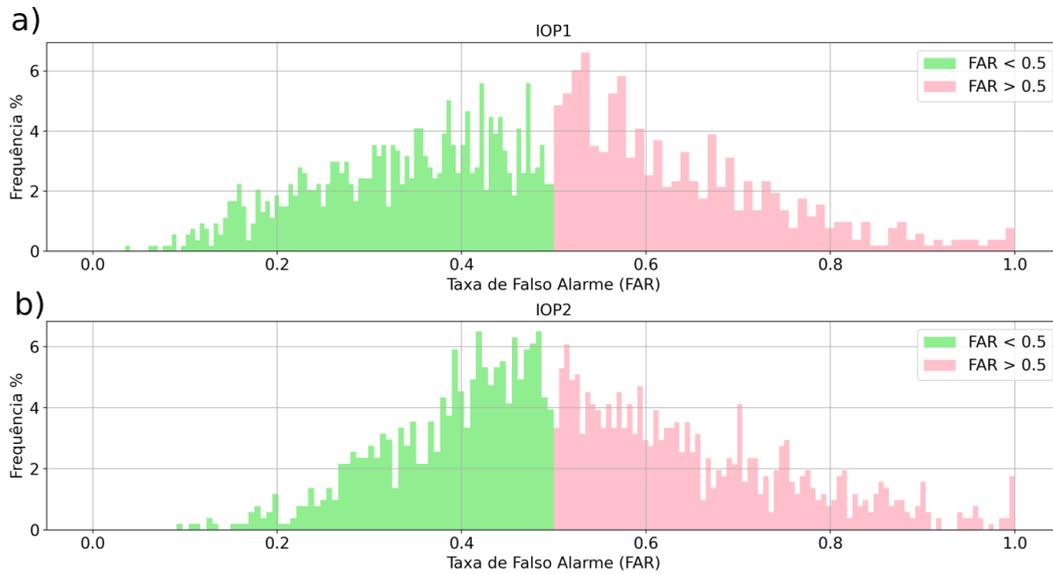
#### 4.2.4 Características morfológicas que impactam na performance da previsão

Uma questão importante no desenvolvimento de um algoritmo de rastreamento e previsão está relacionada à determinação de suas incertezas. Em meteorologia é sabido que sistemas precipitantes podem oferecer um desafio à sua previsão devido às diferentes dinâmicas envolvidas em sua propagação (CALHEIROS, 2008). Neste sentido, analisar os impactos das características morfológicas dos sistemas, como seu tamanho, tempo de vida e intensidade são de suma importância em um sistema de *nowcasting*. Como para esta análise é necessário ter controle sobre o deslocamento individual de cada família, apenas o índice FAR é possível de ser calculado. Tal análise seguiu os mesmos critérios apresentados em Fazolo (2019), exceto que nele foram analisados eventos de descargas elétricas.

Como supradito, nesta subseção avalia-se os índices estatísticos de falso alarme (FAR) para o grupo Fam(Geral), uma vez que a ideia é analisar como seria um sistema de previsão sem tipificação de eventos. Os indivíduos desta categoria de família foram divididos em dois subgrupos ( $FAR < 0,5$  e  $FAR > 0,5$ ). Estes subgrupos representam famílias que ao longo do seu ciclo de vida obtiveram os melhores ( $< 0,5$ ) e os piores ( $> 0,5$ ) índices de FAR. Partindo da análise destes subgrupos, buscou-se compreender as características médias dos eventos classificados como melhores e piores casos.

Com a relação à distribuição, o número de famílias com índices FAR médio  $< 0,5$  foi de 1062 no IOP1 e 781 no IOP2. As famílias com os piores índices ( $FAR > 0,5$ ) somaram 524 para o IOP1 e 897 no IOP2. A distribuição de frequência destes eventos pode ser vista na Figura 4.11. O intervalo que representa a largura de cada barra (em inglês, *bins*) do histograma ao longo do eixo FAR, foi distribuído em intervalos de 10% das observações de cada grupo. Vale ressaltar que embora os grupos ( $FAR < 0,5$  e  $> 0,5$ ) sejam exibidos na mesma figura, sua distribuição é independente. Comparando os melhores casos dos IOPs ( $FAR < 0,5$ , verde) a distribuição de frequência das famílias mais próximas do valor ideal (igual à 0) foi observada no IOP1, e comparando os piores casos ( $FAR > 0,5$ , rosa) nota-se que o IOP2 possui a distribuição dos índices mais próximos do valor não desejado (igual à 1). Tal resultado é esperado, uma vez que as tempestades mais frequentes na estação seca apresentam dinâmica mais complexa, que por sua vez gera maior incerteza, como amplamente discutido anteriormente.

Figura 4.11 - Distribuição das ocorrências para famílias com os melhores e piores casos durante os IOP1 (a) e IOP2 (b).



Fonte: Produção do Autor.

Um ponto importante quando se monitora um sistema precipitante é definir o sua duração, pois quando melhor organizados em grande escala, podem durar mais tempo (MULHOLLAND et al., 2018). Logo, a próxima análise aborda sobre o tempo de duração do ciclo de vida das famílias para os melhores e piores casos. Na Figura 4.12ab são apresentados os *boxplots* com a duração dos ciclos de vida para essas condições durante os IOPs. Nota-se na Figura 4.12ab que os eventos que foram melhor previstos apresentam tempo de vida mais duradero em ambos IOPs, em detrimentos aos sistemas mais curtos que são um desafio a previsão. Esses resultados corroboram com aqueles encontrados por Fazolo (2019) para sistemas de tempestades elétricas. A diferença entre os sistemas melhores previstos dos piores chega a aproximadamente 50 minutos de duração no IOP1 e 1 hora no IOP2. Durante o IOP2 os sistemas apresentam tempo de vida mais longo em ambos os casos em comparação ao IOP1, contudo, com maior amplitude. Resultado que mostra uma maior incerteza para eventos que ocorrem durante este período.

Como susodito, investigar as características morfológicas relacionados ao tamanho das células de chuva são importante para determinar os melhores aspectos relacionados ao rastreo dos sistemas precipitantes. A Figura 4.12cd apresenta os diagramas

de caixa (*boxplots*) relacionados a área das células para as famílias com os melhores e piores índices de FAR nos IOPs 1 e 2. Avaliando os melhores casos (diagramas verde), nota-se que o limite superior do diagrama no IOP1 apresentou os maiores índices de áreas por células, no entanto, os valores para os quartis e mediana foram próximos em ambos os IOPs. A diferença relacionada ao limite superior do diagrama de melhores casos no IOP1 (Figura 4.12c) é um indicativo que células com maiores áreas foram melhor rastreadas durante este período. Este resultados mostram que famílias com maiores extensões de área por célula são melhor rastreadas, uma possível consequência de uma melhor organização dinâmica. Os piores casos (diagramas rosas) confirmam que células menores estão associadas com famílias de menor tamanho, ou seja, mais complexas de rastrear devido a sua fraca dinâmica de propagação.

A severidade de um sistema é outro fator que deve ser levando em consideração durante o monitoramento e previsão de eventos meteorológicos (CALHEIROS et al., 2016). No caso de sistemas precipitantes rastreados por radar, são os valores de refletividade que definem se um sistema é mais intenso ou não. Para encontrar os resultados pertinentes à refletividade média das famílias, calculou-se a média da refletividade média dos *clusters*, segundo a seguinte Equação 4.1 :

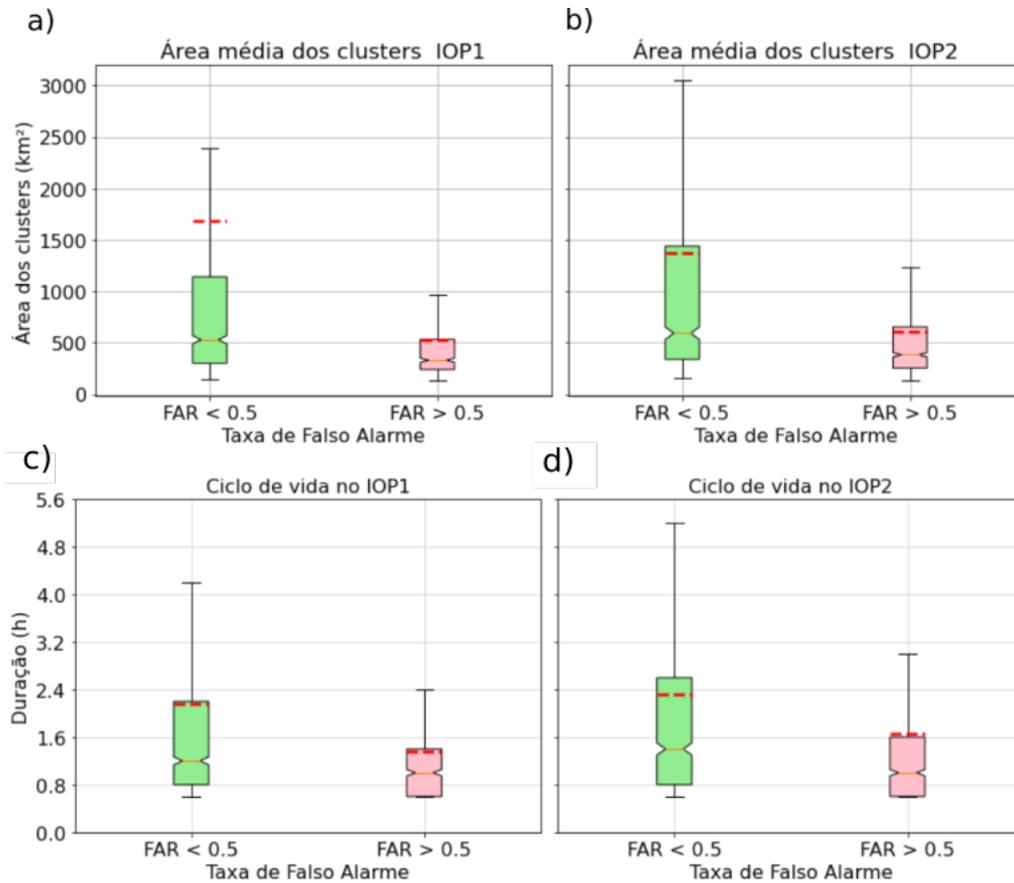
$$\bar{Z} = \frac{1}{n} \sum_{t=0}^n (10^{dBZ_t/10}) \quad (4.1)$$

onde,  $\bar{Z}$  é a média dos valores de refletividade dos *clusters* em ( $mm^6/m^3$ ). Em seguida, é convertida a refletividade para dBZ, dado pela seguinte Equação 4.2:

$$dBZ = 10 * \log_{10}(\bar{Z}) \quad (4.2)$$

A Figura 4.13 exhibe os diagramas de caixa associados a média de refletividade das famílias durante os IOPs 1 e 2. O valor médio de refletividade para os casos no IOP1 foi de  $\sim 26,8$  dBZ para os melhores casos e  $\sim 26$  dBZ nos piores. A diferença de valores neste IOP foram suaves, uma consequência da maior frequência de sistemas estratiformes. Apenas com esta variação não é possível deduzir uma diferença clara entre os melhores e piores casos no IOP1. Por outro lado, no IOP2 os índices de refletividade mostram valores mais elevados ( $\sim 30,3$  dBZ melhores casos), indicando que sistemas com maior intensidade que ocorrem neste período são melhor previstos. Acredita-se que a medida que limiares mais intensos são usados no rastreo, mais

Figura 4.12 - Duração do ciclo de vida das famílias para os melhores e piores casos rastreados via radar para durante o IOP1 (a) e IOP2 (b). c) Área média para os melhores e piores casos durante o IOP1. d) Área média para os melhores e piores casos durante o IOP2.

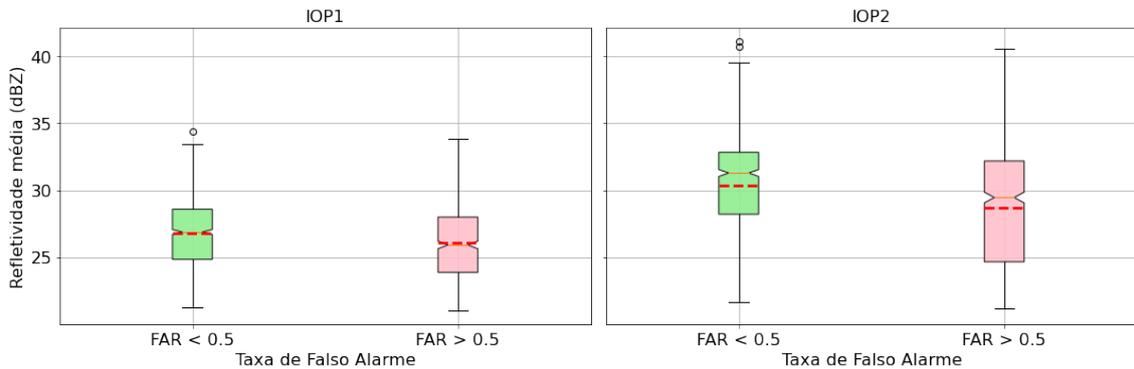


Fonte: Produção do Autor.

evidentes poderiam ser as diferenças. Contudo, o escopo dessa análise não se limitou a eventos de tempestades, mas todos aqueles precipitantes.

Para um meteorologista em um ambiente de monitoramento, determinar as trajetórias preferenciais de sistemas precipitantes que ocorrem em uma determinada região é de suma importância, pois a partir disto é possível antecipar as condições de deslocamento de um sistema. Para representar as características de propagação dos sistemas nos melhores e piores casos utilizou-se o conceito matemático associado aos campos vetoriais de movimento das células precipitantes. Partindo deste princípio, avaliou-se na Figura 4.14 o comportamento dos vetores de deslocamento para os grupos com os melhores e piores índices estatísticos ( $FAR < 0,5$  e  $FAR > 0,5$ ).

Figura 4.13 - a) Refletividade média para os melhores casos durante o IOP1. b) Valores de refletividade média do radar nos melhores e piores casos durante IOP2.



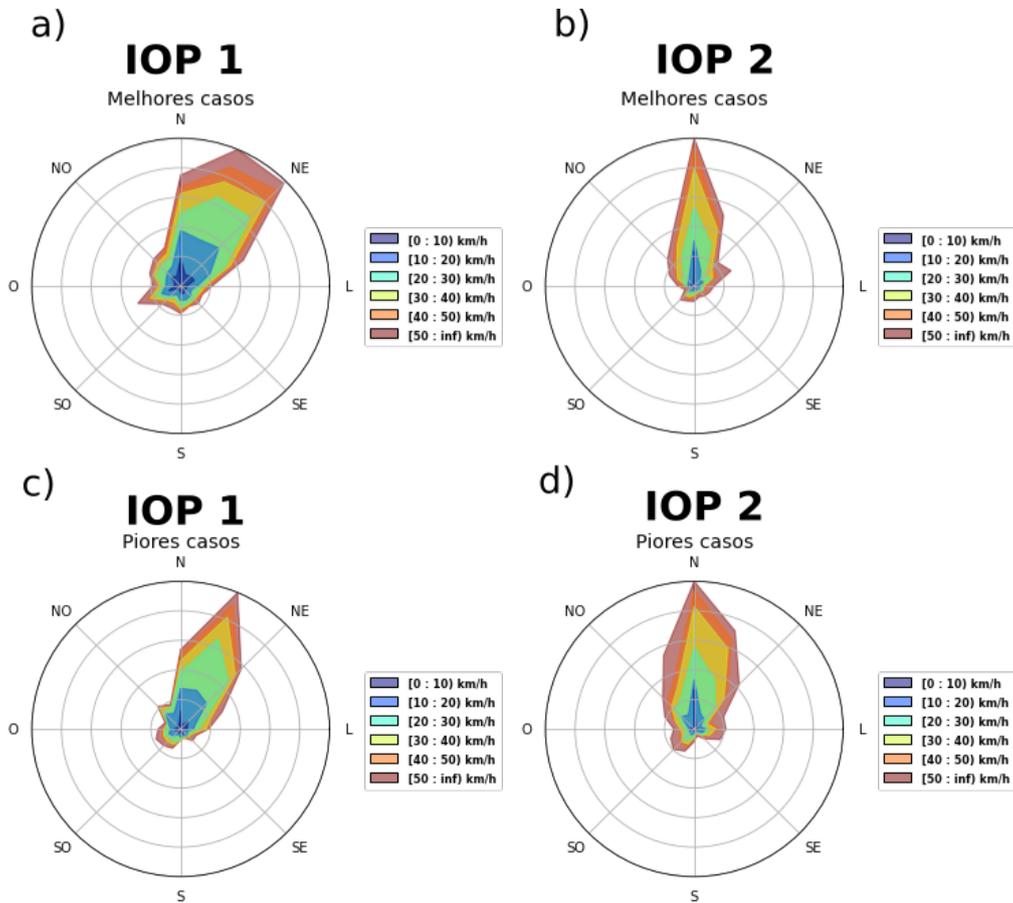
Fonte: Produção do Autor.

O padrão de propagação para os casos no IOP1 demonstra uma diferença notável nos campos de direção entre os melhores e piores casos. Os melhores casos apresentaram características cinemáticas mais esparsas nos índices associados a direção de movimento das células. Como avaliado nos resultados anteriores, o IOP1 corresponde a observações feitas durante a estação chuvosa na Amazônia, e neste período às características morfológicas dos sistemas apresentam grandes regiões estratiformes. Levando em conta esta característica e o ângulo direcional nos melhores casos, observa-se na rosa dos ventos que a origem dos eventos no IOP1 ocorreu predominantemente de Norte e Nordeste dirigindo-se à Sudoeste, em velocidades médias de  $\sim 23$  à  $\sim 34$  km/h para os níveis de CAPPI utilizados (3 km). Os eventos com pior previsão apresenta a mesma direção, mas são contidos em uma área mais estreita.

A propagação durante o IOP2 (Figura 4.14b) apresentou características inversa aquela observada no IOP1 (Figura 4.14a). O primeiro detalhe observado é justamente sobre a concentração direcional (área mais estreita) de propagação, que predominantemente ocorreu de Norte para Sul nos melhores casos. Nos piores casos (Figura 4.14cd) observou-se um comportamento direcional mais esparsa. A tendência direcional dos sistemas precipitantes durante o IOP2 nos melhores casos está associado principalmente a sistemas mais intensos. Além disso, as características morfológicas dos sistemas precipitantes durante o IOP2, como visto nos resultados anteriores, associam os sistemas desse IOP com sistemas de menor extensão de área na média e maiores índices de refletividade. A velocidade de propagação dos sistemas durante o IOP2 (Figura 4.14b) para os melhores casos foi em média  $\sim 30$  à  $\sim 42$  km/h e  $\sim 32$  à  $\sim 44$  km/h nos piores casos. Neste último apesar de mais rápido,

tem uma diferença considerada relativamente pequena o que deixa os resultados inconclusivos neste quesito e maiores estudos precisam ser direcionados.

Figura 4.14 - a);b) Propagação dos sistemas classificados com FAR < 0,5 durante os IOPs 1 e 2. c);d) Propagação dos sistemas como piores casos (FAR > 0,5).



Fonte: Produção do Autor.

As análises aqui apresentadas, demonstram o desempenho do algoritmo e suas peculiaridades para o rastreamento dos sistemas precipitantes na região Amazônica. Os resultados obtidos evidenciam a efetividade do algoritmo na avaliação dos tipos de eventos decorrentes de fusões, divisões e continuidades de células precipitantes no decorrer do ciclo de vida das famílias. Outro ponto a ser considerado é a avaliação geral dos eventos, estes classificados dentro do grupo Fam(Geral), poucas abordagens na literatura retratam um conjunto mais complexo de eventos dinâmicos. Normalmente utiliza-se de filtros com base na tipificação dos eventos para investigar uma certa característica de desenvolvimento e propagação.

Neste trabalho, o principal enfoque foi na investigação dos rastreios (melhores e piores casos) com base nos índices estatísticos durante os períodos de observação. Os resultados encontrados demonstram que durante os IOPs as células precipitantes com os melhores índices estão relacionadas a sistemas com maiores durações em seu ciclo de vida e células com maiores áreas. Outro fator importante é o parâmetro de rastreio relacionado aos valores de refletividade, foram observadas diferenças nos índices de intensidade dos sistemas tanto no IOP1 quanto no IOP2. Tais diferenças demonstram que para cada período faz-se necessário ajustar os parâmetros com intuito de obter melhores resultados de rastreio. Relacionando os índices de refletividade dos sistemas, seu ciclo de vida e área das células, conclui-se que sistemas precipitantes com grandes áreas podem persistir por mais tempo sobre a região de cobertura do radar e possuem maiores ciclos de vida.

Os resultados relacionados a propagação dos sistemas demonstra que os sistemas que são mais facilmente previstos apresentaram índices de deslocamento de acordo com a literatura. Além disso, observou-se uma clara diferença relacionada a dispersão dos vetores, de modo que, nos melhores casos no IOP1 o deslocamento deu-se de Nordeste para Sudeste com vetores mais esparsos e isto está associado principalmente ao tamanho das células, morfologicamente maiores, e de menor intensidade, provocando um maior deslocamento do vetor baseado nos centroides. Já no IOP2, a característica predominante em sua propagação está associada principalmente a sistemas mais intensos que concentram vetores menos esparsos, onde o deslocamento entre o centroide de tempos suscetivos gerou deslocamentos de Norte para Sul.

### **4.3 Rastreio via satélite**

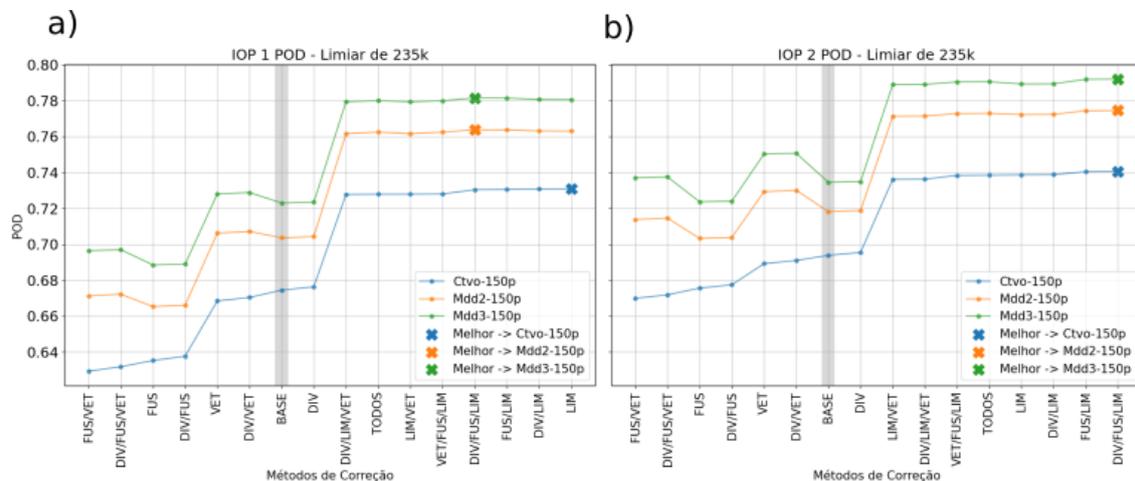
Os resultados apresentados anteriormente foram focadas na capacidade do algoritmo em assimilar dados de radar meteorológico e a partir disso descrever as características dos sistemas rastreados e sua previsão. De modo a verificar a habilidade do algoritmo em lidar com diferentes plataformas de medidas, nesta seção serão analisados os resultados obtidos a partir do rastreio dos sistemas convectivos de mesoescala via satélite geoestacionário. Neste sentido, foram avaliados os os métodos de correção do deslocamento com base no POD referente a previsão desses fenômenos em função do rastreio de seus *clusters* de nuvens. Está avaliação utilizou os parâmetros de rastreio da Tabela 3.2 para realizar o processamento dos períodos de observação (i.e. IOPs). Um dos objetivos desta análise é também demonstrar a capacidade de adaptação do algoritmo para rastreio de sistemas atmosféricos em maiores escalas.

As demais análises feitas nesta subseção abordam os melhores e piores aspectos relacionados a duração dos eventos sobre a região de estudos, como: características morfológicas dos sistemas atmosféricos, os limiares de intensidade, distribuição dos valores de limiares de  $Tb$  e a propagação dos sistemas. Para uma maior dinâmica de leitura e focando em dados de satélite como um completo as análises de dados de radar, ressalta-se que não serão exploradas a avaliação geral de habilidade do algoritmo (*Skill Score*) e análises de classificação dos eventos (Divisões, Fusões e Continuidades), como vistos na seção anterior, no entanto para fins exploratórios estes resultados foram anexados no apêndice .

#### 4.3.1 Análise dos métodos de correção do deslocamento

Para avaliar a habilidade do algoritmo com base nos métodos de correção do deslocamento dos *clusters* de nuvens para SCM, foram utilizados os índices estatísticos de POD de cada método em ambos os IOPs. Na Figura 4.15 exibe-se os indicadores estatísticos de POD relacionados aos métodos de correção e técnicas de extrapolação para o limiar de 235K (VILA et al., 2008) para diferentes métodos de extrapolação e correção de vetor. Este limiar foi utilizado para definir a feição externa dos *clusters* e delimitar o contorno das nuvens de grande desenvolvimento vertical (MACHADO et al., 2002). As linhas paralelas correspondem as técnicas de extrapolação e a marcação em destaque (x) representam os melhores métodos de correção com o parâmetro de 150 píxeis como número mínimo por *cluster*. Nota-se que em ambos os IOPs os métodos de correção DIV/FUS/LIM obtiveram os melhores valores de POD (acima de 0.78) para técnica de extrapolação Mdd3. O método DIV/FUS/LIM é aquele que corrige o vetor de deslocamento em eventos de Divisões e Fusões entre células e utiliza os vetores de limiares internos para correção vetorial (Seções 3.3.1.4, 3.3.1.3 e 3.3.1.2). De modo geral, os melhores índices de POD foram influenciados principalmente pelo método LIM em todos as técnicas de extrapolação (Ctvo, Mdd2 e Mdd3). O método de correção por limiares internos mostrou-se o mais eficiente para rastreo com satélite, isto ocorre devido a células menores embebidas em regiões internas e suas características convectivas mais intensas, estas delimitadas pelos parâmetros de 220 e 210 K com 100 e 50 píxeis. No geral apenas o método LIM agregou nos demais métodos melhorias nos índices de POD em média 5% tomando como referência o método BASE (destacado pela linha vertical cinza). Como a dinâmica de SCMs assume uma maior interação entre diferentes tipos de nuvens e mecanismos de realimentação, o melhor resultado mostra justamente que as três correções englobam as principais fontes de erro e assim tentam mitigar esses problemas.

Figura 4.15 - Resultados dos rastreios para o satélite e métodos de correção do deslocamento para os parâmetros de 235k com 150 píxeis nos IOP1 (a) e IOP2 (b).



Fonte: Produção do Autor.

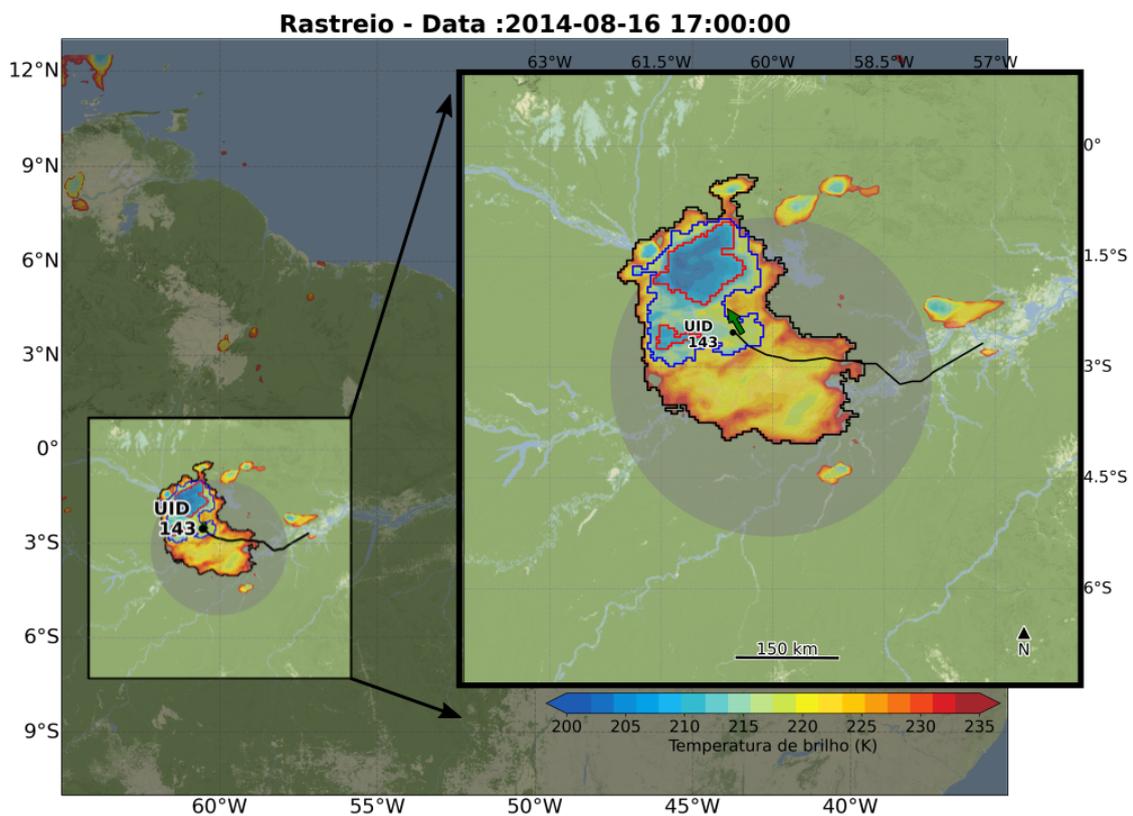
Como mencionado acima, o método DIV/FUS/LIM apresentou os melhores índices estatístico de POD. Estes métodos foram selecionados para realização das próximas análises nos IOPs 1 e 2 das observações de satélite. Vale ressaltar que estes índices correspondem aos valores estatísticos de POD para toda a região de cobertura dos dados de satélite, como listados nos tópicos da Seção 3.1. A seção seguinte mostra análises do FAR (indicador estatístico utilizado) sobre uma região menor, para melhor associar os resultados aqueles observados pelo radar

#### 4.3.2 Área de estudo para o rastreio via satélite

De modo a melhor rerepresentar os sistemas rastreado e inter-comparar os resultados com aqueles de sistemas precipitantes foi definida uma área que corresponde ao dobro da área de cobertura do radar. Uma maneira de não perder informação de sistemas maiores que podem englobar toda a área do radar. Na Figura 4.16 é apresentado um exemplo de rastreio feito pelo algoritmo para as observações de satélite. Foram considerados os sistemas cujo centroide da célula de nuvem cruzou os limites do quadro destacado na Figura 4.16 que corresponde a valores de latitude e longitude nas coordenadas: -64.156, -7.304 (canto inferior esquerdo) e -55.826, 1.008 (canto superior direito). O círculo (cinza) representa a área de cobertura do radar. Exibe-se na mesma figura as feições de contorno dos *clusters* de nuvem referentes as geometrias identificadas pelo algoritmo. O polígono preto corresponde a feição

de contorno do limiar 235 K, já as estruturas internas (polígonos azuis e vermelhos) realçam as feições dos limiares 220 e 210 K (Parâmetros de rastreo da Tabela 3.2). O centroide é identificado por um ponto preto ao lado da seta (verde) indicando o centro de massa e a direção de propagação da célula de acordo com o vetor de deslocamento. O UID é o identificador do *cluster* para o tempo de observação (2014-08-16 17:00:00). A trajetória do *cluster* ao longo do seu ciclo de vida é exibida como uma linha que tem origem próxima as coordenadas 57°W e 2.75°S.

Figura 4.16 - Área de estudos do satélite. Imagem do satélite GOES13 no canal infravermelho para o dia 16 de Agosto de 2014 às 17 horas (GMT).



As geometrias internas correspondem aos limiares de rastreo. Polígonos pretos estão associados ao limiar de 235 K, polígonos Azuis correspondem ao limiar de 220 K, Polígonos Vermelhos associados ao limiar de 210 K. A linha contínua (Preta) corresponde a trajetória de deslocamento da nuvem rastreada até as 17 horas (GMT) do dia 16 de Agosto de 2014.

Fonte: Produção do Autor.

### 4.3.3 Parâmetros que impactam na previsão dos SCMs

Assim como foi realizado para o radar (Seção 4.2.4), uma avaliação das melhores e piores previsões de SCM com o satélite GOES-13 foi realizada. Criou-se dois grupos ( $FAR < 0,5$  e  $FAR > 0,5$ ) para designar os melhores e piores casos, destes grupos exibem-se os resultados na Tabela 4.3.3) do número de famílias rastreadas para cada um dos IOPs.

Tabela 4.3 - Grupos dos melhores e piores casos cujo centroide cruzou a região de estudos nos IOPs 1 e 2.

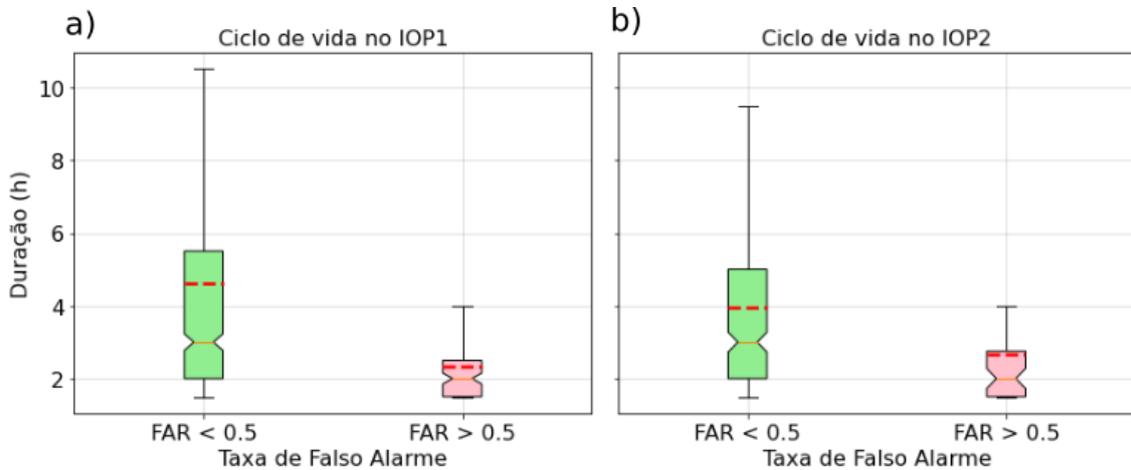
Grupo	Nº de famílias (IOP1)	Nº de famílias (IOP2)
$FAR < 0,5$	577	297
$FAR > 0,5$	110	51

Fonte: Produção do Autor.

A primeira análise demonstra o ciclo de vida dos grupos relacionados as famílias que adentraram a região de estudos durante os IOPs. O *boxplot* da Figura 4.17 exhibe os resultados relacionados a duração de ciclo de vida para os grupos com melhores previsões (verdes) e piores (rosas) nos IOPs 1 e 2. A maior parte dos eventos com melhores índices de FAR teve duração de ciclo de vida entre 2h e 5,5h (quartis inferiores e superiores) no IOP1 (Figura 4.17a) e no IOP2 (Figura 4.17b) a duração média ocorreu entre 2h a 5h. Nota-se que as famílias com os melhores casos são compostas de sistemas que perduraram por mais tempo durante seu ciclo de vida, este comportamento também foi visto nas análises anteriores para o radar 4.2.4). Entende-se que famílias com menor ciclo de vida tendem a acumular baixos índices estatísticos pois estes dependem de um maior desenvolvimento, principalmente se envolvem mecanismos de fusão de *clusters*.

Como abordado nas seções anteriores, sabe-se que o IOP1 ocorreu durante a estações chuvosa e o IOP2 já na estação seca na Amazônia. Os resultados para o ciclo de vida das células de nuvem mostra que famílias com maior duração foram melhor previstas. Seguindo com os resultados, buscou-se avaliar as características morfológicas das células de nuvem, na Figura 4.18 exhibe-se os diagramas de caixa para o tamanho das células. Nos quartis inferiores dos melhores casos para IOPs 1 e 2, foram encontrados valores para área média dos *clusters* com  $\sim 7901km^2$  e  $\sim 6924km^2$  respectivamente para os períodos 1 e 2 dos IOPs e valores de  $\sim 34335km^2$  e  $\sim 31261km^2$  para os

Figura 4.17 - Duração do ciclo de vida das famílias para o rastreo com dados do satélite GOES-13. a) Duração dos eventos nos grupos no IOP1. b) Duração no IOP2.

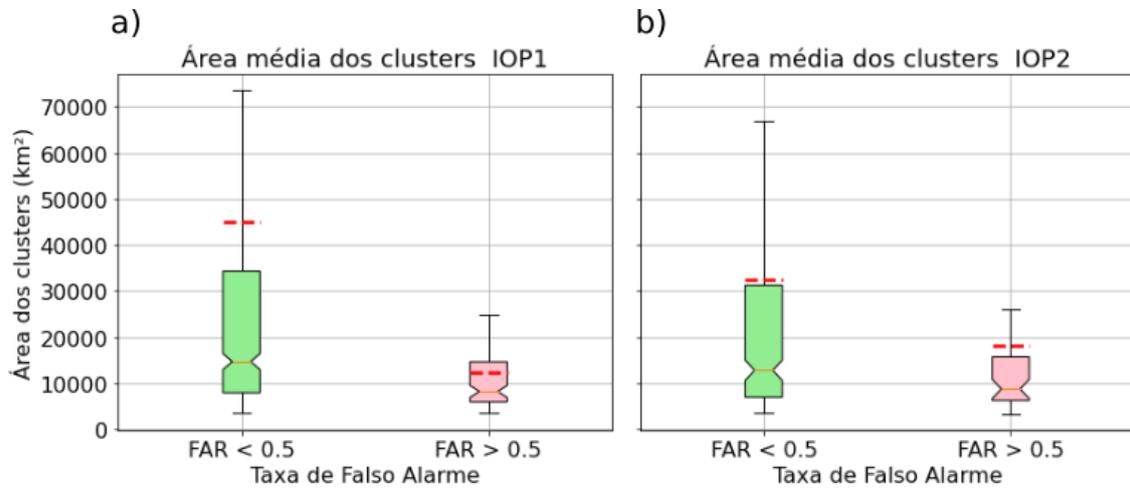


Fonte: Produção do Autor.

quartis superiores. Os valores de tamanho médio dos *clusters* foi de  $\sim 44931km^2$  para o IOP1 (Figura 4.18a) e  $\sim 32410km^2$  para o IOP2 (Figura 4.18b). Tal resultados indicam que células maiores foram melhor rastreadas e previstas se comparadas as células de menor proporção média ( $\sim 12446km^2$  e  $\sim 18103km^2$ ). IOP1 e 2, respectivamente. Células com grandes dimensões estão associadas a sistemas de maiores escalas, principalmente os SCMs atuantes na bacia Amazônica. As características morfológicas destes sistemas são amplamente estudadas na literatura (LAURENT et al., 2002; MACHADO; LAURENT, 2004; MARKOWSKI; RICHARDSON, 2011; NUNES et al., 2016; ANSELMO et al., 2021), as informações encontradas pelo algoritmo estão de acordo com as características morfológicos dos sistemas atmosféricos durante os períodos de observação (IOPs) para região da bacia Amazônia. Ocorrências de SCMs maiores, como linhas de instabilidade, é frequente durante o IOP1 (Figura 4.18a), pois uma das principais características relacionadas a estes sistemas está associada à dinâmica de intensidade das correntes ascendentes no seu interior em núcleos convectivos embebidos em regiões estratiformes (temperaturas mais quentes) cujo ciclos de vida tem maiores durações (MACHADO et al., 1998). Da mesma forma como no rastreo com dados de radar, constatou-se que famílias com células maiores são melhor previstas.

Uma análise sobre os limiares de  $Tb$  foi realizada com o objetivo de definir sua distribuição para os melhores e piores casos de previsão. Na Figura 4.19 são exibidos os

Figura 4.18 - Comparativo entre as áreas dos *clusters* de nuvem nos melhores e piores casos para o IOP1 (a) e IOP2 (b) dos dados de satélite.

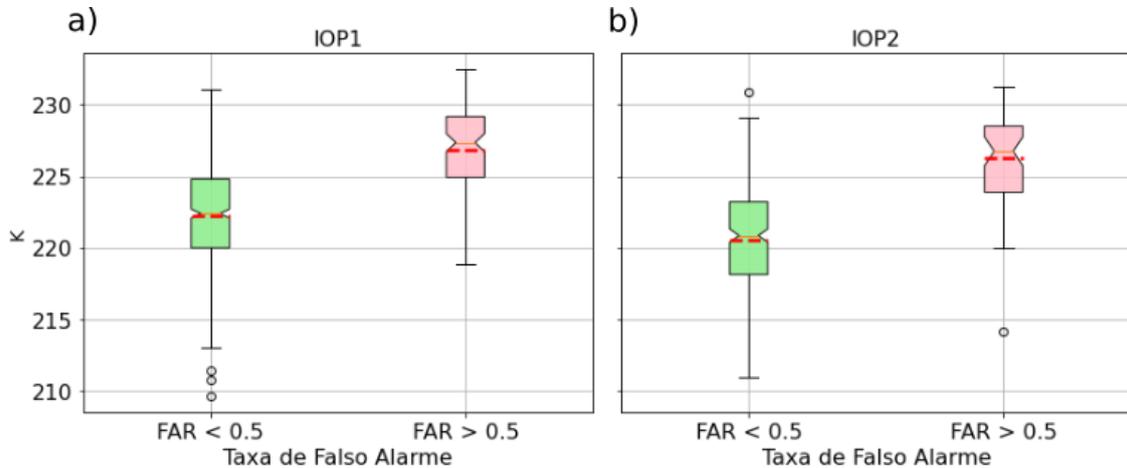


Fonte: Produção do Autor.

diagramas de caixa referente a  $Tb$  dos topo das nuvens em ambos os IOPs. Constatase uma clara diferença entre os melhores e piores casos nos dois IOPs, onde, valores de  $Tb$  menores foram classificados nos melhores casos e os maiores para os piores casos. A diferença das médias entre os grupos com os melhores índices ( $FAR < 0.5$ , diagramas verdes) nos IOPs, foi de apenas 2 K. O resultado para os quartis inferiores dos melhores casos no IOP2 (Figura 4.19b) mostram que neste período as famílias apresentaram características de células com menores valores de  $Tb$  (células mais frias). Essa característica está associada a sistemas mais intensos, que da mesma forma como vistos nos resultados para o rastreo de sistemas precipitantes, é uma característica comum para o período da estação seca na bacia Amazônica. Limiares maiores (mais quentes) estão associados a sistemas com atividades convectivas menores, próximos a grandes regiões estratificadas, estas características são comumente associados aos SCMs na Amazônia (VELASCO; FRITSCH, 1987).

De modo geral, os resultados até o momento apresentam características similares aos encontradas no rastreo dos sistemas precipitantes. Além disso, as características de duração do ciclo de vida, morfológicas e de intensidade da variável  $Tb$  mostram que o rastreo para os períodos dos IOPs estão de acordo com os índices encontrados na literatura Li e Fu (2004), Nunes et al. (2016), Eichholz (2017), Anselmo et al. (2021).

Figura 4.19 - Limiares de temperatura de brilho nos melhores e piores casos. a) Distribuição dos limiares para IOP1. b) Distribuição dos limiares de temperatura de brilho durante IOP2.



Fonte: Produção do Autor.

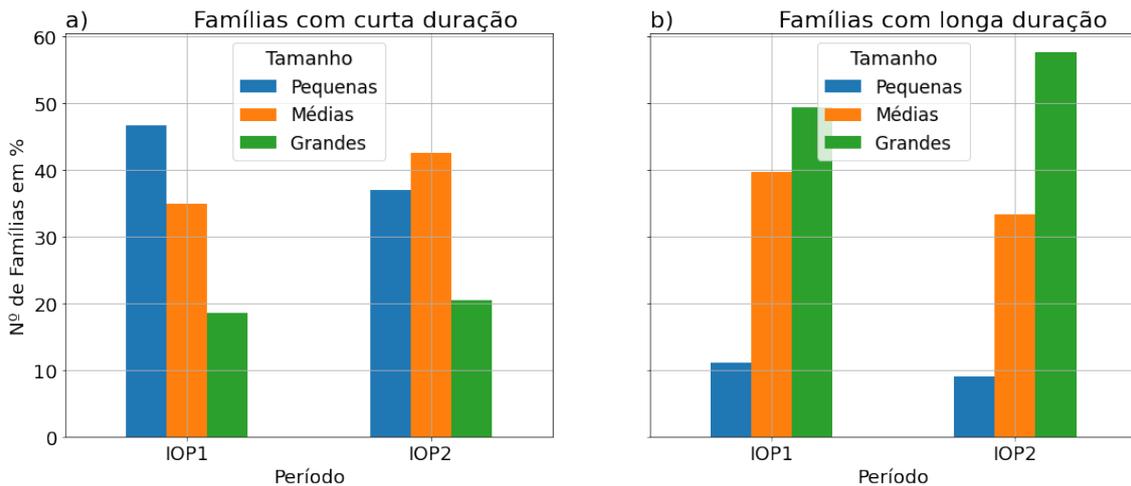
Como notado nos resultados anteriores, o tamanho e ciclo de vida impactam diretamente no rastreo e previsão. Em um sistema de monitoramento de tempestades é de suma importância definir como essas relações podem ser associadas para um melhor acompanhamento dos eventos. Neste sentido, para um melhor prognostico dos resultados de rastreo das células de nuvem, foi utilizado a relação entre o ciclo de vida das famílias e seu tamanho para classificar os sistemas em grupos. A classificação com base no tempo de duração levou em conta os estudos [Velasco e Fritsch \(1987\)](#), [Machado et al. \(1998\)](#) sobre os SCMs na bacia Amazônica, onde, sistemas de curta duração possuem sua maturação em média de 2 a 3 horas e os de longa duração, 5 a 6 horas. Baseado nisso, aplicou-se um filtro sobre os melhores casos nos IOPs agrupando as famílias com base nos seus ciclos de duração da seguinte e classificando-os como: Famílias com sistemas de curta duração, são as que possuem ciclo de vida maior que 2 horas e menor que 5; Famílias de longa duração possuem ciclos maiores que 5 horas. Além da classificação baseada no ciclo de vida, também foram separados os grupos de acordo com o tamanho médio das famílias. Foram subdivididos em três grupos relacionados com o tamanho médio dos *clusters* de nuvem durante todo o seu ciclo de vida e categorizados da seguinte forma:

- (a) **Pequenas:** Representam as famílias que ao longo do seu ciclo de vida apresentaram área média das células de chuva com valores entre 0 e 33% do máximo observado em todas as famílias durante o IOP.

- (b) **Médias:** São as famílias que possuem área média com valores entre 34% e 66% do máximo observado durante seu ciclo de vida.
- (c) **Grandes:** Famílias com área média maiores que 67% do total de valores das áreas médias por família no IOP.

A proporção do número de famílias é exibida nos gráficos da Figura 4.20 que mostra os valores relativos aos tipos de família com base em sua duração e tamanho. Avaliando a população dos grupos, nota-se que o IOP1 (Figura 4.20a) apresentou o maior número de famílias com curta e longa duração e também uma maior quantidade de elementos nos grupos por tamanho de família.

Figura 4.20 - Percentual de classificação dos sistemas com base no ciclo de vida e tamanho de área. a) Grupos de famílias com curta duração durante os IOPs 1 e 2. b) Famílias de sistemas com longa duração durante os IOPs 1 e 2.

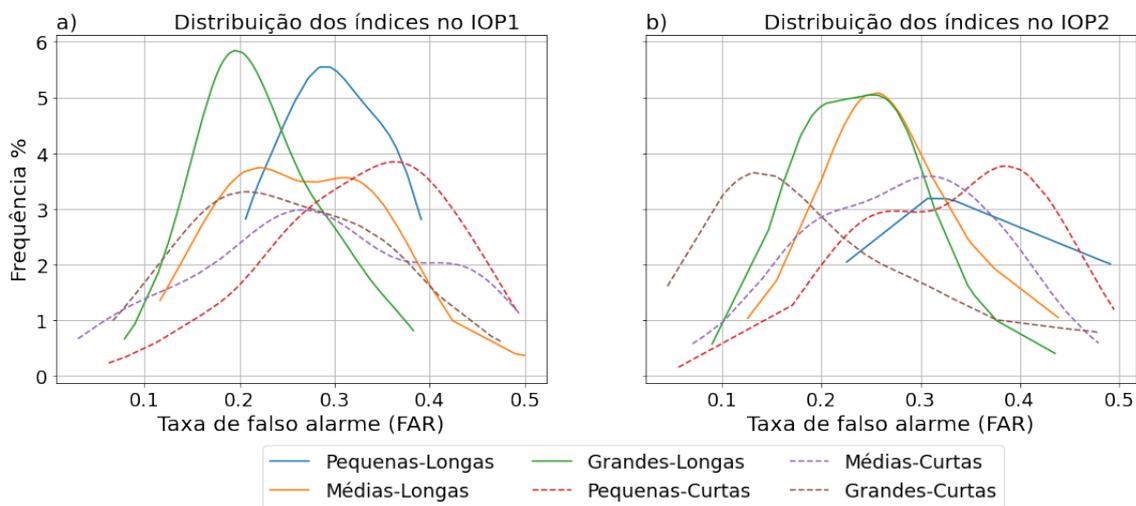


Fonte: Produção do Autor.

Uma avaliação de distribuição dos índices de FAR por tipos de família com base no seu ciclo de vida e tamanho foi feito para estimar qual tipo de sistema foi melhor previsto pelo algoritmo. Na Figura 4.21 exibe-se a densidade dos índices de FAR por tipos de família rastreados durante os IOPs 1 e 2. Nesta avaliação foram agrupados de forma crescente os índices de FAR dos grupos de famílias e distribuídos em forma de frequência relativa as ocorrências dos eventos ao longo dos IOPs. Cada linha representa um grupo de família e sua distribuição dos índices de taxa de falso alarme. Famílias que obtiveram índices menores (mais a esquerda eixo-x) foram

melhor classificadas. Nota-se que, famílias com sistemas grandes e de longa duração possuem uma faixa expressiva de elementos e estão deslocadas mais a esquerda no eixo do gráfico (melhores resultados) para o IOP1 (Figura 4.21a). No IOP2 (Figura 4.21b) as famílias grandes e de curta duração foram as que obtiveram os melhores índices, uma característica também observada neste período, onde tempestades se desenvolvem rapidamente. Nota-se ainda que fica evidente a pior performance das correções e previsões para eventos curtos e pequenos em ambos os IOPs.

Figura 4.21 - Histograma de frequência relativa do FAR para diferentes classes de tamanho e duração durante os IOP1 (a) e 2 (b).



Fonte: Produção do Autor.

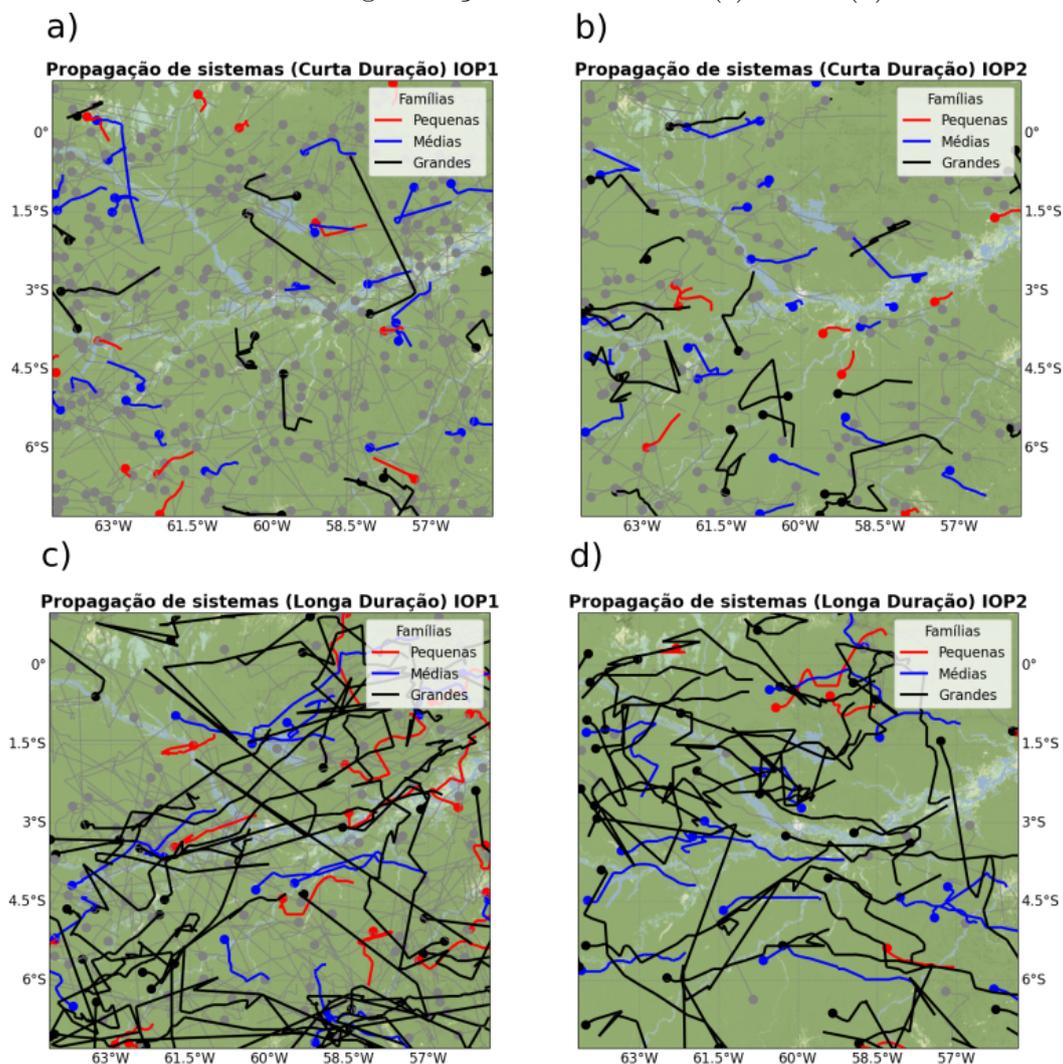
Análises visuais das trajetórias dos sistemas podem ajudar na determinação de áreas com maior ocorrência de sistemas, e suas possíveis relação com as características da superfície (corpos d'água, áreas florestais, área urbana e etc.). Exibe-se na Figura 4.22 o deslocamento dos sistemas de acordo com suas classificações, as famílias destacados nas cores vermelhas (pequenas), médias (azuis) e pretas (grandes) referem-se aos sistemas mais bem classificados no que se diz respeito ao seu índice de FAR. De maneira visual nota-se uma diferença clara no perfil de deslocamento entre os sistemas de curta duração (Figura 4.22ab) e longa duração (Figura 4.22cd), onde, sistemas de longa duração demonstram características mais esparsas entre o ponto de origem do sistema (início da linha) e final (círculos). A proporção entre o deslocamento do ponto inicial dos sistemas ao ponto final foi mais uniforme para famílias

dos tipos pequenas e médias, isso ocorre devido ao menor deslocamento do centroide em imagens sucessivas ocasionando em um rastreo e previsões mais precisos. Marcações na cor cinza são referentes aos eventos ocorridos de forma geral, nota-se uma clara diferença entre a quantidade de eventos durante os IOPs, onde, no IOP1 registraram uma maior quantidade de eventos se comparados ao IOP2 em ambos os tipos de sistemas (curtos e longos). De modo geral, a trajetória dos sistemas seguiu um fluxo de leste para oeste, principalmente em sistemas com áreas de médio porte (azuis). Ressalta-se na figura que muitos sistemas longos se deslocam em direção aos rios onde ali encerram sua trajetória, resultado que precisa de análises mais profundas sobre os efeitos de corpos d'água e brisas fluviais na dinâmica desses eventos. Contudo, em alguns casos a dispersão dos vetores de deslocamento dos sistemas traçaram fluxos em em múltiplas direções. Os gráficos tipo rosa dos ventos para as classificações deste estudo foram anexadas no apêndice deste trabalho .

Os resultados aqui apresentados mostram que o algoritmo pode ser aplicável a rastreo de sistemas atmosféricos em maiores escalas via dados de satélite. Como visto na Seção 4.3.1 sobre análise dos métodos de correção do deslocamento, os resultados demonstram que os índices de POD das previsões em toda região de cobertura do satélite apresentaram valores acima de 0,78 de precisão em 30 minutos de previsão no IOP1 e maiores que 0,79 no IOP2, isto em 8 métodos de correção que utilizam a técnica de extrapolação com 3 vetores de deslocamento. Este resultado demonstra que a previsão de até um tempo de observação a frente do observado foi significativo, pois, os índices estatísticos calculados retratam de maneira geral os indicadores utilizados para o calculo global do POD, isto é, a precisão global do algoritmo ficou próxima aos valores ideais (1 para POD).

Para os estudos realizados na região demarcada (exibido na Figura 4.16) os resultados obtidos demonstram que foi possível determinar peculiaridades mais localizadas para os rastreios via satélite. Dentre os resultados encontrados destacam-se o ciclo de vida, área dos *clusters* e limiares dos sistemas ao cruzar a região demarcada, vistos na Seção 4.3.3. Estes resultados demonstram que os sistemas previstos pelo algoritmo obtiveram índices iguais ou próximos aos vistos na literatura. A classificação com base na duração e proporção de área dos eventos permitiu destacar que sistemas grandes e de longa duração foram melhor previstos pelo algoritmo, e a trajetória dos sistemas como vistos na Figura 4.22 permite uma visualização do deslocamento dos sistemas, algo fundamental para selecionar estudos direcionados a características morfológicas mais específicas e locais de gênese e dissipação de sistemas atmosféricos.

Figura 4.22 - Trajetória dos sistemas com curta duração durante o IOP1 (a) e IOP2 (b).  
Sistemas com longa duração durante o IOP1(c) e IOP2(d).



Na figura os círculos ao final das linhas representam o término do ciclo de vida de um sistema. Famílias com tamanho Pequeno são exibidas por linhas vermelhas. Famílias de tamanho Médio estão representadas por linhas Azuis. Famílias com tamanho Grande são exibidas por linhas Pretas. Linhas Cinza representam as demais famílias.

Fonte: Produção do Autor.

#### 4.4 Estudo de caso: tempestade no dia 16 de agosto de 2014

Em meteorologia é muito comum analisar casos específicos de eventos dos quais se pretender estudar. Estes casos dão uma visão mais focada no problema e podem ajudar a entender alguns processos físicos com maior propriedade. Nesta seção discorre-se sobre a utilização dos resultados de rastreamento do algoritmo para análise de uma ocorrência de tempestade identificada e rastreada via dados de radar e satélite. No dia 16 de agosto de 2014, um evento de precipitação significativa incidiu sobre a cidade de Manaus-AM, instrumentos de diversas entidades registraram uma ao longo da passagem do sistema, o INMET mostrou valores moderados de taxa de chuva, cerca de 18mm/h<sup>1</sup>, além deste instrumento, no mesmo período um pluviômetro instalado pelo projeto GoAmazon no sítio T3 (Manacapuru-AM), também registrou precipitação mais significativa para o mesmo dia, com taxas de 60,96 mm/h (Anexo Tabela D.4). Baseado neste evento, os resultados a seguir apresentam estatísticas relacionadas ao comportamento do mesmo sistema atmosférico rastreado pelo algoritmo via informações do radar e satélite. A partir desta análise discorre-se sobre a capacidade do algoritmo em rastrear tempestades utilizando multi-sensores em sinergia, uma futura implementação.

Na Figura 4.23 exibe-se o desenvolvimento das áreas de diversos *clusters* de precipitação rastreados pelo algoritmo ao longo do dia 16 de agosto de 2014. Cada linha do gráfico representa o comportamento de desenvolvimento das áreas dos *clusters* para os limiares de 20, 30 e 35 dBZ ao longo do dia entre as 07 h às 23 h (GMT). Nota-se que a partir das 13 h um sistema individual (linhas azuis) se destaca, a área deste *cluster* desenvolve-se até as 16:48 h e em seguida observa-se o que seria o início de um processo de dissipação, onde nota-se uma redução das regiões rastreadas em todos os limiares. Antes das 13:00 h uma maior quantidade de sistemas menores pode ser observada na Figura 4.23, e em seguida o rápido aumento do sistema em destaque que se deu pela fusão com outros sistemas. Como visto anteriormente nos resultados deste trabalho, a fusão entre *clusters* normalmente ocasiona o crescimento das regiões precipitantes, principalmente em 20 dBZ, onde áreas estratiformes são mais comuns. Contudo, áreas convectivas (35 dBZ) também apresentaram tal comportamento.

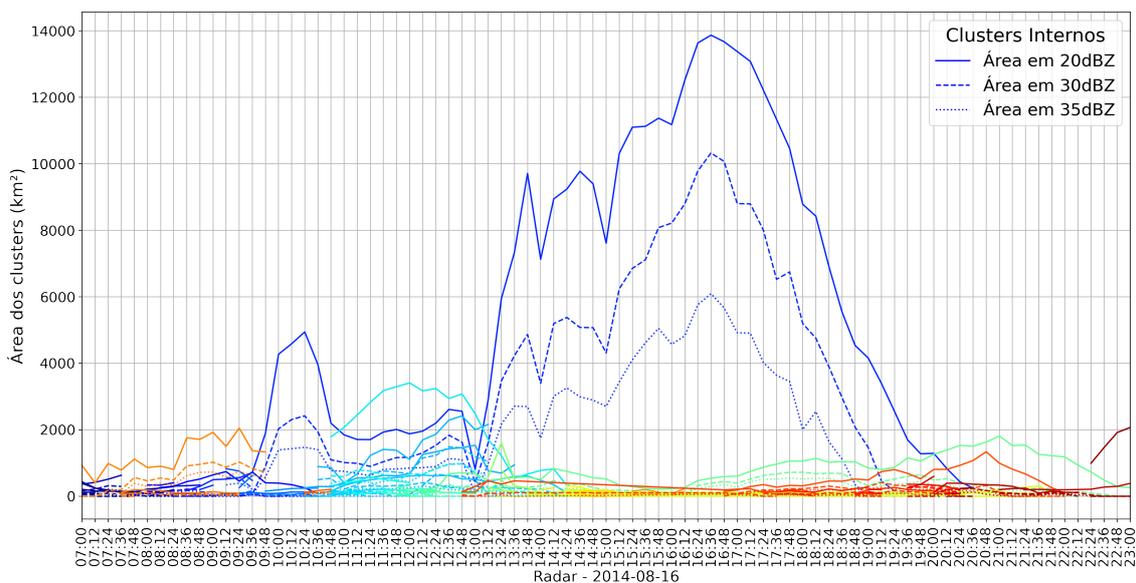
Em seguida, exibe-se na Figura 4.24 o comportamento de desenvolvimento da área dos *clusters* de nuvem rastreados via satélite ao longo do período entre 07h da manhã até as 23h do dia 16 de agosto de 2014. Da mesma forma como visto nos resultados

---

<sup>1</sup>INMET - <https://bityli.com/MnTig>

para o rastreo via radar no mesmo período, nota-se que um sistema se destaca entre os demais (linhas azuis superiores). Este *cluster* iniciou sua fase de desenvolvimento por volta das 09:30 da manhã, teve um primeiro ápice às 20:30 h e novamente às 23:00 h quando seu centroide ultrapassou os limites delimitados para a região de estudos do satélite. O comportamento dos valores de área dos *clusters* novamente apresentou uma simetria de desenvolvimento para as linhas que representam os limiares de 235, 220 e 210 K, nota-se no decorrer do seu desenvolvimento houve uma tendência de crescimento contínuo das áreas até as 20:30 h, como susodito, contudo pouca variação foi notada no limiar mais frio, o 210 K.

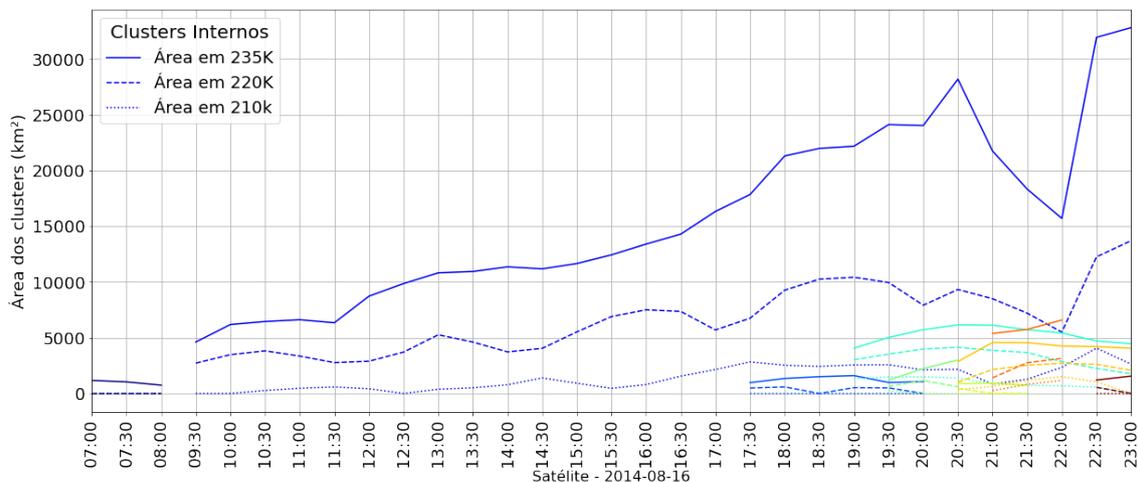
Figura 4.23 - Eventos ao longo do dia 16 de agosto de 2014 identificados pelo algoritmo via dados do radar.



Fonte: Produção do Autor.

As linhas com maiores registros de área (Figuras 4.23,4.24) estão associadas a um SCM que cruzou a região de estudos e foi rastreado em ambos os sensores (radar e satélite). Para o radar, o sistema com maior desenvolvimento recebeu o UID 135 e no rastreo via satélite o UID atribuído foi 143. Na Figura 4.25 exibe-se as informações relacionadas ao SCM rastreado via radar e satélite, as linhas contínuas (cores preta, azul e vermelha) estão associadas ao eixo y da figura e denotam os valores médios dos *clusters* definidos por cada limiar no decorrer do ciclo de vida do SCM. O número

Figura 4.24 - Eventos ao longo do dia 16 de agosto de 2014 identificados pelo algoritmo via dados do satélite GOES-13 no canal infravermelho.



Fonte: Produção do Autor.

de *clusters* internos para o 1º e 2º limiar são representados por barras (cores laranja e verde) associadas ao eixo y a direita da figura. As classificações de continuidade (CONT), fusões (FUS) e divisões (DIV) são exibidos na parte superior das Figura 4.25a e b.

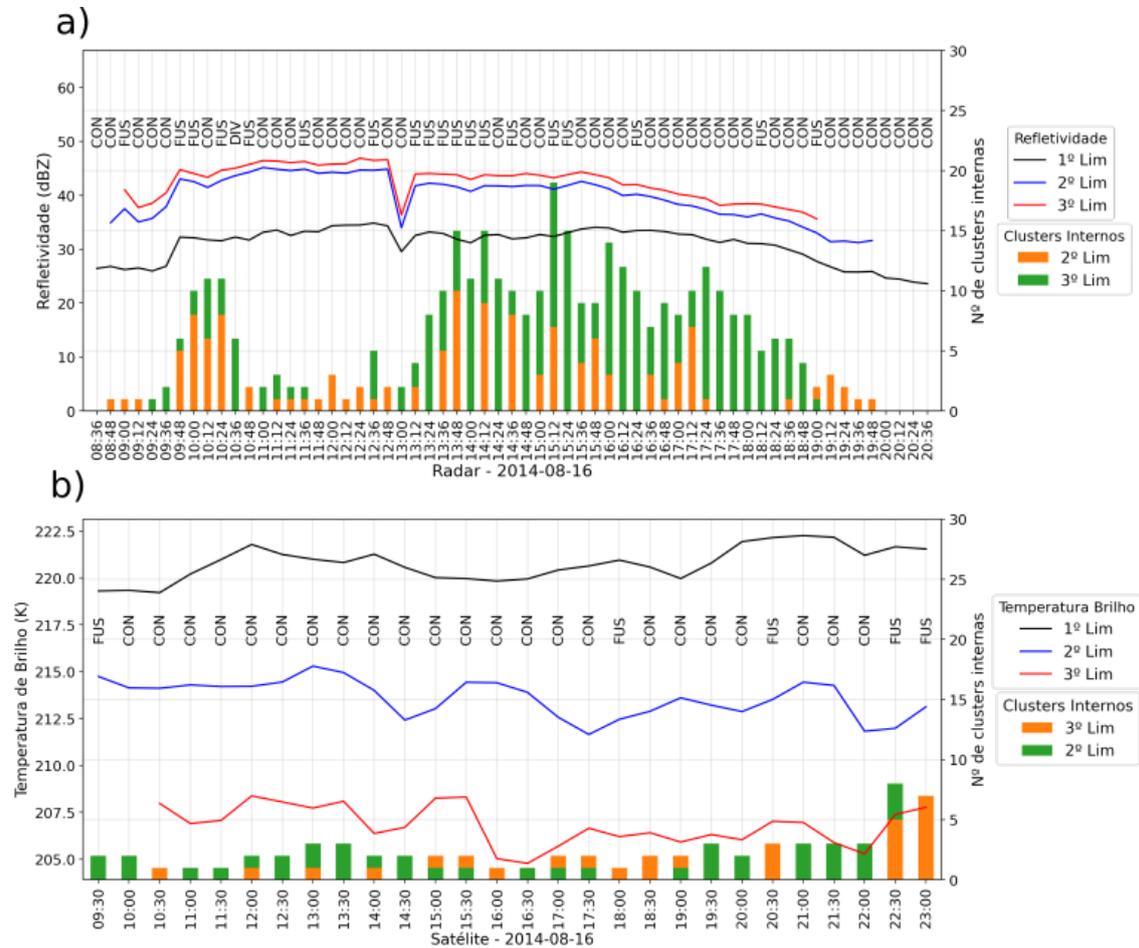
O *cluster* que recebeu o UID 135 para o rastreamento via radar foi identificado inicialmente às 08:36 do dia 16 de agosto de 2014, seu desenvolvimento ocorreu após eventos de fusão (FUS) entre *clusters* adjacentes, sendo o primeiro destes às 09:00 h (Figura 4.25a). No momento da identificação do SCM rastreado via radar contabilizou-se apenas 1 *cluster* interno para o 2º limiar de refletividade (30 dBZ). Logo após às 09:48 um número maior de fusões elevou a quantidade de *clusters* internos (nos limiares 30 e 35 dBZ, 2º Lim e 3º Lim, respectivamente). Observou-se uma elevação na média de refletividade para todos os limiares logo após os eventos de fusão no início do desenvolvimento do SCM por volta das 09:48 minutos. O SCM apresentou pouca variação nos valores de refletividade até às 12:48 h. Neste ponto este sistema estava próximo a cidade de Manaus e possivelmente uma falha nas observações volumétricas do radar às 13:00, devido ao cone cego, fez com que a área e os valores de refletividade fossem atenuados. A partir das 13:12 h o SCM estava sobre a zona urbana da cidade de Manaus e notou-se uma ascensão do número de *clusters* internos. O ciclo de vida deste SCM rastreado via radar teve duração de 12h, no decorrer

do seu desenvolvimento foi observado que uma quantidade significativa de eventos classificados como contínuos (39 ocorrências) intercalam-se entre eventos de fusões (19 ocorrências) e apenas um evento de divisão (DIV) ocorrido às 10:36 h. Nota-se que os valores de refletividade média durante todo o ciclo de vida apresentaram tendências parecidas, no entanto, após às 19:00 h os núcleos internos atenuaram-se ou desapareceram, e isto é um forte indicativo que o SCM rastreado via radar estava em processo de dissipação ou simplesmente a altura do feixe não mais se tornava representativa, pois o sistema já se encontrava distantes do radar.

Na Figura 4.25b exibe-se o ciclo de vida do sistema rastreado em destaque e suas características relacionadas via satélite. Da mesma forma como mencionado no caso rastreado via radar, o SCM aqui abordado foi inicialmente identificado pelo algoritmo às 09:30 h e sua gênese deu-se após um evento de fusão entre dois *clusters*, como pode ser visto pela classificação de FUS ocorrido no mesmo horário. Ao longo do seu ciclo de vida o SCM rastreado via satélite não apresentou uma dinâmica tão acentuada se comparado ao mesmo rastreado via radar. Nota-se que sucessivos eventos de continuidade ocorreram durante toda sua propagação e apenas no final de sua passagem pela região de estudos foram observados eventos de fusões e um aumento do número de *clusters* internos. As informações relacionadas aos *clusters* internos mostram que às 10:30 h o algoritmo identificou 1 *cluster* no 3º limiar (210 K), e antes disso outros 2 *clusters* para o 2º limiar (220 K). Neste momento o SCM apresentava uma fase de maturação mais acentuada, onde o limiar de 210 K mostrava a presença de possíveis células mais convectivas embebidas no sistema. Neste instante também foi observado um aumento acentuado nos valores de refletividade do radar. Estruturas verticais conhecida como torres convectivas, caracterizadas por fortes correntes ascendentes fazem parte da dinâmica dos SCMs (HOUZE JUNIOR, 2004) e podem ter sido responsáveis por essas variações.

Ressalta-se que a velocidade média do sistema ao longo do seu ciclo de vida rastreado via radar foi de  $\sim 48,07$  km/h, enquanto que via satélite apresentou velocidade média de  $\sim 40,11$  km/h. O que mostra que ambos apresentaram velocidades semelhantes e uma certa concordância entre os rastreios, independente da plataforma. Na Figura 4.26 exibe-se a representação de trajetória dos *clusters* via satélite e radar em três diferentes momentos do ciclo de vida: às 10:24 h (a) para o radar e 10:30 h (b) para o satélite; (c) e (d); (e) e (f). Embora os sensores registrem os eventos em níveis distintos e tempo próximos, mas não exatamente o mesmo, nota-se uma semelhança nas trajetórias. A linha preta contínua denota o caminho percorrido pelo centroide dos *clusters* desde sua gênese até o momento de visualização de cada figura. O trajeto

Figura 4.25 - a) Desenvolvimento dos limiares de refletividade e número de *clusters* internos para o SCM com UID 135 rastreado via radar. b) Desenvolvimento dos limiares de temperatura de brilho e número de *clusters* internos para o SCM com UID 143 rastreado via satélite.



Fonte: Produção do Autor.

do SCM teve origem próximo às coordenadas 57°W 3°S como observado na Figura 4.26b, às 09:00 h da manhã do dia 16 de agosto de 2014 e seguiu de Leste para Oeste ao longo do curso do rio Amazonas. A trajetória do SCM visualizada em ambos os sensores (linha vermelha para o satélite e linha preta para o radar representam as trajetórias) apresentar características distintas, um consequência da natureza do dado, a chuva dentro da nuvem. Contudo, observa-se que inicialmente ambos apresentam deslocamento semelhante, com pequenas variações, principalmente no radar, onde processos de fusão e divisão podem ser mais frequentes e mudar a trajetória rapidamente. Nota-se que nos primeiros dois pares (a,b e c,d) a nuvem aparenta ter um deslocamento mais uniforme, o que pode ser útil para corrigir os vetores mais rui-

dosos do radar. Entretanto, ao fim do ciclo de vida dentro da área do radar (Figura 4.26e,f) observa-se que as nuvem apresentou um leve deslocamento para noroeste e o sistema precipitante para oeste. Este comportamento, como visto na Figura, se deu devido a falta de uma divisão no *cluster* do satélite, onde o núcleo mais ativo seguiu para noroeste, enquanto a chuva em fase de dissipação estava associada a parte menos desenvolvida da nuvem e que se desprendia do sistema principal. Logo, este tipo de associação entre diferentes sensores deve levar em consideração também o ciclo de vida do sistema. Um desafio que deve ser enfrentado em trabalhos futuros.

Com base nos resultados aqui apresentados, conclui-se que o rastreamento do SCM ocorrido no dia 16 de agosto de 2014 pôde ser investigado de maneira eficiente em ambos os sensores. Como visto nos resultados referentes ao desenvolvimento de área dos *clusters* ao longo do dia 16 de agosto de 2014, foi possível identificar que um evento destacava-se dentre os demais ocorridos no mesmo dia. A partir da análise deste evento, discorreu-se sobre suas características morfológicas e especificidades relacionadas as variáveis de cada sensor (Refletividade e *Tb*), correlacionando com o número de *clusters* internos do SCM simultaneamente. Com base nesta análise, concluímos que o algoritmo pode ser utilizado para análises individuais de eventos. Além disso, ficou claro que o uso de diferentes sensores em sinergia para o rastreamento do mesmo sistema pode ser importante para melhor definir o deslocamento destes e sua possível previsão. Este é um objetivo que deve ser alcançado em trabalhos futuros.

Figura 4.26 - Representação das trajetórias para rastreamento via radar e satélite em: a) ;b) ;c) ;d) ;e) ;f) . Linhas pretas mostram as trajetórias para o radar e a linhas vermelhas mostram as trajetórias pelo satélite.

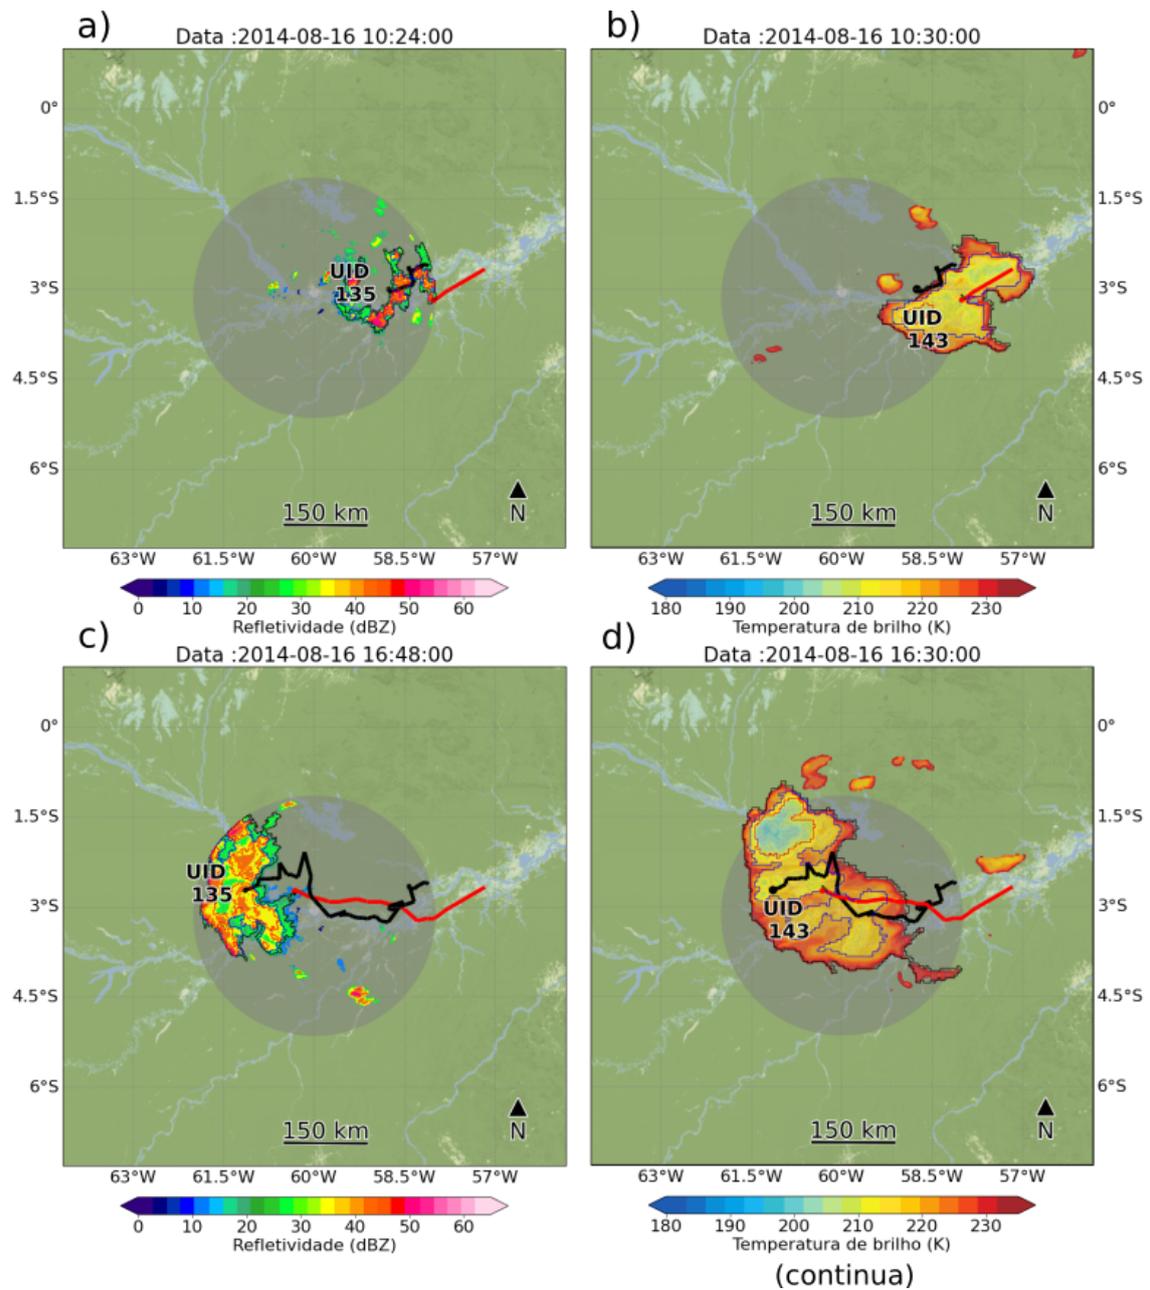
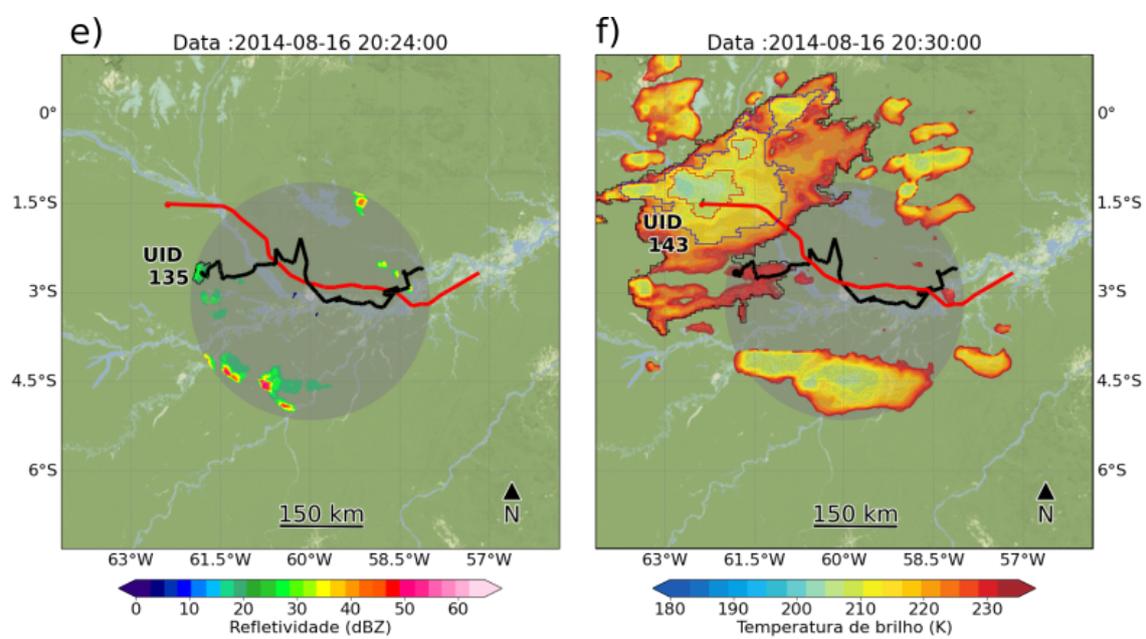


Figura 4.26 - Conclusão.



Fonte: Produção do Autor.



## 5 CONCLUSÃO

Neste trabalho foi desenvolvido um novo algoritmo que pode ser aplicado nos estudos sobre a propagação e previsão de sistemas precipitantes e nuvens, de modo a auxiliar na previsão do tempo em curtíssimo prazo (i.e. *nowcasting*). No decorrer do processo de implementação do algoritmo, foi necessário compreender as dificuldades associadas na identificação, rastreamento e previsão dos sistemas atmosféricos atuantes na bacia amazônica. Para isso, buscou-se na literatura científica os algoritmos empregados com propósito de rastrear sistemas atmosféricos semelhantes. Ao longo dos estudos foram abstraídos os métodos envolvidos nesse processo para desenvolver uma ferramenta que utilizasse informações de sensores meteorológicos (e.g. radares e satélites). Além disso, novas tecnologias foram apresentadas, como os métodos de correção vetorial com objetivo de atenuar as incertezas na previsão do deslocamento dos *clusters* identificados pelo algoritmo de aprendizado não-supervisionado (i.e. DBSCAN).

O conjunto de técnicas empregadas no algoritmo foram fundamentais para alcançar os objetivos propostos neste trabalho. Cada método envolvido no fluxo de processamento teve um papel essencial na discretização dos dados. O que possibilitou que os resultados obtidos fossem avaliados com intuito de determinar os melhores parâmetros para o rastreamento e previsão de eventos individuais. Neste sentido, a linguagem de programação na qual foi empregada para desenvolver o algoritmo é outro ponto a se destacar. O Python é uma linguagem moderna e de fácil manipulação, que permitiu que a cada nova versão do algoritmo, funcionalidades mais robustas pudessem ser implementadas. Além disso, sua aceitação em serviço de computação de nuvem ajudou numa avaliação mais rápida dos dados deste estudo. Uma vez que o algoritmo em si já está sob uma plataforma de fácil colaboração.

Uma vez estabelecido o conjunto de metodologias do algoritmo, buscou-se implementar os métodos de correção do deslocamento dos *clusters* para contornar as incertezas associados a técnica baseada em centroide, que prejudicam na definição correta do deslocamento dos sistemas rastreados. Como visto na Seção 3.11, a técnica que utiliza o centroide dos *clusters* como alvo para rastreamento, apresenta problemas relacionados a estimação dos vetores de deslocamento, os métodos desenvolvidos neste trabalho buscaram contornar ou atenuar este problema. Para isso, foram propostos quatro métodos de correção (VET, LIM, FUS e DIV) e avaliou-se por meio dos índices estatísticos a previsão dos eventos rastreados, utilizando as técnicas de extrapolação temporal descritas por Fazolo (2019) sobre *clusters* individuais (métodos

Ctvo, Mdd2 e Mdd3). Estes métodos foram utilizados intercalando-os com a combinação de todos os métodos de correção do deslocamento e parâmetros de rastreo (limiares e número mínimo de pixels por *clusters*) para definir o melhor conjunto de informações.

A avaliação dos métodos de correção e extrapolação foi realizada em observações durante períodos distintos, chamados de IOPs, que representam a estação chuvosa e seca na bacia Amazônica. Os dados utilizados nesta pesquisa foram o do radar meteorológico do SIPAM, disponibilizados pelo projeto GoAmazon, e as imagens do canal infravermelho do satélite GOES-13. Os resultados obtidos demonstraram que os melhores parâmetros e métodos de extrapolação para rastreo via radar foram: Refletividade igual à 20 dBZ com 30 pixels de número mínimo de área por *cluster*, empregando o método de extrapolação Mdd3 (a média dos vetores em 3 imagens consecutivas), estes, avaliados para o modo básico do algoritmo, ainda sem as correções do deslocamento.

A análise dos métodos de correção do deslocamento mostrou que 16 deles no IOP1 foram 24,15% superiores ao modo base, Ctvo-BASE-20-15. Destes, o método DIV/LIM com 20 dBZ, 30 pixels de área e para o método de extrapolação Mdd3, obtive a melhor performance, com até 25.43% maior que o valor do POD de referência para o método base. No IOP2 para o radar radar, a performance para os métodos de correção do deslocamento obteve melhorias de até 22,55% para o método Mdd3-FUS/LIM-20-30. O algoritmo generalizado, aquele que levou em consideração todo o período de estudo (IOP1+IOP2), sem diferenciar estações, mostrou que o metodologia de correção Mdd3-DIV/LIM-20-30, com POD igual a 0,739, foi aquela que mais eficiente dentre os demais, obtendo melhorias de até 22,5% superiores ao método Ctvo-BASE-20-15 generalizado.

Uma vez definido os métodos de correção do deslocamento mais eficientes para cada IOP, investigou-se as características médias dos sistemas precipitantes rastreados via radar. As análises para os IOPs mostraram diferentes características no ciclo de vida, morfologia dos *clusters* precipitantes, análise da refletividade média e propagação dos sistemas com base nos grupos de famílias identificados. Com relação as características médias dos sistemas de precipitação rastreados, alguns resultados podem ser salientados e remetem a uma consistência física já apresentada em outros estudos (MACHADO et al., 1998; CALHEIROS, 2008; FAZOLO, 2019). Os sistemas contínuos, mesmo que mais frequentes, são menores e possuem menor ciclo de vida. Sistemas que tiveram fusão são mais duradouros e apresentam um tamanho

maior (como esperado). Aqueles que tiveram divisões são menores que o anterior e apresentam ciclo de vida intermediário. Durante o IOP1, foram observados sistemas com maior duração no ciclo de vida e maiores áreas, além disso, a propagação destes sistemas ocorreu em velocidades médias de famílias de  $\sim 23$  a  $\sim 34$  km/h predominantemente de Norte e Nordeste em direção à Sudoeste. Já no IOP2, registraram-se eventos com menores áreas e sua propagação deu-se de forma mais rápida se comparado aos índices do IOP1, com velocidades médias em torno de  $\sim 30$  a  $\sim 42$  km/h e apresentou característica de direção predominantemente de Norte para Sul. Também foram avaliadas as características que mais impactam na performance de previsão do algoritmo, destas, conclui-se que células precipitantes com os melhor previstas estão relacionadas com sistemas de maior duração, maiores áreas e mais intensos.

Avaliando os métodos de correção do deslocamento e técnicas de extrapolação aplicadas no rastreamento via satélite, demonstrou-se através dos índices de POD que os métodos de correção que utilizam os limites internos (LIM) conseguiram aprimorar as habilidades do algoritmo em até 10% comparando-os com o método BASE. O POD do algoritmo para previsões de até 30min via satélite obteve índices de 0,78 para rastreios no IOP1 e 0,79 no IOP2. Estes índices demonstram que o algoritmo foi bastante eficiente no rastreamento de sistemas maiores, detectáveis via imagens de satélite. Cujas as características de rastreamento foram similares aquelas observadas por radar. Ou seja, sistemas maiores, com maior ciclo de vida e mais frio (maior desenvolvimento vertical) são mais fáceis de serem previstos.

No estudo de caso que rastreou via radar e satélite a ocorrência de um SCM sobre a região de estudo, teve como objetivo principal demonstrar que a usabilidade do algoritmo para rastreios por meio da sinergia entre multi-sensores pode ser aplicável para uma melhor compreensão das características de deslocamento dos sistemas ao longo de seus ciclos de vida na bacia amazônica, além de uma possível melhoria na previsão de eventos mais severos.

De modo geral, o novo algoritmo mostrou por meio dos resultados avaliados que sua aplicabilidade é satisfatória, que a metodologia empregada na sua concepção pode ser utilizada para investigar os sistemas atmosféricos atuantes na bacia amazônica. Contudo muitas melhorias ainda precisam ser empregadas para atenuar as incertezas associadas ao rastreamento baseado na técnica de centroide e silhueta e na previsão por extrapolação. Tem-se como perspectiva a evolução destas metodologias para cada vez mais aprimorar os meios que levam a compreensão da dinâmica de desenvolvimento

e propagação dos sistemas atmosféricos atuantes na amazônia e no Brasil. Espera-se em trabalhos futuros implementar o uso de tecnologias como, inteligência artificial, aprendizado de máquina e técnicas para processamento de grandes volumes de dados. Além disso, pretende-se incorporar dentro do algoritmos novas funcionalidade que permitam o uso concomitante de diferentes sensores para o rastreo e previsão de um mesmo sistema.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AALST, W. van der. Data science in action. In: \_\_\_\_\_. **Process mining: data science in action**. Berlin, Heidelberg: [s.n.], 2016. p. 3–23. ISBN 978-3-662-49851-4. Disponível em: <[https://doi.org/10.1007/978-3-662-49851-4\\_1](https://doi.org/10.1007/978-3-662-49851-4_1)>. 7
- AGGARWAL, J.; CAI, Q.; LIAO, W.; SABATA, B. Articulated and elastic non-rigid motion: a review. In: WORKSHOP IN MOTION ON NON-RIGID AND ARTICULATE OBJECTS, 1994. **Proceedings...** [S.l.], 1994. p. 2–14. 19
- ALBRECHT, R. I.; GOODMAN, S. J.; BUECHLER, D. E.; BLAKESLEE, R. J.; CHRISTIAN, H. J. Where are the lightning hotspots on earth? **Bulletin of the American Meteorological Society**, v. 97, n. 11, p. 2051–2068, 2016. 1
- ANSELMO, E. M.; MACHADO, L. A.; SCHUMACHER, C. Cinematic characteristics of amazonian convective systems. 2019. Disponível em: <<http://mogyb.cptec.inpe.br/soschuva/pdf/relatorios/relatorio-2019/anexo17.pdf>>. Acesso em: 01 abr. 2021. 15, 16
- ANSELMO, E. M.; MACHADO, L. A.; SCHUMACHER, C.; KILADIS, G. N. Amazonian mesoscale convective systems: life cycle and propagation characteristics. **International Journal of Climatology**, 2021. 15, 81, 82
- ATLAS, D. **Radar in meteorology: Battan Memorial and 40th anniversary radar meteorology conference**. [S.l.]: Springer, 2015. 17
- BAR-SHALOM, Y.; FORTMANN, T. E.; CABLE, P. G. **Tracking and data association**. [S.l.]: Acoustical Society of America, 1990. 19
- BISHOP, C. M. **Pattern recognition and machine learning**. [S.l.]: Springer, 2006. 8
- BLACK, M. J.; JEPSON, A. D. Eigentracking: robust matching and tracking of articulated objects using a view-based representation. **International Journal of Computer Vision**, v. 26, n. 1, p. 63–84, 1998. 20
- BROWNING, K. Morphology and classification of middle-latitude thunderstorms. **Thunderstorm Morphology and Dynamics**, v. 133, p. 147, 1986. 15
- BROWNING, K. A. Review lecture: local weather forecasting. **Proceedings of the royal society of London. A. Mathematical and Physical Sciences**, v. 371, n. 1745, p. 179–211, 1980. 58, 59

- CALHEIROS, A. J. P. **Sistema de previsão imediata da precipitação: o hydrotrack**. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008. 70, 98
- CALHEIROS, A. J. P.; ENORÉ, D. P.; MATTOS, E. V.; COSTA, I. C. da; MACHADO, L. A. T. **Sistema de previsão imediata: descrição dos produtos**. [S.l.: s.n.], 2016. 2, 72
- CASSIANO, K. M. **Análise de séries temporais usando análise espectral singular (SSA) e clusterização de suas componentes baseada em densidade**. Tese (Doutorado em Engenharia Elétrica) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2014. 30
- CAVALCANTI, I. F. **Tempo e clima no Brasil**. [S.l.]: Oficina de Textos, 2016. 10
- CHALON, J.; JAUBERT, G.; LAFORE, J.; ROUX, F. The west african squall line observed on 23 june 1981 during copt 81: mesoscale structure and transports. **Journal of Atmospheric Sciences**, v. 45, n. 19, p. 2744–2763, 1988. 14
- CHENG, H.; SINHA, A.; CRUZ, F. W.; WANG, X.; EDWARDS, R. L.; D'HORTA, F. M.; RIBAS, C. C.; VUILLE, M.; STOTT, L. D.; AULER, A. S. Climate change patterns in amazonia and biodiversity. **Nature Communications**, v. 4, n. 1, p. 1–6, 2013. 3
- COHEN, J.; DIAS, M. S.; NOBRE, C. Aspectos climatológicos das linhas de instabilidade na amazônia. **Climanálise**, v. 4, n. 11, p. 34–40, 1989. 4, 14
- COMANICIU, D.; RAMESH, V.; MEER, P. Kernel-based object tracking. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 25, n. 5, p. 564–577, 2003. 20
- CORFIDI, S.; MERITT, J.; FRITSCH, J. Predicting the movement of mesoscale convective complexes. **Weather and Forecasting**, v. 11, n. 1, p. 41–46, 1996. 66
- CORREIA, F. W. S.; MANZI, A. O.; CÂNDIDO, L. A.; SANTOS, R. M. N. d.; PAULIQUEVIS, T. Balanço de umidade na amazônia e sua sensibilidade às mudanças na cobertura vegetal. **Ciência e Cultura**, v. 59, n. 3, p. 39–43, 2007. 10
- COTTON, W. R.; ANTHES, R. A. **Storm and cloud dynamics**. [S.l.]: Academic Press, 1992. 41, 64, 66, 68

CRANE, R. K. Automatic cell detection and tracking. **IEEE Transactions on Geoscience Electronics**, v. 17, n. 4, p. 250–262, 1979. 3, 15, 29, 51

DIXON, M.; WIENER, G. Titan: thunderstorm identification, tracking, analysis, and nowcasting—a radar-based methodology. **Journal of Atmospheric and Oceanic Technology**, v. 10, n. 6, p. 785–797, 1993. 3, 16, 35, 51, 59

DOYLE, W. Operations useful for similarity-invariant pattern recognition. **Journal of the ACM (JACM)**, v. 9, n. 2, p. 259–267, 1962. 29

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. [S.l.]: John Wiley & Sons, 2012. 8

EICHHOLZ, C. W. **Análise cinemática e dinâmica da propagação de células de chuva e aglomerados de nuvens**. 157 p. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017-05-23 2017. Disponível em: <<http://urlib.net/rep/8JMKD3MGP3W34P/3NQ5D2P>>. Acesso em: 05 mar. 2021. 18, 27, 82

ELAT, G. D. E. A. **Nova rede de dados revela aumento da média anual de raios no Brasil e densidades de descargas com maior precisão para estados e municípios**. 2015. Disponível em: <<http://www.inpe.br/webelat/homepage/menu/noticias/release.php?id=72>>. 1

ESTER, M.; KRIEGEL, H.-P.; SANDER, J.; XU, X. A density-based algorithm for discovering clusters in large spatial databases with noise. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING. **Proceedings...** [S.l.], 1996. p. 226–231. 30, 31

FAZOLO, E. L. **Estudo de novas técnicas para previsão a curto prazo do deslocamento do campo horizontal da atividade elétrica em tempestades**. Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2019. 38, 39, 70, 71, 97, 98

FERREIRA, R. C. **Estudo de sistemas convectivos de mesoescala com uso de assimilação de dados de radar**. Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016. 11

FISCH, G.; MARENGO, J. A.; NOBRE, C. A. Uma revisão geral sobre o clima da amazônia. **Acta Amazônica**, v. 28, n. 2, p. 101–101, 1998. 4, 10

GAGNE, D. J.; MCGOVERN, A.; HAUPT, S. E.; SOBASH, R. A.; WILLIAMS, J. K.; XUE, M. Storm-based probabilistic hail forecasting with machine learning applied to convection-allowing ensembles. **Weather and Forecasting**, v. 32, n. 5, p. 1819–1840, 2017. 3

GAMACHE, J. F.; HOUZE JUNIOR, R. A. Mesoscale air motions associated with a tropical squall line. **Monthly Weather Review**, v. 110, n. 2, p. 118–135, 1982. 14, 15

GARSTANG, M.; MASSIE, H. L.; HALVERSON, J.; GRECO, S.; SCALA, J. Amazon coastal squall lines. part i: structure and kinematics. **Monthly Weather Review**, v. 122, n. 4, p. 608–622, 1994. 15, 59, 66

GOODMAN, S. J. et al. The goes-r proving ground: accelerating user readiness for the next-generation geostationary environmental satellite system. **Bulletin of the American Meteorological Society**, v. 93, n. 7, p. 1029–1040, 2012. 2

GRECO, S.; SWAP, R.; GARSTANG, M.; ULANSKI, S.; SHIPHAM, M.; HARRISS, R.; TALBOT, R.; ANDREAE, M.; ARTAXO, P. Rainfall and surface kinematic conditions over central amazonia during able 2b. **Journal of Geophysical Research: Atmospheres**, v. 95, n. D10, p. 17001–17014, 1990. 14, 15

GRIRA, N.; CRUCIANU, M.; BOUJEMAA, N. Unsupervised and semi-supervised clustering: a brief survey. In: CORD, M.; CUNNINGHAM, P.; DAHYOT, R.; SZIRANYI, T. (Ed.). ‘**A review of machine learning techniques for processing multimedia content**’, report of the muscle European network of excellence. [S.l.: s.n.], 2004. 30

HAUSDORFF, F. **Set theory**. [S.l.]: American Mathematical Society (RI), 1991. 20

HOUZE JUNIOR, R. A. Structure and dynamics of a tropical squall–line system. **Monthly Weather Review**, v. 105, n. 12, p. 1540–1567, 1977. 14, 54

\_\_\_\_\_. Stratiform precipitation in regions of convection: a meteorological paradox? **Bulletin of the American Meteorological Society**, v. 78, n. 10, p. 2179–2196, 1997. 11, 14, 15, 44, 54, 58, 59

\_\_\_\_\_. Mesoscale convective systems. **Reviews of Geophysics**, v. 42, n. 4, 2004. 11, 91

\_\_\_\_\_. **Cloud dynamics**. [S.l.]: Academic Press, 2014. 12, 14, 15, 56

JAMES, P. M.; REICHERT, B. K.; HEIZENREDER, D. Nowcastmix: automatic integrated warnings for severe convection on nowcasting time scales at the german weather service. **Weather and Forecasting**, v. 33, n. 5, p. 1413–1433, 2018. 18

JOHNSON, J.; MACKEEN, P. L.; WITT, A.; MITCHELL, E. D. W.; STUMPF, G. J.; EILTS, M. D.; THOMAS, K. W. The storm cell identification and tracking algorithm: an enhanced wsr-88d algorithm. **Weather and Forecasting**, v. 13, n. 2, p. 263–276, 1998. 17, 35, 51

KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions of the ASME–Journal of Basic Engineering**, v. 82, p. 35–45, 1960. 19

KESSLER, E. **Thunderstorms—a social, scientific, & technological documentary: thunderstorm morphology and dynamics**. [S.l.]: US Department of Commerce, National Oceanic and Atmospheric Administration . . . , 1982. 15

KHANDAN, R.; ALAVIPANAH, S. K.; BIAZAR, A. P.; GHARAYLOU, M. Probabilistic convective initiation nowcasting with reduced satellite-nwp predictors over Iran. **Asia-Pacific Journal of Atmospheric Sciences**, v. 54, n. 3, p. 431–443, 2018. 3

KOBER, K.; TAFFERNER, A. Tracking and nowcasting of convective cells using remote sensing data from radar and satellite. **Meteorologische Zeitschrift**, v. 18, n. 1, p. 75–84, 2009. 27

KOUSKY, V. E. Diurnal rainfall variation in northeast brazil. **Monthly Weather Review**, v. 108, n. 4, p. 488–498, 1980. 14, 66

KURIHANA, T.; FOSTER, I.; WILLETT, R.; JENKINS, S.; KURIHANA, K.; WERMAN, R.; LOURENCO, R. B.; NEO, C.; MOYER, E. Cloud classification with unsupervised deep learning. In: INTERNATIONAL WORKSHOP ON CLIMATE INFORMATICS, 9. **Proceedings...** [S.l.], 2019. 3

LAKSHMANAN, V.; HONDL, K.; RABIN, R. An efficient, general-purpose technique for identifying storm cells in geospatial images. **Journal of Atmospheric and Oceanic Technology**, v. 26, n. 3, p. 523–537, 2009. 3

- LAURENT, H.; MACHADO, L. A.; MORALES, C. A.; DURIEUX, L. Characteristics of the amazonian mesoscale convective systems observed from satellite and radar during the wetamc/lba experiment. **Journal of Geophysical Research: Atmospheres**, v. 107, n. D20, p. LBA–21, 2002. 66, 81
- LAURINI, R.; THOMPSON, D. **Fundamentals of spatial information systems**. [S.l.]: Academic Press, 1992. 32
- LEAL NETO, H. B.; ALMEIDA, A. P.; CALHEIROS, A. J. As dificuldades no rastreamento de tempestades com uso de refletividade radar a partir de técnicas de geoprocessamento: um estudo de caso sobre a região amazônica. In: BRAZILIAN SYMPOSIUM ON GEOINFORMATICS (GEOINFO). **Proceedings...** São José dos Campos, 2020. p. 240–245. 40
- LI, W.; FU, R. Transition of the large-scale atmospheric and land surface conditions from the dry to the wet season over amazonia as diagnosed by the ecmwf re-analysis. **Journal of Climate**, v. 17, n. 13, p. 2637–2651, 2004. 82
- LOUREIRO, R. S. d.; SARAIVA, J. M.; SARAIVA, I.; SENNA, R. C.; FREDÓ, A. S. Estudo dos eventos extremos de precipitação ocorridos em 2009 no estado do Pará. **Revista Brasileira de Meteorologia**, v. 29, n. SPE, p. 83–94, 2014. 4
- MACHADO, L.; ROSSOW, W.; GUEDES, R.; WALKER, A. Life cycle variations of mesoscale convective systems over the americas. **Monthly Weather Review**, v. 126, n. 6, p. 1630–1654, 1998. 2, 11, 12, 81, 83, 98
- MACHADO, L. A.; LAURENT, H.; LIMA, A. A. Diurnal march of the convection observed during trmm-wetamc/lba. **Journal of Geophysical Research: Atmospheres**, v. 107, n. D20, p. LBA–31, 2002. 27, 77
- MACHADO, L. A. et al. Overview: precipitation characteristics and sensitivities to environmental conditions during goamazon2014/5 and acridicon-chuva. **Atmospheric Chemistry and Physics**, v. 18, n. BNL-205803-2018-JAAM, 2018. 13, 27, 49, 54, 56
- MACHADO, L. A. T.; LAURENT, H. The convective system area expansion over amazonia and its relationships with convective system life duration and high-level wind divergence. **Monthly Weather Review**, v. 132, n. 3, p. 714–725, 2004. 3, 81
- MAIMON, O.; ROKACH, L. **Data mining and knowledge discovery handbook**. [S.l.]: Berlin: Springer, 2005. 30

- MARKOWSKI, P.; RICHARDSON, Y. **Mesoscale meteorology in midlatitudes**. [S.l.]: John Wiley & Sons, 2011. 81
- MARSHALL, J. S.; PALMER, W. M. K. The distribution of raindrops with size. **Journal of Meteorology**, v. 5, n. 4, p. 165–166, 1948. 27
- MARTIN, S. T.; ARTAXO, P.; MACHADO, L.; MANZI, A. O.; SOUZA, R. d.; SCHUMACHER, C.; WANG, J.; BISCARO, T.; BRITO, J.; CALHEIROS, A. The green ocean amazon experiment (goamazon2014/5) observes pollution affecting gases, aerosols, clouds, and rainfall over the rain forest. **Bulletin of the American Meteorological Society**, v. 98, n. 5, p. 981–997, 2017. 4
- MARTINS, S. R.; SCHLINDWEIN, S. L.; D'AGOSTINI, L. R.; BONATTI, M.; VASCONCELOS, A. C. F. de; HOFFMANN, A. F.; FANTINI, A. C. Mudanças climáticas e vulnerabilidade na agricultura: desafios para desenvolvimento de estratégias de mitigação e adaptação. **Revista Brasileira de Ciências Ambientais**, n. 17, p. 17–27, 2010. 1
- MATHON, V.; LAURENT, H. Life cycle of sahelian mesoscale convective cloud systems. **Quarterly Journal of the Royal Meteorological Society**, v. 127, n. 572, p. 377–406, 2001. 35
- MATTHEWS, J.; TROSTEL, J. **An Improved Storm Cell Identification and Tracking (SCIT) Algorithm based on DBSCAN Clustering and JPDA Tracking Methods**. 2010. Disponível em: <<https://ams.confex.com/ams/pdfpapers/164442.pdf>>. Acesso em: 9 jul. 2021. 3, 17, 35
- MINOTTA-ZAPATA, F.; RODRÍGUEZ-SOLÍS, R. A. A clustering method for rain-cell detection in weather nowcasting approaches. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. **Proceedings...** [S.l.], 2019. p. 53424–3427. 3
- MOLION, L. On the dynamic climatology of the amazon basin and associated rain-producing mechanisms. In: DICKINSON, R. E. (Ed.). **Geophysiology of Amazonia**. New York: John Wiley and Sons: [s.n.], 1987. 14
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: REZENDE, S. O. (Ed.). **Sistemas inteligentes-Fundamentos e aplicações**. [S.l.]: Manole, 2003. v. 1, n. 1, p. 32. 8

MONCRIEFF, M. The dynamical structure of two-dimensional steady convection in constant vertical shear. **Quarterly Journal of the Royal Meteorological Society**, v. 104, n. 441, p. 543–567, 1978. 66

MULHOLLAND, J. P.; NESBITT, S. W.; TRAPP, R. J.; RASMUSSEN, K. L.; SALIO, P. V. Convective storm life cycle and environments near the Sierras de Córdoba, Argentina. **Monthly Weather Review**, v. 146, n. 8, p. 2541–2557, 2018. 71

MURPHY, A. H. What is a good forecast? an essay on the nature of goodness in weather forecasting. **Weather and Forecasting**, v. 8, n. 2, p. 281–293, 1993. 46

NEGRÓN-JUÁREZ, R. I.; CHAMBERS, J. Q.; GUIMARAES, G.; ZENG, H.; RAUPP, C. F.; MARRA, D. M.; RIBEIRO, G. H.; SAATCHI, S. S.; NELSON, B. W.; HIGUCHI, N. Widespread amazon forest tree mortality from a single cross-basin squall line event. **Geophysical Research Letters**, v. 37, n. 16, 2010. 4

NEWTON, C. W. Structure and mechanism of the prefrontal squall line. **Journal of Atmospheric Sciences**, v. 7, n. 3, p. 210–222, 1950. 14

NEWTON, C. W.; FANKHAUSER, J. C. Movement and propagation of multicellular convective storms. **Pure and Applied Geophysics**, v. 113, n. 1, p. 747–764, 1975. 66

NEWTON, C. W.; NEWTON, H. R. Dynamical interactions between large convective clouds and environment with vertical shear. **Journal of Atmospheric Sciences**, v. 16, n. 5, p. 483–496, 1959. 15

NOBRE, A. D. **O futuro climático da Amazônia**. São José dos Campos, São Paulo: [s.n.], 2014. Disponível em: <<http://www.pbmc.coppe.ufrj.br/documentos/futuro-climatico-da-amazonia.pdf>>. Acesso em: 9 jul. 2021. 3

NOBRE, C. A. Mudanças climáticas globais: possíveis impactos nos ecossistemas do país. **Parcerias Estratégicas**, v. 6, n. 12, p. 239–258, 2010. 1

NOBRE, C. A.; OBREGÓN, G. O.; MARENGO, J. A.; FU, R.; POVEDA, G. Características do clima amazônico: aspectos principais. In: KELLER, M.; BUSTAMANTE, M.; GASH, J.; DIAS, P. S. **Amazonia and global change**. EGU, 2009. p. 149–162. Disponível em: <[https://daac.ornl.gov/LBA/lbaconferencia/amazonia\\_global\\_change/10\\_Characteristicas\\_Nobre.pdf](https://daac.ornl.gov/LBA/lbaconferencia/amazonia_global_change/10_Characteristicas_Nobre.pdf)>. Acesso em: 9 jul. 2021. 21, 54, 56

- NUNES, A. M.; DIAS, M. A. S.; ANSELMO, E. M.; MORALES, C. A. Severe convection features in the amazon basin: a trmm-based 15-year evaluation. **Frontiers in Earth Science**, v. 4, p. 37, 2016. [81](#), [82](#)
- OLIVEIRA, A. P. D.; FITZJARRALD, D. R. The amazon river breeze and the local boundary layer: Ii. linear analysis and modelling. **Boundary-Layer Meteorology**, v. 67, n. 1, p. 75–96, 1994. [66](#)
- OLIVEIRA, T. B. S. **Clusterização de dados utilizando técnicas de redes complexas e computação bioinspirada**. 91 p. Dissertação (Mestrado em Ciências da Computação e Matemática Computacional) — Universidade de São Paulo, 2008. [31](#)
- O’NEIL, C.; SCHUTT, R. **Doing data science: straight talk from the frontline**. [S.l.]: O’Reilly Media, 2013. [xv](#), [7](#), [8](#)
- ORLANSKI, I. A rational subdivision of scales for atmospheric processes. **Bulletin of the American Meteorological Society**, JSTOR, p. 527–530, 1975. [4](#)
- PEREIRA FILHO, A. J.; CARBONE, R. E.; TUTTLE, J. D.; KARAM, H. A. Convective rainfall in Amazonia and adjacent tropics. **Atmospheric and Climate Sciences**, v. 5, n. 02, p. 137, 2015. [15](#)
- PEREIRA, R. F. d. O. **Propriedades físicas da precipitação e eletrificação dos sistemas precipitantes observados durante o projeto chuva-manaus e goamazon**. Tese (Doutorado em Meteorologia) — Universidade de São Paulo, São Paulo, 2019. [65](#)
- QUEIROZ, A. P. de. **Monitoramento e previsão imediata de tempestades severas usando dados de radar**. Dissertação (Mestrado em Meteorologia) — Universidade de São Paulo, São José dos Campos, 2009. [2](#), [4](#)
- REHBEIN, A.; AMBRIZZI, T. **Sistemas convectivos de mesoescala observados na bacia Amazônica durante o projeto GOAmazon**. Dissertação (Mestrado em Meteorologia) — Universidade de São Paulo, São Paulo, 2016. [11](#), [12](#)
- REHBEIN, A.; AMBRIZZI, T.; MECHOSO, C. R. Mesoscale convective systems over the amazon basin. part i: climatological aspects. **International Journal of Climatology**, v. 38, n. 1, p. 215–229, 2018. [12](#), [27](#)
- RONFARD, R. Region-based strategies for active contour models. **International Journal of Computer Vision**, v. 13, n. 2, p. 229–251, 1994. [20](#)

- SCHUBERT, E.; SANDER, J.; ESTER, M.; KRIEGEL, H. P.; XU, X. Dbscan revisited, revisited: why and how you should (still) use dbscan. **ACM Transactions on Database Systems (TODS)**, v. 42, n. 3, p. 1–21, 2017. 30
- SCHUMACHER, C.; FUNK, A. **GoAmazon2014/5 Rain Rates from the SIPAM Manaus S-band Radar**. 4 2018. Disponível em: <<https://www.osti.gov/dataexplorer/biblio/dataset/1459578>>. Acesso em: 9 jul. 2021. 22
- SHI, J. et al. Good features to track. In: **CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION**. [S.l.]: IEEE, 1994. p. 593–600. 20
- STORLIE, C. B.; LEE, T. C.; HANNIG, J.; NYCHKA, D. Tracking of multiple merging and splitting targets: a statistical perspective. **Statistica Sinica**, p. 1–31, 2009. 39
- STREIT, R. L.; LUGINBUHL, T. E. Maximum likelihood method for probabilistic multihypothesis tracking. In: **INTERNATIONAL SYMPOSIUM FOR OPTICS AND PHOTONICS. Proceedings...** [S.l.], 1994. v. 2235, p. 394–405. 19
- SU, A.; LI, H.; CUI, L.; CHEN, Y. A convection nowcasting method based on machine learning. **Advances in Meteorology**, v. 2020, 2020. 18, 19
- TORN, R. **Dynamic meteorology iii**. 2014. Disponível em: <[http://www.atmos.albany.edu/daes/atmclasses/atm418/atmosphere\\_scales.png](http://www.atmos.albany.edu/daes/atmclasses/atm418/atmosphere_scales.png)>. 10
- TSONIS, A.; AUSTIN, G. An evaluation of extrapolation techniques for the short-term prediction of rain amounts. **Atmosphere-Ocean**, v. 19, n. 1, p. 54–65, 1981. 38
- TUKEY, J. W. et al. **Exploratory data analysis**. [S.l.]: Reading, Mass., 1977. 7
- VALÊNCIO, C. R.; DANIEL, G. P.; MEDEIROS, C. A. D.; CANSIAN, A. M.; BAIDA, L. C.; FERRARI, F. Vdbscan+: Performance optimization based on gpu parallelism. In: **INTERNATIONAL CONFERENCE ON PARALLEL AND DISTRIBUTED COMPUTING, APPLICATIONS AND TECHNOLOGIES**. [S.l.]: IEEE, 2013. p. 23–28. 32
- VELASCO, I.; FRITSCH, J. M. Mesoscale convective complexes in the americas. **Journal of Geophysical Research: Atmospheres**, v. 92, n. D8, p. 9591–9613, 1987. 11, 82, 83

VILA, D. A.; MACHADO, L. A. T.; LAURENT, H.; VELASCO, I. Forecast and tracking the evolution of cloud clusters (fortracc) using satellite infrared imagery: methodology and validation. **Weather and Forecasting**, v. 23, n. 2, p. 233–245, 2008. 3, 13, 16, 27, 35, 36, 37, 38, 51, 59, 63, 65, 77

WILKS, D. S. **Statistical methods in the atmospheric sciences**. [S.l.]: Academic Press, 2011. 46, 53

WILLIAMS, M.; HOUZE JUNIOR, R. A. Satellite-observed characteristics of winter monsoon cloud clusters. **Monthly Weather Review**, v. 115, n. 2, p. 505–519, 1987. 2, 11

WILSON, J. W.; CROOK, N. A.; MUELLER, C. K.; SUN, J.; DIXON, M. Nowcasting thunderstorms: a status report. **Bulletin of the American Meteorological Society**, v. 79, n. 10, p. 2079–2100, 1998. 1

WMO, W. M. O. **Guidelines for nowcasting techniques**. 2017. Acessado em: 20 abr. 2021. Disponível em: <[https://journals.ametsoc.org/view/journals/wefo/33/1/waf-d-17-0099\\_1.xml](https://journals.ametsoc.org/view/journals/wefo/33/1/waf-d-17-0099_1.xml)>. 18

YILMAZ, A.; JAVED, O.; SHAH, M. Object tracking: a survey. **ACM Computing Surveys**, v. 38, n. 4, p. 13–es, 2006. 19



## APÊNDICE A - TABELA COM PARÂMETROS ESTATÍSTICOS

Tabela D.1 - Resultados dos parâmetros de rastreo com o modo operacional BASE sem aplicação dos métodos de correção vetorial.

Métodos	<i>Hit</i>	<i>Miss</i>	<i>False Alarm</i>	POD	FAR	BIAS
Ctvo-BASE-20-15	10245734	5371487	5391783	0.656	0.344	1.0186
Ctvo-BASE-20-30	10162395	5122969	5153394	0.664	0.336	1.0189
Ctvo-BASE-30-15	1869881	1777084	1813814	0.512	0.492	1.0399
Ctvo-BASE-30-30	1796633	1618923	1645621	0.526	0.479	1.0368
Ctvo-BASE-35-15	505413	712120	734750	0.415	0.592	1.0517
Ctvo-BASE-35-30	449267	592594	612267	0.431	0.576	1.0510
Mdd2-BASE-20-15	9916765	4519962	4632780	0.686	0.318	1.0101
Mdd2-BASE-20-30	9913211	4399915	4497970	0.692	0.312	1.0078
Mdd2-BASE-30-15	1786918	1427829	1495513	0.555	0.455	1.0211
Mdd2-BASE-30-30	1735946	1327995	1381781	0.566	0.443	1.0176
Mdd2-BASE-35-15	463817	572095	613415	0.447	0.569	1.0277
Mdd2-BASE-35-30	412994	481483	514358	0.461	0.554	1.0241
Mdd3-BASE-20-15	9469972	3911518	4047670	0.707	0.299	1.0013
Mdd3-BASE-20-30	9517719	3856982	3975612	0.711	0.294	1.0020
Mdd3-BASE-30-15	1651982	1188653	1267203	0.581	0.434	1.0078
Mdd3-BASE-30-30	1616828	1120137	1186183	0.590	0.423	1.0069
Mdd3-BASE-35-15	410137	465403	510697	0.468	0.554	1.0102
Mdd3-BASE-35-30	364998	394246	432948	0.480	0.542	1.0089

Fonte: Produção do Autor.

Tabela D.2 - Índices estatísticos do IOP1 para os métodos de correção vetorial, extrapolação e parâmetros de rastreo.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd3-DIV/LIM-20-30	6493422	1822177	1861126	0.7809	0.2228	25.43
Mdd3-LIM-20-30	6493140	1822459	1861413	0.7808	0.2228	25.42
Mdd3-DIV/LIM/VET-20-30	6495378	1823132	1861985	0.7808	0.2228	25.42
Mdd3-LIM/VET-20-30	6495242	1823268	1862126	0.7808	0.2228	25.42
Mdd3-DIV/LIM-20-15	6444242	1810038	1862986	0.7807	0.2243	25.38
Mdd3-LIM-20-15	6444099	1810181	1863126	0.7807	0.2243	25.38
Mdd3-DIV/FUS/LIM-20-30	6481851	1823002	1862985	0.7805	0.2233	25.3
Mdd3-FUS/LIM-20-30	6481528	1823325	1863310	0.7805	0.2233	25.29
Mdd3-LIM/VET-20-15	6450550	1820298	1872801	0.7799	0.225	25.11
Mdd3-DIV/LIM/VET-20-15	6450429	1820419	1872915	0.7799	0.225	25.1
Mdd3-TODOS-20-15	6437340	1819405	1871691	0.7796	0.2253	25.02
Mdd3-VET/FUS/LIM-20-15	6437062	1819683	1871974	0.7796	0.2253	25.01
Mdd3-DIV/FUS/LIM-20-15	6432592	1824599	1877483	0.779	0.2259	24.81
Mdd3-FUS/LIM-20-15	6432295	1824896	1877774	0.779	0.226	24.8

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd3-TODOS-20-30	6442215	1847822	1887203	0.7771	0.2266	24.15
Mdd3-VET/FUS/LIM-20-30	6442171	1847866	1887245	0.7771	0.2266	24.15
Mdd2-DIV/LIM-20-15	6776212	2107501	2142919	0.7628	0.2403	19.27
Mdd2-LIM-20-15	6775737	2107976	2143374	0.7627	0.2403	19.26
Mdd2-VET/FUS/LIM-20-30	6758916	2114541	2142107	0.7617	0.2407	18.91
Mdd2-TODOS-20-30	6758904	2114553	2142132	0.7617	0.2407	18.91
Mdd2-DIV/FUS/LIM-20-30	6758439	2116507	2143840	0.7615	0.2408	18.85
Mdd2-DIV/LIM/VET-20-15	6766041	2119161	2154962	0.7615	0.2416	18.84
Mdd2-FUS/LIM-20-30	6758205	2116741	2144066	0.7615	0.2408	18.84
Mdd2-DIV/LIM-20-30	6756565	2116892	2143855	0.7614	0.2409	18.82
Mdd2-LIM/VET-20-15	6765493	2119709	2155539	0.7614	0.2416	18.82
Mdd2-LIM-20-30	6756397	2117060	2144001	0.7614	0.2409	18.81
Mdd2-TODOS-20-15	6760222	2123829	2158232	0.7609	0.242	18.65
Mdd2-VET/FUS/LIM-20-15	6759552	2124499	2158917	0.7609	0.2421	18.63
Mdd2-DIV/FUS/LIM-20-15	6759081	2126120	2161381	0.7607	0.2423	18.57
Mdd2-FUS/LIM-20-15	6758635	2126566	2161809	0.7607	0.2423	18.56
Mdd2-DIV/LIM/VET-20-30	6750236	2124710	2151693	0.7606	0.2417	18.53
Mdd2-LIM/VET-20-30	6749965	2124981	2151968	0.7606	0.2417	18.52
Mdd3-DIV-20-30	6258259	2051369	2088749	0.7531	0.2502	16.0
Mdd3-BASE-20-30	6256931	2052697	2090068	0.753	0.2504	15.94
Mdd3-DIV-20-15	6207437	2053673	2103007	0.7514	0.2531	15.41
Mdd3-BASE-20-15	6206161	2054949	2104274	0.7513	0.2532	15.35
Mdd3-DIV/VET-20-30	6152073	2106463	2144842	0.7449	0.2585	13.21
Mdd3-VET-20-30	6151742	2106794	2145228	0.7449	0.2586	13.19
Mdd3-DIV/VET-20-15	6101449	2108569	2159109	0.7432	0.2614	12.61
Mdd3-VET-20-15	6101373	2108645	2159151	0.7432	0.2614	12.6
Mdd2-DIV-20-30	6522533	2339445	2360844	0.736	0.2658	10.17
Mdd2-BASE-20-30	6518812	2343166	2364252	0.7356	0.2662	10.03
Mdd2-DIV-20-15	6503656	2371118	2400008	0.7328	0.2696	9.09
Mdd2-BASE-20-15	6500672	2374102	2402825	0.7325	0.2699	8.97
Ctvo-DIV/LIM-20-30	7080667	2632052	2632358	0.729	0.271	7.79
Ctvo-LIM-20-30	7079761	2632680	2632847	0.7289	0.2711	7.76
Ctvo-DIV/FUS/LIM-20-30	7059574	2647914	2652045	0.7272	0.2731	7.18
Ctvo-FUS/LIM-20-30	7058662	2648548	2652511	0.7272	0.2731	7.16
Ctvo-DIV/LIM-20-15	7146853	2686254	2687703	0.7268	0.2733	7.04
Ctvo-LIM-20-15	7145424	2687405	2688619	0.7267	0.2734	7.0
Ctvo-DIV/LIM/VET-20-30	7055963	2655775	2654530	0.7265	0.2734	6.95
Ctvo-LIM/VET-20-30	7055223	2656237	2654766	0.7265	0.2734	6.93
Mdd2-DIV/VET-20-30	6358883	2400785	2421668	0.7259	0.2758	6.74
Ctvo-TODOS-20-30	7045273	2661769	2665011	0.7258	0.2745	6.69
Ctvo-VET/FUS/LIM-20-30	7044539	2662225	2665214	0.7257	0.2745	6.67
Mdd2-VET-20-30	6356781	2402887	2423487	0.7257	0.276	6.66
Ctvo-DIV/LIM/VET-20-15	7117363	2714637	2715197	0.7239	0.2761	6.05
Ctvo-LIM/VET-20-15	7115859	2715863	2716080	0.7238	0.2763	6.0
Mdd2-DIV/VET-20-15	6339825	2435729	2462746	0.7224	0.2798	5.55
Ctvo-DIV/FUS/LIM-20-15	7095393	2727720	2732626	0.7223	0.278	5.51
Mdd2-VET-20-15	6338187	2437367	2464165	0.7223	0.2799	5.49
Ctvo-FUS/LIM-20-15	7093986	2728849	2733534	0.7222	0.2782	5.47
Ctvo-TODOS-20-15	7081304	2739865	2744201	0.721	0.2793	5.07
Ctvo-VET/FUS/LIM-20-15	7079787	2741104	2745228	0.7209	0.2794	5.02
Ctvo-DIV-20-30	6819820	2748738	2733896	0.7127	0.2862	2.25
Ctvo-BASE-20-30	6747898	2729398	2706647	0.712	0.2863	2.0
Ctvo-DIV-20-15	6832391	2836151	2822839	0.7067	0.2924	0.18

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Ctvo-BASE-20-15	6775898	2819973	2797795	0.7061	0.2922	0.0
Ctvo-DIV/VET-20-30	6565288	2883149	2875885	0.6949	0.3046	-3.84
Ctvo-VET-20-30	6495437	2861738	2845520	0.6942	0.3046	-4.07
Ctvo-DIV/VET-20-15	6570939	2981670	2978882	0.6879	0.3119	-6.21
Ctvo-VET-20-15	6516230	2963708	2951899	0.6874	0.3118	-6.38
Mdd3-DIV/FUS/VET-20-30	5419769	2474337	2518056	0.6866	0.3172	-6.66
Mdd3-FUS/VET-20-30	5417231	2476875	2520605	0.6862	0.3175	-6.77
Mdd3-DIV/FUS-20-30	5358744	2463092	2498023	0.6851	0.3179	-7.15
Mdd3-FUS-20-30	5356759	2465077	2499979	0.6848	0.3182	-7.24
Mdd3-DIV/FUS/VET-20-15	5187334	2617445	2654698	0.6646	0.3385	-14.12
Mdd3-FUS/VET-20-15	5186315	2618464	2655706	0.6645	0.3387	-14.16
Mdd3-DIV/FUS-20-15	5166272	2621297	2665400	0.6634	0.3403	-14.54
Mdd3-FUS-20-15	5164681	2622888	2666973	0.6632	0.3405	-14.61
Mdd2-DIV/FUS-20-30	5441968	2778661	2800850	0.662	0.3398	-15.02
Mdd2-FUS-20-30	5437954	2782675	2804605	0.6615	0.3403	-15.19
Mdd2-DIV/FUS/VET-20-30	5476095	2807129	2826303	0.6611	0.3404	-15.32
Mdd2-FUS/VET-20-30	5472989	2810235	2829354	0.6607	0.3408	-15.45
Mdd3-FUS/LIM-30-30	985576	515592	548995	0.6565	0.3578	-16.87
Mdd3-DIV/FUS/LIM-30-30	985571	515597	549009	0.6565	0.3578	-16.87
Mdd3-VET/FUS/LIM-30-30	984581	516587	549898	0.6559	0.3584	-17.1
Mdd3-TODOS-30-30	984422	516746	550075	0.6558	0.3585	-17.14
Mdd3-DIV/LIM-30-30	981006	520162	553521	0.6535	0.3607	-17.91
Mdd3-LIM-30-30	980961	520207	553562	0.6535	0.3607	-17.92
Mdd3-DIV/LIM/VET-30-30	978881	522287	555588	0.6521	0.3621	-18.39
Mdd3-LIM/VET-30-30	978803	522365	555654	0.652	0.3621	-18.41
Mdd3-DIV/FUS/LIM-30-15	996010	539560	579124	0.6486	0.3677	-19.57
Mdd3-FUS/LIM-30-15	995919	539651	579226	0.6486	0.3677	-19.59
Mdd3-DIV/LIM/VET-30-15	995307	540263	579702	0.6482	0.3681	-19.72
Mdd3-LIM/VET-30-15	995071	540499	579947	0.648	0.3682	-19.77
Mdd3-DIV/LIM-30-15	994165	541405	580818	0.6474	0.3688	-19.98
Mdd3-LIM-30-15	994057	541513	580932	0.6474	0.3688	-20.0
Mdd3-VET/FUS/LIM-30-15	989880	545690	585378	0.6446	0.3716	-20.92
Mdd3-TODOS-30-15	989852	545718	585393	0.6446	0.3716	-20.93
Ctvo-DIV/FUS-20-30	5730104	3240231	3232499	0.6388	0.3607	-22.92
Mdd2-DIV/FUS/VET-20-15	5213362	2957512	2967223	0.638	0.3627	-23.17
Mdd2-FUS/VET-20-15	5211201	2959673	2969292	0.6378	0.363	-23.26
Ctvo-FUS-20-30	5657992	3221081	3205564	0.6372	0.3617	-23.44
Mdd2-DIV/FUS-20-15	5160977	2963948	2985034	0.6352	0.3664	-24.13
Mdd2-FUS-20-15	5157940	2966985	2987896	0.6348	0.3668	-24.26
Mdd2-DIV/FUS/LIM-30-30	1069992	617376	646303	0.6341	0.3766	-24.5
Mdd2-FUS/LIM-30-30	1069875	617493	646425	0.634	0.3766	-24.53
Mdd2-VET/FUS/LIM-30-30	1069024	618344	647164	0.6335	0.3771	-24.7
Mdd2-TODOS-30-30	1069021	618347	647148	0.6335	0.3771	-24.7
Mdd3-DIV-30-30	950981	550187	583434	0.6335	0.3802	-24.72
Mdd3-BASE-30-30	950545	550623	583863	0.6332	0.3805	-24.81
Mdd2-DIV/LIM-30-30	1061620	625748	654149	0.6292	0.3813	-26.19
Mdd2-LIM-30-30	1061620	625748	654186	0.6292	0.3813	-26.19
Mdd2-LIM/VET-30-30	1061152	626216	654538	0.6289	0.3815	-26.29
Mdd2-DIV/LIM/VET-30-30	1061072	626296	654578	0.6288	0.3815	-26.3
Mdd3-DIV-30-15	962109	573461	612915	0.6265	0.3891	-27.08
Mdd3-BASE-30-15	961624	573946	613395	0.6262	0.3895	-27.19
Ctvo-DIV/FUS/VET-20-30	5557857	3344676	3338580	0.6243	0.3753	-27.84
Ctvo-FUS/VET-20-30	5487626	3323645	3308682	0.6228	0.3761	-28.36

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd2-DIV/FUS/LIM-30-15	1088387	660572	698109	0.6223	0.3908	-28.52
Mdd2-FUS/LIM-30-15	1088122	660837	698372	0.6222	0.3909	-28.57
Mdd2-DIV/LIM/VET-30-15	1084651	664308	701195	0.6202	0.3926	-29.25
Mdd2-LIM/VET-30-15	1084418	664541	701433	0.62	0.3928	-29.29
Mdd2-TODOS-30-15	1084223	664736	702499	0.6199	0.3932	-29.33
Mdd2-VET/FUS/LIM-30-15	1083986	664973	702747	0.6198	0.3933	-29.38
Mdd3-VET-30-30	930328	570840	603864	0.6197	0.3936	-29.4
Mdd3-DIV/VET-30-30	930284	570884	603945	0.6197	0.3936	-29.41
Mdd2-DIV/LIM-30-15	1083543	665416	702181	0.6195	0.3932	-29.47
Mdd2-LIM-30-15	1083358	665601	702363	0.6194	0.3933	-29.5
Mdd3-DIV/VET-30-15	940659	594911	634102	0.6126	0.4027	-31.83
Mdd3-VET-30-15	940553	595017	634183	0.6125	0.4027	-31.86
Mdd3-DIV/FUS-30-30	911582	578726	611464	0.6117	0.4015	-32.14
Mdd3-FUS-30-30	910996	579312	612024	0.6113	0.4018	-32.27
Mdd3-DIV/FUS/VET-30-30	916258	584910	617758	0.6104	0.4027	-32.59
Mdd3-FUS/VET-30-30	916255	584913	617701	0.6104	0.4027	-32.59
Mdd2-DIV-30-30	1028511	658857	686597	0.6095	0.4003	-32.87
Mdd2-BASE-30-30	1027046	660322	687941	0.6087	0.4011	-33.16
Ctvo-DIV/FUS-20-15	5341036	3522892	3506079	0.6026	0.3963	-35.24
Mdd3-DIV/FUS-30-15	917554	607038	646570	0.6018	0.4134	-35.49
Mdd3-FUS-30-15	916926	607666	647181	0.6014	0.4138	-35.63
Ctvo-FUS-20-15	5284512	3506745	3481171	0.6011	0.3971	-35.74
Mdd2-DIV-30-15	1050608	698351	734538	0.6007	0.4115	-35.87
Mdd2-BASE-30-15	1049288	699671	735772	0.6	0.4122	-36.13
Mdd2-DIV/VET-30-30	997831	689537	717325	0.5914	0.4182	-39.06
Mdd2-VET-30-30	997185	690183	717779	0.591	0.4185	-39.19
Ctvo-FUS/LIM-30-30	1142655	795068	815126	0.5897	0.4164	-39.62
Ctvo-DIV/FUS/LIM-30-30	1142503	795220	815256	0.5896	0.4164	-39.65
Ctvo-DIV/FUS/VET-20-15	5182890	3607790	3580938	0.5896	0.4086	-39.66
Mdd3-DIV/FUS/VET-30-15	901873	628251	666811	0.5894	0.4251	-39.72
Mdd3-FUS/VET-30-15	901848	628276	666776	0.5894	0.4251	-39.72
Ctvo-FUS/VET-20-15	5127714	3590295	3555174	0.5882	0.4094	-40.14
Mdd2-DIV/FUS-30-30	985828	690924	717659	0.5879	0.4213	-40.22
Ctvo-VET/FUS/LIM-30-30	1137937	799786	819713	0.5873	0.4187	-40.45
Ctvo-TODOS-30-30	1137818	799905	819769	0.5872	0.4188	-40.47
Mdd2-FUS-30-30	984112	692640	719283	0.5869	0.4223	-40.57
Ctvo-LIM-30-30	1134294	804838	823159	0.5849	0.4205	-41.23
Ctvo-DIV/LIM-30-30	1134141	804991	823295	0.5849	0.4206	-41.26
Mdd2-DIV/VET-30-15	1019041	729918	766047	0.5827	0.4291	-42.01
Ctvo-LIM/VET-30-30	1129793	809339	827692	0.5826	0.4228	-42.02
Ctvo-DIV/LIM/VET-30-30	1129649	809483	827842	0.5826	0.4229	-42.05
Mdd2-VET-30-15	1018373	730586	766557	0.5823	0.4295	-42.14
Mdd2-DIV/FUS/VET-30-30	973214	703538	730039	0.5804	0.4286	-42.78
Mdd2-FUS/VET-30-30	972209	704543	730772	0.5798	0.4291	-42.98
Ctvo-FUS/LIM-30-15	1173151	867798	894335	0.5748	0.4326	-44.69
Ctvo-DIV/FUS/LIM-30-15	1173062	867887	894434	0.5748	0.4326	-44.7
Mdd2-DIV/FUS-30-15	994250	737795	771860	0.574	0.437	-44.95
Mdd2-FUS-30-15	992664	739381	773403	0.5731	0.4379	-45.26
Ctvo-LIM-30-15	1168851	873507	898432	0.5723	0.4346	-45.54
Ctvo-DIV/LIM-30-15	1168753	873605	898507	0.5723	0.4346	-45.55
Ctvo-VET/FUS/LIM-30-15	1166188	874925	901920	0.5713	0.4361	-45.86
Ctvo-TODOS-30-15	1165905	875208	902180	0.5712	0.4362	-45.91
Ctvo-DIV-30-30	1102159	829422	846339	0.5706	0.4344	-46.12

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Ctvo-LIM/VET-30-15	1164128	878394	903406	0.5699	0.4369	-46.34
Ctvo-DIV/LIM/VET-30-15	1164009	878513	903513	0.5699	0.437	-46.36
Ctvo-BASE-30-30	1083023	820773	835793	0.5689	0.4356	-46.7
Ctvo-DIV-30-15	1136548	895413	919774	0.5593	0.4473	-49.95
Mdd2-DIV/FUS/VET-30-15	970807	766898	803075	0.5587	0.4527	-50.18
Mdd2-FUS/VET-30-15	969932	767773	803822	0.5582	0.4532	-50.35
Ctvo-BASE-30-15	1118932	886953	908686	0.5578	0.4482	-50.46
Mdd3-DIV/FUS/LIM-35-30	175392	141535	159888	0.5534	0.4769	-51.97
Mdd3-FUS/LIM-35-30	175338	141589	159943	0.5532	0.477	-52.02
Ctvo-DIV/FUS-30-30	1054759	859621	877351	0.551	0.4541	-52.8
Mdd3-DIV/FUS-35-30	174592	142335	160683	0.5509	0.4793	-52.82
Mdd3-FUS-35-30	174521	142406	160754	0.5507	0.4795	-52.9
Mdd3-TODOS-35-30	174398	142529	160884	0.5503	0.4798	-53.03
Mdd3-VET/FUS/LIM-35-30	174361	142566	160923	0.5502	0.48	-53.07
Ctvo-FUS-30-30	1035613	850982	866781	0.5489	0.4556	-53.49
Mdd3-DIV/FUS-35-15	197624	165831	187652	0.5437	0.4871	-55.26
Mdd3-FUS-35-15	197537	165918	187739	0.5435	0.4873	-55.34
Mdd3-DIV/LIM/VET-35-30	172086	144841	163172	0.543	0.4867	-55.51
Mdd3-LIM/VET-35-30	172056	144871	163202	0.5429	0.4868	-55.55
Ctvo-DIV/VET-30-30	1048783	883230	899895	0.5428	0.4618	-55.56
Mdd3-DIV-35-30	172028	144899	163206	0.5428	0.4868	-55.58
Mdd3-BASE-35-30	171953	144974	163282	0.5426	0.4871	-55.66
Mdd3-TODOS-35-15	197077	166378	188218	0.5422	0.4885	-55.77
Mdd3-VET/FUS/LIM-35-15	197014	166441	188280	0.5421	0.4887	-55.83
Ctvo-VET-30-30	1030355	873873	888087	0.5411	0.4629	-56.16
Mdd3-DIV/FUS/LIM-35-15	196218	167237	189039	0.5399	0.4907	-56.57
Mdd3-FUS/LIM-35-15	196179	167276	189076	0.5398	0.4908	-56.61
Mdd3-DIV/FUS/VET-35-30	170547	146380	164703	0.5381	0.4913	-57.17
Mdd3-FUS/VET-35-30	170462	146465	164789	0.5379	0.4915	-57.26
Mdd3-DIV/LIM/VET-35-15	194747	168708	190464	0.5358	0.4944	-57.95
Mdd3-DIV/LIM-35-30	169795	147132	165472	0.5358	0.4936	-57.97
Mdd3-LIM/VET-35-15	194684	168771	190528	0.5356	0.4946	-58.01
Mdd3-LIM-35-30	169752	147175	165515	0.5356	0.4937	-58.02
Mdd3-DIV/VET-35-30	169496	147431	165742	0.5348	0.4944	-58.3
Mdd3-VET-35-30	169491	147436	165757	0.5348	0.4944	-58.3
Mdd3-DIV-35-15	193767	169688	191443	0.5331	0.497	-58.87
Mdd3-BASE-35-15	193653	169802	191558	0.5328	0.4973	-58.98
Ctvo-DIV/FUS-30-15	1064780	937836	960761	0.5317	0.4743	-59.36
Mdd3-DIV/LIM-35-15	192913	170542	192305	0.5308	0.4992	-59.67
Mdd3-LIM-35-15	192886	170569	192330	0.5307	0.4993	-59.69
Ctvo-DIV/VET-30-15	1077988	954405	977778	0.5304	0.4756	-59.8
Mdd2-DIV/FUS-35-30	200266	177606	193371	0.53	0.4912	-59.94
Ctvo-FUS-30-15	1047166	929374	949630	0.5298	0.4756	-60.0
Mdd2-FUS-35-30	199941	177931	193666	0.5291	0.492	-60.23
Ctvo-VET-30-15	1060979	945338	965571	0.5288	0.4765	-60.33
Mdd3-DIV/FUS/VET-35-15	191081	172374	194144	0.5257	0.504	-61.38
Ctvo-DIV/FUS/VET-30-30	1006361	908019	924529	0.5257	0.4788	-61.4
Mdd3-FUS/VET-35-15	191001	172454	194223	0.5255	0.5042	-61.46
Mdd2-DIV/FUS/LIM-35-30	198368	179504	195314	0.525	0.4961	-61.65
Mdd2-FUS/LIM-35-30	198325	179547	195366	0.5248	0.4962	-61.69
Ctvo-FUS/VET-30-30	987877	898718	912835	0.5236	0.4803	-62.1
Mdd2-DIV-35-30	197621	180251	195902	0.523	0.4978	-62.32
Mdd2-BASE-35-30	197327	180545	196147	0.5222	0.4985	-62.58

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd3-DIV/VET-35-15	189787	173668	195353	0.5222	0.5072	-62.6
Mdd3-VET-35-15	189758	173697	195392	0.5221	0.5073	-62.62
Mdd2-TODOS-35-30	197129	180743	196556	0.5217	0.4993	-62.76
Mdd2-VET/FUS/LIM-35-30	197057	180815	196631	0.5215	0.4995	-62.83
Mdd2-DIV/FUS-35-15	226364	210068	231511	0.5187	0.5056	-63.79
Mdd2-FUS-35-15	225978	210454	231877	0.5178	0.5064	-64.09
Mdd2-DIV/LIM/VET-35-30	193743	184129	199766	0.5127	0.5077	-65.81
Mdd2-LIM/VET-35-30	193662	184210	199853	0.5125	0.5079	-65.89
Mdd2-TODOS-35-15	223282	213150	234519	0.5116	0.5123	-66.19
Mdd2-VET/FUS/LIM-35-15	223183	213249	234629	0.5114	0.5125	-66.27
Mdd2-DIV-35-15	223120	213312	234510	0.5112	0.5124	-66.32
Mdd2-BASE-35-15	222732	213700	234851	0.5103	0.5132	-66.62
Mdd2-DIV/FUS/LIM-35-15	222639	213793	235100	0.5101	0.5136	-66.69
Mdd2-FUS/LIM-35-15	222589	213843	235171	0.51	0.5137	-66.73
Mdd2-DIV/LIM-35-30	192697	185175	200862	0.51	0.5104	-66.75
Mdd2-LIM-35-30	192643	185229	200925	0.5098	0.5105	-66.8
Mdd2-DIV/FUS/VET-35-30	192260	185612	201177	0.5088	0.5113	-67.15
Mdd2-FUS/VET-35-30	192140	185732	201208	0.5085	0.5115	-67.26
Ctvo-DIV/FUS/VET-30-15	1018671	994526	1015814	0.506	0.4993	-68.1
Ctvo-FUS/VET-30-15	1001579	985542	1004470	0.504	0.5007	-68.77
Mdd2-DIV/VET-35-30	189889	187983	203444	0.5025	0.5172	-69.28
Mdd2-DIV/LIM/VET-35-15	219316	217116	238218	0.5025	0.5207	-69.28
Mdd2-VET-35-30	189834	188038	203408	0.5024	0.5173	-69.33
Mdd2-LIM/VET-35-15	219209	217223	238335	0.5023	0.5209	-69.37
Mdd2-DIV/LIM-35-15	218078	218354	239596	0.4997	0.5235	-70.25
Mdd2-LIM-35-15	218003	218429	239689	0.4995	0.5237	-70.31
Mdd2-DIV/FUS/VET-35-15	216557	219875	241029	0.4962	0.5267	-71.43
Mdd2-FUS/VET-35-15	216320	220112	241196	0.4957	0.5272	-71.62
Ctvo-DIV/FUS-35-30	223231	231395	241413	0.491	0.5196	-73.2
Ctvo-FUS-35-30	219330	228291	238092	0.49	0.5205	-73.55
Ctvo-DIV-35-30	222687	231939	241869	0.4898	0.5206	-73.6
Mdd2-DIV/VET-35-15	213726	222706	243557	0.4897	0.5326	-73.64
Mdd2-VET-35-15	213583	222849	243628	0.4894	0.5329	-73.75
Ctvo-BASE-35-30	218786	228835	238557	0.4888	0.5216	-73.96
Ctvo-DIV-35-15	251794	279273	292052	0.4741	0.537	-78.94
Ctvo-DIV/FUS-35-15	251752	279315	292520	0.474	0.5375	-78.97
Ctvo-BASE-35-15	247304	275430	287593	0.4731	0.5377	-79.3
Ctvo-FUS-35-15	247262	275472	288019	0.473	0.5381	-79.32
Ctvo-DIV/FUS/LIM-35-30	215247	240975	250890	0.4718	0.5382	-79.74
Ctvo-FUS/LIM-35-30	215128	241094	251023	0.4715	0.5385	-79.82
Ctvo-TODOS-35-30	213538	242684	252536	0.4681	0.5418	-81.01
Ctvo-VET/FUS/LIM-35-30	213389	242833	252757	0.4677	0.5422	-81.12
Ctvo-DIV/LIM-35-30	210456	245766	255440	0.4613	0.5483	-83.31
Ctvo-LIM-35-30	210337	245885	255573	0.461	0.5485	-83.4
Ctvo-DIV/LIM/VET-35-30	208986	247236	256760	0.4581	0.5513	-84.41
Ctvo-LIM/VET-35-30	208827	247395	256985	0.4577	0.5517	-84.52
Ctvo-DIV/FUS/LIM-35-15	242982	291985	304122	0.4542	0.5559	-85.73
Ctvo-FUS/LIM-35-15	242933	292034	304210	0.4541	0.556	-85.76
Ctvo-DIV/FUS/VET-35-30	204680	249946	259225	0.4502	0.5588	-87.08
Ctvo-TODOS-35-15	240834	294133	306333	0.4502	0.5599	-87.09
Ctvo-VET/FUS/LIM-35-15	240748	294219	306451	0.45	0.56	-87.15
Ctvo-FUS/VET-35-30	200966	246655	255795	0.449	0.56	-87.51
Ctvo-DIV/VET-35-30	202597	252029	261296	0.4456	0.5633	-88.64

(Continua)

Tabela D.2 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Ctvo-DIV/LIM-35-15	238032	296935	308608	0.4449	0.5646	-88.87
Ctvo-LIM-35-15	237980	296987	308696	0.4448	0.5647	-88.91
Ctvo-VET-35-30	198936	248685	257864	0.4444	0.5645	-89.05
Ctvo-DIV/LIM/VET-35-15	236878	298089	309515	0.4428	0.5665	-89.61
Ctvo-LIM/VET-35-15	236776	298191	309675	0.4426	0.5667	-89.67
Ctvo-DIV/FUS/VET-35-15	230330	300737	313116	0.4337	0.5762	-92.7
Ctvo-FUS/VET-35-15	225890	296844	308544	0.4321	0.5773	-93.24
Ctvo-DIV/VET-35-15	227496	303571	315561	0.4284	0.5811	-94.51
Ctvo-VET-35-15	223174	299560	310972	0.4269	0.5822	-95.0

Fonte: Produção do Autor.

Tabela D.3 - Índices estatísticos do IOP2 para os métodos de correção vetorial, extrapolação e parâmetros de rastreo.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd3-FUS/LIM-20-30	3402604	1664335	1746437	0.6715	0.3392	22.484
Mdd3-DIV/FUS/LIM-20-30	3402487	1664452	1746690	0.6715	0.3392	22.479
Mdd3-DIV/LIM-20-30	3403585	1665005	1747503	0.6715	0.3392	22.478
Mdd3-LIM-20-30	3403516	1665074	1747561	0.6715	0.3393	22.475
Mdd3-LIM/VET-20-30	3400839	1663953	1746459	0.6715	0.3393	22.469
Mdd3-DIV/LIM/VET-20-30	3400798	1663994	1746478	0.6715	0.3393	22.467
Mdd3-TODOS-20-30	3394961	1671101	1752962	0.6701	0.3405	22.156
Mdd3-VET/FUS/LIM-20-30	3394808	1671254	1753108	0.6701	0.3405	22.148
Mdd3-FUS/LIM-20-15	3415126	1711079	1798908	0.6662	0.345	21.228
Mdd3-DIV/FUS/LIM-20-15	3415085	1711120	1798955	0.6662	0.345	21.226
Mdd3-VET/FUS/LIM-20-15	3405285	1714859	1802536	0.6651	0.3461	20.961
Mdd3-TODOS-20-15	3405149	1714995	1802690	0.665	0.3461	20.955
Mdd3-LIM/VET-20-15	3405780	1718774	1805477	0.6646	0.3465	20.849
Mdd3-DIV/LIM/VET-20-15	3405508	1719046	1805746	0.6645	0.3465	20.836
Mdd3-LIM-20-15	3404026	1720032	1807947	0.6643	0.3469	20.783
Mdd3-DIV/LIM-20-15	3403918	1720140	1808061	0.6643	0.3469	20.778
Mdd2-FUS/LIM-20-30	3552602	1918464	1996464	0.6493	0.3598	17.248
Mdd2-DIV/FUS/LIM-20-30	3552532	1918534	1996548	0.6493	0.3598	17.245
Mdd3-DIV/VET-20-30	3275713	1769571	1846786	0.6493	0.3605	17.229
Mdd2-DIV/LIM-20-30	3550553	1920580	1995950	0.649	0.3599	17.158
Mdd3-VET-20-30	3274157	1771127	1848346	0.649	0.3608	17.156
Mdd2-LIM-20-30	3550488	1920645	1996010	0.6489	0.3599	17.155
Mdd2-LIM/VET-20-30	3546144	1921994	1997106	0.6485	0.3603	17.052
Mdd2-DIV/LIM/VET-20-30	3546050	1922088	1997099	0.6485	0.3603	17.048
Mdd2-VET/FUS/LIM-20-30	3538366	1929006	2006758	0.6472	0.3619	16.737
Mdd2-TODOS-20-30	3538336	1929036	2006863	0.6472	0.3619	16.736
Mdd3-DIV-20-30	3262085	1802988	1884229	0.644	0.3661	15.995
Mdd3-BASE-20-30	3260788	1804285	1885544	0.6438	0.3664	15.935
Mdd3-DIV/VET-20-15	3278962	1815501	1892427	0.6436	0.3659	15.9
Mdd3-VET-20-15	3277392	1817071	1894016	0.6433	0.3662	15.828
Mdd2-FUS/LIM-20-15	3591825	1992354	2078997	0.6432	0.3666	15.802
Mdd2-DIV/FUS/LIM-20-15	3591670	1992509	2079151	0.6432	0.3666	15.795
Mdd2-VET/FUS/LIM-20-15	3582059	1999561	2085263	0.6418	0.3679	15.458
Mdd2-TODOS-20-15	3581743	1999877	2085566	0.6417	0.368	15.445
Mdd2-LIM/VET-20-15	3576980	2001182	2087712	0.6412	0.3685	15.337
Mdd2-DIV/LIM/VET-20-15	3576508	2001654	2088126	0.6412	0.3686	15.318

(Continua)

Tabela D.3 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd2-LIM-20-15	3573068	2007434	2091732	0.6403	0.3693	15.109
Mdd2-DIV/LIM-20-15	3572973	2007529	2091840	0.6403	0.3693	15.104
Mdd3-DIV-20-15	3264962	1855418	1942244	0.6376	0.373	14.486
Mdd3-BASE-20-15	3263811	1856569	1943396	0.6374	0.3732	14.433
Mdd2-DIV/VET-20-30	3397364	2037205	2100008	0.6251	0.382	11.536
Mdd2-VET-20-30	3393793	2040016	2101825	0.6246	0.3825	11.402
Mdd2-DIV-20-30	3397588	2054157	2131957	0.6232	0.3856	11.081
Mdd2-BASE-20-30	3394399	2056749	2133718	0.6227	0.386	10.959
Mdd3-DIV/FUS/VET-20-30	3086725	1891853	1973104	0.62	0.39	10.324
Mdd3-FUS/VET-20-30	3084477	1894101	1975365	0.6195	0.3904	10.217
Mdd2-DIV/VET-20-15	3426196	2119869	2192206	0.6178	0.3902	9.797
Mdd2-VET-20-15	3422761	2122544	2194094	0.6172	0.3906	9.671
Mdd2-DIV-20-15	3418888	2143825	2228854	0.6146	0.3946	9.051
Mdd2-BASE-20-15	3416093	2145860	2229955	0.6142	0.395	8.952
Mdd3-DIV/FUS-20-30	3039012	1915575	1993955	0.6134	0.3962	8.76
Mdd3-FUS-20-30	3037391	1917196	1995595	0.613	0.3965	8.682
Mdd3-DIV/FUS/VET-20-15	3059103	1977166	2062125	0.6074	0.4027	7.353
Mdd3-FUS/VET-20-15	3057488	1978781	2063733	0.6071	0.403	7.278
Ctvo-FUS/LIM-20-30	3611711	2347725	2399332	0.606	0.3992	7.031
Ctvo-LIM-20-30	3614295	2349735	2402309	0.606	0.3993	7.023
Ctvo-DIV/FUS/LIM-20-30	3610361	2348780	2400349	0.6059	0.3993	6.985
Ctvo-DIV/LIM-20-30	3612943	2350792	2403329	0.6058	0.3995	6.977
Mdd3-DIV/FUS-20-15	3034876	1986073	2070571	0.6044	0.4056	6.652
Mdd3-FUS-20-15	3033751	1987198	2071692	0.6042	0.4058	6.599
Ctvo-LIM/VET-20-30	3602777	2363967	2415569	0.6038	0.4014	6.502
Ctvo-DIV/LIM/VET-20-30	3601421	2365028	2416536	0.6036	0.4016	6.456
Ctvo-VET/FUS/LIM-20-30	3590118	2368817	2422716	0.6025	0.4029	6.188
Ctvo-TODOS-20-30	3588623	2370017	2423987	0.6023	0.4032	6.136
Ctvo-FUS/LIM-20-15	3679434	2483004	2530233	0.5971	0.4075	4.913
Ctvo-DIV/FUS/LIM-20-15	3678432	2484006	2531186	0.5969	0.4076	4.875
Ctvo-LIM-20-15	3665744	2500326	2549446	0.5945	0.4102	4.306
Ctvo-DIV/LIM-20-15	3664726	2501344	2550416	0.5943	0.4104	4.267
Ctvo-VET/FUS/LIM-20-15	3662258	2505339	2551269	0.5938	0.4106	4.138
Ctvo-TODOS-20-15	3660999	2506598	2552535	0.5936	0.4108	4.09
Ctvo-LIM/VET-20-15	3657960	2506496	2556780	0.5934	0.4114	4.045
Ctvo-DIV/LIM/VET-20-15	3656590	2507866	2558001	0.5932	0.4116	3.992
Mdd2-DIV/FUS/VET-20-30	3167854	2175537	2250485	0.5929	0.4153	3.917
Mdd2-FUS/VET-20-30	3163683	2179708	2254419	0.5921	0.4161	3.733
Mdd2-DIV/FUS-20-30	3143733	2191736	2269521	0.5892	0.4193	3.058
Ctvo-DIV-20-30	3464550	2421146	2472983	0.5886	0.4165	2.922
Mdd2-FUS-20-30	3140513	2195119	2272685	0.5886	0.4198	2.911
Ctvo-BASE-20-30	3414497	2393571	2446747	0.5879	0.4174	2.745
Ctvo-DIV/VET-20-30	3419633	2479350	2520412	0.5797	0.4243	0.813
Ctvo-VET-20-30	3369010	2451585	2493265	0.5788	0.4253	0.602
Mdd2-DIV/FUS/VET-20-15	3151741	2307635	2387396	0.5773	0.431	0.248
Mdd2-FUS/VET-20-15	3148596	2310780	2390373	0.5767	0.4316	0.112
Ctvo-DIV-20-15	3506878	2574317	2620321	0.5767	0.4277	0.099
Ctvo-BASE-20-15	3469836	2551514	2593988	0.5763	0.4278	0.0
Mdd2-DIV/FUS-20-15	3128122	2313868	2393829	0.5748	0.4335	-0.341
Mdd2-FUS-20-15	3125546	2316444	2396303	0.5743	0.434	-0.452
Ctvo-DIV/VET-20-15	3462798	2632139	2669549	0.5681	0.4353	-1.914
Ctvo-VET-20-15	3424661	2609671	2644810	0.5675	0.4358	-2.059
Mdd3-VET/FUS/LIM-30-30	701189	534608	567406	0.5674	0.4473	-2.09

(Continua)

Tabela D.3 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd3-TODOS-30-30	701052	534745	567544	0.5673	0.4474	-2.116
Mdd3-FUS/LIM-30-30	700764	535033	567789	0.5671	0.4476	-2.171
Mdd3-DIV/FUS/LIM-30-30	700705	535092	567862	0.567	0.4476	-2.183
Mdd3-LIM-30-30	695381	540416	573086	0.5627	0.4518	-3.199
Mdd3-DIV/LIM-30-30	695368	540429	573107	0.5627	0.4518	-3.202
Mdd3-LIM/VET-30-30	693779	542018	574688	0.5614	0.4531	-3.505
Mdd3-DIV/LIM/VET-30-30	693621	542176	574853	0.5613	0.4532	-3.535
Mdd3-FUS/LIM-30-15	727533	577532	616784	0.5575	0.4588	-4.434
Mdd3-DIV/FUS/LIM-30-15	727401	577664	616915	0.5574	0.4589	-4.457
Mdd3-VET/FUS/LIM-30-15	725768	579297	618489	0.5561	0.4601	-4.753
Mdd3-TODOS-30-15	725597	579468	618660	0.556	0.4602	-4.784
Ctvo-DIV/FUS-20-30	3173945	2548696	2592499	0.5546	0.4496	-5.104
Ctvo-FUS-20-30	3123949	2521064	2565993	0.5534	0.451	-5.394
Mdd3-LIM/VET-30-15	721411	583654	622736	0.5528	0.4633	-5.54
Mdd3-DIV/LIM/VET-30-15	721301	583764	622857	0.5527	0.4634	-5.56
Mdd3-LIM-30-15	721233	583832	622940	0.5526	0.4634	-5.573
Mdd3-DIV/LIM-30-15	721213	583852	622967	0.5526	0.4635	-5.576
Mdd3-DIV/VET-30-30	674168	561629	594265	0.5455	0.4685	-7.25
Mdd3-VET-30-30	673999	561798	594390	0.5454	0.4686	-7.282
Mdd2-FUS/LIM-30-30	749391	627529	654672	0.5443	0.4663	-7.553
Mdd2-DIV/FUS/LIM-30-30	749335	627585	654743	0.5442	0.4663	-7.562
Ctvo-DIV/FUS/VET-20-30	3136115	2628732	2673397	0.544	0.4602	-7.61
Mdd2-VET/FUS/LIM-30-30	747924	628996	656149	0.5432	0.4673	-7.804
Mdd2-TODOS-30-30	747909	629011	656167	0.5432	0.4673	-7.807
Ctvo-FUS/VET-20-30	3085924	2601295	2646700	0.5426	0.4617	-7.941
Mdd3-DIV-30-30	666781	569016	601846	0.5396	0.4744	-8.661
Mdd2-DIV/LIM-30-30	742421	634499	661520	0.5392	0.4712	-8.747
Mdd2-LIM-30-30	742421	634499	661513	0.5392	0.4712	-8.747
Mdd3-BASE-30-30	666283	569514	602320	0.5392	0.4748	-8.756
Mdd2-LIM/VET-30-30	740574	636346	663219	0.5378	0.4724	-9.064
Mdd2-DIV/LIM/VET-30-30	740489	636431	663332	0.5378	0.4725	-9.078
Mdd3-VET-30-15	700612	604453	643501	0.5368	0.4788	-9.302
Mdd3-DIV/VET-30-15	700586	604479	643543	0.5368	0.4788	-9.306
Mdd2-FUS/LIM-30-15	781712	684672	717347	0.5331	0.4785	-10.187
Mdd2-DIV/FUS/LIM-30-15	781496	684888	717565	0.5329	0.4787	-10.222
Mdd2-VET/FUS/LIM-30-15	779135	687249	719803	0.5313	0.4802	-10.602
Mdd3-DIV/FUS/VET-30-30	656614	579183	611670	0.5313	0.4823	-10.602
Mdd2-TODOS-30-15	778909	687475	720023	0.5312	0.4804	-10.638
Ctvo-DIV/FUS-20-15	3136675	2770924	2814842	0.531	0.473	-10.69
Mdd3-FUS/VET-30-30	656021	579776	612247	0.5308	0.4827	-10.716
Ctvo-FUS-20-15	3099633	2748121	2788423	0.5301	0.4736	-10.903
Mdd3-DIV-30-15	690798	614267	653381	0.5293	0.4861	-11.076
Mdd3-BASE-30-15	690358	614707	653808	0.529	0.4864	-11.156
Mdd2-LIM-30-15	771925	694459	726688	0.5264	0.4849	-11.762
Mdd2-DIV/LIM-30-15	771861	694523	726766	0.5264	0.485	-11.772
Mdd2-LIM/VET-30-15	771244	695140	727401	0.5259	0.4854	-11.872
Mdd2-DIV/LIM/VET-30-15	771116	695268	727548	0.5259	0.4855	-11.892
Mdd3-DIV/FUS/VET-30-15	682363	622702	661639	0.5229	0.4923	-12.602
Mdd3-FUS/VET-30-15	682202	622863	661817	0.5227	0.4924	-12.631
Mdd3-DIV/FUS-30-30	645843	589954	622490	0.5226	0.4908	-12.659
Mdd3-FUS-30-30	645488	590309	622835	0.5223	0.4911	-12.727
Ctvo-DIV/FUS/VET-20-15	3087279	2844553	2874903	0.5205	0.4822	-13.167
Ctvo-FUS/VET-20-15	3049346	2822641	2850548	0.5193	0.4832	-13.44

(Continua)

Tabela D.3 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd2-DIV/VET-30-30	713780	662989	689494	0.5184	0.4913	-13.643
Mdd2-VET-30-30	711928	664841	691056	0.5171	0.4926	-13.96
Mdd2-DIV-30-30	710152	666421	692719	0.5159	0.4938	-14.247
Mdd2-BASE-30-30	708900	667673	693840	0.515	0.4946	-14.462
Mdd3-DIV/FUS-30-15	669462	633943	672398	0.5136	0.5011	-14.78
Mdd3-FUS-30-15	669172	634233	672680	0.5134	0.5013	-14.833
Mdd2-DIV/VET-30-15	744850	721134	753314	0.5081	0.5028	-16.087
Mdd2-VET-30-15	743458	722526	754506	0.5071	0.5037	-16.311
Mdd2-DIV/FUS/VET-30-30	696976	679944	706355	0.5062	0.5033	-16.536
Mdd2-FUS/VET-30-30	695214	681706	708007	0.5049	0.5046	-16.838
Mdd2-DIV-30-15	738752	727036	758724	0.504	0.5067	-17.052
Mdd2-BASE-30-15	737630	728158	759741	0.5032	0.5074	-17.233
Ctvo-FUS/LIM-30-30	765394	777835	788767	0.496	0.5075	-18.947
Ctvo-DIV/FUS/LIM-30-30	764837	778392	789190	0.4956	0.5078	-19.032
Mdd2-DIV/FUS-30-30	681329	695591	722163	0.4948	0.5145	-19.218
Mdd2-DIV/FUS/VET-30-15	725095	741289	773258	0.4945	0.5161	-19.299
Ctvo-VET/FUS/LIM-30-30	762675	780554	791815	0.4942	0.5094	-19.363
Mdd2-FUS-30-30	680228	696692	723168	0.494	0.5153	-19.406
Ctvo-TODOS-30-30	762274	780955	792224	0.4939	0.5096	-19.424
Mdd2-FUS/VET-30-15	723731	742653	774550	0.4935	0.517	-19.518
Ctvo-LIM-30-30	758056	785173	795382	0.4912	0.512	-20.069
Ctvo-DIV/LIM-30-30	757520	785709	795808	0.4909	0.5123	-20.151
Ctvo-LIM/VET-30-30	755302	787927	798379	0.4894	0.5139	-20.49
Ctvo-DIV/LIM/VET-30-30	754715	788514	798888	0.489	0.5142	-20.58
Mdd2-DIV/FUS-30-15	715262	751122	783021	0.4878	0.5226	-20.881
Mdd2-FUS-30-15	714282	752102	783906	0.4871	0.5232	-21.039
Mdd3-LIM/VET-35-30	213262	229055	249432	0.4821	0.5391	-22.209
Mdd3-DIV/LIM/VET-35-30	213244	229073	249449	0.4821	0.5391	-22.218
Mdd3-LIM-35-30	212936	229381	249788	0.4814	0.5398	-22.383
Mdd3-DIV/LIM-35-30	212885	229432	249838	0.4813	0.5399	-22.41
Ctvo-FUS/LIM-30-15	803696	866803	881633	0.4811	0.5231	-22.453
Ctvo-DIV/FUS/LIM-30-15	803115	867384	882089	0.4808	0.5234	-22.535
Ctvo-VET/FUS/LIM-30-15	800657	869842	884848	0.4793	0.525	-22.882
Ctvo-TODOS-30-15	800157	870342	885223	0.479	0.5252	-22.953
Mdd3-FUS/LIM-35-30	211266	231051	251482	0.4776	0.5435	-23.274
Mdd3-DIV/FUS/LIM-35-30	211247	231070	251495	0.4776	0.5435	-23.284
Ctvo-LIM-30-15	796081	874418	888174	0.4766	0.5273	-23.529
Ctvo-DIV/LIM-30-15	795511	874988	888617	0.4762	0.5276	-23.61
Mdd3-TODOS-35-15	243142	268943	292625	0.4748	0.5462	-23.941
Mdd3-VET/FUS/LIM-35-15	243107	268978	292660	0.4747	0.5462	-23.957
Mdd3-VET/FUS/LIM-35-30	209673	232644	253068	0.474	0.5469	-24.124
Mdd3-DIV/FUS/LIM-35-15	242700	269385	293084	0.4739	0.547	-24.144
Mdd3-TODOS-35-30	209629	232688	253111	0.4739	0.547	-24.147
Mdd3-FUS/LIM-35-15	242664	269421	293124	0.4739	0.5471	-24.161
Ctvo-LIM/VET-30-15	791221	879278	893187	0.4736	0.5303	-24.216
Ctvo-DIV-30-30	728525	809770	820390	0.4736	0.5297	-24.228
Ctvo-DIV/LIM/VET-30-15	790637	879862	893684	0.4733	0.5306	-24.298
Ctvo-BASE-30-30	713610	798150	809828	0.472	0.5316	-24.594
Mdd3-LIM/VET-35-15	241154	270931	294557	0.4709	0.5498	-24.857
Mdd3-DIV/LIM/VET-35-15	241110	270975	294601	0.4708	0.5499	-24.877
Mdd3-DIV/LIM-35-15	240912	271173	294762	0.4705	0.5503	-24.968
Mdd3-LIM-35-15	240873	271212	294800	0.4704	0.5503	-24.986
Ctvo-DIV/VET-30-30	715299	821189	831397	0.4655	0.5375	-26.128

(Continua)

Tabela D.3 - Continuação.

<b>Método</b>	<b>Hit</b>	<b>Miss</b>	<b>False Alarm</b>	<b>POD</b>	<b>FAR</b>	<b>Skill Score</b>
Ctvo-VET-30-30	699523	810430	821212	0.4633	0.54	-26.662
Mdd3-DIV/FUS/VET-35-30	204065	238252	258623	0.4614	0.559	-27.116
Mdd3-FUS/VET-35-30	203802	238515	258889	0.4608	0.5595	-27.256
Ctvo-DIV-30-15	764363	901321	915722	0.4589	0.545	-27.698
Ctvo-BASE-30-15	750949	890131	905128	0.4576	0.5465	-28.003
Ctvo-DIV/FUS-30-30	700856	831508	841568	0.4574	0.5456	-28.056
Mdd3-DIV/FUS-35-30	202044	240273	260734	0.4568	0.5634	-28.194
Mdd3-FUS-35-30	201841	240476	260937	0.4563	0.5638	-28.302
Ctvo-FUS-30-30	685936	819893	830948	0.4555	0.5478	-28.492
Mdd2-FUS/LIM-35-30	234832	281773	299505	0.4546	0.5605	-28.717
Mdd2-DIV/FUS/LIM-35-30	234827	281778	299530	0.4546	0.5605	-28.72
Mdd2-DIV/LIM/VET-35-30	234544	282061	299744	0.454	0.561	-28.849
Mdd2-LIM/VET-35-30	234456	282149	299808	0.4538	0.5612	-28.889
Mdd2-DIV/LIM-35-30	234240	282365	299969	0.4534	0.5615	-28.988
Mdd2-LIM-35-30	234190	282415	300001	0.4533	0.5616	-29.01
Ctvo-DIV/FUS/VET-30-30	692977	838788	848889	0.4524	0.5506	-29.228
Ctvo-DIV/VET-30-15	750639	913238	926865	0.4511	0.5525	-29.526
Mdd2-TODOS-35-30	232754	283851	301500	0.4505	0.5643	-29.666
Mdd2-VET/FUS/LIM-35-30	232748	283857	301486	0.4505	0.5643	-29.669
Ctvo-FUS/VET-30-30	677456	827774	838440	0.4501	0.5531	-29.779
Mdd3-DIV/VET-35-30	199033	243284	263679	0.45	0.5699	-29.8
Mdd3-VET-35-30	198819	243498	263885	0.4495	0.5703	-29.914
Mdd3-DIV/FUS/VET-35-15	230168	281917	305582	0.4495	0.5704	-29.92
Ctvo-VET-30-15	736715	902558	916343	0.4494	0.5543	-29.933
Mdd3-FUS/VET-35-15	229936	282149	305810	0.449	0.5708	-30.027
Mdd2-DIV/FUS/LIM-35-15	268780	330700	351400	0.4484	0.5666	-30.183
Mdd2-FUS/LIM-35-15	268675	330805	351484	0.4482	0.5668	-30.225
Mdd2-TODOS-35-15	268445	331035	351760	0.4478	0.5672	-30.315
Mdd2-VET/FUS/LIM-35-15	268282	331198	351899	0.4475	0.5674	-30.379
Mdd3-DIV/FUS-35-15	227297	284788	308478	0.4439	0.5758	-31.243
Mdd3-FUS-35-15	227103	284982	308672	0.4435	0.5761	-31.332
Ctvo-DIV/FUS-30-15	733084	924749	938415	0.4422	0.5614	-31.637
Mdd2-LIM/VET-35-15	264388	335092	355687	0.441	0.5736	-31.912
Mdd2-DIV/LIM-35-15	264384	335096	355629	0.441	0.5736	-31.914
Mdd2-LIM-35-15	264337	335143	355663	0.4409	0.5736	-31.932
Mdd2-DIV/LIM/VET-35-15	264291	335189	355802	0.4409	0.5738	-31.95
Ctvo-FUS-30-15	719653	913576	927762	0.4406	0.5632	-32.006
Mdd3-DIV/VET-35-15	224829	287256	310910	0.439	0.5803	-32.38
Mdd3-VET-35-15	224539	287546	311185	0.4385	0.5809	-32.514
Mdd2-DIV/FUS/VET-35-30	226109	290496	308066	0.4377	0.5767	-32.702
Mdd3-DIV-35-30	193288	249029	269432	0.437	0.5823	-32.866
Mdd2-FUS/VET-35-30	225550	291055	308596	0.4366	0.5777	-32.957
Mdd3-BASE-35-30	193045	249272	269666	0.4364	0.5828	-32.995
Ctvo-DIV/FUS/VET-30-15	723300	934833	948058	0.4362	0.5672	-33.049
Ctvo-FUS/VET-30-15	709501	924028	937636	0.4343	0.5693	-33.492
Mdd2-DIV/FUS-35-30	224219	292386	310007	0.434	0.5803	-33.565
Mdd2-FUS-35-30	223858	292747	310351	0.4333	0.581	-33.73
Mdd2-DIV/VET-35-30	220741	295864	313329	0.4273	0.5867	-35.154
Mdd2-VET-35-30	220225	296380	313834	0.4263	0.5876	-35.39
Mdd3-DIV-35-15	216743	295342	318889	0.4233	0.5954	-36.107
Mdd3-BASE-35-15	216484	295601	319139	0.4228	0.5958	-36.226
Mdd2-DIV/FUS/VET-35-15	251876	347604	368212	0.4202	0.5938	-36.838
Mdd2-DIV/FUS-35-15	251363	348117	368718	0.4193	0.5946	-37.04

(Continua)

Tabela D.3 - Continuação.

Método	Hit	Miss	False Alarm	POD	FAR	Skill Score
Mdd2-FUS/VET-35-15	251344	348136	368768	0.4193	0.5947	-37.047
Mdd2-FUS-35-15	250982	348498	369102	0.4187	0.5952	-37.19
Mdd2-DIV-35-30	216067	300538	317869	0.4182	0.5953	-37.289
Mdd2-BASE-35-30	215667	300938	318211	0.4175	0.596	-37.472
Mdd2-DIV/VET-35-15	248065	351415	371940	0.4138	0.5999	-38.338
Mdd2-VET-35-15	247517	351963	372494	0.4129	0.6008	-38.554
Ctvo-DIV/FUS/LIM-35-30	245773	359017	368325	0.4064	0.5998	-40.09
Ctvo-FUS/LIM-35-30	245770	359020	368406	0.4064	0.5998	-40.091
Ctvo-TODOS-35-30	244172	360794	370073	0.4036	0.6025	-40.742
Ctvo-VET/FUS/LIM-35-30	244131	360835	370134	0.4035	0.6026	-40.758
Mdd2-DIV-35-15	241553	357927	378155	0.4029	0.6102	-40.902
Mdd2-BASE-35-15	241085	358395	378564	0.4022	0.6109	-41.086
Ctvo-DIV/LIM-35-30	242631	362159	371115	0.4012	0.6047	-41.316
Ctvo-LIM-35-30	242628	362162	371196	0.4012	0.6047	-41.317
Ctvo-DIV/LIM/VET-35-30	242204	362762	371902	0.4004	0.6056	-41.51
Ctvo-LIM/VET-35-30	242167	362799	371999	0.4003	0.6057	-41.524
Ctvo-FUS/LIM-35-15	281402	425984	435344	0.3978	0.6074	-42.113
Ctvo-DIV/FUS/LIM-35-15	281390	425996	435311	0.3978	0.6074	-42.117
Ctvo-DIV/FUS-35-30	239613	363284	372956	0.3974	0.6088	-42.2
Ctvo-TODOS-35-15	281000	426562	435970	0.3971	0.6081	-42.27
Ctvo-VET/FUS/LIM-35-15	280923	426639	436090	0.397	0.6082	-42.296
Ctvo-FUS-35-30	235361	358391	368432	0.3964	0.6102	-42.445
Ctvo-LIM-35-15	275514	431872	440831	0.3895	0.6154	-44.077
Ctvo-DIV/LIM-35-15	275502	431884	440798	0.3895	0.6154	-44.081
Ctvo-DIV-35-30	234749	368636	378201	0.3891	0.617	-44.178
Ctvo-DIV/LIM/VET-35-15	274894	432668	441627	0.3885	0.6163	-44.307
Ctvo-LIM/VET-35-15	274850	432712	441727	0.3884	0.6164	-44.321
Ctvo-BASE-35-30	230481	363759	373710	0.3879	0.6185	-44.46
Ctvo-DIV/FUS/VET-35-30	233389	369332	378800	0.3872	0.6188	-44.609
Ctvo-FUS/VET-35-30	229118	364458	373985	0.386	0.6201	-44.9
Ctvo-DIV/FUS-35-15	267553	436507	446503	0.38	0.6253	-46.311
Ctvo-FUS-35-15	263291	431020	441436	0.3792	0.6264	-46.501
Ctvo-DIV/VET-35-30	225980	376961	386361	0.3748	0.631	-47.543
Ctvo-VET-35-30	221853	371943	381414	0.3736	0.6322	-47.821
Ctvo-DIV-35-15	262397	442151	452177	0.3724	0.6328	-48.1
Ctvo-BASE-35-15	258109	436690	447157	0.3715	0.634	-48.324
Ctvo-DIV/FUS/VET-35-15	259465	444419	454121	0.3686	0.6364	-49.0
Ctvo-FUS/VET-35-15	255083	439052	448955	0.3675	0.6377	-49.268
Ctvo-DIV/VET-35-15	252731	451373	461091	0.3589	0.6459	-51.285
Ctvo-VET-35-15	248560	445795	455724	0.358	0.6471	-51.513

Fonte: Produção do Autor.

Tabela D.4 - Precipitação registrada no sítio T3 - Manacapuru(AM).

Data Hora	mm/h
2014-08-16 02:50:00	15.24
2014-08-16 09:02:00	15.24
2014-08-16 14:24:00	15.24
2014-08-16 14:25:00	15.24
2014-08-16 14:26:00	15.24
2014-08-16 14:27:00	45.72

(Continua)

Tabela D.4 - Continuação.

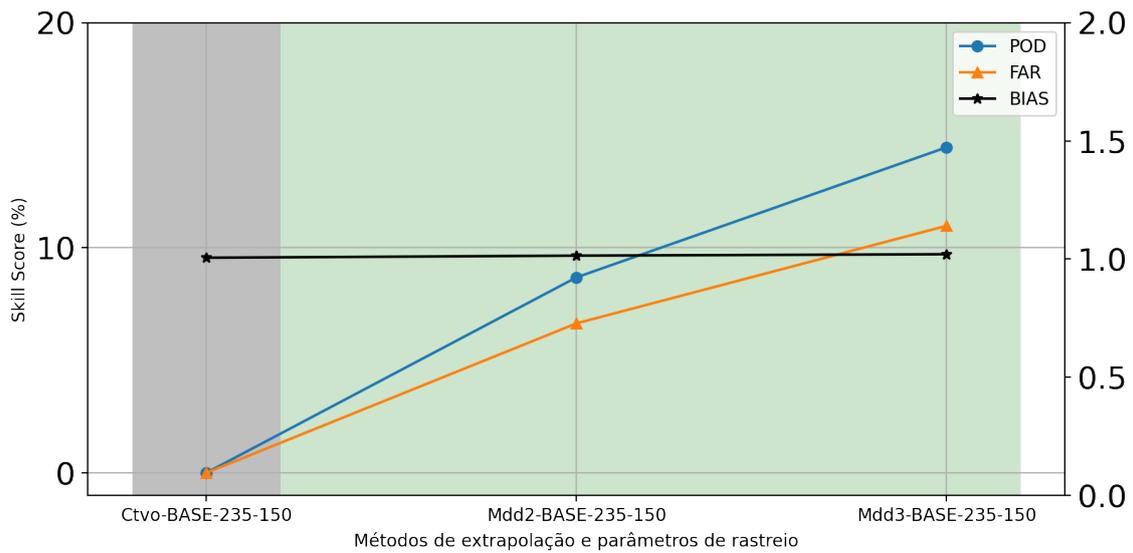
<b>Data Hora</b>	<b>mm/h</b>
2014-08-16 14:28:00	45.72
2014-08-16 14:29:00	30.48
2014-08-16 14:30:00	60.96
2014-08-16 14:31:00	30.48
2014-08-16 14:32:00	30.48
2014-08-16 14:33:00	30.48
2014-08-16 14:34:00	30.48
2014-08-16 14:35:00	30.48
2014-08-16 14:36:00	15.24
2014-08-16 14:37:00	15.24
2014-08-16 14:38:00	15.24
2014-08-16 14:39:00	15.24
2014-08-16 14:40:00	15.24
2014-08-16 14:42:00	15.24
2014-08-16 14:44:00	15.24
2014-08-16 14:45:00	15.24
2014-08-16 14:47:00	15.24
2014-08-16 14:49:00	15.24
2014-08-16 14:53:00	15.24
2014-08-16 14:56:00	15.24
2014-08-16 15:01:00	15.24
2014-08-16 15:39:00	15.24
2014-08-16 15:44:00	15.24
2014-08-16 15:48:00	15.24
2014-08-16 15:52:00	15.24
2014-08-16 15:55:00	15.24
2014-08-16 15:59:00	15.24
2014-08-16 16:02:00	15.24
2014-08-16 16:05:00	15.24
2014-08-16 16:08:00	15.24
2014-08-16 16:12:00	15.24
2014-08-16 16:14:00	15.24
2014-08-16 16:16:00	15.24
2014-08-16 16:19:00	15.24
2014-08-16 16:22:00	15.24
2014-08-16 16:26:00	15.24
2014-08-16 16:31:00	15.24
2014-08-16 16:36:00	15.24
2014-08-16 16:41:00	15.24
2014-08-16 16:48:00	15.24

Fonte: Produção do Autor.



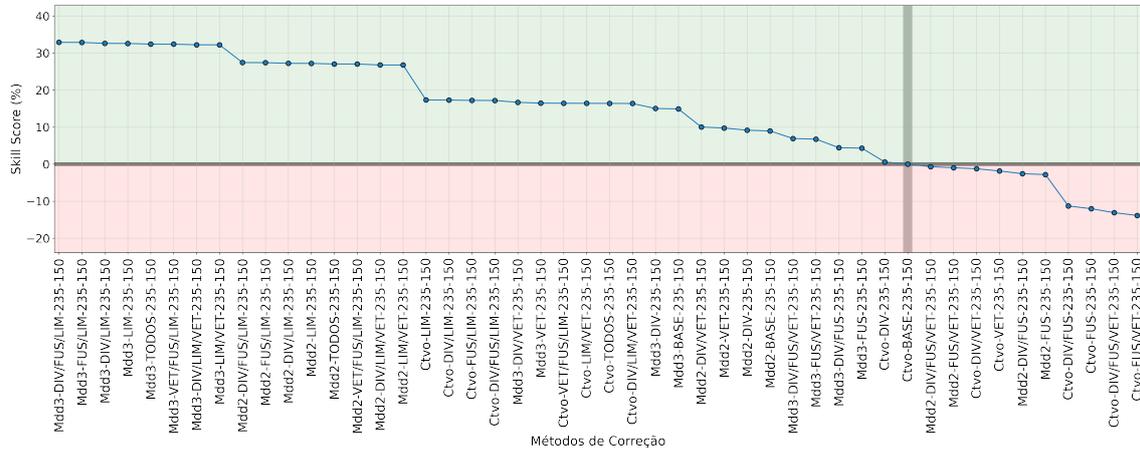
## APÊNDICE B - FIGURAS AUXILIARES PARA RASTREIO VIA SATÉLITE

Figura B.1 - Habilidade dos métodos de extrapolação com base nos seus parâmetros de rastreo para o modo operacional básico com dados de Satélite.



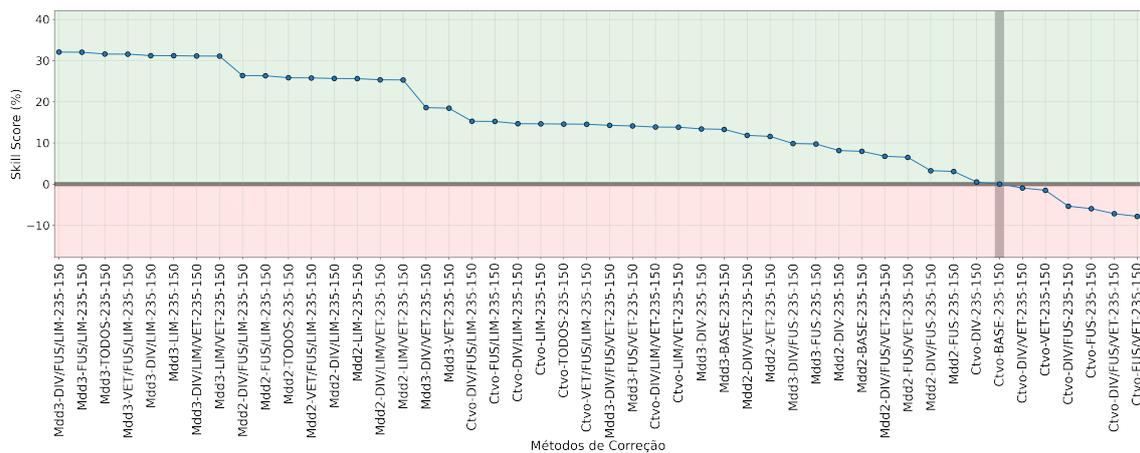
Fonte: Produção do Autor.

Figura B.2 - Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiares e extrapolação com referência ao Ctvo-BASE-235-150 para o IOP1.



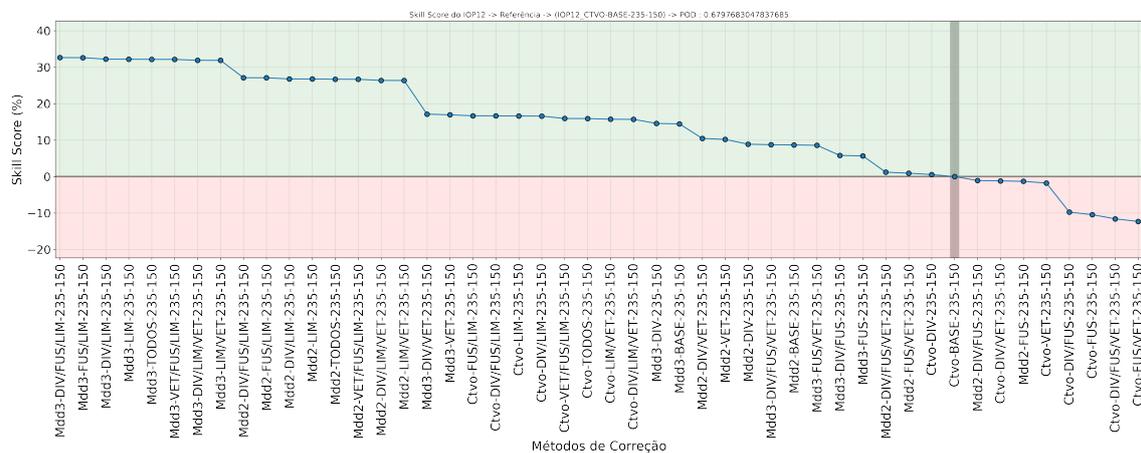
Fonte: Produção do Autor.

Figura B.3 - Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiares e extrapolação com referência ao Ctvo-BASE-235-150 para o IOP2.



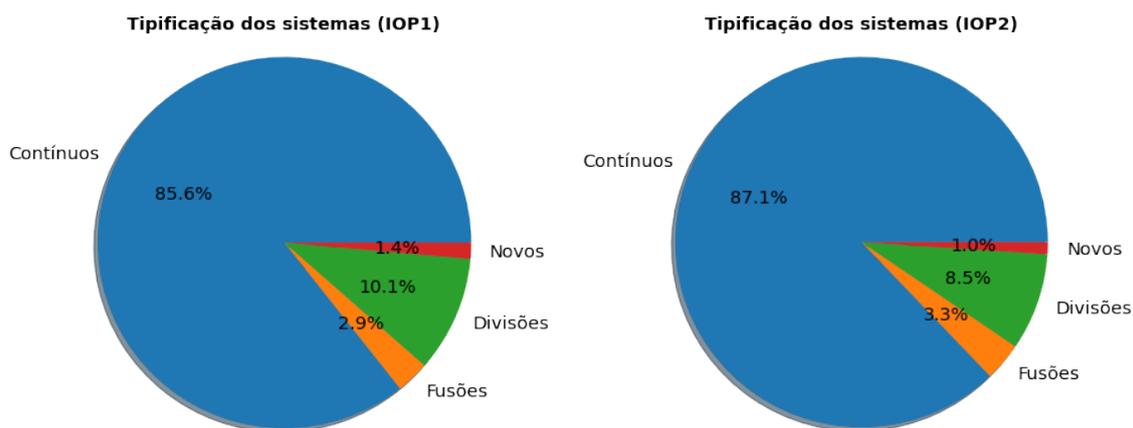
Fonte: Produção do Autor.

Figura B.4 - Skill Score para os diferentes métodos de correção vetorial rastreados via satélite, limiares e extrapolação com referência ao Ctvo-BASE-235-150 para oIOP1+IOP2.



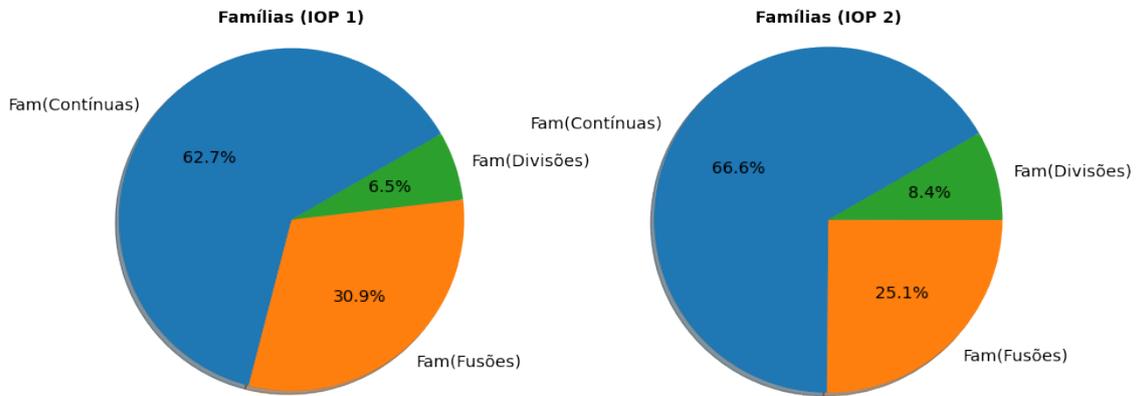
Fonte: Produção do Autor.

Figura B.5 - Ocorrência de cluster de nuvem por tipo (contínuos, fusão e divisão) durante os IOPs 1 (a) e 2 (b) do satélite.



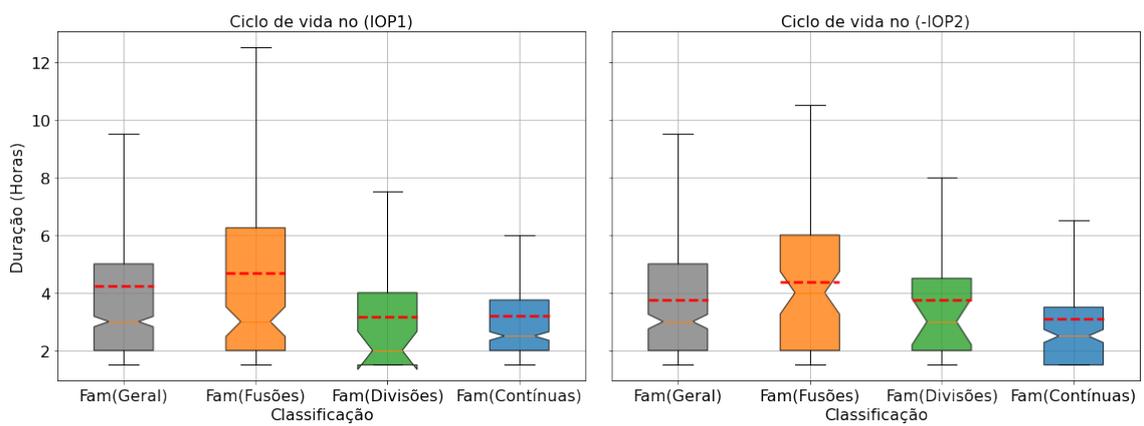
Fonte: Produção do Autor.

Figura B.6 - Ocorrência de famílias nuvem por tipo (contínuos, fusão e divisão) durante os IOP1 (a) e IOP2 (b).



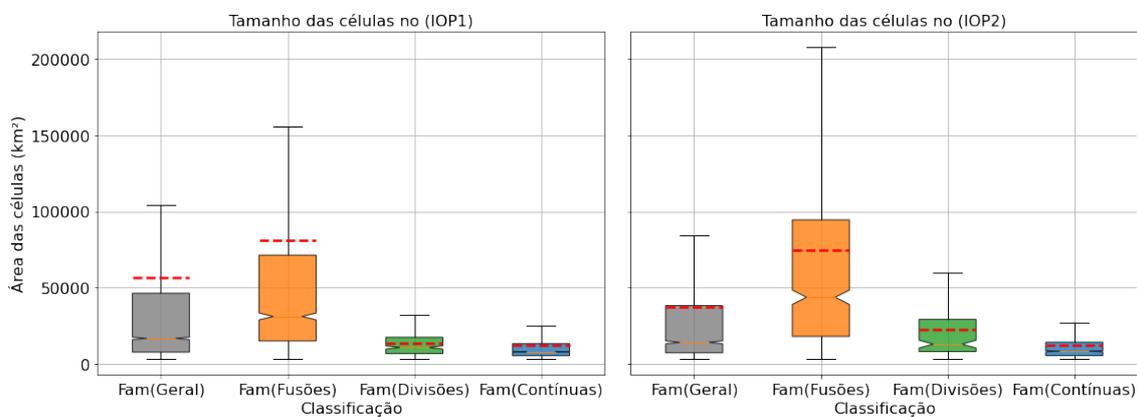
Fonte: Produção do Autor.

Figura B.7 - Figura 8 Satélite.



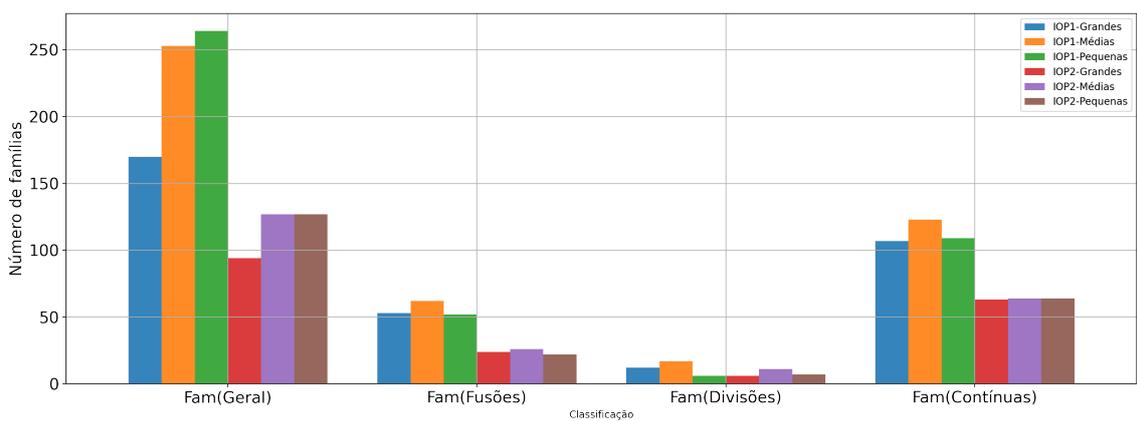
Fonte: Produção do Autor.

Figura B.8 - Duração em horas para os tipos de famílias no IOP1 e IOP2 do satélite.



Fonte: Produção do Autor.

Figura B.9 - Tamanho médio dos sistemas com base em suas famílias no IOP1 e IOP2 do satélite.

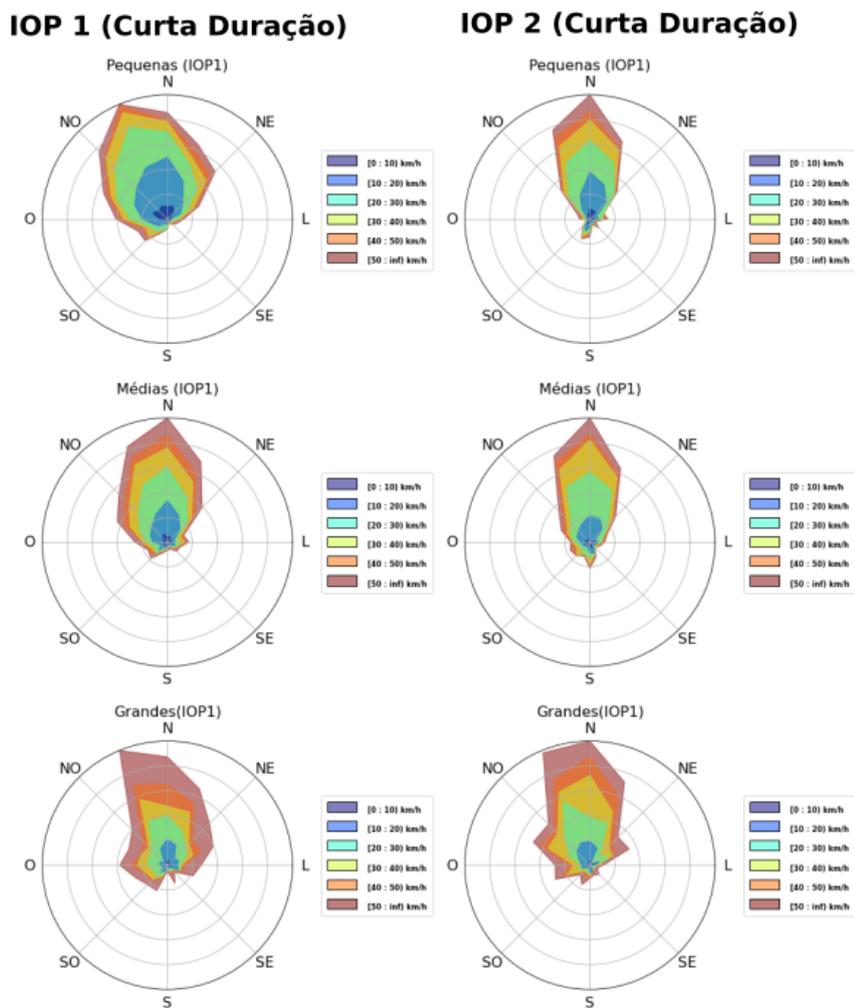


Fonte: Produção do Autor.



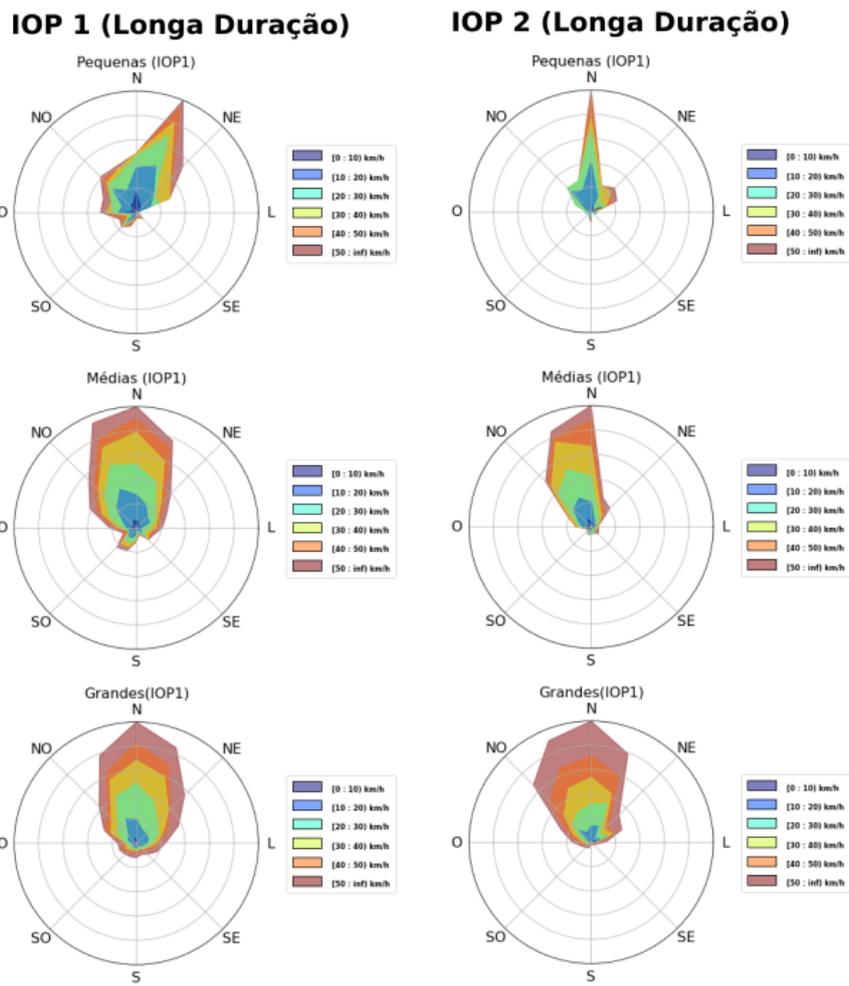
## APÊNDICE C - ROSA DOS VENTOS PARA RASTREIO VIA SATÉLITE

Figura C.1 - Propagação satélite curta duração.



Fonte: Produção do Autor.

Figura C.2 - Propagação satélite longa duração.



Fonte: Produção do Autor.

## APÊNDICE D - FIGURAS PARA O ESTUDO DE CASO - RADAR

Figura D.1 - Rastreo UID 135 RADAR - Data: 16/08/2014.

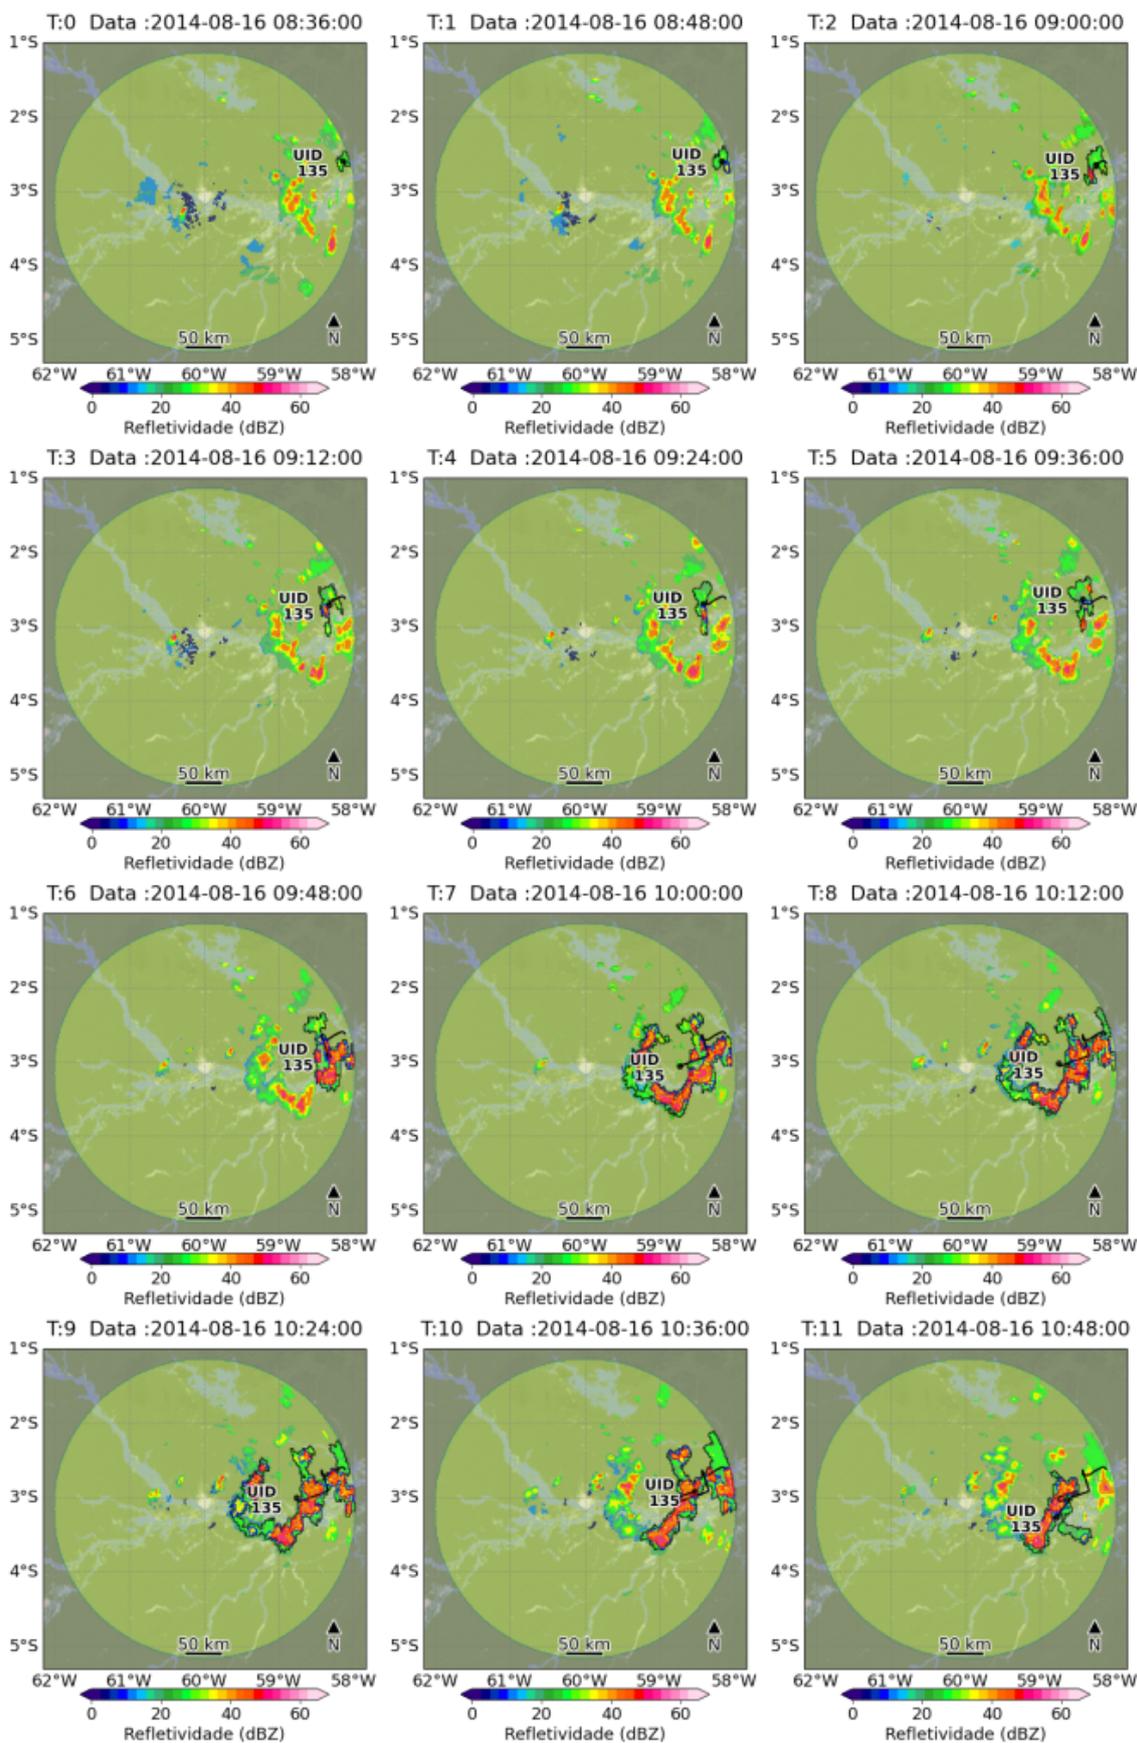




Figura D.3 - Continuação.

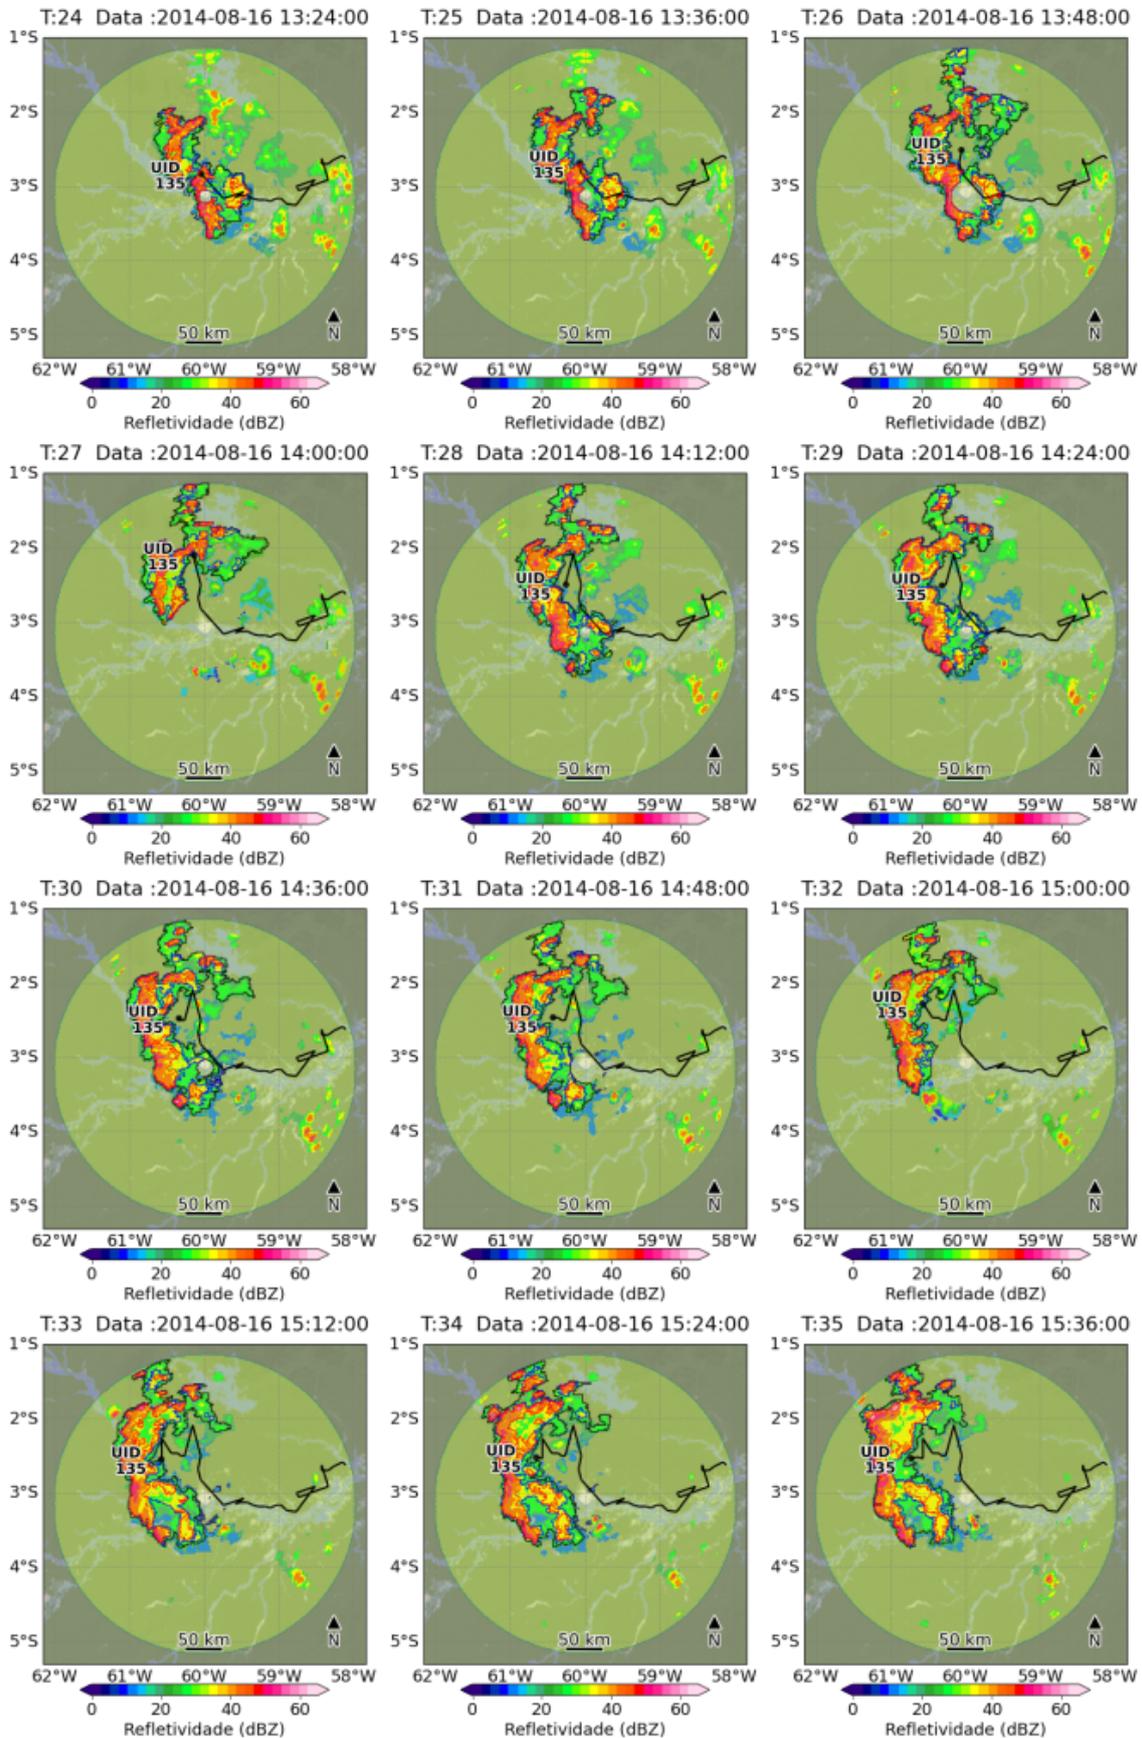


Figura D.4 - Continuação.

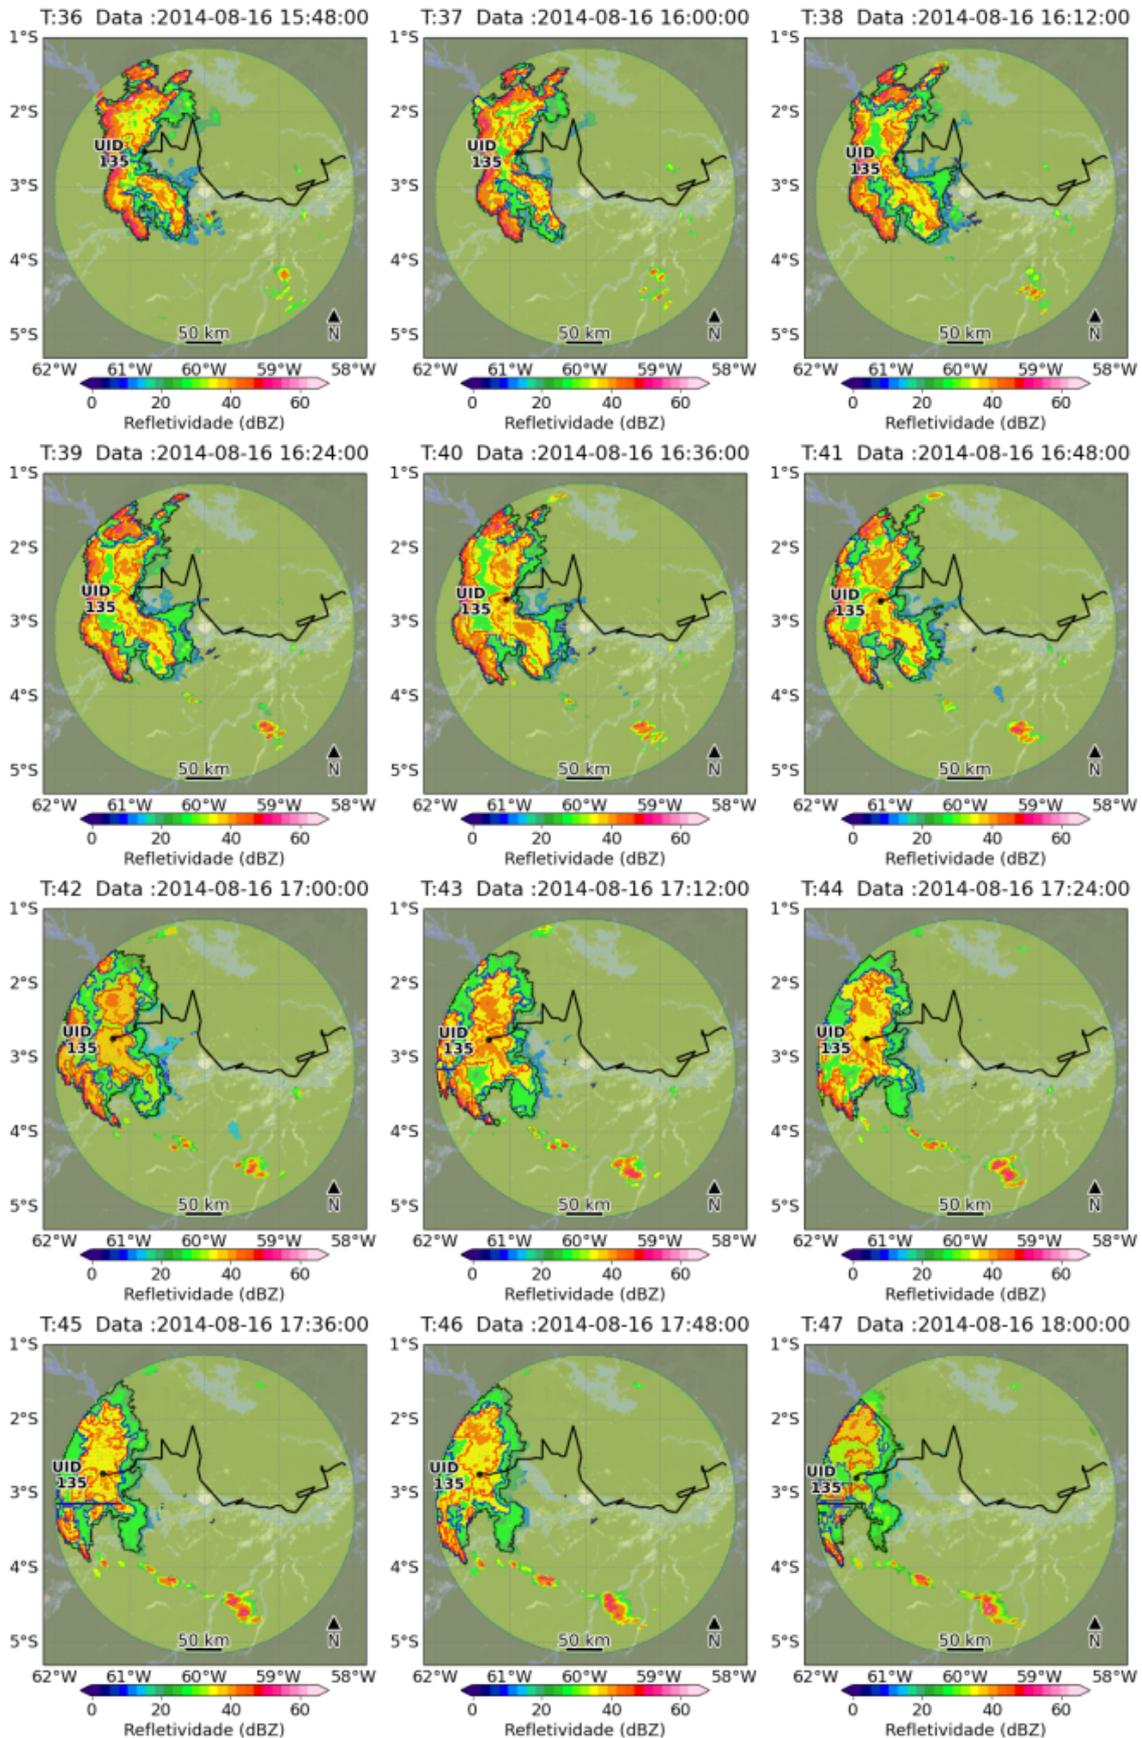
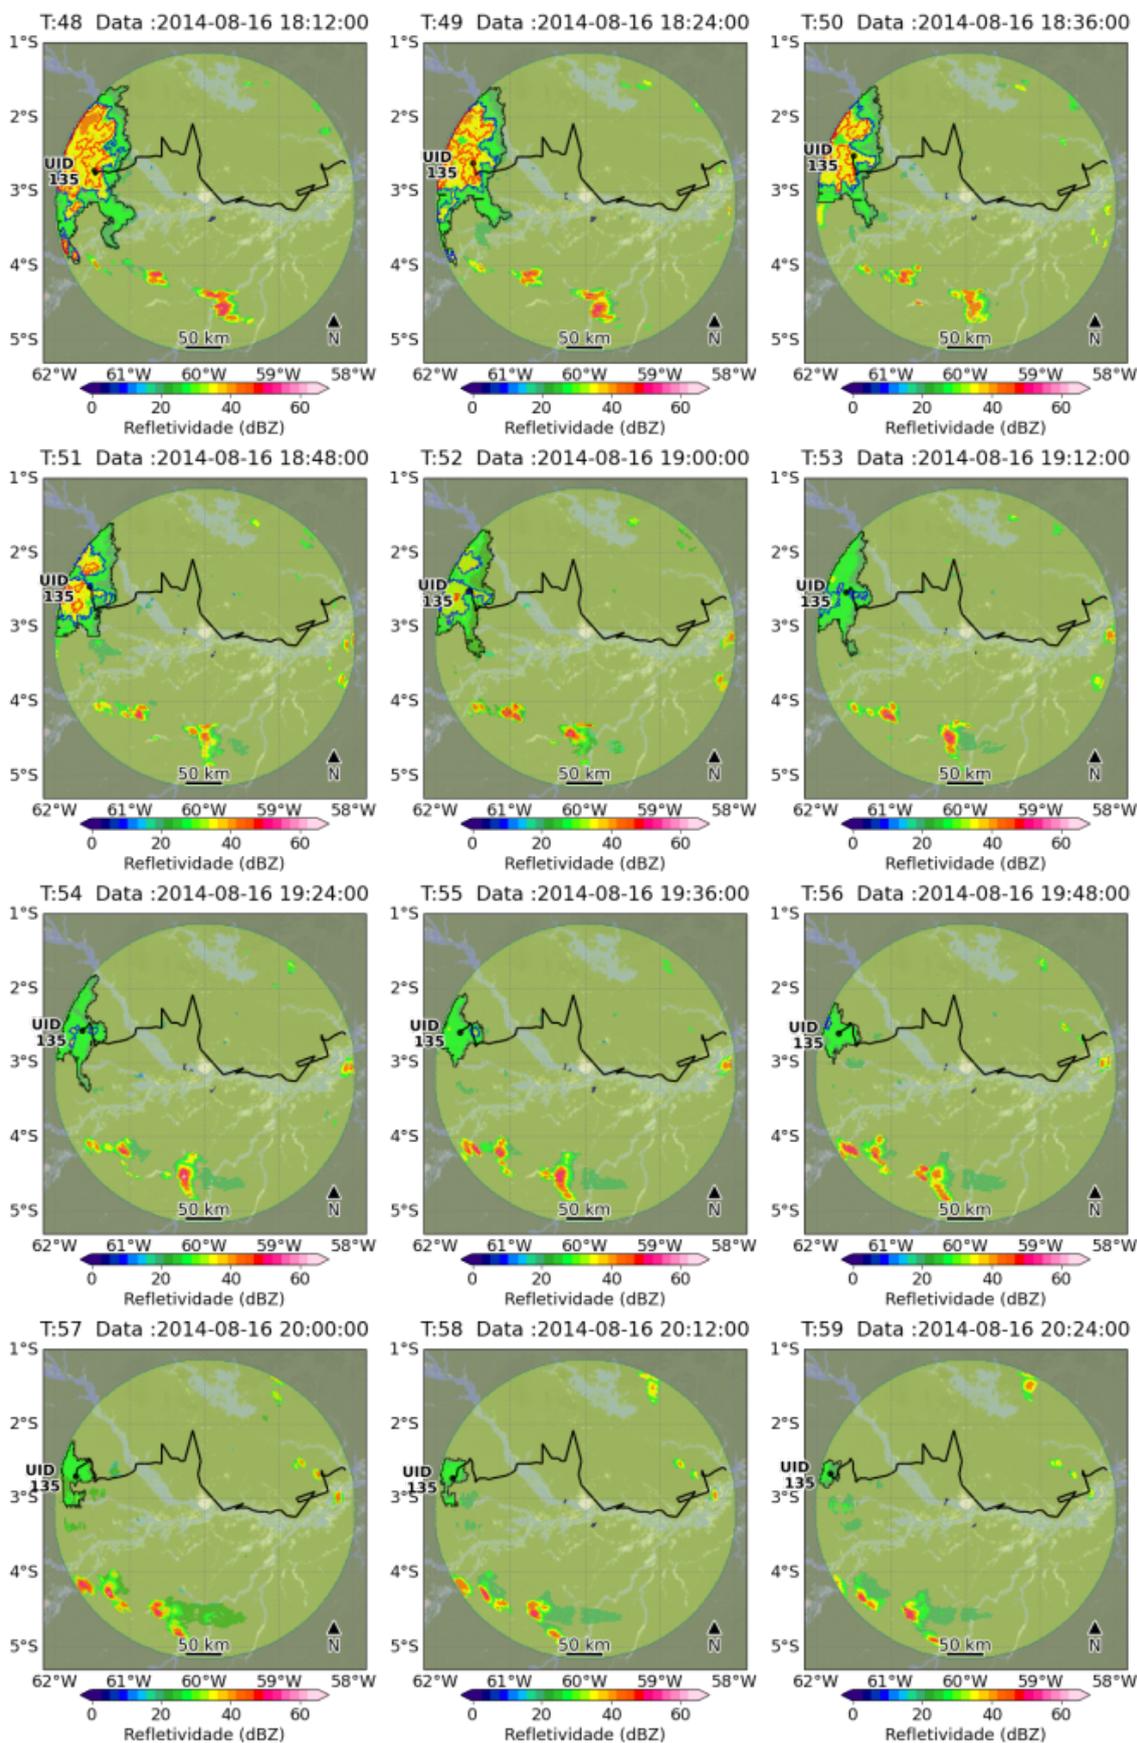


Figura D.5 - Conclusão.



## APÊNDICE E - FIGURAS PARA O ESTUDO DE CASO - SATELITE

Figura E.1 - Rastreo UID 143 SATELITE - Data: 16/08/2014.

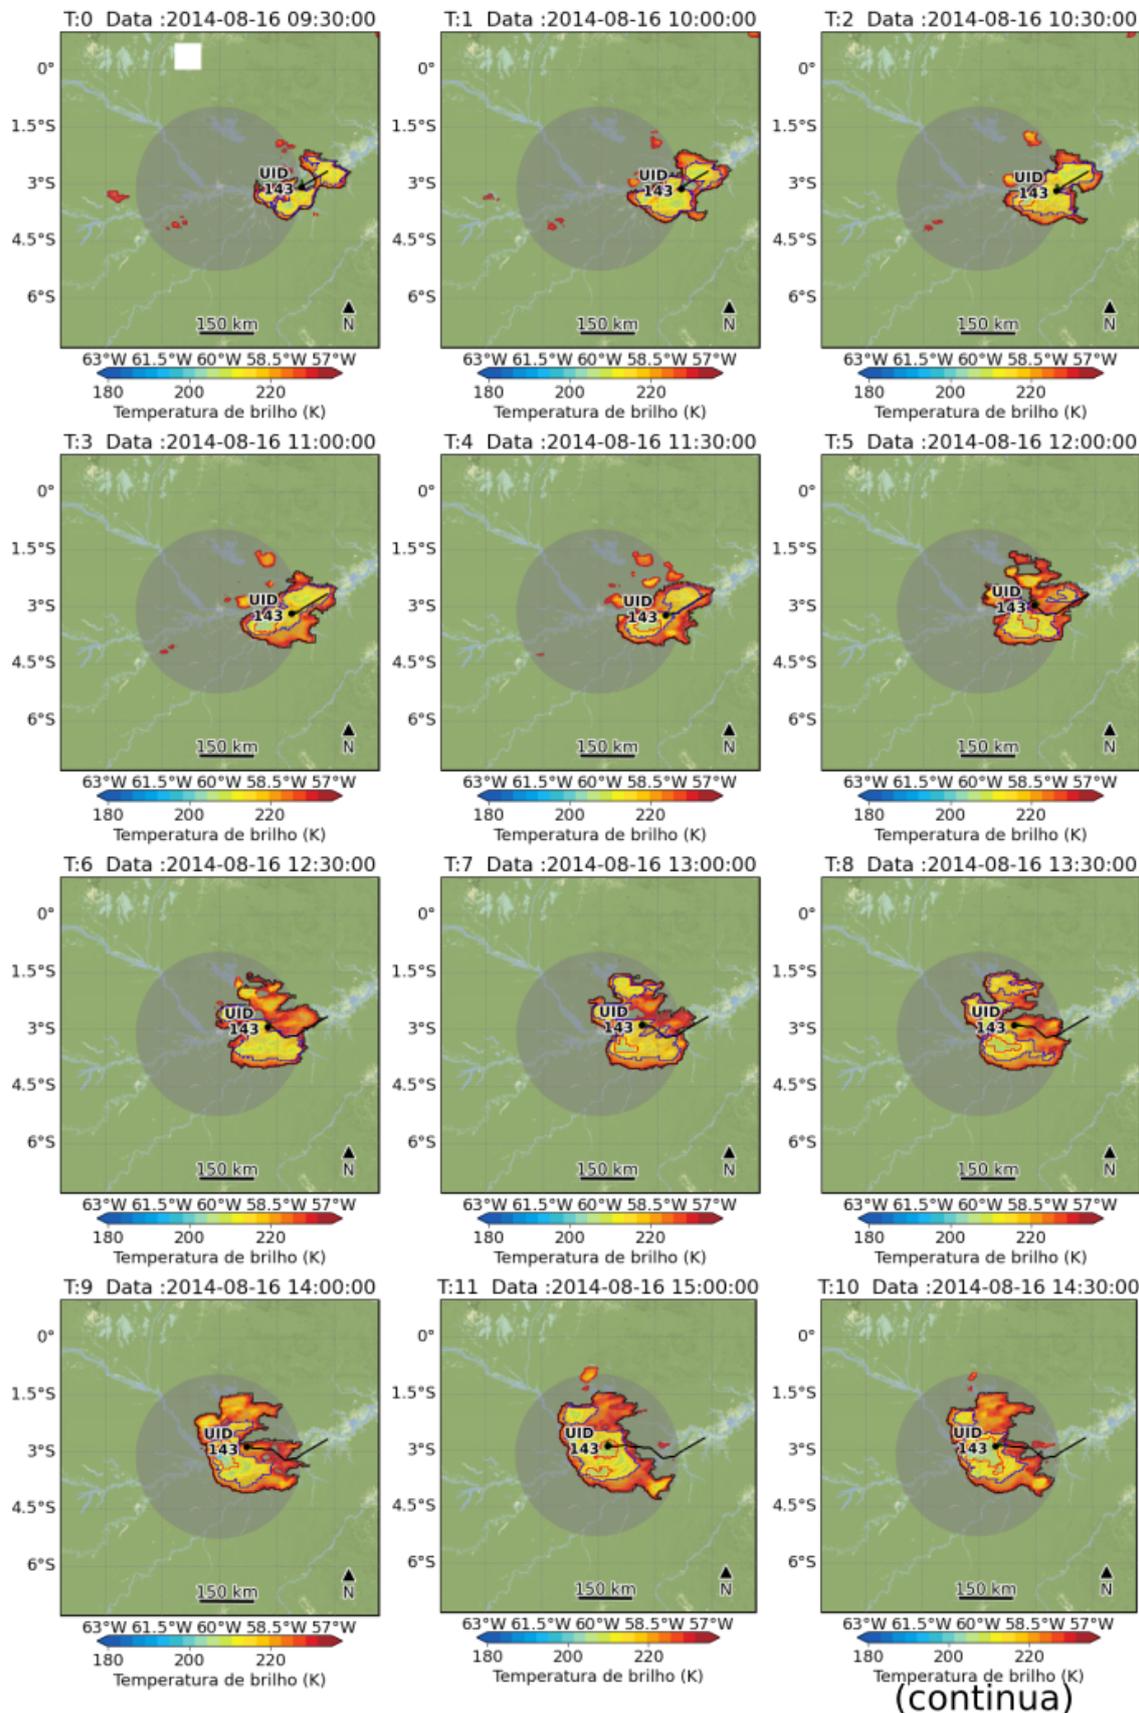
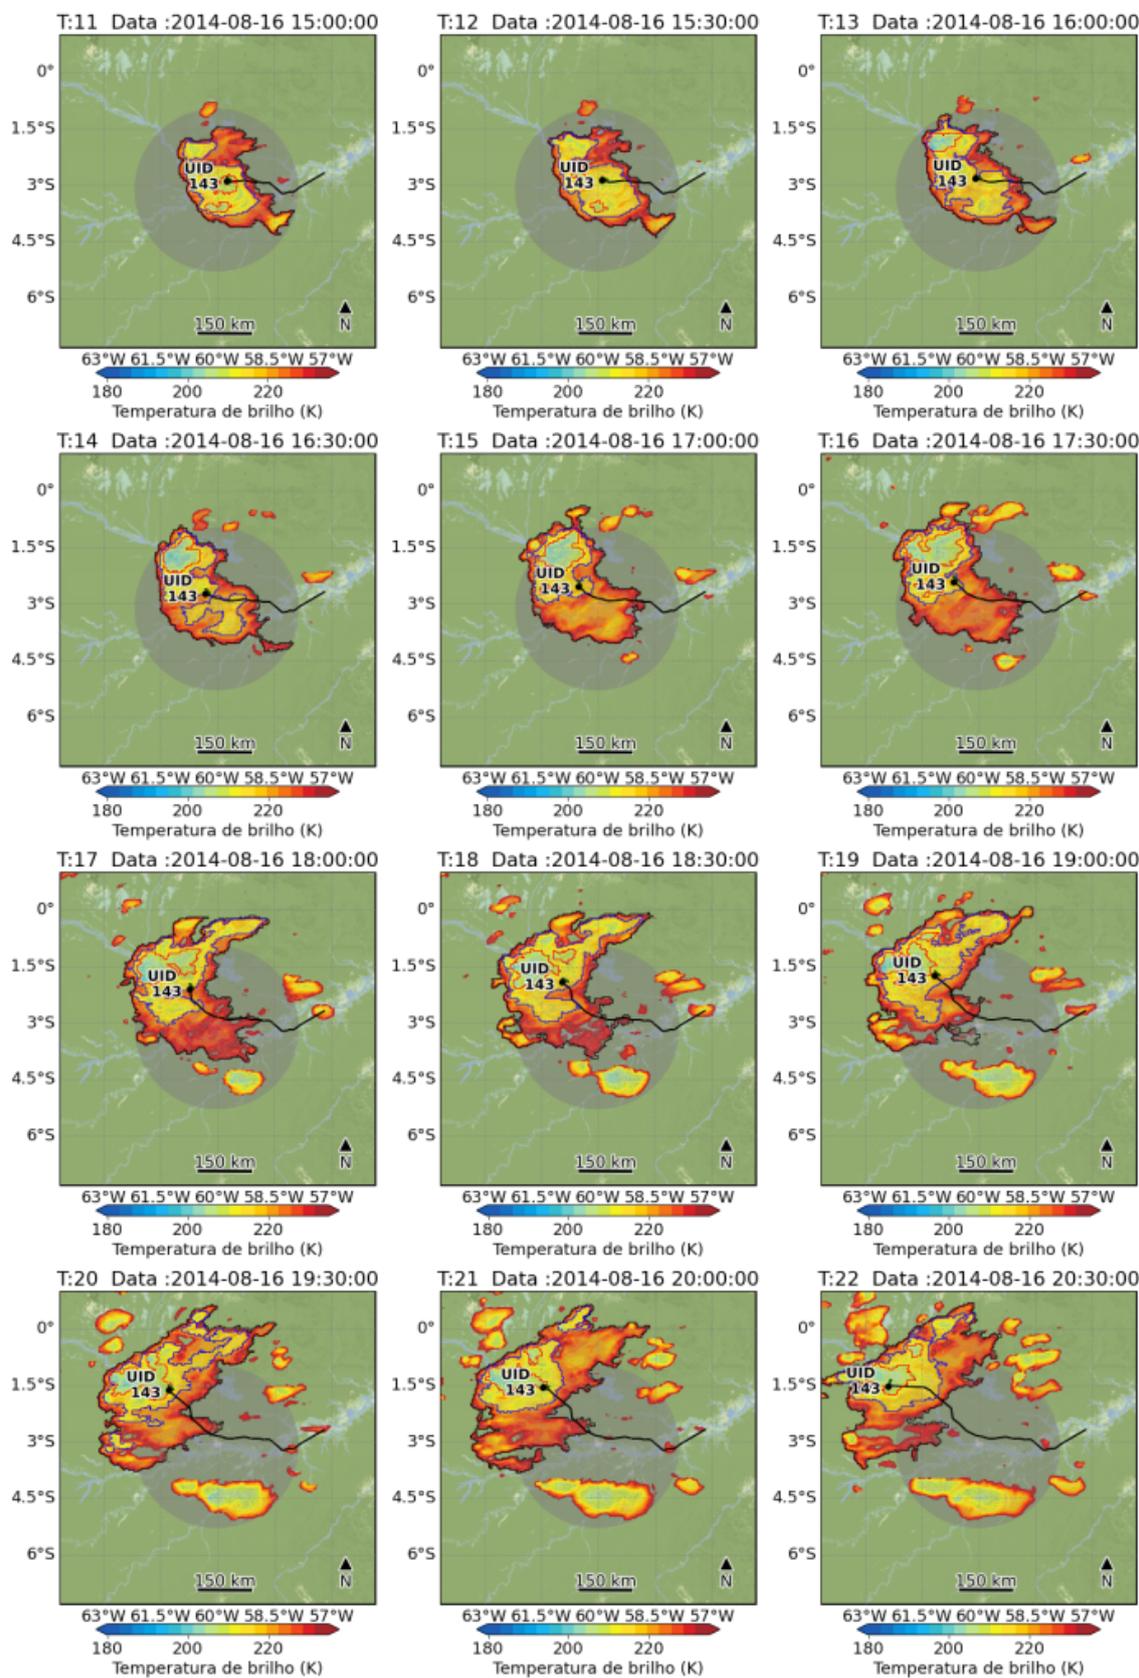
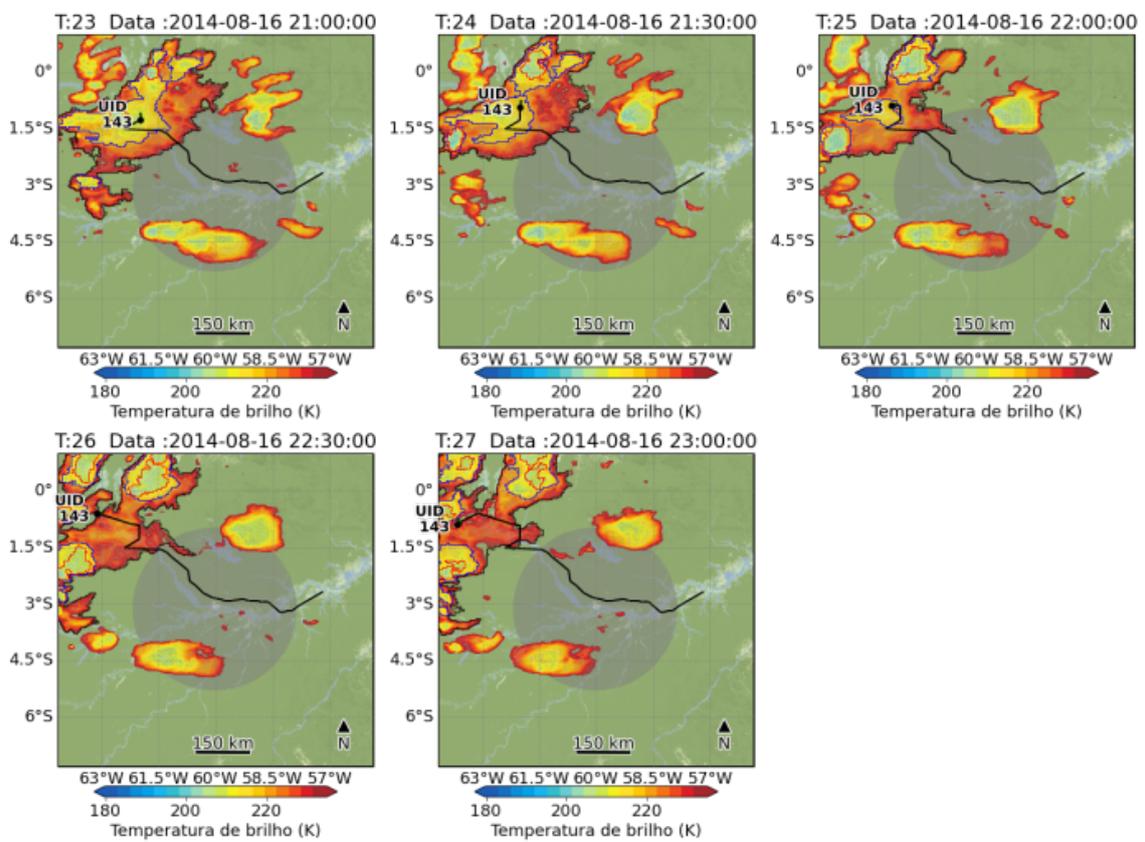


Figura E.2 - Continuação.



(continua)

Figura E.3 - Conclusão.



Fonte: Produção do Autor.