



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/05.19.14.31-TDI

## **AValiação orientada a objeto do impacto dos aerossóis de queimadas na previsão de ondas de calor na América do Sul**

Glícia Ruth Garcia de Araújo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Meteorologia, orientada pelo Dr.  
Luiz Fernando Sapucci, aprovada  
em 29 de maio de 2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/42GMDDH>>

INPE  
São José dos Campos  
2020

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

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

### **Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

### **Membros:**

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

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

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

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

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

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

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

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

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

### **EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/05.19.14.31-TDI

## **AValiação orientada a objeto do impacto dos aerossóis de queimadas na previsão de ondas de calor na América do Sul**

Glícia Ruth Garcia de Araújo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Meteorologia, orientada pelo Dr.  
Luiz Fernando Sapucci, aprovada  
em 29 de maio de 2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/42GMDDH>>

INPE  
São José dos Campos  
2020

Dados Internacionais de Catalogação na Publicação (CIP)

---

Araújo, Glícia Ruth Garcia de.

Ar15a Avaliação Orientada a Objeto do Impacto dos Aerossóis de Queimadas na Previsão de Ondas de Calor na América do Sul / Glícia Ruth Garcia de Araújo. – São José dos Campos : INPE, 2020.

xxiv + 120 p. ; (sid.inpe.br/mtc-m21c/2020/05.19.14.31-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.

Orientador : Dr. Luiz Fernando Sapucci.

1. Ondas de calor. 2. Previsibilidade atmosférica. 3. Modelagem ambiental. 4. Avaliação. 5. Orientado a objeto. I.Título.

CDU 551.583.1

---



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

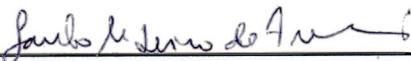
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Glicia Ruth Garcia de Araújo**

Título: "AVALIAÇÃO ORIENTADA A OBJETO DO IMPACTO DOS AEROSSÓIS DE QUEIMADAS NA PREVISÃO DE ONDAS DE CALOR NA AMÉRICA DO SUL"

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

Dr. Saulo Ribeiro de Freitas



Presidente / INPE / Cachoeira Paulista - SP

Participação por Video - Conferência

Aprovado      ( ) Reprovado

Dr. Luiz Fernando Sapucci



Orientador(a) / INPE / Cachoeira Paulista - SP

Participação por Video - Conferência

Aprovado      ( ) Reprovado

Dra. Ariane Frassoni dos Santos de Mattos



Membro da Banca / INPE / Cachoeira Paulista - SP

Participação por Video - Conferência

Aprovado      ( ) Reprovado

Dr. Daniel Pires Bittencourt



Convidado(a) / FUNDACENTRO / Florianópolis - SC

Participação por Video - Conferência

Aprovado      ( ) Reprovado

Este trabalho foi aprovado por:

( ) maioria simples

unanimidade



*Na vida tudo é uma onda, sempre há uma perturbação, mesmo que  
mínima para manter o equilíbrio.*

GLÍCIA GARCIA



## AGRADECIMENTOS

Primeiramente, quero agradecer a Deus acima de tudo por possibilitar chegar até aqui, e vencer mais essa etapa.

Ao meu orientador Dr. Luiz Fernando Sapucci por ter abraçado esta pesquisa, e pelos ensinamentos e incentivos dados ao longo desses dois anos de curso, que contribuiu veemente para a minha formação profissional, como também pessoal.

À pesquisadora Dra. Ariane Frassoni que desde o início colaborou em todos os esforços para o desenvolvimento deste trabalho.

Ao pessoal da Divisão de Modelagem e Desenvolvimento (DIDMD), e ao Valter Oliveira pelo suporte dado em relação às rodadas do BRAMS. Ao João Gerd de Mattos pela ajuda no SCANTEC.

À todos os professores do Programa de Pós-Graduação em Meteorologia (PGMET) do INPE pelos ensinamentos dados ao longo do curso.

À CAPES pela oportunidade de bolsa para realização desta pesquisa no INPE.

Aos meus amigos e colegas de curso pelo apoio e ajuda quando precisei. Em especial ao meu companheiro Francisco Agostinho de Brito Neto pela paciência e pela ajuda com o código em Python de identificação das ondas de calor, além de estar ao meu lado quando mais precisei.

Por fim, a minha irmã (Gliciane Ruthênia) e ao meu cunhado (Jubson Simões) que me ajudaram a chegar até aqui, dando apoio aos meus estudos.

Sou muito grata a todos vocês!



## RESUMO

Eventos de ondas de calor aumentam o risco de problemas cardiovasculares, e consequentemente aumenta o número de óbitos, além de prejudicar a agricultura e pecuária. No setor elétrico, a Temperatura Máxima do Ar ( $T_{max}$ ) é um dos parâmetros atmosféricos mais importantes que afeta a quantidade de consumo de energia pela população. Considerando a importância da previsão da  $T_{max}$  para diferentes setores da sociedade, é importante entender o quanto confiável e precisa é a previsão de curto prazo da  $T_{max}$ . Diversos estudos têm demonstrado que os aerossóis atmosféricos têm influência na previsibilidade de algumas variáveis atmosféricas na escala de tempo, principalmente na temperatura do ar próximo à superfície devido aos efeitos diretos e indiretos associados com os aerossóis. Na América do Sul (AS), as principais fontes de emissão são as queimadas que injetam mais de 630 Tg/ano de aerossóis e gases traços na atmosfera. Um sistema de previsão de tempo totalmente integrado com superfície, atmosfera e química pode diminuir os erros sistemáticos das previsões de temperatura. Portanto, o objetivo principal desta pesquisa é diagnosticar os erros dos valores de  $T_{max}$  em episódios de ondas de calor provenientes da previsão numérica de tempo em uma avaliação espacial orientada a objetos utilizando o Method For Object-Based Diagnostic Evaluation (MODE) implementado no software SCANTEC (Sistema Comunitário de Avaliação de modelos Numéricos de Previsão de Tempo e Clima). A eficácia dessa técnica deverá ser demonstrada, e para isso as previsões com a inclusão da química atmosférica serão comparadas com um experimento realizado sem a inclusão dessa, e assim avaliar a influência da química na previsão das ondas de calor na escala de tempo na AS. Sendo assim, foi utilizado o modelo regional BRAMS, para o período de julho a outubro de 2016 a 2018. Para a determinação dos objetos no MODE foi utilizado um limiar de temperatura que caracteriza os eventos extremos de calor, baseado nos valores de análises do GFS e reanálises do ERA5 como referências. Os resultados mostram que com a química incluída na previsão a curto prazo, a  $T_{max}$  em superfície diminuiu consideravelmente em regiões com AOT acentuada, consequentemente reduzindo a extensão da onda de calor, e aumentando o número de objetos no campo de avaliação do MODE. Dos dois episódios de ondas de calor avaliados, a previsão integrada com química representou melhor as características geométricas dos eventos. Ambas previsões não conseguiram prever com antecedência o início e final da onda de calor, sendo mais evidente esta falha na previsão integrada. Além disso, as previsões superestimam os objetos das referências no episódio de agosto de 2017, errando mais por falsos alarmes do que por falhas. Contudo, no episódio com maior persistência em agosto de 2016, a previsão integrada apresentou uma maior acurácia na quantidade de objetos em relação a previsão sem química.

Palavras-chave: Ondas de Calor. Previsibilidade Atmosférica. Modelagem Ambiental. Avaliação. Orientado a Objeto.



# OBJECT-BASED EVALUATION OF THE IMPACT OF BURNING AEROSOLS ON HEAT WAVES FORECAST IN SOUTH AMERICA

## ABSTRACT

Heat wave events increase the risk of cardiovascular problems, and consequently increase the number of deaths, in addition to damage agriculture and livestock. In the electric sector, Maximum Air Temperature  $T_{max}$  is one of the most important atmospheric parameters that impact the amount of power consumption by population. Considering the importance of  $T_{max}$  forecasts for different sectors of the society, it is important understand how reliable and accurate are short-range  $T_{max}$  forecasts. Several studies have shown that aerosols influence atmospheric forecasts in the short-range timescale, specially air temperature due the direct effect associated with aerosols. In South America (SA), the main source of aerosol emissions is biomass burning that more inject 630 Tg/year of aerosols and trace gases in the atmosphere. Fully integrated models that combine surface, atmosphere and chemistry should decrease systematic errors in temperature forecasts. Therefore, the main goal of this research is to diagnose the errors of the values of  $T_{max}$  in heat wave episodes from numerical weather forecasting in an object-based spatial evaluation using Method For Object-Based Diagnostic Evaluation (MODE) implemented in the SCANTEC (in Portuguese Sistema Comunitário de Avaliação de modelos Numéricos de Previsão de Tempo e Clima). The effectiveness of this technique should be demonstrated, and for this, the predictions of atmospheric chemistry will be compared with an experiment realized without its inclusion, and thus evaluate the influence of chemistry on the prediction of heat waves in the time scale in SA. Thus, the BRAMS regional model was used for the period from July to October 2016 to 2018. For objects identification in MODE, we were used a temperature threshold that characterizes extreme heat events, based on GFS analysis values and ERA5 reanalysis as references. The results show that with the atmospheric chemistry included in the short-term forecast, surface  $T_{max}$  decreases considerably in regions with marked AOT, consequently reducing the extent of the heat wave, and increasing the number of objects in the MODE evaluation field. Of the two episodes of heat waves evaluated, the prediction integrated with chemistry better represented the geometric characteristics of the events. Both forecasts could not predict in advance the beginning and final of the heat wave, however this failure in integrated forecasts is more evident. In addition, the forecasts overestimating the objects of the references in the August 2017 episode, erring more by false alarms than by failures. However, in the episode with greater persistence in August 2016, the integrated forecast showed a greater accuracy in the number of objects in relation to the prediction without chemistry.

Keywords: Heat Waves. Atmospheric Predictability. Environmental Modeling. Evaluation. Object-Based.



## LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Esquema simplificado da estrutura principal do SCANTEC com os respectivos módulos do MODE dentro do <i>core</i> do <i>software</i> . . . . .	11
2.2 Representação do ciclo de vida dos aerossóis primários e secundários na atmosfera. . . . .	18
2.3 Forçantes radiativa climática de fontes naturais e antrópicas (1750-2011) baseada no quinto relatório do IPCC. . . . .	20
3.1 Mapa da AS com destaque para o domínio (retângulo) em que esta configurada a versão do modelo BRAMS com resolução horizontal de 20 km, utilizada nessa pesquisa. . . . .	29
3.2 Representação das parametrizações físicas, químicas e de superfície dos processos de subgrade do modelo BRAMS. . . . .	32
3.3 Dendrograma representando o processo de formação de grupos na análise de <i>cluster</i> com 10 elementos hipotéticos, e três grupos formados representados pelos retângulos coloridos em <i>shaded</i> . . . . .	39
4.1 Soma da distância dos quadrados entre os valores de $T_{max}$ da reanálise do ERA5 para formação de até 9 <i>clusters</i> . . . . .	42
4.2 Análise do índice <i>Silhouette</i> e <i>clusters</i> espacializados na AS da $T_{max}$ da reanálise do ERA5 para três grupos definidos ( $k=3$ ). . . . .	43
4.3 Máscaras em branco sobre o continente Sul Americano das áreas de conflitos entre <i>clusters</i> da $T_{max}$ da reanálise do ERA5 para três grupos definidos. . . . .	44
4.4 Climatologia horária da Temperatura a 2 metros da reanálise ERA5 nas três regiões homogêneas definidas na análise de <i>cluster</i> no período sazonal (JASO: 1979-2018). . . . .	45
4.5 Box-Plot mensal da temperatura máxima da reanálise do ERA5 nas três áreas homogêneas de $T_{max}$ no período de 1979-2018. . . . .	46
4.6 Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 10 a 12 de agosto de 2017 na análise do GFS às 18 UTC. . . . .	49
4.7 Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 10 a 12 de agosto de 2017 na reanálise ERA5 às 18 UTC. . . . .	50

4.8	Campos de restauração da $T_{max}$ em °C dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 10 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS. . . .	51
4.9	Campos de restauração da $T_{max}$ em °C dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 11 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS. . . .	52
4.10	Campos de restauração da $T_{max}$ em °C dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 12 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS. . . .	53
4.11	Índices estatísticos CSI, POD, FAR, Bias e MMI dos objetos identificados entre a reanálise do ERA5 e análise do GFS no período de ocorrência do episódio de agosto de 2017. . . . .	55
4.12	Objetos de onda de calor identificados no MODE/SCANTEC com seus respectivos campos restaurados de $T_{max}$ na análise do GFS e reanálise do ERA5 e para a previsão de 18h válidas para o dia 10 de agosto de 2017 às 18 UTC sem e com a modelagem química integrada e o campo de AOT em 550 nm. . . . .	57
4.13	Objetos de ondas de calor nas previsões de 18h sem química e integrada com química pareados pelo MODE/SCANTEC como os objetos presentes nas referências GFS e ERA5 para 10 de agosto de 2017 às 18 UTC. . . .	58
4.14	Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada, usando como referência as análises do GFS para o caso de agosto de 2017. . . . .	60
4.15	Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada, usando como referência a reanálise do ERA5 para o caso de agosto de 2017. . . . .	61
4.16	Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42 e 66 hs sem e com a modelagem química integrada pareados em relação a análise do GFS para o caso de agosto de 2017. . . . .	62
4.17	Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a análise do GFS e as previsões das 18, 42 e 66 hs sem e com a química integrada para o caso de agosto de 2017. . . . .	63

4.18 Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42 e 66 hs sem e com a modelagem química integrada pareados em relação a reanálise ERA5 para o caso de agosto de 2017. . . . .	64
4.19 Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a reanálise do ERA5 e as previsões das 18, 42 e 66 hs sem e com a química integrada para o caso de agosto de 2017. . . . .	65
4.20 Média do Máximo Interesse (MMI) dos objetos pareados entre as previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada e as análises do GFS e ERA5 para o caso de agosto de 2017. . . . .	67
4.21 Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 13 a 21 de agosto de 2016 na reanálise ERA5 às 18 UTC. . . . .	69
4.22 Onda de calor identificada espacializado na Área1 e intensidade média diária em °C nas previsões de 18h sem a química e com a química atmosférica integrada e campo de AOT em 550 nm para o dia 16 de agosto de 2016 às 18 UTC. . . . .	72
4.23 Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada, usando como referência a reanálise do ERA5 no período de ocorrência do caso de agosto de 2016. . . . .	74
4.24 Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42, 66 e 90 hs sem química e integrada com a modelagem química pareados em relação a reanálise do ERA5 para o episódio de onda de calor em agosto de 2016. . . . .	75
4.25 Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a reanálise do ERA5 e as previsões das 18, 42, 66 e 90 hs sem química e com a química atmosférica integrada para o episódio de agosto de 2016. . . . .	77
4.26 Média do Máximo Interesse Observado (MMIO) dos objetos observados para as previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada. . . . .	78
4.27 Média do Máximo Interesse Previsto (MMIP) dos objetos previstos para previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada. . . . .	79
4.28 Média do Máximo Interesse (MMI) dos objetos pareados entre as previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada e reanálise do ERA5. . . . .	80

A.1	Análise do índice <i>Silhouette</i> e <i>clusters</i> espacializados na AS da $T_{max}$ da reanálise do ERA5 para quatro grupos definidos ( $k=4$ ). . . . .	109
B.1	Box-Plot do total de ondas de calor por ano nas três regiões homogêneas de $T_{max}$ – Reanálise ERA5 (JASO: 1979-2019). . . . .	110
B.2	Frequência mensal de ondas de calor em percentagem nas três regiões homogêneas de $T_{max}$ – Reanálise ERA5 (JASO: 1979-2019). . . . .	111
B.3	Classificação das ondas de calor em eventos intensos, médios e fracos nas regiões homogêneas de $T_{max}$ no período JASO de 1979-2019. . . . .	112
B.4	Frequência do número de pontos de grade e intensidade média das ondas de calor na AS nas três regiões homogêneas de $T_{max}$ no período JASO de 1979-2019. . . . .	113
B.5	Distribuição e tendência anual da duração média em dias das ondas de calor nas três regiões homogêneas de $T_{max}$ no período JASO de 1979-2019.	114
B.6	Distribuição e tendência anual da intensidade média em °C das ondas de calor nas três regiões homogêneas de $T_{max}$ no período JASO de 1979-2019.	115
C.1	Efeito da componente química nos fluxos radiativos de calor sensível e onda longa emitida pela superfície em $Wm^{-2}$ para o dia 16 de agosto de 2016. . . . .	117
C.2	Perfil vertical médio dos aerossóis na previsão integrada com química do modelo BRAMS para o dia 16 de agosto de 2016. . . . .	118
C.3	Linhas de corrente e velocidade do vento das previsões do modelo BRAMS, e diferenças entre a previsão com e sem a modelagem química nos níveis de 850 hPa, 500 hPa e 250 hPa para o dia 16 de agosto de 2016.	119
C.4	Perfil vertical da umidade específica das diferenças entre as previsões com e sem a química atmosférica sobre o corte transversal demarcado (linha preta) no mapa para o dia 16 de agosto de 2016. . . . .	120

## LISTA DE TABELAS

	<u>Pág.</u>
2.1 Tabela de Contingência. . . . .	13
2.2 Cálculo hipotético da matriz de interesse entre 3 objetos previstos e 2 objetos observados. . . . .	15
3.1 Pesos atribuídos na composição do valor de IT dos objetos pareados de ondas de calor avaliados no MODE. . . . .	35
4.1 Atributos dos objetos pareados identificados entre a reanálise do ERA5 e análise do GFS no período de 10 a 12 de agosto de 2017. . . . .	54
4.2 Contingência dos objetos no dia 10 de agosto de 2017. . . . .	55
4.3 Contingência dos objetos no dia 11 de agosto de 2017. . . . .	55
4.4 Contingência dos objetos no dia 12 de agosto de 2017. . . . .	55
4.5 Interesse total (IT) dos objetos pareados entre as referências e a previsão sem e com a inclusão da modelagem química atmosférica integrada para os prazos das 18, 42 e 66 hs. . . . .	66
4.6 Onda de Calor identificada nas previsões sem química e integrada com a química atmosférica no período do caso de agosto de 2016. . . . .	70
4.7 Total de sucessos, falhas e falsos alarmes das previsões sem química e integrada com a química atmosférica para os prazos das 18, 42, 66 e 90 horas para o episódio de onda de calor em agosto de 2016. . . . .	73
4.8 IT dos objetos pareados entre a reanálise do ERA5 e a previsão sem química e com a química atmosférica integrada para os prazos das 18, 42, 66 e 90 hs. . . . .	77



## LISTA DE ABREVIATURAS E SIGLAS

AERONET	–	<i>Aerosol Robotic Network</i>
AOT	–	<i>Aerosol Optical Thickness</i>
AS	–	América do Sul
BRAMS	–	<i>Brazilian developments on the Regional Atmospheric Modeling System</i>
CATT	–	<i>Coupled Aerosol and Tracer Transport model</i>
CCN	–	Núcleos de Condensação das Nuvens
CLP	–	Camada Limite Planetária
CSI	–	<i>Critical Success Index</i>
CPTEC	–	Centro de Previsão de Tempo e Estudos Climáticos
ECMWF	–	<i>European Centre for Medium-Range Weather Forecasts</i>
FAR	–	<i>False Alarm Ratio</i>
GFS	–	<i>Global Forecast System</i>
GSS	–	<i>Gilbert Skill Score</i>
INPE	–	Instituto Nacional de Pesquisas Espaciais
IT	–	Interesse Total
IPCC	–	<i>Intergovernmental Panel on Climate Change</i>
MetUM	–	Met Office Unified Model
MIP	–	Máximo Interesse Previsto
MIO	–	Máximo Interesse Observado
MODE	–	<i>Method For Object-Based Diagnostic Evaluation</i>
MMI	–	Média do Máximo Interesse
NCAR	–	<i>National Center for Atmospheric Research</i>
NCEP	–	<i>National Centers for Environmental Prediction</i>
ODP	–	Oscilação Decadal do Pacífico
PC	–	<i>Proportion Correct</i>
PI	–	Parâmetro de Intensidade
PId	–	Parâmetro de Intensidade Diário
PM	–	Material Particulado
POD	–	<i>Probability of Detection</i>
PNTC	–	Previsão Numérica de Tempo e Clima
PNT	–	Previsão Numérica de Tempo
REQM	–	Raiz do Erro Quadrático Médio
SCANTEC	–	Sistema Comunitário de Avaliação de modelos de PNTC
$T_{max}$	–	Temperatura Máxima do Ar
$\overline{T}_{max}$	–	Temperatura Máxima Média do Ar
$T_{min}$	–	Temperatura Mínima do Ar
WRF	–	<i>Weather Research and Forecasting</i>



## LISTA DE SÍMBOLOS

$a$	–	número de sucessos
$a_{ref}$	–	ocorrência de evento por acaso
$b$	–	número de falsos alarmes
$c$	–	número de falhas
$C_i$	–	função de confiança
$d$	–	rejeições corretas
$D$	–	dias julianos
$i$	–	início da série histórica
$IP_i$	–	interesse parcial dos objetos
$k$	–	pontos de grade
$N$	–	número de anos
$W_i$	–	pesos dos atributos pares de objetos
$\ell$	–	atributos dos objetos identificados
$\sigma$	–	desvio padrão



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Objetivos . . . . .	5
<b>2 REVISÃO BIBLIOGRÁFICA</b> . . . . .	<b>7</b>
2.1 Avaliação de modelos . . . . .	7
2.1.1 Métodos robustos de avaliação de modelos: avaliação orientada a objeto	8
2.1.2 Avaliação de previsões de temperatura do ar . . . . .	16
2.2 Visão geral sobre os aerossóis atmosféricos, seu papel nos padrões de tem- peratura próximo à superfície e impactos na previsibilidade da atmosfera	16
2.2.1 Efeitos direto e indireto dos aerossóis e seus impactos nas variações da temperatura do ar próximo à superfície . . . . .	19
2.2.2 O papel dos aerossóis na previsibilidade da atmosfera . . . . .	22
2.3 Ondas de calor . . . . .	26
<b>3 METODOLOGIA</b> . . . . .	<b>28</b>
3.1 Área de estudo . . . . .	28
3.2 Modelo numérico escolhido . . . . .	30
3.3 Dados utilizados como referência na avaliação . . . . .	32
3.3.1 Análise do <i>Global Forecast System</i> (GFS) . . . . .	32
3.3.2 Reanálises do ERA5 . . . . .	33
3.4 Metodologia orientada a objeto MODE para avaliação da temperatura do ar . . . . .	34
3.4.1 Metodologia de identificação dos episódios de ondas de calor . . . . .	36
3.4.2 Análise de <i>cluster</i> . . . . .	38
<b>4 RESULTADOS E DISCUSSÕES</b> . . . . .	<b>41</b>
4.1 Análise de <i>cluster</i> : identificação das regiões homogêneas de temperatura máxima do ar . . . . .	41
4.1.1 Análise descritiva da temperatura máxima do ar . . . . .	44
4.1.2 Episódios de ondas de calor identificados na América do Sul . . . . .	46
4.2 Avaliação dos episódios de ondas de calor: estudo de casos . . . . .	48
4.2.1 Análise do GFS <i>vs.</i> reanálise do ERA5: caso de agosto de 2017 . . . . .	48

4.2.2	Avaliação das previsões de ondas de calor sem e com a inclusão da química atmosférica: caso de agosto de 2017 . . . . .	55
4.2.3	Avaliação das previsões de ondas de calor sem e com a inclusão da química atmosférica: caso agosto de 2016 . . . . .	68
<b>5</b>	<b>CONCLUSÕES . . . . .</b>	<b>81</b>
5.1	Sugestões para trabalhos futuros . . . . .	84
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>86</b>
	<b>APÊNDICE A - ANÁLISE DE <i>CLUSTER</i> DA TEMPERATURA MÁXIMA DO AR NA AMÉRICA DO SUL . . . . .</b>	<b>109</b>
	<b>APÊNDICE B - CLIMATOLOGIA DAS ONDAS DE CALOR NA AMÉRICA DO SUL. . . . .</b>	<b>110</b>
	<b>APÊNDICE C - IMPACTOS DA QUÍMICA NAS VARIÁVEIS ATMOSFÉRICAS DO MODELO BRAMS . . . . .</b>	<b>116</b>

# 1 INTRODUÇÃO

A Previsão Numérica de Tempo (PNT) é obtida a partir do emprego de métodos numéricos para resolver as equações que governam o estado da atmosfera, de modo a obter uma previsão em escalas de tempo que variam de horas a aproximadamente uma semana. A PNT é de extrema importância para a tomada de decisões e para o planejamento em vários setores da sociedade, desde atividades do dia a dia, como por exemplo para informar à população se o período do dia será mais quente ou mais frio, chuvoso ou ensolarado, ou para setores estratégicos da economia, como é o caso da agricultura, gestão de recursos hídricos e geração de energia (por exemplo, solar, eólica, hidrelétrica etc.).

Para a obtenção de uma previsão de qualidade necessita-se representar de forma mais realista possível os processos físicos e dinâmicos da atmosfera (KALNAY, 2002). Entretanto, mesmo com todos os avanços realizados ao longo de décadas para melhorar a descrição da atmosfera nos modelos numéricos, estas ferramentas ainda são representações simplificadas do que realmente ocorre no sistema terrestre como um todo (interação da atmosfera com os oceanos, a criosfera, a superfície continental e os processos biogeoquímicos). A atual geração de modelos numéricos de tempo e clima tem apresentado considerável avanço em diversas características, como por exemplo, no aumento da resolução espacial, na melhor representação de processos físicos a partir de parametrizações, e no acoplamento da atmosfera com outras componentes do sistema terrestre (EYRING et al., 2019).

Simular o comportamento médio da atmosfera tem sido uma tarefa desafiadora, e muitos centros operacionais de meteorologia associados ao desenvolvimento dos modelos avançaram consideravelmente para tornar possível o sucesso nessa tarefa (DUDHIA, 2014). Os modelos atmosféricos adequados para PNT dependem dos conhecimentos adquiridos e compartilhados pelos centros de meteorologia do mundo, pois consistem de vários componentes distintos e suas interações, sendo cada um com suas próprias particularidades científicas (DUDHIA, 2014).

Vários esforços têm sido realizados para aumentar a complexidade dos modelos numéricos, visando a melhor representação da atmosfera e o ganho na qualidade das PNT. Como exemplos pode-se citar os trabalhos de Moreira (2013) e Moreira et al. (2013) que a partir do acoplamento de um modelo de superfície mais complexo contribuiu para a melhoria do desempenho do modelo *Brazilian Developments on the Regional Atmospheric Modeling System* (BRAMS). Balsamo et al. (2017) apontaram os benefícios de acoplar os componentes de modelagem oceânica e terrestre

ao modelo atmosférico do *European Centre for Medium-Range Weather Forecasts* (ECMWF), destacando principalmente a melhoria na representação da variabilidade do ciclo diurno e dos padrões sinóticos do Sistema Integrado de Previsão (do inglês *Integrated Forecast System* - IFS) do ECMWF. Do mesmo modo, o desenvolvimento de modelos atmosféricos que incluem a química atmosférica com o objetivo de melhor representar os processos radiativos e a formação de nuvens e precipitação tem evoluído rapidamente nos anos recentes (BAKLANOV et al., 2017). Estes modelos acoplados permitem a retroalimentação do estado atmosférico com as perturbações na composição da atmosfera devido à presença de poluentes atmosféricos a cada passo de tempo do modelo (FREITAS et al., 2009).

A emissão para a atmosfera de maiores quantidades de compostos gerados pelas ações humanas leva a uma alteração da química da atmosfera, que consequentemente altera os padrões de circulação (PÖSCHL, 2005; SEINFELD; PANDIS, 2006; RIESE et al., 2012; OBERLÄNDER-HAYN et al., 2016). Estas alterações são representadas nos modelos que consideram a química atmosférica como parte integrante das equações que governam a atmosfera. De fato, diversos estudos têm identificado que a composição da atmosfera exerce um papel fundamental na qualidade das previsões em diversas escalas de tempo (TOMPKINS et al., 2005; REALE et al., 2011). Em vista disso, a integração da componente meteorológica com modelos de química atmosférica passou a ser incorporada na rotina operacional de centros de meteorologia em todo o mundo. Os trabalhos pioneiros de Freitas (1999), Longo et al. (1999), Freitas et al. (2005a) colocaram o Brasil no protagonismo no cenário internacional em termos de modelagem de previsão de tempo integrada com a modelagem da qualidade do ar (também chamada de modelagem ambiental e a partir de agora denominada previsão integrada com química). A implementação operacional do modelo de área limitada BRAMS para previsão de tempo e qualidade do ar no Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE) em 2003 contribuiu para que outros centros de meteorologia do mundo, a exemplo do ECMWF (BENEDETTI et al., 2008; FLEMMING et al., 2009) também implementassem operacionalmente um modelo de previsão de tempo que integra a meteorologia e a química, fazendo uso de desenvolvimentos brasileiros como o modelo de levantamento de plumas de fumaça (FREITAS et al., 2006).

O bom desempenho das previsões de qualidade do ar também está intimamente relacionada à representação das fontes de emissões, além da qualidade do modelo numérico. Os trabalhos de Freitas et al. (2011), Frassoni et al. (2018) apresentaram os esforços para melhor representar e validar as emissões de diversas fontes sobre

a América do Sul (AS). Destacam-se as queimadas como principais fontes de emissão de gases traços e aerossóis, que injetam mais de 630 Tg/ano destes compostos na atmosfera globalmente (FINLAYSON-PITTS; PITTS-JUNIOR, 2000). No Brasil, as maiores concentrações de poluentes devido às queimadas ocorrem durante os meses de julho a setembro, principalmente em regiões de florestas tropicais e cerrados, e a principal é causada pela atividade humana, devido ao uso do solo, agricultura, dentre outras atividades (ARTAXO et al., 2006). Também é nesse período que são observadas altas temperaturas sobre a região central do Brasil devido às características climatológicas da região serem predominantemente de alta incidência de radiação solar e ausência de nebulosidade (ARTAXO et al., 2006).

Segundo Freitas et al. (2005a), há um pico de concentração de aerossóis e gases traços próximo à superfície na região tropical do Brasil durante este período. Entretanto, os problemas com a poluição do ar não se restringem às fontes de queimadas. Nos grandes aglomerados urbanos também se observa uma interação importante entre a emissão de poluentes e a meteorologia (ALONSO, 2011; SILVA, 2016). Silva (2016) analisou a intensidade de ilhas de calor urbanas formadas na região Metropolitana de São Paulo, e identificou com métodos da análise observacional e modelagem que em média, a concentração dos poluentes aumenta com o aumento da intensidade das ilhas de calor <sup>1</sup>. Altas temperaturas aliadas a altas concentrações de poluentes próximo à superfície especialmente nos meses mais quentes do ano são ingredientes favoráveis para a ocorrência de problemas de saúde principalmente nas populações mais vulneráveis.

Popularmente, tem-se a precipitação como a variável meteorológica mais importante na previsão de tempo devido a sua alta variabilidade espacial e temporal e por trazer transtornos à sociedade por meio de enchentes, secas, deslizamentos de terra etc. Entretanto, a previsão da temperatura do ar, principalmente em regiões que sofrem com grandes amplitudes térmicas, é também de fundamental importância. Bitencourt et al. (2016) utilizaram dados de Temperatura Máxima do Ar ( $T_{max}$ ) diária da série histórica (1961-2014) de 265 estações meteorológicas do Instituto Nacional de Meteorologia (INMET), separadas em três áreas do Brasil para identificar episódios de ondas de calor. Os autores selecionaram aqueles episódios com duração de pelo menos três dias, que no mínimo a metade das observações na área considerada apresentassem  $T_{max}$  superiores à média mais um desvio padrão. Esta identificação apontou um grande número de casos, sendo que a maioria ocorreu durante a prima-

---

<sup>1</sup>A principal característica de uma ilha de calor urbana é o aumento da temperatura do ar em áreas urbanas em relação às áreas periféricas e rurais (OKE, 1987)

vera e verão.

O calor intenso aumenta o risco de problemas cardiovasculares, e estão relacionados a um crescimento do número de óbitos (CHENG; SU, 2010; SILVEIRA et al., 2019). Hajat et al. (2006) encontraram uma associação acentuada entre temperaturas altas devido à ocorrência de ondas de calor e a mortalidade de pessoas por problemas respiratórios e cardiovasculares. Além das mortes causadas por ondas de calor, as altas temperaturas prolongadas também prejudicam a agricultura e pecuária. No setor elétrico, a  $T_{max}$  é um dos parâmetros atmosféricos mais importantes que afeta a quantidade de consumo de energia pela população. Estes problemas podem se tornar recorrentes no Brasil, pois as ondas de calor estão cada vez mais frequentes no país (BITENCOURT et al., 2016).

Considerando que a  $T_{max}$  é uma variável importante para identificação de ondas de calor (BITENCOURT et al., 2016), deve-se também considerar a relevância da previsão numérica da  $T_{max}$  para diferentes setores da sociedade. Desta forma, torna-se importante entender como os modelos numéricos representam essa variável atmosférica e identificar quais os erros sistemáticos mais comuns observados nas previsões de  $T_{max}$ . Previsões de maior qualidade em centros de previsão de tempo são de suma importância para que sejam disponibilizados à sociedade ferramentas que contribuam para políticas públicas de mitigação e alertas a serem emitidos para a população quando da ocorrência de eventos severos que podem induzir problemas para a sociedade. Devido às simplificações impostas no desenvolvimento bem como na operacionalização de modelos de PNT, principalmente devido às restrições de recursos computacionais, observam-se erros sistemáticos provenientes de diversas componentes dos modelos. Por exemplo, os resultados de modelos de PNT sem a inclusão de determinados tipos de aerossóis e/ou da química atmosférica no balanço radiativo e consequentemente na temperatura do ar podem divergir do estado real atmosférico (ZHANG et al., 2016).

Recentes esforços no sentido de avaliar os modelos de previsão numérica levam à identificação de importantes diferenças entre modelos e a erros comuns entre estes, que podem estar associados às incertezas nos dados de referência utilizados nas avaliações, à variabilidade interna ou aos erros associados à representação de processos físicos nos modelos (ZADRA et al., 2018). Com a maior complexidade dos modelos numéricos, aliado ao aumento do conjunto de saídas que os mesmos produzem, a multiplicidade de aplicações e a crescente disponibilidade de conjuntos de dados observacionais, há a necessidade de definições de metodologias robustas e sistemáticas

para avaliação de modelos (EYRING et al., 2019). O Sistema Comunitário de Avaliação de previsões Numérica de Tempo e Clima (SCANTEC) é uma iniciativa do CPTEC para contribuir nesse tema, o qual visa criar um ambiente de intercomparação de modelos, computacionalmente eficiente e flexível para receber novas implementações, inclusão de novos modelos e métricas estatísticas (MATTOS; SAPUCCI, 2017). Dentre as métricas nele implementadas encontra-se o *Method For Object-Based Diagnostic Evaluation* (MODE), que embora dedicado para a avaliação orientada a objeto das previsões de precipitação, apresenta o potencial para a avaliação espacial de outras variáveis atmosféricas.

A avaliação orientada a objeto aplicado para o caso das  $T_{max}$  e identificação de ondas de calor em sistemas de modelagem que incluem não somente a componente atmosférica, mas também a química, é uma promissora frente de investigação. Fontes de emissões antrópicas estão, em geral, espacialmente distribuídas em regiões preferenciais (por exemplo, megacidades e o arco de desflorestamento da Amazônia). O efeito local da concentração de material emitido por estas fontes sobre determinados padrões meteorológicos é considerável. São esperados efeitos mais proeminentes sobre o comportamento da temperatura, por exemplo, e conseqüentemente sobre a ocorrência de ondas de calor, nas regiões onde há uma maior concentração de poluentes.

Nas regiões fontes, espera-se portanto, que haja maior concentração e conseqüentemente maiores efeitos espaciais sobre os campos de temperatura. Neste caso, métodos de avaliação espacial podem ter uma maior contribuição para a identificação de erros sistemáticos em modelos ambientais do que métricas tradicionais. Assim, a presente proposta apresenta como hipótese a seguinte afirmação: **a metodologia orientada a objeto é uma ferramenta eficaz para a avaliação espacial das previsões de episódios de ondas de calor sobre a AS**. Visando comprovar essa hipótese e demonstrar a eficiência da técnica, ela é aqui aplicada na avaliação do impacto da inclusão da componente química atmosférica na qualidade das previsões de  $T_{max}$  e em eventos de ondas de calor previstas pelo modelo atmosférico BRAMS, baseando-se em estudos de casos.

## 1.1 Objetivos

O objetivo geral do presente trabalho é diagnosticar os erros dos valores de  $T_{max}$  em episódios de ondas de calor provenientes da PNT em uma avaliação espacial orientada a objetos utilizando o MODE do SCANTEC. A eficácia dessa técnica deverá ser demonstrada, e para isso as previsões do modelo BRAMS com a inclusão

da química atmosférica serão comparadas com um experimento realizado sem a inclusão dessa, e assim avaliar a influência da química na previsão das ondas de calor na escala de tempo.

Para realização desta pesquisa são propostos os seguintes objetivos específicos:

- Investigar uma metodologia que permita a adaptação do código MODE que se encontra dentro do SCANTEC do CPTEC/INPE para avaliação espacial orientada a objeto da  $T_{max}$ ;
- Identificar episódios de ondas de calor, fazendo uso de dados da reanálise do ERA5 do ECMWF no período disponível de 1979 a 2018, que subsidiem a avaliação da PNT;
- Demonstrar a eficácia da técnica orientada a objeto para a avaliação espacial de eventos de ondas de calor previstos por modelos de PNT, evidenciando os benefícios obtidos com essa metodologia.
- Avaliar objetivamente, por meio da técnica MODE, a contribuição da componente química no desempenho do modelo atmosférico em prever as  $T_{max}$  e ondas de calor sobre a AS, utilizando como referência as análises dos modelos e reanálise do ERA5.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo será abordado uma visão geral sobre avaliações de modelos de Previsão Numérica de Tempo e Clima (PNTC), a importância de utilizar métricas padronizadas para avaliação das previsões e os tipos de métricas utilizadas na avaliação da previsão de temperatura do ar (Seção 2.1). Na Seção 2.2 será discutida uma visão geral sobre aerossóis atmosféricos, seu papel nos padrões de temperatura próximo à superfície e como eles impactam a previsibilidade da atmosfera nas escalas de tempo e clima. Também será abordado a inclusão dos aerossóis no contexto da evolução no desenvolvimento dos modelos numéricos. Por último, será abordado na Seção 2.3 a definição de ondas de calor, sua ocorrência principalmente na AS e suas relações com padrões de variabilidade climática.

### 2.1 Avaliação de modelos

O princípio de avaliação dos modelos de PNTC é a comparação subjetiva ou objetiva das previsões conflitadas com observações, seja por medições *in situ* ou remotas, fornecendo a qualidade das previsões na representação de vários processos físicos e dinâmicos (EYRING et al., 2019). A análise subjetiva de modelos se dá por meio da comparação visual de dois campos (previsão *versus* observado) com o intuito de verificar regiões com superestimativa ou subestimativa. Apesar de ser um método simples e rápido que é comumente utilizado na comunidade meteorológica, requer um certo tipo de cuidado e experiência da parte do especialista, pois a tomada de decisão pode diferir de pessoa para pessoa (DOLIF et al., 2013). Logo, a análise objetiva é primordial para a convergência e quantificação dos resultados finais, sendo realizada por diferentes tipos de métricas estatísticas frequentemente utilizadas para avaliação de modelos, como o Viés, Raiz do Erro Quadrático Médio (REQM), Erro Médio Absoluto, Coeficiente de Correlação de Anomalia, além da aplicação de testes de confiança e significância estatística nos dados (WILKS, 2011).

Ao longo dos anos, os modelos se tornaram cada vez mais complexos com a inclusão de novas parametrizações físicas e com a redução do espaçamento de grade. Juntamente com essa evolução, novas ferramentas de avaliação de modelos vêm surgindo. Por exemplo, o *Continuous Ranked Probability Score* (CRPS) foi utilizado por Hersbach (2000) para avaliar as previsões por *Ensemble*<sup>2</sup>. A utilização de diferentes métricas pode acarretar na divergência entre os dados observados *versus*

---

<sup>2</sup>É definida como sendo um conjunto de previsões a partir de um conjunto de análises obtido ao aplicar diferentes perturbações positivas e negativas em um estado inicial, tendo como objetivo aumentar a confiabilidade da previsão (KASAHARA; KANAMITSU, 2003).

modelados. Por exemplo, alguns empecilhos na avaliação são postos quando há uma defasagem temporal entre a previsão e a observação. Logo, há uma necessidade de padronização das métricas utilizadas para avaliação das previsões. Novas métricas como o *Earth System Model Evaluation Tool* - ESMValTool (EYRING, 2016) e *Coordinated set of Model Evaluation Capabilities* - CMEC (GLECKLER et al., 2016) são discutidas em Eyring et al. (2019) como novas ferramentas padronizadas para avaliação dos modelos do projeto *Coupled Model Intercomparison Project* (CMIP), ajudando a identificar as causas que geram os erros sistemáticos nos modelos. Além disso, existem técnicas mais robustas realizadas por meio da orientação a objeto. Esta metodologia é a mais próxima da “realidade”, cuja resposta imita a capacidade humana de analisar e distinguir características entre os campos de dados observados e previstos. Além de identificar melhor os erros sistemáticos das previsões por levar em consideração não só a diferença entre os valores previstos e observados, mas os padrões espaciais dos objetos avaliados.

### 2.1.1 Métodos robustos de avaliação de modelos: avaliação orientada a objeto

A orientação a objeto foi recentemente introduzida na avaliação de modelos de PNTC. Apesar de ser uma metodologia antiga utilizada na comunidade científica, em especial nas pesquisas com geoprocessamento, poucos são os trabalhos que utilizam esse tipo de técnica na meteorologia. Os métodos orientados a objetos mais aplicados para avaliação de modelos são apresentados a seguir. *Contiguous Rain Areas* - CRA, primeiramente proposto por Ebert e McBride (1998), Ebert e McBride (2000) para avaliar a precipitação, permite estimar os erros de localização, padrão e volume de chuva. Além disso, o CRA possibilita avaliar as previsões sobre áreas pequenas. Um exemplo disso é o estudo de Tartaglione et al. (2005) que avaliou a previsão da precipitação sobre a ilha de Cyprus. Outra técnica aplicada para avaliação de modelos é o *Composite-Based* que analisa os campos de previsões de precipitação em relação à distribuição do campo de precipitação observado separadamente, onde as qualidades das previsões são medidas em termos de similaridade. Segundo Nachamkin (2009), essa técnica tem mais sensibilidade em identificar erros de deslocamento da previsão.

Marzban e Sandgathe (2006) introduziu a análise de *cluster* como uma técnica de orientação a objeto para avaliar a previsão da precipitação, combinando o campo previsto com o observado em conjunto, onde o tamanho dos *clusters* é determinado pelo número de pontos de grade. Esta técnica é definida como uma análise de

agrupamento de objetos similares por meio de um conjunto de dados. A aplicação fornece cálculos de falsos alarmes, acertos e erros, além do *Critical Success Index* (CSI) (MARZBAN; SANDGATHE, 2008). Essa metodologia foi aplicada por ARAÚJO et al. (2019) para avaliar os campos de precipitação e temperatura previstos no período do outono austral sobre o Nordeste Brasileiro, com diferencial na escolha do número de *clustes* por meio do índice *silhouette*. A técnica SAL (do inglês *Structure, Amplitude, Location*) proposta por Wernli et al. (2008) define a estrutura, amplitude e localização dos campos de precipitação da observação e previsão separadamente em um determinado domínio, sendo melhor para avaliação de eventos intensos de precipitação, fornecendo as qualidades e erros específicos da previsão (WERNLI et al., 2009).

Outro método orientado a objeto introduzido no *National Center for Atmospheric Research* (NCAR) (DAVIS et al., 2006a; DAVIS et al., 2006b) e denominado de MODE (DAVIS et al., 2009) foi desenvolvido com intuito de avaliar as previsões de regiões com precipitação nos modelos de PNTC. Todavia, esta métrica também serve para analisar quaisquer variáveis previstas em um modelo numérico, desde que cada variável seja atribuída de forma correta para identificação dos objetos (DAVIS et al., 2006b). O MODE tem como objetivo identificar e comparar objetos de interesse de dois conjuntos de dados espacialmente, por meio de ferramentas estatísticas para averiguar as semelhanças e/ou diferenças entre os objetos (DAVIS et al., 2009).

Segundo Gilleland et al. (2009) que avaliou todas as técnicas apresentadas acima, o MODE é a técnica orientada a objeto mais completa, pois fornece informações essenciais sobre escala, erros de localização, intensidade e estrutura, além do número de sucessos, falhas, falsos alarmes e rejeições corretas. Isso se deve ao aprimoramento do método ao longo dos anos, tornando-o mais relevante em relação às métricas comuns de avaliação. No MODE, são atribuídas as características como localização, forma, orientação e tamanho para identificação dos objetos dos campos de previsão e observação, onde os objetos identificados são tratados em formas geométricas (DAVIS et al., 2006a). Para a identificação dos objetos, aplica-se um filtro nos campos originais (previsão e observação), criando um novo campo binário chamado de convolução. A partir desse campo, emprega-se um limiar de intensidade para eliminar valores pequenos, por exemplo, formando uma máscara binária no campo. Essa máscara é aplicada novamente sobre o campo original, apresentando apenas os valores de intensidade em volta de valores zero. Com a identificação dos objetos, as propriedades dos objetos são calculadas, como Área, Perímetro, Centróide, Complexidade e Razão de Aspecto para identificação dos objetos pareados (previstos *versus* observados), e

medição do grau de similaridade por meio da diferenciação dos atributos de objetos pares. Por último, a avaliação por lógica difusa *matching* e *merging* implementada por Davis et al. (2009), calcula a função de interesse total para cada par de objeto, indicando a alta probabilidade de correspondência ou não entre os pares. Ressalta-se que vários outros estudos utilizaram o MODE para avaliação de previsões como cobertura de nuvens (MITTERMAIER; BULLOCK, 2013; CARRASCO et al., 2014; GRIFFIN et al., 2017) e precipitação (CARRASCO, 2017). Além de implementarem esta ferramenta em centros de previsão numérica, como no Instituto de Meteorologia de Cuba (LORENZO et al., 2016) e no CPTEC/INPE do Brasil (CARRASCO, 2017).

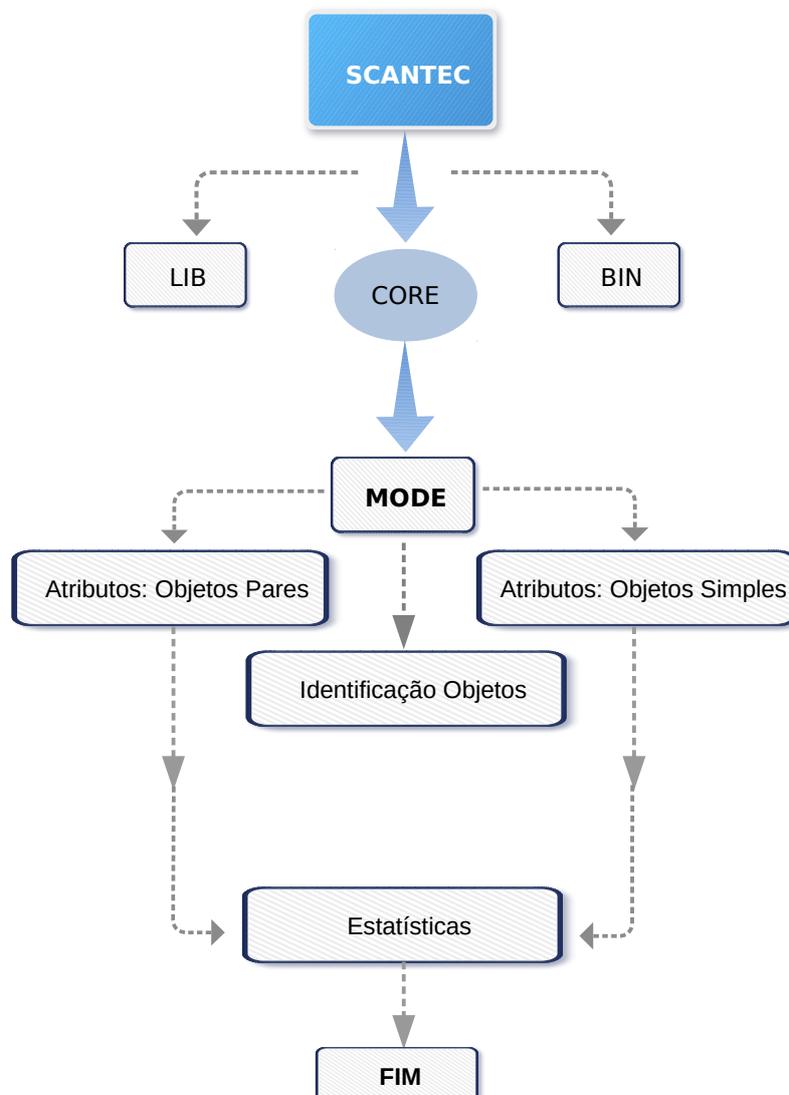
Visando contribuir nesse assunto, a Divisão de Modelagem e Desenvolvimento (DIDMD) do CPTEC/INPE desenvolveu uma ferramenta denominada SCANTEC com o objetivo principal de disponibilizar um sistema de avaliação de modelos de PNTC com as características descritas acima (MATTOS; SAPUCCI, 2017). Esse sistema está apto para avaliar todos os modelos utilizados no centro, o que é feito por meio do desenvolvimento de *plugins* específicos para cada uma das versões desses modelos. Além disso, diversas métricas de avaliação têm sido incorporadas ao longo dos anos no SCANTEC.

O SCANTEC é um programa computacional desenvolvido em linguagens C e FORTRAN, que possibilita a realização de cálculos estatísticos padronizados para avaliação de modelos numéricos de tempo e clima (MATTOS; SAPUCCI, 2017). Esta ferramenta proporciona a avaliação simultânea de vários modelos com diferentes resoluções espaciais, comparando-os de forma eficiente, devido à padronização da grade e aplicação dos cálculos de forma padronizada, o que contribui positivamente na determinação das deficiências e conseqüentemente no aprimoramento dos modelos de previsão numérica. O software SCANTEC é constituído por um núcleo central que interliga três principais módulos: o de leitura dos dados dos modelos; métricas estatísticas; e disponibilidade dos resultados. O software dispõe da leitura de dados binários em formatos HDF4, NetCDF e GRIB1, sendo este último utilizado globalmente no armazenamento de dados meteorológicos (SAPUCCI et al., 2011).

O módulo de leitura dos dados dos modelos já está apto para receber os dados dos modelos ambientais a serem utilizados nessa pesquisa. O módulo de métricas estatísticas é composto de outros sub-módulos. Há um específico para os cálculos estatísticos básicos como o Viés, REQM, Erro Médio Absoluto e o Coeficiente de Correlação de Anomalia, bem como está apto a receber novos módulos e/ou metodologias (SAPUCCI et al., 2011). Em um outro sub-módulo, foram implementadas

diversas métricas destinadas para a avaliação de precipitação, como histograma de frequência, *Empirical Orthogonal Functions* (EOF) e tabela de contingência. Dentro desse sub-módulo, também com a finalidade de avaliar a precipitação, foi implementado o método orientado a objeto MODE (CARRASCO, 2017). Este método foi implementado dentro do núcleo do SCANTEC em quatro módulos (ver esquema na Figura 2.1), os quais foram ajustados para avaliar a previsão da precipitação de diferentes modelos de PNTC [para mais detalhes da implementação ver Carrasco (2017)].

Figura 2.1 - Esquema simplificado da estrutura principal do SCANTEC com os respectivos módulos do MODE dentro do *core* do *software*.



Fonte: Produção da autora.

O MODE é executado em quatro etapas dentro do SCANTEC, a saber:

- a) **Identificação dos objetos:** Nesta etapa são definidos os campos de convolução e limiarização para a identificação dos objetos da variável de interesse dos campos de previsão e observação. A convolução é aplicada no campo de dados brutos de objetos, ou seja, em variáveis discretas como chuva e nuvens para suavização dos campos no espaço, juntamente com a aplicação de um limiar de intensidade para identificar áreas de interesse do usuário (CARRASCO, 2017).
- b) **Cálculo dos atributos dos objetos:** nela são realizados os cálculos da geometria dos objetos identificados na etapa anterior, tais como Área, Perímetro, Centroide, Ângulo de Orientação, Razão de Aspecto e o grau de Complexidade.
- c) **Cálculo dos atributos dos objetos pares:** Em seguida é comparado o grau de semelhança de todos os possíveis pares de objetos (observados e previstos) por meio das diferenciações e razões das mesmas características citadas na etapa anterior. Como resultado dessa etapa, obtém-se um agrupamento dos pares mais prováveis de objetos correspondentes nos campos.
- d) **Lógica difusa:** Nesta última etapa é calculada a função de Interesse Total (IT) para cada par de objeto ( $i$ ), que varia de 0 a 1, em que os valores próximos à 1 indicam alta probabilidade de correspondência entre os objetos observados e previstos (DAVIS et al., 2009), sendo expressa por:

$$IT(\ell) = \frac{\sum_i W_i C_i(\ell) IP_i(\ell_i)}{\sum_i W_i C_i(\ell)}, \quad (2.1)$$

em que  $\ell$  são relacionados aos atributos dos objetos identificados;  $C_i$  é a função de confiança dada na comparação das diferenças e razões dos atributos de objetos pareados;  $IP_i$  é o interesse parcial dos atributos baseados também nas diferenças e razões dos objetos correspondentes (previstos e observados); e  $W_i$  são os pesos atribuídos para os pares de objetos, com maior peso na Distância Mínima entre as Bordas dos objetos, Diferença de Centroide e Razão da Área de Intersecção, e menor peso na Diferença de Ângulo de Orientação e Razão das Áreas. Após o cálculo do IT, um limiar de 0,7 é aplicado para definir o pareamento entre os objetos, ou seja, caso os objetos pareados apresentarem um IT acima desse limite serão correspondidos, ao contrário, os objetos não serão correspondidos. Este limiar é

utilizado como padrão no *Model Evaluation Tools Version 5.2* (METv5.2) e no MODE/SCANTEC, pois ao aumentar o valor, o número de objetos correspondidos será menor, e ao diminuir, aumentará o número de objetos pareados (BROWN et al., 2014).

Por meio das etapas descritas acima, principalmente após a identificação dos objetos pareados na lógica difusa, o MODE gera uma tabela de contingência (WILKS, 2011) de acordo com a Tabela 2.1, levando em consideração o número total de objetos detectados. Dado o total de objetos pareados identificados (previstos e observados) que correspondem ao número de sucessos ( $a = N_{\text{pares}}$ ); o total de objetos previstos, mas não correspondentes ao total de objetos observados que indicam o número de falsos alarmes ( $b = N_{\text{previstos}} - N_{\text{pares}}$ ); e o total de objetos observados que não foram previstos, este último corresponde ao número de falhas ( $c = N_{\text{observados}} - N_{\text{pares}}$ ). E o “d” na Tabela 2.1 é desconsiderado, pois não há contabilização de objetos não previstos, como também os não observados (CARRASCO, 2017).

Tabela 2.1 - Tabela de Contingência.

	Observado		
	Sim	Não	
Previsto	Sim	<b>a</b>	<b>b</b>
	Não	<b>c</b>	<b>d</b>

Fonte: Wilks (2011).

Feita a contingência dos objetos, o MODE calcula os seguintes índices por meio da Tabela 2.1, segundo Wilks (2011):

- a) ***Probability of Detection (POD)***: também conhecido como *Hit Rate*, este índice mostra o desempenho de detecção do evento de interesse. A POD é a taxa de acertos dada pelas ocasiões em que ocorreu a previsão corretamente. É calculada da seguinte forma:

$$POD = \frac{a}{a + c}. \quad (2.2)$$

A POD varia entre 0 e 1, indicando que quanto mais próximo de 1, as previsões são perfeitas, sendo sensível ao número de sucessos. Quando a POD é igual à 0 significa que as previsões são totalmente errôneas, ou seja,

na orientação a objeto nenhum par é correspondido entre o observado e o previsto.

- b) **CSI:** também chamado de *Threat Score*, é dado pela razão entre o total previsto corretamente e o total em que o evento foi previsto e/ou observado. Este índice pode ser descrito como uma medida de proporção de acertos da previsão. O CSI é expresso por

$$\text{CSI} = \frac{a}{a + b + c}. \quad (2.3)$$

O CSI varia de 0 a 1, e quanto mais próximo da unidade, melhor é a previsão. Do contrário, ou seja, CSI próximo à zero, o número de falsos alarmes e falhas no modelo de PNTC são maiores.

- c) **Bias:** É a razão entre o previsto (“sim”) e o observado (“sim”). Tendo em vista que o Bias não é uma medida de precisão. Ele fornece apenas o quanto o modelo subestima ( $B < 1$ ) ou superestima ( $B > 1$ ) a observação. É calculado como:

$$\text{Bias} = \frac{a + b}{a + c}. \quad (2.4)$$

Ressalta-se que quando o Bias é igual a 1, tem-se uma previsão perfeita, ou seja, o mesmo número de eventos previstos é igual ao número de eventos observados.

- d) **False Alarm Ratio (FAR):** é a taxa de falsos alarmes, sendo dado pela fração das previsões erradas, ou seja, a proporção de número de eventos previstos que não foram observados. O FAR é obtido pela seguinte equação:

$$\text{FAR} = \frac{b}{a + b}. \quad (2.5)$$

O FAR varia entre 0 e 1, mas tem uma orientação negativa aos demais índices já descritos nessa seção. Quanto mais próximo de 1 o valor de FAR, pior é a previsão do evento. Já os valores menores que 1 são preferidos, pois indicam melhor qualidade da previsão em relação aos falsos alarmes.

- e) **Gilbert Skill Score (GSS):** é dito como a razão de sucessos, também denominada de *Equitable Threat Score*. Sendo semelhante ao índice CSI, este também calcula a razão em que o número de casos previstos corresponde ao de observados, descartando as rejeições corretas como na equação 2.3,

além de levar em consideração a probabilidade de um evento previsto corretamente ocorrer por acaso ( $a_{ref}$ ). O GSS é calculado da seguinte forma:

$$GSS = \frac{a - a_{ref}}{a - a_{ref} + b + c}, \quad (2.6)$$

sendo,

$$a_{ref} = \frac{(a + b)(a + c)}{n}. \quad (2.7)$$

O GSS segue o mesmo padrão dos demais índices descritos anteriormente, com exceção do FAR, em que valores próximos de 1 indicam uma boa previsão.

Além dos índices mostrados anteriormente, têm-se a métrica MMI (Média do Máximo Interesse), sendo utilizada também para comparar as previsões de diferentes modelos. É expressa por:

$$MMI = \frac{MIP + MIO}{2}, \quad (2.8)$$

em que MIP (Máximo Interesse Previsto) e MIO (Máximo Interesse Observado) correspondem ao valor máximo de interesse de cada linha (objetos previstos *versus* observados) e coluna (objetos observados *versus* previstos) da matriz de interesse (Tabela 2.2), respectivamente. Esta métrica calcula o IT entre todos os objetos dos campos observado e previsto, sem levar em consideração o limiar de 0,7, sendo sensível aos falsos alarmes e falhas.

Tabela 2.2 - Cálculo hipotético da matriz de interesse entre 3 objetos previstos e 2 objetos observados.

<b>Previstos</b>	<b>Observados</b>	
	1	2
1	0,9	0,7
2	0,5	0,8
3	0,4	0,5

Fonte: Davis et al. (2009), Carrasco (2017).

### 2.1.2 Avaliação de previsões de temperatura do ar

A avaliação de produtos de previsão numérica utilizando métricas estatísticas simples para variáveis meteorológicas ainda predomina na comunidade científica, o que pode resultar em análises inconsistentes na definição da qualidade das previsões (GILLELAND et al., 2009; EYRING et al., 2019). Vários estudos utilizam análises subjetivas e/ou objetivas simples e sem padronização para avaliar a qualidade das previsões de diversas variáveis, inclusive da temperatura do ar. Por exemplo, Zhang et al. (2016) utilizou análises subjetivas e objetivas, como relação de dispersão, Viés e REQM para avaliar o impacto de partículas de aerossóis provenientes de queima de biomassa nas previsões da temperatura do ar a 2 metros próximo à superfície. Diferente do estudo anterior, Nageswararao et al. (2016) além de utilizarem as métricas citadas anteriormente, avaliaram a climatologia das previsões do modelo *Climate Forecast System* (CFS), avaliando as temperaturas no inverno sobre a Índia por meio do coeficiente de correlação, índice de concordância, e POD. Já o trabalho de Ji et al. (2015) apresentou um diferencial com relação aos trabalhos anteriores que foi utilizar o modelo de eficiência Nash-Sutcliffe para avaliar a temperatura do ar proveniente do *Global Land Data Assimilation System* (GLDAS) em diferentes regiões do globo.

Apesar da temperatura do ar ser mais simples de prever em relação à chuva, há uma concordância entre os centros de meteorologia mundiais de que esta variável ainda precisa ser melhor representada pelos modelos. De acordo com uma pesquisa subjetiva realizada pelo Grupo de Experimentação Numérica da Organização Meteorológica Mundial, depois dos processos associados a nuvens e convecção, erros sistemáticos nos fluxos de superfície e ciclo diurno da temperatura na superfície são os mais recorrentes nos centros de meteorologia do mundo, e impactam diretamente as previsões de temperatura do ar próximo à superfície. Técnicas mais complexas e aprimoradas para identificação de erros sistemáticos como é o caso das metodologias orientadas a objeto como o MODE são de suma importância para diagnosticar a qualidade das previsões de temperatura do ar, em especial no que se refere aos padrões espaciais.

## 2.2 Visão geral sobre os aerossóis atmosféricos, seu papel nos padrões de temperatura próximo à superfície e impactos na previsibilidade da atmosfera

De acordo com a literatura, a estação de queimadas na AS está concentrada principalmente entre os meses de julho a outubro (SETZER; PEREIRA, 1991; FREITAS et al., 2005a; REDDINGTON et al., 2015). Sendo as queimadas uma das principais fon-

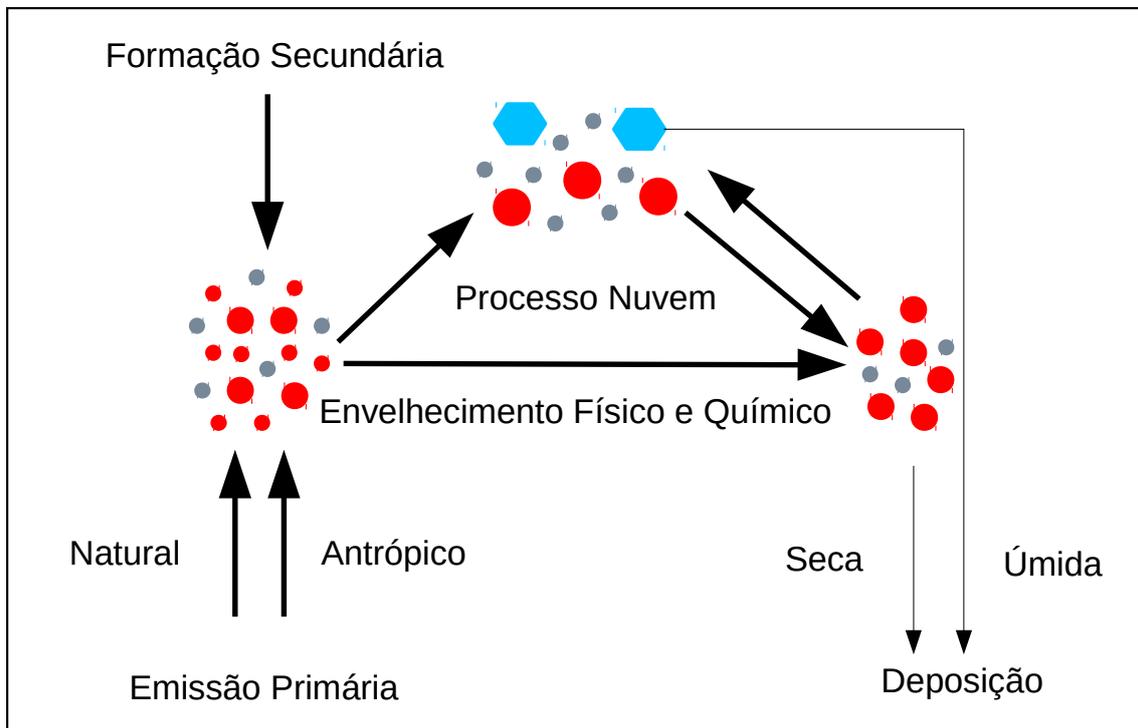
tes de aerossóis atmosféricos na AS, principalmente para o período a que se refere este estudo, dar-se-á maior ênfase a este constituinte atmosférico, embora tenha-se o conhecimento de que outros compostos, como os gases traços, exerçam um papel importante para os padrões atmosféricos.

O aerossol atmosférico pode ser definido como uma partícula sólida ou líquida suspensa na atmosfera, podendo existir diversos tipos, tamanhos, composição, além de possuir diferentes propriedades físicas e químicas (LEVY, 2009). Estas propriedades dependem da origem em que são gerados e dos processos de produção, seja estes de fontes antrópicas ou naturais. O tamanho das partículas de aerossóis varia de nanômetros a micrômetros, com valores típicos de diâmetro entre 0,001 a 10  $\mu\text{m}$ . Os aerossóis sólidos são amplamente conhecidos na comunidade científica por Material Particulado (do inglês *particulate matter* – PM), onde as partículas finas possuem um diâmetro inferior a 2,5  $\mu\text{m}$  (PM2.5), enquanto que as grossas possuem diâmetro inferior a 10  $\mu\text{m}$  (PM10). Geralmente, os particulados finos são provenientes da queima de biomassa ou carvão, e os grossos são oriundos de sal marinho e poeira do solo (FINLAYSON-PITTS; PITTS-JUNIOR, 2000; HAYWOOD; BOUCHER, 2000; SEINFELD; PANDIS, 2006; LEVY, 2009).

Os aerossóis são classificados em dois tipos na natureza, sendo estes denominados de primários e secundários. Os aerossóis primários são oriundos diretamente da fonte, seja pela queima de biomassa, combustão incompleta, erupções vulcânicas, poeira transportada pelo vento, solos e minerais, sal marinho, spray das ondas oceânicas, além dos materiais biológicos, como fragmentos de plantas, micro-organismos e pólen. No entanto, os aerossóis secundários são gerados na atmosfera por meio de reações químicas com partículas e gases, formando novas partículas por nucleação e condensação de precursores gasosos, como os Compostos Orgânicos Voláteis (sigla em inglês – VOCs), óxidos de nitrogênio ( $NO_x$ ), e dióxido de enxofre ( $SO_2$ ) (PÖSCHL, 2005). As partículas de aerossol se originam de uma determinada fonte, passam por vários processos físico-químicos e se extinguem por meio da deposição úmida e seca [ver esquema na Figura 2.2].

De acordo com Grey e North (2009), a deposição seca ocorre por meio da ação gravitacional e mistura turbulenta, onde as partículas com maior diâmetro estão mais sujeitas a este tipo de deposição. Enquanto que a deposição úmida ocorre por meio da precipitação (pluvial, granizo, neve etc.), sendo esta a principal forma de remoção de particulados na atmosfera. Geralmente, o tempo de residência dos aerossóis troposféricos é de dias a semanas. Consequentemente, partículas grossas, como o

Figura 2.2 - Representação do ciclo de vida dos aerossóis primários e secundários na atmosfera.



As setas correspondem aos *feedbacks* desde a sua origem, formação, interações com nuvens e tempo de vida na atmosfera. Os diferentes tipos e formas de aerossóis são representados pelas cores azul, vermelho, e cinza.

Fonte: Adaptado de Pöschl (2005).

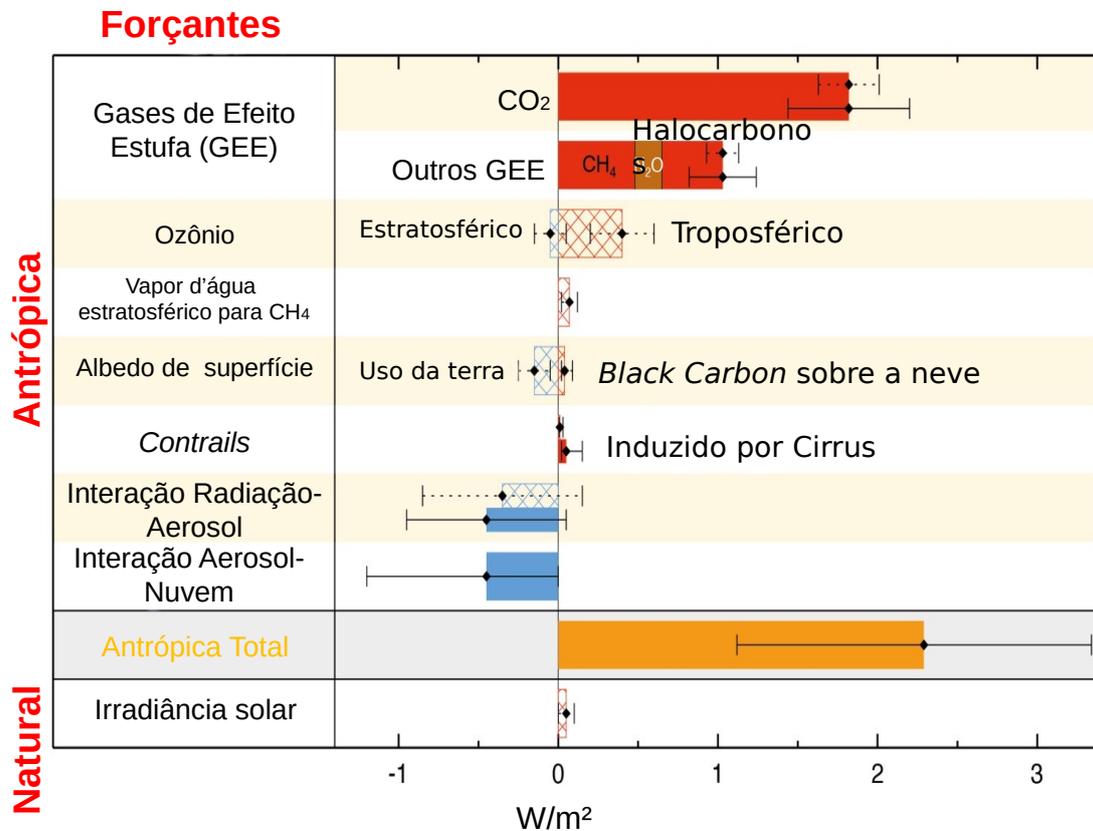
PM<sub>10</sub>, têm um tempo de vida menor, da ordem de horas a dias, em relação a outras partículas (SEINFELD; PANDIS, 2006; LEVY, 2009). Ressalta-se que a deposição seca pode ocasionar problemas em regiões com alta densidade demográfica que emitem grandes quantidades de poluição para a atmosfera. Pode-se ocorrer o acúmulo de particulados em objetos e edificações, deixando-os com aspectos de sujeira (deposição seca). Já a deposição úmida pode provocar problemas como a chuva ácida causada se houver elevado teor de ácido sulfúrico, nítrico e nitroso. A ocorrência de chuva ácida pode provocar a acidificação em rios, lagos, solos, além de destruir a cobertura vegetal e corroer objetos (GRENNFELT et al., 1980; FORNARO, 2006; BRIMBLECOMBE et al., 2007; BRENA, 2009; CALLEGARO et al., 2015).

### 2.2.1 Efeitos direto e indireto dos aerossóis e seus impactos nas variações da temperatura do ar próximo à superfície

Além dos processos apresentados anteriormente, os aerossóis atmosféricos desempenham um papel importante na atmosfera por meio de diferentes mecanismos (RÉMY et al., 2015). Um desses mecanismos tem uma forte influência sobre o tempo e clima do planeta, principalmente na alteração do balanço radiativo por meio da absorção e espalhamento da radiação solar de onda curta e onda longa a partir do chamado efeito direto (YU et al., 2006; BELLOUIN et al., 2005; VALSARAJ; KOMMALAPATI, 2009; SUZUKI; TAKEMURA, 2019). Outro mecanismo, denominado de efeito indireto, afeta a concentração, o tamanho e a composição química dos Núcleos de Condensação das Nuvens (CCN), que por sua vez alteram o ciclo de vida, as propriedades ópticas e a atividade precipitante das nuvens (HAYWOOD; BOUCHER, 2000; ROSENFELD et al., 2008; CURIER et al., 2009; COSTANTINO; BRÉON, 2012; GÁCITA et al., 2017; ANDREAE et al., 2018; FAN et al., 2018; SATURNO et al., 2018).

Sabe-se que os aerossóis suspensos na atmosfera são provenientes de diversas fontes emissoras, sendo assim, algumas partículas, dependendo da sua composição e quantidade na atmosfera, podem apresentar maior poder de absorção ou de espalhamento da radiação solar (SEINFELD; PANDIS, 2006). A interação da radiação com as propriedades ópticas dos aerossóis irá impactar no resfriamento ou aquecimento da atmosfera, e conseqüentemente influenciará na mudança da temperatura da superfície terrestre. Essa mudança na temperatura média global em uma escala climatológica ocorre por meio da alteração do balanço energético líquido, não só por meio do efeito direto e indireto dos aerossóis, mas também pela influência de vários outros componentes atmosféricos e de superfície (forçantes), como gases de efeito estufa, gases traços, uso do solo que altera o albedo de superfície, *contrails* (“rastros” de partículas condensadas provenientes da passagem de aviões ou jatos) etc. Essas forçantes de fontes naturais e antrópicas podem ser negativas ou positivas, ou seja, resultam no resfriamento ou aquecimento do meio atmosférico e/ou superfície terrestre, respectivamente [ver Figura 2.3]. Este processo é denominado de forçante radiativa, sendo calculada desde o período pré-industrial até o presente, e medida em  $Wm^{-2}$  (MYHRE et al., 2013). De acordo com o quinto relatório do Painel Intergovernamental de Mudanças Climáticas (sigla em inglês - IPCC), a forçante também pode ser definida como uma mudança instantânea da irradiância solar no topo da atmosfera ou na tropopausa.

Figura 2.3 - Forçantes radiativa climática de fontes naturais e antrópicas (1750-2011) baseada no quinto relatório do IPCC.



Forçamento positivo (barras em vermelho) e negativo (barras em azul), e intervalos de incertezas (barras em preto). As barras preenchidas e quadriculadas representam a forçante radiativa e a efetiva, respectivamente.

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

Climatologicamente, os aerossóis têm uma forçante radiativa negativa predominante, ou seja, um efeito de resfriamento da temperatura média global do planeta, e uma pequena fração de aquecimento pelo *Black Carbon*. Isto ocorre pois a maioria dos particulados com maior tempo de vida suspensos na atmosfera dispersam a radiação solar, refletindo boa parte dos raios incidentes de volta para o espaço. Entretanto, alguns aerossóis como o *Black Carbon*, absorvem essa radiação (LIU, 2002; PETTY, 2006; GREY; NORTH, 2009; MYHRE et al., 2013). Dependendo da sua localização na atmosfera, o *Black Carbon* pode contribuir para o aquecimento do meio onde se encontra, levando a um forçamento positivo (SEINFELD; PANDIS, 2006). Por exemplo, quando a absorção da radiação na atmosfera ocorre principalmente em níveis

baixos, ou seja próximo à superfície, esta partícula pode contribuir com o forçamento positivo na superfície (SEINFELD; PANDIS, 2006). Além disso, a deposição desse particulado em superfícies de gelo e neve reduz a capacidade de espalhamento da radiação solar, e conseqüentemente aumenta a absorção, provocando o aquecimento, e posteriormente, o degelo dessas superfícies (RAMANATHAN; CARMICHAEL, 2008; YASUNARI et al., 2010; MYHRE et al., 2013; LEE et al., 2017).

O impacto local dos aerossóis na temperatura do ar próximo à superfície não depende apenas de suas propriedades ópticas, mas também de outros fatores como a altitude onde se encontra a camada de aerossóis (MITCHELL JUNIOR, 1971), que irá influenciar no aquecimento ou resfriamento da temperatura em um período curto de tempo. Um exemplo disso é o trabalho de Mass e Robock (1982). Este estudo foi um dos primeiros realizados para identificar os efeitos locais da pluma de erupção vulcânica sobre a temperatura de superfície em uma escala de tempo. Eles identificaram uma diminuição da temperatura de aproximadamente  $8^{\circ}\text{C}$  sobre as áreas atingidas pela poeira vulcânica durante o dia, e um aumento na temperatura também de aproximadamente  $8^{\circ}\text{C}$  durante a noite. Esta inversão na temperatura durante o dia ocorre devido à inibição da radiação de onda curta incidente na superfície por meio dos processos de absorção e espalhamento da radiação solar pelo PM do vulcão, superando a radiação infravermelha emitida pela nuvem de poeira. Já durante a noite, a concentração de PM do vulcão que se encontra na baixa troposfera, tem um efeito contrário, ou seja, ao longo da noite a radiação que foi absorvida durante o dia pela pluma vulcânica é emitida para a superfície, e aprisionada pela própria nuvem de poeira que serve como uma espécie de “estufa”, fazendo com que a temperatura próximo à superfície aumente (MASS; ROBOCK, 1982).

Diferente da poeira vulcânica, Robock (1991) verificou que a pluma de fumaça proveniente da queima de biomassa à princípio não apresenta efeitos radiativos na temperatura de superfície durante a noite. Porém, possui o mesmo mecanismo de resfriamento da superfície durante o dia. Robock (1991) identificou que regiões atingidas pela pluma de fumaça proveniente de incêndios florestais ocorridos em diversas partes do globo tiveram um efeito negativo sobre a temperatura do ar no decorrer do dia, com diferenças de até  $-7^{\circ}\text{C}$ . Além do efeito direto negativo das plumas, estudos mostram que a poeira e CCN também possuem um efeito de resfriamento da temperatura do ar próximo à superfície. Mallet et al. (2009) utilizaram simulações numéricas com um modelo de Mesoescala Não-Hidrostático (MesoNH) apenas com o efeito direto incluso, sem a dispersão da radiação por ondas longas. Perante a inserção na parametrização de radiação do índice de refração, e os diversos ta-

manhos de partículas provenientes de medições de radiômetros da *Aerosol Robotic Network* (AERONET) durante um evento de poeira intensa sobre o ocidente da África. Os autores identificaram uma redução na temperatura da superfície de até 4°C ao meio dia sobre a região, onde uma alta Profundidade Óptica de Aerossóis (do inglês *Aerosol Optical Depth* – AOD) <sup>3</sup> foi observada.

A interação entre a radiação-aerossóis-nuvens é a mais complexa, e possui uma maior incerteza (MYHRE et al., 2013), pois além do efeito radiativo, os aerossóis impactam no tempo de vida das nuvens e na precipitação. O aumento da concentração de aerossóis higroscópicos dentro da nuvem aumenta a concentração de CCN. A nuvem passa a ter um maior número de gotículas pequenas, o que gera um aumento no albedo da nuvem, e conseqüentemente, há uma diminuição da energia que chega na superfície (BOUCHER et al., 2013). O efeito contrário ocorre quando os CCN se tornam maiores. Scott et al. (2018) identificaram que a maior concentração de partículas de aerossóis e CCN acima de 100nm no verão é responsável pelas anomalias de temperaturas do ar mais quentes.

Ressalta-se que a pluma de fumaça proveniente da queima de biomassa sobre uma certa região tem um forçamento negativo, principalmente na superfície. Entretanto, na atmosfera há um forçamento positivo, onde se encontra a camada de aerossóis (PROCOPIO et al., 2004). A poeira também reduz a radiação que chega na superfície com uma média regional de  $-137 \text{ Wm}^{-2}$  (MALLET et al., 2009), como também a pluma de poeira vulcânica que tem um efeito de resfriamento da superfície (MASS; ROBOCK, 1982; ROBOCK, 2000; TIMMRECK, 2012; RAIBLE et al., 2016). Todas essas forçantes, além de impactar diretamente e indiretamente na temperatura do ar próximo a superfície, influenciam no balanço hidrológico, onde a diminuição da energia solar que chega na superfície altera o processo de evaporação, e conseqüentemente, altera os regimes de precipitação.

### 2.2.2 O papel dos aerossóis na previsibilidade da atmosfera

Há poucas décadas atrás se tinha o conhecimento de que aerossóis e gases de efeito estufa influenciavam a circulação atmosférica (PÖSCHL, 2005; SEINFELD; PANDIS, 2006; RIESE et al., 2012; OBERLÄNDER-HAYN et al., 2016). Medições em superfície e a partir de imagens de satélite da espessura óptica atmosférica remontam ao final

---

<sup>3</sup>É definida como uma medida da extinção (espalhamento e absorção) do raio solar por partículas de aerossóis contidas em toda coluna atmosférica. O AOD é adimensional, e refere-se ao quanto de luz solar direta é impedida de atingir a superfície terrestre pelas partículas (NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA, 2019b).

da década de 1970 (CARLSON; WENDLING, 1977), mas a possibilidade de unir dados de satélite com dados do *Moderate Resolution Imaging Spectroradiometer* (MODIS) ou do *Cloud-Aerosol lidar and Infrared Pathfinder Satellite Observation* possibilitou melhor compreender as propriedades ópticas dos aerossóis em anos mais recentes.

Menor importância foi dada ao papel da química atmosférica, em especial dos aerossóis, em modelos numéricos, devido ao seu curto período de tempo na atmosfera. No entanto, a discussão de vários cientistas no início do século XX estava voltada para entender qual dos gases de efeito estufa, como o vapor d'água e  $CO_2$ , afetavam mais a temperatura do planeta (EDWARDS, 2011). Por causa desta linha de pensamento, apenas os gases foram incluídos nos modelos climáticos por volta de 1970 (TREUT et al., 2007). Uma década depois, mais processos físicos foram incluídos dentro do modelo como a superfície terrestre, nuvens e gelo. Com o avanço do conhecimento nos processos físicos/dinâmicos da atmosfera e oceanos, os modelos foram cada vez mais aprimorados ao longo do tempo. Na década de 1990 foi acrescentado o oceano, e seis anos depois as atividades vulcânicas, o sulfato proveniente de indústrias, circulação superficial oceânica e gelo marinho (TREUT et al., 2007; EDWARDS, 2011). No início do século XXI foram incluídos alguns processos mais complexos como o ciclo de carbono, escoamento de superfície, circulação profunda nos oceanos, e aerossóis, e alguns anos depois foram acrescentados a interação da vegetação com a atmosfera e os processos químicos atmosféricos (TREUT et al., 2007; EDWARDS, 2011). A inclusão dos aerossóis dentro dos modelos de clima ocorreu devido ao aumento de pesquisas sobre os efeitos dos particulados na atmosfera, realizados nas últimas décadas (TREUT et al., 2007). Além dos modelos de clima, passou-se a dar atenção também à inclusão da química atmosférica e modelos de determinados tipos de aerossóis em alguns modelos regionais de previsão de tempo (GRELL et al., 2005; FREITAS et al., 2005a; LONGO et al., 2007; CHAPMAN et al., 2009; GRELL et al., 2011; LONGO et al., 2013; MULCAHY et al., 2014).

Diversos estudos mostram que a inclusão dos aerossóis em modelos atmosféricos globais e regionais, tanto para previsão do clima quanto para previsão de tempo melhoram substancialmente o Viés de algumas variáveis atmosféricas. Na literatura, há uma gama de estudos sobre a influência dos aerossóis e os seus impactos na previsão de clima e na previsão de curto prazo. A inclusão dos aerossóis de queimada no *Weather Research and Forecasting Model* (WRF) (GRELL et al., 2011) contribuiu para a redução dos erros da precipitação na previsão sobre o Alasca. Além disso, os aerossóis provenientes da pluma de fumaça influenciaram na camada limite, deixando-a mais estável e rasa. Mulcahy et al. (2014) encontraram melhorias nas previsões com

aerossóis interativos utilizando o modelo de PNT do *Met Office Unified Model* (MetUM). Os autores identificaram a redução do Viés no perfil vertical da temperatura e na radiação de onda longa, além de identificarem que a atuação de aerossóis de poeira e fumaça reduz o Viés positivo na previsão da precipitação, com diminuição das chuvas na região do Sahel de 1 a 3 mm/dia.

Os aerossóis influenciam principalmente o fluxo de radiação incidente que chega na superfície. Um exemplo deste impacto é analisado por [Tsikerdekis et al. \(2017\)](#) por meio de simulações realizadas com o modelo regional climático RegCM4, onde constataram que locais como o ocidente da África e Atlântico leste, com emissões de poeira quase que constante, têm mudanças importantes na forçante radiativa, com menos radiação chegando na superfície, aproximadamente  $20 \text{ W/m}^2$ , e  $5\text{-}10 \text{ W/m}^2$ , respectivamente. Alterações como essas na radiação solar têm influência direta na temperatura do ar próximo à superfície. Os impactos da poeira do deserto nos fluxos radiativos e na Camada Limite Planetária (CLP) em um curto período de tempo foram estudados por [Rémy et al. \(2015\)](#) por meio do sistema *Monitoring Atmospheric Composition and Climate – Interim Implementation* (MACC – II) com aerossóis interativos. Os autores mostraram uma melhoria importante na previsão da temperatura do ar a 2 metros e nas previsões dos fluxos radiativos de superfície até 48 horas. Também, foi observada a diminuição de aproximadamente  $5^\circ\text{C}$  nas previsões de temperatura realizadas por diferentes modelos em regiões afetadas pela pluma de fumaça proveniente de queimadas nos Estados Unidos da América, destacando-se a cidade de Grand Forks ([ZHANG et al., 2016](#)). Mais recentemente, [Benedetti e Vitart \(2018\)](#), realizaram experimentos com o sistema de previsão por conjuntos do ECMWF fazendo uso de aerossóis climatológicos e interativos. Os autores mostraram ganho de desempenho nas previsões sub-sazonais do modelo na escala mensal, além de terem observado uma modulação dos aerossóis de poeira pela Oscilação Madden-Julian. Para a variável temperatura, houve uma redução de Viés de  $0,5^\circ\text{C}$  a  $2^\circ\text{C}$  sobre o leste da Ásia e Oceano Pacífico Norte.

Na AS, a maioria dos trabalhos relacionados aos aerossóis fazem uso de dados observacionais provenientes de satélites e da rede AERONET para fins de comparação com modelos numéricos, como por exemplo [Freitas et al. \(2005a\)](#), [Pereira et al. \(2009\)](#), [Hoelzemann et al. \(2009\)](#), [Rosário et al. \(2013\)](#), e comumente realizados sobre a Amazônia, devido a diversos projetos experimentais nessa região ([PROCOPIO et al., 2003](#); [ARTAXO et al., 2006](#); [BRITO et al., 2014](#); [SATURNO et al., 2018](#); [ANDREAE et al., 2018](#); [FAN et al., 2018](#)). Além disso, estudos realizados sobre a AS utilizam o modelo brasileiro BRAMS para estudar os impactos de diferentes fontes de aeros-

sóis na atmosfera e superfície terrestre, principalmente nos fluxos radiativos. Este modelo possui vários processos físicos e químicos inseridos, como emissões provenientes de cidades, indústrias, biogênica, queima de biomassa, vulcões, biocombustível e queima de resíduos agrícolas (FREITAS et al., 2006; FREITAS et al., 2011; LONGO et al., 2011; LONGO et al., 2013; PAVANI et al., 2016).

Os impactos exercidos pela queima de biomassa modelados pelo BRAMS nos fluxos de radiação solar sobre a AS são evidenciados no estudo de Rosário et al. (2013). Os autores apresentaram a diminuição dos fluxos de radiação de onda curta sobre a bacia Amazônica de  $-10 \text{ W/m}^2$  a  $-55 \text{ W/m}^2$ . Além disso, a eficiência do fluxo radiativo do aerossol em várias localidades variou de  $-154 \text{ W/m}^2$  a  $-163 \text{ W/m}^2$ . Um outro estudo mais local sobre o sítio experimental ABRACOS em Rondônia no Brasil realizado por Artaxo et al. (2006) por meio de experimentos com e sem a inclusão de aerossóis no modelo BRAMS para três dias de previsão, mostrou uma diminuição de  $1^\circ\text{C}$  nas temperaturas máximas do ar próximo à superfície com a inserção dos aerossóis. Também, identificaram que períodos com altas concentrações de aerossóis, há um impacto na redução em aproximadamente 40% da radiação de onda curta, e conseqüentemente, esta redução afeta os fluxos de calor latente e sensível (ARTAXO et al., 2006). Moreira et al. (2017) utilizaram o modelo regional BRAMS totalmente integrado, considerando apenas o efeito direto dos aerossóis para avaliar seu impacto relativo à queima de biomassa nos fluxos de  $\text{CO}_2$  na Região Amazônica durante o ano de 2010. Os autores analisaram os efeitos da atenuação da radiação solar global e o aumento do fluxo de radiação solar difusa no interior do dossel da vegetação. Seus resultados indicaram que os aerossóis de queimada contribuíram para um aumento de cerca de 27% na produtividade primária bruta da Amazônia e 10% na respiração das plantas, bem como um declínio na respiração do solo de 3%. Além dos impactos nos fluxos de  $\text{CO}_2$ , Moreira et al. (2017) também analisaram o comportamento do ciclo diurno da temperatura do ar a 2 metros, identificando uma diminuição de aproximadamente  $2,5^\circ\text{C}$  na temperatura média durante a noite.

Kolusu et al. (2015) realizaram um trabalho usando um esquema clássico de queima de biomassa no prognóstico de diversas variáveis em um período curto de tempo sobre a AS por meio do modelo MetUM. Os autores identificaram uma redução da radiação incidente na superfície, com diminuição da temperatura do ar em até  $2^\circ\text{C}$  e redução da velocidade do vento e precipitação (0,05 a 0,12 mm/dia) devido à diminuição dos fluxos de calor sensível e evapotranspiração (0,2 e 0,3 mm/dia) no primeiro dia de previsão, respectivamente, além do impacto na CLP e mudanças relativas na pressão. Flemming et al. (2020) encontraram resultados semelhantes

ao comparar o desempenho do modelo IFS do ECMWF com a inclusão do efeito direto dos aerossóis de poeira e de fumaça de forma interativa com aquela versão que considera a climatologia dos aerossóis. Foi observado que a inclusão de aerossóis de queimada interativos contribuem para melhorar o desempenho das previsões de temperatura próximo à superfície do IFS em áreas onde este tipo de aerossol é importante, por exemplo, sobre a AS, região central do continente africano e nordeste da Ásia.

### 2.3 Ondas de calor

As alterações nos fluxos radiativos, e conseqüentemente nas variáveis meteorológicas podem gerar impactos futuros, principalmente na temperatura global do planeta. Nos últimos relatórios do IPCC vêm-se debatendo o aumento da temperatura média global nas últimas décadas associado aos processos antrópicos que influenciam nas mudanças do clima com impactos observados em todos os continentes e oceanos. Eventos extremos estão se tornando cada vez mais frequentes em todo o globo, e com eles, os transtornos causados à sociedade vêm aumentando. Um exemplo disto, são as temperaturas extremas que associadas à um longo período de dias, aumenta o risco de mortes por problemas respiratórios e cardiovasculares devido ao estresse térmico provocado ao corpo humano (HAJAT *et al.*, 2006; CHENG; SU, 2010; BITENCOURT *et al.*, 2012; SILVEIRA *et al.*, 2019). As elevadas temperaturas também prejudicam o setor econômico, como a agricultura, pecuária e setor energético.

Recentemente, estudos apontam o aumento da frequência e intensidade de ondas de calor na AS, principalmente na primavera e verão (BITENCOURT *et al.*, 2016; CECCHERINI *et al.*, 2016; REIS *et al.*, 2019). Projeções climáticas de ondas de calor realizadas sobre a AS por Feron *et al.* (2019), mostram que estes eventos podem se tornar mais frequentes e com longos períodos de persistência na região Amazônica e deserto do Atacama no verão. Atualmente, pouco se conhece sobre os mecanismos físicos envolvidos no processo de desenvolvimento e manutenção dos episódios de ondas de calor na AS, como também da sua associação com modos de variabilidade climática. Por meio de uma climatologia de 1961-2014, Bitencourt *et al.* (2016) estudaram a relação entre a ocorrência de ondas de calor no Brasil e a Oscilação Decadal do Pacífico (ODP), e encontraram que mesmo com o aumento dos episódios não há uma resposta explícita com anos de El Niño e La Niña. Um estudo similar realizado por Reis *et al.* (2019) na região subtropical do Brasil mostrou que existe uma fraca relação entre os casos de ondas de calor e as fases do ENSO.

Na literatura existe diversas definições de ondas de calor, sendo um dos critérios mais

utilizados as temperaturas máximas acima do percentil de 95% com duração mínima entre três ou cinco dias. A Organização Meteorológica Mundial (OMM) sugere que as ondas de calor sejam definidas por um período de no mínimo três dias consecutivos de temperaturas máximas e mínimas acima de um limiar baseado nas condições meteorológicas de uma determinada região [WORLD METEOROLOGICAL ORGANIZATION - WMO \(2009\)](#). Além destes critérios, alguns estudos também levam em consideração anomalias na umidade relativa. Por exemplo, o trabalho de [Nissan et al. \(2017\)](#) analisou seis critérios de definição de ondas de calor em Bangladesh, e uma dessas condições foi a umidade relativa diurna e noturna acima do percentil de 95% em pelo menos 3 dias consecutivos.

Em relação às condições atmosféricas, as ondas de calor estão geralmente associadas com anomalias de circulação anticiclônica, principalmente em médio e altos níveis que causam subsidência de ar, e conseqüentemente geram anomalias negativas de umidade relativa ([NISSAN et al., 2017](#)). Durante a ocorrência de ondas de calor no verão, [Geirinhas et al. \(2018\)](#) analisaram os padrões atmosféricos e de outras variáveis em algumas cidades brasileiras, e constataram que as principais fontes que podem desencadear estes eventos são o aumento do fluxo radiativo e diminuição da umidade do solo, normalmente associados com uma circulação anticiclônica quase-estacionária e diminuição na cobertura de nuvens. Além dos padrões anticiclônicos, um estudo observacional realizado por [Chazette et al. \(2017\)](#) investigou por meio de medições diárias a atuação de diversos tipos de aerossóis durante três episódios de ondas de calor sobre Paris. O trabalho mostrou que aerossóis carbonáceos próximos à superfície advindos de outras regiões da Europa induzem um aumento nos fluxos radiativos, tornando estes eventos ainda mais severos.

### 3 METODOLOGIA

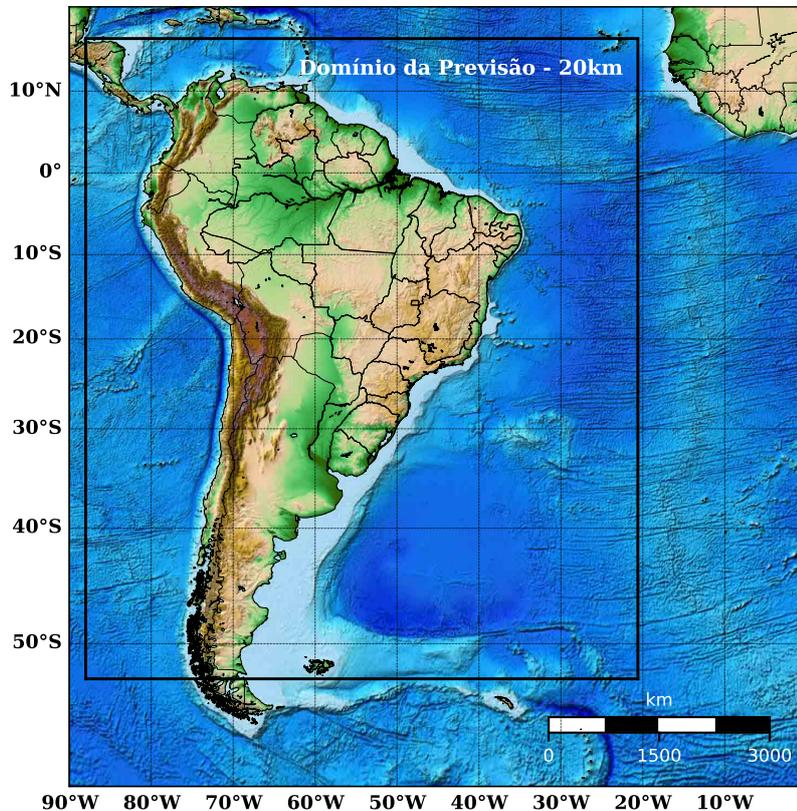
Esta pesquisa é uma continuidade de diversas contribuições que evoluem ao longo do tempo no CPTEC/INPE e em outros centros de meteorologia no país e no mundo, fruto da interação entre grupos e linhas de pesquisas. A metodologia descrita no presente capítulo é baseada principalmente no trabalho de Carrasco (2017), sendo esta pesquisa uma continuidade do trabalho da referida autora no que diz respeito à utilização do MODE para verificação espacial da temperatura a superfície prevista por modelos de PNT no CPTEC/INPE. Faz-se também uso de todo conhecimento em modelagem da qualidade do ar e PNT adquiridas ao longo de 15 anos de operacionalização do modelo ambiental do CPTEC, documentado em diversas dissertações de mestrado, teses de doutorado e artigos científicos. Só para citar aqui alguns exemplos, destacam-se os trabalhos de Freitas et al. (2005b), Longo et al. (2011) e Moreira et al. (2013).

Este Capítulo tem a seguinte organização: na Seção 3.1 é apresentado a área de estudo utilizada no presente trabalho. A Seção 3.2 apresenta os principais detalhes do modelo numérico escolhido para esta pesquisa. Por fim, na Seção 3.3 e Seção 3.4 são descritos os dados disponíveis para essa pesquisa, e a metodologia utilizada para a avaliação orientada a objeto da temperatura do ar, respectivamente.

#### 3.1 Área de estudo

As previsões foram realizadas sobre a AS [ver Figura 3.1] entre as latitudes  $16,35^{\circ}\text{N}/52,68^{\circ}\text{S}$  e longitudes de  $88,04^{\circ}\text{W}/20,65^{\circ}\text{W}$ , representadas pelo retângulo nessa figura. A extensão territorial da AS é de 17,8 milhões de  $\text{km}^2$ , sendo dividida em 12 países, onde vivem 6% da população mundial (INFOESCOLA, 2019). O período de estudo compreende os meses de Julho, Agosto, Setembro e Outubro (JASO) de 2016, 2017 e 2018. Este período em questão foi escolhido por se tratar climatologicamente de um período seco em grande parte da AS, com temperaturas elevadas, principalmente durante o mês de setembro, onde são observadas temperaturas mais altas em relação ao verão austral. Além disso, é nessa época que há uma maior concentração de particulados na atmosfera, devido ao aumento das queimadas na primavera austral no continente Sul Americano. Deve-se destacar que nesse período há um aumento de ondas de calor sobre o Brasil, principalmente nos meses de agosto, setembro e outubro (BITENCOURT et al., 2016). Esse aumento na frequência das ondas de calor também foi identificado na AS por Ceccherini et al. (2016).

Figura 3.1 - Mapa da AS com destaque para o domínio (retângulo) em que esta configurada a versão do modelo BRAMS com resolução horizontal de 20 km, utilizada nessa pesquisa.



Fonte: Produção da autora.

A AS possui uma área territorial muito extensa, apesar de ter grande parte da sua área inserida em regiões tropicais, sua parte mais ao sul é fortemente influenciada pelo clima antártico. Outra importante peculiaridade dessa região é a Cordilheira dos Andes, além de outros tipos de relevo, que abrange quase que toda sua costa oeste, funcionando como uma barreira topográfica influenciando significativamente a circulação atmosférica da região. Além disso, ou por consequência dessas características já mencionadas, a AS possui diferentes tipos de vegetação, e é rodeada por vastas áreas oceânicas. Tais características influenciam o estabelecimento de diferentes regimes climáticos (REBOITA et al., 2012). No extremo norte do continente, as temperaturas são elevadas durante o ano todo sem sofrer grandes variações, já o contrário ocorre para o extremo sul, onde são observadas temperaturas relativamente mais frias em relação a outras regiões da AS. Os sistemas frontais, por exemplo, influenciam em grande parte da AS, principalmente as regiões sul e su-

deste do continente. Dependendo de sua intensidade, as temperaturas do ar são fortemente alteradas nessas regiões. Além disso, esses sistemas influenciam a região Norte e Centro-Oeste do Brasil com friagens (ESCOBAR et al., 2018).

### 3.2 Modelo numérico escolhido

Na presente Seção será apresentado o modelo BRAMS que possui o sistema integrado de modelagem ambiental (meteorologia/aerossóis/química) disponível no CPTEC/INPE, utilizado nesta pesquisa. Destaca-se que as rodadas sem e com a integração da química do modelo BRAMS foram realizadas utilizando a versão operacional (Versão 5.2) com resolução horizontal de aproximadamente 20Km, e previsão até 96 horas, mas apenas os prazos de 18, 42, 66 e 90 horas foram utilizados para avaliação no SCANTEC, que correspondem à previsão das 18 UTC, horário aproximado de ocorrência da  $T_{max}$ .

O modelo regional BRAMS foi originalmente desenvolvido a partir do modelo *Regional Atmospheric Modeling System* (RAMS) na Universidade do Estado do Colorado nos Estados Unidos (WALKO et al., 2000). Ao longo dos anos foram realizados vários desenvolvimentos para tornar o modelo adequado para as regiões tropicais e subtropicais da AS (FREITAS et al., 2005b; FREITAS et al., 2009; LONGO et al., 2011; SANTOS E SILVA et al., 2012; MOREIRA et al., 2013; SANTOS et al., 2013; MOREIRA et al., 2017; FREITAS et al., 2017).

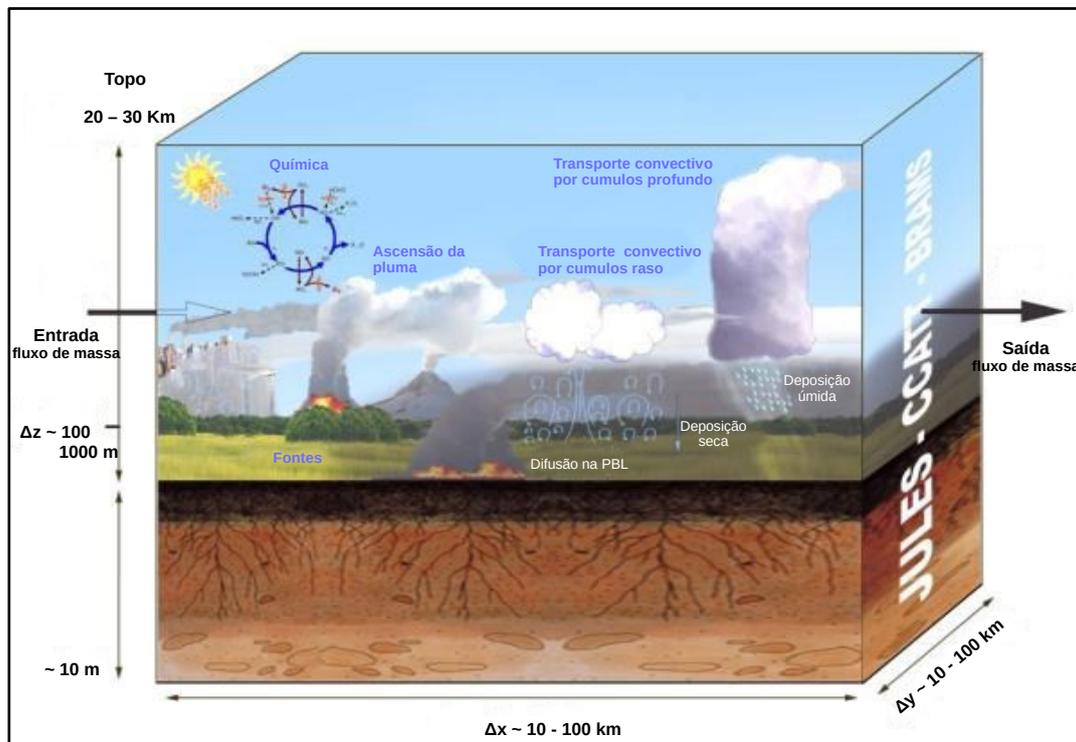
O modelo BRAMS resolve as equações prognósticas (dinâmicas e termodinâmicas do movimento atmosférico) de características não hidrostática e compressível (FREITAS et al., 2009; FREITAS et al., 2017). O modelo é baseado em diferenças finitas e utiliza grade do tipo C de Arakawa (MESINGER; ARAKAWA, 1976), coordenada vertical sigma-z, na qual acompanha o terreno na parte inferior e possui topo plano. O BRAMS possui várias parametrizações físicas: microfísica das nuvens, radiação, turbulência, interações de superfície, e convecção (profunda e rasa). O modelo *Coupled Aerosol and Tracer Transport model* (CATT) é responsável pela parte química do modelo BRAMS, simulando o transporte de gases e aerossóis provenientes de diversas fontes na AS. O CATT é um modelo de transporte euleriano que foi acoplado integralmente ao modelo atmosférico BRAMS, e tem como característica a integração simultânea do transporte dos gases e aerossóis a medida que o estado atmosférico avança no tempo, utilizando o mesmo *time-step*, e parametrizações físicas e dinâmicas (FREITAS et al., 2009; LONGO et al., 2013; FREITAS et al., 2017).

O BRAMS possui diversos processos de subgrade, onde a continuidade de massa

dos traçadores químicos é resolvida pelos efeitos da turbulência na CLP, transporte convectivo por convecção profunda e rasa, advecção em escala de grade, além do levantamento da pluma de fumaça devido à queima de biomassa (FREITAS et al., 2006). O modelo ainda inclui os processos de remoção desses traçadores pela deposição seca e úmida [ver detalhes dos processos na Figura 3.2]. Outra característica do BRAMS é o acoplamento com o esquema de superfície JULES (*Joint UK Land Environment Simulator*), onde os processos de retroalimentação entre a atmosfera e superfície ocorrem simultaneamente. Por exemplo, a atmosfera fornece para o JULES a velocidade do vento próximo à superfície, temperatura do ar, pressão, água condensada e fluxos de radiação descendente, além do vapor de água e gases traços, como o  $CO_2$ , monóxido de carbono, metano e VOCs. Posteriormente, o JULES retorna à atmosfera os fluxos de calor sensível e latente, fluxos de *momentum* da superfície, fluxos acidentais de onda curta e onda longa e fluxos de gases traços (MOREIRA et al., 2013).

O BRAMS possui ferramentas de pré-processamento para geração dos dados de emissões, como o PREP-CHEM-SRC (FREITAS et al., 2011; FRASSONI et al., 2018) e o D-PREP que gera as condições iniciais e de contorno para o modelo (aerossóis/química/meteorologia). De acordo com Freitas et al. (2011), o PREP-CHEM-SRC fornece as emissões de gases e aerossóis provenientes de diversas fontes (urbanas, indústrias, queima de biomassa, vulcão, biogênicas, queima de combustíveis fósseis e de resíduos agrícolas), conteúdo flexibilidade na resolução espacial e disponível tanto para modelos regionais, quanto para os globais.

Figura 3.2 - Representação das parametrizações físicas, químicas e de superfície dos processos de subgrade do modelo BRAMS.



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

### 3.3 Dados utilizados como referência na avaliação

Nesta Seção será apresentada uma breve descrição dos dados utilizados como referência (referido a partir de agora como controle) na avaliação das previsões do BRAMS. Foram utilizadas duas fontes de dados distintas: (1) a análise do *Global Forecast System* (GFS), e (2) a reanálise do ERA5, ambas utilizadas como valores de referência para avaliar a qualidade das previsões de  $T_{max}$  e dos episódios de ondas de calor provenientes dos experimentos utilizados nesta pesquisa.

#### 3.3.1 Análise do *Global Forecast System* (GFS)

Uma primeira abordagem (menos rigorosa) para a avaliação da qualidade das previsões é compará-las com as próprias análises utilizadas como condição de contorno no BRAMS. Embora o modelo ambiental em avaliação não possua suas próprias análises, o uso da análise por ele utilizada evita, ou mesmo minimiza, a influência da qualidade das condições iniciais nas incertezas das previsões, bem como evita in-

jeção de incertezas provenientes da interpolação de resultados nos pontos da grade do modelo, uma vez que as análises possuem a mesma grade.

As análises do GFS são compostas por previsões desse modelo e dados assimilados pelo GSI (*Gridpoint Statistical Interpolation*). O GFS é um modelo global formado por várias componentes, como a atmosférica (SAHA et al., 2010), oceânica “*Modular Ocean Model*” (MOM) (GRIFFIES, 2012), superfície continental “*Land Surface Model*” (LSM) (PAN; MAHRT, 1987), e de gelo marinho “*Sea Ice Simulator*” (SIS) (WINTON, 2000). Foi desenvolvido primordialmente pelo *National Centers for Environmental Prediction* (NCEP) e possui uma gama de variáveis atmosféricas, como também do solo, além da concentração de ozônio na atmosfera. As análises do GFS se encontram disponíveis no sítio na internet no *National Operational Model Archive and Distribution System* (NOMADS) da *National Oceanic and Atmospheric Administration* (NOAA) para o período que compreende de 02 de abril de 2004 até o presente. Os dados são diários, com frequência a cada 6 horas (00:00, 06:00, 12:00, 18:00 UTC). Possuem uma resolução horizontal de aproximadamente 28km para previsões operacionais de até 16 dias e outra resolução horizontal de 70km para previsões entre uma e duas semanas, com resolução temporal a cada 3 horas, tendo em vista que os dados da análise é referente ao primeiro horário da saída do modelo (NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA, 2019a).

Para leitura da análise do GFS no SCANTEC foi necessário realizar uma simulação dos dados para as mesmas configurações de grade do modelo BRAMS, ou seja, nesta simulação apenas o primeiro tempo de integração foi levado em consideração, que corresponde a análise do GFS. A grade da análise do GFS se aproxima da grade do BRAMS, devido à técnica de relaxamento Newtoniano, conhecida também como *nudging* utilizada por este modelo. O *nudging* faz com que a solução do modelo seja “relaxada” em relação aos dados de grande escala apenas nos pontos de grade próximos durante a integração no tempo. Por exemplo, em relação a circulação atmosférica de grande escala em um modelo regional, os valores fornecidos pela condição de contorno e no interior do domínio se mantêm o mais próximo possível (LUCAS-PICHER et al., 2016).

### 3.3.2 Reanálises do ERA5

Em uma segunda abordagem na avaliação, foi usada uma informação externa, em grade regular e, em teoria, mais próxima de uma verdade do ponto de vista da modelagem numérica, que é a reanálise. O ERA5 foi recentemente disponibilizado pelo ECMWF, como o mais novo conjunto de informações globais da atmosfera em escala

horizontal refinada de aproximadamente 31km e com 137 níveis verticais, desenvolvido para substituir a reanálise do Era-Interim. A reanálise do ERA5/ECMWF é escolhida aqui por se tratar de dados com mais alta resolução espacial e temporal em relação às demais reanálises atualmente disponíveis.

Os dados do ERA5 estão disponíveis desde o período de 1979 até os dias atuais. Segundo [Hersbach et al. \(2019\)](#), a reanálise do ERA5 é obtida a partir de observações combinadas com as informações do modelo de previsão pelo método de assimilação 4D-Var (Análise Variacional Quadridimensional) utilizando o ciclo 41r2 do sistema integrado de previsões do ECMWF, possibilitando a cada hora estimativas da evolução da atmosfera e de superfície. As informações assimiladas no ERA5 aumentaram consideravelmente em relação ao ERA-Interim, no qual os dados de radiação por satélite são dominantes. Diversos campos atmosféricos são analisados, como temperatura, vento, umidade, ozônio, pressão de superfície, como também parâmetros a 2 metros em relação à superfície (temperatura e umidade), umidade e temperatura do solo, neve e ondas oceânicas. Sendo que todas estas variáveis são utilizadas na inicialização do modelo de previsão de curto prazo, fornecendo estimativas do estado atmosférico para realizar o próximo ciclo da análise. O ERA5 apresenta melhorias em relação à reanálises anteriores para o caso da radiação, Temperatura da Superfície do Mar, e gelo marinho, pois inclui novas forçantes para a irradiância solar total, ozônio, gases de efeito estufa, e aerossóis, como o sulfato estratosférico de origem vulcânica ([HERSBACH et al., 2019](#)).

Como as reanálises do ERA5 possui resolução temporal horária e frequência diária, ressalta-se que o horário utilizado nesta pesquisa corresponde ao máximo de temperatura durante às 24 horas. Para isso foi realizada uma climatologia horária da Temperatura a 2 metros em relação à superfície no período sazonal de 40 anos (JASO: 1979-2018).

### **3.4 Metodologia orientada a objeto MODE para avaliação da temperatura do ar**

Embora criado inicialmente para a avaliação espacial da qualidade das previsões de precipitação, na presente pesquisa foi utilizado o MODE para avaliar espacialmente a previsão de ondas de calor. Para a avaliação de outras variáveis utilizando o MODE no SCANTEC, como é o caso da temperatura do ar, foi necessário realizar uma adaptação dentro de seus módulos. Algumas modificações nas rotinas do SCANTEC também foram necessárias, como a inclusão da variável Temperatura à 2 metros (T2M) no módulo de leitura das variáveis (*SCAM\_dataMOD*), além de desligar o

*flag* de precipitação na subrotina *SCAM\_RUN()* no módulo *SCAM\_coreMOD*.

Como mostrado no item 2.1.1, o MODE é executado em quatro etapas, sendo primeiramente realizada a identificação dos objetos pela aplicação da convolução do campo original e de um limiar de intensidade, a identificação dos objetos pares, a lógica difusa na aplicação da função do calculo do IT, levando em consideração as funções de confiança ( $C_i$ ), interesses parciais ( $IP_i$ ) e os pesos de cada atributo ( $W_i$ ), e por último a realização das estatísticas dos objetos por meio da tabela de contingência. Em relação aos pesos dos atributos, foram mantidos os mesmos dos objetos pareados utilizados na avaliação da precipitação por Carrasco (2017). Estes pesos são adotados como padrões pelo NCAR no *Model Evaluation Tools* Versão 5.2 para avaliação da precipitação e são mostrados na Tabela 3.1. É dado maior peso para a Distância Mínima entre as Bordas, Diferença de Centroide e Razão da Área de Interseção dos objetos pareados, pois estes atributos em relação aos demais demonstram maior indicação dos objetos estarem próximos. Ajustes nesses pesos podem ser necessários para aprimorar essa técnica, o que não foi feito na presente pesquisa, podendo ser um tópico de pesquisa futura.

Tabela 3.1 - Pesos atribuídos na composição do valor de IT dos objetos pareados de ondas de calor avaliados no MODE.

<b>Atributos</b>	<b>Pesos</b>
Distância Mínima entre Bordas	4
Diferença de Centroide	2
Razão de Área de Interseção	2
Razão das Áreas	1
Razão de Perímetros	0
Diferença de Ângulo	1
Razão de Aspecto	0
Razão de Complexidade	0

Fonte: Adaptado de Carrasco (2017).

Por se tratar de uma variável contínua com pouca variação espacial e temporal, a convolução no módulo de identificação de objetos foi desligada para a temperatura. A convolução é aplicada para identificar regiões com objetos, antes de ser aplicado o limiar de intensidade para suavização do campo, tornando o campo contínuo no espaço, por exemplo, este processo é utilizado para variáveis discretas, como precipitação, nuvens, entre outras. Além da convolução, outra modificação necessária

foi alterar o valor do limite da área do objeto (*area\_tresh*) para 25, com intuito de eliminar objetos menores, onde o valor para a precipitação é 2 no MODE do SCANTEC. Mas, caso o usuário queira apenas objetos que atendam a um critério mínimo de números de quadrados de grade, este valor pode ser modificado, como também aplicar valor zero para que todos os objetos sejam mantidos.

Para a identificação dos objetos nos campos de referência e previstos da  $T_{max}$ , foram utilizados os limiares de intensidade dos episódios de ondas de calor identificados por meio da metodologia proposta por Bitencourt et al. (2016). A identificação de ondas de calor no período de estudo da pesquisa foi realizada por meio dos dados da análise do GFS, e climatologicamente na reanálise do ERA5. Inicialmente, foram avaliados apenas os episódios condizentes em dias nas referências e previsões, mesmo que a persistência identificada em ambas seja diferente.

### 3.4.1 Metodologia de identificação dos episódios de ondas de calor

Seguindo a metodologia proposta por Bitencourt et al. (2016), o critério de identificação da onda de calor é baseado no valor médio da  $T_{max}$  somado a um ou dois valores de desvio padrão (aqui foi adotado apenas um valor do desvio-padrão), com duração mínima de três dias e extensão espacial. O critério de caracterização é expresso por:

$$T_{max} \geq \bar{T}_{max} + \sigma, \quad (3.1)$$

sendo,  $\bar{T}_{max}$  a Temperatura Máxima Média do Ar diária e desvio padrão ( $\sigma$ ). A  $\bar{T}_{max}$  e o  $\sigma$  são expressos pelas Equações 3.2 e 3.3, respectivamente:

$$\bar{T}_{max} = \frac{1}{N(k, D)} \sum_i^N T_{max(i)}(k, D), \quad (3.2)$$

e

$$\sigma(k, D) = \sqrt{\frac{\sum_i^N (T_{max(i)}(k, D) - \bar{T}_{max}(k, D))^2}{N(k, D) - 1}}. \quad (3.3)$$

Bitencourt et al. (2016) calculou a  $\bar{T}_{max}$  diária e o  $\sigma$  a partir de uma série histórica, sendo  $k$  correspondente ao número de estações meteorológicas,  $D$  ao número de

dias julianos ( $D = 1,2,3,\dots,365$ ) e  $N(k,D)$  ao número de anos da série histórica. Para o caso da presente pesquisa,  $k$  corresponde à quantidade de pontos de grade disponíveis nos dados de referência,  $D$  o número de dias julianos dos meses de JASO ( $D = 181,182,183,\dots,304$ ), e  $N(k,D)$  representa o número de anos da série histórica dos dados de reanálise do ERA5 (1979 a 2018), ou seja  $i=1979,1980,\dots,2018$ .

Assim que o critério de identificação dado por 3.1 for obedecido em no mínimo de 25% dos pontos de grade (por se tratar de dados de reanálise, devido a quantidade de número de pontos), calcular-se-á o valor médio entre os dias identificados, obedecendo o mínimo de três dias. Por último, calcular-se-á o Parâmetro de Intensidade (PI) dado pela  $\bar{T}_{max}$  entre os dias estabelecidos pelo critério de identificação. Logo, as ondas de calor são classificadas quando PI é maior que o limite superior ao terceiro quartil da série, ou seja, acima do percentil de 75%. Além do PI, foi calculado o Parâmetro de Intensidade Diário (PID) de cada episódio para identificação dos dias com maior intensidade. O PID é dado pela média espacial de cada dia do evento identificado. Ressalta-se que os resultados da temperatura média máxima diária e do desvio padrão diário da climatologia do ERA5 foram tomados como referência para o critério de identificação das ondas de calor nos dados de análise do GFS e na previsão do BRAMS.

Para classificação destes eventos na AS foi preciso redefinir as áreas de estudo por meio da análise de *cluster*, pois ao realizar os cálculos anteriores, principalmente do percentil de 75% da  $T_{max}$  nas faixas de latitudes e longitudes definidas por Bitencourt et al. (2016) havia influência de regiões com relevos acidentados, como a Cordilheira dos Andes.

Em relação a construção do algoritmo de identificação dos episódios de ondas de calor e aplicação da análise de *cluster* para definição das áreas homogêneas de  $T_{max}$  foi utilizada a linguagem de programação Python, e a versão utilizada desse software foi a 3.7.3.

Com o algoritmo foi possível realizar uma climatologia sazonal de 1979 a 2019 dos episódios na reanálise do ERA5. Os eventos identificados nesta climatologia foram classificados à partir dos quartis da série do PI, independente da persistência. A onda de calor é classificada como intensa se o PI for maior que o percentil de 75%, média se PI for menor que 75% e maior que 25%, e fracas se PI for menor que o percentil de 25%. Foi aplicado a análise de tendência na série anual da intensidade e persistência das ondas de calor por meio do teste Mann-Kendall com significância estatística de 5%, utilizando o pacote *pymannkendall* disponível no Python (HUS-

SAIN; MAHMUD, 2019). Esse teste é bastante utilizado na literatura para verificar tendências crescentes ou decrescentes em séries temporais, sendo não paramétrico, ou seja, a série temporal não precisa atender à suposição de normalidade. Além disto, a frequência mensal e do número de pontos de grade e intensidade média da onda de calor foram calculadas para cada área definida.

### 3.4.2 Análise de *cluster*

Conhecido também por análise de agrupamento, a análise de *cluster* é bastante útil para separar uma série de dados em grupos ou *clusters*, comparando os atributos estatísticos como variância e covariâncias de cada elemento observado com os demais elementos e classificando-os em determinado *cluster* (ROMESBURG, 2004; WILKS, 2011) tendo como critério a semelhança ou diferença dos padrões de variabilidade. Por exemplo, no caso da temperatura que é a variável de interesse, subjetivamente a classificação dos grupos seria de acordo com a distribuição mensal, e de regiões com temperaturas climatologicamente parecidas.

Para a realização da análise, foi utilizado o método hierárquico e aglomerativo da variância mínima de Ward, e como medida de dissimilaridade, a distância euclidiana, também conhecida por matriz de distância, a qual é utilizada para calcular a similaridade dos pares de vetores da matriz  $x_i$  e  $x_j$ , dada por:

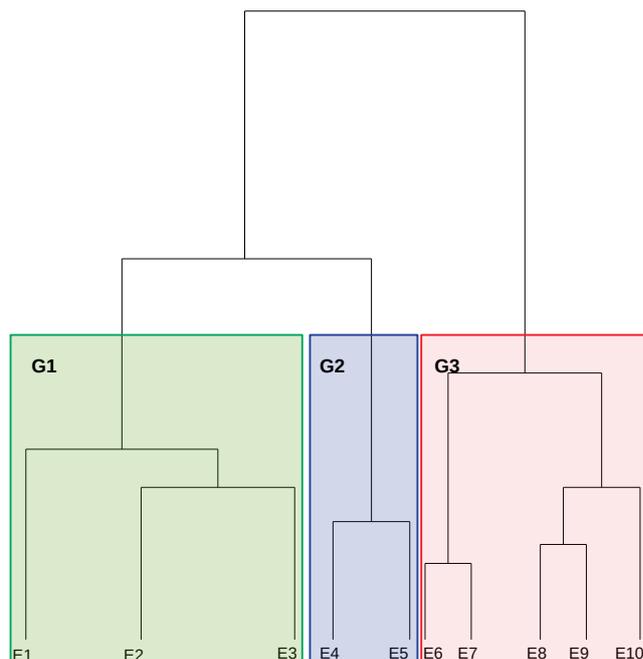
$$d_{i,j} = \left[ \sum_{n=1}^K w_n (x_{i,n} - x_{j,n})^2 \right]^{1/2} \quad (3.4)$$

onde,  $w_n=1$  para cada  $n=1, \dots, K$ . Quanto mais próximo de zero for a distância euclidiana, mais similares são os elementos comparados (WILKS, 2011).

Após o cálculo da distância euclidiana, o método de Ward é utilizado como uma função de ligação entre os *clusters*, ou seja, este se baseia na soma dos quadrados da distância calculada anteriormente, e agrupa pares de *clusters* com base na semelhança. Por exemplo, na Figura 3.3 temos uma representação hipotética de como ocorre a aglomeração de *clusters* na forma de hierarquização. As caixas coloridas nessa figura representam a quantidade de *clusters* ou grupos escolhidos neste exemplo. Esse método se inicia com  $k$  grupos individuais (E1,E2,E3,...,E10), e a cada etapa estes são aglomerados um por um, e diminuem gradativamente a quantidade, até formar um único grupo. No geral, a escolha da quantidade de *clusters* à serem utilizados é subjetiva, e muitos usuários “cortam” a árvore hierárquica em um de-

terminado patamar para divisão dos grupos. Outra forma subjetiva é analisar um gráfico da soma da distância dos quadrados, onde a determinação da quantidade de grupos ocorre quando a soma começa a tender à zero, se tornando cada vez menor a medida em que o número de *clusters* aumenta. No entanto, isso pode gerar uma dúvida no final da análise, se a escolha do número de *clusters* foi de fato correta. Logo, o índice *Silhouette* proposto por Rousseeuw (1987) foi utilizado para definição “apropriada” da quantidade de *clusters*. O índice *Silhouette* (ROUSSEEUW, 1987) varia de -1 a 1, em que valores próximo a -1 indicam que a atribuição do grupo ou *cluster* está inadequada, 0 representa o limite entre os grupos, e quanto mais próximo de 1 indica que o *cluster* está classificado corretamente.

Figura 3.3 - Dendrograma representando o processo de formação de grupos na análise de *cluster* com 10 elementos hipotéticos, e três grupos formados representados pelos retângulos coloridos em *shaded*.



Fonte: Produção da autora.

Para aplicação da análise de *cluster*, foi selecionada a temperatura máxima do dia em cada ponto de grade pelo *Climate Data Operators* (CDO) versão 1.9.3, independente do horário. Após foi realizada uma média sazonal JASO de 1979 a 2018, onde a

matriz de dados foi organizada em latitude, longitude e a média sazonal de cada ano. Os grupos identificados sobre a AS foram espacializados por meio da interpolação linear, além disto, as áreas de conflitos entre *clusters* foram mascaradas para evitar o máximo possível a influência dessas regiões de incertezas.

## 4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados de uma análise de *cluster* para identificação das regiões homogêneas de  $T_{max}$ , com uma análise descritiva dessa variável, destacando os episódios de ondas de calor identificados sobre a AS. A avaliação orientada a objeto das previsões de ondas de calor da versão integrada com química do modelo BRAMS com aquela versão meteorológica são também mostrados e discutidos em estudos de casos.

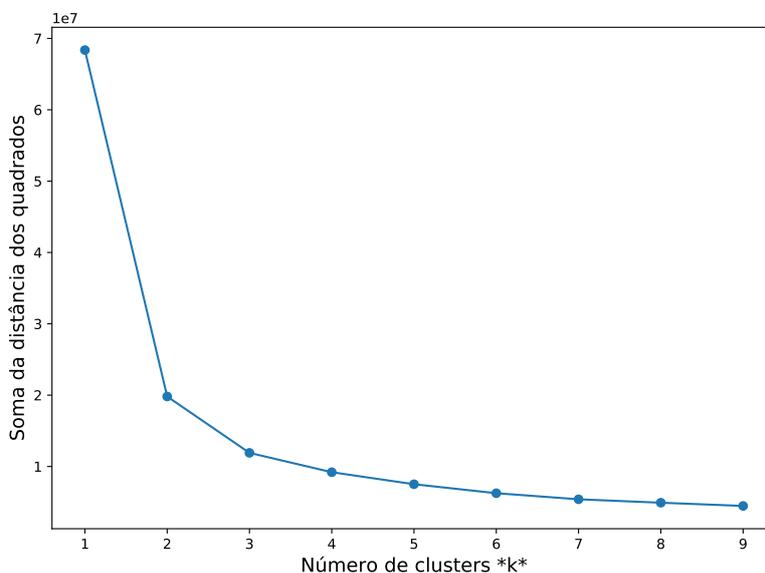
### 4.1 Análise de *cluster*: identificação das regiões homogêneas de temperatura máxima do ar

Diante da incerteza de escolha do número de *clusters*, a Figura 4.1 mostra uma estimativa de quantos grupos devem ser utilizados na análise de agrupamento da  $T_{max}$  na AS no período sazonal (JASO) de 1979-2018. Este gráfico representa a distância entre os elementos dentro dos *clusters* ( $k=1,2,3,\dots,9$ , sendo  $k$  o total de grupos analisados). Nota-se que a distância diminui à medida que  $k$  aumenta, se tornando mais contínua a partir de 5 grupos, o que indica a não utilização da quantidade de *cluster* acima deste valor, devido a pouca variabilidade entre os *clusters*, pois a similaridade entre os elementos aumentam. Normalmente o ponto de escolha da quantidade de grupos é baseado quando há uma curva acentuada provocada pela maior distância, neste caso, o ideal seria  $k=4$ . No entanto, não fica claro a escolha do número de *clusters*, pois  $k=3$  também poderia ser uma boa opção. Portanto, uma avaliação mais objetiva é uma boa indicação para determinação da quantidade de grupos, como o índice *Silhouette* discutido anteriormente na Seção 3.4.2.

O índice *Silhouette* aplicado aos dados de  $T_{max}$  (Figura 4.2a) indicou uma melhor configuração para três *clusters* com índice médio de 0,576, apresentando poucas áreas de conflitos (valores próximos à -1). Destaca-se que para quatro *clusters*, este índice diminui para 0,446. Apesar de ter melhor caracterizado regiões como a Cordilheira dos Andes, a análise com  $k=4$  apresentou valores mais próximos a -1, indicando mais conflitos entre as regiões (ver Figura A.1 no Apêndice A). A medida que se aumenta o número de grupos, menor se torna o índice, o que condiz com a Figura 4.1.

Os grupos definidos foram espacializados sobre a área de estudo, conforme Figura 4.2b. Pôde-se notar que a caracterização de cada *cluster* é influenciada pelo relevo da AS e os padrões de circulação atmosférica. O regime climatológico da temperatura nesta época do ano é caracterizado por temperaturas mais elevadas no norte e mais baixas no extremo sul, este último sendo mais influenciado pela atuação de sistemas

Figura 4.1 - Soma da distância dos quadrados entre os valores de  $T_{max}$  da reanálise do ERA5 para formação de até 9 *clusters*.

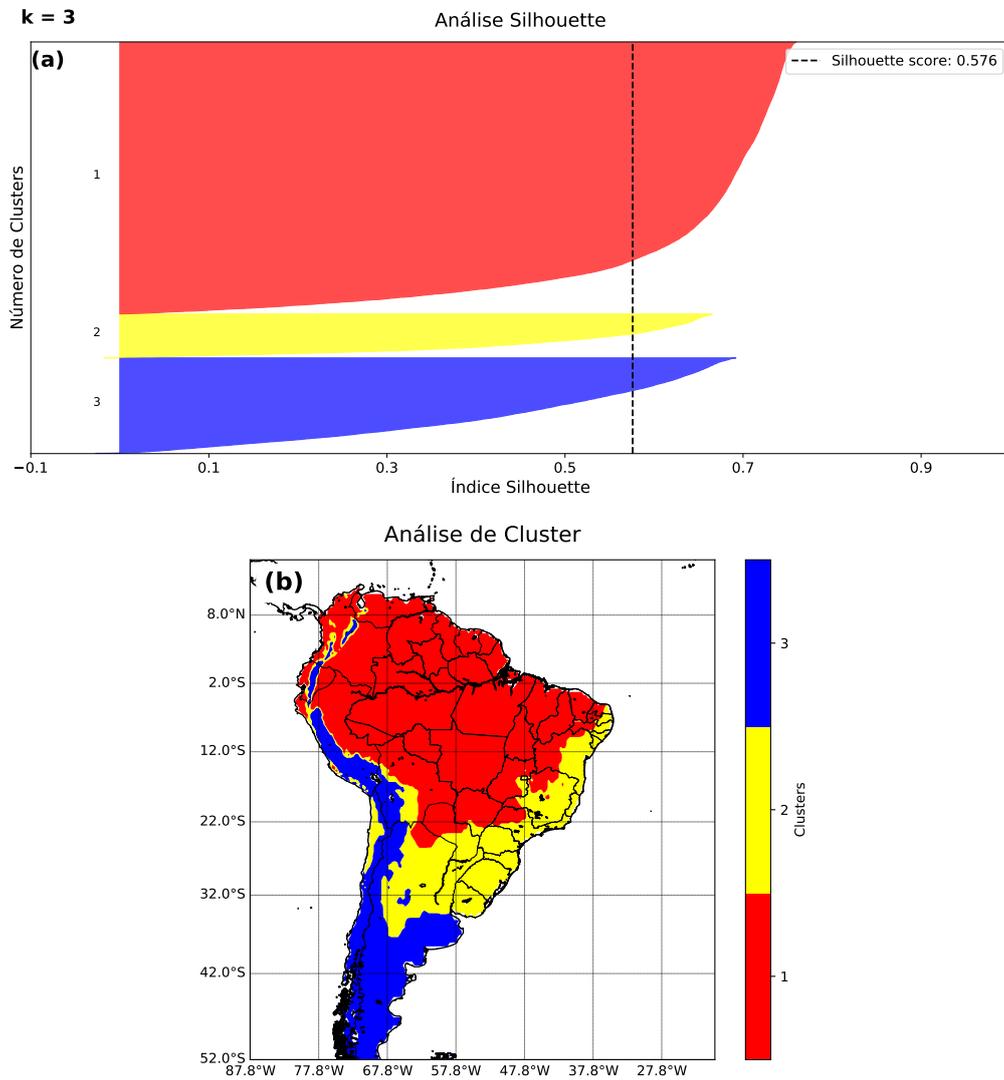


Fonte: Produção da autora.

frontais (REBOITA et al., 2012). O *cluster* 1 (vermelho) definida como Área 1 possui 14.412 pontos de grade (latitude/longitude) e representa grande parte da região tropical da América de Sul. Já a segunda Área determinada pelo *cluster* 2 (amarelo) têm 5.818 pontos de grade, e compreende grande parte da faixa leste e sudeste da AS, além das regiões com relevo elevado próximo à Cordilheira dos Andes. O *cluster* 3 ou Área 3 (azul) têm 4.530 pontos, e representa regiões com topografia mais acentuada, bem como o sul do continente.

A Figura 4.3 mostra as três principais regiões dos *clusters* com mascaras nas pequenas áreas de conflitos entre grupos (destacadas em branco no mapa). Essas áreas de conflitos entre *clusters* ocorrem principalmente em regiões influenciadas por topografias acidentadas acima de 19°S, como pode-se ver na Figura 4.2, onde os *clusters* 1, 2 e 3 se misturam. Algumas regiões próximas dessas áreas de conflito entre os grupos foram mantidas, como a região onde fica localizado o deserto do Atacama no Chile caracterizado no *cluster* 2 (amarelo). Pois esta região tem um padrão de temperatura máxima semelhante ao Sul do Brasil no período em questão, por exemplo, além de estarem na mesma faixa de latitude, apesar da circulação atmosférica serem diferentes em ambas regiões devido a influência dos Andes.

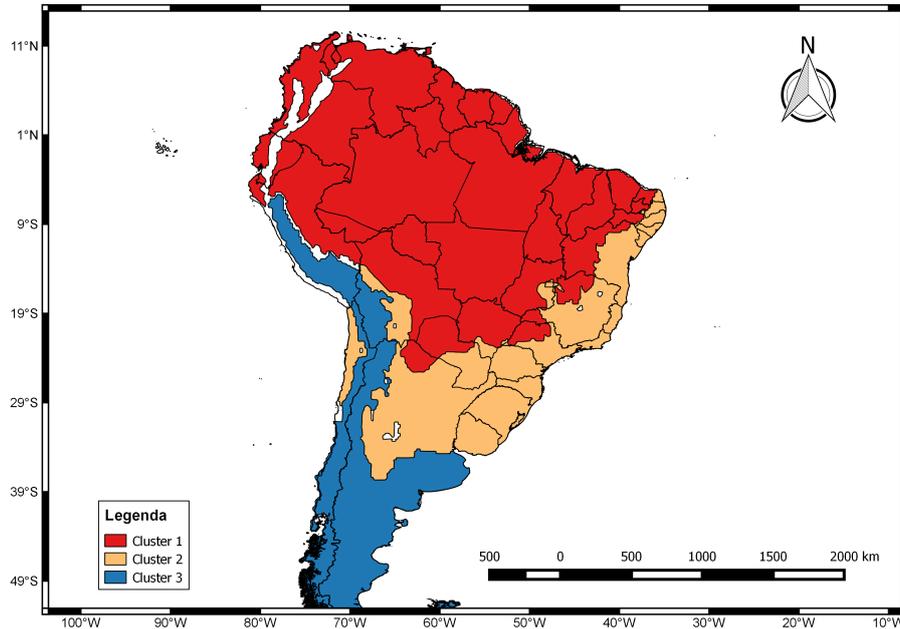
Figura 4.2 - Análise do índice *Silhouette* e *clusters* espacializados na AS da  $T_{max}$  da reanálise do ERA5 para três grupos definidos ( $k=3$ ).



Em (a) tem-se o índice *Silhouette* com três grupos definidos ( $k=3$ ), e em (b) os *clusters* espacializadas sobre a AS. A Área 1 representada pelo *cluster* 1 em vermelho, Área 2 em amarelo, e em azul a Área 3 .

Fonte: Produção da autora.

Figura 4.3 - Máscaras em branco sobre o continente Sul Americano das áreas de conflitos entre *clusters* da  $T_{max}$  da reanálise do ERA5 para três grupos definidos.



A Área 1 representada pelo *cluster* 1 em vermelho, Área 2 em amarelo, e em azul a Área 3 .

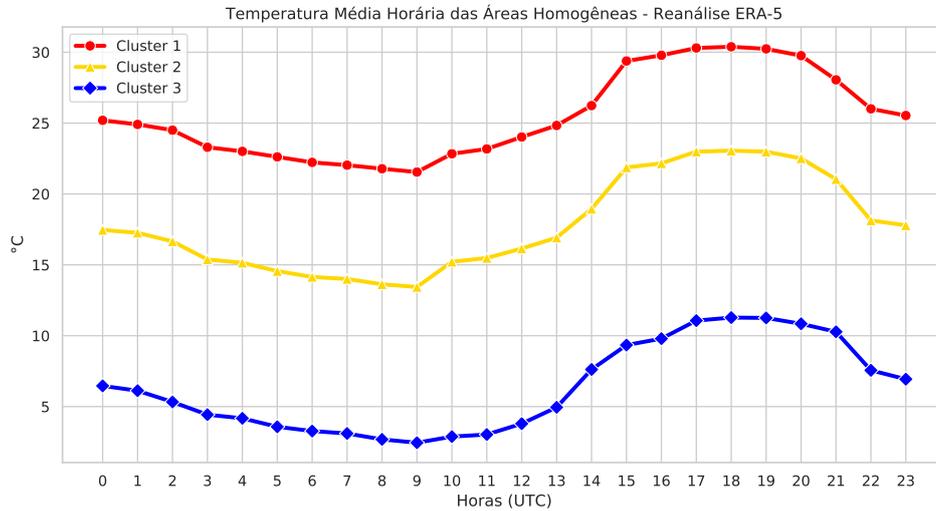
Fonte: Produção da autora.

#### 4.1.1 Análise descritiva da temperatura máxima do ar

Apesar do horário da  $T_{max}$  variar latitudinalmente, o horário sinótico que mais se aproxima da máxima temperatura que ocorre ao longo do dia é às 18 UTC (horário local: 15 horas) nas três áreas definidas (ver Figura 4.4). Ressalta-se que o período de estudo em questão é uma transição de estações inverno-primavera austral, ao se aproximar do equinócio no Hemisfério Sul, os raios solares começam a ficar perpendiculares a linha do equador, o que torna a radiação bem distribuída em todo o hemisfério, ou seja, os dias e noites têm a mesma duração. Nota-se a predominância deste efeito na Figura 4.4, onde o comportamento diurno da  $T_{max}$  nas regiões definidas sobre a AS são semelhantes, com temperaturas mais elevadas na Área 1, amenas na Área 2, e abaixo de 12 °C na Área 3.

Destaca-se que a temperatura do ar é assimilada a cada 6 horas (0000, 0600, 1200, 1800 UTC) no ciclo 41R2 do ECMWF/ERA5 em uma janela de 12 horas (0900 - 2100 UTC) em vários níveis da atmosfera. Independentemente da frequência ser de hora em hora há incertezas nas saídas a cada 3 horas (HERSBACH et al., 2019).

Figura 4.4 - Climatologia horária da Temperatura a 2 metros da reanálise ERA5 nas três regiões homogêneas definidas na análise de *cluster* no período sazonal (JASO: 1979-2018).

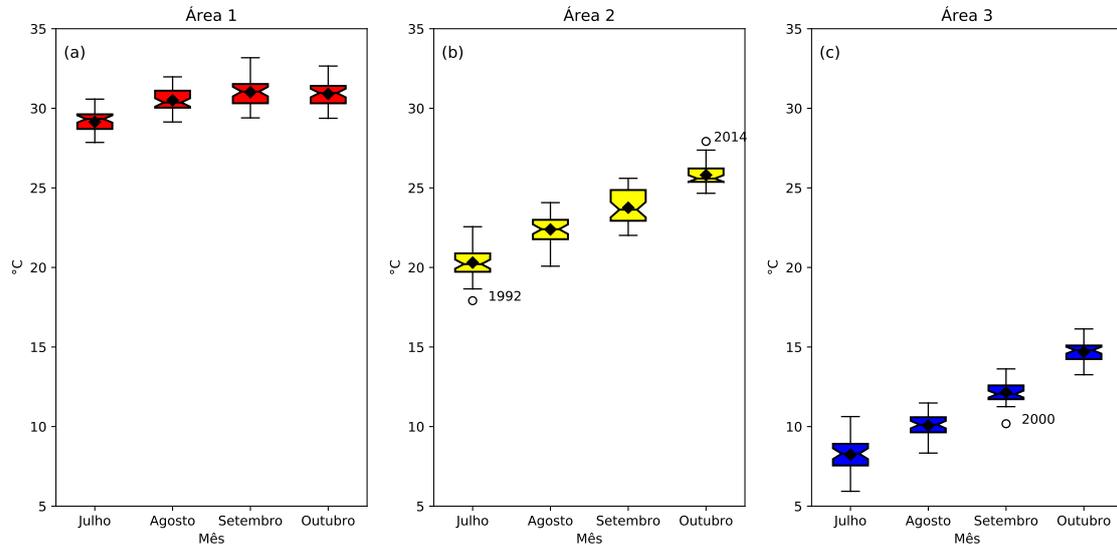


As linhas contínuas coloridas representam as regiões homogêneas definidas pela análise de *cluster* (Área 1 (vermelha); Área 2 (amarela); Área 3 (azul)).

Fonte: Produção da autora.

Por meio de uma análise descritiva da  $T_{max}$ , a Área 1 (Figura 4.5a) tem uma distribuição mensal diferente das demais áreas (Figura 4.5b,c), onde o mês de setembro apresenta maiores temperaturas. Além disso, observa-se que não há extremos associados em todos os meses, devido ser uma região com pouca variação de temperatura durante todo o período. No caso das Áreas 2 e 3, as temperaturas máximas sobem gradativamente ao longo dos meses, sendo o mês de outubro a apresentar valores elevados de  $T_{max}$ . Alguns extremos de temperatura podem ser notados nestas áreas, sendo dois abaixo do percentil de 10% nas regiões 2 e 3, em julho de 1992 e setembro de 2000, respectivamente, e outro extremo acima do percentil de 95% em outubro de 2014 na Área 2. Em média, os percentis de 75% identificados em cada região homogênea de  $T_{max}$  foram de 32°C, 26°C, 14°C para a Área 1, Área 2 e Área 3, respectivamente.

Figura 4.5 - Box-Plot mensal da temperatura máxima da reanálise do ERA5 nas três áreas homogêneas de  $T_{max}$  no período de 1979-2018.



As cores dos box-plots correspondem a cada região homogênea definida na análise de *cluster*, Área 1 (a), Área 2 (b) e Área 3 (c). Os círculos sem preenchimento são os *outlines* da série, a média da temperatura máxima mensal em cada área são representadas pelos losangos preenchidos. Os anos especificados em cada *outline* correspondem aos extremos de  $T_{max}$ .

Fonte: Produção da autora.

#### 4.1.2 Episódios de ondas de calor identificados na América do Sul

Aplicando a metodologia descrita no Capítulo 3 (Seção 3.4.1) para a identificação das ondas de calor nos dados da reanálise ERA5 no período de 1979 a 2019, foram identificados 191 episódios em toda a AS, sendo que 47,12% dos casos ocorreram na Área 2, 35,60% na Área 3, e apenas 17,28% na Área 1. Os resultados em detalhes desse estudo são apresentados no Apêndice B, os quais são discutidos nessa Seção.

Os resultados indicam que estes eventos estão se tornando cada vez mais frequentes, com aumento significativo (ao nível de significância de 5%) da intensidade e persistência em todas as áreas [ver figuras B.6 e B.5 no Apêndice B]. A tendência de aumento fica evidente na Área 1, onde as ondas se tornaram mais frequentes à partir de 2005. Vários estudos apontaram este aumento nas últimas décadas, principalmente à partir de 1980 associado à padrões de circulação anticiclônica e de variabilidade climática, como o Modo Anular Sul (sigla em inglês - SAM), ODP e

eventos de ENSO (El Niño-Oscilação Sul), sendo que estes dois últimos modos não possuem uma relação clara com a ocorrência das ondas de calor (BARRUCAND et al., 2008; BITENCOURT et al., 2016; CECCHERINI et al., 2016; GEIRINHAS et al., 2018; BITENCOURT et al., 2019; REIS et al., 2019).

As regiões com maior frequência de ondas de calor na Área 1 estão entre as latitudes de 2°S-12°S e longitudes de 64°W-53°W, compreendendo grande parte do Norte-Centro do Brasil (sudeste da Amazônia, sul do Pará, Rondônia, Mato Grosso), e Bolívia. No entanto, a maior intensidade se encontra em uma faixa com sentido nordeste-sudoeste fora da região de maior ocorrência, atingindo temperaturas médias de até 40,5°C. Esta configuração se torna contínua na Área 2, sobre o norte da Argentina, onde a intensidade média chega a 37,5°C, e as regiões de maior ocorrência se encontram no Sul do Brasil, norte e centro da Argentina, e sul do Paraguai. Em relação a Área 3, os episódios de ondas de calor ocorrem mais sobre a região da Patagônia chegando a uma intensidade média de 25°C, além da região próxima à Santiago do Chile [Consultar Figura B.4 no Apêndice B]. Estes locais de maior ocorrência podem estar associados à uma diminuição da umidade do solo devido à alterações do saldo radiativo induzida principalmente pelos efeitos antrópicos. Barkhordarian et al. (2019) observou uma tendência de aumento no Deficit de Pressão de Vapor (DPV) no sudeste da Amazônia e região central do Brasil no período agosto-setembro-outubro de 1987-2016 associado ao aquecimento radiativo devido aos gases de efeito estufa e ao efeito local de diminuição de cobertura de nuvens pelo *Black Carbon*, e uso do solo, onde a variabilidade do DPV pode ser explicada predominantemente pela redução de umidade da superfície.

Ressalta-se que no mês de outubro de 2014, onde foi identificado um extremo de  $T_{max}$  acima do percentil de 95% na Área 2, visto na Seção anterior Figura 4.5, foram identificadas duas ondas de calor intensas com duração entre 8 e 10 dias. Como é esperado, não houve episódios nos anos de extremos abaixo do percentil de 10% (1992 e 2000) na Área 2 e Área 3, além disto, os episódios mais intensos ocorrem principalmente nos meses de maior  $T_{max}$  nas três regiões [ver Figura B.3]. Embora os episódios intensos de ondas de calor ocorram predominantemente nos meses de setembro e outubro na AS, mais de 60% dos casos ocorrem nos meses de agosto e setembro na Área 1, acima de 30% em agosto na Área 2, e aproximadamente 60% nos meses de agosto e setembro na Área 3 [Figura B.2]. Bitencourt et al. (2016) identificaram que além do verão austral, a maioria das ocorrências de ondas de calor no Brasil acontecem no trimestre agosto-setembro-outubro nas regiões acima de 15°S, e com maior frequência em outubro abaixo desta latitude.

## 4.2 Avaliação dos episódios de ondas de calor: estudo de casos

Uma série de episódios de ondas de calor foram identificados no período de simulação do modelo BRAMS (JASO: 2016-2018), sendo que apenas dois casos foram selecionados para avaliação na Área 1, região mais afetada pelas queimadas nesse período, onde se encontra o “arco de desflorestamento”, tornando-se uma área mais propícia aos impactos dos aerossóis de queimadas na previsão de curto prazo. O primeiro caso escolhido compreende o período de 10 a 12 de agosto de 2017 em que as previsões integradas com química ainda não estavam estabilizadas (problema de *Spin-up* do modelo), pois esse foi o único período condizente entre as duas referências. Além disso, um segundo caso no período de agosto de 2016 foi avaliado somente com a referência do ERA5, uma vez que não foi identificada onda de calor na análise do GFS. Os resultados da avaliação orientada a objeto das previsões de ondas de calor estão organizados da seguinte forma: a previsão integrada é evidenciada com o intuito de apresentar o impacto da química e conseqüentemente dos aerossóis de queimadas na previsão e os seus impactos na morfologia da onda de calor. Na Seção a seguir, é mostrada a avaliação do primeiro caso no MODE/SCANTEC levando-se em consideração as referências adotadas.

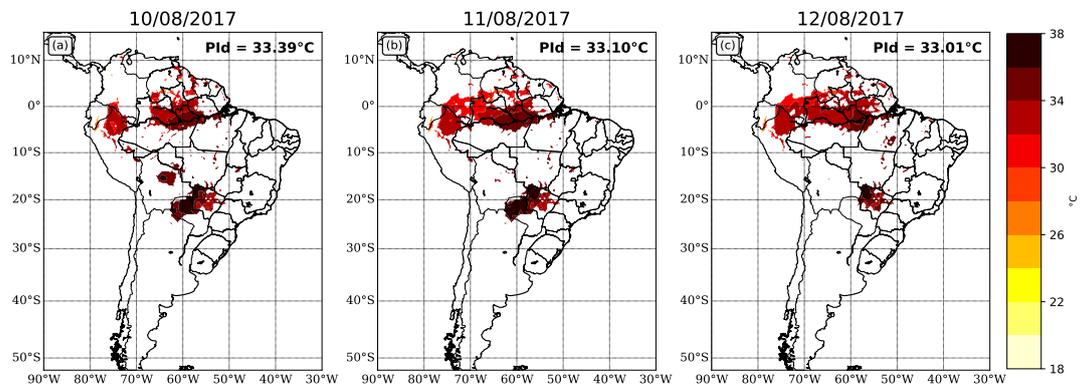
### 4.2.1 Análise do GFS vs. reanálise do ERA5: caso de agosto de 2017

O período de ocorrência da onda de calor identificada nos dados de referência possui uma defasagem na duração. Na análise do GFS, foi identificado um episódio entre os dias 10 e 12 de agosto de 2017, já no ERA5 foi encontrado um evento que persistiu por 19 dias, desde o dia 02 de agosto até o dia 20 de agosto de 2017.

A onda de calor identificada no GFS (Figura 4.6) apresenta um comportamento similar ao episódio encontrado na reanálise do ERA5 (Figura 4.7), principalmente sobre o norte da AS, Mato Grosso do Sul e norte do Paraguai. Apesar de na análise haver a diminuição considerável da extensão da onda de calor em relação ao ERA5 que representa uma faixa de onda localizada sobre a região central do continente com direção nordeste-sudoeste. Em relação à região norte, o outro foco da onda cresce gradativamente ao longo dos dias. O mesmo pode ser observado na análise do GFS, mas de uma forma mais lenta e menos expandida. Os limiares de intensidade identificados na análise do GFS e reanálise do ERA5 foram de 33, 17 °C e de 33, 69 °C, respectivamente (aqui foi considerado apenas o PI entre os dias avaliados). Além disso, os PId obtidos indicam que a onda de calor em ambas referências são mais intensas no primeiro dia, se tornando mais fraca no dia 12 de agosto.

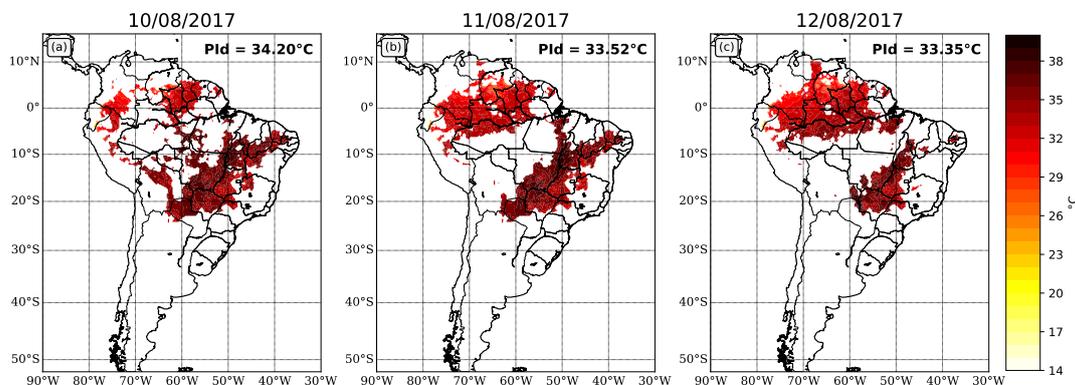
Na análise do GFS (Figura 4.6), os núcleos mais intensos das ondas de calor com aproximadamente 38 °C, são encontrados sobre a região central do principal afluente do rio Amazonas, norte do Paraguai e Mato Grosso do Sul no Brasil. Já na reanálise do ERA5, os núcleos intensos estão sobre a região central da AS, na faixa mencionada anteriormente, principalmente sobre o noroeste do Piauí, sul de Mato Grosso, e no ponto tríplice da fronteira entre a Bolívia, Paraguai e Brasil, atingindo aproximadamente 40 °C.

Figura 4.6 - Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 10 a 12 de agosto de 2017 na análise do GFS às 18 UTC.



Fonte: Produção da autora.

Figura 4.7 - Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 10 a 12 de agosto de 2017 na reanálise ERA5 às 18 UTC.



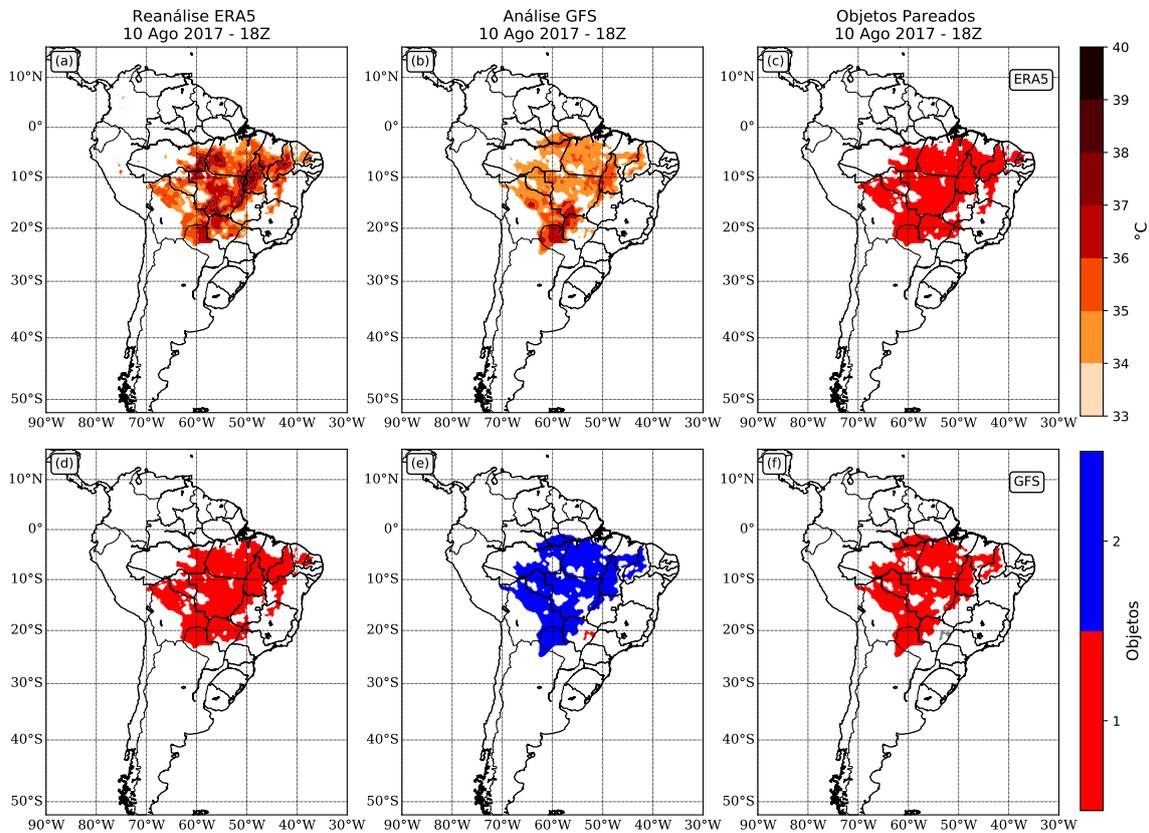
Fonte: Produção da autora.

Na avaliação realizada entre as referências no SCANTEC, a reanálise do ERA5 foi estabelecida como a verdade, e o limiar de intensidade aplicado para identificação dos objetos no MODE foi de 33,69 °C. Foi identificado um objeto no campo da reanálise (Figura 4.8d) e dois objetos no campo da análise do GFS (Figura 4.8e) no dia 10 de agosto de 2017. Os objetos pareados identificados em vermelho nas Figuras 4.8c e 4.8f são similares entre as referências, apesar da expansão do objeto ser menor na análise do GFS, além de estar deslocado para norte em relação à reanálise do ERA5. Nos campos restaurados da temperatura a 2 metros (Figura 4.8a,b) observa-se que a intensidade da onda de calor no ERA5 é maior em relação à análise do GFS com núcleos de até 40 °C, como visto anteriormente.

Ressalta-se que a configuração da onda de calor detectada no algoritmo de identificação do Python pode se apresentar diferente na avaliação orientada a objeto do SCANTEC, pois apenas o limiar de intensidade da onda é aplicado no MODE, não levando em consideração o critério mínimo de 25% dos pontos obedecerem os critérios estabelecidos anteriormente na Seção 3.4.1. Logo, regiões que não cumpriram o critério de  $T_{max} \geq \bar{T}_{max} + \sigma$  em no mínimo de três dias consecutivos irão aparecer no MODE.

Com a aplicação do limiar no dia 12 de agosto, foi identificado um objeto principal (em vermelho) na reanálise do ERA5 na faixa central da AS no sentido nordeste-sudoeste, e outros cinco objetos são identificados, um sobre o noroeste da Venezuela, três sobre o afluente principal do Rio Amazonas, e outro objeto no norte da Bolí-

Figura 4.8 - Campos de restauração da  $T_{max}$  em  $^{\circ}\text{C}$  dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 10 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS.



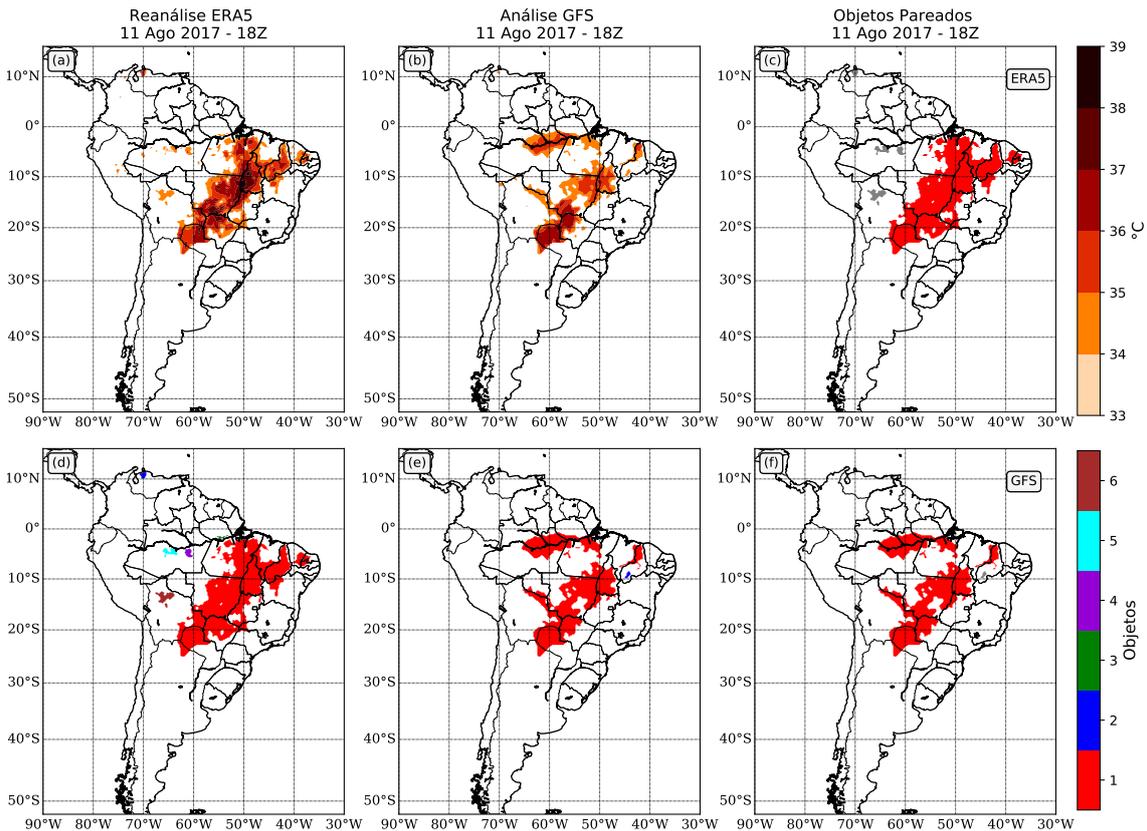
Campos restaurados em (a) e (b), e campos dos objetos em (d) e (e) na reanálise do ERA5 e análise do GFS, respectivamente. Nas figuras (c) e (f) tem-se os objetos pareados encontrados entre a análise do GFS e reanálise do ERA5. Os objetos não pareados são representados pela cor cinza.

Fonte: Produção da autora.

via (Figura 4.9d). Na análise do GFS, apenas dois objetos são identificados (Figura 4.9e), um principal (vermelho) sobre a faixa central da AS se estendendo até o afluente principal do Rio Amazonas, e outro objeto (azul) no sul do estado do Piauí no Brasil. Os objetos pareados foram os principais objetos encontrados nos campos de referências (Figura 4.9c,f). Como visto anteriormente, os núcleos com maior intensidade se encontram na reanálise do ERA5 com temperaturas até  $39^{\circ}\text{C}$  (Figura 4.9a), em relação à análise do GFS esses núcleos chegam até aproximadamente  $37^{\circ}\text{C}$  (Figura 4.9b). O mesmo é observado para o dia 12 de agosto nos campos restaurados da temperatura a 2 metros (Figura 4.9a,b). Em relação ao primeiro dia de avaliação

da onda de calor, o evento teve uma diminuição de 1 °C nos núcleos mais intensos nos dias consecutivos, mostrando que a onda estava perdendo força em ambas referências.

Figura 4.9 - Campos de restauração da  $T_{max}$  em °C dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 11 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS.



Campos restaurados em (a) e (b), e campos dos objetos em (d) e (e) na reanálise do ERA5 e análise do GFS, respectivamente. Nas figuras (c) e (f) tem-se os objetos pareados encontrados entre a análise do GFS e reanálise do ERA5. Os objetos não pareados são representados pela cor cinza.

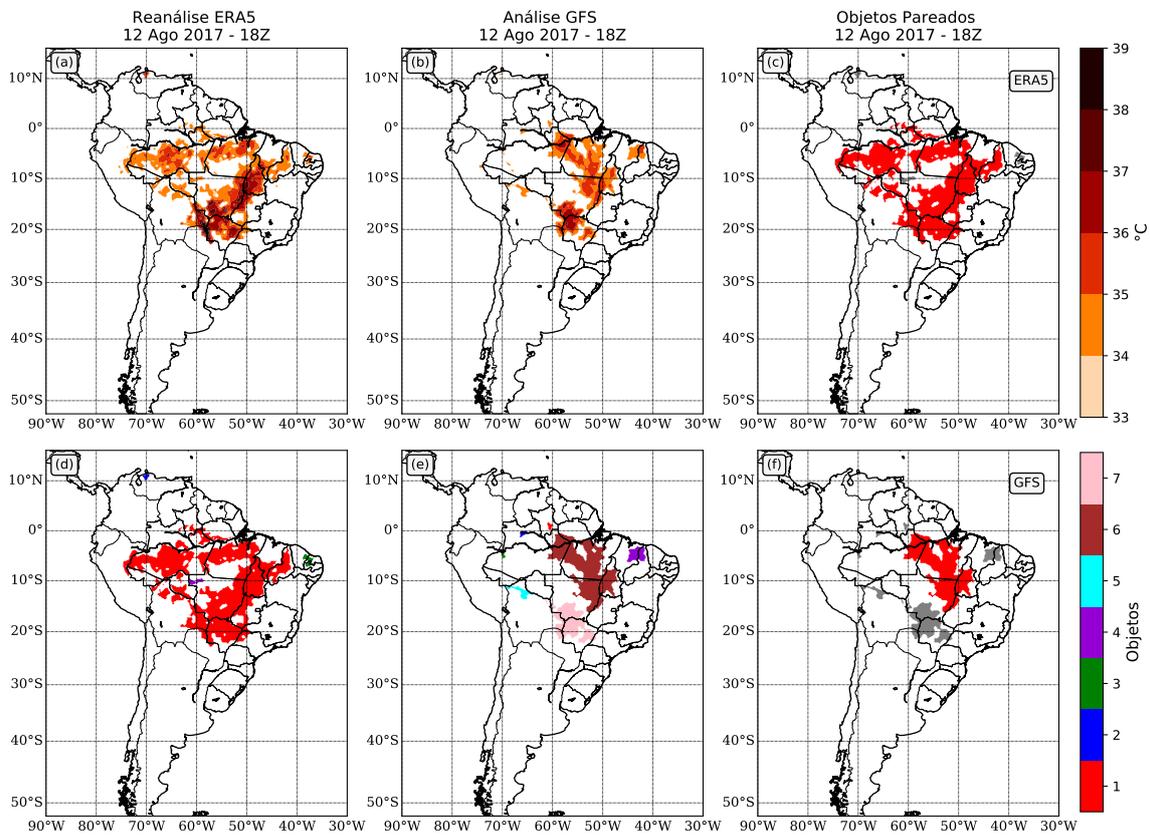
Fonte: Produção da autora.

No terceiro dia do evento, as referências diferem em relação a quantidade e extensão de objetos identificados no MODE, apresentando mais objetos na análise. Foram identificados quatro objetos no campo da reanálise (Figura 4.10d), e sete objetos menores na análise (Figura 4.10e). Nas Figuras 4.10c,f, os objetos pareados entre as

referências diferem bastante, tanto na posição quanto na extensão.

Os atributos dos objetos na Tabela 4.1 mostram claramente o quão os objetos correspondem ao longo do período de ocorrência da onda de calor, sendo melhor para o primeiro dia do evento, apresentando maior Razão da Área de Intersecção, Razão das Áreas, menor Diferença de Centroide e Ângulo de Orientação, com IT de 0,91, como visto anteriormente na Figura 4.8. Ao longo do tempo, as duas referências começam a divergir, e com isso o IT dos objetos tende a diminuir.

Figura 4.10 - Campos de restauração da  $T_{max}$  em °C dos objetos de onda de calor identificados no MODE/SCANTEC e objetos pareados para o dia 12 de agosto de 2017 às 18 UTC na reanálise do ERA5 e análise do GFS.



Campos restaurados em (a) e (b), e campos dos objetos em (d) e (e) na reanálise do ERA5 e análise do GFS, respectivamente. Nas figuras (c) e (f) tem-se os objetos pareados encontrados entre a análise do GFS e reanálise do ERA5. Os objetos não pareados são representados pela cor cinza.

Fonte: Produção da autora.

Tabela 4.1 - Atributos dos objetos pareados identificados entre a reanálise do ERA5 e análise do GFS no período de 10 a 12 de agosto de 2017.

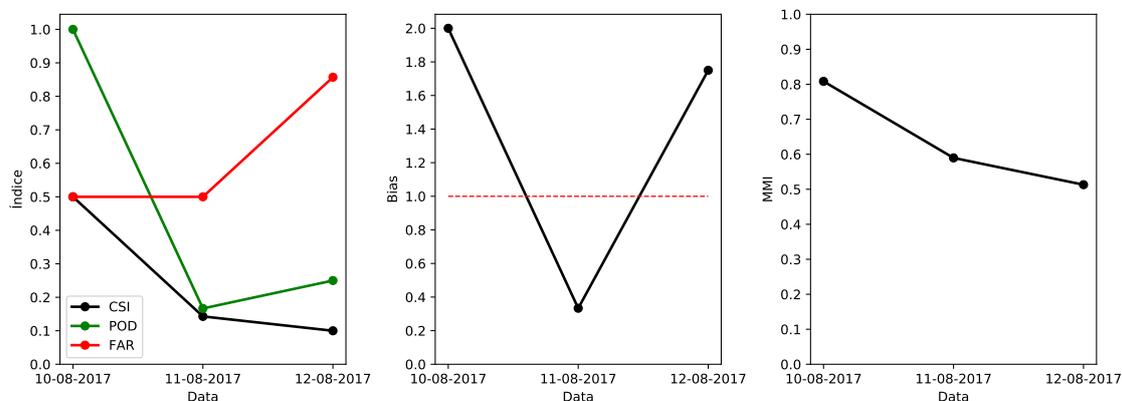
<b>Atributos dos Objetos Pareados</b>	<b>10-08-2017</b>	<b>11-08-2017</b>	<b>12-08-2017</b>
Razão Área	0,88	0,83	0,35
Diferença Centróide (pontos)	13,93	19,92	21,26
Diferença Orientação (°)	0,16	0,37	0,87
Razão Área de Intersecção	0,60	0,45	0,22
Interesse Total (IT)	0,91	0,87	0,83

Fonte: Produção da autora.

Todos os índices CSI, POD, FAR, Bias e MMI apresentados na Figura 4.11 também indicam que no primeiro dia do evento as referências correspondem bem entre si, com probabilidade de detecção igual à 1, 50% dos objetos foram “previstos” corretamente na análise do GFS, e com 50% de falsos alarmes, devido ao segundo objeto que aparece na análise (visto na Figura 4.8e). Nos dias 11 e 12 de agosto, o CSI diminui gradativamente, tendendo à zero, indicando que os objetos entre as referências não se sobrepõe. Já em relação ao POD, ele é menor no segundo dia do evento em comparação com o dia 12 de agosto, pois no dia 11 há mais falhas do que falsos alarmes (ver Tabela 4.3). No entanto, no dia 12 de agosto, os falsos alarmes são maiores que as falhas, e por isso o FAR chega próximo de 0,9 (ver Tabela 4.4). O Bias mostra que nos dias 10 e 12, a análise do GFS superestima a quantidade de objetos que aparece no ERA5, isto pode ser claramente visto nas Figuras 4.8d,e; 4.10d,e, respectivamente. Entretanto, no dia 11 de agosto, há uma subestimativa dos objetos do GFS em relação ao ERA5, como visto na Figura 4.9d,e.

A MMI é outra forma de avaliar, de forma resumida e útil, todas essas informações, baseando-se apenas nos atributos utilizados no cálculo do IT, sem aplicação de um limiar e sem levar em consideração todos os objetos pareados. Ressalta-se que o máximo interesse observado e o máximo interesse previsto são penalizados quando há falhas e falsos alarmes, respectivamente, tornando o valor da MMI menor. Isto é observado na Figura 4.11 da MMI, onde os valores desta métrica decrescem com o passar dos dias, sendo mais alto no primeiro dia do evento, e menor nos dias posteriores devido a quantidade de falhas e falsos alarmes.

Figura 4.11 - Índices estatísticos CSI, POD, FAR, Bias e MMI dos objetos identificados entre a reanálise do ERA5 e análise do GFS no período de ocorrência do episódio de agosto de 2017.



A linha vermelha tracejada na figura do Bias representa o limite 1 de que a previsão foi “perfeita”.

Fonte: Produção da autora.

Tabela 4.2 - Contingência dos objetos no dia 10 de agosto de 2017. Tabela 4.3 - Contingência dos objetos no dia 11 de agosto de 2017.

Análise GFS	Reanálise ERA5	
	Sim	Não
Sim	1	1
Não	0	-

Análise GFS	Reanálise ERA5	
	Sim	Não
Sim	1	1
Não	5	-

Tabela 4.4 - Contingência dos objetos no dia 12 de agosto de 2017.

Análise GFS	Reanálise ERA5	
	Sim	Não
Sim	1	6
Não	3	-

#### 4.2.2 Avaliação das previsões de ondas de calor sem e com a inclusão da química atmosférica: caso de agosto de 2017

As previsões foram avaliadas para os tempos de integração das 18, 42 e 66 horas à partir da inicialização do dia 09 até o dia 12 de agosto de 2017 às 00 UTC. Por exemplo, a previsão com início no dia 09 de agosto às 42 e 66 horas de integração

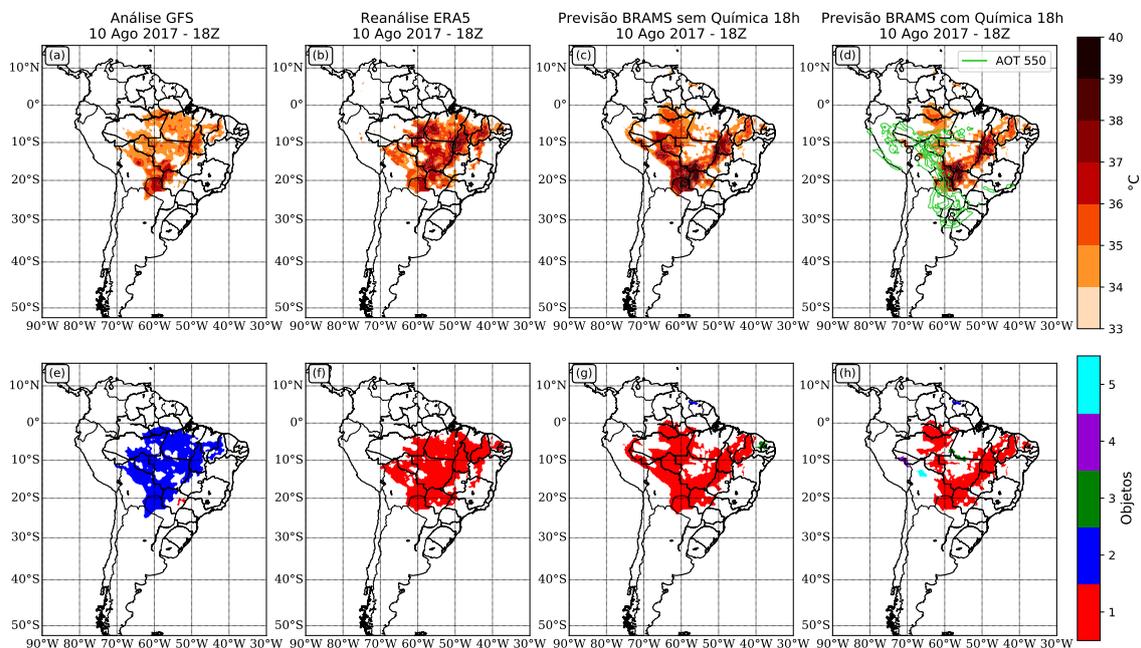
foi escolhida, pois corresponde aos dias 10 e 11 de agosto às 18 UTC em que ocorreu o episódio de onda de calor, respectivamente. A seguir tem-se uma visão geral de como esses objetos se comportam em termos de extensão e intensidade nas previsões meteorológicas e integradas com química ao longo do tempo no modelo BRAMS. As figuras dos objetos das referências são evidenciadas novamente nesta Seção para efeito de comparação com as previsões.

Os objetos identificados nas referências e previsões de 18 horas do dia 10 de agosto na Figura 4.12 foram definidos por meio do limiar de intensidade da onda de calor da reanálise do ERA5 entre os dias 10 e 12 de agosto de 2017, o mesmo utilizado anteriormente na Seção 4.2.1. A previsão sem a inclusão da química (Figura 4.12c) apresenta núcleos mais intensos da onda de calor com  $\approx 40^\circ\text{C}$  sobre o norte do Paraguai e noroeste do Mato Grosso do Sul no Brasil. No entanto, a análise do GFS (Figura 4.12a) mostra um núcleo entre  $36^\circ\text{C}$  e  $37^\circ\text{C}$  sobre essas regiões, uma diferença de aproximadamente  $3^\circ\text{C}$ . Em relação ao ERA5 (Figura 4.12b), o segundo núcleo intenso das previsões sem química e integrada com química atmosférica visto nas Figuras 4.12c,d, se assemelha ao núcleo mais intenso desta referência que se encontra sob o ponto tríplice das fronteiras dos estados de Tocantins, Mato Grosso e Goiás no Brasil, tanto em termos de intensidade quanto de localização. Além disso, a extensão da onda de calor identificada nas previsões se assemelha às referências.

Os formatos dos objetos de ondas de calor detectados nas previsões pelo MODE são similares, apesar da previsão integrada com química apresentar mais objetos (Figura 4.12h) em relação a previsão sem química (Figura 4.12g). Com destaque ao objeto maior em vermelho nas duas previsões, nota-se que ele está mais expandido à nordeste da Bolívia e no estado do Acre no Brasil no campo de previsão sem química. Já na previsão integrada com química, esta área diminui criando novos objetos, como também na região central do objeto. Sugere-se que isto ocorre devido uma maior Espessura Óptica de Aerossóis (sigla AOT do inglês - *Aerosol Optical Thickness*) nessas regiões com valores variando de 0,6 a 1,8 (linhas de contorno em verde na Figura 4.12d), onde o efeito direto predomina, ou seja, grande parte da radiação solar incidente é refletida de volta para o espaço ou absorvida na atmosfera pelos aerossóis, diminuindo a radiação de onda curta que chega na superfície (ROSÁRIO et al., 2013), conseqüentemente a temperatura do ar próxima à superfície se torna menor (ARTAXO et al., 2006; KOLUSU et al., 2015; ARCHER-NICHOLLS et al., 2016; MOREIRA et al., 2017).

Na previsão integrada com química, além de diminuir a extensão da onda de calor,

Figura 4.12 - Objetos de onda de calor identificados no MODE/SCANTEC com seus respectivos campos restaurados de  $T_{max}$  na análise do GFS e reanálise do ERA5 e para a previsão de 18h válidas para o dia 10 de agosto de 2017 às 18 UTC sem e com a modelagem química integrada e o campo de AOT em 550 nm.



(a) Campos restaurados da temperatura a 2 metros dos objetos na análise do GFS e (b) reanálise do ERA5 às 18 UTC, (c) previsão do BRAMS sem química e (d) integrada com química, juntamente com o campo de AOT em 550 nm (contorno em verde). As figuras (e) a (h) representam os campos de objetos identificados para a análise do GFS, reanálise do ERA5, previsão sem química, e integrada com química, respectivamente, onde cada cor corresponde à um determinado objeto.

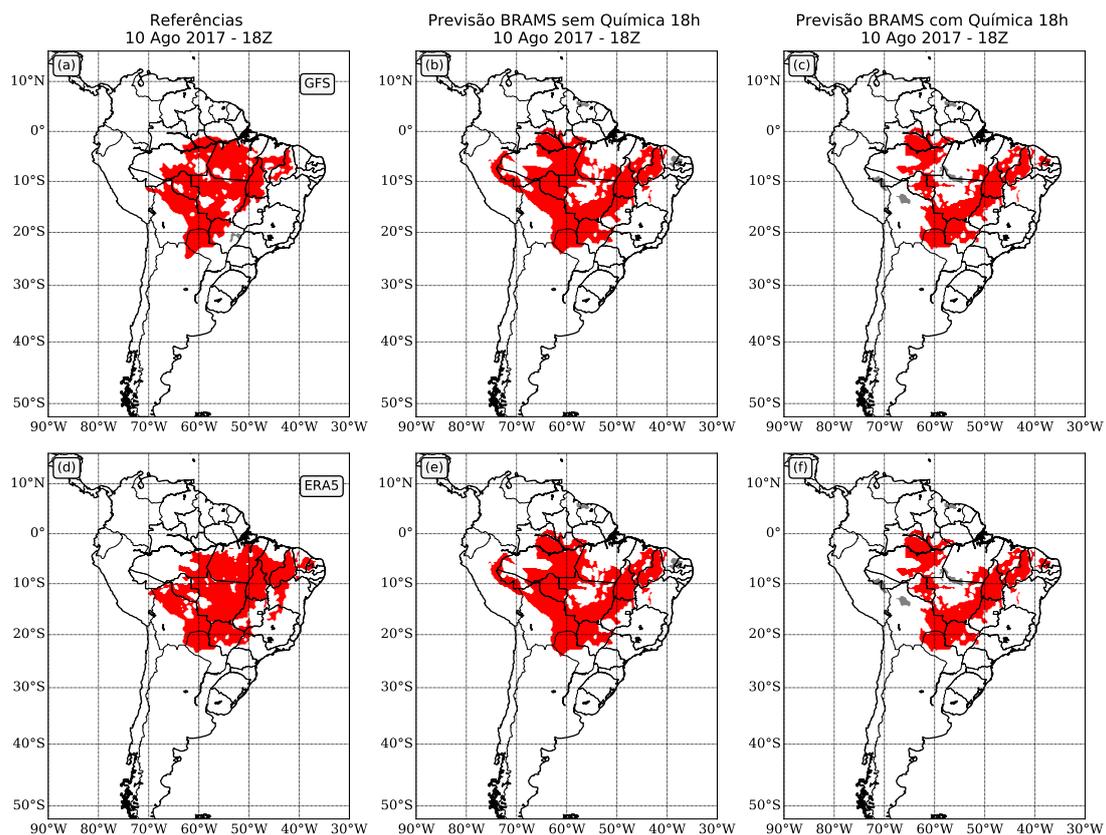
Fonte: Produção da autora.

há uma diminuição de aproximadamente  $3^{\circ}\text{C}$  na temperatura do núcleo mais intenso observado na previsão sem química. Entretanto, nos locais não afetados pelos aerossóis, a intensidade e o formato da onda são semelhantes entre as previsões, principalmente na faixa com orientação nordeste-sudoeste. Este padrão se mantém em todos os tempos de integração avaliados. Ressalta-se que as previsões sem química e integrada com a química atmosférica conseguem captar o enfraquecimento da onda de calor em termos de abrangência espacial no último dia do episódio. No entanto, a quantidade de objetos aumenta nas previsões de 18, 42 e 66 horas, sendo esse aumento mais acentuado nas previsões integradas com química.

O pareamento entre os objetos das referências e previsões se baseiam principal-

mente nos cálculos dos atributos e IT visto anteriormente na Seção 2.1.1. Os objetos pareados (isto é, objetos previstos que foram encontrados objetos semelhantes na referência) na Figura 4.13 são representados pela cor vermelha, e em cor cinza são os objetos não pareados. Apenas um objeto foi associado entre as referências e previsões de 18 horas do dia 10 de agosto. Em relação a todos os tempos de integração, o objeto principal pareado que aparece entre as referências e previsões segue o padrão nordeste-sudoeste que se estende desde o estado do Piauí no Brasil até o norte do Paraguai. Nas previsões de mais longo prazo, de 42 e 66 horas, têm-se um aumento do número de objetos pareados, principalmente entre a análise do GFS e a previsão integrada com química.

Figura 4.13 - Objetos de ondas de calor nas previsões de 18h sem química e integrada com química pareados pelo MODE/SCANTEC como os objetos presentes nas referências GFS e ERA5 para 10 de agosto de 2017 às 18 UTC.

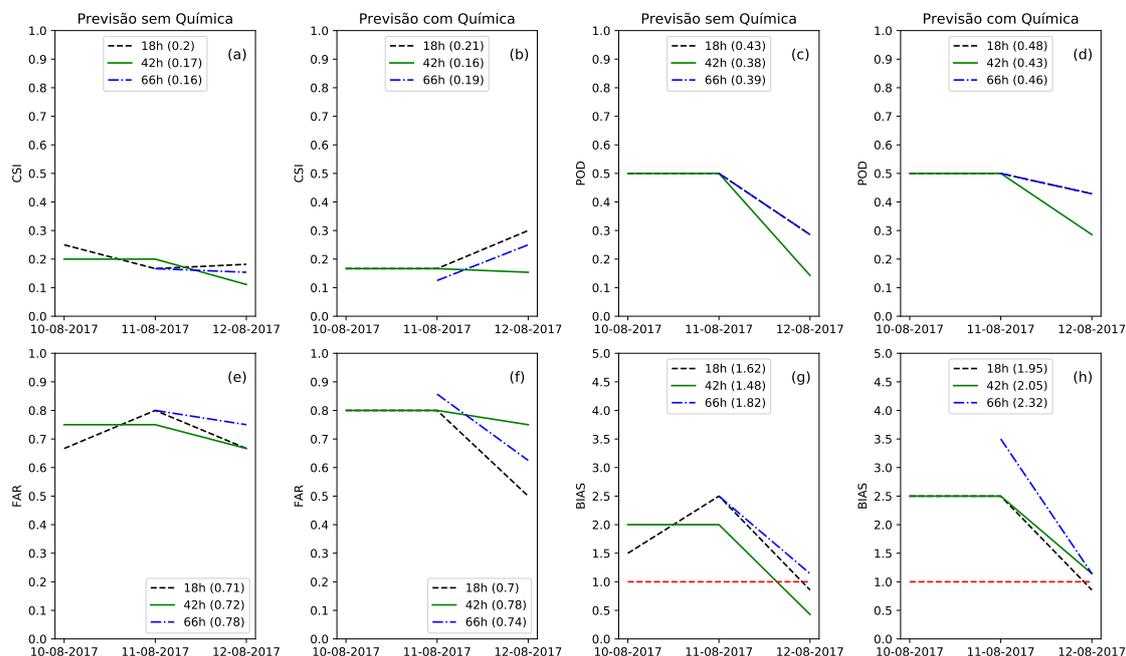


As figuras mostram os objetos pareados em vermelho entre (a) a análise do GFS e (b) a previsão sem química, e (c) previsão integrada com química, (d) reanálise do ERA5 e (e) previsão sem química, e (f) previsão integrada com química. Os objetos não pareados são representados pela cor cinza.

Fonte: Produção da autora.

Apesar do aumento de objetos no último dia do episódio da onda de calor, a previsão integrada com química apresentou melhor desempenho, como indica os índices estatísticos da avaliação orientada a objeto (Figura 4.14), principalmente para as previsões de 18 e 66 horas devido a maior quantidade de objetos pareados tendo como referência a análise do GFS, isso em relação a previsão sem química. Este resultado impacta na média geral dos índices entre os dias do evento, por exemplo, no último dia do episódio (12 de agosto), o CSI e o FAR foram melhor para a previsão integrada com química, mas as diferenças entre as previsões para este dia são pequenas, aproximadamente 0,1. A POD mostra que 50% da onda de calor foi prevista corretamente nos dias 10 e 11 de agosto em ambas previsões, embora a probabilidade diminua no último dia, a previsão integrada com química tem melhor desempenho em todos os horários de integração. No entanto, o Bias mostrou-se maior na previsão integrada com química nos três horários de integração, devido a quantidade elevada de objetos em relação a análise do GFS, sendo que no dia 12, o Bias foi próximo de 1, ou seja, indicando que a previsão foi quase “perfeita” nas duas previsões, pois a quantidade de objetos previstos foi aproximadamente igual a quantidade de objetos observados na referência.

Figura 4.14 - Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada, usando como referência as análises do GFS para o caso de agosto de 2017.



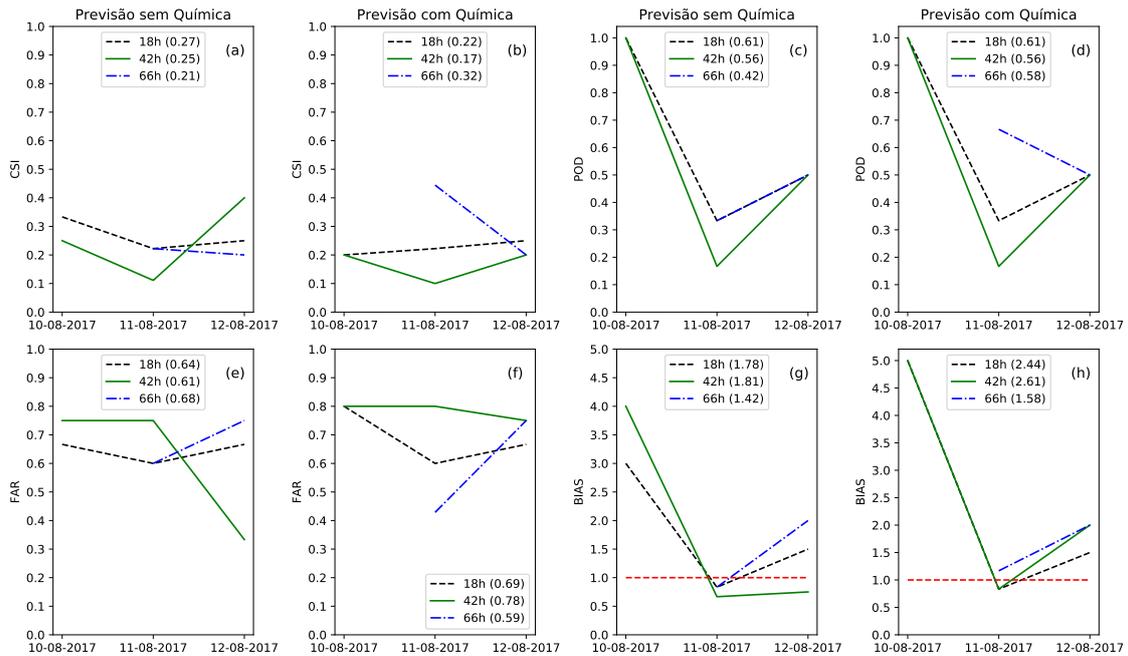
A linha vermelha tracejada na figura do Bias representa o limite 1 de que a previsão foi “perfeita”.

Fonte: Produção da autora.

Como visto na figura anterior, a previsão integrada com química de 66 horas apresenta um bom desempenho nos índices estatísticos dos objetos em relação a reanálise do ERA5 (Figura 4.15). Isto é devido ao fato que no dia 11 de agosto, a previsão integrada com química apresenta melhor desempenho do que a previsão sem química, pois o CSI é de aproximadamente 0,5 e com 70% de objetos previstos corretamente, com maior quantidade de objetos pareados com a análise do ERA5, apresentando um menor valor de FAR e Bias próximo de 1. Já em relação ao dia 12 de agosto, os índices das previsões são aproximadamente iguais. Por outro lado, a previsão sem química foi melhor para as 18 e 42 horas, principalmente no primeiro dia do evento, apesar de apresentar mais falsos alarmes, ou seja, uma maior quantidade de objetos em relação ao campo de referência com Bias igual à 3 e 4, respectivamente. No dia 10, a POD foi igual à 1 às 18 e 42 horas na duas previsões, pois a quantidade de objetos pareados foi igual aos objetos observados na referência. Nota-se também que este índice é igual em ambas previsões em todo o período do evento, isto ocorre de-

vido a proporção dos objetos observados no campo de referência ser igual nas duas previsões com a mesma quantidade de objetos pareados.

Figura 4.15 - Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada, usando como referência a reanálise do ERA5 para o caso de agosto de 2017.



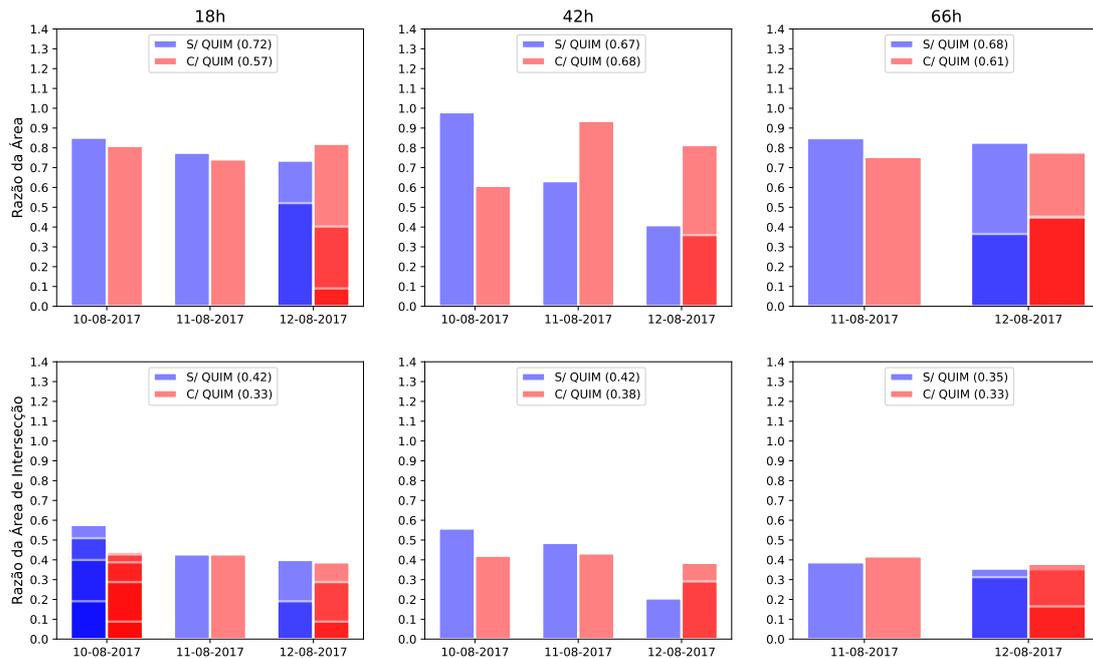
A linha vermelha tracejada na figura do Bias representa o limite 1 de que a previsão foi “perfeita”.

Fonte: Produção da autora.

A Figura 4.16 mostra os valores dos atributos, Razão das Áreas e Razão da Área de Intersecção dos objetos pareados pelo MODE entre a análise do GFS e as previsões de 18, 42 e 66 horas com e sem química. Os valores entre parênteses nos gráficos são as médias globais dos atributos de cada previsão. Em geral, a previsão sem química representa melhor as razões das áreas dos objetos pareados. No entanto, cabe destacar que no tempo de integração das 42 horas na Razão das Áreas, as previsões integradas com química nos dias 11 e 12 apresentou um desempenho melhor do que as previsões sem a química, embora essa melhora tenha impactado na Razão da Área de Intersecção apenas no dia 12. Nota-se que a Razão da Área de Intersecção diminui mais no último dia do episódio, indicando que a área de intersecção se torna

menor entre os objetos observados e previstos, devido a diminuição da extensão dos objetos nos campos de previsão principalmente.

Figura 4.16 - Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42 e 66 hs sem e com a modelagem química integrada pareados em relação a análise do GFS para o caso de agosto de 2017.



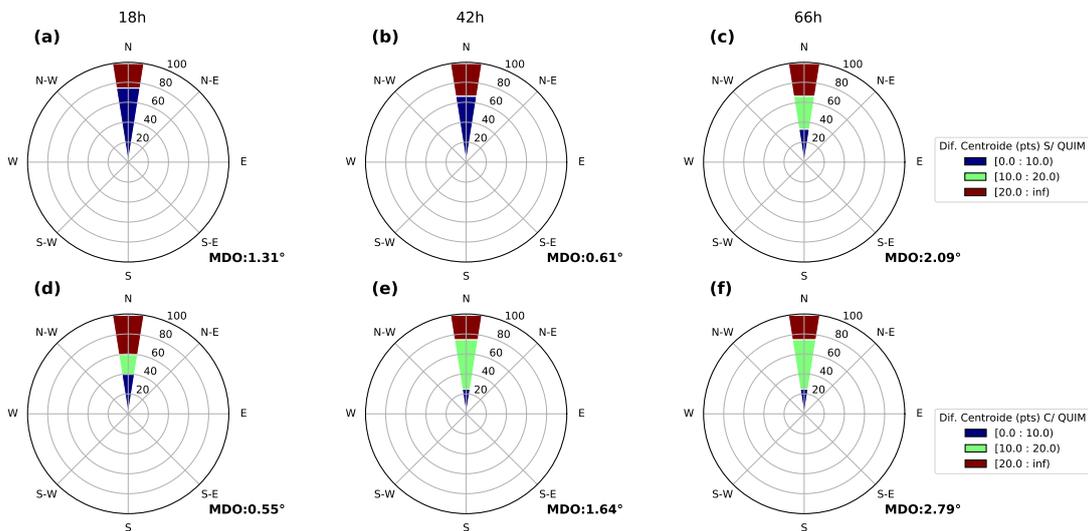
Previsão de 18, 42 e 66 hs do BRAMS sem química (barra azul), e integrada com química (barra vermelha) para o período de 10 a 12 de agosto de 2017. Cada barra representa um objeto pareado entre as previsões e referência do GFS nos respectivos tempos de integração.

Fonte: Produção da autora.

A Diferença do Ângulo de Orientação entre os objetos pareados do GFS e previsões sem química e integrada com química é predominantemente de norte na Figura 4.17 do *windrose*, o mesmo pode ser visto na Figura 4.19 com a reanálise do ERA5. É notável que a frequência de pontos entre 0 e 10 (pétala azul) é maior nas previsões sem química. Na previsão integrada com química de 18 horas, metade da Diferença de Centroides entre os objetos pareados é maior que 20 pontos. No entanto, a Média da Diferença do Ângulo de Orientação (MDO) é menor para esta previsão com valor de  $0,55^\circ$  em relação à previsão sem química.

Ressalta-se que com o aumento do tempo de integração do modelo BRAMS (42, 66 horas), a frequência acima de 20 pontos da Diferença de Centroide diminui na previsão integrada com química (4.17e,f), o contrário é visto na previsão sem química na Figura 4.17b,c. Esse resultado é esperado, levando em consideração que a previsão integrada com química não está estabilizada para esse caso. Já a previsão sem química (estabilizada) apresenta uma degradação em prever a posição da onda de calor ao longo do tempo de integração. O que é de se esperar quando se trata de modelos numéricos, pois com o aumento do tempo de integração, o erro da previsão pode aumentar.

Figura 4.17 - Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a análise do GFS e as previsões das 18, 42 e 66 hs sem e com a química integrada para o caso de agosto de 2017.



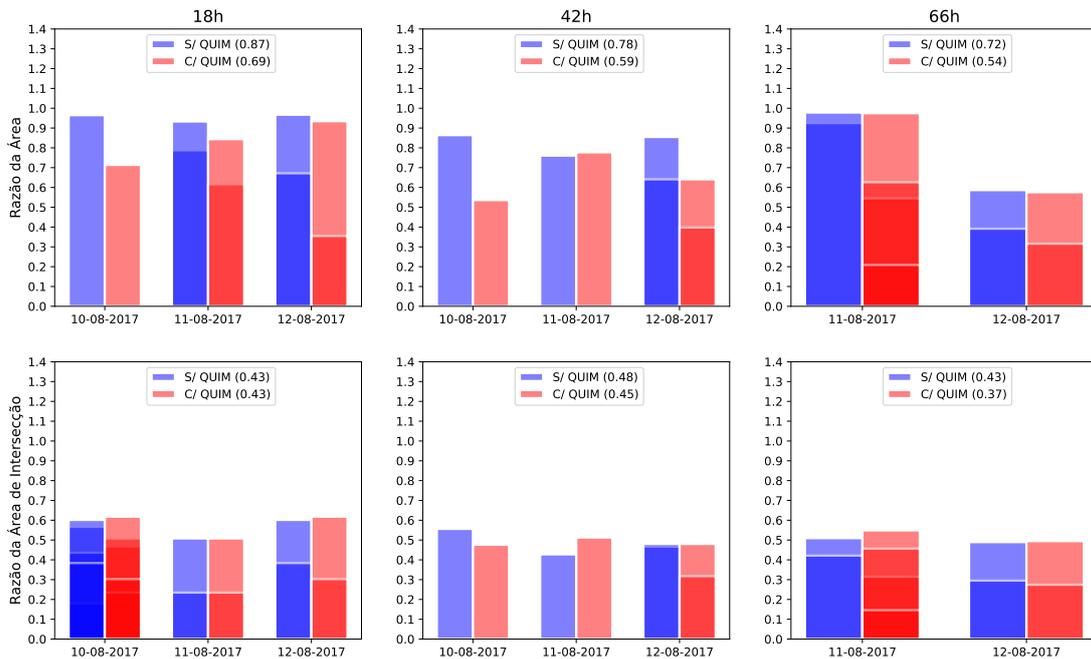
De (a) a (c) tem-se as previsões sem química, e de (d) a (f) a previsão integrada com química para as previsões de 18, 42 e 66 hs no período de 10 a 12 de agosto de 2017. As pétalas coloridas representam a frequência da Diferença de Centroide, além da Média da Diferença do Ângulo de Orientação (MDO) destacado em negrito na figura entre os objetos pareados.

Fonte: Produção da autora.

Os atributos dos objetos pareados relacionados à Razão das Áreas e Razão da Área de Intersecção entre as previsões e reanálise do ERA5 mostrados na Figura 4.18, indicam que a previsão integrada com química apresentou melhora na representação do formato da onda de calor, principalmente nos dias 11 e 12 de agosto no tempo

de integração das 42 para Razão da Área de Intersecção. Em relação aos horários de integração do modelo BRAMS das 18 e 66 horas para esses dias, as previsões sem química e integrada com química são aproximadamente iguais nas razões entre as áreas dos objetos. No entanto, a previsão integrada com química de 18 e 42 horas apresenta pior desempenho no primeiro dia do episódio da onda. Ressalta-se que devido a maior quantidade de objetos pareados entre a referência e a previsão integrada com química no dia 11 às 66 horas, por exemplo, podem influenciar nos valores menores da média global das razões entre áreas. Destaca-se que diferente da Razão da Área de Intersecção entre os objetos pareados da análise do GFS e previsões do BRAMS, os valores entre as razões das áreas de intersecções são levemente maiores, pois os objetos das previsões correspondem melhor em termos de morfologia com o campo de referência do ERA5.

Figura 4.18 - Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42 e 66 hs sem e com a modelagem química integrada pareados em relação a reanálise ERA5 para o caso de agosto de 2017.

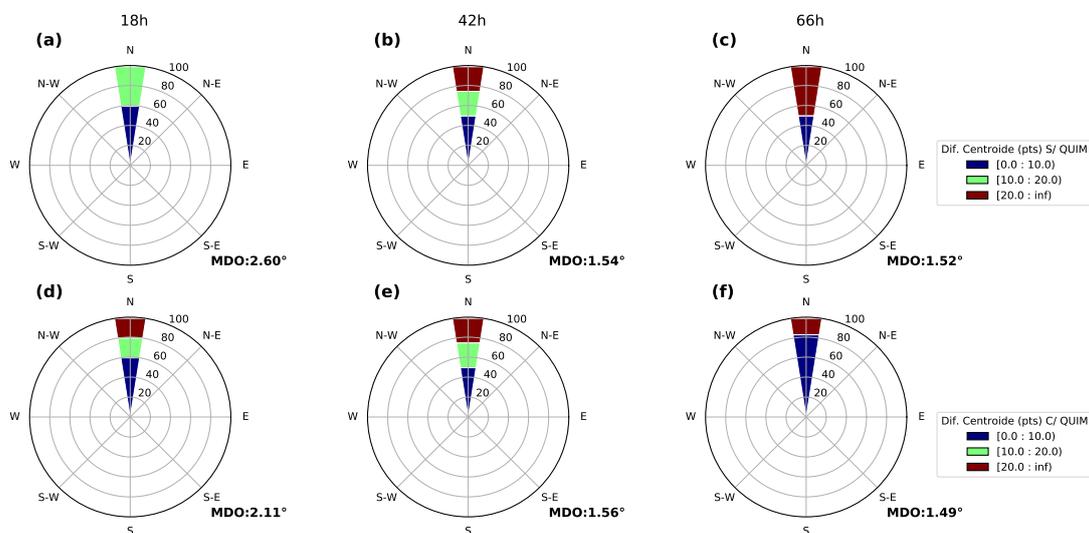


Previsão de 18, 42 e 66 hs do BRAMS sem química (barra azul), e integrada com química (barra vermelha) para o período de 10 a 12 de agosto de 2017. Cada barra representa um objeto pareado entre as previsões e referência do ERA5 nos respectivos tempos de integração.

Fonte: Produção da autora.

A Figura 4.19 mostra as diferenças de Centroide e Ângulo de Orientação entre os objetos pareados entre as previsões e a reanálise do ERA5, as quais indicam que a previsão de 18 horas sem a inclusão da química apresentou uma maior proporção da Diferença de Centroide com até 20 pontos, apesar da frequência entre 0 e 10 pontos serem iguais em ambas previsões com 60%. Para 42 horas de integração na Figura 4.19b,e, as previsões sem e com a inclusão de química apresentam a mesma proporção com 50% entre 0 e 10, 28% entre 10 e 20, e 22% acima de 20 pontos de diferença entre centroides. Em relação às 66 horas, a previsão integrada com química possui uma frequência de aproximadamente 83% entre 0 e 10 pontos (Figura 4.19f), já a previsão sem química tem 50% entre 0 e 10, e outros 50% acima de 20 pontos de Diferença de Centroide (Figura 4.19c). Além disto, nota-se que a média da Diferença do Ângulo de Orientação (MDO) é menor na previsão integrada com química com  $2,11^\circ$  e  $1,49^\circ$  para às 18 e 66 horas, respectivamente.

Figura 4.19 - Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a reanálise do ERA5 e as previsões das 18, 42 e 66 hs sem e com a química integrada para o caso de agosto de 2017.



De (a) a (c) tem-se as previsões sem química, e de (d) a (f) a previsão integrada com química para as previsões de 18, 42 e 66 hs no período de 10 a 12 de agosto de 2017. As pétalas coloridas representam a frequência da Diferença de Centroide, além da Média da Diferença do Ângulo de Orientação (MDO) destacado em negrito na figura entre os objetos pareados.

Fonte: Produção da autora.

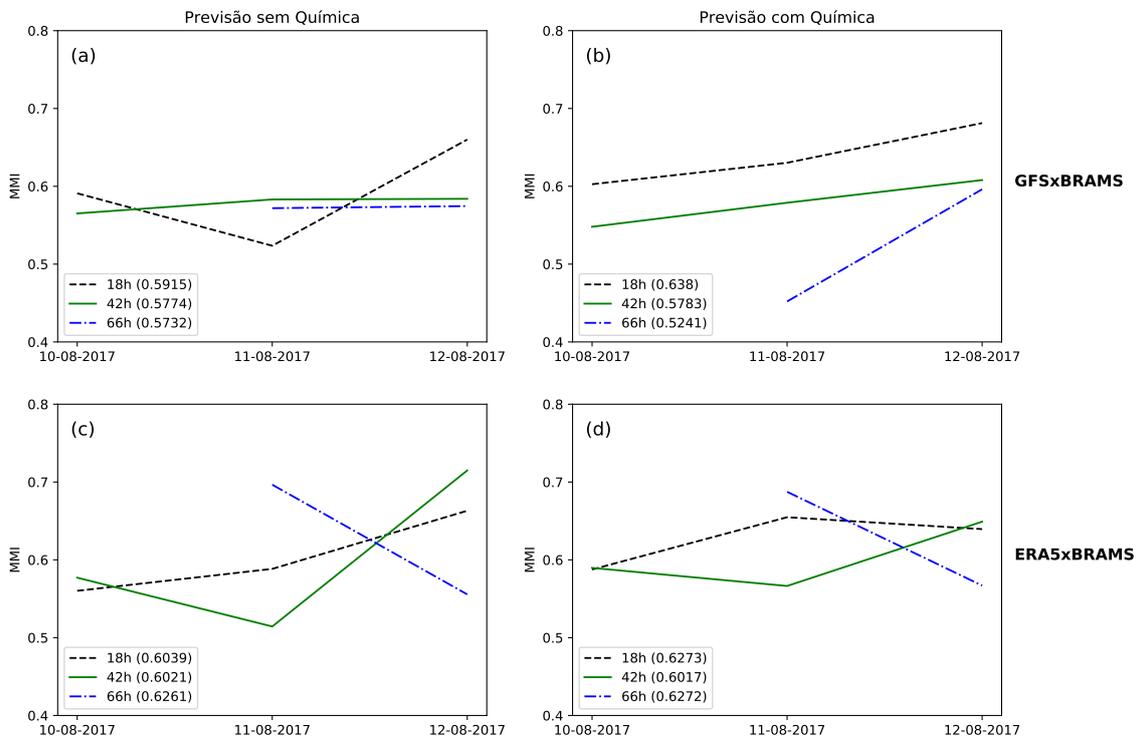
Tabela 4.5 - Interesse total (IT) dos objetos pareados entre as referências e a previsão sem e com a inclusão da modelagem química atmosférica integrada para os prazos das 18, 42 e 66 hs.

	<b>Previsão</b>	<b>18h</b>	<b>42h</b>	<b>66h</b>
GFSxBRAMS	Sem química	0.92	0.91	0.88
	Com química	0.86	0.88	0.85
ERA5xBRAMS	Sem química	0.89	0.92	0.88
	Com química	0.92	0.90	0.89

Fonte: Produção da autora.

No geral, a previsão sem química representa melhor as características das áreas da onda de calor em relação ao GFS (ver Tabela 4.5), como na representação do tamanho, orientação e sobreposição dos objetos. Apesar do Ângulo de Orientação ser menor para as previsões de 18 horas (Figura 4.17d), e a Razão das Áreas ser maior às 42 horas na previsão integrada com química (Figura 4.16). Por outro lado, a Média do Máximo Interesse (MMI), que leva em consideração todos os objetos nos campos de referência e previsão, apresentados na Figura 4.20b mostrou que a previsão integrada com química representa melhor a morfologia dos objetos em todos os horários de integração do modelo BRAMS, apesar da diferença ser mínima entre as previsões de 42 e 66 horas. Este resultado pode está associado ao número elevado de *outlines* no cálculo da matriz do IT, pois há uma gama maior de valores com possíveis objetos pareados na previsão integrada com química em relação a previsão sem química. Para reduzir este impacto, o cálculo da mediana deve ser utilizado em aplicações futuras neste método (DAVIS et al., 2009; CARRASCO, 2017). Os índices estatísticos também mostraram que a previsão integrada com química é melhor principalmente para às 18 e 66 horas, visto anteriormente na Figura 4.14. Entretanto, o Bias é menor na previsão sem a química em todos os tempos de integração em relação à previsão integrada com química, pois este é bastante sensível aos falsos alarmes e falhas.

Figura 4.20 - Média do Máximo Interesse (MMI) dos objetos pareados entre as previsões de 18, 42 e 66 hs do BRAMS sem e com a química integrada e as análises do GFS e ERA5 para o caso de agosto de 2017.



Em (a;c) e (b;d) tem-se a previsão de 18, 42 e 66 hs sem e com a química integrada, respectivamente, versus análise do GFS e reanálise do ERA5.

Fonte: Produção da autora.

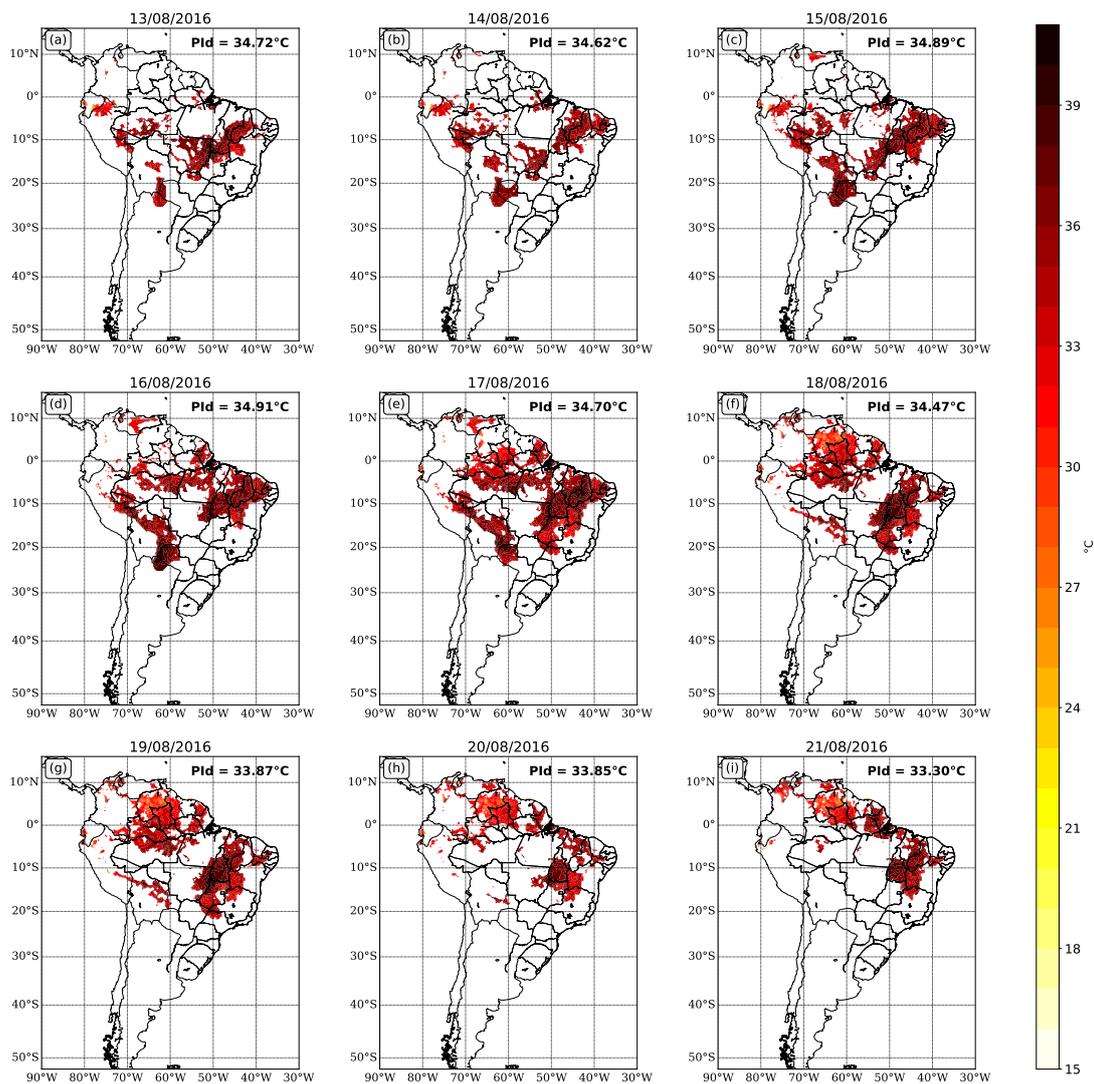
Em contrapartida, a previsão integrada com química caracteriza melhor a morfologia, principalmente a posição da onda de calor na reanálise do ERA5 nos tempos de integração das 18 e 66 horas de acordo com a Tabela 4.5. A MMI na Figura 4.20 também indica um melhor desempenho desta previsão em relação a previsão sem química. Entre as previsões de 42 horas houve pouca diferença na MMI exposta entre parêntesis na Figura 4.20, pois apresentou muitas falhas e falsos alarmes, tanto na previsão sem química quanto na previsão integrada com química. Os índices estatísticos apresentados anteriormente na Figura 4.15 confirmam este resultado, onde o CSI e POD apresentam valores baixos em relação aos outros horários de integração, e valores elevados no FAR, devido à áreas de temperaturas extremas não previstas e não observadas em todo o período avaliado, respectivamente.

### 4.2.3 Avaliação das previsões de ondas de calor sem e com a inclusão da química atmosférica: caso agosto de 2016

O segundo caso identificado na reanálise do ERA5 pelo algoritmo de identificação das ondas de calor persistiu por 9 dias na Área 1, compreendendo o período de 13 à 21 de agosto de 2016 (visto na Figura 4.21). A onda começou a se desenvolver com maior destaque em uma faixa no sentido nordeste-sudoeste sobre a região central do Brasil, como aquela citada na climatologia da Seção 4.1.2. A partir do dia 15 na Figura 4.21, duas faixas distintas de temperaturas extremas se formam sobre o afluente principal da bacia Amazônica se estendendo até os países do norte da AS, e outra no sentido noroeste-sudeste desde o estado do Acre no Brasil até o norte do Paraguai apresentando núcleos intensos de aproximadamente 41 °C. A onda de calor teve sua maior intensidade no dia 16 de agosto com PId de 34,91 °C, e maior abrangência espacial no dia 17. Este evento começou a perder força a partir do sexto dia em termos de extensão e intensidade da onda (Figura 4.21f), apresentando menor abrangência espacial e intensidade (PId de 33,30 °C) no último dia do episódio.

Além disto, o algoritmo de identificação da onda de calor foi aplicado nas previsões sem química e integrada com a química nesse mesmo período em que foi detectado o episódio na reanálise do ERA5. Ressalta-se que a verificação começou à partir da previsão inicializada no dia 12 até o dia 21 de agosto de 2016 às 00 UTC nos tempos de integração de 18, 42, 66 e 90 horas que correspondem às 18 UTC. A Tabela 4.6 mostra os dias e os tempos de integração em que foram previstas as ondas de calor nas previsões sem química (S/ QUIM) e integrada com a química (C/ QUIM). Ambas previsões não foram capazes de prever com antecedência o episódio na previsão inicializada no dia 12 de agosto, como também o término do evento. Sendo que a previsão sem química foi prever à partir do dia 13 de agosto em 42 horas de integração que corresponde ao dia 14 às 18 UTC. Já a previsão integrada com química teve uma diferença de dois dias em relação a previsão sem química, prevendo a onda de calor somente no dia 14 de agosto às 42 horas que corresponde ao dia 15 de agosto às 18 UTC.

Figura 4.21 - Episódio de onda de calor espacializado na Área 1 e intensidade média diária em °C identificado no período de 13 a 21 de agosto de 2016 na reanálise ERA5 às 18 UTC.



Fonte: Produção da autora.

Tabela 4.6 - Onda de Calor identificada nas previsões sem química e integrada com a química atmosférica no período do caso de agosto de 2016.

Episódio	Onda de Calor ERA5	13-08	14-08	15-08	16-08	17-08	18-08	19-08	20-08	21-08
Início da Previsão S/ QUIM										
	13-08-2016		42 h	66 h	90 h	Tempo de Integração				
	14-08-2016		18 h	42 h	66 h	90 h				
	15-08-2016			18 h	42 h	66 h	90 h			
	16-08-2016				18 h	42 h	66 h	90 h		
	17-08-2016					18 h	42 h	66 h	90 h	
	18-08-2016						18 h	42 h	66 h	
Início da Previsão C/ QUIM										
	14-08-2016			42 h	66 h	90 h	Tempo de Integração			
	15-08-2016				42 h	66 h	90 h			
	16-08-2016				18 h	42 h	66 h	90 h		
	17-08-2016					18 h	42 h	66 h		

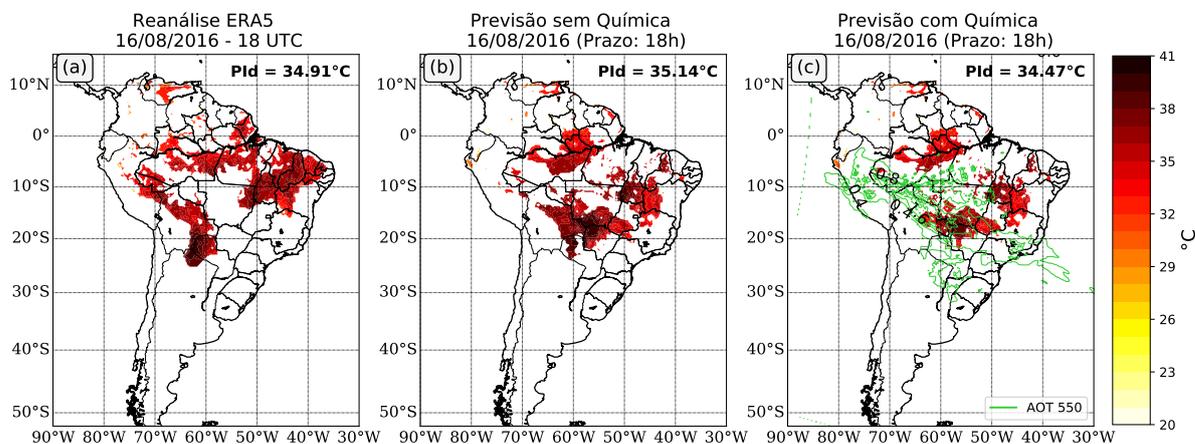
A primeira linha da Tabela corresponde ao período da onda identificada no ERA5. Abaixo dessa linha, na primeira coluna tem-se a data inicial das previsões, com os tempos de integração nas demais linhas em que foi identificado o episódio.

Fonte: Produção da autora.

Em relação ao término do evento, com a previsão sem química, foi possível representar a onda de calor até o dia 18 de agosto nos tempos de integração das 18, 42 e 66 horas, ou seja, até o dia 20 de agosto, apesar das previsões inicializadas nos dias 19, 20 e 21 não captarem mais o evento. No entanto, a previsão integrada com química, além de ter indicado o atraso da ocorrência do episódio, também não indicou o seu término, adiantando o evento no dia 19 de agosto às 18 UTC (previsão inicializada no dia 17 de agosto às 00 UTC). Nota-se na Tabela 4.6 que o único dia em que as duas previsões concordaram foi 16 de agosto em todos os tempos, ou seja, no dia mais intenso da onda de calor visto na Figura 4.21d. Destaca-se que este evento não foi identificado na análise do GFS que é utilizado como condição de contorno no BRAMS, ainda assim, as previsões do modelo BRAMS conseguiram captar o episódio da onda de calor identificada na reanálise do ERA5.

Os dias e horários em que a previsão integrada com química não previu a onda de calor estão associados principalmente com a presença de aerossóis na Área 1, onde a maioria dos campos previstos apresentava  $AOT < 1$ , mas com grande impacto na diminuição da temperatura de superfície. Quando a onda de calor está mais intensa e extensa, a previsão integrada com química consegue captar este evento, apesar dos aerossóis diminuírem a sua extensão e intensidade em regiões com maior AOT. Por exemplo, na Figura 4.22, tem-se a onda de calor identificada nas previsões sem e com a inclusão da química no dia 16 de agosto para às 18 horas. Nota-se que nas regiões com  $AOT > 1$  (Figura 4.22c), há uma diferença da  $T_{max}$  entre as previsões sem a química (Figura 4.22a) e integrada com a química (Figura 4.22b) de aproximadamente  $20^{\circ}\text{C}$ , como pode-se ver no norte do Paraguai e nordeste da Bolívia. Além disso, a intensidade se torna menor na previsão integrada com química, com uma diferença no PID de  $\approx 0,7^{\circ}\text{C}$  em relação à previsão sem a química. Utilizando o modelo BRAMS com os mesmos experimentos, Artaxo et al. (2006) encontrou uma redução da  $T_{max}$  próximo à superfície de  $1^{\circ}\text{C}$  associada à atenuação da radiação de onda curta que chega na superfície devido à AOT elevada em um sítio experimental ABRACOS no estado de Rondônia no Brasil.

Figura 4.22 - Onda de calor identificada espacializado na Área 1 e intensidade média diária em °C nas previsões de 18h sem a química e com a química atmosférica integrada e campo de AOT em 550 nm para o dia 16 de agosto de 2016 às 18 UTC.



Campos de  $T_{max}$  extremas da (a) Reanálise ERA5; (b) previsão do BRAMS sem química; (c) previsão integrada com química e campo de AOT em 550 nm (contorno em verde).

Fonte: Produção da autora.

O limiar de intensidade utilizado no MODE/SCANTEC para a avaliação das previsões para este episódio foi de 34,37°C. Nos campos dos objetos identificados na previsão integrada com química, há mais objetos em relação à previsão sem química devido a AOT elevada nos tempos de integração das 18, 42, 66 e 90 horas, ou seja, antes um só objeto classificado na previsão sem química pode se tornar vários na previsão integrada com química devido à presença dos aerossóis. Logo, a previsão integrada com química apresenta mais falsos alarmes do que a previsão sem a química para todos os horários de integração, como pode ser observado na Tabela 4.7. Entretanto, a previsão integrada com química tem uma quantidade maior de sucessos. Isto ocorre devido ao maior número de objetos correspondentes entre a referência e a previsão. Já a previsão sem química (destacado em azul na Tabela 4.7) apresenta mais falhas, pois o número de objetos no ERA5 é maior do que o da previsão.

Nota-se também na Tabela 4.7 que a quantidade de objetos previstos pela previsão integrada com química se aproxima do total de objetos observados na referência do ERA5, apesar do baixo desempenho observado em relação aos falsos alarmes. Na

Figura 4.23h, é possível observar este comportamento, onde no geral a previsão integrada com química apresenta Bias próximo à 1 em todos os horários de integração. No entanto, há uma maior superestimativa nos horários de integração das 18 e 42 horas, principalmente nos primeiros quatro dias do evento, e uma subestimativa na quantidade de objetos a partir do dia 17 de agosto. O contrário foi observado para os prazos de previsão de 66 e 90 horas. A previsão sem química mostrada na Figura 4.23g mostra subestimativa dos objetos presentes na reanálise do ERA5 em todos os horários de integração, sendo mais próximo de 1 às 66 e 90 horas, principalmente a partir do dia 18 de agosto onde a quantidade de objetos previstos se torna mais próximo do “observado”.

Tabela 4.7 - Total de sucessos, falhas e falsos alarmes das previsões sem química e integrada com a química atmosférica para os prazos das 18, 42, 66 e 90 horas para o episódio de onda de calor em agosto de 2016.

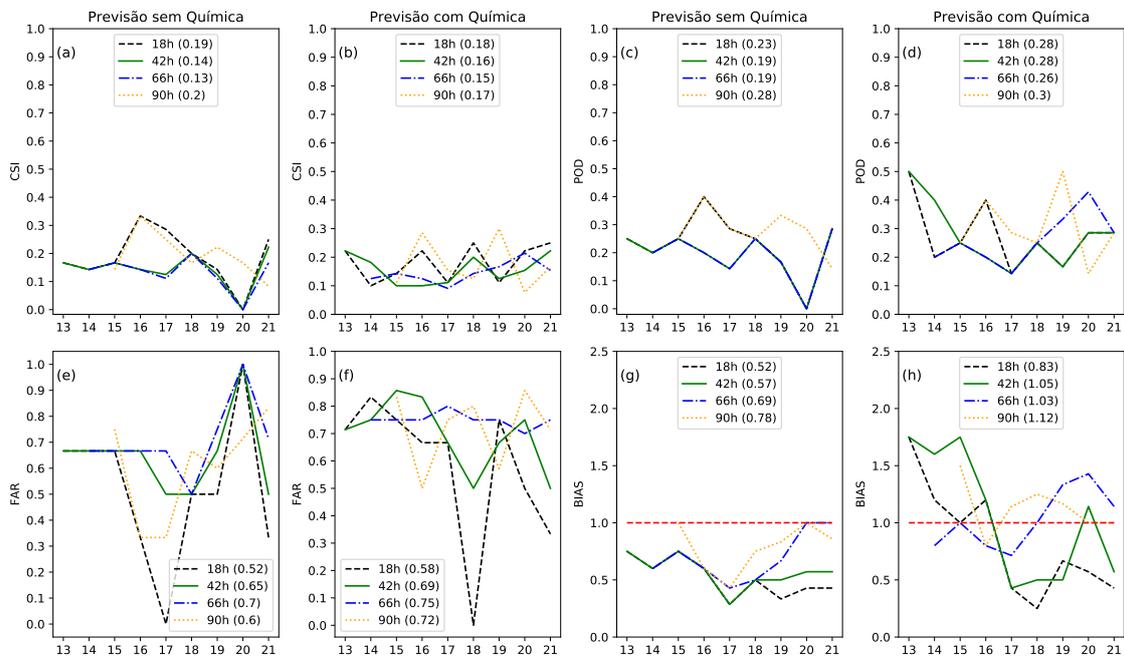
Previsão	Prazos	Sucessos	Falhas	Falsos Alarmes	Observados	Previstos
S/ QUIM	18h	12	41	15	49	24
		13	36	25	49	38
	42h	9	40	18	49	27
		13	36	35	49	48
C/ QUIM	66h	7	37	24	45	32
		12	33	35	45	47
	90h	11	29	20	39	31
		12	28	32	39	44

Fonte: Produção da autora.

Na Figura 4.23 são mostrados os valores do Bias e dos índices CSI, FAR e POD ao longo dos dias em que houve o episódio da onda de calor nas previsões sem química e integrada com a química para os horários de integração das 18, 42, 66 e 90 horas. Em média, o CSI e o POD apresentaram valores muito baixos, menores que 0,2 e 0,5, respectivamente, e o FAR acima de 0,6 em ambas previsões. Isto indica que houve poucos objetos pareados entre a reanálise do ERA5 e as previsões, além de apresentar muitas falhas e falsos alarmes, como visto na Tabela 4.7. Comparando os dois experimentos, observou-se que a previsão integrada com química apresentou um melhor desempenho em relação à previsão sem química em todos os tempos

de integração, como pode ser observado nos valores do POD sendo um pouco mais elevados na previsão integrada com química devido a uma quantidade maior de objetos pareados (maior número de sucessos em todos os horários). Apesar dos valores de CSI serem próximos entre as previsões, é notável um pior desempenho no dia 20 de agosto na previsão sem a inclusão da química às 18, 42 e 66 horas, onde o CSI e POD são iguais à 0, e FAR igual à 1 na Figura 4.23(a,c,e), respectivamente, essa resposta nos índices para este dia específico está associado ao não pareamento de objetos com o ERA5.

Figura 4.23 - Índices estatísticos da avaliação orientada a objeto de ondas de calor das previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada, usando como referência a reanálise do ERA5 no período de ocorrência do caso de agosto de 2016.



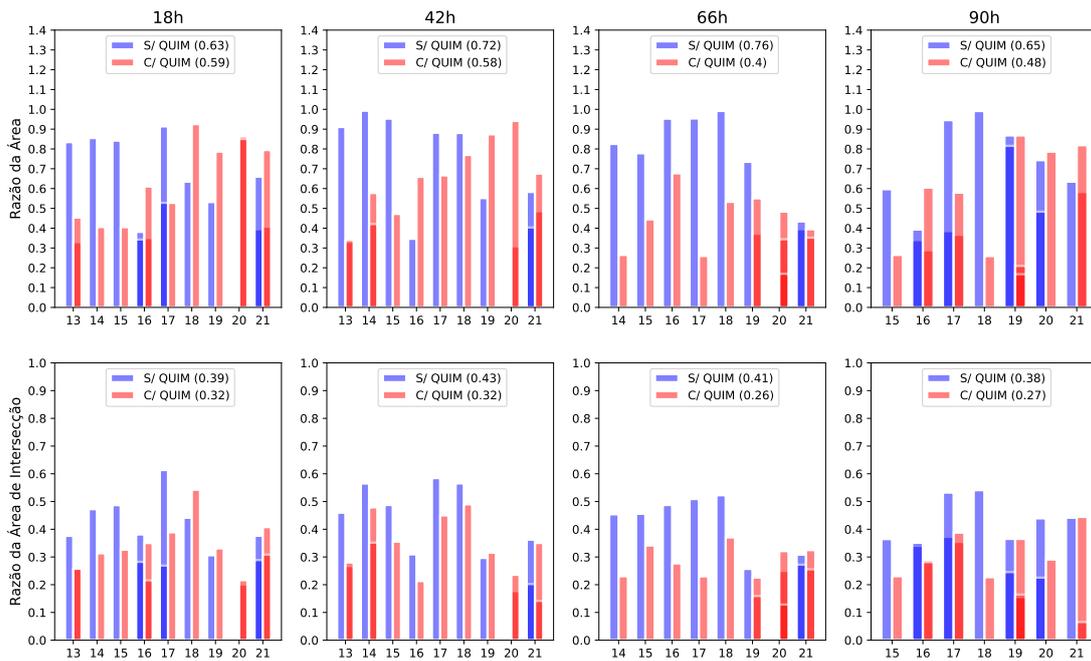
A linha vermelha tracejada na figura do Bias representa o limite 1 de que a previsão foi “perfeita”.

Fonte: Produção da autora.

Por meio da análise dos atributos dos objetos pares na Figura 4.24, verifica-se em todos os tempos de integração que a Razão das Áreas e Razão da Área de Intersecção são maiores na previsão sem química (em azul) nos primeiros dias do episódio da onda de calor. Por outro lado, a previsão integrada com química (em vermelho)

representa melhor as características morfológicas dos objetos observados pela reanálise do ERA5 nos últimos dias do evento, sendo mais sutil esta melhora na Razão da Área de Intersecção.

Figura 4.24 - Razão das Áreas e Razão da Área de Intersecção dos objetos de ondas de calor das previsões de 18, 42, 66 e 90 hs sem química e integrada com a modelagem química pareados em relação a reanálise do ERA5 para o episódio de onda de calor em agosto de 2016.



Previsão sem química (barra azul), e previsão integrada com química (barra vermelha) para os horários de integração das 18, 42, 66 e 90 horas no período de 13 a 21 de agosto de 2016. Cada barra representa um objeto pareado entre as previsões e referência do ERA5 nos respectivos tempos de integração.

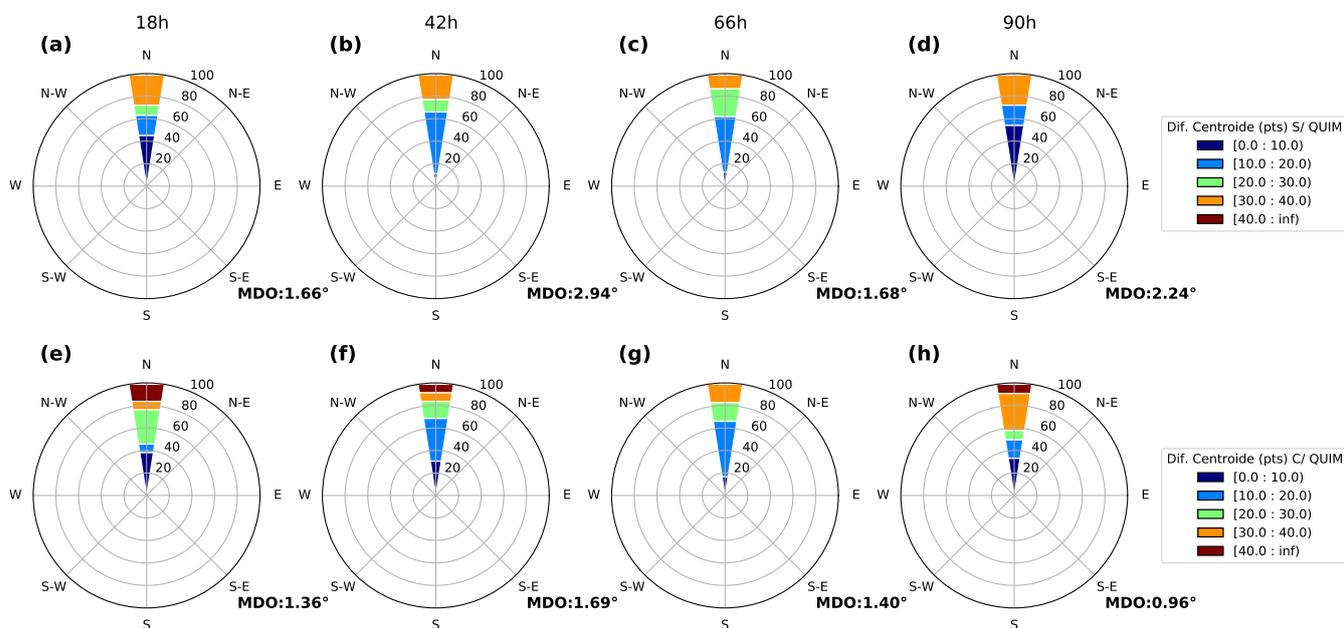
Fonte: Produção da autora.

Em relação ao posicionamento dos objetos, a Figura 4.25 mostra as diferenças de Centróide e Ângulo de Orientação em termos de frequência entre os objetos pareados da reanálise do ERA5 e previsões do modelo BRAMS. A frequência entre 0 e 10 pontos é maior na previsão sem química para os horários das 18 ( $\approx 45\%$ ), e 90 ( $\approx 55\%$ ). Já a previsão integrada com química apresenta um distanciamento maior entre os centroides dos objetos, acima de 40 pontos. No entanto, a previsão integrada com química possui uma frequência maior entre 0 e 10 no tempo de integração das 42 horas, apesar de apresentar uma pequena proporção de pontos acima de 40. Para

o prazo das 66 horas, as duas previsões obtiveram frequências próximas da Diferença de Centroide, sendo um pouco elevada em menos pontos de diferença na previsão integrada com química. Nota-se também que a previsão integrada com química apresentou melhor desempenho na orientação dos objetos com menores valores da MDO em todos os tempos de integração em relação a previsão sem química.

O IT global dos objetos pareados para o período do episódio da onda de calor é apresentado na Tabela 4.8. No geral, os valores de IT entre as previsões foram próximos. A previsão sem química apresentou um interesse maior dos objetos nos tempos de integração das 18, 66 e 90 horas. Entretanto, o IT é maior na previsão integrada com química no prazo das 42 horas, devido à maior frequência de pontos entre 0 e 10 e menor Ângulo de Orientação visto na Figura 4.25f, bem como um melhor desempenho em relação ao formato da onda de calor nos últimos dias do episódio.

Figura 4.25 - Diferença do centroide e Diferença do Ângulo de Orientação dos objetos pareados pelo MODE/SCANTEC entre a reanálise do ERA5 e as previsões das 18, 42, 66 e 90 hs sem química e com a química atmosférica integrada para o episódio de agosto de 2016.



(a) a (d) previsão sem química, e (e) a (h) previsão integrada com química atmosférica para os horários de integração das 18, 42, 66 e 90 horas no período de 13 a 21 de agosto de 2016. As pétalas coloridas representam a frequência da Diferença de Centroide entre os objetos pareados, além da Diferença do Ângulo de Orientação.

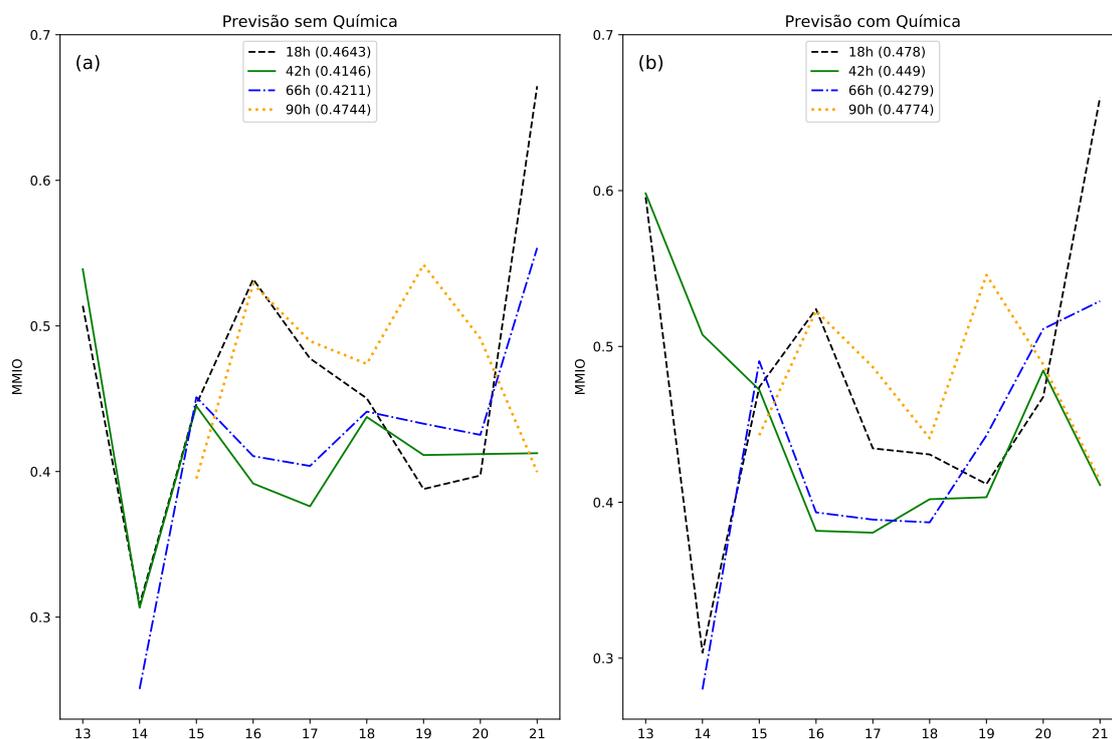
Fonte: Produção da autora.

Tabela 4.8 - IT dos objetos pareados entre a reanálise do ERA5 e a previsão sem química e com a química atmosférica integrada para os prazos das 18, 42, 66 e 90 hs.

	Previsão	18h	42h	66h	90h
ERA5xBRAMS	Sem química	0,87	0,84	0,86	0,88
	Com química	0,85	0,85	0,84	0,83

Fonte: Produção da autora.

Figura 4.26 - Média do Máximo Interesse Observado (MMIO) dos objetos observados para as previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada.

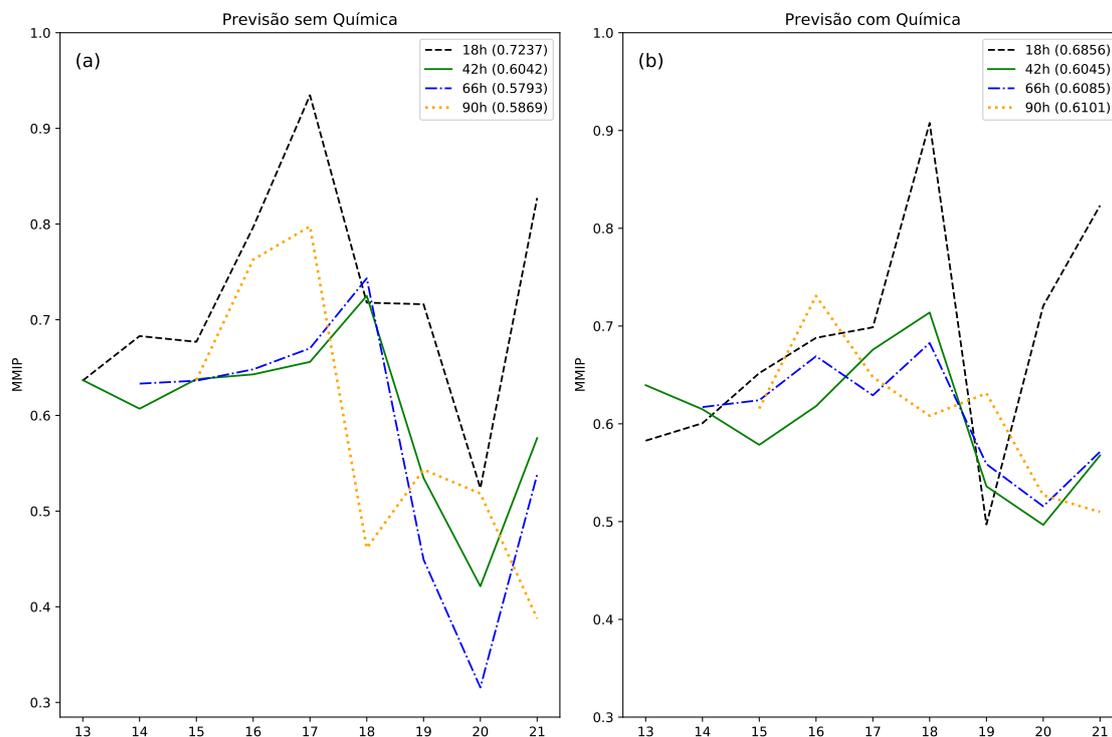


Em a e b tem-se a previsão sem química e integrada com a química, respectivamente, versus reanálise do ERA5 para os tempos de integração de 18, 42, 66 e 90 horas.

Fonte: Produção da autora.

Os resultados anteriores são sintetizados na MMI discretizada no período de ocorrência da onda de calor em agosto de 2016, que é dada pela MMIO (Figura 4.26) e MMIP (Figura 4.27). Nota-se que a maioria dos valores da MMIO em todos os horários de integração são menores do que 0,6 em ambas previsões, e o comportamento temporal são semelhantes. Na MMIP é um pouco mais elevada em relação à MMIO, principalmente na previsão integrada com química (Figura 4.27a) com valores acima de 0,5 em todo o período do evento, pois há um maior número de objetos em comparação com a previsão sem química, possibilitando um maior pareamento com os objetos da reanálise do ERA5. Como visto anteriormente, isto influenciará no resultado final da MMI, pois o número de possíveis objetos pareados é maior na previsão integrada com química, implicando em uma amostra maior na matriz do IT. Já na previsão sem química (Figura 4.27b), a MMIP é maior que 0,6 nos cinco primeiros dias, se tornando menor a partir do dia 18 até o dia 20 de agosto, devido a menor quantidade de objetos pareados com o ERA5.

Figura 4.27 - Média do Máximo Interesse Previsto (MMIP) dos objetos previstos para previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada.

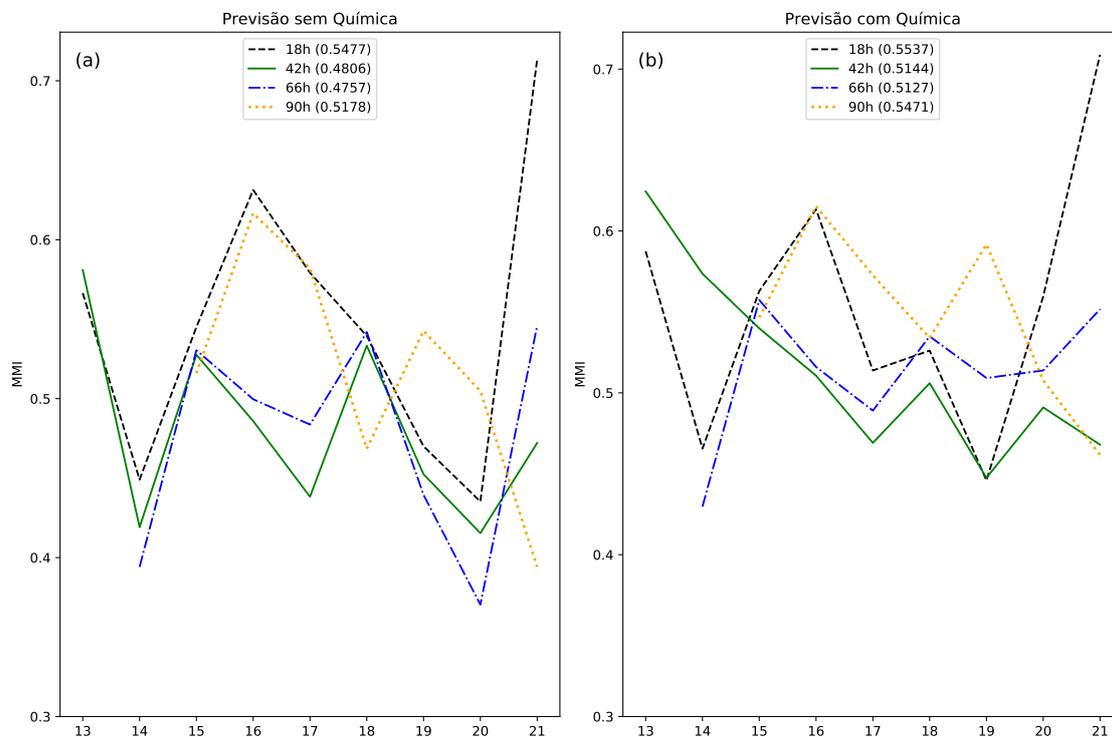


Em a e b tem-se a previsão sem química e integrada com a química, respectivamente, versus reanálise do ERA5 para os tempos de integração das 18, 42, 66 e 90 horas.

Fonte: Produção da autora.

Geralmente, a MMIO e MMIP não são iguais (DAVIS et al., 2009). Por exemplo, no dia 14 de agosto, a MMIO foi menor em ambas previsões, pois a quantidade de falhas diminui este índice, além de uma quantidade de objetos pequenos em relação à reanálise do ERA5 para este dia. Já a MMIP apresentou valores mais elevados, devido ao menor número de falsos alarmes. Objetos menores nos campos previstos em relação ao observado diminui os valores das razões das áreas, e vice-versa, contribuindo para diminuição da MMIO e MMIP. Como também objetos não sobrepostos, onde a Distância Mínima entre as Bordas dos objetos observados e previstos é considerado de maior importância no cálculo da matriz do IT, além da Diferença de Centróide. Apesar da diferença entre as previsões sem química e integrada com a química serem pequenas na MMI (Figura 4.28), a previsão integrada com química representa melhor a morfologia da onda de calor, desempenhando um melhor papel em relação ao tamanho e posição da área do evento por meio da análise dos atributos dos objetos pares.

Figura 4.28 - Média do Máximo Interesse (MMI) dos objetos pareados entre as previsões de 18, 42, 66 e 90 hs do BRAMS sem e com a química integrada e reanálise do ERA5.



Em a e b tem-se a previsão sem química e integrada com a química, respectivamente, versus reanálise do ERA5 para os tempos de integração das 18, 42, 66 e 90 horas.

Fonte: Produção da autora.

Os resultados apresentados até aqui indicam que a química atmosférica impacta positivamente na qualidade da previsão de curto prazo de episódios de ondas de calor sobre a AS realizada com o modelo BRAMS, pois a presença de altas concentrações de aerossóis e gases traços na atmosfera reduzem os fluxos de calor sensível e radiação de onda longa emitida pela superfície, consequentemente impactando outras variáveis atmosféricas do modelo [Para mais detalhes Consultar [Apêndice C](#)]. Logo, este trabalho sugere a necessidade de um melhor entendimento da inclusão da química atmosférica na modelagem das ondas de calor na escala de tempo.

## 5 CONCLUSÕES

Esta pesquisa visou demonstrar a eficácia e os benefícios obtidos ao diagnosticar os erros das previsões de ondas de calor na AS por meio da metodologia orientada a objeto MODE no SCANTEC. Para isso foi utilizado previsões do modelo BRAMS em uma versão em que a modelagem química está completamente integrada com a componente meteorológica, bem como uma outra versão do mesmo modelo sem a contribuição da modelagem dos aerossóis. Para isso, inicialmente foi realizado um levantamento de episódios de ondas de calor sobre a AS. Uma análise de *cluster* foi aplicada para identificar as áreas em que a  $T_{max}$  apresenta um comportamento homogêneo. Para isso foram utilizados dados da reanálise ERA5 durante o período que compreende os meses de JASO de 1979-2019. Neste trabalho, visando explicar os resultados encontrados nas previsões obtidas com a inclusão da química atmosférica, também avaliou-se os impactos dos aerossóis na extensão da onda de calor.

Por meio das análises *Silhouette* e *cluster*, pôde-se concluir a utilização de três áreas homogêneas de  $T_{max}$  sobre a AS no período quadrienal JASO, com menos áreas de conflitos entre *clusters*. A maior área determinada pela análise de *cluster* (Área 1) abrange grande parte da região tropical do continente. As demais áreas compreendem a faixa leste e sudeste da AS, como também regiões com relevo acidentado próximo à Cordilheira dos Andes (Área 2), e regiões de topografia mais acentuada e Sul da AS (Área 3).

Com a aplicação dos critérios de identificação das ondas de calor propostos por Bitencourt et al. (2016) nos dados de reanálise do ERA5 durante o período de 1979-2019, foram detectados 191 casos em todo o continente sul americano, sendo 47,12% na Área 2, 35,60% na Área 3, e 17,28% na Área 1, região que abrange maior parte da área tropical. Os resultados sugerem que nas últimas décadas a frequência de ocorrência, duração e intensidade das ondas de calor vêm aumentando ao nível de significância de 5% em todo o território da AS, sendo mais evidente em termos de intensidade na região tropical (Área 1) com uma faixa no sentido nordeste-sudoeste, continuando sobre o norte da Argentina e região da Patagônia, principalmente nos meses de agosto e setembro. Presume-se que estas áreas de maior ocorrência podem estar associadas devido às mudanças causadas pelo uso da terra e emissões de gases traços e aerossóis para a atmosfera, que conseqüentemente alteram o balanço radiativo, podendo acarretar na diminuição da umidade no solo (BARKHORDARIAN et al., 2019).

A proposta de aplicação da metodologia orientada a objeto MODE na  $T_{max}$  se mos-

trou promissora no que diz respeito à representação das características espaciais e geométricas das áreas com ondas de calor. Uma avaliação inicial como prova de conceito foi realizada, na qual um episódio de onda de calor com persistência de 3 dias entre as análises utilizadas como referência provenientes do GFS e da reanálise ERA5 foi investigado. Os resultados mostraram que com o método, foi possível identificar de forma mais abrangente o comportamento ao longo do tempo em termos de extensão e intensidade da onda avaliada. Os valores dos índices estatísticos orientados a objeto permitem quantificar de forma objetiva o desempenho de cada produto em termos de qualidade no posicionamento espacial dos eventos de onda de calor.

Em relação à avaliação das referências GFS e ERA5 para o caso de agosto de 2017, foi encontrada uma defasagem de duração de 8 dias, tanto no início e final da onda de calor. Por meio do MODE no SCANTEC avaliando apenas os dias condizentes entre as referências, pôde-se concluir que a análise do GFS e reanálise do ERA5 concordaram melhor apenas no primeiro dia do evento, se tornando mais divergentes nos demais dias, devido à maior quantidade de falhas e falsos alarmes.

No que se refere à avaliação do impacto da integração da meteorologia com a química atmosférica na qualidade das previsões de curto prazo das ondas de calor utilizando o MODE, dois estudos de casos foram realizados (9 dias: Agosto de 2016; 3 dias: agosto de 2017) na Área 1. Ambos os casos ocorreram na maior região definida pela análise de *cluster* e que é bastante influenciada pela ocorrência de queimadas (ARTAXO et al., 2006) no período de estudo em questão. A referência aqui utilizada foi a análise do GFS e reanálise do ERA5. A partir dos resultados obtidos pode-se concluir que:

- Para o caso de agosto de 2016, a previsão integrada com a química atmosférica apresentou um melhor desempenho para representar a extensão espacial da onda de calor identificada na referência do ERA5 em todos os horários de integração do modelo BRAMS, principalmente nos últimos dias do episódio, quando comparada com a previsão sem a química. Em relação a posição, a previsão sem química apresenta um melhor desempenho na posição da onda de calor às 18 e 90 horas, sendo que a previsão integrada com química se sobressai no prazo de integração de 42 horas;
- Para o caso de agosto de 2017, o formato e posicionamento dos eventos foi melhor representado pela previsão integrada com a química nos prazos mais longos de integração (42 e 66 horas);

- Ambas previsões superestimam os objetos das referências no caso de agosto de 2017. Este resultado é mais evidente na previsão integrada com a química no primeiro dia do evento, pois a quantidade de objetos é maior em relação à previsão sem química. Isto ocorre devido à diminuição da extensão da onda de calor em virtude da presença dos aerossóis, demonstrado pelo campo de AOT. A maior concentração de aerossóis reduz a  $T_{max}$  próximo à superfície, contribuindo com o aumento de objetos na previsão. No entanto, no episódio com maior persistência em agosto de 2016, a previsão integrada com química apresentou uma melhor acurácia na quantidade de objetos em todos os tempos de integração do modelo BRAMS.

Em relação ao período de ocorrência da onda de calor identificada na reanálise do ERA5 entre os dias 13 e 21 de agosto de 2016 por meio do algoritmo de identificação dos episódios, verificou-se que as previsões do modelo BRAMS não indicaram com antecedência o evento, assim como o seu término. A previsão sem química apresentou uma defasagem inicial (final) de 1 dia (3 dias antes) da data de inicialização em 12 de agosto às 00 UTC (21 de agosto às 00 UTC), sendo acrescido de +1 dia na previsão integrada com química. Contudo, ambas previsões representaram a onda de calor no seu dia mais intenso (16 de agosto) em todos os horários de integração. Este atraso pode estar relacionado à problemas de valor inicial na simulação numérica, pois não foi possível detectar este episódio na análise do GFS, utilizada como condição de contorno no modelo BRAMS. Vale ressaltar que as análises do GFS utilizadas neste trabalho são provenientes de uma versão do modelo que não possui um módulo de aerossóis interativos, e por isso deve apresentar deficiências na representação dos padrões de temperatura próximo à superfície.

Os impactos nos fluxos radiativos são importantes quando a AOT em 550 nm é elevada, reduzindo a temperatura de superfície. Na previsão integrada com química para o dia 16 de agosto de 2016 houve uma diferença expressiva na  $T_{max}$  ( $\approx 20^\circ C$ ) em relação à previsão sem a química nas regiões em que a extensão da onda de calor diminuiu devido à maior concentração de aerossóis, como no norte do Paraguai e nordeste da Bolívia. Entretanto, ressalta-se que o efeito verificado de redução da extensão da onda de calor devido à presença dos aerossóis, à princípio positivo, é importante para a previsão de curto prazo. Uma onda de calor, cuja definição se dá na escala sinótica, e portanto pode ser prevista por modelos regionais que geralmente são executados para um prazo de previsão de até três dias, pode se estender por períodos mais longos, podendo ser enquadrada como um evento meteorológico de escala subsazonal. Em se tratando de previsões de médio e longo prazos, como

é o caso de previsões sazonais e subsazonais, o efeito dos aerossóis pode não ser positivo, uma vez que mudanças nos padrões próximo à superfície devido à presença de aerossóis podem induzir mudanças de padrões atmosféricos em altos níveis (BENEDETTI; VITART, 2018), e gerar mecanismos que podem inclusive intensificar ou prolongar os eventos de ondas de calor.

### 5.1 Sugestões para trabalhos futuros

Diante dos resultados encontrados nesta pesquisa, a orientação a objeto MODE contribuiu de forma eficaz para identificação dos erros nas previsões de  $T_{max}$ . Consequentemente, contribuiu também para a identificação dos episódios de ondas de calor que se enquadram dentro da escala de tempo de curto prazo. Além disso, esse estudo pode servir como base na geração de novos produtos que subsidiem a previsão destes eventos nos centros operacionais de previsão de tempo e clima, podendo ser subsídio para a geração de alertas, e consequentemente promoção de políticas públicas que visem amenizar os efeitos causados pelo calor excessivo na saúde da população, sendo também evidenciada nos setores de recursos hídricos, energéticos e alimentícios (agricultura e agropecuária). Outro ponto importante é o contínuo aprimoramento das métricas e módulos da metodologia orientada a objeto MODE no SCANTEC para diagnosticar os erros de posição, extensão e duração das ondas de calor previstas por modelos de PNT. Logo, este estudo possibilita a abrangência de vários pontos que podem ser trabalhados futuramente, como:

- Reestruturar o módulo de identificação de objetos do MODE, incluindo o algoritmo de identificação das ondas de calor para melhor avaliar a intensidade e duração dos eventos;
- A inclusão do cálculo da Mediana do Máximo Interesse dos objetos previstos e observados no MODE/SCANTEC, possibilitando a comparação entre as duas métricas MMI;
- Investigar quais das espécies que compõem o material particulado emitido pelas queimadas e que é produzido pelo BRAMS estão mais associadas ao viés da temperatura próximo à superfície, como também de outras variáveis atmosféricas;
- Realizar experimentos para identificar a importância da condição inicial e de contorno para os resultados do modelo, utilizando por exemplo a reanálise do ERA5;

- Avaliar o desempenho do modelo para a previsão das temperaturas mínimas do ar ( $T_{min}$ ), e comparar com dados de estações meteorológicas de superfície. Pois além da  $T_{max}$ , a variável  $T_{min}$  é utilizada como critério acima do percentil de 95% para a identificação de ondas de calor durante a noite (NISSAN et al., 2017);
- Estudar climatologicamente o impacto dos aerossóis na redução da umidade do solo para explicar as regiões de maior ocorrência e intensidade das ondas de calor na AS.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALONSO, M. F. **Previsão de tempo químico para a América do Sul: impacto das emissões urbanas nas escalas local e regional**. 216 p. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. Disponível em:

<<http://urlib.net/sid.inpe.br/mtc-m18/2011/06.06.15.12.09>>. Acesso em: 16 maio 2016". 3

ANDREAE, M. O.; AFCHINE, A.; ALBRECHT, R.; HOLANDA, B. A.; ARTAXO, P.; MINIKIN, A.; BARBOSA, H. M. J.; WANG, J.; BORRMANN, S.; PÖSCHL, U.; COSTA, A.; JÄRVINEN, E.; MACHADO, L. A. T.; WENDISCH, M.; KRISNA, T.; JURKAT, T.; SCHLAGER, H.; KRÄMER, M.; WEINZIERL, B.; PÖHLKER, C.; DOLLNER, M.; KLIMACH, T.; VOIGT, C.; KNOTE, C.; FÜTTERER, D.; WALSER, A.; ROSENFELD, D.; SCHULZ, C.; SCHNAITER, M.; PÖHLKER, M. L.; SPANU, A.; MERTES, S.; SCHNEIDER, J.; SPERLING, V. B.; SAUER, D.; KONEMANN, T.; CECCHINI, M. A.; ZIEREIS, H. Aerosol characteristics and particle production in the upper troposphere over the Amazon Basin. **Atmospheric Chemistry and Physics**, v. 18, n. 2, p. 921–961, 2018. 19, 24

ARAÚJO, G. R. G.; SANTOS E SILVA, C. M.; SILVA, A. G. Evaluation of cumulus parametrizations Emanuel and Grell of regional climate model RegCM4: simulating precipitation and surface temperature over Northeastern of Brazil during the southern autumn. **Anuário do Instituto de Geociências - UFRJ**, v. 42, n. 1, p. 231–240, 2019. ISSN 01019759. Disponível em:

<[http://dx.doi.org/10.11137/2019{}\\_1{}\\_231{}\\_240http://www.anuario.igeo.ufrj.br/2019{}\\_01/2019{}\\_1{}\\_231{}\\_240.pdf](http://dx.doi.org/10.11137/2019{}_1{}_231{}_240http://www.anuario.igeo.ufrj.br/2019{}_01/2019{}_1{}_231{}_240.pdf)>. 9

ARCHER-NICHOLLS, S.; LOWE, D.; SCHULTZ, D. M.; MCFIGGANS, G. Aerosol-radiation-cloud interactions in a regional coupled model: the effects of convective parameterisation and resolution. **Atmospheric Chemistry and Physics**, v. 16, n. 9, p. 5573–5594, 2016. ISSN 16807324. Disponível em: <[www.atmos-chem-phys.net/16/5573/2016/](http://www.atmos-chem-phys.net/16/5573/2016/)>. 56

ARTAXO, P.; OLIVEIRA, P. H.; LARA, L. L.; PAULIQUEVIS, T. M.; RIZZO, L. V.; PIRES JUNIOR, C.; PAIXÃO, M. A.; LONGO, K. M.; FREITAS, S. R.; CORREIA, A. L. Efeitos climáticos de partículas de aerossóis biogênicos e

emitidos em queimadas na Amazônia. **Revista Brasileira de Meteorologia**, v. 21, n. 3a, p. 168–189, 2006. 3, 24, 25, 56, 71, 82, 116, 117

BAKLANOV, A.; BRUNNER, D.; CARMICHAEL, G.; FLEMMING, J.; FREITAS, S.; GAUSS, M.; HOV, ; MATHUR, R.; SCHLÜNZEN, K. H.; SEIGNEUR, C.; VOGEL, B. Key issues for seamless integrated chemistry–meteorology modeling. **Bulletin of the American Meteorological Society**, v. 98, n. 11, p. 2285–2292, 2017. 2

BALSAMO, G.; MOGENSEN, K.; KEELEY, S.; BIDLOT, J.-R.; BOUSSETTA, S.; DUTRA, E.; WEDI, N. Coupling of oceans and land surfaces in the ECMWF integrated forecasting system: sensitivity and impact of diurnal and synoptic variability on medium-range skill. In: **The 2017 Blue Book**. [S.l.]: World Meteorological Organization, World Climate Research Program – Working Group on Numerical Experimentation, 2017. 1

BARKHORDARIAN, A.; SAATCHI, S. S.; BEHRANGI, A.; LOIKITH, P. C.; MECHOSO, C. R. A recent systematic increase in vapor pressure deficit over tropical South America. **Scientific Reports**, v. 9, p. 1–12, 2019. ISSN 20452322. 47, 81

BARRUCAND, M.; RUSTICUCCI, M.; VARGAS, W. Temperature extremes in the south of South America in relation to Atlantic Ocean surface temperature and Southern Hemisphere circulation. **Journal of Geophysical Research Atmospheres**, v. 113, n. 20, 2008. ISSN 01480227. 47

BELLOUIN, N.; BOUCHER, O.; HAYWOOD, J.; REDDY, M. S. Global estimate of aerosol direct radiative forcing from satellite measurements. **Nature**, v. 438, n. 7071, p. 1138–1141, 2005. ISSN 14764687. 19

BENEDETTI, A.; MORCRETTE, J.-j.; BOUCHER, O.; DETHOF, A.; ENGELEN, R. J.; FISHER, M.; FLENTJES, H.; HUNEEUS, N.; JONES, L.; KAISER, J. W.; KINNE, S.; MANGOLD, A.; RAZINGER, M.; SIMMONS, A. J.; SUTTIE, M.; TEAM, G.-A. Aerosol analysis and forecast in the ECMWF integrated forecast system: data assimilation. **Journal of Geophysical Research**, n. 571, p. 1–23, 2008. Disponível em: <<http://www.ecmwf.int/publications/>>. 2

BENEDETTI, A.; VITART, F. Can the direct effect of aerosols improve subseasonal predictability? **Monthly Weather Review**, v. 146, n. 10, p. 3481–3498, 2018. ISSN 0027-0644. 24, 84

BITENCOURT, D. P.; FUENTES, M. V.; FRANKE, A. E.; SILVEIRA, R. B.; ALVES, M. P. The climatology of cold and heat waves in Brazil from 1961 to 2016. **International Journal of Climatology**, v. 40, p. 2464–2478, 2019. ISSN 10970088. 47

BITENCOURT, D. P.; FUENTES, M. V.; MAIA, P. A.; AMORIM, F. T. Frequência, duração, abrangência espacial e intensidade das ondas de calor no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 506–517, 2016. ISSN 19824351. 3, 4, 26, 28, 36, 37, 47, 81

BITENCOURT, D. P.; RUAS, A. C.; MAIA, P. A. Análise da contribuição das variáveis meteorológicas no estresse térmico associada à morte de cortadores de cana-de-açúcar. **Cadernos De Saude Publica**, v. 28, n. 1, p. 65–74, 2012. 26

BOUCHER, O.; RANDALL, D.; ARTAXO, P.; BRETHERTON, C.; FEINGOLD, G.; FORSTER, P.; KERMINEN, V.-m.; KONDO, Y.; LIAO, H.; LOHMANN, U.; RASCH, P.; SATHEESH, S.; SHERWOOD, S.; STEVENS, B.; ZHANG, X.; QIN, D.; PLATTNER, G.-k.; TIGNOR, M.; ALLEN, S.; BOSCHUNG, J.; NAUELS, A.; XIA, Y.; BEX, V.; MIDGLEY, P. **Clouds and Aerosols. In: INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. The physical science basis: 2013.** [s.n.], 2013. 572–657 p. Disponível em: <<https://archive.ipcc.ch/pdf/assessment-report/ar5/wg1/WG1AR5{ }Chapter07{ }FINAL.pdf>>. 22

BRENA, N. A. **A chuva ácida e os seus efeitos sobre as florestas.** 2. ed. São Paulo: Biblioteca Nacional, 2009. 1–214 p. ISBN 9788590245896. 18

BRIMBLECOMBE, P.; HARA, H.; HOULE, D.; NOVAK, M. **Acid rain-deposition to recovery.** Norwich: Springer, 2007. 1–419 p. ISBN 9781402058844. 18

BRITO, J.; RIZZO, L. V.; MORGAN, W. T.; COE, H.; JOHNSON, B.; HAYWOOD, J.; LONGO, K.; FREITAS, S.; ANDREAE, M. O.; ARTAXO, P. Ground-based aerosol characterization during the South American Biomass Burning Analysis (SAMBBA) field experiment. **Atmospheric Chemistry and Physics**, v. 14, n. 22, p. 12069–12083, 2014. ISSN 16807324. 24

BROWN, B.; BULLOCK, R.; FOWLER, T.; GOTWAY, J. H.; NEWMAN, K.; JENSEN, T.; MEIER-FLEISCHER, K.; CARSLAW, D. C.; ROPKINS, K. Model Evaluation Tools Version 5.2 (METv5.2). **Environmental Modelling and**

**Software**, v. 27-28, p. 52–61, 2014. ISSN 13648152. Disponível em:

<<http://dx.doi.org/10.1016/j.envsoft.2011.09.008>>. 13

CALLEGARO, R. M.; ANDRZEJEWSKI, C.; GOMES, D. G.; TURCHETTO, F.; MEZZOMO, J. C.; GRIEBELER, A. Efeitos da chuva ácida em recursos florestais.

**Caderno de Pesquisa**, v. 27, n. 3, p. 13–20, 2015. 18

CARLSON, T. N.; WENDLING, P. Reflected radiance measured by noaa 3 vhrh as a function of optical depth for saharan dust. **Journal of Applied**

**Meteorology**, v. 16, n. 12, p. 1368–1371, 1977. Disponível em:

<[https://doi.org/10.1175/1520-0450\(1977\)016<1368:RRMBNV>2.0.CO;2](https://doi.org/10.1175/1520-0450(1977)016<1368:RRMBNV>2.0.CO;2)>.

23

CARRASCO, A. C.; LORENZO, M. S.; RODRÍGUEZ, N. Q. Método de Evaluación Diagnóstico Orientado a Objetos Modificado (MODEMod) utilizando la información de los satélites meteorológicos. **Ciencia de la Tierra y el**

**Espacio**, v. 15, n. 2, p. 139–150, 2014. Disponível em:

<<https://www.researchgate.net/publication/281452734>>. 10

CARRASCO, A. R. **Método de avaliação orientada a objeto aplicado às previsões de precipitação sobre a América do Sul**. 92 p. Dissertação

(Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017. Disponível em:

<<http://urlib.net/8JMKD3MGP3W34P/3NH9KMB>>. 10, 11, 12, 13, 15, 28, 35, 66

CECCHERINI, G.; RUSSO, S.; AMEZTOY, I.; Patricia Romero, C.;

CARMONA-MORENO, C. Magnitude and frequency of heat and cold waves in recent decades: the case of South America. **Natural Hazards and Earth**

**System Sciences**, v. 16, n. 3, p. 821–831, 2016. ISSN 16849981. Disponível em:

<[www.nat-hazards-earth-syst-sci.net/16/821/2016/](http://www.nat-hazards-earth-syst-sci.net/16/821/2016/)>. 26, 28, 47

CHAPMAN, E. G.; GUSTAFSON JUNIOR, W. I.; EASTER, R. C.; BARNARD, J. C.;

GHAN, S. J.; PEKOUR, M. S.; FAST, J. D. Coupling aerosol-cloud-radiative processes in the WRF-Chem model: investigating the radiative impact of elevated point sources. **Atmospheric Chemistry and**

**Physics**, v. 9, n. 3, p. 945–964, 2009. ISSN 16807324. 23

CHAZETTE, P.; TOTEMS, J.; SHANG, X. Atmospheric aerosol variability above the Paris Area during the 2015 heat wave - comparison with the 2003 and 2006

heat waves. **Atmospheric Environment**, v. 170, p. 216–233, dec 2017. ISSN

1352-2310. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1352231017306544>>. 27

CHENG, X.; SU, H. Effects of climatic temperature stress on cardiovascular diseases. **European Journal of Internal Medicine**, v. 21, n. 3, p. 164–167, 2010. ISSN 09536205. 4, 26

COSTANTINO, L.; BRÉON, F. M. Aerosol indirect effect on warm clouds over South-East Atlantic, from co-located MODIS and CALIPSO observations. **Atmospheric Chemistry and Physics**, v. 12, n. 1, p. 14197–14246, 2012. ISSN 16807316. 19

CURIER, L.; LEEUW, G.; KOLMONEN, P.; SUNDSTRÖM, A.-M.; SOGACHEVA, L.; BENNOUNA, Y. Aerosol retrieval over land using the (a)atsr dual-view algorithm. In: KOKHANOVSKY, A. A.; LEEUW, G. (Ed.). **Satellite aerosol remote sensing over land**. Chichester, UK: Springer, 2009. p. 135–159. 135 p. 19

DAVIS, C.; BROWN, B.; BULLOCK, R. Object-based verification of precipitation forecasts. Part I: methodology and application to mesoscale rain areas. **Monthly Weather Review**, v. 134, n. 7, p. 1772–1784, 2006. ISSN 0027-0644. Disponível em: <<https://journals.ametsoc.org/doi/pdf/10.1175/MWR3145.1><http://journals.ametsoc.org/doi/abs/10.1175/MWR3145.1>>. 9

DAVIS, C.; BROWN, B. G.; BULLOCK, R. Object-based verification of precipitation forecasts. Part II: application to convective rain systems. **Monthly Weather Review**, v. 134, n. 7, p. 1785–1795, 2006. ISSN 0027-0644. Disponível em: <<https://journals.ametsoc.org/doi/pdf/10.1175/MWR3146.1>>. 9

DAVIS, C. A.; BROWN, B. G.; BULLOCK, R.; HALLEY-GOTWAY, J. The Method for Object-Based Diagnostic Evaluation (MODE) Applied to Numerical Forecasts from the 2005 NSSL/SPC Spring Program. **Weather and Forecasting**, v. 24, n. 5, p. 1252–1267, 2009. ISSN 0882-8156. 9, 10, 12, 15, 66, 79

DOLIF, G.; ENGELBRECHT, A.; JATOBÁ, A.; SILVA, A. J. D. da; GOMES, J. O.; BORGES, M. R.; NOBRE, C. A.; CARVALHO, P. V. R. de. Resilience and brittleness in the ALERTA RIO system: a field study about the decision-making of forecasters. **Natural Hazards**, v. 65, n. 3, p. 1831–1847, 2013. ISSN 0921030X. Disponível em: <[https://link.springer.com/content/pdf/10.1007/978-3-319-11069-0\\_12](https://link.springer.com/content/pdf/10.1007/978-3-319-11069-0_12)>. 7

DUDHIA, J. A history of mesoscale model development. **Asia-Pacific Journal of Atmospheric Sciences**, v. 50, n. 1, p. 121–131, Jan 2014. ISSN 1976-7951.

Disponível em: <<https://doi.org/10.1007/s13143-014-0031-8>>. 1

EBERT, E.; MCBRIDE, J. Verification of precipitation in weather systems: determination of systematic errors. **Journal of Hydrology**, v. 239, n. 1–4, p. 179–202, 2000. Disponível em: <[www.elsevier.com/locate/jhydrol](http://www.elsevier.com/locate/jhydrol)>. 8

EBERT, E. E.; MCBRIDE, J. L. Routine verification of nwp quantitative precipitation forecasts for weather systems. In: AMERICAN METEOROLOGICAL SOCIETY, 1998. **Proceedings...** Phoenix, 1998. v. 16, p. J119–J122. 8

EDWARDS, P. N. History of climate modeling. **Wiley Interdisciplinary Reviews: Climate Change**, v. 2, n. 1, p. 128–139, 2011. ISSN 17577799.

Disponível em:

<<https://onlinelibrary.wiley.com/doi/pdf/10.1002/wcc.95>>. 23

ESCOBAR, G. C. J.; VAZ, J. C. M.; REBOITA, M. S. Circulação atmosférica em superfície associada às friagens no centro-oeste do Brasil. **Anuário do Instituto de Geociências**, v. 42, n. 1, p. 241–254, 2018. ISSN 1982-3908. Disponível em:

<[http://dx.doi.org/10.11137/2019\\_{\\_}1\\_{\\_}241\\_{\\_}254](http://dx.doi.org/10.11137/2019_{_}1_{_}241_{_}254)>. 30

EYRING, V. ESMValTool (v1.0) – a community diagnostic and performance metrics tool for routine evaluation of Earth system models in CMIP.

**Geoscientific Model Development**, v. 9, p. 1747–1802, 2016. Disponível em:

<<http://www.geosci-model-dev.net/9/1747/2016/http://www.esmvaltool.org/>>. 8

EYRING, V.; COX, P. M.; FLATO, G. M.; GLECKLER, P. J.; ABRAMOWITZ, G.; CALDWELL, P.; COLLINS, W. D.; GIER, B. K.; HALL, A. D.; HOFFMAN, F. M.; HURTT, G. C.; JAHN, A.; JONES, C. D.; KLEIN, S. A.; KRASTING, J. P.; KWIATKOWSKI, L.; LORENZ, R.; MALONEY, E.; MEEHL, G. A.; PENDERGRASS, A. G.; PINCUS, R.; RUANE, A. C.; RUSSELL, J. L.; SIMPSON, I. R.; SANDERSON, B. M.; SHERWOOD, S. C.; STOUFFER, R. J.; SANTER, B. D.; WILLIAMSON, M. S. Taking climate model evaluation to the next level. **Nature Climate Change**, v. 9, n. 2, p. 102–110, 2019. ISSN 1758-678X. 1, 5, 7, 8, 16

FAN, J.; ROSENFELD, D.; ZHANG, Y.; GIANGRANDE, S. E.; LI, Z.; MACHADO, L. A. T.; MARTIN, S. T.; YANG, Y.; WANG, J.; ARTAXO, P.;

BARBOSA, H. M. J.; BRAGA, R. C.; COMSTOCK, J. M.; FENG, Z.; GAO, W.; GOMES, H. B.; MEI, F.; PÖSCHL, U.; PÖHLKER, C.; PÖHLKER, M. L.; SOUZA, R. A. F. Substantial convection and precipitation enhancements by ultrafine aerosol particles. **Science**, v. 359, n. 6374, p. 411–418, 2018. ISSN 0036-8075. 19, 24

FERON, S.; CORDERO, R. R.; DAMIANI, A.; LLANILLO, P. J.; JORQUERA, J.; SEPULVEDA, E.; ASECIO, V.; LAROZE, D.; LABBE, F.; CARRASCO, J.; TORRES, G. Observations and projections of heat waves in South America. **Scientific Reports**, v. 9, n. 8173, p. 1–15, 2019. Disponível em: <<https://doi.org/10.1038/s41598-019-44614-4>>. 26

FINLAYSON-PITTS, B. J.; PITTS-JUNIOR, J. N. **Chemistry of the upper and lower atmosphere**. California, UK: Academic Press, 2000. 993 p. ISBN 978-0-12-257060-5. 3, 17

FLEMMING, J.; BOZZO, A.; BARRE, J.; ENGELEN, R.; GARRIGUES, S.; HOGAN, R.; HUIJNEN, V.; INNESS, A.; KIPLING, Z.; PARRINGTON, M.; REMY, S.; TSONEVSKY, I.; PEUCH, V.-H. **Does accounting for the direct-radiative effect of prognostic aerosols improve 5-day temperature forecast of the ECMWF weather forecast model?** 2020. Disponível em: <[https://presentations.copernicus.org/EGU2020/EGU2020-18254\\_presentation.pdf](https://presentations.copernicus.org/EGU2020/EGU2020-18254_presentation.pdf)>. 25

FLEMMING, J.; INNESS, A.; FLENTJE, H.; HUIJNEN, V.; MOINAT, P.; SCHULTZ, M. G.; STEIN, O. Coupling global chemistry transport models to ECMWF's integrated forecast system. **Geoscientific Model Development**, v. 2, n. 2, p. 253–265, 2009. ISSN 19919603. 2

FORNARO, A. Águas de chuva: conceitos e breve histórico. há chuva ácida no Brasil? **Revista USP**, n. 70, p. 78–87, 2006. 18

FRASSONI, A.; FRANÇA, D. A.; CHOVERT, A.; SILVA, F.; G.PEREIRA; EIRAS, D.; OLIVEIRA, V.; FREITAS, S.; LONGO, K.; M.ALONSO. Prep-chem-src version 1.8: improvements to better represent local urban and biomass burning emissions over south america. In: **The 2017 Blue Book**. [S.l.]: World Meteorological Organization, World Climate Research Program – Working Group on Numerical, 2018. p. 4–7. 2, 31

FREITAS, S. R. **Modelagem numérica do transporte e das emissões de gases traços e aerossóis de queimadas no Cerrado e Floresta Tropical da**

**América do Sul.** 205 p. Tese (Doutorado em Física) — Universidade de São Paulo, São Paulo, 1999. [2](#)

FREITAS, S. R.; LONGO, K. M.; ALONSO, M. F.; PIRRE, M.; MARECAL, V.; GRELL, G.; STOCKLER, R.; MELLO, R. F.; SÁNCHEZ-GÁCITA, M. PREP-CHEM-SRC – 1.0: a preprocessor of trace gas and aerosol emission fields for regional and global atmospheric chemistry models. **Geoscientific Model Development**, v. 4, n. 2, p. 419–433, 2011. ISSN 1991959X. [2](#), [25](#), [31](#)

FREITAS, S. R.; LONGO, K. M.; ANDREAE, M. O. Impact of including the plume rise of vegetation fires in numerical simulations of associated atmospheric pollutants. **Geophysical Research Letters**, v. 33, p. 1–5, 2006. [2](#), [25](#), [31](#)

FREITAS, S. R.; LONGO, K. M.; SILVA DIAS, M. A. F.; SILVA DIAS, P. L. Emissões de queimadas em ecossistemas da América do Sul. **Estudos Avançados**, v. 19, n. 53, p. 167–185, 2005. [2](#), [3](#), [16](#), [23](#), [24](#)

FREITAS, S. R.; LONGO, K. M.; SILVA DIAS, M. A. F.; SILVA DIAS, P. L.; CHATFIELD, R.; PRINS, E.; ARTAXO, P.; GRELL, G. A.; RECUERO, F. S. Monitoring the transport of biomass burning emissions in South America. **Environmental Fluid Mechanics**, v. 5, n. 1-2, p. 135–167, 2005. ISSN 1567-7419. [28](#), [30](#)

FREITAS, S. R.; LONGO, K. M.; SILVA DIAS, M. A. F.; CHATFIELD, R.; SILVA DIAS, P.; ARTAXO, P.; ANDREAE, M. O.; GRELL, G.; RODRIGUES, L. F.; FAZENDA, A.; PANETTA, J. The coupled aerosol and tracer transport model to the brazilian developments on the regional atmospheric modeling system (catt-brams) - part 1: model description and evaluation. **Atmospheric Chemistry and Physics Discussions**, v. 9, p. 2843–2861, 2009. [2](#), [30](#)

FREITAS, S. R.; PANETTA, J.; LONGO, K. M.; RODRIGUES, L. F.; MOREIRA, D. S.; ROSÁRIO, N. E.; SILVA DIAS, P. L.; SILVA DIAS, M. A.; SOUZA, E. P.; FREITAS, E. D.; LONGO, M.; FRASSONI, A.; FAZENDA, A. L.; SANTOS E SILVA, C. M.; PAVANI, C. A.; EIRAS, D.; FRANÇA, D. A.; MASSARU, D.; SILVA, F. B.; SANTOS, F. C.; PEREIRA, G.; CAMPONOGARA, G.; FERRADA, G. A.; Campos Velho, H. F.; MENEZES, I.; FREIRE, J. L.; ALONSO, M. F.; GÁCITA, M. S.; ZARZUR, M.; FONSECA, R. M.; LIMA, R. S.; SIQUEIRA, R. A.; BRAZ, R.; TOMITA, S.; OLIVEIRA, V.; MARTINS, L. D. The Brazilian developments on the Regional Atmospheric Modeling System (BRAMS 5.2): an integrated environmental model tuned for

tropical areas. **Geoscientific Model Development**, v. 10, n. 1, p. 189–222, 2017. ISSN 19919603. 30

GÁCITA, M. S.; LONGO, K. M.; FREIRE, J. L.; FREITAS, S. R.; MARTIN, S. T. Impact of mixing state and hygroscopicity on CCN activity of biomass burning aerosol in Amazonia. **Atmospheric Chemistry and Physics**, v. 17, n. 3, p. 2373–2392, 2017. ISSN 16807324. 19

GEIRINHAS, J. L.; TRIGO, R. M.; LIBONATI, R.; COELHO, C. A. S.; PALMEIRA, A. C. Climatic and synoptic characterization of heat waves in Brazil. **International Journal of Climatology**, v. 38, n. 4, p. 1760–1776, 2018. ISSN 08998418. Disponível em: <<http://doi.wiley.com/10.1002/joc.5294>>. 27, 47

GILLELAND, E.; AHIJEVYCH, D.; EBERT, E. E.; CASATI, B.; BROWN, B. G. Intercomparison of spatial forecast verification methods. **Weather and Forecasting**, v. 24, n. 5, p. 1416–1430, 2009. ISSN 0882-8156. Disponível em: <<http://www.ral.ucar.edu/projects/icp/>>. 9, 16

GLECKLER, P. J.; DOUTRIAUX, C.; DURACK, P. J.; TAYLOR, K. E.; ZHANG, Y.; WILLIAMS, D. N.; MASON, E.; SERVONNAT, J. A more powerful reality test for climate models. **Eos**, v. 97, 2016. 8

GRELL, G.; FREITAS, S. R.; STUEFER, M.; FAST, J. Inclusion of biomass burning in WRF-Chem: impact of wildfires on weather forecasts. **Atmospheric Chemistry and Physics**, v. 11, n. 11, p. 5289–5303, 2011. ISSN 16807316. 23

GRELL, G. A.; PECKHAM, S. E.; SCHMITZ, R.; MCKEEN, S. A.; FROST, G.; SKAMAROCK, W. C.; EDER, B. Fully coupled “online” chemistry within the WRF model. **Atmospheric Environment**, v. 39, n. 37, p. 6957–6975, 2005. ISSN 13522310. 23

GRENNFELT, P.; BENGTSON, C.; SKARBY, L. An estimation of the atmospheric input of acidifying substances to a forest ecosystem. In: HUTCHINSON, T. C.; HAVAS, M. (Ed.). **Effects of acid precipitation on terrestrial ecosystems**. Toronto: Springer, 1980. v. 4, p. 29–40. 18

GREY, W. M. F.; NORTH, P. R. J. Aerosol optical depth from dual-view (a) atsr satellite observations. In: KOKHANOVSKY, A. A.; LEEUW, G. (Ed.). **Satellite aerosol remote sensing over land**. Chichester, UK: Springer, 2009. p. 161–192. 162 p. 17, 20

GRIFFIES, S. M. **Elements of the Modular Ocean Model (MOM) 2012 release with updates**. Princeton, USA: [s.n.], 2012. 1–632 p. Disponível em: [www.gfdl.noaa.gov/fms](http://www.gfdl.noaa.gov/fms).>. 33

GRIFFIN, S. M.; OTKIN, J. A.; ROZOFF, C. M.; SIEGLAFF, J. M.; CRONCE, L. M.; ALEXANDER, C. R.; JENSEN, T. L.; WOLFF, J. K. Seasonal analysis of cloud objects in the High-Resolution Rapid Refresh (HRRR) model using object-based verification. **Journal of Applied Meteorology and Climatology**, v. 56, n. 8, p. 2317–2334, 2017. ISSN 15588432. Disponível em: [www.ametsoc.org/PUBSReuseLicenses](http://www.ametsoc.org/PUBSReuseLicenses)>. 10

HAJAT, S.; ARMSTRONG, B.; BACCINI, M.; BIGGERI, A.; BISANTI, L.; RUSSO, A.; PALDY, A.; MENNE, B.; KOSATSKY, T. Impact of high temperatures on mortality: is there an added heat wave effect? **Epidemiology**, v. 17, n. 6, p. 632–638, 2006. ISSN 1044-3983. 4, 26

HAYWOOD, J.; BOUCHER, O. Estimates of the direct and indirect radiative forcing due to tropospheric aerosols: a review. **Reviews of Geophysics**, v. 38, n. 4, p. 513–543, 2000. ISSN 87551209. 17, 19

HERSBACH, H. Decomposition of the continuous ranked probability score for ensemble prediction systems. **Weather and Forecasting**, v. 15, n. 5, p. 559–570, 2000. ISSN 0882-8156. Disponível em: [http://journals.ametsoc.org/doi/abs/10.1175/1520-0434\(2000\)29015:3C0559:3ADOTCRP3E2.0.CO;3B2](http://journals.ametsoc.org/doi/abs/10.1175/1520-0434(2000)29015:3C0559:3ADOTCRP3E2.0.CO;3B2)>. 7

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HORÁNYI, A.; SABATER, J. M.; NICOLAS, J.; RADU, R.; SCHEPERS, D.; SIMMONS, A.; SOCI, C.; DEE, D. Global reanalysis: goodbye ERA-Interim, hello ERA5. **ECMWF Newsletter**, n. 159, p. 17–24, 2019. 34, 44

HOELZEMANN, J. J.; LONGO, K. M.; FONSECA, R. M.; Do Rosário, N. M. E.; EIBERN, H.; FREITAS, S. R.; PIRES, C. Regional representative of AERONET observation sites during the biomass burning season in South America determined by correlation studies with MODIS Aerosol Optical Depth. **Journal of Geophysical Research Atmospheres**, v. 114, n. 13, p. 1–20, 2009. ISSN 01480227. 24

HUSSAIN, M.; MAHMUD, I. Pymannkendall: a python package for non parametric mann kendall family of trend tests. **Journal of Open Source**

**Software**, v. 4, n. 39, p. 1556, 7 2019. ISSN 2475-9066. Disponível em:  
<<http://dx.doi.org/10.21105/joss.01556>>. 38

INFOESCOLA. **América do Sul**. 2019. Disponível em:  
<<https://www.infoescola.com/geografia/america-do-sul/>>. 28

JI, L.; SENAY, G. B.; VERDIN, J. P. Evaluation of the Global Land Data Assimilation System (GLDAS) air temperature data products. **Journal of Hydrometeorology**, v. 16, n. 6, p. 2463–2480, 2015. ISSN 1525-755X. Disponível em: <<http://daymet.ornl.gov/>>. 16

KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. [S.l.]: Cambridge University Press, 2002. 1 p. 1

KASAHARA, A.; KANAMITSU, M. Weather prediction, numerical. In: MEYERS, R. A. (Ed.). **Encyclopedia of physical science and technology**. [S.l.]: Elsevier, 2003. p. 805–835. 7

KOLUSU, S. R.; MARSHAM, J. H.; MULCAHY, J.; JOHNSON, B.; DUNNING, C.; BUSH, M.; SPRACKLEN, D. V. Impacts of Amazonia biomass burning aerosols assessed from short-range weather forecasts. **Atmospheric Chemistry and Physics Discussions**, v. 15, n. 13, p. 12251–12266, 2015. ISSN 16807375. 25, 56, 119

LEE, W. L.; LIOU, K. N.; HE, C.; LIANG, H. C.; WANG, T. C.; LI, Q.; LIU, Z.; YUE, Q. Impact of absorbing aerosol deposition on snow albedo reduction over the southern Tibetan plateau based on satellite observations. **Theoretical and Applied Climatology**, v. 129, n. 3-4, p. 1373–1382, 2017. ISSN 14344483. Disponível em: <<https://lta.cr.usgs.gov/GTOP030>>. 21

LEVY, R. C. The dark-land modis collection 5 aerosol retrieval: algorithm development and product evaluation. In: KOKHANOVSKY, A. A.; LEEUW, G. (Ed.). **Satellite aerosol remote sensing over land**. Chichester, UK: Springer, 2009. p. 19–68. 20 p. 17, 18

LIU, K. N. **An introduction to atmospheric radiation**. 2. ed. California, UK: Elsevier Science, 2002. 1–579 p. ISBN 0124514510. 20, 116

LONGO, K. M.; FREITAS, S. R.; PIRRE, M.; MARÉCAL, V.; RODRIGUES, L. F.; ALONSO, M. F.; MELLO, R. The chemistry-catt brams model: a new efficient tool for atmospheric chemistry studies at local and regional scales. **Geoscience Model Development Discuss**, 2011. 25, 28, 30

LONGO, K. M.; FREITAS, S. R.; PIRRE, M.; MARÉCAL, V.; RODRIGUES, L. F.; PANETTA, J.; ALONSO, M. F.; ROSÁRIO, N. E.; MOREIRA, D. S.; GÁCITA, M. S.; ARTETA, J.; FONSECA, R.; STOCKLER, R.; KATSURAYAMA, D. M.; FAZENDA, A.; BELA, M. The Chemistry CATT-BRAMS model (CCATT-BRAMS 4.5): a regional atmospheric model system for integrated air quality and weather forecasting and research. **Geoscientific Model Development**, v. 6, n. 5, p. 1389–1405, 2013. ISSN 1991959X. Disponível em:

<[www.geosci-model-dev-discuss.net/6/1173/2013/](http://www.geosci-model-dev-discuss.net/6/1173/2013/)>. 23, 25, 30

LONGO, K. M.; FREITAS, S. R.; SETZER, A.; PRINS, E.; ARTAXO, P.; ANDREAE, M. O. The Coupled Aerosol and Tracer Transport model to the Brazilian developments on the Regional Atmospheric Modeling System (CATT-BRAMS) – Part 2: model sensitivity to the biomass burning inventories. **Atmospheric Chemistry and Physics**, v. 7, n. 6, p. 8571–8595, 2007. ISSN 8571-8595. Disponível em: <[www.atmos-chem-phys-discuss.net/7/8571/2007/www.atmos-chem-phys.org/acpd/5/11143/SRef-ID:1680-7375/acpd/2005-5-11143EuropeanGeosciencesUnion](http://www.atmos-chem-phys-discuss.net/7/8571/2007/www.atmos-chem-phys.org/acpd/5/11143/SRef-ID:1680-7375/acpd/2005-5-11143EuropeanGeosciencesUnion)>. 23

LONGO, K. M.; THOMPSON, A. M.; KIRCHHOFF, V. W. J. H.; REMER, L. A.; FREITAS, S. R.; SILVA DIAS, M. A. F.; HART, W.; ARTAXO, P.; SPINHIRNE, J. D.; YAMASOE, M. A. Correlation between smoke and tropospheric ozone concentration in Cuiabá during Smoke, Clouds, and Radiation-Brazil (SCAR-B). **Journal of Geophysical Research: Atmospheres**, v. 104, n. D10, p. 12113–12129, 1999. 2

LORENZO, S. M.; MONTEJO, B. I.; FERNÁNDEZ, M. H.; CARRASCO, A. R.; GENÓ, C. F. R.; PROVEYER, L. V.; HERNÁNDEZ, A. L. F. Detection, reporting and evaluation tools for outputs from numerical forecast models developed in Cuba. **Revista Cubana de Meteorología**, v. 22, n. 2, p. 150–163, 2016. Disponível em:

<<http://rcm.insmet.cu/index.php/rcm/article/viewFile/216/173>>. 10

LUCAS-PICHER, P.; CATTIAUX, J.; BOUGIE, A.; LAPRISE, R. How does large-scale nudging in a regional climate model contribute to improving the simulation of weather regimes and seasonal extremes over North America? **Climate Dynamics**, v. 46, n. 3-4, p. 929–948, 2016. ISSN 14320894. 33

MALLET, M.; TULET, P.; SERÇA, D.; SOLMON, F.; DUBOVIK, O.; PELON, J.; VPONT; THOURON, O. Impact of dust aerosols on the radiative budget,

surface heat fluxes, heating rate profiles and convective activity over West Africa during March 2006. **Atmospheric Chemistry and Physics**, v. 9, n. 18, p. 7143–7160, 2009. ISSN 16807324. Disponível em:

<[www.atmos-chem-phys.net/9/7143/2009/](http://www.atmos-chem-phys.net/9/7143/2009/)>. 21, 22

MARZBAN, C.; SANDGATHE, S. Cluster analysis for verification of precipitation fields. **Weather and Forecasting**, v. 21, n. 5, p. 824–838, 2006. ISSN 0882-8156. Disponível em:

<<https://journals.ametsoc.org/doi/pdf/10.1175/WAF948.1>>. 8

\_\_\_\_\_. Cluster analysis for object-oriented verification of fields: a variation.

**Monthly Weather Review**, v. 136, n. 3, p. 1013–1025, 2008. ISSN 0027-0644.

Disponível em:

<<https://journals.ametsoc.org/doi/pdf/10.1175/2007MWR1994.1>>. 9

MASS, C.; ROBOCK, A. The short-term of the Mount St. Helens volcanic eruption on surface temperature in the Northwest United States. **Monthly Weather Review**, v. 110, p. 614–622, 1982. 21, 22

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **SCANTEC - Sistema Comunitário de Avaliação de modelos Numéricos de Tempo e Clima**. 2017. BR 51 2017 000576-1, 13-junho-2017. 5, 10

MESINGER, F.; ARAKAWA, A. Numerical methods used in climate models.

**GARP Publication Series**, v. 1, n. 17, p. 1–64, 1976. Disponível em:

<[http://oceanrep.geomar.de/40278/1/Mesinger{}\\_ArakawaGARP.pdf](http://oceanrep.geomar.de/40278/1/Mesinger{}_ArakawaGARP.pdf)>. 30

MITCHELL JUNIOR, J. M. The effect of atmospheric aerosols on climate with special reference to temperature near the earth's surface. **Journal of Applied Meteorology**, v. 10, p. 703–714, 1971. 21

MITTERMAIER, M. P.; BULLOCK, R. Using MODE to explore the spatial and temporal characteristics of cloud cover forecasts from high-resolution NWP models. **Meteorological Applications**, v. 20, n. 2, p. 187–196, 2013. ISSN 13504827. 10

MOREIRA, D. S. **Simulação numérica do ciclo do carbono na Amazônia**. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. 1

MOREIRA, D. S.; FREITAS, S. R.; BONATTI, J. P.; MERCADO, L. M.; É. Rosário, N. M.; LONGO, K. M.; MILLER, J. B.; GLOOR, M.; GATTI, L. V. Coupling between the JULES land-surface scheme and the CCATT-BRAMS

atmospheric chemistry model (JULES-CCATT-BRAMS1.0): applications to numerical weather forecasting and the CO<sub>2</sub> budget in South America. **Geoscientific Model Development**, v. 6, n. 4, p. 1243–1259, 2013. ISSN 1991959X. Disponível em: <[www.geosci-model-dev.net/6/1243/2013/](http://www.geosci-model-dev.net/6/1243/2013/)>. 1, 28, 30, 31, 32

MOREIRA, D. S.; LONGO, K. M.; FREITAS, S. R.; YAMASOE, M. A.; MERCADO, L. M.; ROSÁRIO, N. E.; GLOOR, E.; VIANA, R. S.; MILLER, J. B.; GATTI, L. V.; WIEDEMANN, K. T.; DOMINGUES, L. K.; CORREIA, C. C. Modeling the radiative effects of biomass burning aerosols on carbon fluxes in the Amazon region. **Atmospheric Chemistry and Physics**, v. 17, n. 23, p. 14785–14810, 2017. ISSN 16807324. Disponível em: <<https://doi.org/10.5194/acp-17-14785-2017>>. 25, 30, 56

MULCAHY, J. P.; WALTERS, D. N.; BELLOUIN, N.; MILTON, S. F. Impacts of increasing the aerosol complexity in the Met Office global numerical weather prediction model. **Atmospheric Chemistry and Physics**, v. 14, n. 9, p. 4749–4778, 2014. ISSN 16807324. 23

MYHRE, G.; SHINDELL, D.; BRÉON, F.-M.; COLLINS, W.; FUGLESTVEDT, J.; HUANG, J.; KOCH, D.; LAMARQUE, J.-F.; LEE, D.; MENDOZA, B.; NAKAJIMA, T.; ROBOCK, A.; STEPHENS, G.; TAKEMURA, T.; ZHANG, H. **Anthropogenic and natural radiative forcing**. Springer, 2013. 659–740 p. Disponível em: <<http://link.springer.com/10.1007/978-1-4614-1040-9>> <[http://www.wrap.org.uk/sites/files/wrap/New\\_Markets\\_for\\_AD\\_WRAP\\_format\\_Final\\_v2.c6779ccd.11341.pdf](http://www.wrap.org.uk/sites/files/wrap/New_Markets_for_AD_WRAP_format_Final_v2.c6779ccd.11341.pdf)> <<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Specification+for+whole+digestate+,+s>>. 19, 20, 21, 22

NACHAMKIN, J. E. Application of the composite method to the spatial forecast verification methods intercomparison dataset. **Weather and Forecasting**, v. 24, n. 5, p. 1390–1400, 2009. ISSN 0882-8156. Disponível em: <<https://journals.ametsoc.org/doi/pdf/10.1175/2009WAF2222225.1>>. 8

NAGESWARARAO, M. M.; MOHANTY, U. C.; KIRAN PRASAD, S.; OSURI, K. K.; RAMAKRISHNA, S. S. Performance evaluation of NCEP climate forecast system for the prediction of winter temperatures over India. **Theoretical and Applied Climatology**, v. 126, n. 3-4, p. 437–451, 2016. ISSN 14344483. Disponível em: <<https://>>

[//link.springer.com/content/pdf/10.1007/978-3-319-25007-0\\_16](https://link.springer.com/content/pdf/10.1007/978-3-319-25007-0_16).  
16

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA.  
**NOAA-GFS**. 2019. Disponível em: <<https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-forecast-system-gfs>>.  
Acesso em: 06 abr. 2019. 33

\_\_\_\_\_. **SURFRAD aerosol optical depth**. 2019. Disponível em:  
<<https://www.esrl.noaa.gov/gmd/grad/surfrad/aod/>>. Acesso em: 20 Mar.  
2019. 22

NISSAN, H.; BURKART, K.; PEREZ, E. C. de; VAN AALST, M.; MASON, S.  
Defining and predicting heat waves in Bangladesh. **Journal of Applied  
Meteorology and Climatology**, v. 56, n. 10, p. 2653–2670, 2017. ISSN  
15588432. 27, 85

OBERLÄNDER-HAYN, S.; GERBER, E. P.; ABALICHIN, J.; AKIYOSHI, H.;  
KERSCHBAUMER, A.; KUBIN, A.; KUNZE, M.; LANGEMATZ, U.; MEUL, S.;  
MICHOU, M.; MORGENSTERN, O.; OMAN, L. D. Is the Brewer-Dobson  
circulation increasing or moving upward? **Geophysical Research Letters**, v. 43,  
n. 4, p. 1772–1779, 2016. ISSN 19448007. 2, 22

OKE, T. R. **Boundary layer climates**. 2. ed. Routledge, 1987. ISBN  
0470993642,9780470993644,0470993812,9780470993811,  
0416705308, 9780416705300,0416705200,9780416705201. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=2A3816FC19FB375DFE99363F9B9F0C57>>.  
3

PAN, H.-L.; MAHRT, L. Interaction between soil hydrology and boundary-layer  
development. **Boundary-Layer Meteorology**, v. 38, p. 185–202, 1987.  
Disponível em:  
<<https://link.springer.com/content/pdf/10.1007/BF00121563.pdf>>. 33

PAVANI, C. A. B.; FREITAS, S. R. de; LIMA, W. F. A.; COELHO, S. M. S.  
d. C.; ROSÁRIO, N. M. É. do; MOREIRA, D. S.; YOSHIDA, M. C. Including  
functionalities in BRAMS model to simulate the volcanic ash transport: description  
and sensitivity analysis applied to the eruptive event of Puyehue in 2011. **Revista  
Brasileira de Meteorologia**, v. 31, n. 4, p. 377–393, 2016. ISSN 19824351.  
Disponível em: <<http://dx.doi.org/10.1590/0102-778631231420150035>>. 25

PENNA, B. R. **Impacto dos aerossóis na reanálise Merra-Z**. 126 p. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018. Disponível em:

<<http://urlib.net/8JMKD3MGP3W34R/3R35M4H>>. 120

PEREIRA, G.; FREITAS, S. R.; MORAES, E. C.; FERREIRA, N. J.; SHIMABUKURO, Y. E.; RAO, V. B.; LONGO, K. M. Estimating trace gas and aerosol emissions over South America: relationship between fire radiative energy released and aerosol optical depth observations. **Atmospheric Environment**, v. 43, n. 40, p. 6388–6397, 2009. ISSN 13522310. 24

PETTY, G. W. **Atmospheric radiation**. 2. ed. [S.l.]: Sundog, 2006. 1–445 p. 20

PÖSCHL, U. Atmospheric aerosols: composition, transformation, climate and health effects. **Angewandte Chemie**, v. 44, n. 46, p. 7520–7540, 2005. ISSN 14337851. 2, 17, 18, 22

PROCOPIO, A. S.; ARTAXO, P.; KAUFMAN, Y. J.; REMER, L. A.; SCHAFER, J. S.; HOLBEN, B. N. Multiyear analysis of amazonian biomass burning smoke radiative forcing of climate. **Geophysical Research Letters**, v. 31, n. 3, p. 1–4, 2004. ISSN 00948276. 22

PROCOPIO, A. S.; REMER, L. A.; ARTAXO, P.; KAUFMAN, Y. J.; HOLBEN, B. N. Modeled spectral optical properties for smoke aerosols in Amazonia. **Geophysical Research Letters**, v. 30, n. 24, p. 1–5, 2003. ISSN 00948276. 24

RAIBLE, C. C.; BRÖNNIMANN, S.; AUCHMANN, R.; BROHAN, P.; FRÖLICHER, T. L.; GRAF, H. F.; JONES, P.; LUTERBACHER, J.; MUTERS, S.; NEUKOM, R.; ROBOCK, A.; SELF, S.; SUDRAJAT, A.; TIMMRECK, C.; WEGMANN, M. Tambora 1815 as a test case for high impact volcanic eruptions: Earth system effects. **Wiley Interdisciplinary Reviews: Climate Change**, v. 7, n. 4, p. 569–589, 2016. ISSN 17577799. Disponível em: <<https://onlinelibrary.wiley.com/doi/pdf/10.1002/wcc.407>>. 22

RAMANATHAN, V.; CARMICHAEL, G. Global and regional climate changes due to black carbon. **Nature Geoscience**, v. 1, n. 4, p. 221–227, 2008. ISSN 17520894. Disponível em:

<<http://www.nature.com/ngeo/journal/v1/n4/full/ngeo156.html>>. 21

REALE, O.; LAU, K. M.; SILVA, A. da. Impact of interactive aerosol on the african easterly jet in the nasa geos-5 global forecasting system. **Weather and**

**Forecasting**, v. 26, n. 4, p. 504–519, 2011. Disponível em:

<<https://doi.org/10.1175/WAF-D-10-05025.1>>. 2

REBOITA, M. S.; KRUSCHE, N.; AMBRIZZI, T.; ROCHA, R. P. Entendendo o tempo e o clima na América do Sul. **Terra e Didática**, v. 8, n. 1, p. 34–50, 2012. 29, 42

REDDINGTON, C. L.; BUTT, E. W.; RIDLEY, D. A.; ARTAXO, P.; MORGAN, W. T.; COE, H.; SPRACKLEN, D. V. Air quality and human health improvements from reductions in deforestation-related fire in Brazil. **Nature Geoscience**, v. 8, n. 10, p. 768–771, 2015. ISSN 17520908. 16

REIS, N. C. S.; BOIASKI, N. T.; FERRAZ, S. E. T. Characterization and spatial coverage of heat waves in subtropical Brazil. **Atmosphere**, v. 10, n. 284, p. 2–15, may 2019. 26, 47

RÉMY, S.; BENEDETTI, A.; BOZZO, A.; HAIDEN, T.; JONES, L.; RAZINGER, M.; FLEMMING, J.; ENGELEN, R. J.; PEUCH, V. H.; THEPAUT, J. N. Feedbacks of dust and boundary layer meteorology during a dust storm in the eastern Mediterranean. **Atmospheric Chemistry and Physics**, v. 15, n. 22, p. 12909–12933, 2015. ISSN 16807324. 19, 24

RIESE, M.; PLOEGER, F.; RAP, A.; VOGEL, B.; KONOPKA, P.; DAMERIS, M.; FORSTER, P. Impact of uncertainties in atmospheric mixing on simulated UTLS composition and related radiative effects. **Journal of Geophysical Research: Atmospheres**, v. 117, n. D16, p. 1–10, 2012. 2, 22

ROBOCK, A. Surface cooling due to forest fire smoke. **Journal of Geophysical Research**, v. 96, n. D11, p. 20869–20878, 1991. ISSN 0148-0227. 21

\_\_\_\_\_. Volcanic eruptions and climate. **Reviews of Geophysics**, v. 38, n. 2, p. 191–219, 2000. ISSN 00371777. 22

ROMESBURG, C. **Cluster analysis for researchers**. [S.l.]: Lulu, 2004. 38

ROSÁRIO, N. E.; LONGO, K. M.; FREITAS, S. R.; YAMASOE, M. A.; FONSECA, R. M. Modeling the South American regional smoke plume: aerosol optical depth variability and surface shortwave flux perturbation. **Atmospheric Chemistry and Physics**, v. 13, n. 6, p. 2923–2938, 2013. ISSN 16807324. 24, 25, 56, 116

ROSENFELD, D.; LOHMANN, U.; RAGA, G. B.; O'DOWD, C. D.; KULMALA, M.; FUZZI, S.; REISELL, A.; ANDREAE, M. O. Flood or drought: how do aerosols affect precipitation? **Science**, v. 321, n. 5894, p. 1309–1313, 2008. ISSN 0036-8075. 19

ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of Computational and Applied Mathematics**, v. 20, n. C, p. 53–65, 1987. ISSN 03770427. 39

SAHA, S.; MOORTHY, S.; PAN, H.-L.; WU, X.; WANG, J.; NADIGA, S.; TRIPP, P.; KISTLER, R.; WOOLLEN, J.; BEHRINGER, D.; LIU, H.; STOKES, D.; GRUMBINE, R.; GAYNO, G.; WANG, J.; HOU, Y.-T.; CHUANG, H.-y.; JUANG, H.-M. H.; SELA, J.; IREDELL, M.; TREADON, R.; KLEIST, D.; VAN DELST, P.; KEYSER, D.; DERBER, J.; EK, M.; MENG, J.; WEI, H.; YANG, R.; LORD, S.; DOOL, H. van den; KUMAR, A.; WANG, W.; LONG, C.; CHELLIAH, M.; XUE, Y.; HUANG, B.; SCHEMM, J.-K.; EBISUZAKI, W.; LIN, R.; XIE, P.; CHEN, M.; ZHOU, S.; HIGGINS, W.; ZOU, C.-Z.; LIU, Q.; CHEN, Y.; HAN, Y.; CUCURULL, L.; REYNOLDS, R. W.; RUTLEDGE, G.; GOLDBERG, M. The NCEP climate forecast system reanalysis. **Bulletin of the American Meteorological Society**, v. 91, n. 8, p. 1015–1058, 2010. ISSN 0003-0007. Disponível em: <<http://cfs.ncep.noaa.gov/cfsr>>. 33

SANTOS, A. F. dos; FREITAS, S. R.; MATTOS, J. G. Z. de; VELHO, H. F. de C.; GAN, M. A.; LUZ, E. F. P. da; GRELL, G. A. Using the firefly optimization method to weight an ensemble of rainfall forecasts from the brazilian developments on the regional atmospheric modeling system (brams). **Advances in Geosciences**, v. 14, p. 1–13, 2013. ISSN 1680-7340 and 1680-7359. Acesso em: 27 jul. 2013. 30

SANTOS E SILVA, C. M.; FREITAS, S. R. de; GIELOW, R. Numerical simulation of the diurnal cycle of rainfall in sw amazon basin during the 1999 rainy season: the role of convective trigger function. **Theoretical and Applied Climatology**, v. 109, p. 473, 2012. 30

SAPUCCI, L. F.; MATTOS, J. G. Z.; FRASSONI, A.; GONÇALVES, L. G. G.; BASTARZ, C.; SCHUBERT, D. V. Potencialidades do SCAMTEC (Sistema de Avaliação de Modelos Numérico de Previsão de Tempo e Clima) na avaliação de previsões de precipitação. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 17. **Anais... CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA**, 2011. p. 5. Disponível em:

<[http://plutao.dpi.inpe.br/col/dpi.inpe.br/plutao/2011/06.11.15.03/doc/Sapucci\\_potencialidades.pdf](http://plutao.dpi.inpe.br/col/dpi.inpe.br/plutao/2011/06.11.15.03/doc/Sapucci_potencialidades.pdf)>. 10

SATURNO, J.; DITAS, F.; VRIES, M. P.; HOLANDA, B. A.; PÖHLKER, M. L.; CARBONE, S.; WALTER, D.; BOBROWSKI, N.; BRITO, J.; CHI, X.; GUTMANN, A.; ANGELIS, I. H.; MACHADO, L. A.; MORAN-ZULOAGA, D.; RÜDIGER, J.; SCHNEIDER, J.; SCHULZ, C.; WANG, Q.; WENDISCH, M.; ARTAXO, P.; WAGNER, T.; PÖSCHL, U.; ANDREAE, M. O.; PÖHLKER, C. African volcanic emissions influencing atmospheric aerosols over the Amazon rain forest. **Atmospheric Chemistry and Physics**, v. 18, n. 14, p. 10391–10405, 2018. ISSN 16807324. 19, 24

SCOTT, C. E.; ARNOLD, S. R.; MONKS, S. A.; ASMI, A.; PAASONEN, P.; SPRACKLEN, D. V. Substantial large-scale feedbacks between natural aerosols and climate. **Nature Geoscience**, v. 11, n. 1, p. 44–48, 2018. ISSN 17520908. 22

SEINFELD, J. H.; PANDIS, S. N. **Atmospheric chemistry and physics: from air pollution to climate change**. 2. ed. New Jersey: John Wiley and Sons, 2006. 1225 p. ISSN 0013-9157. ISBN 9780471720188. 2, 17, 18, 19, 20, 21, 22

SETZER, A. W.; PEREIRA, M. C. Amazonia biomass burnings in 1987 and an estimate of their tropospheric emissions. **A Journal of the Human Environment**, v. 20, n. 1, p. 19–22, 1991. ISSN 00447447. 16

SILVA, F. B. **Análise dos efeitos combinados da Ilha de Calor Urbana e poluição do ar**. 269 p. (INPE-10394-TDI/920). Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016. 3

SILVEIRA, I. H.; OLIVEIRA, B. F. A.; CORTES, T. R.; JUNGER, W. L. The effect of ambient temperature on cardiovascular mortality in 27 Brazilian cities. **Science of The Total Environment**, v. 691, p. 996–1004, nov 2019. ISSN 00489697. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0048969719330669>>. 4, 26

SUZUKI, K.; TAKEMURA, T. Perturbations to global energy budget due to absorbing and scattering aerosols. **Journal of Geophysical Research: Atmospheres**, p. 1–16, 2019. ISSN 2169-897X. 19

TARTAGLIONE, N.; CASAIOLI, M.; MARIANI, S.; ACCADIA, C.; SPERANZA, A. Comparison of rain gauge observations with modeled precipitation over Cyprus

using contiguous rain area analysis. **Atmospheric Chemistry and Physics**, v. 5, n. 8, p. 2147–2154, 2005. Disponível em:

<[www.atmos-chem-phys.org/acp/5/2147/SRef-ID:1680-7324/acp/2005-5-2147EuropeanGeosciencesUnion](http://www.atmos-chem-phys.org/acp/5/2147/SRef-ID:1680-7324/acp/2005-5-2147EuropeanGeosciencesUnion)>. 8

TIMMRECK, C. Modeling the climatic effects of large explosive volcanic eruptions. **Wiley Interdisciplinary Reviews: Climate Change**, v. 3, n. 6, p. 545–564, 2012. ISSN 17577799. Disponível em:

<<https://onlinelibrary.wiley.com/doi/pdf/10.1002/wcc.192>>. 22

TOMPKINS, A. M.; CARDINALI, C.; MORCRETTE, J.-J.; RODWELL, M. Influence of aerosol climatology on forecasts of the african easterly jet.

**Geophysical Research Letters**, v. 32, n. 10, 2005. 2

TREUT, L.; SOMERVILLE, R.; CUBASCH, U.; DING, Y.; MAURITZEN, C.; MOKSSIT, A.; PETERSON, T.; PRATHER, M.; QIN, D.; MANNING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; KINGDOM, U.

**Historical overview of climate change science**. [s.n.], 2007. 93–127 p.

Disponível em: <<https://archive.ipcc.ch/pdf/assessment-report/ar4/wg1/ar4-wg1-chapter1.pdf>>. 23

TSIKERDEKIS, A.; ZANIS, P.; STEINER, A. L.; SOLMON, F.; AMIRIDIS, V.; MARINO, E.; KATRAGKOU, E.; KARACOSTAS, T.; FORET, G. Impact of dust size parameterizations on aerosol burden and radiative forcing in RegCM4.

**Atmospheric Chemistry and Physics**, v. 17, n. 2, p. 769–791, 2017. 24

VALSARAJ, R. R.; KOMMALAPATI, K. T. **Atmospheric aerosols. characterization, chemistry, modeling, and climate**. Washington: [s.n.], 2009. 199 p. 19

WALKO, R. L.; COTTON, W. R.; FEINGOLD, G.; STEVENS, B. Efficient computation of vapor and heat diffusion between hydrometeors in a numerical model. **Atmospheric Research**, v. 53, p. 171–183, 2000. Disponível em:

<[www.elsevier.com/locate/atmos](http://www.elsevier.com/locate/atmos)>. 30

WERNLI, H.; HOFMANN, C.; ZIMMER, M. Spatial forecast verification methods intercomparison project: application of the SAL technique. **Weather and Forecasting**, v. 24, n. 6, p. 1472–1484, 2009. ISSN 0882-8156. Disponível em:

<<https://journals.ametsoc.org/doi/pdf/10.1175/2009WAF2222271.1>>. 9

WERNLI, H.; PAULAT, M.; HAGEN, M.; FREI, C. SAL—A novel quality measure for the verification of quantitative precipitation forecasts. **Monthly**

**Weather Review**, v. 136, n. 11, p. 4470–4487, 2008. ISSN 0027-0644. Disponível em: <<https://journals.ametsoc.org/doi/pdf/10.1175/2008MWR2415.1>>. 9

WILKS, D. Introduction. In: DMOWSKA, R.; HARTMANN, D.; ROSSBY, H. T. (Ed.). **International geophysics series**. 3. ed. San Diego, USA: Academic Press, 2011. v. 100, p. 1–665. ISBN 9780123850225. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/B9780123850225000014>>. 7, 13, 38

WINTON, M. A reformulated three-layer sea ice model. **Journal of Atmospheric and Oceanic Technology**, v. 17, n. 4, p. 525–531, apr 2000. Disponível em: <[http://journals.ametsoc.org/doi/abs/10.1175/1520-0426\(2000\)17<29017\(3C0525\)3AARTLSI>3E2.0.CO;2](http://journals.ametsoc.org/doi/abs/10.1175/1520-0426(2000)17<29017(3C0525)3AARTLSI>3E2.0.CO;2)>. 33

WORLD METEOROLOGICAL ORGANIZATION - WMO. Guidelines on analysis of extremes in a changing climate in support of informed decisions for adaptation. **Data Climate**, 2009. 27

YASUNARI, T. J.; BONASONI, P.; LAJ, P.; FUJITA, K.; VUILLERMOZ, E.; MARINONI, A.; CRISTOFANELLI, P.; DUCHI, R.; TARTARI, G.; LAU, K. M. Estimated impact of black carbon deposition during pre-monsoon season from Nepal Climate Observatory - pyramid data and snow albedo changes over Himalayan glaciers. **Atmospheric Chemistry and Physics**, v. 10, n. 14, p. 6603–6615, 2010. ISSN 16807316. Disponível em: <[www.atmos-chem-phys.net/10/6603/2010/](http://www.atmos-chem-phys.net/10/6603/2010/)>. 21

YU, H.; KAUFMAN, Y. J.; CHIN, M.; FEINGOLD, G.; REMER, L. A.; ANDERSON, T. L.; BALKANSKI, Y.; BELLOUIN, N.; BOUCHER, O.; CHRISTOPHER, S.; DECOLA, P.; KAHN, R.; KOCH, D.; LOEB, N.; REDDY, M. S.; SCHULZ, M.; TAKEMURA, T.; ZHOU, M. A review of measurement-based assessments of the aerosol direct radiative effect and forcing. **Atmospheric Chemistry and Physics**, v. 6, n. 3, p. 613–666, 2006. ISSN 16807324. 19

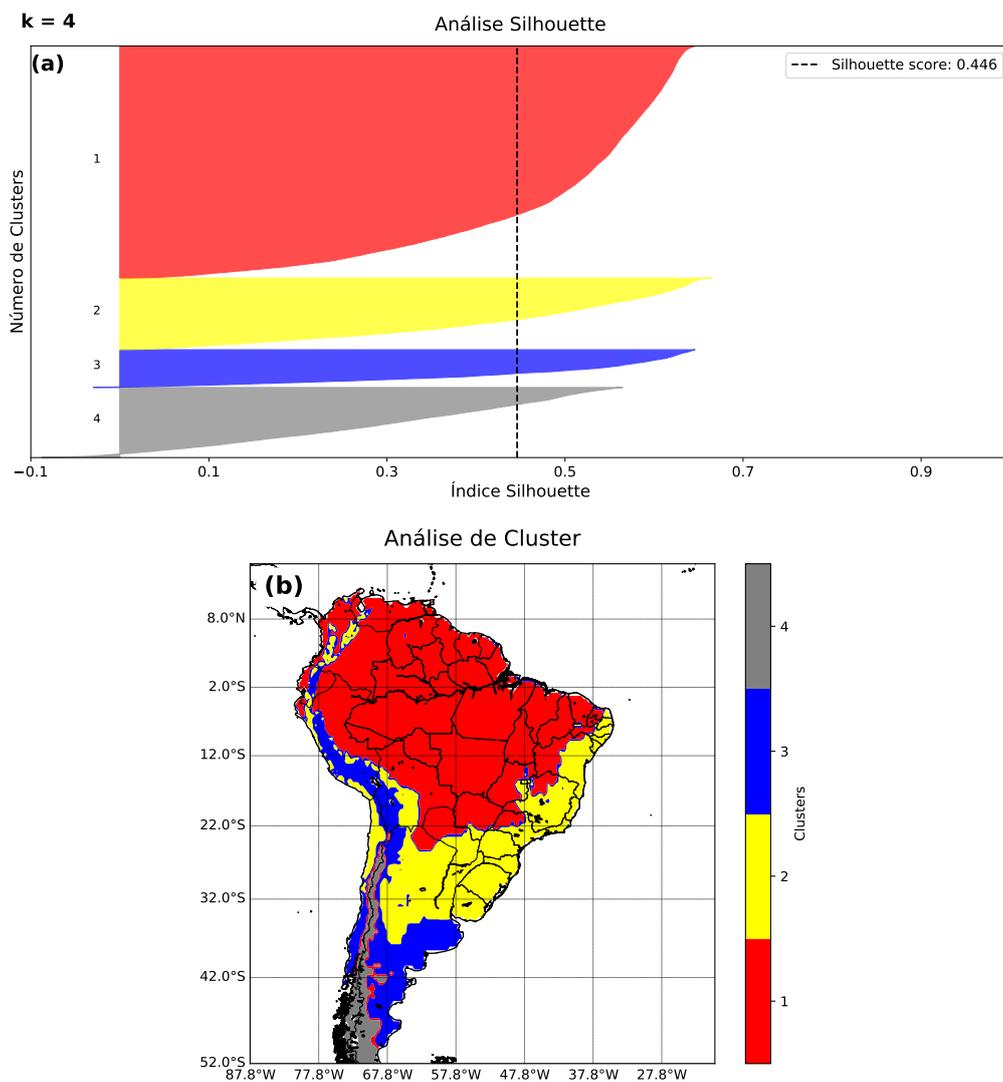
ZADRA, A.; WILLIAMS, K.; FRASSONI, A.; RIXEN, M.; ADAMES, F.; BERNER, J.; BOUYSSSEL, F.; CASATI, B.; CHRISTENSEN, H.; EK, M. B.; FLATO, G.; HUANG, Y.; JUDT, F.; LIN, H.; MALONEY, E.; MERRYFIELD, W.; NIEKERK, A. V.; RACKOW, T.; SAITO, K.; WEDI, N.; YADAV, P. Systematic errors in weather and climate models: nature, origins, and ways forward. **Bulletin of the American Meteorological Society**, v. 99, n. 4, p. ES67–ES70, 2018. Disponível em: <<https://doi.org/10.1175/BAMS-D-17-0287.1>>. 4

ZHANG, J.; REID, J. S.; CHRISTENSEN, M.; BENEDETTI, A. An evaluation of the impact of aerosol particles on weather forecasts from a biomass burning aerosol event over the Midwestern United States: observational-based analysis of surface temperature. **Atmospheric Chemistry and Physics**, v. 16, n. 10, p. 6475–6494, 2016. ISSN 16807324. [4](#), [16](#), [24](#)



## APÊNDICE A - ANÁLISE DE *CLUSTER* DA TEMPERATURA MÁXIMA DO AR NA AMÉRICA DO SUL

Figura A.1 - Análise do índice *Silhouette* e *clusters* espacializados na AS da  $T_{max}$  da reanálise do ERA5 para quatro grupos definidos ( $k=4$ ).

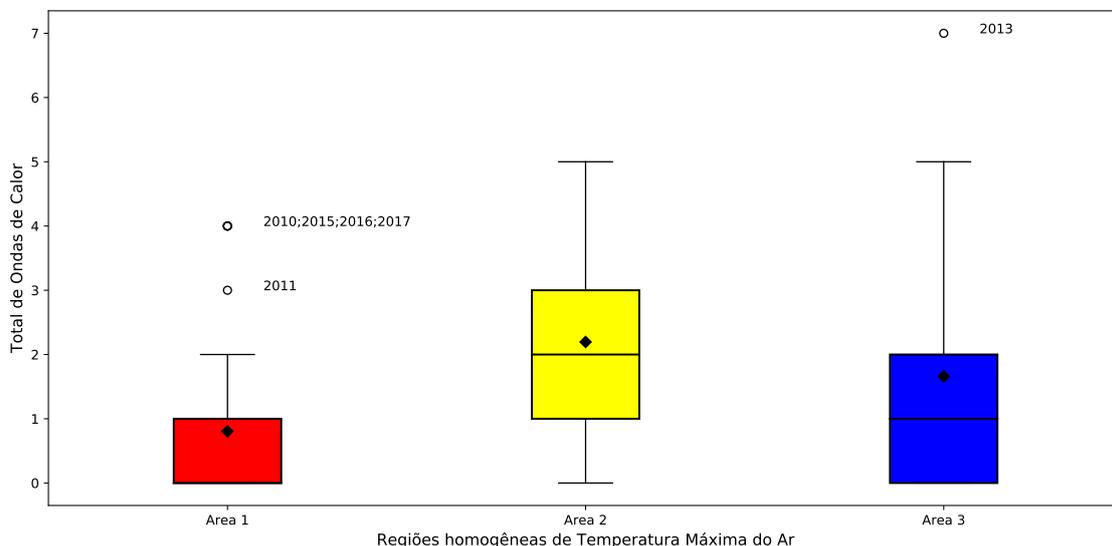


Fonte: Produção da autora.

## APÊNDICE B - CLIMATOLOGIA DAS ONDAS DE CALOR NA AMÉRICA DO SUL

Nesta Seção é apresentada a climatologia dos episódios de ondas de calor em cada região homogênea de  $T_{max}$ , desde a análise descritiva do total de ondas de calor, frequência mensal e frequência do número de pontos de grade, classificação dos eventos em intensos, médios e fracos, e análise de tendência da intensidade e persistência.

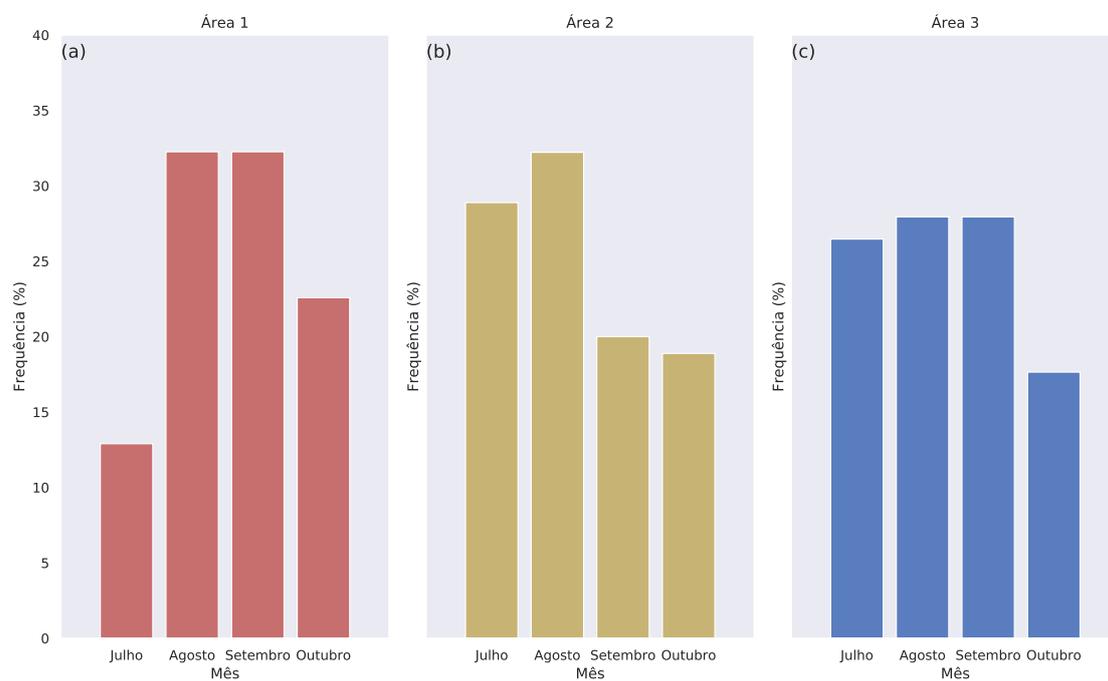
Figura B.1 - Box-Plot do total de ondas de calor por ano nas três regiões homogêneas de  $T_{max}$  – Reanálise ERA5 (JASO: 1979-2019).



As cores dos box-plots correspondem a cada região homogênea definida na análise de *cluster*. Os círculos sem preenchimento são os *outlines* da série, a média dos dados de ondas de calor em cada área são representadas pelos losangos preenchidos. Os anos especificados em cada *outline* correspondem aos extremos de ondas de calor.

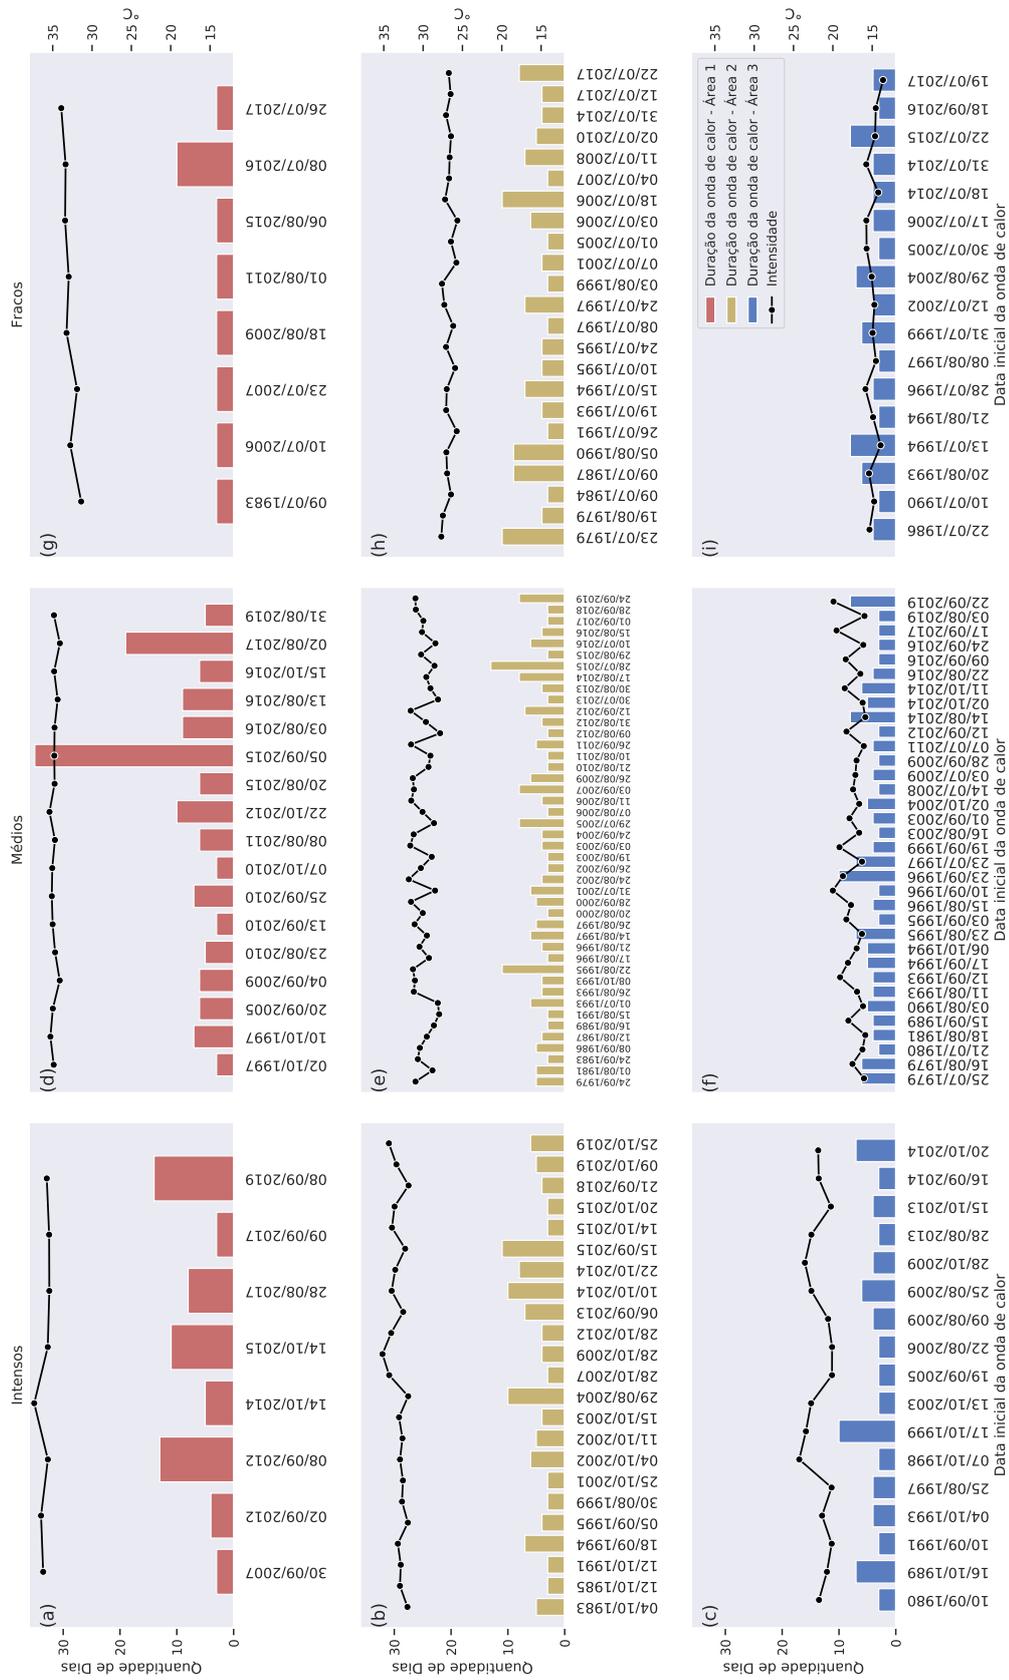
Fonte: Produção da autora.

Figura B.2 - Frequência mensal de ondas de calor em percentagem nas três regiões homogêneas de  $T_{max}$  – Reanálise ERA5 (JASO: 1979-2019).



Fonte: Produção da autora.

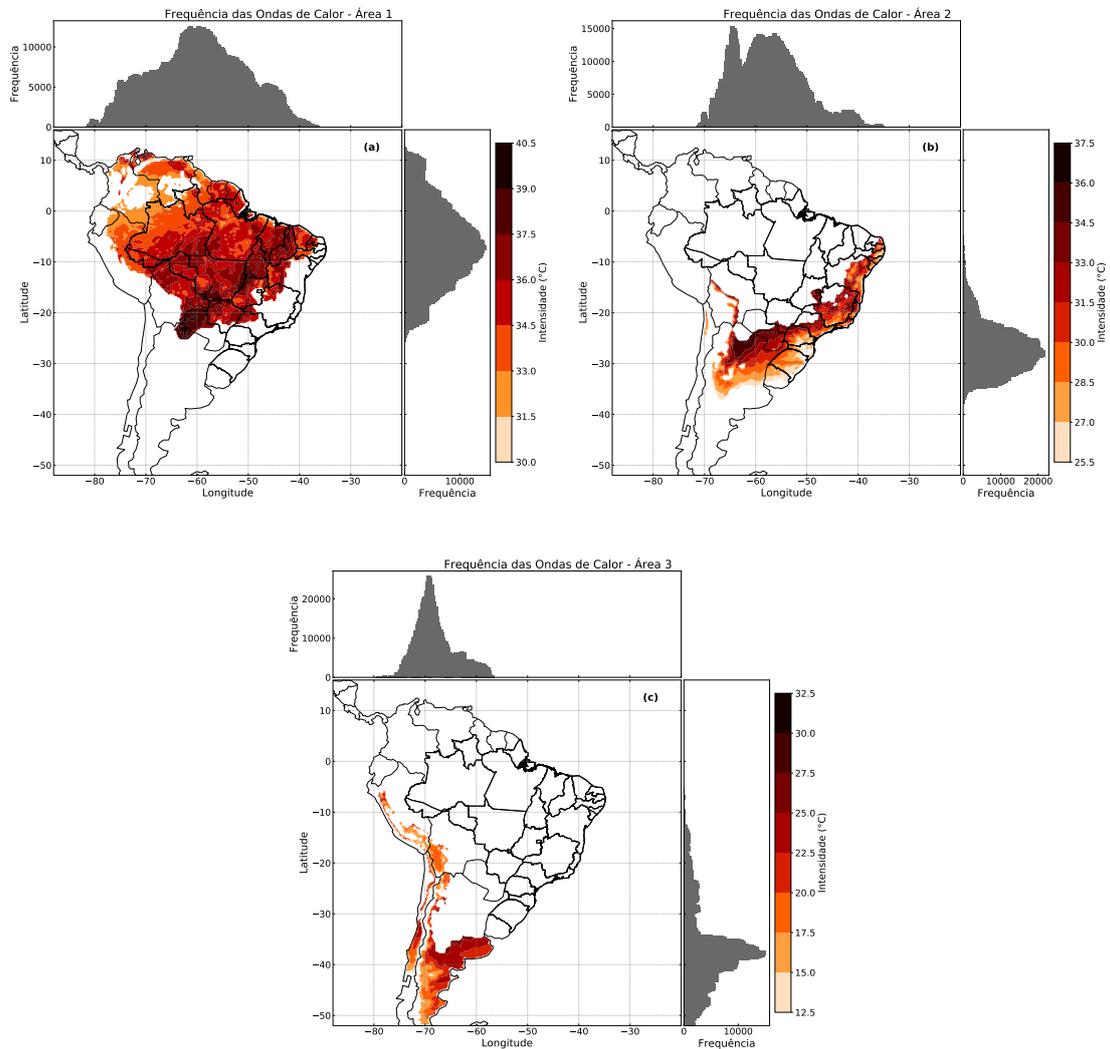
Figura B.3 - Classificação das ondas de calor em eventos intensos, médios e fracos nas regiões homogêneas de  $T_{max}$  no período JASO de 1979-2019.



No eixo x temos a data de início de cada episódio, e as barras correspondem a quantidade de dias em que a onda de calor persistiu na Área 1 [(a),(d),(g)], Área 2 [(b),(e),(h)] e Área 3 [(c),(f),(i)]. A linha contínua representa o Parâmetro de Intensidade em °C de cada evento.

Fonte: Produção da autora.

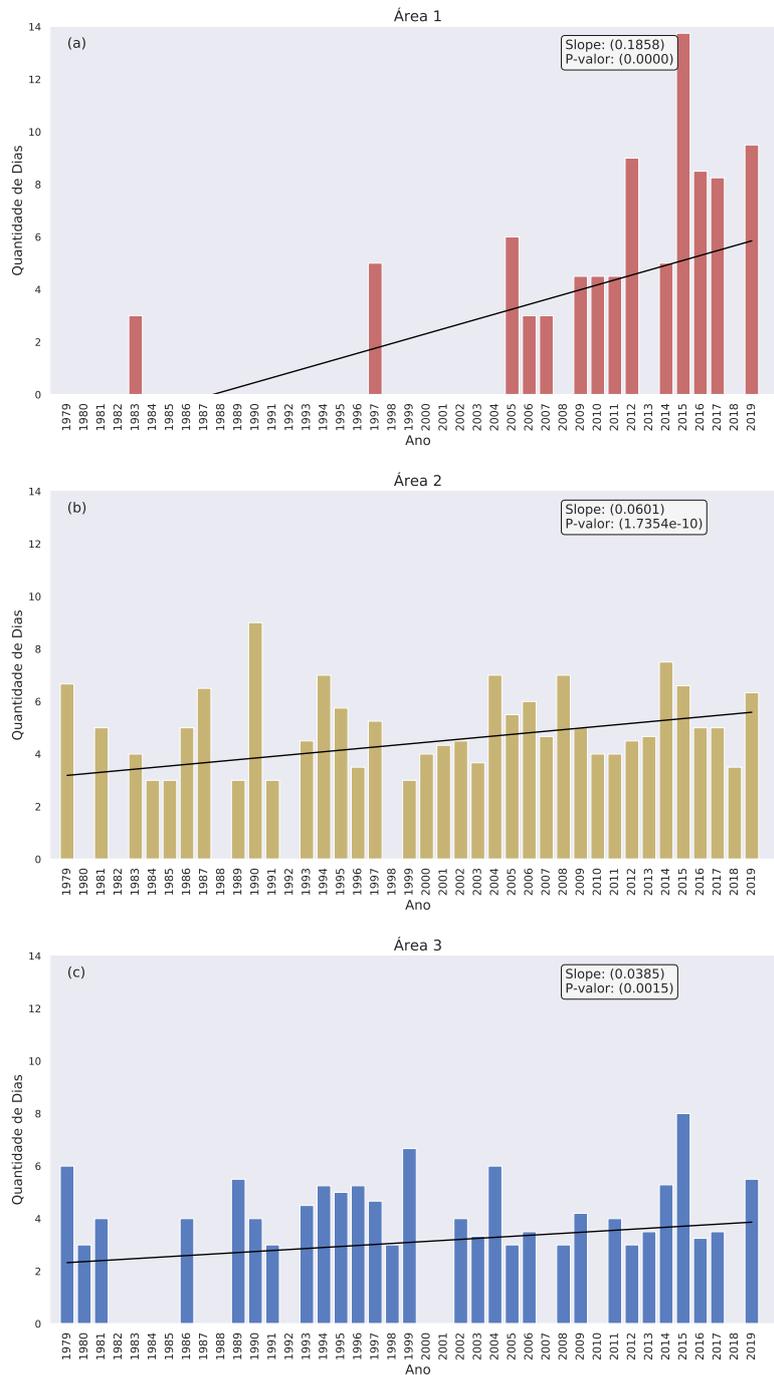
Figura B.4 - Frequência do número de pontos de grade e intensidade média das ondas de calor na AS nas três regiões homogêneas de  $T_{max}$  no período JASO de 1979-2019.



Os histogramas em cinza representam a frequência do número de pontos de grade em longitude (eixo x) e latitude (eixo y) em que ocorreu os episódios de ondas de calor desde de julho, agosto, setembro e outubro de 1979 a 2019 na Área 1 (a), Área 2 (b) e Área 3 (c). A intensidade média de cada ponto de grade frequente está apresentado no mapa em *shaded* das áreas.

Fonte: Produção da autora.

Figura B.5 - Distribuição e tendência anual da duração média em dias das ondas de calor nas três regiões homogêneas de  $T_{max}$  no período JASO de 1979-2019.



As barras correspondem à quantidade de dias médios dos episódios de ondas de calor no período de 1979 a 2019 na Área 1 (a), Área 2 (b) e Área 3 (c). A linha contínua representa a regressão linear da série anual. O *Slope* ou inclinação da reta mostra em média o quanto a cada ano, as ondas de calor vêm aumentando. O P-valor da análise de tendência, menor que 5% mostra que tem significância estatística, ou seja, a hipótese nula ( $H_0$ ) de que a série não possui tendência é rejeitada.

Fonte: Produção da autora.

Figura B.6 - Distribuição e tendência anual da intensidade média em °C das ondas de calor nas três regiões homogêneas de  $T_{max}$  no período JASO de 1979-2019.



As barras correspondem à intensidade média dos episódios de ondas de calor no período de 1979 a 2019 na Área 1 (a), Área 2 (b) e Área 3 (c). A linha contínua representa a regressão linear da série anual. O *Slope* ou inclinação da reta mostra em média o quanto a cada ano, as ondas de calor vêm aumentando. O P-valor da análise de tendência, abaixo de 5% mostra que tem significância estatística, ou seja, a hipótese nula ( $H_0$ ) de que a série não possui tendência é rejeitada.

Fonte: Produção da autora.

## APÊNDICE C - IMPACTOS DA QUÍMICA NAS VARIÁVEIS ATMOSFÉRICAS DO MODELO BRAMS

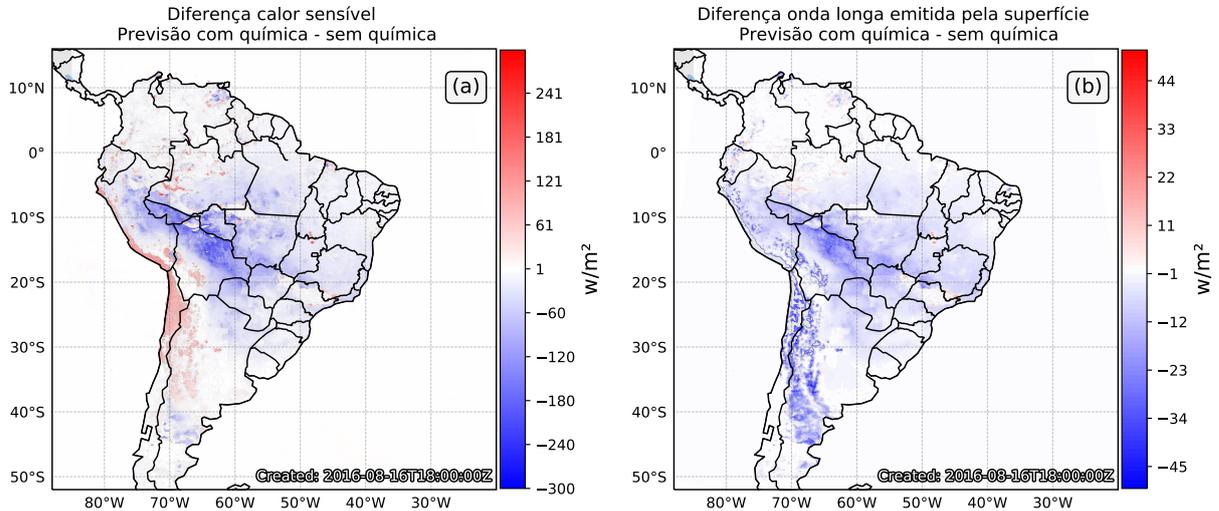
Nesta Seção faz-se uma análise dos efeitos da inclusão da componente química atmosférica do modelo em outras variáveis meteorológicas. São apresentadas as análises do vento zonal e meridional nos níveis de 850, 500 e 250 hPa, calor sensível, radiação de onda longa emitida pela superfície e umidade específica.

Como visto na Tabela 4.6, a onda de calor no dia 16 de agosto de 2016 foi prevista pelas duas versões do modelo em todos os horários de integração da previsão correspondente às 18 UTC. Além disso, este foi o dia que o episódio apresentou maior intensidade, o que também estimulou a análise do dia 16 de agosto às 18 horas. Portanto, considera-se este caso ideal para a interoperação das variáveis meteorológicas citadas nas duas versões do modelo.

A diferença dos campos de calor sensível e onda longa emitida pela superfície entre as previsões sem e com a integração da química atmosférica são apresentadas na Figura C.1(a e b), respectivamente. Observa-se uma diminuição dos fluxos radiativos nas regiões que compreendem os estados do Acre, Rondônia, e Mato Grosso no Brasil, como também em outros países, como a Bolívia e norte do Paraguai, onde há uma concentração maior de aerossóis de queimada na atmosfera (AOT em  $550\text{nm} > 1$ ). Essa diferença chega até  $-300\text{ W/m}^2$  no campo de calor sensível, e aproximadamente  $-46\text{ W/m}^2$  de onda longa. Esta alteração nos fluxos radiativos pode ocorrer devido à atenuação (absorção/retroespalhamento) da radiação de onda curta incidente pelos aerossóis na atmosfera, causando a diminuição da temperatura próximo da superfície. Este resultado é corroborado por aqueles apresentados por [Rosário et al. \(2013\)](#), que identificaram, a partir de resultados do modelo BRAMS, uma redução da radiação de onda curta de até  $-163\text{ W/m}^2$  em regiões com altas concentrações de aerossóis de queimadas. Assim como o estudo de [Artaxo et al. \(2006\)](#), que identificou que AOT elevada diminuiu os fluxos radiativos de onda curta, calor sensível, e calor latente do mesmo modelo.

Nota-se também na Figura C.1a, correspondente à previsão integrada, uma região de aumento do fluxo de calor sensível sobre a região dos Andes, sendo mais destacável no deserto do Atacama com aproximadamente  $+300\text{ W/m}^2$ . Esta resposta é inversa àquela identificada sobre a região amazônica, e pode ser explicada pela relação entre a superfície e a cobertura de nuvens ou ocorrência de precipitação de neve na região. Isto porque a diminuição da radiação de onda longa emitida verificada no modelo pode estar relacionada ao aumento do albedo ([LIOU, 2002](#)).

Figura C.1 - Efeito da componente química nos fluxos radiativos de calor sensível e onda longa emitida pela superfície em  $Wm^{-2}$  para o dia 16 de agosto de 2016.



Diferença entre as previsões com e sem a química atmosférica das variáveis calor sensível (a) e onda longa emitida pela superfície (b) para o dia 16 de agosto de 2016 no prazo de 18 horas de integração.

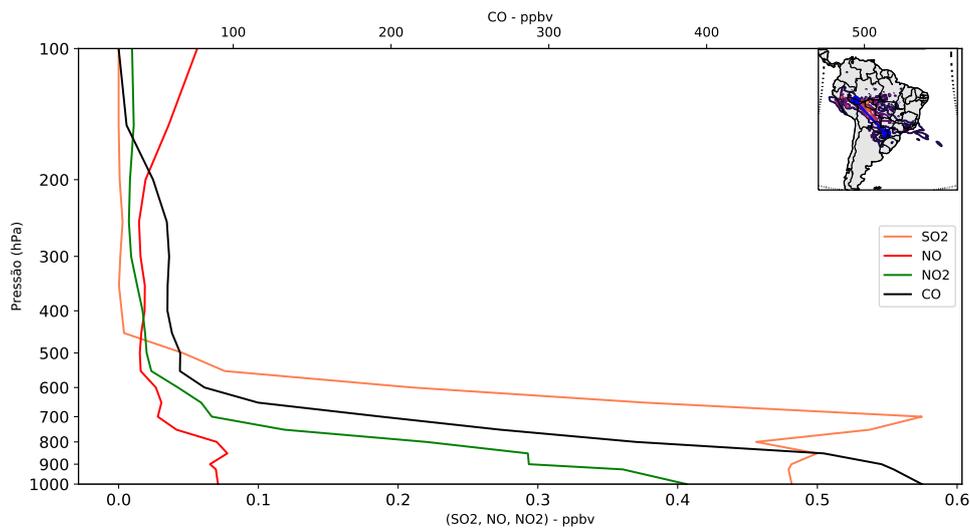
Fonte: Produção da autora.

Foi selecionado um corte transversal nas latitudes e longitudes ( $9^{\circ}S-70^{\circ}W$ ;  $25^{\circ}S-55^{\circ}W$ ), onde a AOT é elevada (em  $550\text{ nm} > 1$ ), com o objetivo de analisar o comportamento médio dos principais constituintes químicos previstos pelo modelo na camada atmosférica que vai desde a superfície até 100 hPa para o dia 16 de agosto de 2016 na previsão de 18 horas (ilustrado na Figura C.2).

A maior concentração é do monóxido de carbono, chegando a ser um pouco maior que 500 ppbv, seguido do  $SO_2$ ,  $NO_2$ , e  $NO$ . Esses constituintes químicos são encontrados com maior frequência no período seco da Amazônia, e são associados principalmente com a queima de biomassa (ARTAXO et al., 2006). A maior concentração é encontrada na camada atmosférica próxima à superfície. O perfil vertical dos constituintes químicos na área analisada é característico de um transporte vertical realizado pelos processos convectivos, que têm início na camada limite atmosférica devido à turbulência térmica ou mecânica. A maior concentração próximo à superfície pode ser explicada pelo fato de que área analisada está próxima às fontes de

emissão de queimadas. Entre os níveis de 550 e 500 hPa é notado uma diminuição brusca, podendo estar associada a movimentos subsidentes. Por exemplo, na Figura C.3e pode ser observado no nível de 500 hPa um escoamento anticiclônico centrado sobre a Bolívia, onde se encontra maiores valores da AOT.

Figura C.2 - Perfil vertical médio dos aerossóis na previsão integrada com química do modelo BRAMS para o dia 16 de agosto de 2016.



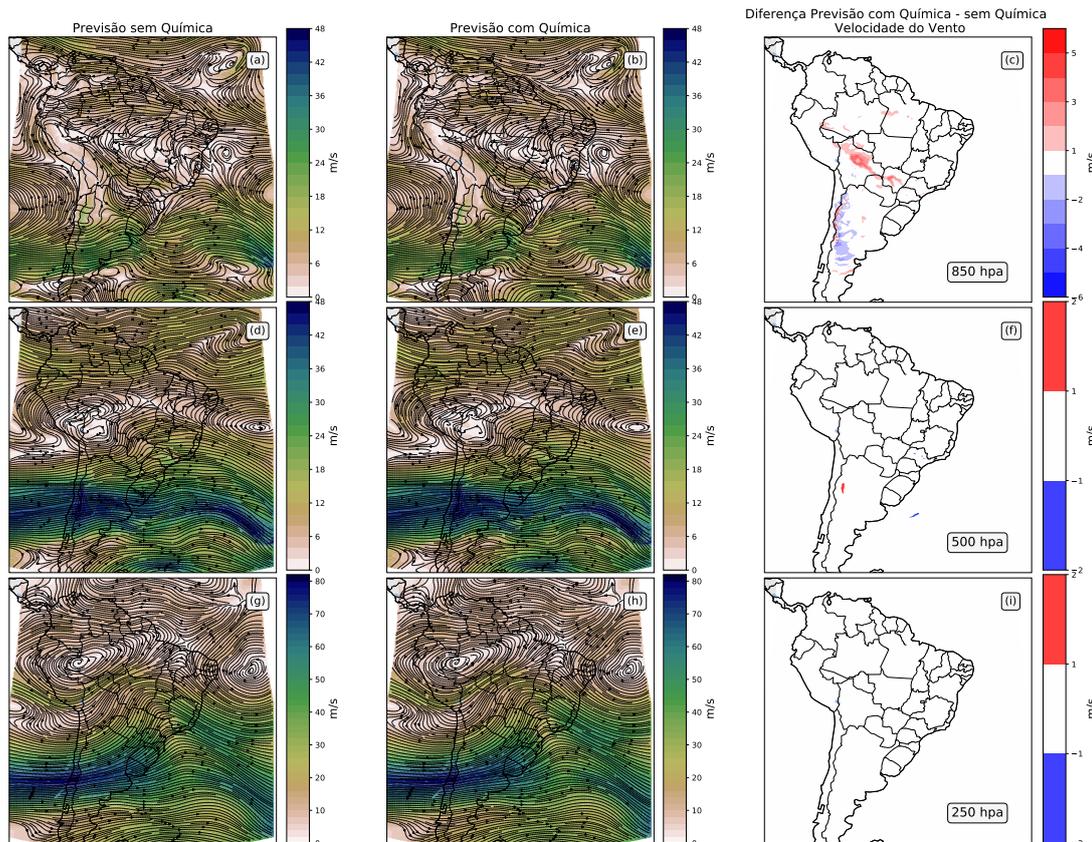
As linhas contínuas representam a média do corte transversal (linha azul destacada no mapa) com maior AOT, em laranja tem-se o dióxido de enxofre ( $\text{SO}_2$ ), óxido de nitrogênio (NO) em vermelho, dióxido de nitrogênio ( $\text{NO}_2$ ) em verde, e monóxido de carbono (CO) em preto estimados em parte por bilhões por volume (ppbv). A escala do CO está representada no topo da figura.

Fonte: Produção da autora.

O maior impacto da química atmosférica na magnitude do vento foi encontrado no nível de 850 hPa, onde a diferença chega a aproximadamente +5 m/s na região de maior concentração de aerossóis (Figura C.3c). Além disso, nas previsões sem e com a inclusão da química (Figuras C.3a e b, respectivamente) é notado um escoamento com sentido noroeste-sudeste nesta região em 850 hPa, com uma velocidade do vento entre 18 e 24 m/s, com características típicas de um Jato de Baixos Níveis. O padrão de circulação neste nível observado nas previsões são praticamente os mesmos, havendo uma pequena alteração na direção do vento sobre a região da Bolívia, onde o escoamento de noroeste é defletido para o sudoeste do país na previsão sem química.

Já na previsão integrada, esse fluxo é desviado para sudeste. Em relação aos níveis de 500 e 250 hPa, não há alterações no padrão de circulação e velocidade do vento entre as previsões (ilustrado nas Figuras d-i), pois como vimos anteriormente na Figura C.2, a maior concentração de aerossóis se encontra abaixo de 500 hPa.

Figura C.3 - Linhas de corrente e velocidade do vento das previsões do modelo BRAMS, e diferenças entre a previsão com e sem a modelagem química nos níveis de 850 hPa, 500 hPa e 250 hPa para o dia 16 de agosto de 2016.



As linhas de corrente e velocidade do vento estão representadas em (a) e (b) para 850 hPa; (d) e (e) em 500 hPa; (g) e (h) em 250 hPa. As figuras em (c), (f) e (i) mostram a diferença da velocidade do vento entre a previsão sem e com a química atmosférica nos níveis de 850, 500 e 250 hPa, respectivamente.

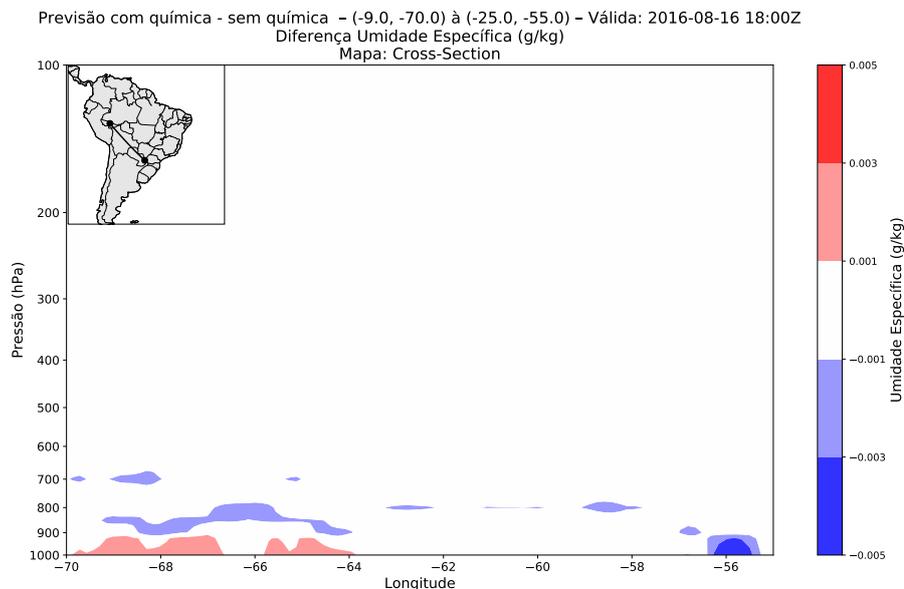
Fonte: Produção da autora.

Kolusu et al. (2015) encontrou uma diminuição na velocidade do vento a 10 metros sobre a mesma região nos dois dias de simulações com a inclusão de aerossóis de queimada realizadas com o modelo MetUM, associando esta redução com a diminuição do fluxo de calor sensível. Apesar desta diminuição do calor sensível ter

sido verificada aqui, o vento em 850 hPa se intensifica na previsão integrada. Esta intensificação pode estar associada a um aumento do gradiente de pressão à superfície na região de maior influência dos aerossóis de queimada (figura não mostrada), podendo ser explicado pelo maior contraste de temperatura causado pelo resfriamento da temperatura à superfície, já que na previsão sem a inclusão da química, a temperatura se encontrava mais uniforme sobre a região.

No caso da umidade específica se observa na Figura C.4 um dipolo nos níveis e região de maior concentração de aerossóis entre as longitudes de 70 °W e 64 °W, sobre a Bolívia. Próximo à superfície, entre os níveis de 1000 e 900 hPa, observa-se um aumento da umidade de até 0,005 g/kg. Já nos níveis acima de 900 até 700 hPa, onde é observado uma diminuição dos aerossóis nesta camada, a umidade específica diminui na previsão integrada. Uma análise similar foi realizada com a reanálise do MERRA-2 por Penna (2018), associando o aumento (redução) da umidade específica com a compressão (expansão) do volume de ar, que consequentemente possui a capacidade de aumentar (diminuir) a retenção de vapor devido ao resfriamento (aquecimento) das regiões resultante dos efeitos causados pelos aerossóis.

Figura C.4 - Perfil vertical da umidade específica das diferenças entre as previsões com e sem a química atmosférica sobre o corte transversal demarcado (linha preta) no mapa para o dia 16 de agosto de 2016.



Fonte: Produção da autora.