



UNIVERSIDADE EDUARDO MONDLANE
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE FÍSICA

MESTRADO EM GESTÃO DE RISCO DE DESASTRES E ADAPTAÇÃO ÀS MUDANÇAS
CLIMÁTICAS

3ª Edição: 2022-2023

**Aplicabilidade da Plataforma myDewetra para a Previsão da
Precipitação Induzida por Ciclones Tropicais em
Moçambique: Caso do Ciclone Freddy (2023)**

Autor:

Rafael Chicoco Benedito Mabunda

Supervisor:

Prof. Doutor Alberto Mavume

Maputo, Novembro de 2024



UNIVERSIDADE EDUARDO MONDLANE
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE FÍSICA

MESTRADO EM GESTÃO DE RISCO DE DESASTRES E ADAPTAÇÃO ÀS MUDANÇAS
CLIMÁTICAS

3ª Edição: 2022-2023

**Aplicabilidade da Plataforma myDewetra para a Previsão da
Precipitação Induzida por Ciclones Tropicais em
Moçambique: Caso do Ciclone Freddy (2023)**

Autor:

Rafael Chicoco Benedito Mabunda

Supervisor:

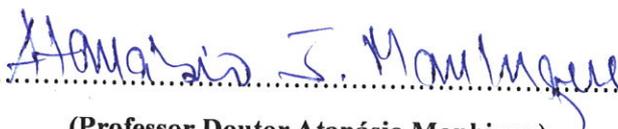
Prof. Doutor Alberto Mavume

Maputo, Novembro de 2024

DECLARAÇÃO DO JÚRI

Este trabalho foi aprovado com a classificação de 16 (dezasseis) valores, no dia 30 de Outubro de 2024 por nós, membros do júri examinador nomeados pela Faculdade de Ciências da Universidade Eduardo Mondlane.

Presidente do Júri



(Professor Doutor Atanásio Manhique)

Arguente



(Professor Doutor Alberto J. Bié)

Supervisor



(Professor Doutor Alberto Mavume)

DECLARAÇÃO DE HONRA

Eu, Rafael Chicoco Benedito Mabunda, declaro por minha honra que esta dissertação é da minha autoria e nunca foi submetida nesta ou em outra instituição para aquisição de qualquer outro grau académico, e que constitui resultado de um esforço individual e de orientação do meu supervisor. O seu conteúdo é original e todas as fontes consultadas estão devidamente citadas e referenciadas na bibliografia. Esta dissertação é apresentada em cumprimento parcial dos requisitos para a obtenção do grau de mestre em *Gestão de Risco de Desastres e Adaptação às Mudanças Climáticas*, no Departamento de Física da Faculdade de Ciências, Universidade Eduardo Mondlane.

Maputo, Novembro de 2024

Rafael Chicoco Benedito Mabunda

(Rafael Chicoco Benedito Mabunda)

Agradecimentos

Em primeiro lugar agradeço aos meus pais Benedito Rafael Mabunda e Joana Elias Cavele pelo dom da vida e pelo apoio em todo meu percurso académico. Aos meus irmãos Delfina Benedito Mabunda, Elias Benedito Mabunda e Milagre Maluleque.

Agradeço a We World-GVC por oferecer a bolsa de estudos e no apoio para o desenvolvimento do tema de estudo. Agradeço também à Fundação CIMA, especialmente o Alessandro Masoero e Laura Poletti pela partilha dos dados de previsão da precipitação e trajectória do ciclone Freddy.

Ao meu supervisor Professor Alberto Mavume pelo acompanhamento e paciência durante todo o processo de elaboração da dissertação. Agradeço também por ter me ajudado a aceder a bolsa de estudos.

Aos meus amigos e colegas, especialmente o David Cutane, Hélio Clemente, Nehemias Lasse, Helder Domingos, Edna Algy, Adalgisa Tinga, Angelina Marissol e a todos que directa ou indirectamente contribuíram para o meu sucesso durante todo o percurso académico.

Índice

Lista de Figuras	v
Resumo	ix
Abstract.....	x
Lista de Abreviaturas	x
Capítulo 1 – Introdução e Objectivos.....	1
1.1. Introdução	1
1.2. Motivação	3
1.3. Objectivos	3
1.3.1. Objectivo Geral.....	3
1.3.2. Objectivos específicos	3
1.4. Problema de pesquisa.....	4
1.5. Justificativa do estudo.....	4
1.6. Hipóteses.....	5
Capítulo 2 - Revisão de literatura	6
2.1. Ciclones tropicais.....	6
2.2. Trajetória do ciclone tropical	9
2.3. Intensidade dos Ciclones Tropicais.....	12
2.4. Precipitação de ciclones tropicais	15
2.4.1. Os mecanismos físicos por trás das chuvas em ciclones tropicais.....	16
2.4.1.1. <i>Fornecimento de humidade</i>	16
2.4.1.2. <i>Transição extratropical</i>	18
2.4.1.3. <i>Topografia</i>	20
2.4.1.4. <i>Sistemas convectivos de mesoescala</i>	22
2.4.1.5. <i>Camada limite</i>	26
2.5. Medição da precipitação	27
2.5.1. Métodos de Medição	28
2.5.1.1. Pluviómetros.....	29
2.5.1.2. Disdrómetros	33
2.5.2. Estimativa da precipitação	34
2.5.2.1. Estimativa por radares.....	34

2.5.2.2. Estimativas por satélite.....	36
2.6. Previsão da precipitação de ciclones tropicais que atingem a região continental.....	38
2.6.1. Previsão de consenso.....	39
2.6.2. Papel da assimilação de dados na previsão da precipitação de ciclones tropicais	49
2.6.3. Previsão da precipitação de ciclones tropicais com base em inteligência artificial	51
2.7. Impactos da precipitação de ciclones tropicais.....	52
2.7.1. Impactos negativos.....	52
2.7.2. Impactos positivos.....	55
2.8. Ciclones tropicais mais recentes que fizeram o <i>landfall</i> o Moçambique.....	56
Capítulo 3 – Descrição da plataforma myDewetra.....	60
3.1. Características da plataforma myDewetra	60
3.2. Modelos de previsão da plataforma myDewetra	61
3.2.1. Modelo GFS	63
3.2.2. ECMWF-ENS	65
Capítulo 4 – Materiais e Métodos	67
4.1. Descrição do ciclo de vida do ciclone Freddy	67
4.2. Área de estudo	70
4.3. Clima de Moçambique.....	71
4.4. Sistemas que influenciam a precipitação em Moçambique	72
4.5. Dados	74
4.5.1. Dados “observados” da Trajectória e Intensidade.....	74
4.5.2. Dados da precipitação observada	75
4.5.3. Dados de previsões do modelo GFS	76
4.6. Metodologia.....	76
4.6.1. Avaliação da previsão da trajectória do ciclone tropical	76
4.6.2. Avaliação da previsão da intensidade.....	77
4.6.3. Avaliação da previsão da precipitação.....	77
4.7. Limitações do estudo	78
Capítulo 5 - Resultados e Discussão	79
5.1. Avaliação da previsão da trajectória	79
5.1.1. Primeiro <i>landfall</i>	79

5.1.1.1. Erro de previsão da trajetória para o primeiro <i>landfall</i>	82
5.1.2. Segundo <i>landfall</i>	84
5.1.2.1. Erros de previsão de trajetória do segundo <i>landfall</i>	87
5.2. Avaliação das previsões de intensidade	89
5.2.1. Primeiro <i>landfall</i>	90
5.2.2. Segundo <i>landfall</i>	92
5.3. Avaliação da previsão da precipitação	96
5.3.1. Primeiro <i>landfall</i>	96
5.3.2. Segundo <i>landfall</i>	105
Capítulo 6 – Conclusões	111
6.1. Conclusões	111
6.3. Recomendações	113
6.4. Próximos passos	113
Referências Bibliográficas	114
Apêndices	140

Lista de Figuras

Figura 2.1: Direção rotacional do ciclone tropical	6
Figura 2.2: Designação dos ciclones tropicais em diferentes regiões do globo.	7
Figura 2.3: Regiões de maior gênese de ciclones tropicais no sudoeste do oceano Índico	8
Figura 2.4: Circulação de um sistema de alta pressão no Hemisfério Sul.....	10
Figura 2.5: Mapa de localizações de ciclones tropicais (sombreado), com uma noção geral das trajetórias dos ciclones (setas).	11
Figura 2.6: Trajetória do Ciclone Freddy.....	12
Figura 2.7: Diagrama esquemático mostrando o ciclo de vida de um ciclone tropical.....	14
Figura 2.8: Distribuição horizontal do vento do tufão Khanun sobre a ilha de Jeju..	22
Figura 2.9: Contribuição dos sistemas convectivos de mesoescala para a precipitação total global.. ..	24
Figura 2.10: (a) Densidade de gênese do sistema convectivo de mesoescala (SCM) (sombreado em número de eventos dentro de 5 raios) e trilhas de ciclones tropicais (linhas vermelhas marcadas com o nome da tempestade) e (b) locais de gênese do SCM (círculos preenchidos em preto para	

trópicos e vermelhos para regiões subtropicais) de 1º de setembro de 2018 a 30 de novembro de 2018.....	25
Figura 2.11: Pluviómetro de proveta graduada.....	30
Figura 2.12: pluviómetro de registo de precipitação.....	31
Figura 2.13: Pluviómetro de pesagem.....	31
Figura 2.14: gráfico do pluviómetro de pesagem.....	32
Figura 2.15: Pluviómetro de sifão natural.....	32
Figura 2.16: Gráfico do pluviómetro de sifão natural.....	33
Figura 2.17: Disdrómetro.....	34
Figura 2.18: Radar meteorológico Doppler.....	36
Figura 2.19: Fluxograma de cálculo de TSAI.....	41
Figura 2.20: Diagrama esquemático para determinar índice de similaridade de trajetória do ciclone tropical que atinge o continente.....	42
Figura 2.21: Comparação do TSS em diferentes níveis de precipitação para o melhor esquema do modelo LTP_DSEF (Best) e os três modelos dinâmicos (ECMWF, GFS e T639).....	43
Figura 2.22: Fluxograma do modelo de previsão do conjunto de análogo dinâmico (DSAEF).....	44
Figura 2.23: Fluxograma do modelo DSAEF para prever a precipitação de ciclones tropicais....	45
Figura 2.24: Comparação de pontuação de ameaças (TS - Threat Scores) para prever precipitação intensa acumulada (≥ 250 e $\geq 100mm$) pelo modelo DSAEF_LTP.....	46
Figura 2.25: Comparação de pontuações de ameaças de diferentes modelos (ECMWF, GFS, T639, DSAEF_LTP-2 e DSAEF_LTP-3).....	47
Figura 2.26: Pontuações de ameaça (TS250, TS100 e TSsum) do melhor esquema do modelo DSAEF_LTP com similaridade de intensidade.....	48
Figura 2.27: Conexões espaciais entre trajetórias de ciclones tropicais de diferentes intensidades e mortes induzidas por inundações causadas por ciclones tropicais.....	54
Figura 3.1: Interface gráfica da plataforma myDewetra.....	61
Figura 3.2: Modelos disponíveis na plataforma myDewetra para previsão de tempo.....	62
Figura 3.3: Modelos do Cyclone Tracker.....	63
Figura 4.1: Estágios de rápida intensificação do ciclone Freddy. Fonte: (Bhatia, 2023).....	69
Figura 4.2: Localização geográfica de Moçambique. Fonte: Autor.....	71
Figura 4.3: Distribuição espacial da precipitação média anual em Moçambique. Fonte: Autor.....	73

Figura 4.4: Regiões de interesse para esta pesquisa. Fonte: (OCHA, 2023c).	74
Figura 5.1: Localização do centro do ciclone Freddy previsto pelo modelo GFS (representado pelo ponto vermelho) e a localização do centro do ciclone segundo os dados de melhor trajectória (indicado pelo ponto verde).....	80
Figura 5.2: Erros de previsão de trajectória do modelo GFS para lead times de 24h, 48h e 72h durante o movimento do ciclone para a região Sul de Moçambique.....	83
Figura 5.3: Erro médio de previsão de trajectória do modelo GFS durante o seu deslocamento para a primeira entrada em Moçambique.	84
Figura 5.4: Localização do centro do ciclone Freddy previsto pelo modelo GFS (representado pelo ponto vermelho) e a localização do centro do ciclone.....	86
Figura 5.5: Erros de previsão de trajectória do modelo GFS para 24h, 48h e 72h de lead time durante o movimento do ciclone para a região Norte de Moçambique.	88
Figura 5.6: Erro médio da previsão da trajectória do modelo GFS durante o deslocamento para a segunda entrada no Norte de Moçambique.	89
Figura 5.7: Pressão prevista pelo modelo GFS, pressão dos dados de melhor trajectória e o erro de previsão.....	91
Figura 5.8: Erro médio da previsão de intensidade do ciclone Freddy para o primeiro landfall. .	92
Figura 5.9: Pressão prevista, pressão dos dados de Melhor trajectória e o erro de previsão da pressão.	94
Figura 5.10: Erro médio da previsão da intensidade do ciclone Freddy para todos os lead times durante o deslocamento para o segundo landfall.....	95
Figura 5.11: Precipitação acumulada prevista pelo modelo GFS.....	97
Figura 5.12: Precipitação acumulada em 24h observada nas estações de superfície e precipitação prevista pelo modelo GFS.	99
Figura 5.13: Precipitação acumulada em 24h observada nas estações de superfície e a precipitação prevista pelo modelo GFS.	101
Figura 5.14: Raiz do erro médio quadrático médio das previsões de precipitação acumulada em 24h.	102
Figura 5.15: Precipitação máxima acumulada em 24h observada e precipitação prevista pelo modelo GFS. As previsões são de lead times de 24h (a) e 48h (b).	104

Figura 5. 16: Precipitação acumulada em 24h prevista pelo modelo GFS durante o segundo landfall do ciclone Freddy.....	107
Figura 5.17: Precipitação observada (barras azuis) na estação de Quelimane durante o segundo landfall do ciclone Freddy e as previsões do modelo GFS (barras cor de laranja) para lead time de 24h (à esquerda) e 48h (à direita).	108

Lista de Tabelas

Tabela 2.1:Classificação dos sistemas tropicais que são usados no Sudoeste do Oceano Índico.	13
Tabela 2.2: Ciclones tropicais que fizeram landfall em Moçambique entre 2017 a 2022.....	56
Tabela 3.1: Modelos de previsão de perigos da plataforma myDewetra.....	61
Tabela 5.1: Ponto central da precipitação máxima observada e prevista pelo modelo GFS para 24h de lead time.....	104
Tabela 5.2: Ponto central da precipitação máxima observada e prevista pelo modelo GFS para lead time de 48h.	105

Resumo

Nos últimos anos, Moçambique tem sido afectado pelos ciclones tropicais, que causam destruição de bens e perda de vidas. Os impactos dos ciclones tropicais podem ser minimizados através da melhoria das previsões meteorológicas. Previsões de qualidade podem permitir acções antecipadas, garantindo que as populações ameaçadas possam se preparar para os possíveis impactos dos ciclones. Por esse motivo é importante garantir que esse tipo de evento seja previsto com uma precisão que permita a redução do risco de desastres. Como medida para melhorar as previsões meteorológica em Moçambique, foi introduzida em 2021 a plataforma *myDewetra*. Esta é uma plataforma composta por dois modelos para previsão do tempo: GFS e o ECMWF. Esses dois modelos globais permitem fazer previsão meteorológica e já foram avaliados de forma exaustiva para maior parte das bacias oceânicas do Hemisfério Norte, porém poucas pesquisas foram feitas para o Hemisfério Sul, principalmente na bacia do Sudoeste do Oceano Índico (SOI). A avaliação do modelo meteorológico permite perceber o quão adequado ele é para fazer previsão em uma determinada bacia oceânica. Devido a falta de dados do modelo ECMWF, neste estudo foi avaliada a habilidade do modelo GFS em prever a precipitação acumulada em 24h associada a ciclones tropicais usando como caso de estudo o ciclone Freddy (2023). Este ciclone foi o primeiro e o único ciclone que foi usado para testar a plataforma *myDewetra* até a data desta pesquisa. Visto que a quantidade e distribuição da precipitação pode ser fortemente afectada pela trajectória e intensidade do ciclone tropical, notou-se a necessidade de avaliar também a habilidade do modelo GFS em prever trajectória e intensidade do ciclone Freddy. A previsão da trajectória e intensidade foram avaliadas através do cálculo do erro de previsão. A previsão da precipitação foi avaliada através do cálculo da raiz do erro quadrático médio (RMSE – *The Root Mean Squared Error*). Os resultados mostram que o modelo GFS é capaz de prever o local pelo qual o ciclone irá passar, porém o mesmo não é capaz de prever o momento exacto da passagem do ciclone. Como resultado, as previsões de trajectória do ciclone estão propensas a alarmes falsos. Além disso, as previsões de trajectória mostraram uma dependência do *lead time*, ou seja, quanto maior for o *lead time* menor é o desempenho de previsão. Em relação as previsões de intensidade, os resultados mostram que a previsão da intensidade não depende do *lead time*. O modelo superestima a intensidade quando o sistema está sobre a superfície terrestre e subestima a intensidade quando o sistema está sobre as águas do canal de Moçambique. As previsões da precipitação acumulada mostraram que o modelo tem baixo desempenho para prever precipitações extremas associadas ao ciclone tropical Freddy. Além disso, as previsões da precipitação acumulada são dependentes do *lead time*, sendo melhores para o *lead time* de 24h e piores para *lead times* maiores (48h e 72h).

Palavras-chave: Trajectória, Intensidade, *lead time*, Ciclone Freddy, Precipitação de Ciclones Tropicais e *myDewetra*.

Abstract

In recent years, Mozambique has been affected by tropical cyclones, which cause property destruction and loss of life. The impacts of tropical cyclones can be minimized by improving weather forecasts. Forecasts of good quality can enable early action, ensuring that threatened populations can prepare for the possible impacts of cyclones. For this reason, it is important to ensure that this type of event is predicted with an accuracy that allows disaster risk reduction. As a measure to improve weather forecasts in Mozambique, the myDewetra platform was introduced in 2021. This is a platform made up of two weather forecasting models: GFS and ECMWF. These two global models allow meteorological forecasting and have already been exhaustively evaluated for most of the ocean basins in the Northern Hemisphere, but little research has been done for the Southern Hemisphere, mainly in the Southwest Indian Ocean (SOI) basin. The evaluation of the meteorological model allows us to understand how suitable it is to make forecasts in a given ocean basin. Due to the lack of data from the ECMWF model, this study evaluated only the ability of the GFS model to predict the 24-hour accumulated precipitation associated with tropical cyclones using Cyclone Freddy (2023) as a case study. This cyclone was the first and only cyclone that was used to test the myDewetra platform until the date of this research. Since the amount and distribution of precipitation can be strongly affected by the trajectory and intensity of the tropical cyclone, there was a need to also evaluate the ability of the GFS model to predict the trajectory and intensity of Cyclone Freddy. The prediction of trajectory and intensity were evaluated by calculating the prediction error. The precipitation forecast was evaluated by calculating the root mean squared error (RMSE – The Root Mean Squared Error). The results show that the GFS model is capable of forecasting the location through which the cyclone will pass, but it is not capable of forecast the exact moment of the cyclone's passage. As a result, cyclone trajectory predictions are prone to false alarms. Furthermore, trajectory forecast showed a dependency on lead time, i.e., the longer the lead time, the lower the prediction performance. Regarding intensity predictions, the results show that the intensity prediction does not depend on the lead time. The model overestimates the intensity when the system is over the Earth's surface and underestimates the intensity when the system is over the waters of the Mozambique Channel. Accumulated precipitation forecasts showed that the model has poor performance in predicting extreme precipitation associated with Tropical Cyclone Freddy. Furthermore, the accumulated precipitation forecasts are dependent on the lead time, being better for the 24h lead time and worse for longer lead times (48h and 72h).

Keywords: Trajectory, Intensity, lead time, Cyclone Freddy, Tropical Cyclone Precipitation and myDewetra.

Lista de Abreviaturas

CT	Ciclone Tropical
CCM	Complexo Convectivo de Mesoescala
CMRE	Centros Meteorológicos Regionais Especializados
CT	Ciclone Tropical
CVV	Cisalhamento Vertical do Vento
DSAEF	Dynamical-Statistical-Analog Ensemble Forecast
DSD	Drop Size Distribution
ECMWF	European Centre for Medium-Range Weather Forecasts
EUA	Estados Unidos de América
GFS	Global Forecast System
GHz	Gigahertz
GIV	Generalized Initial Value
IA	Inteligência Artificial
IOM	International Organization for Migration
ZCIT	Zona de Convergência Intertropical
ML	Machine Learning
mph	Milhas por hora
NOAA	National Oceanic and Atmospheric Administration
OCHA	Office for the Coordination of Humanitarian Affairs
PNT	Previsão Numérica de Tempo
PQP	Previsão Quantitativa da Precipitação
RADAR	Radio Detection and Ranging
RMSE	Raiz do Erro Quadrático Médio
RNA	Redes Neurais Artificiais
SOI	Sudoeste do Oceano Índico
SCM	Sistemas Convectivos de Mesoescala
TE	Transição Extratropical
TS	Threat Score

TSAI	Tropical Cyclone Track Similarity Area Index
TSM	Temperatura da Superfície do Mar
VCM	Vórtice Convectivo de Mesoescala
VWS	Vertical Wind Shear
WMO	World Meteorological Organization
WRF	Weather Research and Forecast

Capítulo 1 – Introdução e Objectivos

1.1. Introdução

Ciclones tropicais (CT) são sistemas sinópticos que se formam sobre os oceanos tropicais através do suprimento de energia das águas quentes subjacentes. Eles mostram uma circulação ciclónica com uma baixa pressão central (Tang et al., 2018).

As chuvas de CT e as inundações associadas representam um perigo significativo que pode estender-se centenas de quilómetros para o interior, a partir da costa. Os impactos das inundações são causados por eventos compostos com múltiplos factores, tais como precipitação e *storm surge* que levam a inundações nas zonas costeiras (Lamers et al., 2023). Em alguns casos a precipitação e *storm surge* pode se somar à alta descarga de água doce provenientes de rios, intensificando o risco de inundação (Bié et al., 2017). Essas inundações são responsáveis por enormes perdas e danos (Rappaport, 2014; Bié et al., 2017; Lamers et al., 2023).

Prat e Nelson (2016), notaram que a maior parte das chuvas extremas no Leste Asiático (Taiwan, costa leste da China e noroeste da China), Sul e Oeste da Ásia (Omã e montanhas de Satpura na Índia), Oceania (Oeste e Norte da Austrália) e África Oriental (costa de Moçambique, Madagáscar e Ilhas Reunião), estão relacionadas com os ciclones tropicais. Além disso, esses extremos de precipitação são maioritariamente observados no final da estação chuvosa, após o pico da actividade ciclónica.

O ciclone tropical Freddy, que se formou no Oceano Índico e afetou a África Austral, em 24 horas, algumas províncias de Moçambique registaram uma precipitação superior a 200 mm (WMO, 2023b) que, segundo Myronets (2023), essa quantidade de chuva é maior que a média mensal dessas regiões. Uma das causas do volume tão elevado de chuvas foi o movimento lento do ciclone (Myronets, 2023). Segundo este autor, movimentos lentos de ciclones tropicais permitem que eles absorvam mais humidade contida no oceano. Como resultado, ciclone Freddy gerou chuvas fortes e contínuas nas regiões afectadas, resultando muitas vezes em inundações generalizadas (WMO, 2023b).

Uma das maiores preocupações expressas pelos centros meteorológicos que monitoraram o ciclone Freddy foi a sua duração. De acordo com a Australian Bureau of Meteorology (2023), o sistema de

baixa pressão formou-se no dia 5 de fevereiro de 2023 e evoluiu para ciclone tropical no dia 6 de fevereiro, no Oceano Índico, a Sul da Indonésia. Começou a mover-se para Oeste e a força do vento atingiu 270 km/h no seu epicentro. Em 7 de março, quebrou o recorde de ciclone mais duradouro desde o início dos registos meteorológicos, segundo a WMO (2023b), tendo durado mais de 34 dias.

O ciclone Freddy trouxe diversos impactos socioeconómicos e humanitários que vão desde a destruição de casas, corte de estradas, perda de vidas e paralisação de serviços básicos, como água, energia, saúde (WMO, 2023b; Myronets, 2023; Head, 2023). Segundo a *International Organization for Migration* (IOM, 2023), as chuvas registadas antes da chegada do ciclone Freddy deixaram o solo húmido, o que exacerbou os impactos causados pelas chuvas trazidas pelo ciclone Freddy. Os surtos de cólera pioraram na maior parte de Moçambique em termos de números e distribuição geográfica (IOM, 2023; OCHA, 2023b), além de ter deslocado mais de 183 mil pessoas entre Moçambique e Malawi (Gov-UK, 2023).

Embora a intensidade do ciclone seja o parâmetro mais reportado, a precipitação associada aos CT não se correlaciona diretamente com a intensidade da tempestade (Rappaport, 2014). Os CT que são considerados “fracos” pelas medidas de intensidade tradicionais ainda podem produzir chuvas extremamente fortes durante e após a chegada ao continente (Tang et al., 2018; Lamers et al., 2023). Tais eventos extremos constituem um grande desafio para as previsões operacionais e conduzem frequentemente a catástrofes nas regiões afetadas (Tang et al., 2018).

Para mitigar os impactos dos CTs, é importante garantir previsões mais precisas de chuvas e inundações associada aos ciclones tropicais (Barlow, 2011), incluindo a previsão da intensidade (Bousquet et al., 2019). Os meteorologistas dependem fortemente de modelos de previsão numérica do tempo (PNT) para fazer as previsões e, com base nisso, gerar avisos de CT (Moses & Ramotonto, 2018).

Por esse motivo, a avaliação do desempenho dos modelos de PNT na previsão de eventos de CT tem atraído o interesse de diversos pesquisadores. Moses e Ramotonto (2018), avaliaram os modelos do *European Centers for Medium-Range Weather Forecast* (ECMWF) e o *Global Forecast System* (GFS) para previsão do ciclone Dineo, onde observaram que o modelo ECMWF

tem um desempenho melhor que o GFS para a previsão da intensidade, localização e valores máximos de precipitação enquanto que o GFS é melhor que o ECMWF para prever a localização da precipitação máxima, faixa de nuvens associada a tempestade e quantidade total de precipitação. Estas características de ambos modelos os torna complementares para a previsão de ciclones tropicais sobre o Botswana. Para Liu et. al (2021), o modelo ECMWF tende a superestimar precipitações baixas e subestimar precipitações mais altas no noroeste da China.

Apesar dos custos catastróficos sociais dos ciclones tropicais, pouco ainda é sabido sobre a contribuição dos ciclones tropicais para os eventos extremos de precipitação. Este trabalho tem o objectivo de avaliar a aplicabilidade da plataforma myDewetra para a previsão de ciclones tropicais e a sua precipitação associada em Moçambique. Avaliar as previsões de CT do modelo GFS irá fornecer informações cruciais para ajudar os previsores a compreender se este modelo pode ser útil para previsões operacionais. As avaliações também são cruciais para modeladores que podem utilizá-las para direccionar o desenvolvimento futuro e melhorias dos modelos (Moses & Ramotonto, 2018).

1.2. Motivação

Nos últimos anos, a frequência e intensidade de ciclones tropicais que atingiram Moçambique revelaram a incapacidade do país de responder aos seus efeitos. Portanto, a motivação para realizar esta pesquisa é a necessidade que existe de buscar meios de nos adaptarmos aos ciclones tropicais. Um dos meios para tal é aumentando a nossa capacidade de previsão desses sistemas, o que permite que as pessoas possam se preparar para responder aos seus efeitos.

1.3.Objectivos

1.3.1. Objectivo Geral

Avaliar o desempenho do modelo GFS para previsão da precipitação induzida pelo ciclone tropical Freddy em Moçambique.

1.3.2. Objectivos específicos

- Avaliar o erro de previsão trajectória do ciclone Freddy durante o deslocamento do sistema para a região Sul e Norte de Moçambique;

- Avaliar o erro de previsão da intensidade do ciclone Freddy durante o seu deslocamento para a região Sul e Norte de Moçambique;
- Determinar o RMSE da precipitação prevista pelo modelo GFS após o *landfall* do ciclone Freddy na região Sul e Norte de Moçambique;

1.4. Problema de pesquisa

Eventos de chuvas fortes, tipicamente associados a ciclones tropicais, provocam inundações intensas, causando conseqüentemente graves perdas de vidas e propriedades (Fernández-Alvarez et al., 2020). A severidade das cheias está intrinsecamente ligada à intensidade, duração e o volume total das chuvas (Jaffrés & Gray, 2023).

Apesar dos impactos significativos das chuvas causadas pelos ciclones tropicais que atingem a costa, a previsão quantitativa da precipitação continua a ser um problema não resolvido (Rogers et al., 2003). Por exemplo, em Moçambique, em particular, a previsão da precipitação associada a ciclones tropicais representa um dos maiores desafios. É difícil determinar onde cairão as chuvas dos ciclones, quanta chuva cairá, quão intensa será a precipitação e quais serão os impactos localizados dessas chuvas (IFRC, 2020).

Portanto, reconhecendo que o conteúdo de água das tempestades tropicais está a aumentar à medida que a temperatura da superfície do mar aumenta, o que contribui para o aumento da intensidade dos ciclones e a taxa de precipitação associada (Kossin, 2018), a previsão de precipitação dos ciclones tropicais é cada vez mais importante.

Este trabalho pretende responder a seguinte pergunta de pesquisa: Quão bem o sistema de previsão do myDewetra reproduzem os dados observados em termos de trajetória, intensidade e precipitação do ciclone Freddy?

1.5. Justificativa do estudo

Moçambique é um dos países mais afectados por desastres naturais no mundo, por essa razão torna-se um dos países candidatos ideais à melhoria do sistema de aviso prévio para eventos de início rápido como os ciclones tropicais (Nogueira, 2019). Os ciclones tropicais ameaçam a vida e a

propriedades, além de afectar a economia e infligir perigos sociais significativos. Além disso, o aumento da população e urbanização significa que mais pessoas estão sujeitas aos impactos desses eventos (Clyde & Co LLP, 2018). Ser capaz de prever esses eventos com precisão é bastante útil pois permite que as pessoas se preparem para eles.

Embora muitas pesquisas tenham estudado a habilidade dos modelos em prever a precipitação de ciclones tropicais a nível global, outros estudos já mostraram que a precipitação de ciclones tropicais pode variar de acordo com as condições geográficas locais (Chen et al., 2008; Lee et al., 2018). Nesse contexto, visto que o myDewetra usa modelos globais, esta pesquisa pretende investigar a habilidade do modelo GFS em prever a precipitação do ciclone Freddy que atingiu Moçambique em 2023.

1.6. Hipóteses

O myDewetra usa modelos globais, então ele tem um baixo desempenho para prever a precipitação de ciclones tropicais em Moçambique.

Capítulo 2 - Revisão de literatura

2.1. Ciclones tropicais

Ciclone tropical é o termo genérico para um sistema de baixa pressão sobre águas tropicais ou subtropicais com convecção organizada e uma circulação de vento de superfície ciclônica definida (Fink & Speth, 1998). A pressão central é geralmente de 950 mb e excepcionalmente cai abaixo de 900 mb (Barry & Chorley, 2004). Os ventos giram no sentido horário no Hemisfério Sul (e no sentido anti-horário no Hemisfério Norte) ao redor da tempestade com ventos se movendo em direção ao centro (Fink & Speth, 1998; Barry & Chorley, 2004; Stull, 2017). A Figura 2.1 ilustra ciclones tropicais e seus respectivos sentidos de rotação de acordo com o hemisfério.

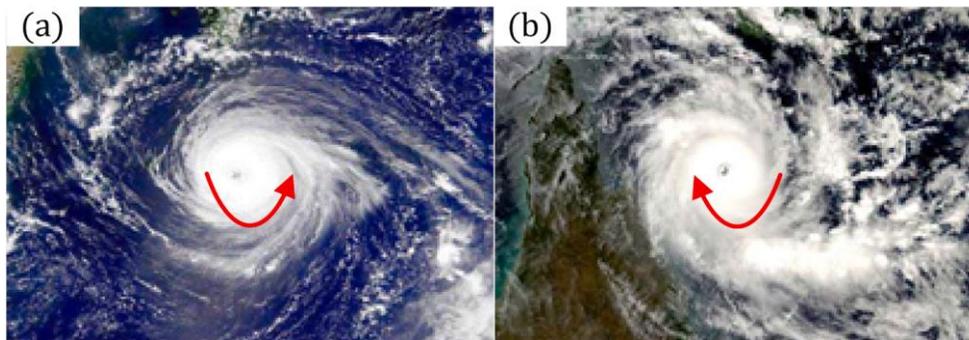


Figura 2.1: Direção rotacional do ciclone tropical: (a) no sentido anti-horário no hemisfério Norte; (b) No sentido horário no hemisfério Sul. Fonte: (Hou et al., 2022).

A designação dada aos ciclones tropicais pode mudar de acordo com a bacia oceânica onde se formou o sistema. Por exemplo, no Golfo do México e no leste do Oceano Pacífico, os ciclones tropicais são chamados de furacões (Frank & Ritchie, 2001), enquanto que no Pacífico ocidental eles são chamados de tufões. Sobre o Oceano Índico e perto da Austrália, eles são chamados de ciclones (Stull, 2017). Por acordo internacional, ciclone tropical é o termo geral para todas as tempestades do tipo ciclone que se originam em águas tropicais (Ahrens, 2009). A Figura 2.2 ilustra as designações atribuídas aos ciclones tropicais de acordo com a região.

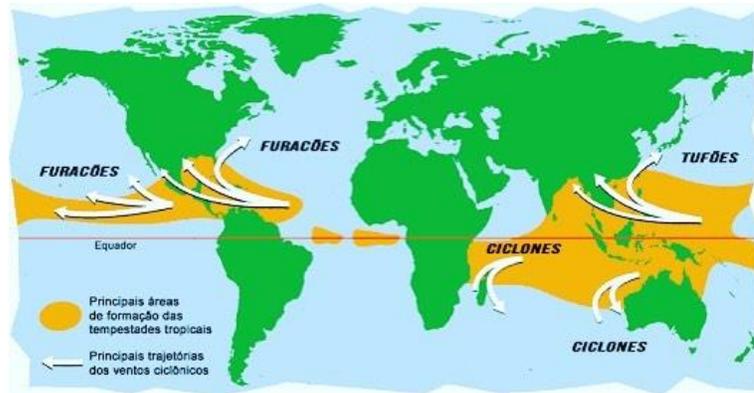


Figura 2.2: Designação dos ciclones tropicais em diferentes bacias oceânicas. Fonte: (Oliveira, 2018).

Os ciclones tropicais diferem dos ciclones de latitude média porque os ciclones tropicais não têm frentes. Os ciclones tropicais têm núcleos quentes, enquanto os ciclones de latitude média têm núcleos frios. Os ciclones tropicais podem persistir duas a três vezes mais do que os ciclones típicos de latitudes médias (Stull, 2017).

Os ciclones tropicais são classificados de acordo com a velocidade do vento máximo sustentado na superfície. Quando os sistemas de baixa pressão possuem ventos máximos sustentados de 10 a 17 m/s são chamadas de “depressões tropicais”, acima de 17 m/s (e abaixo de 33 m/s) são chamados de tempestades tropicais. Na fase de “depressões tropicais”, os ciclones recebem um nome. Quando o vento máximo sustentado é superior a 33 m/s, o sistema é chamado de “ciclone tropical” (Fink & Speth, 1998; Vitart et al., 2003; Barry & Chorley, 2004; Nordhaus, 2010; Evans, 2017).

Os ciclones tropicais ocorrem com mais frequência no Hemisfério Norte em relação ao hemisfério Sul. De acordo com Evans (2017), a nível global ocorrem em média 90 ciclones tropicais por ano. Em média ocorrem 55 ciclones tropicais no hemisfério Norte e 25 no hemisfério Sul (Barry & Chorley, 2004). Aproximadamente 30% dos ciclones que ocorrem a nível global são originados no Oeste do Pacífico Norte (Fan, 2006), enquanto que 6% são originados no Norte do oceano Índico (Singh & Roxy, 2020; Das et al., 2023). De acordo com Mavume (2009), 14 % do total global de ciclones tropicais são originados no Sudoeste do Oceano Índico, o correspondente a 11 ciclones por ano.

Uma série de condições são necessárias, mesmo que nem sempre suficientes, para a formação de ciclones. Um requisito é uma extensa área oceânica com uma temperatura superficial superior a

27°C (Barry & Chorley, 2004; Nordhaus, 2010). Porém, esse limiar deve ser considerado de caso para caso. Por exemplo, Mavume (2009) mostrou que a maior parte dos casos de formação de ciclones tropicais no sudoeste do oceano Índico estavam associados a temperaturas da superfície do mar superiores a 28°C. Por essa razão, os meses mais ativos são de Janeiro e Fevereiro, quando a zona de convergência intertropical (ZCIT) atinge sua posição mais ao Sul (Mavume et al., 2009). A Figura 2.3 ilustra as temperaturas das águas superficiais do sudoeste do oceano Índico associado a maior gênese de ciclones tropicais.

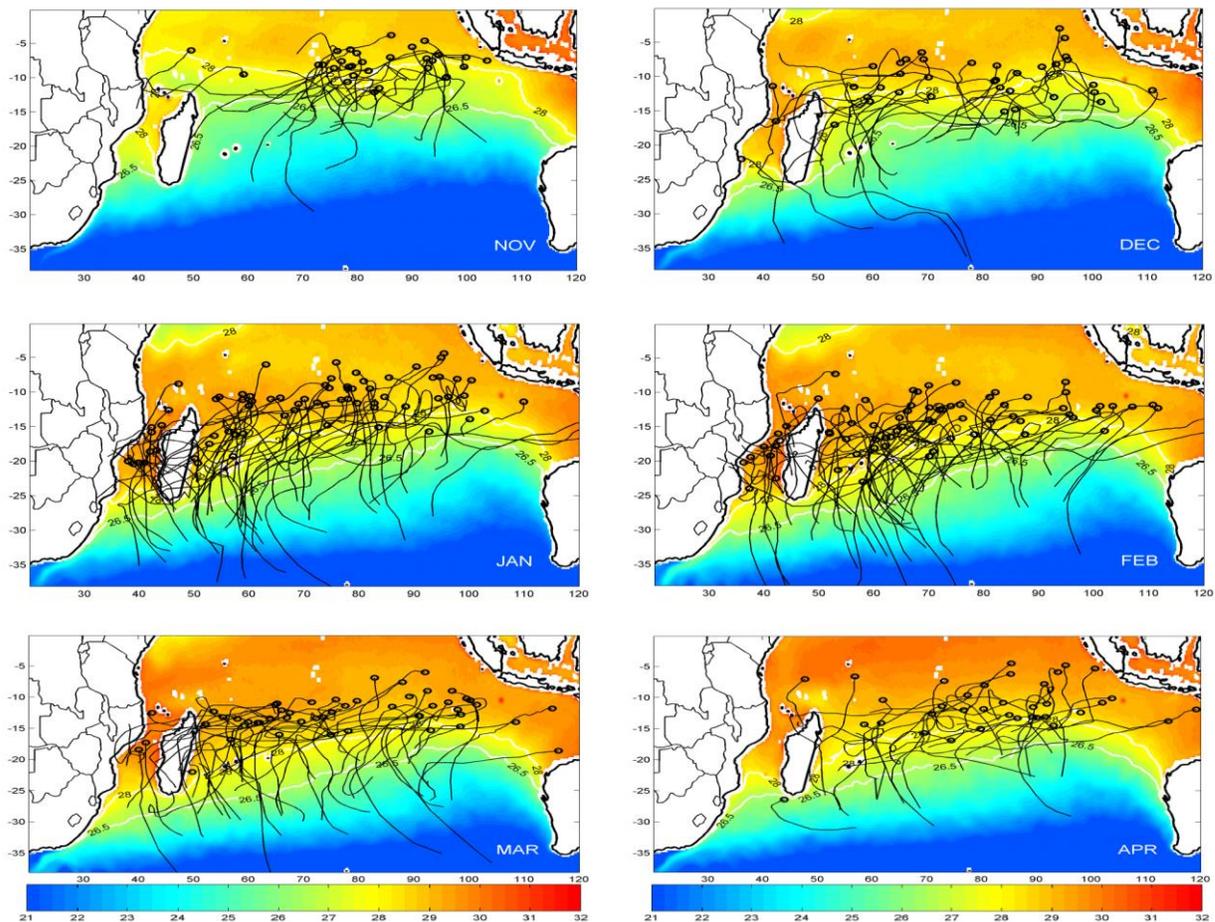


Figura 2.3: Regiões de maior gênese de ciclones tropicais no sudoeste do oceano Índico. A localização da gênese dos ciclones tropicais está indicada por círculos pretos. A isoterma mais a Sul, 26,5°C, representa o limite inferior típico da temperatura da superfície do mar para a formação de ciclones. A isoterma Norte, 28°C, é o valor limite proposto pelo Mavume (2009) para o Sudoeste do Oceano Índico. Portanto, nota-se que a maior parte dos ciclones se formaram a Norte da isoterma de 28°C, que geralmente são regiões com temperaturas mais altas visto que estão mais próximas do equador. Fonte: (Mavume et al., 2009).

Outro aspecto bastante importante sobre a formação dos ciclones tropicais, é que os ciclones raramente se formam perto do equador, onde o parâmetro Coriolis é próximo de zero, ou em zonas de forte cisalhamento vertical do vento (isto é, abaixo de uma corrente de jato), uma vez que ambos os factores inibem o desenvolvimento de um vórtice organizado (Barry & Chorley, 2004). Um pouco longe do equador, entretanto, os CTs podem se formar mais facilmente na presença de uma força de Coriolis maior e de outras condições ambientais favoráveis (Roose et al., 2023). Embora por muitos anos os cientistas acreditaram que os ciclones não se formam abaixo de 5°, por exemplo Pielke (1997), Emanuel (2005, citado por Steenkamp et al., 2019), provou que esse pensamento estava incorreto pela ocorrência do tufão *Vamei*, que foi classificado pela primeira vez como uma depressão tropical a uma latitude de cerca de 1,5° N em 26 de dezembro de 2001 sobre o Mar da China Meridional e fez o *landfall*¹ um dia depois, ao longo da costa sudeste da península malaia a 1,6° N, cerca de 50 km ao Norte de Singapura. Portanto Steenkamp et al. (2019) descobriram que a rotação da terra não é um ingrediente para a ciclogênese tropical. Porém, de acordo com esses autores, regiões com latitude abaixo de 5° se formam menos de 3 ciclones por ano, sendo que a maior parte desses ciclones de latitude baixa se formam no Hemisfério Norte a Oeste do Pacífico.

2.2. Trajetória do ciclone tropical

As massas de ar muitas vezes determinam que rota ou trajetória um determinado ciclone seguirá na superfície da Terra. Como a maioria dos ciclones tropicais contém correntes de direção internas fracas e, portanto, nem sempre são capazes de escolher onde ou quando atingirão a costa, a presença de poderosas massas de ar externas torna-se o principal meio de locomoção para estas tempestades. Ao decidir em que direção e a que velocidade um ciclone tropical se deslocará, as massas de ar determinam se esse sistema atingirá um continente ou se dissipará no mar (Longshore, 2008).

Por definição, as massas de ar são vastos corpos individuais de ar dentro dos quais a distribuição horizontal de temperatura e humidade é bastante uniforme e estável. Cobrindo grandes extensões da superfície da Terra num único trecho, formam-se quando o ar permanece estacionário sobre uma determinada localização geográfica durante um longo período de tempo, derivando assim uma temperatura uniforme daquela da terra ou do mar abaixo (Longshore, 2008).

¹ *Landfall* – é um termo em inglês que se refere a intersecção da trajetória do TC com uma linha costeira (Fudeyasu et al., 2014; Adelino & Bagtasa, 2023), ou seja, é o momento em que o ciclone atinge o continente.

As massas de ar se formam onde há existência de anticiclones. Um anticiclone é perturbação atmosférica na qual um centro de alta pressão barométrica gera ventos circulares que fluem para fora, longe do centro, e com graus decrescentes de intensidade (Nelson, 2014). Comumente chamado de alta, um anticiclone (como o próprio nome indica) é o oposto de um ciclone, ou um centro bem definido de alta pressão no qual os ventos se deslocam para fora do centro. Em um anticiclone, o ar frio e descendente não permite que a humidade do nível do mar suba o suficiente para a troposfera para a formação de nuvens de chuva. Por esta razão, o estado do tempo anticiclónico tende a ser bom, com poucas nuvens e temperaturas quentes, enquanto os sistemas ciclónicos produzem frequentemente precipitações torrenciais e ventos fortes associados a furacões e tufões maduros (Longshore, 2008).

De acordo com Stull (2017), regiões de alta pressão se formam sobre os oceanos, durante o final do verão e início do outono. Os ventos giram no sentido horário (sentido anti-horário) em torno dessas altas no Hemisfério Norte (Sul) (Longshore, 2008; Nelson, 2014). A Figura 2.4 ilustra um esquema de um anticiclone com circulação anti horária, que é característico do Hemisfério Sul.

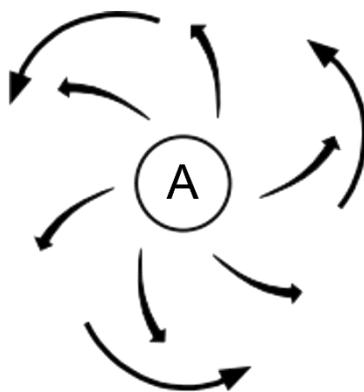


Figura 2.4: Circulação de um sistema de alta pressão no Hemisfério Sul. Fonte: (Nelson, 2014).

Assim, as trajectórias médias dos ciclones tropicais nas longitudes este e central de uma bacia oceânica são geralmente zonais - de este a oeste (Stull, 2017). No entanto, perto do lado oeste das bacias oceânicas, os ventos de monção giram em direção aos polos e, assim, afastam os ciclones tropicais do equador. Muitos desses ciclones tropicais viajam ao longo da costa leste dos continentes na direcção dos polos. A Figura 2.5 ilustra a trajectória média dos ciclones ao redor do globo terrestre.

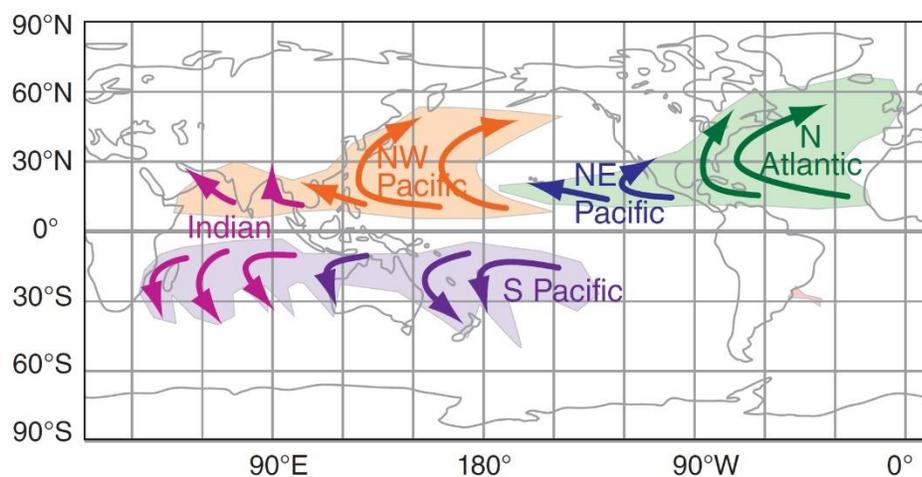


Figura 2.5: Mapa de localizações de ciclones tropicais (sombreado), com uma noção geral das trajetórias dos ciclones (setas). Fonte: (Stull, 2017).

A Figura 2.5 ilustra o padrão médio global, porém Stull (2017) afirma que as trajetórias variam de ano para ano e variam dentro de um ano. Por exemplo, de acordo com o relatório do *Office for the Coordination of Humanitarian Affairs* (OCHA, 2023a), a trajetória do ciclone Freddy não seguiu o padrão global. TC Freddy originou-se como uma perturbação perto da Austrália no início de fevereiro, antes de cruzar o Oceano Índico e atingir a costa este de Madagascar, perto de Mananjary, em 21 de Fevereiro de 2023. Freddy atravessou então a ilha de Madagáscar e o Canal de Moçambique e atingiu Moçambique — perto de Vilanculos — a 24 de Fevereiro. Posteriormente, regressou ao Canal de Moçambique e passou perto da costa sudeste de Madagáscar no dia 5 de Março. No dia 11 de Março, fez o seu segundo lendfall no Norte de Moçambique, na província da Zambézia, antes de prosseguir para o interior em direcção ao Malawi, onde trouxe chuvas torrenciais a partir de 12 de Março. TC Freddy detém o recorde de ciclone tropical duradouro com trajetória mais longa, de acordo com a Organização Meteorológica Mundial (WMO), durando 34 dias, atravessando todo o Sul do Oceano Índico e cobrindo uma distância superior a oito mil quilômetros (OCHA, 2023a). Figura 2.6 ilustra a trajetória do ciclone Freddy desde a sua formação até a sua dissipação. Os pontos indicam a localização do sistema em intervalos de 6h e os números indicam o dia em que o sistema esteve no ponto marcado.

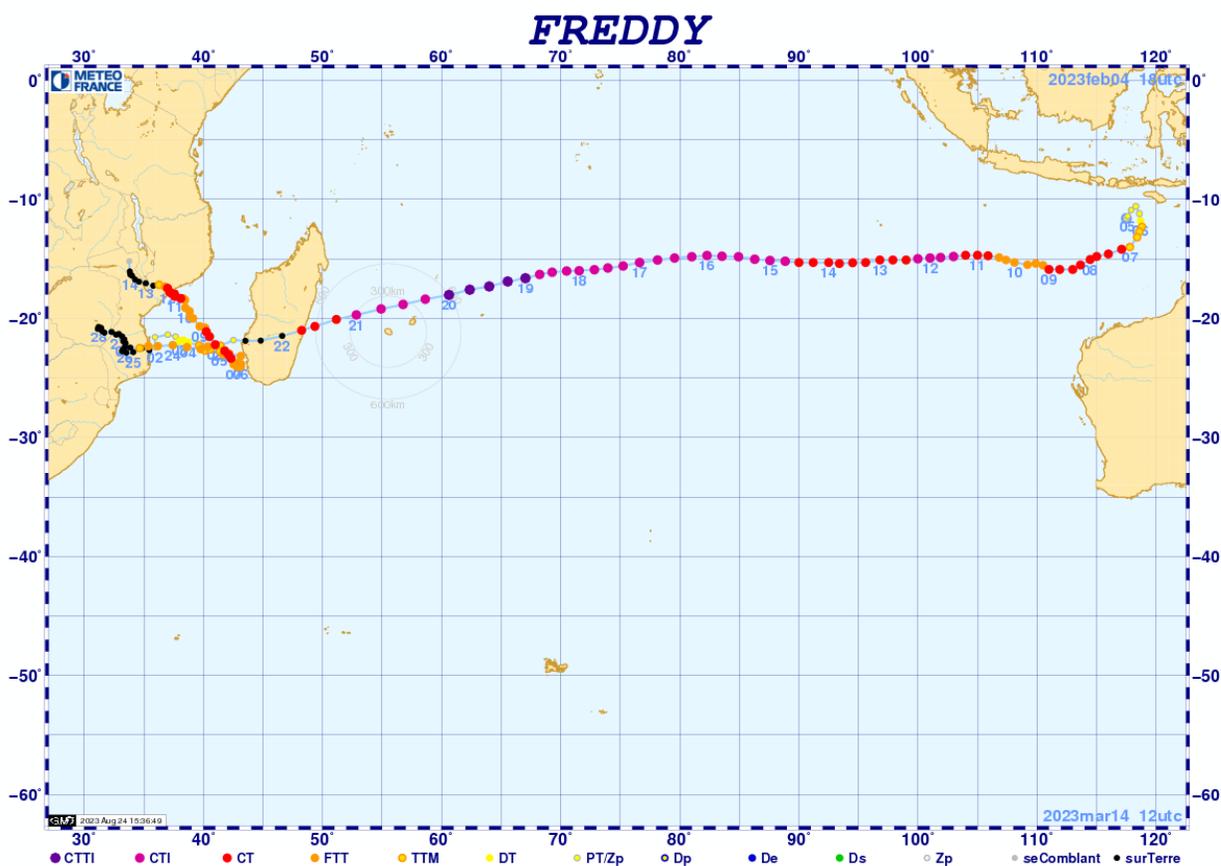


Figura 2.6: Trajetória do Ciclone Freddy. Fonte: (La Reunion, 2023b).

2.3. Intensidade dos Ciclones Tropicais

A intensidade de um TC é geralmente definida como o vento máximo na superfície ou a pressão central mínima próximo a superfície (Wang & Wu, 2004; Hendricks, 2012). Segundo a Bié e Camargo (2023), o vento máximo sustentado de um ciclone determina a sua categoria. Isso ajuda a estimar possíveis danos materiais ao longo da trajetória de um ciclone. A Tabela 2.1 ilustra a classificação dos sistemas tropicais que são usados no Sudoeste do Oceano Índico.

Tabela 2.1: Classificação dos sistemas tropicais que são usados no Sudoeste do Oceano Índico. Fonte: Adaptado de (WMO, 2023a; Bié & Camargo, 2023) e do myDewetra.

Categoria	Classificação dos sistemas tropicais	<u>m/s</u>	<u>nós</u>	<u>mph</u>	<u>km/h</u>
5	Ciclone Tropical Muito Intenso	≥ 70	≥ 137	≥ 157	≥ 252
4	Ciclone Tropical Muito Intenso	58–70	113–136	130–156	209–251
3	Ciclone Tropical Intenso	50–58	96–112	111–129	178–208
2	Ciclone Tropical	43–49	83–95	96–110	154–177
1	Ciclone Tropical	33–42	64–82	74–95	119–153
<i>TT</i>	<i>Tempestade tropical moderada e severa</i>	<i>18–32</i>	<i>34–63</i>	<i>39–73</i>	<i>63–118</i>
<i>DT</i>	<i>Distúrbio e depressão tropical</i>	<i>≤ 17</i>	<i>≤ 33</i>	<i>≤ 38</i>	<i>≤ 62</i>

O ciclo de vida de um TC consiste em uma sucessão de etapas (Figura 2.7) a partir do estabelecimento de um ambiente com a capacidade termodinâmica necessária para o desenvolvimento. O início de uma região de convecção sustentada, que pode resultar de uma variedade de processos, permite o desenvolvimento de um vórtice de mesoescala de superfície ou vórtice sinóptico. O sistema torna-se então autossustentável e capaz de se intensificar através de uma série de processos internos e externos e de interações complexas. No ápice temos um vórtice intenso que é capaz de extrair enorme energia do oceano e pode sofrer oscilações de intensidade e depois decair em um ambiente desfavorável, como mover-se para uma região com temperatura mais baixa da superfície do mar (TSM), forte cisalhamento vertical do vento ou quando o sistema se desloca para terra (Wang & Wu, 2004). Embora o decaimento da intensidade do ciclone normalmente ocorra após a interação com a superfície terrestre, é possível que o ciclone sofra uma rápida intensificação após o *landfall*, porém o efeito é de curta duração (Yurchak, 2022). A Figura 2.7 ilustra um diagrama esquemático do ciclo de vida de um ciclone tropical.

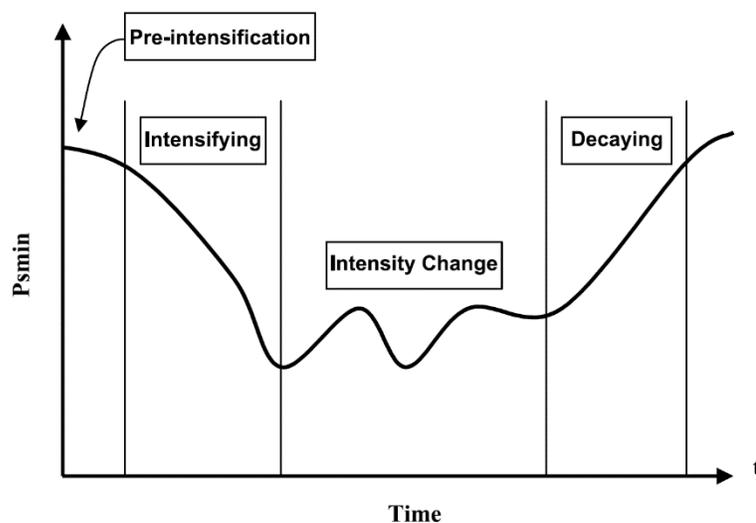


Figura 2.7: Diagrama esquemático mostrando o ciclo de vida de um ciclone tropical. Psmín-pressão central mínima a nível médio do mal. Fonte: (Wang & Wu, 2004)

Os ciclones tropicais (CTs) não são sistemas atmosféricos isolados (Wadler et al., 2023); vários factores externos e internos podem influenciar a intensidade e, por consequência, o seu desenvolvimento (Hendricks, 2012). Esses factores incluem, mas não estão limitados a terra e oceano, radiação solar, cisalhamento vertical do vento ambiental (CVV), humidade atmosférica e outros sistemas atmosféricos circundantes. Variações nesses factores externos e suas interações com a circulação do CT complicam os processos físicos subjacentes às mudanças na intensidade do CT (Wadler et al., 2023).

Porém, o principal combustível para a intensificação dos ciclones tropicais é o calor latente no vapor de água resultante da evaporação da superfície quente do oceano. À medida que o vapor de água se condensa em profundas correntes ascendentes de cúmulos, esse calor latente é libertado na atmosfera, aquecendo-a e induzindo uma circulação secundária que intensifica o vórtice. Ter uma camada superficial oceânica profunda e quente (superior a 26°C) é, portanto, uma condição necessária para a intensificação do CT (Hendricks, 2012). Do mesmo modo, temperaturas mais baixas do oceano induzidas pela ressurgência ou mistura vertical podem reduzir o fluxo de calor latente e calor sensível, resultando no enfraquecimento do ciclone tropical (Bender & Ginis, 2000; Frank & Ritchie, 2001).

O cisalhamento vertical do vento de grande escala tem um impacto negativo sobre os ciclones tropicais quando ocorrem em regiões de ciclones tropicais, onde com o tempo eles induzem o enfraquecimento do sistema. A magnitude do enfraquecimento aumenta com o aumento do cisalhamento (Frank & Ritchie, 2001). Além disso, o cisalhamento do vento pode ser um factor decisivo para determinar se um distúrbio tropical irá evoluir para o estágio de ciclone tropical ou não (Tuleya & Kurihara, 1981).

Embora exista uma compreensão razoável desses processos internos em estruturas idealizadas, ainda há uma grande lacuna em nossa compreensão desses processos na atmosfera real. Além disso, há necessidade de compreender a interação entre esses processos, bem como sua interação com o meio ambiente (Hendricks, 2012). No passado, a grande maioria da pesquisa e modelos dinâmicos operacionais, assumia-se as condições de temperatura fixa da superfície do mar (TSM) (Bender & Ginis, 2000). No entanto, numerosos estudos observacionais e numéricos confirmaram que existe um importante mecanismo de feedback positivo e negativo no sistema de ciclone tropical-oceano. À medida que o ciclone tropical se intensifica, a taxa de evaporação aumenta devido às maiores velocidades do vento, levando a um aumento no suprimento de energia latente que impulsiona a circulação do ciclone tropical. Isso representa um processo de feedback positivo. A forte mistura turbulenta também se desenvolve no oceano superior em resposta ao aumento da tensão do vento. Isso causa uma diminuição na TSM devido ao arrasto das águas mais frias da termoclina na camada de mistura, representando um mecanismo de feedback negativo (Bender & Ginis, 2000). Portanto compreender a dinâmica desses processos é importante pois permite que se melhore a previsão das mudanças de intensidade dos ciclones tropicais (Bender & Ginis, 2000; Hendricks, 2012; Kotal et al., 2019; Yurchak, 2022).

2.4. Precipitação de ciclones tropicais

Os ciclones tropicais que atingem o continente trazem frequentemente chuvas muito fortes para as regiões afectadas, de modo que muitos eventos de precipitação extrema estão relacionados com estes sistemas em todo o mundo. As fortes chuvas associadas aos CTs são um dos eventos naturais mais devastadores nas regiões costeiras do mundo, que podem provocar inundações inesperadas e deslizamentos de terra, causando enormes perdas em propriedades e vidas humanas (Yu & Wang, 2018). Por essas razões, os ciclones tropicais se tornaram um tema importante para comunidade de

pesquisa. Além disso, a mitigação de desastres depende fortemente de melhorias na capacidade de previsão de chuvas dos CTs (Chen et al., 2010). As secções a seguir apresentam uma descrição sobre os mecanismos associados a precipitação de ciclones tropicais.

2.4.1. Os mecanismos físicos por trás das chuvas em ciclones tropicais

2.4.1.1. *Fornecimento de humidade*

A convergência do vapor de água, uma característica fundamental da produção de chuvas CT, fornece um caminho para a compreensão quantitativa dos factores que influenciam as taxas de chuvas torrenciais através de análises de decomposição de factores (Liu et al., 2020; Liu et al., 2022). Além disso, Hill e Lackmann (2009) acreditam que o suprimento de humidade é um factor determinante para o tamanho do ciclone tropical. Por sua vez o tamanho de um CT, além da sua intensidade, tem uma influência directa na extensão das evacuações, no tempo de chegada das condições de tempestade e na duração dos ventos fortes num determinado local. Após a chegada ao continente, a área sob ameaça de tornados gerados por CT e de altos totais de precipitação depende em parte do tamanho da tempestade (Hill & Lackmann, 2009).

Várias pesquisas foram desenvolvidas para compreender a influência do fornecimento de humidade sobre a precipitação de ciclones tropicais. Liu et al. (2020) descobriram que em condições de aquecimento global, o aumento das taxas de evaporação e consequente aumento da humidade atmosférica é o factor mais importante para o aumento da taxa de precipitação em ciclones tropicais dentro de um raio de 500 km.

Utilizando o modelo Weather Research and Forecast (WRF) para investigar a sensibilidade da precipitação total do ciclone tropical Bilis ao conteúdo de vapor de água ambiente, Wu e Chen (2012) descobriram que a precipitação dos ciclones tropicais diminuiu drasticamente com a redução do conteúdo de vapor de água na atmosfera. Eles também notaram que além da convergência de humidade, a mudança no tamanho da tempestade também é responsável pela redução da precipitação. A convergência de humidade reduziu proporcionalmente com o teor de humidade, levando à redução da fonte de humidade para precipitação. O tamanho do TC também diminuiu de acordo com o teor de vapor d'água, e esta redução contribuiu para a diminuição da área de precipitação. Ambos os mecanismos podem levar à redução da precipitação total do ciclone tropical. Witcraft et al. (2005) também estudaram o ciclone tropical Bilis, porém usando o modelo

de Mesoescala Penn State/NCAR Versão 5 (MM5). As simulações mostraram que a precipitação orográfica é dominada pela convergência de humidade e a contribuição da advecção de humidade nas proximidades da montanha é insignificante.

Makarieva et al. (2017), descobriram que a precipitação em ciclones normalmente permanece consideravelmente maior do que a soma da evaporação média até 3.000 km do centro do ciclone. Isto indica que um ciclone não pode ser visto como um sistema de estado estacionário, em que o vapor de água fornecido pela evaporação simultânea ao longo de alguns milhares de quilómetros poderia ser concentrado na menor área de precipitação de um ciclone. Além disso, eles notaram que a quantidade de vapor de água atmosférico pré-existentes são consumidos à medida que o ciclone se move pela atmosfera.

Hill e Lackmann (2009), ao estudar a influência da humidade ambiental na extensão lateral do campo de vento do ciclone tropical, perceberam que ambientes húmidos favorecem o desenvolvimento de ciclones tropicais maiores, com tempestades progressivamente maiores evidentes a cada aumento incremental de humidade relativa. O estudo também revelou que os ciclones tropicais simulados em ambientes secos exibem precipitação reduzida fora do núcleo do sistema em relação a tempestades em ambientes mais húmidos. Estes resultados são consistentes com os resultados obtidos por Pérez-Alarcón et al. (2022) quando analisaram as fontes de humidade para precipitação associadas a grandes furacões durante o ano de 2017 na Bacia do Atlântico Norte. Resultados similares aos do Hill e Lackmann (2009), foram também obtidos por Lin et al. (2015) que investigaram a área da precipitação do ciclone tropical controlada pela temperatura da superfície do mar, onde notaram que a taxa da precipitação dos ciclones tropicais aumentava a medida que a temperatura da superfície do mar aumentava. A principal razão para isso é que o aumento da temperatura da superfície do mar (TSM) está directamente ligada ao aumento do vapor de água da atmosfera, que ocorre por convecção. Como resultado, um CT que se move para uma área de TSM relativa mais alta tende a encontrar uma humidade relativa mais alta na troposfera média, o que por sua vez tende a aumentar o aquecimento por condensação e reduzir o resfriamento evaporativo. Este resultado pode explicar por que os CT tendem a ser os maiores no Oeste do Pacífico Norte, onde estão localizados os maiores valores de TSM relativa e humidade relativa na troposfera média das regiões tropicais.

2.4.1.2. *Transição extratropical*

Durante as estações de verão e outono dos Hemisférios Norte e Sul, um ciclone tropical recorre muitas vezes evolui para um ciclone extratropical de movimento acelerado e desenvolvimento rápido que pode conter ventos com força de tempestade ou mesmo ciclones tropicais (Harr & Elsberry, 2000). Um número significativo de ciclones tropicais move-se para as latitudes médias e transforma-se em ciclones extratropicais. Este processo é geralmente referido como transição extratropical (TE). Durante a TE, um ciclone produz frequentemente chuvas intensas e ventos fortes (Jones et al., 2003).

Klein et al. (2000) define a transição extratropical em termos de duas etapas: transformação, na qual o ciclone tropical evolui para uma tempestade baroclínica; e reintensificação, onde a tempestade transformada se aprofunda como um ciclone extratropical. Colle (2003), afirma que normalmente tais transições estão associadas ao desenvolvimento de assimetrias de tempestade nos campos de precipitação, temperatura e vento à medida que o ciclone se move em direção a latitudes mais altas. Os ciclones tropicais que passam por uma transição extratropical podem evoluir para poderosos ciclones de latitudes médias que causam danos significativos causados pelo vento e pelas ondas nas áreas costeiras (Klein et al., 2000; Colle, 2003). Porém, as características que o ciclone irá adquirir após a TE dependem das condições de circulação existentes nas latitudes médias para as quais o ciclone se moveu (Harr & Elsberry, 2000). Segundo Klein et al. (2000), o início e o fim do estágio de transformação da TE no Oeste do Pacífico Norte são definidos com base na interação da circulação de ciclones tropicais com uma zona baroclínica preexistente de latitude média. Estes autores notaram que os casos que completam o estágio de transformação da TE ficam incorporados na zona baroclínica preexistente de latitude média, com o centro da tempestade no ar frio e descendente. Os casos que iniciam a transformação, mas não ficam incorporados na zona baroclínica, não conseguem completar a transformação e simplesmente se dissipam em temperaturas mais baixas da superfície do mar e em um ambiente de cisalhamento vertical do vento.

Já existem algumas teorias que tentam explicar a influência da transição extratropical na precipitação dos ciclones tropicais, por exemplo Liu et al. (2020), Atallah e Bosart (2003) e Colle, 2003. Liu et al. (2020) estudaram a resposta das chuvas extremas de ciclones tropicais que atingem o continente submetidos a transição extratropical no contexto das mudanças climáticas projectadas.

Eles mostraram que o aquecimento das águas da superfície do mar, devido a mudanças climáticas, induzem ao aumento da taxa da precipitação no núcleo interno para a fase de transição extratropical. Atallah e Bosart (2003), estudaram a transição tropical e distribuição da precipitação do Furacão Floyd (1999). Este estudo demonstrou que durante a fase de transição extratropical forte, a escala da tempestade tropical muitas vezes se expande para corresponder à do cavado de latitudes médias, à medida que o núcleo da tempestade tende a se propagar em direção a valores mais elevados de cisalhamento. Esta evolução representa uma mudança na dinâmica relevante da tempestade de natureza adiabática para baroclínica. No caso do Furacão Floyd, a dinâmica evoluiu de uma forma que acentuou o potencial para fortes precipitações.

A forte precipitação em direção aos polos do ciclone tropical nem sempre é prevista, uma vez que muitas vezes começa longe do centro do ciclone tropical. Devido à expansão da área coberta por nuvens e precipitação quando o ciclone tropical se move em direção aos polos, fortes precipitações podem ocorrer sobre a terra sem que o centro do ciclone tropical atinja a costa. Se a precipitação intensa associada à região central do ciclone tropical cair na mesma região que a precipitação pré-tempestade, o potencial de inundações aumenta (Jones et al., 2003).

A transição extratropical representa um problema de previsão quantitativa de precipitação (PQP) especialmente desafiador. Uma PQP bem-sucedido requer uma previsão precisa da trajetória, intensidade e mudanças estruturais das tempestades que sofrem TE. O momento da mudança de precipitação em relação à trajetória da tempestade descrita acima é muito sensível aos mecanismos físicos que governam o processo de TE (por exemplo, a estrutura dinâmica e termodinâmica do cavado a montante). A geografia local e regional (por exemplo, costas e montanhas) também pode contribuir significativamente para a distribuição final da precipitação associados às tempestades que sofrem TE. Os actuais modelos de previsão operacional são frequentemente “estressados” ao fazer previsões PQP para tempestades que sofrem TE. Da mesma forma, regras simples que invocam a duração da precipitação como o predictor dominante para a precipitação total de tempestades podem falhar para um evento de TE que pode conter circulações de mesoescala incorporadas significativas na presença de terrenos altamente variados (Jones et al., 2003).

2.4.1.3. Topografia

A topografia costeira e montanhosa pode influenciar a precipitação associada aos ciclones tropicais (Cho et al., 2022). Muitas ilhas isoladas compreendem um único pico de montanha devido à actividade vulcânica. As montanhas geralmente apresentam um declive ascendente e um declive descendente, o que leva à convecção e precipitação induzidas orograficamente. A variação na forma geográfica de cada ilha causa diferentes padrões de fluxo de ar, especialmente quando há força suficiente para elevar o ar encosta acima. Quando o vento a barlavento é forte, o ar da superfície sobe sobre a montanha ou desce imediatamente após passar o cume (Lee et al., 2018). O vento horizontal que atinge as encostas das montanhas a barlavento pode gerar um movimento ascendente (Cho et al., 2022), resultando na formação de nuvens através da condensação do vapor de água (Lee et al., 2018), o que pode contribuir para um aumento nas chuvas (Chen et al., 2010).

Existem 4 condições ambientais básicas para ocorrência de chuvas orográficas, nomeadamente: 1) uma corrente de ar condicional ou potencialmente instável que colide com as montanhas, 2) uma corrente de ar muito húmido de baixo nível, 3) uma montanha íngreme e 4) um sistema sinóptico quase estacionário para desacelerar o sistema convectivo sobre a área de ameaça (Lin et al., 2001; Witcraft et al., 2005).

Em 2021, Yamada e Kuribayashi desenvolveram um estudo sobre o efeito da topografia sobre as fortes chuvas causadas pelo tufão Hagibis (2019) em Nagano, Japão. Eles descobriram que as montanhas na região Norte da província de Nagano contribuíram para a forte precipitação, que aumentava a uma taxa aproximadamente constante de 4,4 mm a cada 100 m de aumento de altitude. Para altitudes entre 900 a 1200m, a taxa de incremento da precipitação aumentou. As elevações correspondiam aproximadamente ao nível de convecção livre ou a elevações entre o nível de convecção livre e o nível de condensação por elevação em torno da trajetória do tufão.

Cho et al. (2022) usaram o modelo Weather Research and Forecasting (WRF) para investigar os efeitos das anomalias topográficas e de TSM sobre a precipitação induzida pelo tufão Chaba. As simulações indicaram que a topografia de Ulsan foi responsável por maior quantidade de chuva a barlavento e nos cumes das montanhas em comparação com a precipitação a sotavento, que era relativamente menor. A corrente ascendente induzida orograficamente estendeu-se até a média troposfera e contribuiu para o fluxo vertical ascendente de humidade associado às chuvas. Para

Chen et al. (2010), os efeitos orográficos são responsáveis pelas assimetrias na distribuição das chuvas.

O modelo WRF foi também usado por Racoma et al. (2016) para avaliar a mudança nas chuvas causadas por ciclones tropicais devido ao efeito orográfico da cordilheira de Sierra Madre em Luzon, Filipinas. Os resultados indicam que ao longo da cordilheira existe um aumento da precipitação devido ao efeito orográfico. Estes resultados são consistentes com os resultados obtidos por Cho et al. (2022) e Yamada e Kuribayashi (2021). Porém, Racoma et al. (2016) notaram que além de aumentar a precipitação, a presença da Cordilheira da Sierra Madre retarda o movimento dos ciclones tropicais, permitindo mais tempo para a formação de precipitações sobre o país.

Os perfis de vento também sugerem que os lados de barlavento e sotavento das cadeias de montanhas durante os ciclones tropicais mudam dependendo da trajetória da tempestade. Por exemplo, Lee et al. (2018) notaram que o aumento da precipitação causada pelo Tufão Khanun ocorria tanto a barlavento assim como a sotavento da montanha, dependendo da direção do vento. A Figura 2.8 mostra a distribuição do vento do tufão Khanun sobre a ilha montanhosa de Jeju. Esta figura mostra que a localização da chuva dependia da direção do vento. A localização da chuva indica a zona de barlavento da montanha.

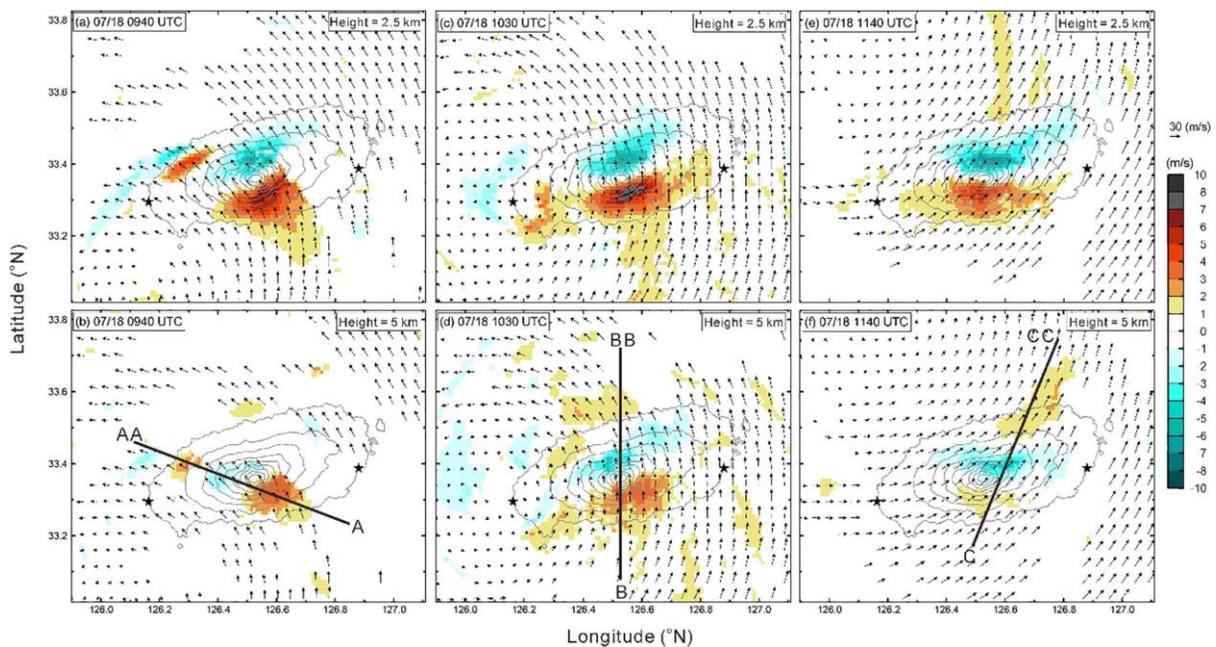


Figura 2.8: Distribuição horizontal do vento do tufão Khanun sobre a ilha de Jeju durante o tufão Khanun. Fonte: (Lee et al., 2018).

Usando dados de taxas de chuva derivadas de radar meteorológico, Panziera e Germann (2010), estudaram a relação entre o fluxo de ar e a precipitação orográfica do lado sul dos Alpes, onde concluíram que a velocidade do vento a barlavento tem o maior impacto na intensidade e frequência da precipitação nas montanhas, enquanto a direção do vento determina a distribuição espacial da precipitação. Condições instáveis causam mais precipitação nas montanhas em comparação com os casos estáveis; no entanto, as diferenças na estabilidade da massa de ar têm um impacto menor na intensidade da precipitação em comparação com a velocidade e direção do vento. Contudo, é importante notar que, embora as cadeias montanhosas possam aumentar a precipitação associada a um ciclone tropical sob certas condições, a rugosidade e a fricção da superfície terrestre podem consumir a energia do ciclone tropical sobre o continente e levar à sua dissipação (Chen et al., 2010).

2.4.1.4. *Sistemas convectivos de mesoescala*

Os sistemas convectivos de mesoescala (SCM) descrevem agrupamentos organizados de tempestades nos trópicos e latitudes médias que abrangem milhares de quilômetros quadrados. Embora reconhecidos há mais de um século, o advento das observações por satélite e radar, bem

como das simulações de modelos atmosféricos, trouxe uma maior compreensão (Schumacher & Rasmussen, 2020).

Seu desenvolvimento requer dois blocos de construção básicos: uma corrente ascendente, em que o ar quente e húmido sobe rapidamente, formando nuvens cumulonimbus características, e uma corrente descendente, que traz a chuva e o ar resfriado por evaporação de volta à superfície, criando uma piscina fria. Essas células convectivas individuais, consistindo em uma única corrente ascendente e descendente, frequentemente interagem para formar aglomerados, linhas ou complexos de tempestades. Tais agrupamentos são denominados colectivamente por sistemas convectivos de mesoescala (SCM), abrangendo quase toda a convecção organizada que tem uma escala de comprimento superior a 100 km em uma ou mais direções e dura 3 horas ou mais (Schumacher & Rasmussen, 2020).

Segundo a *National Oceanic and Atmospheric Administration* (NOAA, 2023a), um Sistema Convectivo de Mesoescala (SCM) é um conjunto de tempestades que se organiza em uma escala maior do que as tempestades individuais e normalmente persiste por várias horas ou mais. Após o surgimento de observações de sistemas meteorológicos baseadas em radar e satélite, várias categorias de SCM foram identificadas, muitas vezes centradas em sua forma (Schumacher & Rasmussen, 2020). Este termo abrangente pode incluir qualquer um dos seguintes tipos de tempestade (NOAA, 2023a):

Complexo Convectivo de Mesoescala (CCM) — Um tipo particular de SCM, um CCM é um grande aglomerado circular e de longa duração de chuvas e tempestades identificado por satélite. Muitas vezes emerge de outros tipos de tempestade durante a madrugada e nas primeiras horas da manhã. Este sistema é frequentemente usado para descrever um aglomerado de tempestades que não satisfaz os critérios de tamanho, forma ou duração de um Complexo Convectivo de Mesoescala.

Vórtice Convectivo de Mesoescala (VCM) – Um centro de baixa pressão dentro de um SCM que puxa os ventos para um padrão circular, ou vórtice. Com um núcleo de apenas 48 a 97 km de largura e 2 a 5 km de profundidade, um VCM é frequentemente esquecido nas análises meteorológicas padrão. Mas um VCM pode ganhar vida própria, persistindo por até 12 horas após a dissipação de

seu SCM de origem. Este VCM órfão às vezes se tornará o precursor do próximo surto de tempestade. Um vórtice convectivo de mesoescala de nível médio se desenvolve na região estratiforme, prolonga o SCM e pode contribuir para o desenvolvimento de ciclones tropicais (Houze, 2004). Por exemplo, um VCM que se desloca para águas tropicais, como o Golfo do México, pode servir como núcleo para uma tempestade tropical ou furacão (NOAA, 2023a). Schumacher e Rasmussen (2020) acrescentam que os SCM podem também ser do tipo sistemas convectivos quasi-linear e linhas de instabilidade. A Figura 2.9 a contribuição dos sistemas convectivos de mesoescala para precipitação total global.

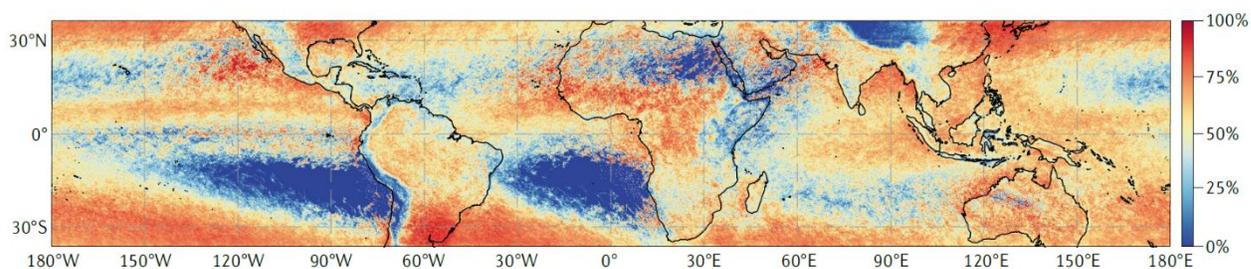


Figura 2.9: Contribuição dos sistemas convectivos de mesoescala para a precipitação total global. Fonte: (Schumacher & Rasmussen, 2020).

Os SCM também geram condições meteorológicas perigosas, incluindo chuvas extremas, inundações e, por vezes, tornados e granizo, todos com impactos económicos e sociais substanciais (Schumacher & Rasmussen, 2020). A maioria dos eventos de chuvas fortes são produzidos por fortes sistemas convectivos de mesoescala e até mesmo sistemas de microescala, como tornados. Estes sistemas geralmente ocorrem no quadrante frontal direito dos tufões que atingem a costa. Vários sistemas convectivos fortes de mesoescala podem ser gerados devido às interações entre o ar frio, a topografia e o próprio ciclone tropical. Forte convergência de camada baixa da atmosfera com vorticidade positiva (negativa) no Hemisfério Norte (Sul) e forte instabilidade potencial e divergência de fluxo de nível superior são favoráveis à gênese e ao crescimento de sistemas convectivos de mesoescala (Chen et al., 2010).

Os SCM sobre o oceano às vezes evoluem para ciclones tropicais (Houze, 2004). Galarneau et al. (2022), usaram sensores da banda do infravermelho de um satélite geostacionário para examinar os ambientes de formação de sistemas convectivos de mesoescala na região tropical global. Eles descobriram que algumas zonas de formação de sistemas convectivos de mesoescala oceânicos

coincidem com as regiões de gênese de ciclones tropicais. Schumacher & Rasmussen (2020) afirmam que uma vez que esses sistemas são impulsionados por processos convectivos húmidos profundos típicos (humidade, sustentação e instabilidade) e cisalhamento vertical do vento, a formação de SCM ocorre preferencialmente em locais onde esses ingredientes estão presentes e podem ser mantidos pela subida em grande escala e pelas piscinas frias que eles produzem. A Figura 2.10 ilustra as zonas de formação de sistemas convectivos de mesoescala e ciclones tropicais da região tropical e subtropical.

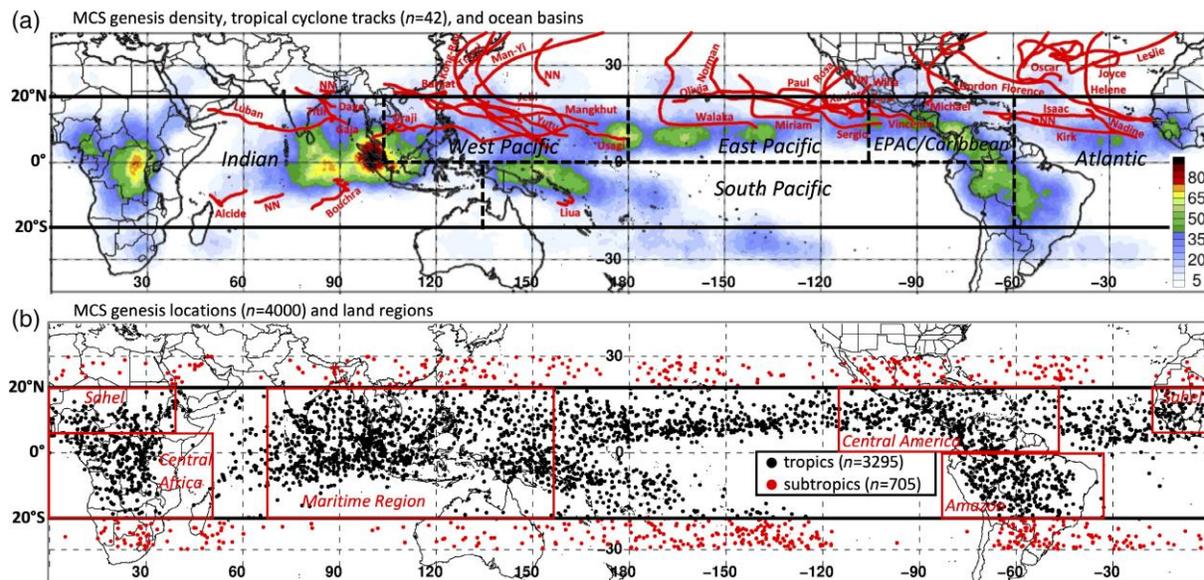


Figura 2.10: (a) Densidade de gênese do sistema convectivo de mesoescala (SCM) (sombreado em número de eventos dentro de 5 raios) e trilhas de ciclones tropicais (linhas vermelhas marcadas com o nome da tempestade) e (b) locais de gênese do SCM (círculos preenchidos em preto para trópicos e vermelhos para regiões subtropicais) de 1° de setembro de 2018 a 30 de novembro de 2018. As latitudes 20 S e 20 N limitam os trópicos neste estudo e são marcadas por um segmento de linha preta espessa. Os limites das (a) bacias oceânicas (linhas tracejadas pretas) e (b) regiões terrestres (linhas vermelhas sólidas) utilizadas neste estudo são indicados. Fonte: (Galarneau et al., 2022).

Os resultados de Galarneau et al. (2022) mostram também que os SCM ocorrem em ambientes de mesoescala que estão mais próximos da saturação através de uma camada profunda (ou seja, manchas húmidas) e que essas condições húmidas estão presentes antes da gênese do SCM. Esta descoberta é consistente com os resultados obtidos por Goyal et al. (2016).

Bister (1996) estudou os mecanismos que levam ao desenvolvimento de ciclones tropicais através de sistemas convectivos de mesoescala. Os resultados deste estudo sugerem que sistemas convectivos de mesoescala de longa duração estão relacionados a ciclogênese tropical. Mais

especificamente, a evaporação da precipitação de mesoescala que dura o suficiente e está associada a pouco cisalhamento (ou, mais geralmente, pouco fluxo relativo através da região de precipitação) pode levar à formação de um furacão.

2.4.1.5. *Camada limite*

Os processos da camada limite têm um efeito muito importante na gênese e no desenvolvimento do CT. As características das superfícies subjacentes são diferentes antes e depois da chegada do CT. As fortes chuvas induzidas por um ciclone tropical resultam em zonas húmidas saturadas, que por sua vez afectam a intensidade e a precipitação do ciclone tropical através de processos de camada limite (Li & Chen, 2007).

Li e Chen (2007) realizaram um estudo numérico sobre o impacto dos fluxos da camada limite sobre zonas húmidas na sustentação e precipitação de ciclones tropicais que atingem o continente. Os resultados mostram que a transferência vertical de fluxos na camada limite sobre áreas húmidas saturadas tem influência significativa na intensidade, estrutura e precipitação de um CT que atinge o continente. O fluxo de calor latente e o fluxo de calor sensível são ambos favoráveis para a sustentação e intensificação do CT, no qual a transferência de calor latente é mais favorável do que a transferência de calor sensível. Também são favoráveis à manutenção da estrutura espiral, e têm efeito evidente na distribuição das chuvas do CT. O fluxo de momento enfraquece significativamente os campos de vento do vórtice do CT e é o factor dominante para dissipação e enfraquecimento em um sistema de baixa pressão, enquanto aumenta a precipitação local induzida por um tufão.

Chen et al. (2021) desenvolveram um estudo sobre recuperação da camada limite e simetria da precipitação precedendo a rápida intensificação de ciclones tropicais sob cisalhamento vertical do vento utilizando simulações numéricas do tufão Mujigae (2015). Eles mostraram que a recuperação da camada limite tem um impacto positivo sobre a simetria da precipitação de ciclones tropicais, especialmente sobre as condições de temperatura da superfície do mar mais altas.

Usando múltiplas fontes de observação e simulação numérica de alta resolução, Duan et al. (2022) investigaram a influência de diferentes esquemas de parametrização da camada limite planetária

na distribuição assimétrica da precipitação do tufão Lekima (2019) antes e durante a chegada ao continente. As simulações mostraram que a distribuição da precipitação tornou-se mais simétrica mesmo à medida que se aproximava do continente, o que pode ser devido à re-intensificação antes da chegada ao continente. Estes resultados indicam que os esquemas da camada limite do modelo podem influenciar largamente a intensidade e estrutura do tufão, incluindo a distribuição assimétrica da precipitação durante a chegada ao continente.

Embora os processos de camada limite tenham influência sobre a precipitação de ciclones tropicais, Tao et al. (2011) simularam as chuvas superficiais extremamente fortes associadas ao tufão Morakot (2009) usando o modelo regional (WRF) e descobriram que os esquemas de microfísica são mais sensíveis do que as parametrizações da camada limite planetária para previsão da precipitação. Além disso, de acordo com Li & Pu (2008) os processos da camada limite também podem influenciar significativamente a intensidade de um ciclone tropical. Esta afirmação é consistente com os resultados obtidos por Li e Wang (2021), que estudaram o papel da dinâmica da camada limite na intensificação dos ciclones tropicais usando simulações numéricas. Eles perceberam que os ciclones tropicais com um coeficiente de arrasto superficial maior podem induzir um fluxo de entrada da camada limite mais forte e mais penetrado internamente e um movimento ascendente no topo da camada limite. Isto pode levar ao aumento da intensidade do ciclone tropical.

2.5. Medição da precipitação

A precipitação é definida como os produtos líquidos ou sólidos da condensação do vapor de água que cai das nuvens ou é depositado no solo. Inclui chuva, granizo, neve, orvalho, geada e neblina. A quantidade total de precipitação que atinge o solo num determinado período é expressa em termos da profundidade vertical da água até à qual cobriria uma projecção horizontal da superfície da Terra (WMO, 2012), sob a condição de não haver perdas nem por infiltração, nem por evaporação, nem por escoamento (Orgaz et al., 1995). A precipitação caída sob a forma de neve ou gelo é tratada como se estivesse fundida, e, portanto, no estado líquido (Orgaz et al., 1995; WMO, 2012). Ao fazer medição da precipitação pretende-se obter o máximo de informação sobre a quantidade de precipitação caída num dado intervalo de tempo. Pretende-se igualmente determinar a sua distribuição no tempo e no espaço (Orgaz et al., 1995).

De acordo com a Organização da Meteorológica Mundial (2012), a unidade de precipitação é a profundidade linear, geralmente em milímetros (volume/área), ou kg m^{-2} (massa/área) para precipitação líquida. A WMO recomenda que as quantidades diárias de precipitação devem ser lidas com aproximação de 0,2 mm e, se possível, com aproximação de 0,1 mm; os valores semanais ou mensais devem ser lidos com aproximação de 1 mm (pelo menos). O erro não deverá ultrapassar 2% do valor total, se este for superior a 10 mm (Orgaz et al., 1995). A taxa de precipitação (intensidade) é expressa de forma semelhante em medidas lineares por unidade de tempo, geralmente milímetros por hora (WMO, 2012).

As medições diárias de precipitação devem ser realizadas em horários fixos comuns a toda a rede ou redes de interesse. Os horários comuns de observação são de hora em hora, de três em três horas e diariamente, para fins sinópticos, climatológicos e hidrológicos, respectivamente. Para alguns propósitos, é necessária uma resolução temporal muito maior para medir taxas de precipitação muito elevadas durante períodos muito curtos. Para outras aplicações, medidores de armazenamento são usados com intervalos de observação de semanas ou meses ou até mesmo um ano, por exemplo em montanhas e desertos (WMO, 2012). Em Moçambique a precipitação acumulada de 24h é lida as 9 horas locais todos os dias.

2.5.1. Métodos de Medição

A melhoria da capacidade das previsões está intimamente ligada à capacidade de medir a precipitação. Quanto melhor for a medição da precipitação, maior será a probabilidade de melhores previsões de precipitação e outros parâmetros meteorológicos (Tapiador et al., 2011).

Dadas as múltiplas aplicações e a sua importância para as atividades humanas, o interesse e o esforço dedicados à monitorização precisa da precipitação tem crescido bastante. A crescente importância do campo, no entanto, corre paralelamente às dificuldades na medição real. A precipitação é uma variável muito difícil de estimar, tanto devido à sua ocorrência espacial irregular, como também devido a processos físicos muito diversos. Por exemplo, embora as nuvens frias e quentes eventualmente gerem precipitação, os processos que levam à formação da água líquida são bastante diferentes (Tapiador et al., 2011).

No geral, a precipitação pode ser medida ou estimada. O termo medição é usado para se referir leituras directas da precipitação, ficando assim restrito a pluviômetros e disdrômetros. A estimativa refere-se a inferir a precipitação a partir de uma medida como temperatura de brilho, momento ou refletividade. As medições e estimativa da precipitação são realizadas através de instrumentos colocados na superfície terrestre, porém os sensores presentes em satélites meteorológicos apenas podem fazer estimativa da precipitação (Tapiador et al., 2011).

2.5.1.1. Pluviômetros

Um pluviômetro ou udómetro é um instrumento meteorológico para medir a precipitação da chuva em um determinado período de tempo por unidade de área. Segundo Ahmad et al. (2017), existem dois tipos principais de pluviômetros:

- I. Pluviômetro comum ou sem registro.
- II. pluviômetro de registro ou pluviógrafo.

I. Pluviômetro simples (sem registro)

O instrumento consiste em um recipiente coletor que é colocado em uma área aberta. A precipitação é medida em termos da altura da água precipitada acumulada no recipiente num determinado tempo e é expressa em milímetros. Como se presume que a mesma quantidade de precipitação de chuva esteja ocorrendo ao redor do container, a área de coleta não é um fator. No entanto, não deve ser demasiado pequeno, nem demasiado grande. Devido à uniformidade espacial das chuvas, 1 mm de precipitação medida equivale a 1 litro de volume de água da chuva precipitada por metro quadrado (Acharya, 2017).

Há dois métodos que correntemente se usam para medir a quantidade de chuva recolhida no udómetro: com uma proveta graduada e com uma vareta graduada. O primeiro método usa-se com mais frequência para udómetros de medição diária, sendo o segundo mais frequente para os de medição semanal ou mensal (Orgaz et al., 1995). A Figura 2.11 mostra um pluviômetro que usa o método da proveja graduada.

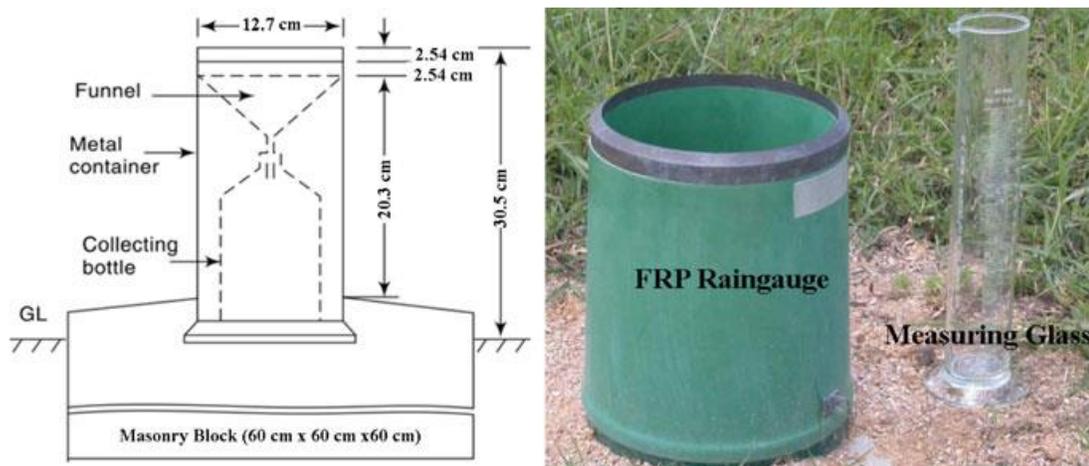


Figura 2.11: Pluviômetro de proveta graduada. Fonte: (Ahmad et al., 2017).

II. Pluviômetro de registo (pluviógrafo)

Os pluviômetros de registo mais comuns são: balde basculante, balde de pesagem e sifão natural (Ahmad et al., 2017).

a. Balde Basculante

Um pluviômetro de balde basculante consiste em um par de baldes coletores de água da chuva. É coberto por um funil, com uma área coletora aberta na parte superior onde é a área de coleta. Os baldes são colocados em um pivô de forma que apenas um balde permaneça sob o funil por vez. Durante a chuva, a água da chuva é coletada no balde coletor, através do funil. Quando a água enche até um ponto conhecido do balde, digamos com volume v , o balde tomba, esvaziando a água. Quando um balde tomba, o outro balde se move rapidamente para o lugar para coletar a água da chuva. Cada vez que um balde tomba, um sinal eletrônico é enviado para um registrador que é registrado pelo instrumento com carimbo de data/hora (Acharya, 2017). A Figura 2.12 ilustra o um pluviômetro de registo.



Figura 2.12: pluviômetro de registo de precipitação. Fonte: (Ahmad et al., 2017).

b. Tipo de balde de pesagem

Neste pluviômetro, o resíduo do funil é esvaziado em um balde montado em uma balança. Um gráfico acionado por relógio registra o peso da caçamba e seu conteúdo (Figura 2.14). Este pluviômetro fornece o gráfico da precipitação acumulada em função do tempo. Em alguns instrumentos deste tipo a unidade de registo é construída de modo que a caneta inverte a sua direcção a cada valor predefinido (20 cm) para obter um gráfico contínuo da precipitação em função do tempo. A Figura 2.13 ilustra o pluviômetro de pesagem.

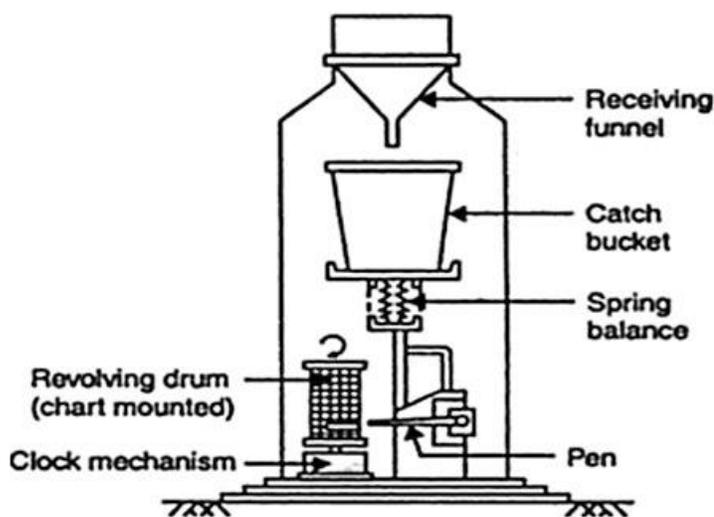


Figura 2.13: Pluviômetro de pesagem. Fonte: (Ahmad et al., 2017).

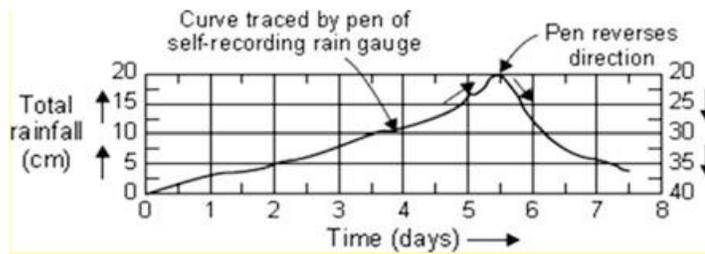


Figura 2.14: gráfico do pluviômetro de pesagem. Fonte: (Ahmad et al., 2017).

c. Pluviômetro de sifão natural

Também conhecido como pluviômetro do tipo flutuador, este pluviômetro possui uma câmara de flutuação para a qual a captura do funil é drenada. A chuva coletada faz com que a boia suba, o que inicia uma caneta para traçar o registro em um tambor giratório acionado por um mecanismo de relógio. Quando o nível máximo predefinido é atingido pela boia, um mecanismo de sifão esvazia a câmara da boia. A Figura 2.15 ilustra um pluviômetro de sifão natural.

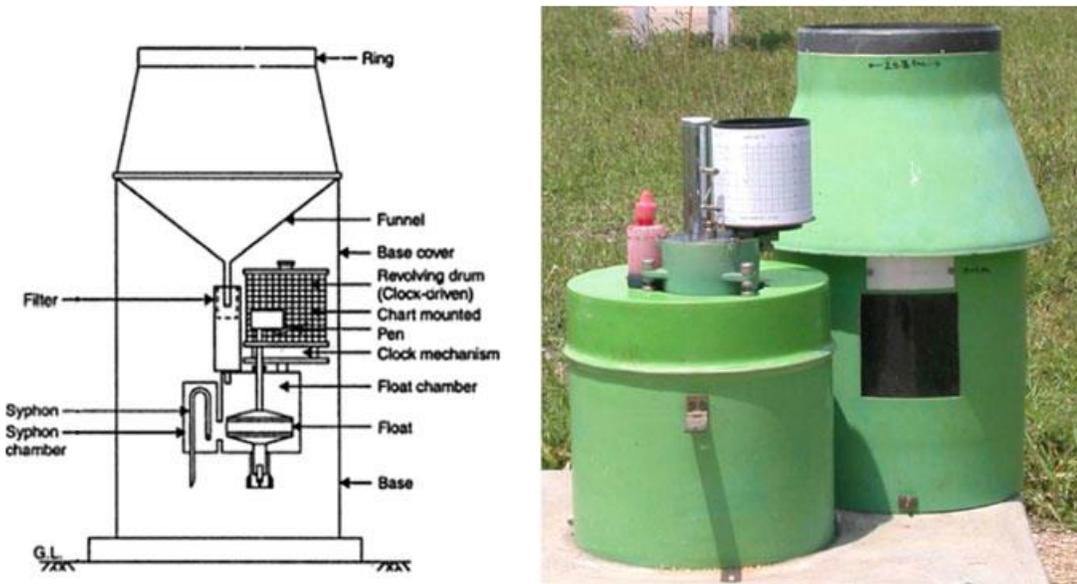


Figura 2.15: Pluviômetro de sifão natural. Fonte: (Ahmad et al., 2017).

Um gráfico típico deste tipo de pluviômetro é mostrado Figura 2.16. As linhas verticais no traço da caneta correspondem ao esvaziamento repentino da câmara da boia pela ação do sifão que repõe

a caneta no nível zero. O pluviômetro de registro do tipo sifão natural fornece um gráfico da curva de massa da chuva.



Figura 2.16: Gráfico do pluviômetro de sifão natural. Fonte: (Ahmad et al., 2017).

A principal vantagem dos pluviômetros de registro em relação ao pluviômetro comum é o registro contínuo da precipitação, além de fornecer dados sobre a intensidade e duração da chuva (Ahmad et al., 2017).

Os medidores de precipitação (ou pluviômetros, se apenas a precipitação líquida puder ser medida) são os instrumentos mais comuns usados para medir a precipitação (WMO, 2012). Os pluviômetros são universalmente considerados como fonte de dados de referência para observações de precipitação, pois fornecem um registro físico direto da precipitação em um determinado local (Tapiador et al., 2011).

2.5.1.2. Disdrômetros

Os disdrômetros são um instrumento relativamente novo que estimam não apenas a precipitação total, mas também a contribuição relativa de cada categoria de tamanho da gota (a distribuição do tamanho da gota, ou DSD - *drop size distribution*) para o total, que é um parâmetro importante para a estimativa de precipitação baseada em microondas (Tapiador et al., 2011). A Figura 2.17 ilustra um disdrômetro.



Figura 2.17: Disdrômetro. Fonte: (Acharya, 2017).

Ambos os instrumentos são directos, pois respondem a gotas individuais, mas têm uma área de amostragem bastante pequena (dezenas de centímetros quadrados), que afeta a representatividade das medições. A distribuição esparsa dos medidores torna necessária a interpolação para fornecer estimativas sobre grandes áreas. Infelizmente, a precipitação interpolada, no entanto, raramente é representativa do campo pluviométrico real (Tapiador et al., 2011). Para superar o problema da representatividade dos pluviômetros comuns e dos disdrômetros, foram desenvolvidos esquemas cada vez mais sofisticados que utilizam estimativas de precipitação por radar para preencher o vazio de amostragem.

2.5.2. Estimativa da precipitação

2.5.2.1. Estimativa por radares

A tecnologia de radar (*Radio Detection and Ranging*) foi intensamente desenvolvida para uso militar no período anterior e durante a Segunda Guerra Mundial. Durante a guerra, os operadores de radar notaram ecos nas telas dos radares causados por fenómenos meteorológicos. Após a guerra, os cientistas estudaram como usar radares para detectar precipitação. Desde então, os radares meteorológicos têm sido utilizados pelos serviços meteorológicos nacionais e instituições de investigação, uma vez que permitem a detecção de nuvens precipitantes, bem como a sua estrutura e desenvolvimento (Sokol et al., 2021).

Os radares amostram um grande volume da precipitação, mas fornecem uma estimativa da precipitação com base no eco retroespalhado, uma estimativa que se refere à precipitação total

através do DSD (Tapiador et al., 2011). Strangeways (2003), afirma que em um sistema de radar meteorológico, o prato transmite alternadamente um pulso de micro-ondas e depois muda para receber o pulso retornado (ou mais corretamente "disperso"). A partir do tempo de retorno do pulso, a distância do alvo pode ser calculada, enquanto a partir da força do sinal retornado, a refletividade da precipitação pode ser estimada. Qualquer mudança de doppler da frequência retornada estabelece a velocidade do alvo (na direção do feixe), enquanto a polarização do sinal fornece informações sobre a forma da precipitação e sua orientação.

As medições de radar da potência das ondas electromagnéticas retroespalhadas pelas gotas de chuva estão directamente relacionadas a uma quantidade física chamada reflectividade, Z . A estimativa da quantidade de chuva (intensidade da chuva, R em mm/h, ou acumulação de chuva, RA em mm) envolve o uso da reflectividade por meio de uma relação $Z - R$ (Krajewski & Smith, 2002). As estimativas da taxa de precipitação em milímetros por hora, R , são derivadas da energia retornada, ou reflectividade do radar, Z , usando uma equação empírica da forma (Strangeways, 2003):

$$Z = aR^b$$

Tanto a quanto b têm muitos valores possíveis, sendo o mais comum $a=200$, $b=1,6$. Os comprimentos de onda utilizados são geralmente 3 cm (banda X ou 10 GHz), 5 cm (banda C ou 6 GHz) e 10 cm (banda S ou 3 GHz), sendo esses comprimentos de onda espalhados principalmente por alvos do tamanho das partículas de precipitação (Strangeways, 2003).

À medida que o prato gira em 360 graus durante um período de 1 a 10 minutos, emite pulsos, cada pulso de um comprimento que abrange uma distância de cerca de 100 m, dando uma resolução de distância razoável (Strangeways, 2003). O alcance de observação pode atingir várias centenas de quilómetros dependendo da potência de emissão das microondas espectrais e da antena transmissora (Strangeways, 2003; Irwandi et al., 2019). Os tipos de radar meteorológico com base no número de antenas são divididos em 2 tipos, por exemplo, Radar MonoStatic, ou seja, Radar onde o transmissor e o receptor são instalados em uma antena, enquanto outro tipo de Radar é o Radar Bistático, onde duas antenas, por exemplo, transmissor e receptor são instalados

separadamente (Irwandi et al., 2019). A Figura 2.18 ilustra um resumo do princípio de funcionamento de um radar meteorológico. Nesta Figura o Radar é MonoStatic.

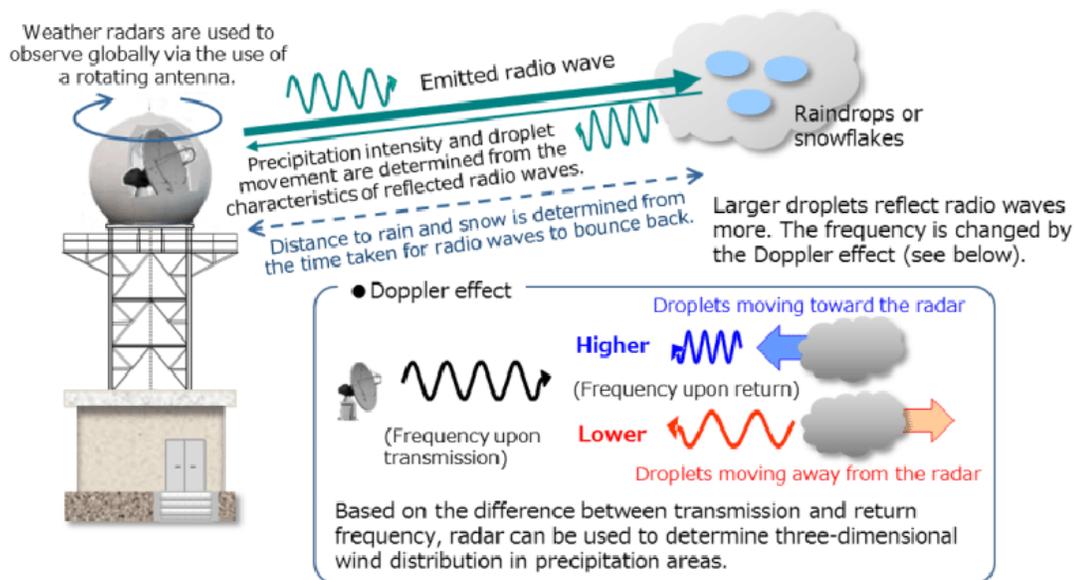


Figura 2.18: Radar meteorológico Doppler, a distância até o local da chuva é calculada a partir do tempo de percurso da onda eletromagnética desde o transmissor até retornar ao sensor. Enquanto que a intensidade da precipitação é calculada a partir da amplitude da onda refletida (a força do eco). Fonte: (Irwandi et al., 2019).

Os radares meteorológicos têm a vantagem de fornecer uma excelente resolução espacial e temporal (Strangeways, 2003), mas a principal desvantagem é que não medem a precipitação. Os radares meteorológicos apenas estimam a precipitação através da reflectividade em altitude, estando assim sujeitos a erros e limitações devido à electrónica e à topografia, e a sua cobertura pode ser inconsistente de local para local e de tempestade para tempestade (Llasat et al., 2017).

2.5.2.2. Estimativas por satélite

Sensores a bordo de satélites em órbita baixa da Terra são os únicos instrumentos capazes de obter estimativas globais e relativamente homogêneas de precipitação. Os métodos usados para derivar a precipitação a partir das radiâncias medidas pelos satélites evoluíram com o tempo, sendo possível destacar: métodos baseados no visível (VIS), no infravermelho (IR), micro-ondas ativas e passivas (MW) e abordagens mistas de IR e MW (Tapiador et al., 2011).

A lógica do método de estimativa baseada no infravermelho é que a precipitação pode ser estimada através da temperatura do topo das nuvens. Por exemplo, os topos frios das nuvens indicam um grande desenvolvimento vertical da nuvem e, portanto, mais probabilidade de chuva. No entanto, a relação entre o topo das nuvens frias e a precipitação superficial é indirecta e muitas vezes a localização das nuvens mais frias não está associada à precipitação superficial mais intensa. O problema é ainda mais complicado por sistemas de nuvens multicamadas que podem bloquear a visão da camada de nuvens que está realmente precipitando. Portanto, a principal desvantagem dos métodos IR é que a radiância medida se origina no topo das nuvens e que a ligação entre a precipitação superficial e a temperatura do topo das nuvens é indirecta (Tapiador et al., 2011).

Uma abordagem mais directa para estimar a precipitação de satélites envolve medições em frequências de micro-ondas e ondas milimétricas, aproximadamente entre as bandas $K\mu$ (10 GHz) e W (95 GHz). Dentro desta faixa espectral, partículas do tamanho de gotas de nuvens e precipitações emitem, absorvem e espalham radiação. Sensores de satélite de micro-ondas podem medir a emissão térmica líquida que emana do topo da atmosfera (técnicas de micro-ondas passivas, ou PMW) ou medir a potência retroespalhada de uma série de pulsos transmitidos (técnicas de micro-ondas ativas) (Tapiador et al., 2011).

As técnicas PMW exploram o facto de que a radiação de micro-ondas emitida pela superfície interage com constituintes atmosféricos, como vapor de água e nuvens distribuídas e partículas de precipitação. Dependendo da frequência da radiação MW, o espalhamento ou emissão domina o sinal medido pelo sensor. Assim, a medição é o sinal desejado dos constituintes atmosféricos misturado com a contribuição radiométrica da superfície terrestre. Dependendo da emissividade da superfície, a contribuição relativa do sinal afectado pelo hidrometeoro para o sinal geral recebido pode ser pequena e a emissão da superfície pode dominar, especialmente sobre a terra (Tapiador et al., 2011).

Os sensores activos de micro-ondas, funcionam como os radares meteorológicos, porém, abordo em satélites meteorológicos. Tal como os radares da superfície da terra, estes sensores presentes nos satélites emitem sinais e depois absorvem o eco gerado pelas nuvens (Tapiador et al., 2011).

2.6. Previsão da precipitação de ciclones tropicais que atingem a região continental

A chuva induzida por CT é muito importante. Portanto, há uma clara necessidade não só de compreender as suas características, mas também de melhorar as capacidades de previsão (Bagtasa, 2020), e comunicação da precipitação de ciclones tropicais (Lamers et al., 2023). A quantidade e a distribuição da chuva associada aos CT devem ser previstas com precisão dentro de um prazo razoável para garantir a protecção de vidas e bens (Fernández-Alvarez et al., 2020).

As previsões numéricas dos modelos meteorológicos foram amplamente citadas por todos os Centros Meteorológicos Regionais Especializados (CMREs) como uma fonte crítica de orientação para a previsão de chuvas de CT (Jia et al., 2022). Os modelos globais e as suas previsões de consenso, em particular, são muito utilizados, pois fornecem cobertura de bacias oceânicas inteiras, são facilmente acessíveis pela maioria dos países e podem ser correlacionados com outros parâmetros de previsão, tais como o trajectória, intensidade e tamanho do CT. As previsões de modelos globais também são mais utilizadas com prazos mais longos, especialmente além de 24 horas, quando os dados observacionais são menos relevantes e o CT está a uma distância maior da área de interesse (Lamers et al., 2023).

Os modelos de previsão numérica de tempo (PNT) não são perfeitamente correctos devido a algumas incertezas envolvidas nos processos de discretização e em escala de sub-rede (Yu et al., 2013). Vários CMREs observaram preocupações com o desempenho de modelo global para previsão de precipitação em situações específicas, particularmente com pequenas ilhas que têm topografia significativa. A baixa resolução espacial não lhes permite representar adequadamente os efeitos orográficos e o aumento da precipitação associado. Outros constrangimentos com os modelos globais incluem a representação inconsistente da convecção profunda que ocorre na parede do olho, bem como faixas de chuva externas com estruturas convectivas menores (Lamers et al., 2023).

Os modelos de alta resolução oferecem uma melhor previsibilidade da precipitação em algumas situações em que podem faltar modelos globais, e antecipam melhor os eventos de precipitação extremos e localizados dos CTs. Deve-se enfatizar que os modelos de alta resolução muitas vezes

têm um domínio limitado e, portanto, não estão disponíveis, ou estão disponíveis apenas de forma limitada, para alguns países ao redor do mundo (Lamers et al., 2023).

Os modelos de alta resolução também tendem a ter uma extensão temporal de previsão limitado e, portanto, ganham cada vez mais uso e importância na previsão de precipitação dentro de cerca de 36 a 48 horas antes a chegada do ciclone ao continente. Em particular, os modelos de alta resolução parecem ser mais valiosos quando podem explorar com precisão a estrutura da tempestade e as intensas faixas de chuva convectiva que se desenvolvem ao longo de gradientes de instabilidade ou no ar mais instável em torno da periferia de um ciclone. Isto inclui informações importantes bem no interior, à medida que um ciclone começa a decair e a perder características tropicais, mas ainda retém uma enorme quantidade de humidade profunda (Lamers et al., 2023).

2.6.1. Previsão de consenso

As técnicas de conjunto são particularmente valorizadas, para ajudar a quantificar a incerteza. Vários países, incluindo, entre outros, Índia, Austrália e EUA, relataram o uso de alguma versão de um conjunto multimodelo, incorporando dados de conjunto de uma ampla variedade de centros de modelação. A Índia e o CMRE Nova Deli, por exemplo, criam um Grande Conjunto Global, que é amplamente utilizado na previsão de chuvas. A orientação é gerada em uma plataforma GIS e usada como auxílio objectivo para previsores (Lamers et al., 2023).

Os conjuntos de modelos de alta resolução podem fornecer informações extremamente valiosas. Os modelos de alta resolução são capazes de representar com mais precisão detalhes em escala fina, mas ainda pode haver uma incerteza significativa na localização ou magnitude de uma característica específica da precipitação. Por exemplo, todos os modelos de alta resolução podem identificar correctamente o potencial de chuvas extremas numa determinada faixa de chuva externa, mas variam em 100 km na localização. Nestes casos, os conjuntos de alta resolução podem fornecer informações probabilísticas e ajudar a identificar os cenários mais prováveis e outros cenários plausíveis (Lamers et al., 2023).

O desenvolvimento contínuo de técnicas em PNT melhorou significativamente a previsão de precipitação de CTs (Jia et al., 2022). Por exemplo, combinar resultados de modelos dinâmicos e informações estatísticas em observações históricas é uma abordagem inovadora para prever

condições meteorológicas severas ou extremas. Uma questão fundamental para esta abordagem é determinar como combinar eficazmente as vantagens dos modelos dinâmicos com as informações valiosas das observações históricas (Ren et al., 2018).

Ren et al. (2018) desenvolveram um modelo de previsão da precipitação de ciclones tropicais que atingem o continente (LTP_DSEF), baseado a similaridade da trajetória. A similaridade de trajetória é determinada utilizando um índice denominado índice de área de similaridade de trajetórias de ciclones tropicais (TSAI- *tropical cyclone track similarity area index*). A Figura 2.19 ilustra o fluxograma para a determinação do TSAI.

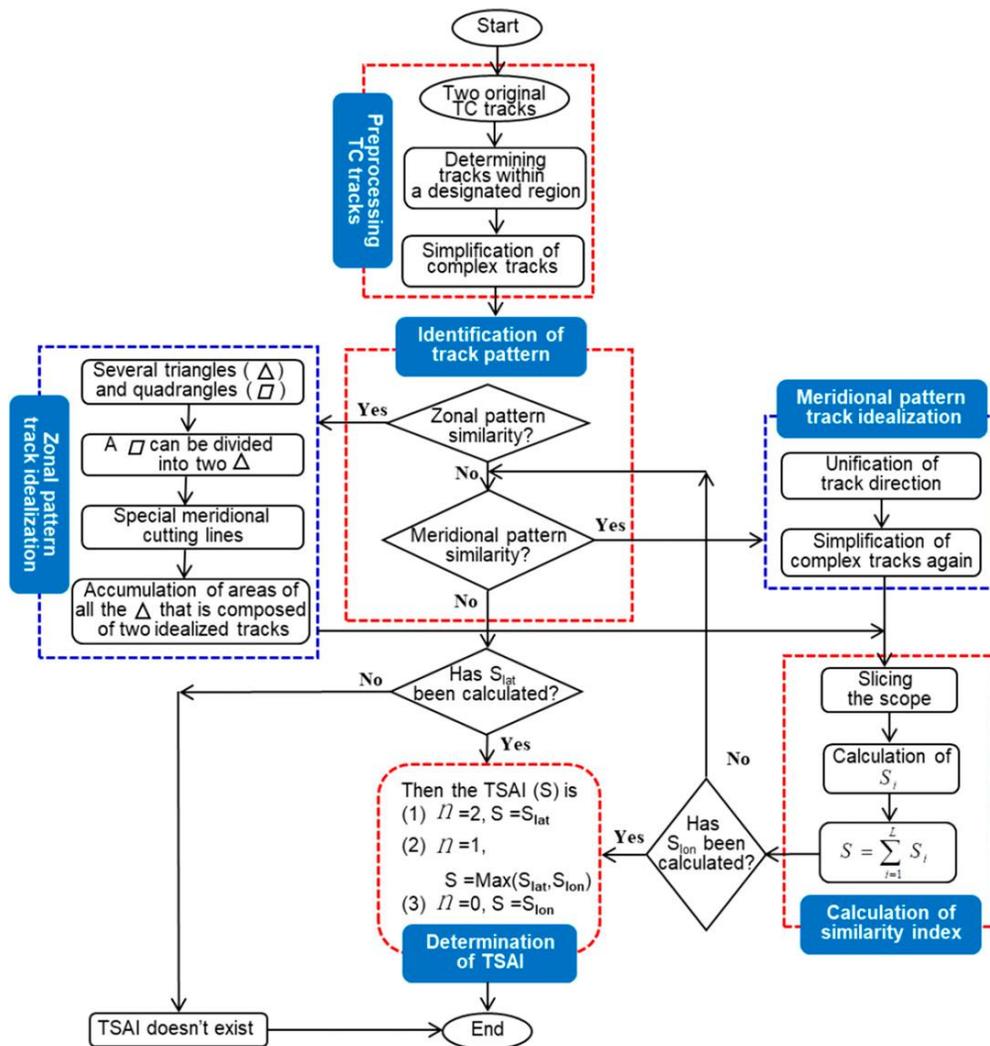


Figura 2.19: Fluxograma de cálculo de TSAI, onde S_{lat} e S_{lon} são os índices de similaridade de trajetória zonal e meridional, respectivamente; n é o número de faixas de CT cujos pontos extremos latitudinais não estão próximos dos pontos de extremidade; e L é o número de fatias do escopo. Fonte: (Ren et al., 2018).

TSAI representa uma área do escopo fechado cercada por duas trilhas TC e dois segmentos de linha conectando os pontos inicial e final das duas trilhas. Quanto menor o valor do TSAI, maior a similaridade das duas trilhas TC, onde um valor 0 indica que as duas trilhas se sobrepõem completamente. A Figura 2.20 ilustra um esquema usado para determinar o índice de similaridade de trajetória do ciclone tropical que atinge o continente.

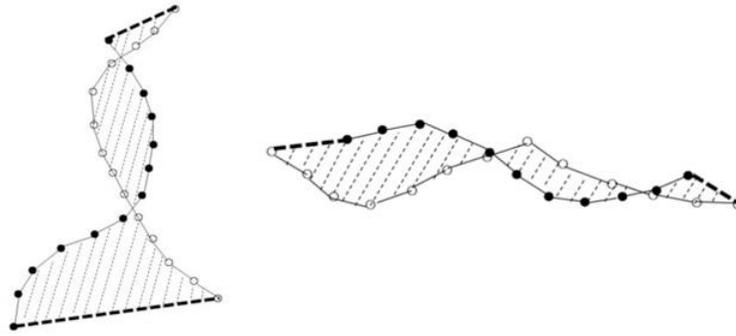


Figura 2.20: Diagrama esquemático para determinar índice de similaridade de trajetória do ciclone tropical que atinge o continente. Diagrama esquemático do escopo fechado (área sombreada) cercada por duas trajetórias de ciclones tropicais (linha pontilhada) e os dois segmentos de linha (linha quebrada espessa) que conectam os dois primeiros pontos e os dois últimos pontos das duas trajetórias do ciclone tropical para os padrões zonais meridionais (esquerda) e zonal (à direita). Fonte: (Ren et al., 2018).

A aplicação do modelo LTP_DSEF nas previsões de precipitação de CTs que atingem o Sul da China revela que o modelo é superior a três modelos numéricos de previsão meteorológica (ou seja, ECMWF, GFS e T639/China), especialmente para precipitação intensa em grandes limiares (ou seja, 100 ou 250 mm) (Ren et al., 2018). A Figura 2.21 ilustra a comparação de pontuação de ameaça (TS-Threat Score) entre diferentes modelos operacionais e o modelo LTP_DSEF.

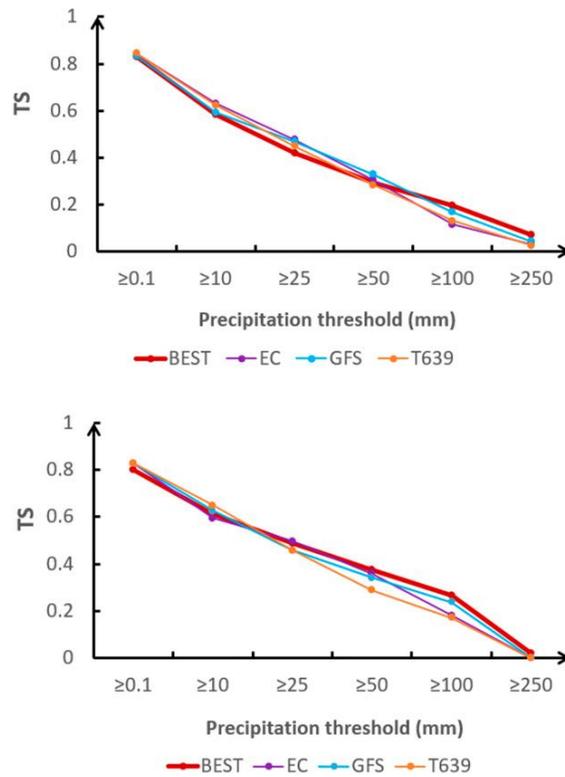


Figura 2.21: Comparação do TSS em diferentes níveis de precipitação para o melhor esquema do modelo LTP_DSEF (Best) e os três modelos dinâmicos (ECMWF, GFS e T639). Mostrados (em cima) a amostra de treinamento e (inferior) a amostra independente. Fonte: (Ren et al., 2018).

Posteriormente, Ren et al. (2020), desenvolveram um modelo de conjunto analógico-estatístico-dinâmico, denominado “*dynamical-statistical-analog ensemble forecast*” (DSAEF). A Figura 2.22 ilustra um fluxograma do modelo de previsão do conjunto de análogo dinâmico (DSAEF).

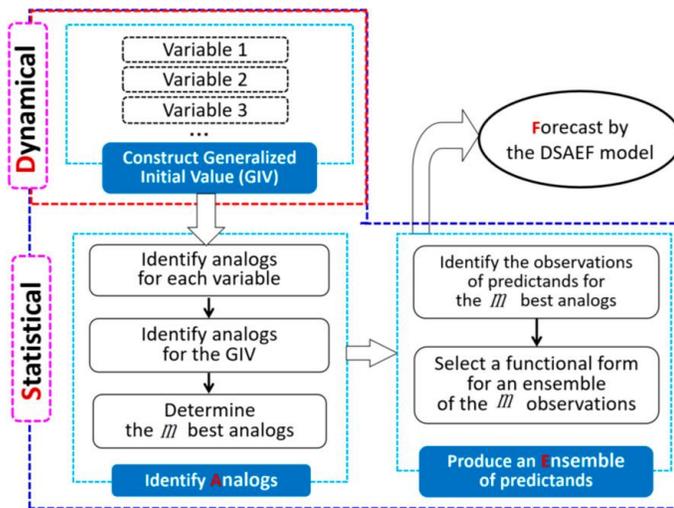


Figura 2.22: Fluxograma do modelo de previsão do conjunto de análogo dinâmico (DSAEF). Fonte: (Ren et al., 2020).

Este modelo baseia-se tanto em observações históricas assim como em simulações numéricas. O modelo foi usado para a previsão da precipitação de ciclones tropicais que atingem o continente (LTC – *Landfalling Tropical Cyclone*), tomando a designação DSAEF_LTP (Ren et al., 2020), tal como mostra o fluxograma da Figura 2.23.

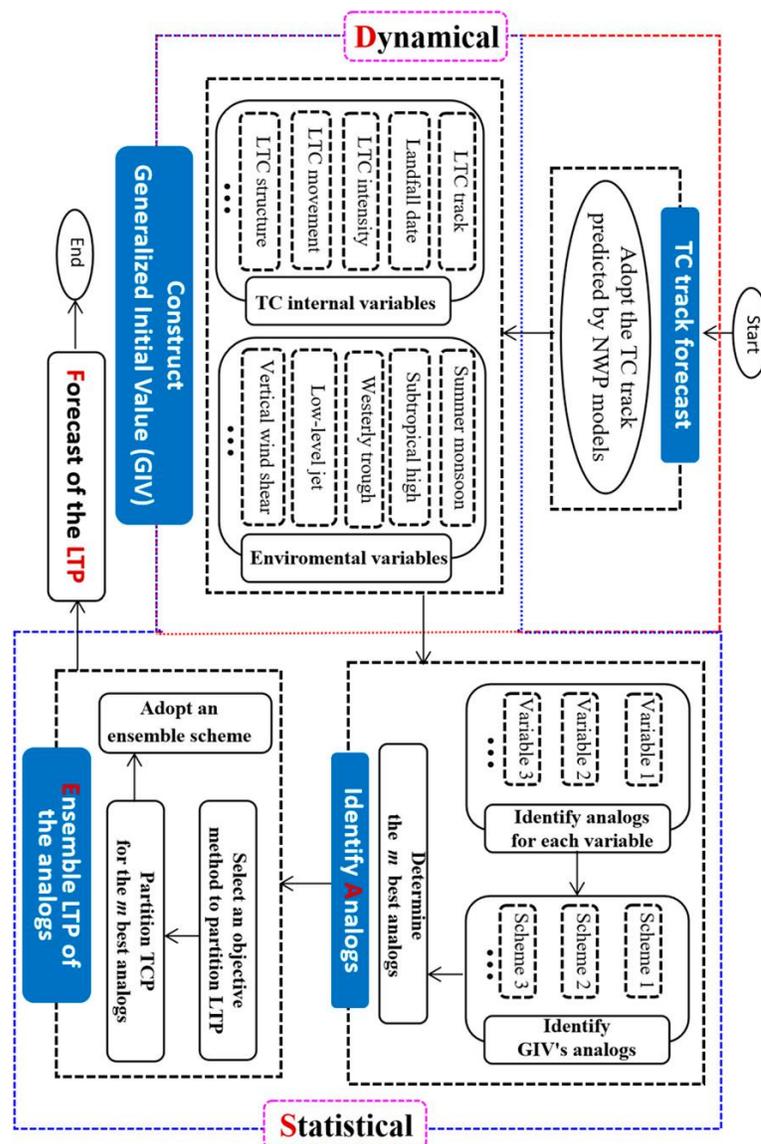


Figura 2.23: Fluxograma do modelo DSAEF para prever a precipitação de ciclones tropicais que (LTP) (abreviada como modelo DSAEF_LTP). Fonte: (Ren et al., 2020).

Este modelo procura CTs que sejam semelhantes a um CT alvo de acordo com a similaridade do valor inicial generalizado (GIV) que contém o valor de alguns fatores que afetam a precipitação do CT. A palavra “generalizado” significa que estão incluídos tanto o valor observado antes do tempo de previsão (tempo inicial) quanto o valor previsto após o tempo inicial. Então, os dados de precipitação acumulada de CTs que são semelhantes ao CT alvo são tratados como uma previsão de consenso da precipitação para o CT alvo. A estação da trajetória e chegada do CT ao continente são consideradas os dois fatores principais na primeira versão do modelo DSAEF_LTP (Jia et al.,

2022). O modelo DSAEF_LTP foi testado usando 21 tufões que atingiram o Sul da China. Os resultados mostraram que o modelo tem melhor desempenho quando são considerados a trajetória dos tufões e o período de chegada ao continente como valor inicial generalizado (GIV), do que quando é considerado apenas as trajetórias dos tufões. Este modelo provou ter um desempenho da previsão comparável aos modelos numéricos operacionais de previsão do tempo usados atualmente na China, nos Estados Unidos e na Europa (Ren et al., 2020). A Figura 2.24 ilustra a comparação de pontuação de ameaça (TS-Threat Score) entre diferentes modelos operacionais e o modelo DSAEF_LTP.

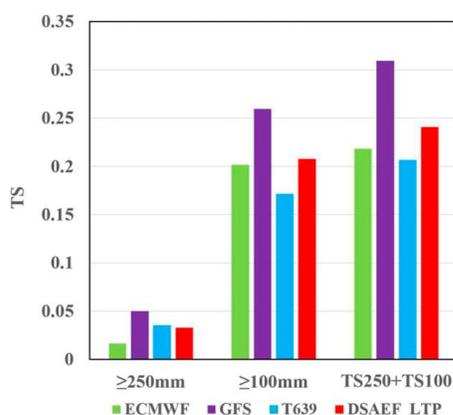


Figura 2.24: Comparação de pontuação de ameaças (TS - Threat Scores) para prever precipitação intensa acumulada (≥ 250 e $\geq 100mm$) pelo modelo DSAEF_LTP e pelos três modelos PNT (ou seja, ECMWF, GFS e T639) para a amostra independente de anos 2014-16. Figura: (Ren et al., 2020).

Embora a primeira versão do modelo DSAEF_LTP tenha mostrado um desempenho relativamente satisfatório, este modelo tinha a limitação de apenas envolver duas variáveis de similaridade (ou seja, trajetória do TC e a tempo de *landfall*). Porém Ren et al. (2020), notaram que o aumento de variáveis relevantes ao GIV, pode melhorar a capacidade de previsão do modelo proposto. Nesse contexto, Ding et al. (2020) introduziram a intensidade do ciclone tropical na previsão de conjunto dinâmico-estatístico-análogo (DSAEF) para o modelo de precipitação do tufão (ou ciclone tropical) (DSAEF_LTP). Os autores notaram que as previsões de chuvas de ciclones tropicais do modelo melhoraram com a introdução da intensidade do ciclone tropical. A melhoria foi de aproximadamente 8,64% (experimento de treinamento) e 9,15% (experimento independente) com a introdução da intensidade. A Figura 2.25 ilustra a comparação da pontuação média de ameaça dos DSAEF_LTP-2, DSAEF_LTP-3 e os três modelos de PNT. Os modelos DSAEF_LTP-2 e

DSAEF_LTP-3 representam o modelo DSAEF_LTP com duas (sem intensidade), correspondente a primeira versão do modelo desenvolvido por (Ren et al., 2020), e três (com intensidade) variáveis, que é o actual modelo, respectivamente.

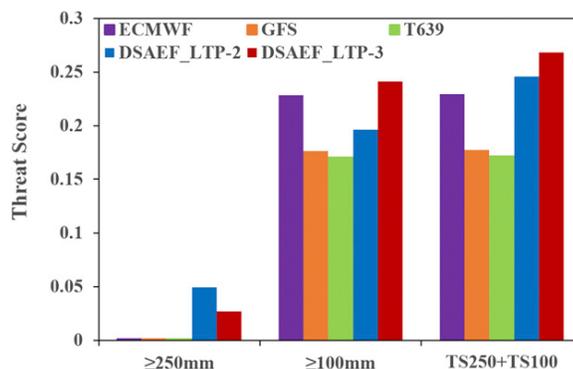


Figura 2.25: Comparação de pontuações de ameaças de diferentes modelos (ECMWF, GFS, T639, DSAEF_LTP-2 e DSAEF_LTP-3) para amostras independentes. Fonte: (Ding et al., 2020).

Além disso, Ding et al. (2020) perceberam que a seleção de ciclones tropicais analógicos com uma intensidade máxima (durante a precipitação sobre a terra) igual a ou superior à intensidade inicial do ciclone tropical alvo fornece melhores previsões. A precisão da previsão para a precipitação acumulada é maior para ciclones tropicais com maior intensidade e maior precipitação observada. Jia et al. (2020) também introduziram a intensidade no valor inicial generalizado (GIV) do modelo DSAEF_LTP para simular a precipitação do supertufão Lekima (2019). Os resultados obtidos por Jia et al. (2020) são consistentes com os resultados obtidos por Ding et al. (2020). Jia et al. (2020) também notaram uma melhoria na capacidade do DSAEF_LTP em prever chuvas fortes (ou seja, precipitação acumulada excedendo os limites de 250 e 100 mm) associadas ao tufão Lekima. Porém, a sua pontuação de ameaça (TS) ocupa o segundo lugar em comparação com três modelos numéricos de previsão meteorológica (ou seja, ECMWF, GRAPES e GFS). A Figura 2.26 ilustra as pontuações de ameaça obtidas nas simulações do tufão Lekima.

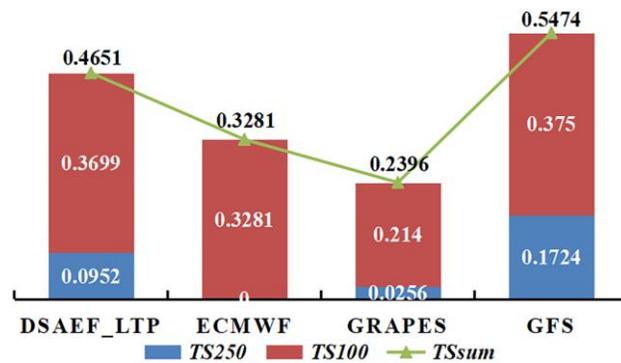


Figura 2.26: Pontuações de ameaça (TS250, TS100 e TSum) do melhor esquema do modelo DSAEF_LTP com similaridade de intensidade, comparado com os dos três modelos dinâmicos (ou seja, ECMWF, GRAPES e GFS), associados ao Lekima. Fonte: (Jia et al., 2020).

Jia et al. (2020) descobriram que existem três factores impediram o modelo DSAEF_LTP de alcançar resultados mais satisfatórios para o tufão Lekima: a ocorrência historicamente rara de precipitação extrema no Norte da China durante Lekima, o aumento do erro de trajecto de previsão quando Lekima se moveu para Norte, e o cálculo da similaridade entre trajectos de Lekima e TCs históricos dentro de uma região imprópria (ou seja, região de similaridade). Para resolver o terceiro problema, foram adotados novos esquemas de regiões de similaridade, que resultaram no aumento do desempenho do modelo.

Estes estudos fizeram um progresso importante na pesquisa sobre a combinação de previsões dinâmicas com os análogos da condição inicial de observações históricas para a previsão de eventos de precipitação associados aos ciclones tropicais que atingem o continente. Porém, de acordo com Jia et al. (2022), nos estudos anteriores (por exemplo, Ding et al., 2020; Jia et al., 2020; Ren et al., 2020) a previsão de consenso é a tecnologia chave do modelo DSAEF_LTP porque determina o desempenho da previsão quando TCs semelhantes são selecionados. No entanto, este modelo contém apenas métodos de conjunto médio e máximo, que apresentam suas desvantagens em termos de altas taxas de erros e alarmes falsos, respectivamente. Além disso, a maior precipitação prevista que uma determinada estação pode atingir é a precipitação máxima histórica de TC da estação.

Para superar as deficiências e melhorar o desempenho de previsão do modelo DSAEF_LTP, Jia et al. (2022) incorporaram novos métodos de consenso para modelo. Experimentos realizados mostraram que o modelo DSAEF_LTP melhorado, apresenta um bom desempenho, principalmente

para a previsão da precipitação acumulada superior a 250 mm. Existem vários estudos relacionados a previsão da precipitação de ciclones tropicais usando o modelo dinâmico-estatístico-análogo, por exemplo, (Qin et al., 2022; Ma et al., 2022a; Ma et al., 2022b; Jiang et al., 2023), que podem ser consultados para mais informações.

2.6.2. Papel da assimilação de dados na previsão da precipitação de ciclones tropicais

O esquema de assimilação² de dados tem sido apontado como um dos factores que também pode melhorar as previsões da precipitação de ciclones tropicais. Segundo Barker D. M. et al. (2004), os sistemas modernos de assimilação de dados de previsão numérica do tempo (PNT) utilizam informações de uma variedade de fontes para fornecer uma melhor estimativa do estado atmosférico em um determinado momento. As fontes de informação utilizadas para produzir a análise incluem observações, previsões anteriores (o histórico ou estado inicial), seus respectivos erros e as leis da física (Barker D. et al., 2003). As estimativas de variáveis atmosféricas provenientes de sistemas de observação (incompletos e imperfeitos) podem ser complementadas com informações de previsões anteriores (o estado anterior ou primeira estimativa), estatísticas detalhadas de erros e as leis da física (Barker D. M. et al., 2004). A assimilação de dados é usada para fornecer as condições iniciais para os modelos de previsão numérica de tempo (Barker D. et al., 2003).

Xiao et al. (2007) desenvolveram um esquema de assimilação de dados baseados no sistema de assimilação de dados variacionais tridimensionais (3DVAR) de refletividade de radar para o modelo *Pennsylvania State University – National Center for Atmospheric Research Mesoscale Model* (MM5). Eles descobriram que a melhoria no sistema de 3DVAR assimilação de dados resultou na melhoria da habilidade do modelo em fazer previsão quantitativa da precipitação associada aos ciclones tropicais. Zhao et al. (2012) utilizaram o sistema 3DVAR para assimilar dados de velocidade radial e refletividade de oito radares no modelo ARPS para simular o tufão Meranti. A assimilação mostrou que os dados da velocidade radial levam a uma melhoria maior nas previsões de intensidade e trajectória do que os dados de reflectividade, enquanto dados de reflectividade adicionais melhoram a previsão de precipitação de ciclones tropicais que atingem o

² Assimilação refere-se ao processo de integração de dados observacionais ao modelo de previsão do tempo, a fim de melhorar as condições iniciais para a previsão. Isso pode incluir dados de estações meteorológicas, satélites, radares e outras fontes.

continente. Eles também notaram que as previsões usando múltiplos radares ainda são as melhores do que quando é usado apenas um radar doppler. Usando uma versão de Pesquisa Avançada do Modelo de Pesquisa e Previsão do Tempo (WRF), Zhang e Pu (2014) descobriram que a assimilação da superfície oceânica e superfície terrestre resulta em melhorias significativas nas previsões quantitativas de precipitação (PQP) de ciclones tropicais durante a chegada o landfall. Zhu et al. (2016) utilizaram o filtro de Kalman como técnica de assimilação de dados do modelo WRF. Os resultados das simulações são consistentes com os resultados obtidos por Zhang e Pu (2014).

Além do esquema de assimilação de dados, vários autores investigaram a importância das parametrizações³ na previsão da precipitação em ciclones tropicais (Ma & Tan, 2009; Yu et al., 2013; Shi & Wang, 2022). Por exemplo, Ma e Tan (2009), observaram que para cada esquema de parametrização de nuvens, a percentagem de precipitação na escala da sub-rede varia substancialmente para diferentes casos de ciclone tropical, o que implica que o comportamento do esquema de parametrização em simulações de precipitação pode estar intimamente associado a características específicas do ciclone tropical. Com base no esquema de Kain–Fritsch, Yu et al. (2013) utilizaram o modelo WRF para melhorar a previsão quantitativa de precipitação (PQP). As simulações mostraram que o desempenho do modelo WRF foi maximizado em termos da habilidade de PQP para o caso de tufão Rusa (2002). Usando o modelo WRF para simular ciclone vicente (2012), Shi e Wang (2022) descobriram que a simulação que combina os esquemas MSKF e RNA para parametrização de cumulus, apresenta a melhor habilidade na previsão de precipitação, especialmente extremos de precipitação. Mahoney (2016), estudou o impacto da convecção explícita e convecção parametrizada na previsão da precipitação. O autor notou que a versão atualizada do esquema de parametrização Kain-Fritsch reduzia os erros de previsão da precipitação. Por outro lado, Gao et al. (2017) notaram que as parametrizações realizadas em modelos de alta resolução apresentavam melhores previsões da precipitação. Este estudo sugere que embora um esquema de parametrização adequado possa ser importante, a resolução do modelo é também um determinante para a qualidade das previsões.

³ A **parametrização** em modelos de previsão do tempo refere-se ao processo de representação de processos em escala de sub-rede, como formação de nuvens, turbulência e precipitação, usando equações matemáticas simplificadas. Estas parametrizações são necessárias porque a resolução dos modelos de previsão do tempo não é alta o suficiente para resolver diretamente estes processos de pequena escala.

2.6.3. Previsão da precipitação de ciclones tropicais com base em inteligência artificial

Nos últimos anos, a Inteligência Artificial (IA) apresentou grandes progressos e tem sido aplicado em diversas áreas da ciência (Liu Y.-y. et al., 2019). Um dos ramos da inteligência artificial é o aprendizado de máquina (*Machine Learning* - ML) (LeCun et al., 2015; Liu Y.-Y. et al., 2021). Como um ramo da IA, o ML pode ser entendido como algoritmos que permitem aos computadores aprender regras a partir de *big data*, de modo a completar as tarefas que são tradicionalmente realizadas por seres humanos. O núcleo essencial do ML é usar algoritmos para analisar dados, aprender com os dados e então tomar decisões ou previsões sobre algo no mundo realista (Liu Y.-Y. et al., 2021).

Como forma de superar limitações actualmente existentes na previsão numérica de tempo, Liu Y.-Y. et al. (2021) propuseram um novo método de identificação de análogos combinando o aprendizado de máquina com a previsão numérica de tempo para estimar a precipitação de ciclones tropicais. Os resultados mostraram que a previsão do método proposto apresentou uma melhoria significativa em comparação com os resultados de previsão fornecidos pela produção direta da PNT. Com base em aprendizado de máquina, Lockwood et al. (2023) desenvolveram um modelo de previsão da precipitação de ciclones tropicais sobre o oceano Atlântico Norte. O modelo mostrou melhoria na precisão da modelagem da precipitação total horária. Ficchi et al. (2024), desenvolveram um modelo baseado em aprendizado de máquina para reduzir os vieses locais das previsões de precipitação dos CTs e ajustar a distribuição espacial de chuvas extremas.

As redes neurais artificiais (RNAs) provaram ser muito bem-sucedidas no tratamento de problemas altamente complicados. Devido à sua poderosa capacidade de modelar sistemas não lineares sem a necessidade de fazer quaisquer suposições, as RNAs têm encontrado aplicações crescentes para modelagem de processos hidrológicos (Lin & Wu, 2009).

Lin & Chen (2005), desenvolveram uma rede neural artificial (RNA⁴) para prever chuvas de tufões em Taiwan. A configuração do modelo é avaliada utilizando oito características do tufão. Este modelo foi testado usando os tufões Herb e Nelson, onde foi concluído que a precipitação pode ser

⁴ **Redes neurais artificiais** (RNA) são um tipo de modelo de aprendizado de máquina inspirado na estrutura e função do cérebro humano. Eles consistem em nós interconectados, ou “neurônios”, organizados em camadas. Cada neurônio recebe uma entrada, processa-a e então passa a saída para a próxima camada de neurônios. Através de um processo de treinamento, a rede aprende a reconhecer padrões e a fazer previsões com base nos dados de entrada.

bem prevista pelo modelo RNA quando as características do tufão e a informação espacial apropriada da precipitação são usadas como entradas para o modelo. Estes resultados são consistentes com os resultados obtidos por Lin G.-F et al., (2009), que usaram máquinas de vetores de suporte, que são um tipo de redes neurais artificiais (RNAs), construíram um modelo de previsão de chuvas de tufões por hora. Estes autores notaram que o modelo baseado em SVMs tinha melhor desempenho do que os modelos convencionais baseados em redes de retropropagação (BPNs). Além disso, Lin G.-F et al., (2009), notaram uma melhoria das previsões da precipitação induzida por tufões quando adicionavam as características dos tufões. Porém, Lin & Chen (2005), alertam que demasiada informação espacial não pode melhorar a capacidade de generalização do modelo, porque a inclusão de informação irrelevante adiciona ruído à rede e prejudica o desempenho da rede neural.

Para melhorar o modelo de redes neurais artificial convencional, que é baseado em redes de retropropagação (BPNs) (Lin G.-F. et al., 2009), Lin & Wu (2009) combinaram dois tipos diferentes de redes neurais artificiais, o mapa auto-organizado (SOM - *self-organizing map*) e a rede perceptron multicamadas (MLPN - *multilayer perceptron network*), para desenvolver o modelo de rede neural híbrida. As simulações mostraram que esta configuração de modelo permite que as previsões tenham maior precisão em relação a abordagem de redes neurais convencionais. Para mais informações, existem vários outros estudos que também investigaram o uso da inteligência artificial para prever a precipitação induzida por ciclones tropicais, por exemplo (Lin et al., 2013; Lin & Jhong, 2015; Chen et al., 2020; Wang et al., 2022).

2.7. Impactos da precipitação de ciclones tropicais

2.7.1. Impactos negativos

Eventos de chuvas fortes, tipicamente associados a ciclones tropicais (CTs), provocam inundações intensas, causando conseqüentemente graves perdas de vidas e propriedades (Fernández-Alvarez et al., 2020). A maior parte dos danos do CT é causada por inundações e deslizamentos de terra devido a fortes precipitações (Wu & Chen, 2012). A severidade das cheias está intrinsecamente ligada à intensidade, duração e total do evento das chuvas (Jaffrés & Gray, 2023). O grau de impacto sobre os seres humanos pode variar de acordo com as diferenças de uso da terra (Villarini et al., 2014), quantidade de bens expostos (Mendelsohn et al., 2012), o número de pessoas e seu

nível de vulnerabilidade, bem como da frequência e intensidade das tempestades (Peduzzi et al., 2012).

Algumas características dos ciclones tropicais incluem ventos extremos, chuvas torrenciais que provocam inundações e/ou deslizamentos de terra, ondas altas e tempestades prejudiciais que levam a extensas inundações costeiras (Peduzzi et al., 2012). Porém, vários autores acreditam que a precipitação é a variável mais importante no estudo dos impactos dos ciclones tropicais devido a sua forte relação com as inundações. As inundações são apontadas como a razão das maiores perdas de vida ligados aos ciclones tropicais (Rappaport, 2000). Porém, de acordo com Liu et al. (2022), as condições de humidade anteriores a ocorrência da precipitação dos ciclones tropicais, podem exacerbar as inundações resultantes.

Na tentativa de perceber os impactos da precipitação dos ciclones tropicais, Villarini et al. (2014) concentraram-se nas inundações no território continental dos Estados Unidos associadas às CT do Atlântico Norte. Eles mostraram que os ciclones tropicais são responsáveis por grandes inundações no leste dos Estados Unidos, região central e alguns pontos do extremo Norte do país. Isto contrasta com as tempestades e os danos causados pelo vento resultantes dos CTs, que são fenómenos bastante localizados que afectam áreas limitadas que estão concentradas perto do local de entrada no continente. Hu et al., (2018) investigaram a mortalidade induzida pelas inundações ao redor do mundo. Eles notaram que os ciclones tropicais estão intimamente relacionados com a mortalidade induzida pelas cheias em partes dos países ao longo da costa ocidental dos oceanos. A frequência das inundações dos canais nestas regiões é a maior e mais importante proporção de mortes induzidas pelas inundações e a maior mortalidade induzida pelas inundações pode ser atribuída às inundações repentinas induzidas pelo CT. Estes resultados são consistentes com as descobertas obtidas por Rappaport (2000), que investigou a perda de vida nos Estados Unidos associada a ocorrência de ciclones tropicais na bacia do Atlântico Norte. A Figura 2.27 ilustra as relações espaciais entre ciclones tropicais e mortalidade.

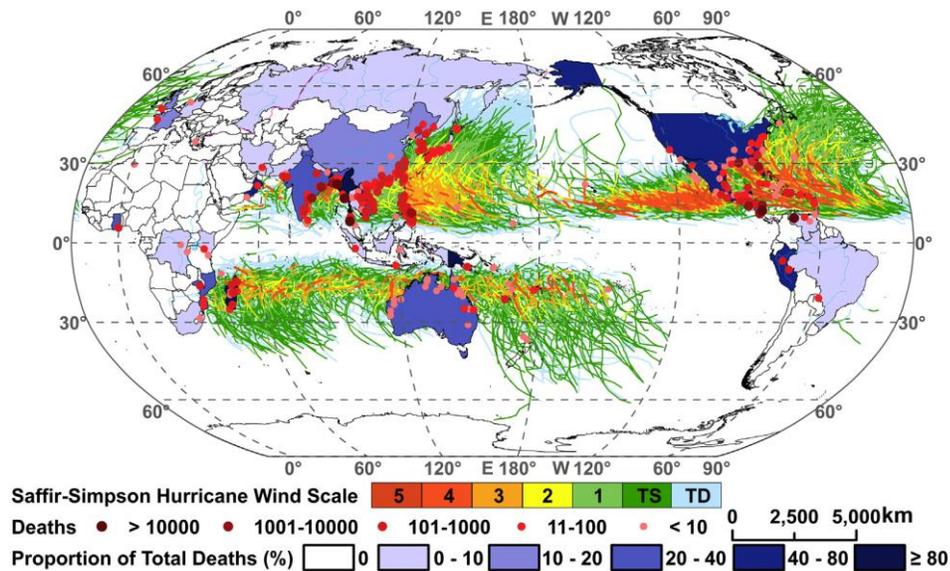


Figura 2.27: Conexões espaciais entre trajetórias de ciclones tropicais de diferentes intensidades e mortes induzidas por inundações causadas por ciclones tropicais, a proporção de mortes induzidas por inundações causadas por ciclones tropicais no total de mortes causadas por todos os tipos de inundações. Fonte: (Hu et al., 2018).

Em geral, para Hu et al., (2018), a intensidade dos ciclones tropicais no hemisfério Sul é menor do que no hemisfério Norte, por isso os eventos de inundação e a mortalidade foram relativamente pequenos em número. Ou seja, estes autores acreditam que a intensidade dos ciclones tropicais tem influência sobre a sua capacidade destes eventos em gerar inundações, resultando no seu efeito sobre a mortalidade. Liu et al. (2022) apontam que só para a Carolina do Norte, o ciclone Matthew causou aproximadamente 4,5 mil milhões de dólares em perdas económicas, enquanto Florence superou isso com 17 mil milhões de dólares. A principal causa dos danos devastadores são as inundações resultantes das chuvas desse ciclone tropical. A transição extratropical, o efeito orográfico e o transporte de humidade são apontados como os principais factores que influenciaram as chuvas extremas associadas ao ciclone Matthew. Kurniawan et al. (2021) estudaram o impacto do ciclone Seroja na chuva e altura das ondas a leste de Nusa Tenggara. Eles descobriram que a precipitação extrema associada ao Seroja foi responsável por grandes inundações que ocorreram na região. Além disso, este ciclone provocou ondas de até 7 metros de altura num intervalo de 6 dias. Jonkman et al. (2009) investigaram as perdas de vida associadas ao ciclone Katrina (2005). Este estudo revelou que além da morte directa por inundações associada a chuvas de ciclones

tropicais (afogamentos), existem impactos adversos à saúde pública que ocorreram depois das cheias. Estes impactos são também considerados como resultantes das chuvas de ciclones tropicais.

Bousquet et al. (2019), afirma que embora a actividade de CT no sudoeste do oceano Índico (SOI) seja geralmente mais fraca em comparação com a de várias outras bacias (Noroeste e Nordeste do Pacífico, Atlântico Norte), grandes tempestades causam regularmente perdas sociais e económicas consideráveis em países africanos vulneráveis, como Moçambique e Madagáscar. Assim, nos últimos 19 anos, os CT causaram pelo menos 20 mortes em cada temporada na área SOI, com mais de 100 mortes em oito temporadas¹ – as duas temporadas mais precoces (e mais dispendiosas) ocorreram em 2016–2017 (mais de 350 mortes e perdas económicas de cerca de 200 milhões de euros em Moçambique e Madagáscar após a chegada dos CT Dineo e Enawo) e 2018–2019 (onde só o CT Idai causou cerca de 1.000 mortes em Moçambique em Março de 2019).

Peduzzi et al. (2012) acreditam que o risco de mortalidade por ciclone tropical depende da intensidade dos ciclones tropicais, da exposição, dos níveis de pobreza e da governação. Apesar da redução prevista na frequência dos ciclones tropicais, espera-se que os aumentos previstos tanto na pressão demográfica como na intensidade dos ciclones tropicais ao longo dos próximos 20 anos aumentem grandemente o número de pessoas expostas por ano e exacerbem o risco de desastres, apesar da potencial progressão no desenvolvimento e governança (Peduzzi et al., 2012).

2.7.2. Impactos positivos

Apesar dos seus impactos negativos sobre as propriedades e vidas humanas, a precipitação induzida pelos ciclones tropicais pode trazer alguns benefícios. Por exemplo, de acordo com Pérez-Alarcón et al. (2023) o facto de os ciclones tropicais necessitarem de grandes quantidades de humidade para a sua gênese e desenvolvimento, tornam estes sistemas importantes condutores de humidade do oceano para a terra e das regiões tropicais para subtropicais e extratropicais. Portanto, os ciclones tropicais são uma importante fonte de água em muitas regiões do mundo, reabastecendo barragens locais, cursos de água e sistemas de águas subterrâneas (Jaffrés & Gray, 2023).

A precipitação induzida por ciclone tropical nas Filipinas foi investigada por Bagtasa (2017), onde usaram uma combinação de observações terrestres e de satélite para produzir um conjunto combinado de dados de precipitação de 64 anos. Considerou-se como precipitação induzida por

ciclone tropical aquela que ocorreu até 10° (~1110 km) do centro do ciclone. Foi concluído que a precipitação de ciclones tropicais contribui com até 54% da chuva sobre o Norte das Filipinas. Ao estudar a contribuição dos ciclones tropicais para a vazão sobre o sudeste e centro-sul dos Estados Unidos, Chalise et al. (2021) descobriram que os TCs respondem por 12% da vazão sazonal e 6% da precipitação sazonal sobre os Estados Unidos da América. Porém algumas regiões, como Flórida, Carolina do Norte e Louisiana, têm a maior ocorrência fracionária de precipitação máxima anual gerada por CT (~20%–32%) e vazão (~15%–27%).

2.8. Ciclones tropicais mais recentes que fizeram o *landfall* o Moçambique

Após a ocorrência do ciclone Jokwe em 2008, Moçambique ficou 9 anos sem ser atingido por ciclones tropicais. Porém, a partir do ano 2017 Moçambique observou uma frequência de ciclones tropicais sem precedentes. De acordo com Tinga (2023), os ciclones tropicais que fazem *landfall* em Moçambique contribuem com até 450 mm de precipitação por época ciclónica, afectando maioritariamente as regiões centro e litoral do país. Essa precipitação corresponde a 45% da média total. Portanto, são nesta pesquisa são considerados como ciclones tropicais mais recentes os que ocorreram desde 2017 a 2023. A Tabela 2.2 apresenta a lista de ciclones tropicais que atingiram Moçambique no intervalo de 2017 a 2023.

Tabela 2.2: *Ciclones tropicais que fizeram landfall em Moçambique entre 2017 e 2023.*

Ciclones tropicais	Ano
Dineo	2017
Idai	2019
Kenneth	2019
Chalane	2020
Eloise	2021
Ana	2022
Gombe	2022
Ciclone Freddy	2023

O ciclone Dineo formou-se no dia 12 de Fevereiro e tingiu o Sul de Moçambique em 15 de Fevereiro de 2017. Foi o primeiro ciclone tropical a atingir Moçambique desde o ciclone Jokwe em 2008. Atingiu o seu pico de força de 129,6 km/h (pico dentro do estatuto de TC) em 15 de Fevereiro, dia em que atingiu o Sul de Moçambique (Inhambane). No local do *landfall* do ciclone

Dineo em Moçambique não havia dados directos da medição da precipitação, porém estimativa por satélites indicavam que a precipitação estava entre 100 a 200 mm. No distrito do vilanculos foi registada uma precipitação de 110 mm (South African Weather Service, 2017). Este sistema enfraqueceu para um mínimo remanescente em 17 de Fevereiro, antes de atingir o Botswana e causar fortes chuvas que resultaram em inundações, especialmente na metade oriental do país, antes de se dissipar. O ciclone Dineo se dissipou no dia 19 de Fevereiro (Moses & Ramotonto, 2018).

Dois anos mais tarde (2019), Moçambique foi atingida por dois ciclones tropicais consecutivos. Em Março, Moçambique foi atingido pelo Ciclone Tropical Idai, que ocorreu em três fases: no início de Março, o sistema de baixa pressão causou inundações no Malawi e nas províncias da Zambézia e Tete, em Moçambique; no dia 14 de Março, o ciclone Idai atingiu a costa perto da cidade portuária da Beira, destruindo telhados de casas e edifícios; finalmente, durante o fim de semana de 16 a 17 de Março, o sistema meteorológico provocou chuvas torrenciais em diversas áreas de Moçambique – deixando 3.000 km² de terra submersos e deixando pessoas presas em casas e árvores. (OCHA, 2019; USAID, 2019). A precipitação na cidade excedeu 200 mm, enquanto os totais mais fortes de mais de 600 mm caíram perto de Chimoio (DG ECHO, 2019).

O ciclone tropical Kenneth atingiu o Norte de Moçambique no dia 25 de Abril de 2019, perto da fronteira com a Tanzânia, como um ciclone de categoria 4 segundo a escala Saffir Simpson, com ventos médios de mais de 100 nós (185 km/h) e rajadas de até 270 km/h (WMO, 2019). Esta foi a primeira vez na história registada que dois ciclones atingiram a costa de Moçambique em sucessão tão próxima, e o mais a Norte que um ciclone alguma vez atingiu o país (OCHA, 2019). A cidade de Pemba, no Norte, que escapou ao impacto inicial de Kenneth, sofreu algumas das piores chuvas. De 27 a 28 de abril caíram 168,7 mm de chuva em 24 horas e de 28 a 29 de abril chegaram a 254,7 mm. A província de Cabo Delgado sofreu inundações e deslizamentos de terra extremamente graves, com ligações de transporte cortadas e comunidades isoladas, tornando o esforço de socorro ainda mais difícil. Foram relatadas dezenas de mortes, além das centenas causadas pelo ciclone Idai (WMO, 2019).

Um ano pós os ciclones Idai e Kenneth, Moçambique foi atingido pela tempestade tropical Chalane na época chuvosa 2020/2021. Este sistema fez o *landfall* no distrito de Muanza, a Norte da cidade da Beira (Sofala), no dia 30 de Dezembro de 2020, a uma velocidade de cerca de 83 km/h, segundo

o Instituto Nacional de Meteorologia (INAM). A tempestade Chalane trouxe fortes chuvas, ventos fortes e inundações em todo o país. Em seguida, deslocou-se para o interior através do centro de Moçambique, enfraquecendo para uma depressão tropical à medida que se movia em direcção ao Zimbabwe e ao Botswana, onde se dissipou nas regiões centro-norte (ARC, 2020).

Durante a mesma época em que ocorreu a tempestade tropical Chalane (2020/2021), Moçambique foi também atingido pelo ciclone tropical Eloise. O ciclone Eloise atingiu a costa na manhã de 23 de Janeiro de 2021, perto da cidade da Beira, em Moçambique, causando danos generalizados e inundações numa longa faixa costeira. O ciclone tropical Eloise atingiu a costa com força de categoria 1, com ventos de 140 km/h e rajadas até 160 km/h, segundo o Instituto Nacional de Meteorologia de Moçambique (INAM) (ARC, 2021). O ciclone trouxe fortes chuvas e ventos fortes que causaram danos significativos, inundações generalizadas e deixaram estradas intransitáveis nas províncias de Sofala, Zambézia, Inhambane e Manica (NOAA, 2021). A Beira recebeu 250 mm de chuva em 24 horas, segundo o INAM. Os relatórios iniciais indicaram que as vítimas foram limitadas (WMO, 2021). O ciclone perdeu força à medida que avançava para o interior de Moçambique, sendo desclassificado para uma tempestade tropical moderada quando se deslocava para o Zimbabwe, África do Sul e Botswana (ARC, 2021).

O ciclone tropical Ana ocorreu em 2022 entre 20 e 25 de Janeiro sobre Madagascar, Moçambique e Malawi. A génese da tempestade ocorreu em 20 de Janeiro como uma depressão tropical e rapidamente evoluiu para uma “tempestade tropical severa” na costa ocidental de Madagáscar. Finalmente, Ana foi declarado um ciclone tropical no dia 24 de Janeiro, ao atingir a província da Zambézia, Moçambique, ao meio-dia (Singh & Schoenmakers, 2023). No dia 24 de Janeiro de 2022, a tempestade tropical Ana atingiu o distrito de Angoche, Nampula (Anticipation Hub, 2022). A tempestade afectou significativamente as províncias de Nampula, Zambézia e Tete, causando inundações generalizadas, interrupções de serviços básicos e graves danos em casas e infra-estruturas (IOM, 2022; OCHA, 2022b). Como resultado, os níveis de água no Rio Licungo subiram, ultrapassando o nível de desencadeamento de 25 de Janeiro no medidor de água de Mocuba, que é usado para determinar e iniciar acções antecipadas no âmbito do Protocolo de Acção Antecipada (PAA) de Moçambique para Cheias (Anticipation Hub, 2022). Além disso, este sistema danificou casas, bem como infra-estruturas públicas, incluindo pontes, linhas eléctricas, escolas,

sistemas de água e instalações de saúde (UNICEF, 2022). A tempestade tropical Ana afetou 126.198 pessoas, feriu 210 pessoas e matou pelo menos 21 pessoas, principalmente nas províncias da Zambézia, Nampula e Tete (FSC, 2022).

O Ciclone Tropical Severo (Categoria 3) Gombe atingiu o distrito de Mossuril, província de Nampula, no dia 11 de Março de 2022, após a passagem da Tempestade Tropical Ana, que atingiu Moçambique em Janeiro, afectando em conjunto mais de 200.000 pessoas (OCHA, 2022a). Depois enfraqueceu ao cruzar o interior para chegar ao Malawi, antes de regressar a Moçambique e desaparecer gradualmente no oceano (ARC, 2022). Segundo o Instituto Nacional de Meteorologia (INAM), Gombe afectou fortemente as províncias de Nampula e Zambézia e, em menor medida, Niassa, Cabo Delgado e Tete. Com chuvas até 200mm/24h e ventos até 190km/h, Gombe provocou inundações generalizadas, deslocações, danos em infra-estruturas públicas e habitações privadas, bem como interrupção de serviços básicos (OCHA, 2022a).

Estes ciclones que atingiram Moçambique deixam claro que a ameaça destes tipos de eventos é iminente. Os ciclones tropicais acima mencionados são apenas os que fizeram *landfall* em Moçambique, porém houve outros sistemas que se formaram durante o mesmo período. Os motivos que levaram esses outros sistemas a não atingir Moçambique são desconhecidos, porém devido ao aumento da frequência e intensidade de ciclones tropicais na região do sudoeste do oceano Índico, torna-se ainda mais urgente a melhoria das previsões desses sistemas, o que pode permitir o aumento da eficácia das acções antecipadas.

Capítulo 3 – Descrição da plataforma myDewetra

3.1. Características da plataforma myDewetra

A plataforma myDewetra foi apresentada pela primeira vez em Moçambique em Outubro de 2021 como uma ferramenta dedicada para a previsão de cheias na bacia hidrográfica do rio Buzi. A ideia central do myDewetra em Moçambique era dar suporte ao sistema de aviso prévio para cheias nas províncias de Manica e Sofala que foram fortemente impactados pelo ciclone Idai em 2019 (CIMA, 2021). Porém, mais tarde a plataforma sofreu uma actualização para que permitisse fazer a previsão da precipitação e ciclones tropicais. O primeiro teste foi realizado com o ciclone Freddy que ocorreu em 2023 e atingiu Moçambique na região Sul e Norte. Esta é a razão que justifica a escolha do ciclone Freddy como caso de estudo.

O Dewetra 2.0 é a evolução do antigo sistema integrado Dewetra, a funcionar desde 2008 no Centro Funcional Central da Direcção Nacional da Protecção Civil (DPC) a/o Gabinete do Primeiro-Ministro da Itália, para a previsão, monitorização e vigilância em tempo real de todos os riscos.

O sistema foi desenvolvido pela Fundação CIMA e é certificado técnica e operacionalmente pela WMO. O aplicativo disponibiliza, por meio de uma interface gráfica, informações em alta resolução e continuamente actualizadas, permitindo ao usuário monitorar eventos climáticos, construir cenários de risco detalhados e avaliar o potencial impacto dos fenómenos nas comunidades e infraestruturas.

O Dewetra 2.0 é capaz de carregar e exibir camadas estáticas e dinâmicas georreferenciadas e permite que os usuários finais naveguem pelos valores de cada estação de medição e outras ferramentas observacionais mais avançadas, oferecendo ferramentas e recursos interativos para a análise de fluxo contínuo e eventos passados.

Esta plataforma permite obter uma visualização de previsões, observações de eventos meteorológicos e hidrológicos além de permitir visualizar os resultados da análise do risco associados a esses mesmos eventos. Embora o myDewetra possa oferecer diversas ferramentas, o foco desta pesquisa é explorar apenas aspectos relacionados com a previsão da precipitação de ciclones tropicais. A Figura 3.1 apresenta a visualização da interface gráfica da plataforma myDewetra.

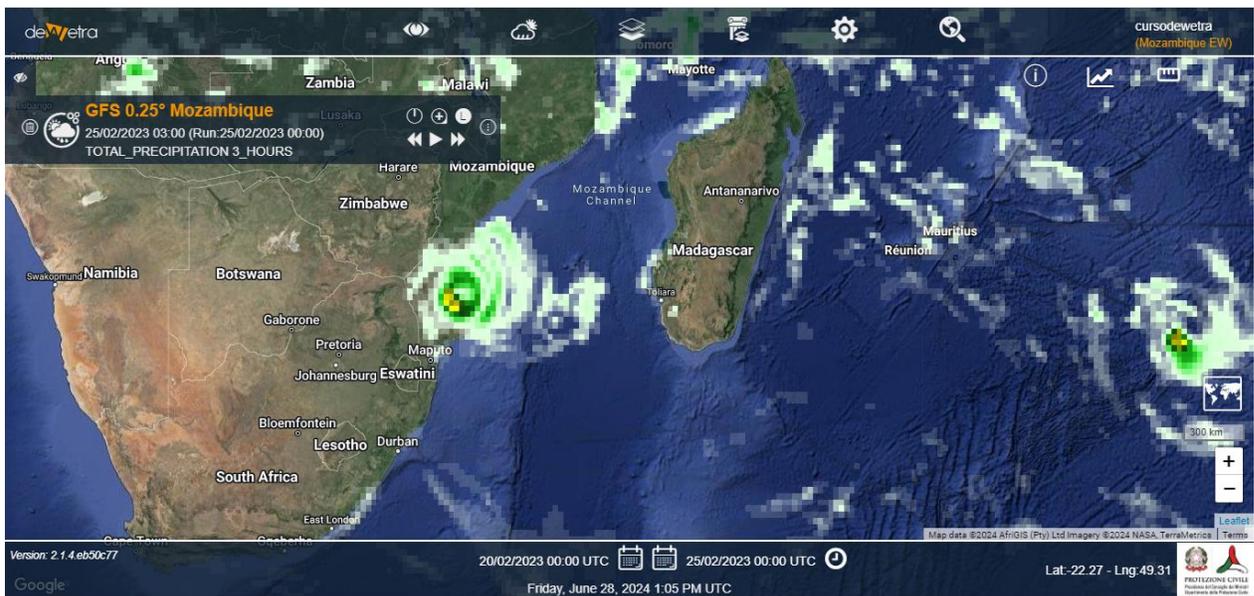


Figura 3.1: Interface gráfica da plataforma myDewetra.

3.2. Modelos de previsão da plataforma myDewetra

A plataforma myDewetra é composta por modelos de previsão para diversos fins, sejam hidrológicos, meteorológico, etc. A Tabela 3.1 ilustra a os modelos de previsão disponíveis no myDewetra de acordo com o tipo de ameaça.

Tabela 3.1: Modelos de previsão de perigos da plataforma myDewetra.

Categoria	Nome do modelo
Modelos Hidrológicos	EFAS layers
	GLOFAS
	GLOFAS Seasonal Outlook - Reporting Points
	GLOFAS Reporting Points
	Global Flood Monitoring System (GFMS)
Modelo de Incêndios Florestais	EFFIS
	RISICO Europe
	RISICO World
	FDI Europe
	FDI World
Modelos Meteorológicos	COSMO 5M
	COSMO Med
	WRF CIMA EUROPE OL
	GFS 0.25°

	ECMWF-ENS
Qualidade de ar	PM10
	PM2.5
Deslizamento de terra	LHASA
Impactos	Flood Affected Population
Previsões de Curto Alcance	GSMAP NC (JAXA)
Poeira	DUST Multi-Model

Visto que o propósito desta pesquisa é avaliar os modelos de previsão de eventos meteorológicos, apenas os modelos dessa categoria serão considerados. É importante notar que os modelos apresentados na Tabela 3.1 representam o total dos modelos que a plataforma possui. Portanto, os modelos que estarão disponíveis para o uso operacional dependem da região em questão. Por exemplo, para Moçambique, os modelos de previsão meteorológica disponíveis são o sistema global de previsão (GFS- *Global Forecast System*), o modelo do Centro Europeu de Previsões Meteorológicas a Médio Prazo (ECMWF - *European Centre for Medium-Range Weather Forecasts*) e observação global de chuvas da JAXA (GSMAP - *JAXA Global Rainfall Watch*) e o Cyclone Tracker. A Figura 3.2 apresenta os modelos de previsão do tempo disponíveis no myDewetra.

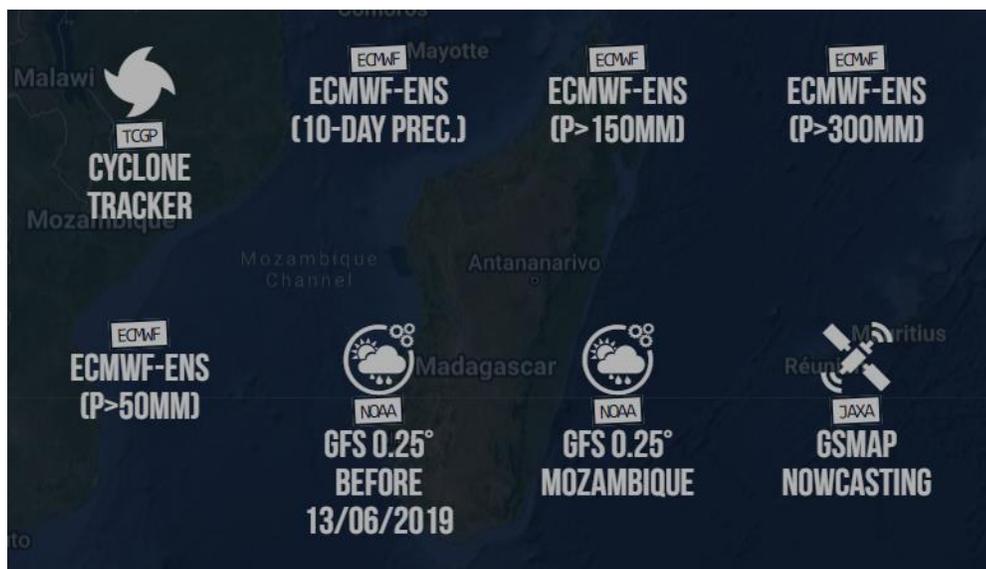


Figura 3.2: Modelos disponíveis na plataforma myDewetra para previsão de tempo.

O *Cyclone Tracker* é uma ferramenta do myDewetra composta por diversos modelos, que permite obter previsões da trajetória do ciclone e sua respectiva intensidade. A Figura 3.3 ilustra os modelos disponíveis para a previsão da intensidade e trajetória do ciclone.

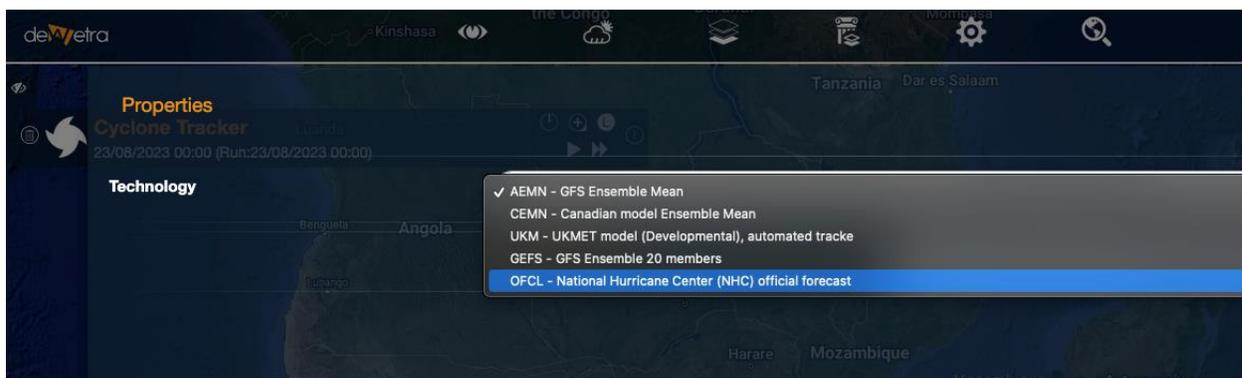


Figura 3.3: Modelos do Cyclone Tracker.

Para obter a previsão da trajetória, basta apenas selecionar o modelo desejado e o período de previsão. Por questões de coerência, será considerado apenas o modelo *GFS Ensemble Mean* (AEMN), uma vez que é o mesmo que foi listado como um dos modelos de previsão da precipitação de ciclone.

A secção a seguir será apresentado uma descrição de cada um dos modelos. Neste trabalho será avaliado apenas os modelos GFS. O modelo do ECMWF não será avaliado nesta pesquisa devido a falta de disponibilidade de dados de previsão, porém será descrito na secção 3.4. O modelo GSMAP também não será avaliado neste trabalho visto que está voltado apenas para previsões imediatas (Nowcasting). De acordo com Li et al. (2014), por definição, nowcasting é uma coleção de previsões muito curtas que começa com a descrição do estado actual do tempo. Segundo Lorenc (2015), essas previsões são válidas num intervalo de zero a 6 horas e depois disso perdem sua utilidade. Portanto, considerando que o tempo ideal para que as previsões de ciclones tropicais sejam úteis é de pelo menos 5 dias para a maioria dos centros de previsão (World Bank, 2018), torna este modelo dispensável para os propósitos desta pesquisa.

3.2.1. Modelo GFS

O GFS (NOAA, n.d.a), é um modelo de previsão meteorológica produzido pelos Centros Nacionais de Previsão Ambiental (NCEP- *National Centers for Environmental Prediction*), fornecendo

previsões atmosféricas e de ondas globais com resolução entre 25 e 28 km. O GFS é usado para condições iniciais e/ou de contorno para outros sistemas de previsão do conjunto de produção NCEP para previsão regional, oceânica e de ondas. O Sistema Global de Assimilação de Dados (GDAS - *Global Data Assimilation System*), que executa um esquema híbrido 4D de assimilação de dados variacionais, produz condições iniciais para a previsão GFS.

O GFS é executado quatro vezes ao dia (i.e., 0000, 0600, 1200, e 1800 UTC), produzindo previsões com até 16 dias de antecedência. Ele produz resultados de previsão de hora em hora para as primeiras 120 horas e, em seguida, de 3 em 3 horas para 5 a 16 dias. O modelo GFS é um modelo acoplado, composto por quatro modelos separados (um modelo de atmosfera, um modelo de oceano, um modelo de terra/solo e um modelo de gelo marinho), que trabalham em conjunto para fornecer uma imagem exacta das condições meteorológicas. São regularmente introduzidas alterações no modelo GFS para melhorar o seu desempenho e a exatidão das previsões (Poletti, 2023).

Dentro do myDewetra, as previsões do modelo GFS estão divididas em duas partes: as previsões da precipitação são determinísticas e as previsões de trajectória e intensidade dos ciclones tropicais são previsões de consenso (ou previsões de conjunto), denominados *Global Ensemble Forecast System (GEFS)*.

O sistema GEFS é baseado no sistema determinístico GFS (Deshpande et al., 2020), sendo por isso denominado *GFS Ensemble Forecast System (GEFS)* (NOAA, 2023d). A diferença fundamental entre o GFS e o GEFS é que o GFS é composto por uma única previsão determinística (NOAA, 2023c), enquanto o GEFS é composto por um total de 21 membros de previsões (20 previsões perturbadas e 1 previsão de controlo) (Deshpande et al., 2020). Cada um desses membros do conjunto é gerado a partir do método *Ensemble Kalman Filter (EnKF)* com a perturbação de previsão dos ciclos anteriores quatro vezes por dia (0000, 0600, 1200 e 1800 UTC) em todos os 64 níveis verticais do modelo. Para simular melhor, a inicialização do vórtice Ciclones/Furacões é realizada para todos os membros do conjunto (Deshpande et al., 2021).

Após as previsões individuais (de membro de controlo e perturbado), a seguir é calculada a média dessas previsões individuais, denominada *ensemble mean (AEMN)* (Deshpande et al., 2021). A

média do conjunto é a média dos valores previstos dos membros do conjunto num determinado momento de previsão (ou seja, a soma dos valores dividida pelo número de membros do conjunto). A média inclina-se para os valores de um maior número de membros do conjunto e é dado menos peso aos valores discrepantes. É usado principalmente em previsões de médio alcance, onde a média tende para o valor mais provável (Owens, 2022). As previsões de intensidade e trajectória dos ciclones tropicais são apresentados em termos de valores médios dessas duas variáveis. Na plataforma myDewetra, a média das previsões de intensidade e trajectória é denominado *AEMN – GFS Ensemble Mean* (Veja Figura 3.3).

3.2.2. ECMWF-ENS

Na plataforma myDewetra, o modelo ECMWF-ENS fornece previsões de médio prazo que consistem em 52 membros individuais, uma única previsão de alta resolução (HRES – High Resolution), uma previsão de controle (CNTL) com uma resolução inferior ao HRES e 50 membros conjunto (ENS - Ensemble) perturbados, que juntos fornecem informações detalhadas sobre a evolução do tempo (Molini, 2023). Este modelo é executado duas vezes por dia (00 UTC, 12 UTC) (Molini, 2023; ECMWF, n.d.).

O membro HRES corresponde ao membro não perturbado, com mais alta resolução espacial (em torno de 9 km) em relação aos outros membros. O seu estado inicial é a estimativa mais precisa das condições atuais e usa a melhor descrição actual da física do modelo. O HRES fornece uma descrição altamente detalhada do tempo futuro e, calculada a média de muitas previsões, é a previsão mais precisa para um determinado período. No entanto, para qualquer previsão específica, pode não ser o membro mais qualificado do conjunto. Além disso, quando visto isoladamente, não pode fornecer uma estimativa da incerteza ou da confiança nas previsões. Poletti (2023) afirma que em média, para muitas previsões, HRES é a previsão mais exacta.

Outro membro do conjunto (CNTL: previsão de controle) está em uma resolução espacial inferior à do HRES, mas nessa resolução mais baixa ele utiliza a estimativa mais precisa das condições atuais e a melhor descrição actual da física do modelo. Seu significado para o conjunto é que ele fornece o membro não-imperturbado ao qual as perturbações para o restante dos membros do conjunto são aplicadas (Molini, 2023).

Os membros perturbados (50 membros) são semelhantes ao CNTL, mas os seus estados iniciais e a física do modelo foram perturbados para explorar a gama de incerteza actualmente compreendida nas observações e no modelo. Eles fornecem uma série de possíveis estados do tempo futuros. Quando calculada a média de muitas previsões (embora não necessariamente para qualquer previsão específica), esta tem menos competências do que o HRES ou o CNTL. No entanto, fornecem uma estimativa da incerteza ou confiança da previsão (Molini, 2023).

Diferente do modelo GFS, no modelo ECMWF as previsões da precipitação acumulada são dadas em forma de probabilidades. Este modelo fornece a quantidade de precipitação acumulada no intervalo de previsão de 10 dias para a mediana da previsão do conjunto ECMWF; Probabilidade (%) de exceder 50–150–300 mm de precipitação acumulada ao longo do intervalo de previsão de 10 dias para a previsão do conjunto ECMWF (Molini, 2023).

Capítulo 4 – Materiais e Métodos

4.1. Descrição do ciclo de vida do ciclone Freddy

O ciclone tropical severo Freddy desenvolveu-se ao Sul da Indonésia e atravessou toda a extensão zonal do Sul do Oceano Índico. A baixa formou-se ao Sul do arquipélago indonésio em 5 de Fevereiro de 2023 e desenvolveu-se em um ciclone tropical às 12h UTC de 6 de Fevereiro. Inicialmente, a circulação era mal definida e alongada, porém a convecção persistente com melhores sinais de organização ocorreu durante o período noturno. Este desenvolvimento continuou até 6 de Fevereiro com faixas curvas aparentes em imagens visíveis e de micro-ondas e a baixa atingiu a magnitude do ciclone tropical às 12:00 UTC de 6 de Fevereiro (Clegg et al., 2023).

Após um breve período de movimento para o Sul, Freddy virou para Oeste e moveu-se sobre águas abertas ao Norte da Austrália Ocidental e ao Sul de Christmas e das Ilhas Cocos. Durante 7 de Fevereiro, Freddy ficou sob a influência da crista de nível médio e começou a se mover para Oeste. A crista de nível médio foi o mecanismo de direcção dominante durante o restante do período em que Freddy esteve na área de responsabilidade da Austrália e esse movimento para Oeste continuou até que Freddy se moveu para leste de 90° E em 14 de Fevereiro. Freddy intensificou-se rapidamente com um olho aparente nas imagens no início de 7 de Fevereiro. O sistema continuou a se intensificar e atingiu o seu primeiro pico de intensidade de 80 nós (150 km/h) às 00:00 UTC de 8 de Fevereiro (Clegg et al., 2023).

A partir das 00:00 UTC de 8 de Fevereiro, Freddy enfraqueceu nas 48 horas seguintes. O sistema estava localizado próximo a um forte gradiente de cisalhamento com ar seco circundando o ciclone tropical. Flutuações na magnitude do cisalhamento vertical do vento sobre o sistema, combinadas com possíveis intrusões de ar seco no núcleo, foram a causa provável da diminuição da intensidade durante o período entre 0000 UTC de 8 de Fevereiro e 1800 UTC de 9 de Fevereiro. Imagens de microondas mostraram que a convecção profunda diminuiu significativamente e a parede Sul do olho foi erodida (Clegg et al., 2023).

As condições tornaram-se mais favoráveis ao desenvolvimento e Freddy começou a se intensificar gradualmente a partir do início de 10 de Fevereiro. Imagens de microondas mostraram convecção profunda começando a envolver o centro. Em 11 de Fevereiro, a convecção profunda tinha-se

formado completamente em torno do centro, à medida que o cisalhamento vertical do vento diminuía e a divergência superior melhorava em todos os quadrantes. Freddy atingiu um segundo pico de intensidade média de 10 minutos de 95 nós (175 km/h) às 18:00 UTC de 11 de Fevereiro e novamente às 06:00 UTC de 12 de Fevereiro. A intensidade de Freddy continuou a flutuar entre 85 nós (155 km/h) e 75 nós (140 km/h) até que o sistema passasse a Oeste de 90° E, e entrasse na área de responsabilidade de La Reunion (Clegg et al., 2023).

De acordo com o Australian Bureau of Meteorology (2023), deslocando – se para Oeste do Oceano Índico, no dia 14 de Fevereiro este sistema era classificado como um ciclone tropical severo com ventos de até 140 km/h com rajadas de 195 km/h, equivalente a categoria 5 segundo a escala de Saffir-Simpson (Cappucci, 2023; La Reunion, 2023e). Até esta data (14 de Fevereiro), o ciclone era monitorado pelo Serviço Meteorológico Australiano (BOM), porém as 12h do mesmo dia, o sistema entrou na região de responsabilidade das Ilhas Reunião. Foi neste dia que também o sistema começou a mostrar simetrias no padrão de nuvens, com um olho bem visível (La Reunion, 2023e).

No dia 19 de Fevereiro, o ciclone continuou a se intensificar significativamente em todo o centro do ciclone e a temperatura do olho aqueceu, levando a uma estrutura anular notável. Esta intensificação também levou o ciclone a atingir o estágio de ciclone tropical muito intenso, com ventos superiores a 222 km/h (La Reunion, 2023c). No dia seguinte o sistema foi desclassificado como um ciclone tropical muito intenso devido ao seu enfraquecimento e a perda das características do olho (La Reunion, 2023f).

No dia 21 de Fevereiro de 2023 o ciclone continuou a enfraquecer com o olho não bem definido (La Reunion, 2023g). Mais tarde no mesmo dia, o ciclone atingiu a região continental de Madagáscar perto da cidade de Mananjary, a 241 km a Sul-sudeste da cidade capital Antananarivo (Erdman & Dolce, 2023). Passando pela Ilha, Freddy enfraqueceu rapidamente como resultado da presença de maior cisalhamento do vento, bem como da intrusão de ar seco. Após ultrapassar a ilha de Madagáscar, a actividade convectiva aumentou, o núcleo interno começou a se reconstruir indicando uma reintensificação do ciclone no canal de Moçambique (La Reunion, 2023d).

O ciclone Freddy foi o primeiro ciclone tropical no Hemisfério Sul a passar por quatro rodadas separadas de rápida intensificação, que ocorreram devido a repetidas rajadas de cisalhamento do

vento que enfraqueceram a tempestade e depois diminuíram (NOAA, 2023b). Rápida Intensificação (RI) é comumente definido como um aumento na velocidade máxima sustentada do vento na superfície de pelo menos um certo limite dentro de 24 horas (Li et al., 2022). O limite mais utilizado foi proposto por Kaplan e DeMaria (2003), que definiram o RI como o percentil 95 das mudanças de intensidade sobre a água em 24 horas nos CTs do Atlântico, que foi de 30 nós/24h. A Figura 4.1 mostra os estágios de rápida intensificação atingidas pelo ciclone Freddy.

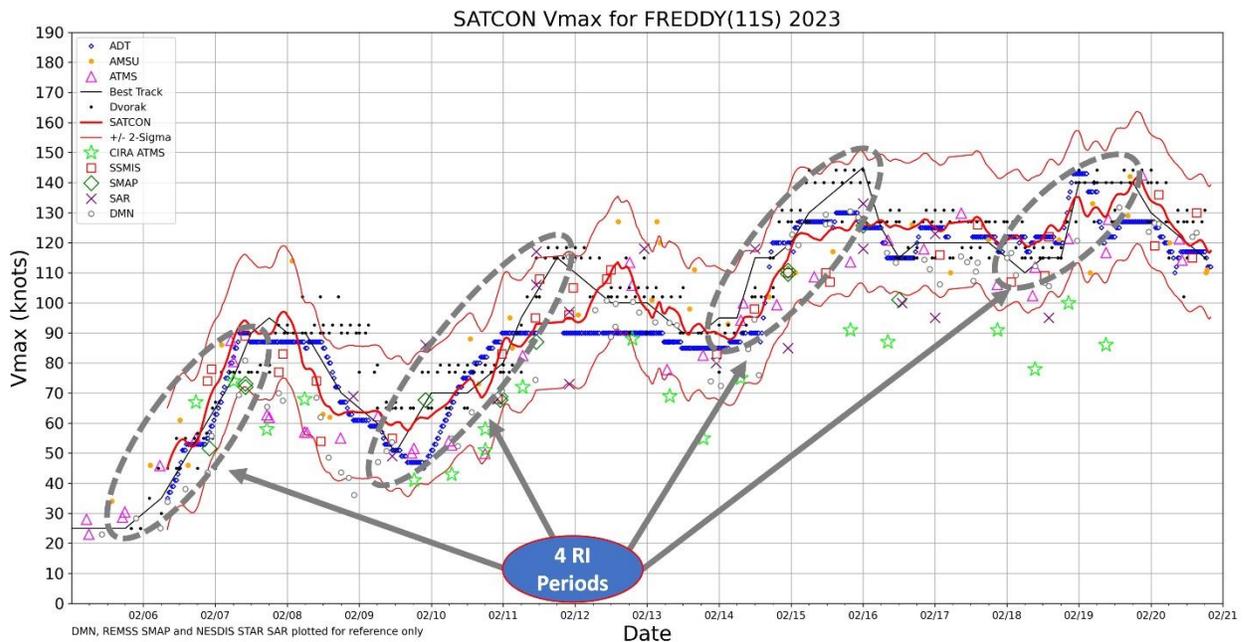


Figura 4.1: Estágios de rápida intensificação do ciclone Freddy. Fonte: (Bhatia, 2023).

O ciclone Freddy continuou a se mover para o Oeste e enfraquecendo significativamente a medida que se aproximava da costa de Moçambique. No dia 24 de Fevereiro, Freddy atingiu Moçambique como uma tempestade tropical moderada, a Sul da cidade de Vilanculos, na província de Inhambane as 14 horas locais (La Reunion, 2023h).

Na noite do dia 2 de Março, o Freddy reimmergiu sobre o canal de Moçambique como uma perturbação tropical, ainda perto da costa do país, indicando uma convecção profunda presente sobre o mar no semicírculo a Leste. Estando distante da superfície terrestre, esta região se encontrava em um ambiente mais favorável a intensificação do sistema (La Reunion, 2023i). No

dia 3 de Março o centro do sistema permaneceu distante da actividade convectiva, permanecendo concentrada nas linhas de instabilidade localizadas no semicírculo a leste (La Reunion, 2023j), sendo classificado ainda como perturbação tropical.

No dia 5 de Março, Freddy teve um movimento relativamente acelerado para o leste e se aproximou da costa de Madagáscar (La Reunion, 2023k). Na manhã do dia 7 de Março o sistema sofreu uma intensificação ocasionada pelo fraco cisalhamento vertical registado quando se aproximava da costa de Madagascar, tendo sido classificado como uma tempestade tropical severa. No mesmo dia, o sistema continuou a evoluir com um olho começando a se formar (La Reunion, 2023l). No dia 9 de Março o sistema já tinha evoluído para ciclone tropical, porém ainda era difícil localizar o centro da circulação (La Reunion, 2023m). No dia 11 de Março o ciclone Freddy atingiu Quelimane as 17:15, na província da Zambézia (La Reunion, 2023n). O ciclone Freddy começou a enfraquecer à medida que se deslocava no interior do país com precipitações não superando 50 mm. O sistema se dissipou completamente no dia 15 de Março (La Reunion, 2023a).

4.2. Área de estudo

Moçambique localiza-se a Sul do Equador, na costa oriental de África na região da África Austral (Langa, 2007). No que respeita a localização cósmica, Moçambique estende-se entre os paralelos 10°27' e 26°52' de latitude Sul e entre os meridianos 30°12' e 40°51' de longitude Este. O território nacional, cobre uma superfície total de 799.380 km², sendo que, 786.380 km² correspondem a terra firme e 1.300 km² são ocupados por águas interiores constituídos pelos rios, lagos, lagoas e pântanos. É limitado a Norte pelo Rio Rovuma que o separa da República Unida da Tanzânia, a Sul pela República da África do Sul, a Este pelo Oceano Índico, a Oeste por Zimbabwe e República da África do Sul, a Noroeste por Malawi e Zâmbia, África do Sul e Swazilândia (Guambe, 2017). A Figura 4.2 ilustra o mapa de localização geográfica de Moçambique.

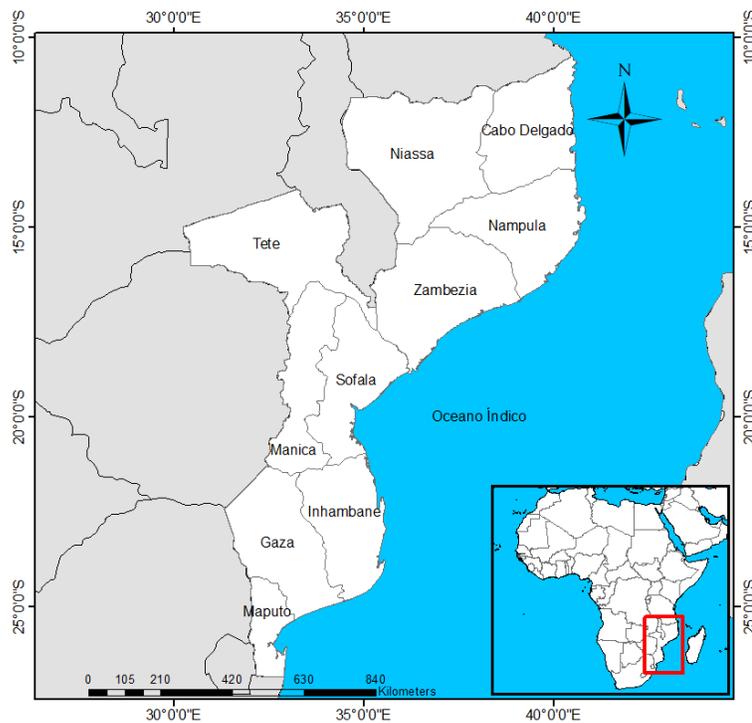


Figura 4.2: Localização geográfica de Moçambique. Fonte: Autor.

4.3. Clima de Moçambique

Guambe (2017), afirma que com base na combinação dos diferentes factores meteorológicos, físicos e humanos conclui-se que em Moçambique ocorrem os seguintes tipos de clima: Clima tropical húmido, Clima tropical seco, Clima tropical semi-árido e Clima tropical de altitude.

Assim, a parte Norte é dominada por um clima tropical chuvoso, enquanto a parte central é dominada por um clima moderadamente húmido modificado pela altitude. A parte Sul é mais influenciada pelos sistemas de latitudes médias ou pelas interações com ambos. Um clima tropical seco de savana também é uma característica comum na parte Sul, o que a torna mais propensa à seca do que no centro ou Norte. Como resultado, a região Centro e Norte recebem uma quantidade de precipitação superior a zona Sul, ultrapassando 400 mm. Outras áreas do centro do país e toda a zona costeira recebem quantidades de precipitação que variam entre 800 e 1000 mm (Mavume et al., 2021).

De Outubro a Março é geralmente quente e chuvoso, com temperaturas ao longo da costa Norte e no interior do vale do Zambeze superiores a 35 °C, em média. De Abril a Setembro é mais fresco

e seco, com temperaturas médias noturnas no Sul a descer abaixo dos 15 °C. A estação chuvosa começa em Novembro e atinge picos em Janeiro/Fevereiro (USAID, 2018).

4.4. Sistemas que influenciam a precipitação em Moçambique

Em geral, os sistemas produtores de precipitação em Moçambique compreendem a Zona de Convergência Intertropical (ZCIT), o El Niño-Oscilação Sul (ENSO), as Depressões Temperadas Tropicais, os ciclones tropicais formados no sudoeste do Oceano Índico (USAID, 2012), as Monções do Índico, os sistemas de baixa pressão no continente, os sistemas frontais, os anticiclones do Índico e os anticiclones do Atlântico (Mavume et al., 2021).

A estação chuvosa em Moçambique vai de Novembro a Abril, trazendo cerca de 150 a 300 mm de precipitação por mês no Norte e 50 a 150 mm por mês no Sul. A precipitação média anual diminuiu 2,5 mm por mês, por década, entre 1960 e 2006. No entanto, a intensidade de chuvas aumentou durante o mesmo período, com os maiores aumentos durante a estação chuvosa (USAID, 2012).

A precipitação tem sua representatividade territorial distribuída pelas regiões planálticas e montanhosas do país, nomeadamente: Planaltos da Marávia–Angónia (Norte de Tete), Sistema Maniamba–Amaramba (Niassa), Formações Chire-Namúli (Zambézia), Maciço Chimanimani (Manica) e Cadeia dos Libombos (Maputo) (Abel, 2011). A Figura 4.3 ilustra a distribuição da precipitação média anual em moçambique.

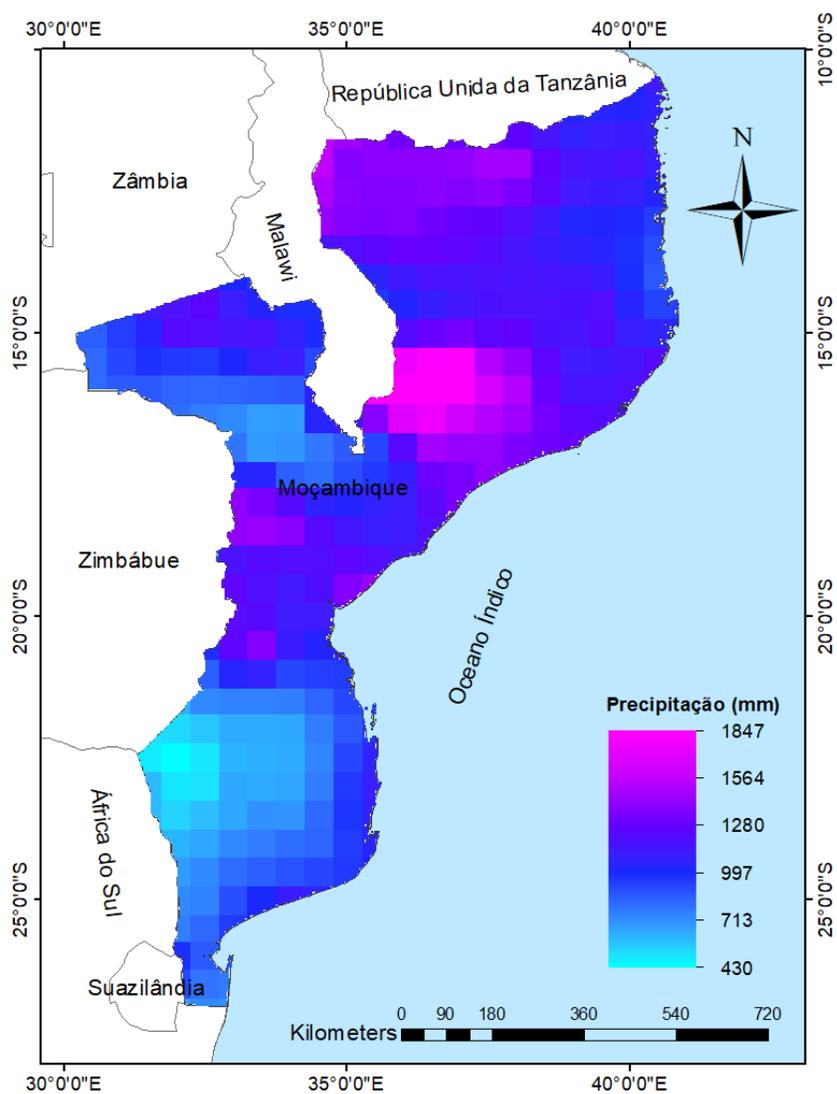


Figura 4.3: Distribuição espacial da precipitação média anual em Moçambique. Fonte: Autor.

Os baixos níveis de precipitação podem ter um impacto grave em Moçambique, que em muitas áreas tem uma baixa resiliência e uma capacidade limitada para mitigar os efeitos da seca (Mavume et al., 2021). Para suprir essa necessidade, os ciclones tropicais tem sido importantes contribuintes para os totais pluviométricos sobre Moçambique, especialmente para a zona Sul. Por exemplo o ciclone Eline (2000) contribuiu com mais de 500 mm de precipitação em Moçambique (Reason & Keibel, 2004; Vitart et al., 2003).

Na maioria dos anos, Moçambique não sofre nenhum ciclone tropical, uma vez que os ciclones tropicais tendem a ter uma recurvatura para Sul muito antes de atingirem a costa africana, poupando assim Moçambique (Vitart et al., 2003). Portanto, a época de ciclones tropicais de 2022-2023 sobre o SIO pode ser vista como excepcional e a previsão de ciclones tropicais sobre Moçambique poderia ser uma ferramenta valiosa para a gestão dos recursos hídricos e prevenção de desastres.

Esta pesquisa estará focada nas áreas atingidas pelo ciclone Freddy dentro do território moçambicano. As províncias afectadas são, Maputo, Gaza, Inhambane Sofala, Zambézia, Manica e Tete (OCHA, 2023c; Daves, 2023). A Figura 4.4 ilustra as áreas previamente indicadas.

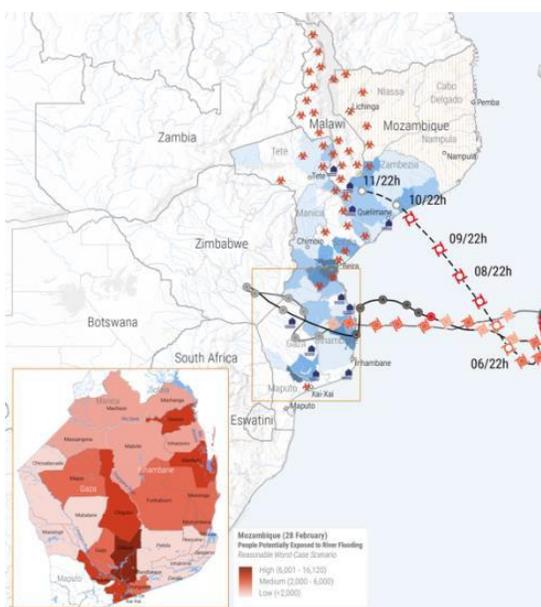


Figura 4.4: Regiões atingidas pelo ciclone Freddy. Fonte: (OCHA, 2023c).

4.5. Dados

4.5.1. Dados de melhor trajetória do ciclone Freddy

Nesta pesquisa, além da precipitação, foi avaliada a habilidade do modelo GFS em prever a intensidade e trajetória. Algumas pesquisas apontam que a intensidade pode ser um indicativo da intensidade da precipitação do ciclone tropical, visto que quanto maior for a intensidade do ciclone antes da sua chegada ao continente maior é a intensidade da precipitação (Feng & Shu, 2018). A trajetória nos informa sobre onde irão cair as chuvas do ciclone tropical.

Foram usados nesta pesquisa dados previstos e “observados” da trajetória e intensidade do ciclone Freddy durante o período em que este sistema chegou no canal de Moçambique até ao *landfall*. Os dados previstos foram obtidos do modelo GFS. Os dados previstos foram requisitados aos desenvolvedores da plataforma myDewetra. Os dados “observados” são os dados de melhor trajetória (MT) do ciclone Freddy produzidos pelo Centro Meteorológico Regional Especializado (CMRE) La Réunion. O CMRE Météo France em La Réunion, designado pela WMO em 1993 (Meteo France, sd) é responsável pela previsão e monitoria de ciclones tropicais em toda a região do Sudoeste do Oceano Índico (SOI) (Meteo France, sd). O CMRE La Réunion é responsável por a monitorização de todos os sistemas tropicais que ocorrem na sua área de responsabilidade (do equador até 40°S e entre as costas africanas até 90°E). A sua principal missão é fornecer informações de orientação adequadas (análises, previsões) aos serviços meteorológicos e hidrológicos nacionais de 15 Estados-Membros da região incluindo Moçambique (Meteo France, sd).

No geral, os dados de melhor trajetória incluem dados da localização do centro do ciclone, vento máximo sustentado e a pressão mínima (Huang et al., 2021). Embora a pressão mínima e o vento máximo sustentado sejam usados para a classificação da intensidade do ciclone (Chavas et al., 2017), neste trabalho foi usada a pressão mínima em vez da velocidade do vento máximo sustentado visto que o RSMC La Réunion usa ventos máximos sustentados de 10 minutos em uma altura de 10 metros (Meteo France, sd.b) enquanto que o myDewetra usa ventos máximos sustentados de 1 min à mesma altura. Essas diferenças nos métodos usados para classificar a intensidade do ciclone com base no vento pode influenciar os resultados da pesquisa.

Para avaliação do desempenho da previsão da intensidade foram usados os dados de pressão mínima central do ciclone enquanto que para a trajetória serão dados das coordenadas do centro do ciclone Freddy. Os dados de melhor trajetória foram obtidos através do RSMC La Réunion.

4.5.2. Dados da precipitação observada

Os dados de precipitação observada foram também usados. Esses dados referem-se à precipitação acumulada em 24h nas estações meteorológicas de superfície existentes no país, correspondentes

ao período da passagem do ciclone Freddy nas regiões Sul (entre os dias 24 a 28 de Fevereiro de 2023) e Norte (entre os dias 11 a 15 de Março) do país.

Os dados observados de precipitação foram obtidos através do Instituto Nacional de Meteorologia (INAM). De acordo com o decreto n.º 109/2020 de 17 de Dezembro, o INAM é a instituição responsável pela actividade meteorológica em Moçambique. De acordo com as recomendações da organização mundial da meteorologia, a observação da precipitação é realizada as 06UTC (WMO, 2012), porém em Moçambique a precipitação é registada diariamente as 9h locais.

4.5.3. Dados de previsões do modelo GFS

Dados de previsão da precipitação, intensidade e trajectória do ciclone Freddy foram obtidos do modelo GFS. Em todas as previsões foi considerado um *lead time*⁵ de 24h, 48h e 72h, excepto para a precipitação onde foi considerado apenas um lead time de 24h e 48h visto que as previsões de 72h estavam bastante longe dos dados observados (veja o apêndice), embora as previsões de até 72h sejam úteis para operações de mitigação de desastres e sistemas de aviso prévio (INGD, 2022).

A precipitação prevista foi comparada com a precipitação observada nas estações meteorológicas de superfície enquanto que a previsão de intensidade e trajectória foram comparados com os dados de MT. A avaliação da previsão da precipitação foi feita apenas dentro do período após *landfall* do ciclone Freddy. Esta abordagem permite uma comparação directa entre os dados observados e os dados previstos (Moses & Ramotonto, 2018). A descrição dos procedimentos metodológicos para o tratamento dos dados é apresentada nas secções a seguir.

4.6. Metodologia

4.6.1. Avaliação da previsão da trajectória do ciclone tropical

As previsões de trajetória foram avaliadas em relação aos dados observados de forma quantitativa, usando erros de trajetória. Para avaliar o desempenho do modelo em relação às localizações centrais dos TC, primeiramente as localizações centrais foram extraídas da base de dados de previsões do modelo. As localizações centrais do ciclone identificadas foram comparadas com os melhores dados de trajetória (localizações centrais) para estimar o erro de trajetória previsto. Erro

⁵ Em meteorologia, “*lead time*” refere-se à quantidade de tempo de antecedência que uma previsão é fornecida antes que um evento meteorológico ou climático específico ocorra (Loughe et al., n.d.).

de trajetória é a distância do grande círculo entre a posição prevista e a posição de melhor trajetória do centro do CT (Fiorino et al., 1993; Chen et al., 2013). Quanto menor for a magnitude deste erro, melhor será a previsão do modelo (Moses & Ramotonto, 2018). Matematicamente, o erro de trajetória pode ser calculado usando as equações propostas por (Argete & Francisco, 2007):

$$E_z = (x_f - x_o) \cos\left(\frac{y_f + y_o}{2}\right) \quad (1)$$

$$E_m = y_f - y_o \quad (2)$$

$$E = \sqrt{E_z^2 + E_m^2} \quad (3)$$

Onde E_z é o erro zonal, E_m é o meridional e E é o erro da trajetória prevista. x e y representam a longitude e latitude respectivamente, (x_f, y_f) é a posição prevista da tempestade enquanto (x_o, y_o) é a melhor posição da trajetória (*best track data*). Um E_z positivo indica uma trajetória prevista que se move mais lentamente do que a trajetória observada na migração para Oeste. Um E_m positivo significa que a trajetória de previsão está ao Norte da posição observada (Argete & Francisco, 2007). O erro E é dado em graus e será convertido para quilómetros pela multiplicação por 111,319 km (1 grau equivale a 111,319 km) (Maria et al., 2020).

4.6.2. Avaliação da previsão da intensidade

Para avaliação das previsões de intensidade foi apenas realizado uma comparação entre a previsão e os dados de MT. Foi também realizado uma avaliação quantitativa das previsões de intensidade do ciclone através do cálculo do erro de previsão. O erro é apenas módulo da diferença entre o valor da pressão prevista e o valor da pressão observada. Este método foi também usado por (Moses & Ramotonto, 2018).

4.6.3. Avaliação da previsão da precipitação

Nesta pesquisa também pretende-se avaliar a capacidade do modelo de prever a localização da precipitação máxima do ciclone. Para tal serão usadas as métricas propostas por (Moses & Ramotonto, 2018), onde considera que a avaliação da previsão da precipitação associada ao ciclone tropical pode ser realizada com base no cálculo da Raiz do Erro Quadrático Médio (RMSE). O cálculo dessa variável será feito usando a fórmula a seguir (Liu et al., 2021):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2} \quad (4)$$

Onde n é o número das estações de observação, i é a estação, f_i é o valor previsto e o_i é o valor observado. Quando o $RMSE = 0$, a previsão é perfeita. O $RMSE$ é uma medida de precisão na previsão.

4.7. Limitações do estudo

Vários constrangimentos foram observados durante a realização desta pesquisa desde a revisão bibliográfica até a análise dos dados. A primeira limitação encontrada está relacionada à escassez de fontes bibliográficas sobre a precipitação induzida pelos ciclones tropicais no contexto de Moçambique e Oceano Índico. Esta situação resultou no uso demasiado de fontes bibliográficas “estrangeiras”, ou seja, a literatura disponível é maioritariamente composta por pesquisas sobre precipitação de ciclones tropicais em outras bacias oceânicas e outros países, principalmente do hemisfério Norte.

A segunda limitação está relacionada a disponibilidade de dados observacionais da precipitação de ciclones tropicais. Os dados que estavam disponíveis não tinham uma densidade satisfatória para esta pesquisa. Por exemplo, para a região Sul não foi possível ter dados da província de Inhambane, apesar de esta ter sido a primeira província a ser atingida pelo ciclone Freddy. Na província da Zambézia, os dados disponíveis eram apenas de uma estação que está na capital provincial (Quelimane). Além disso, as estações cujos dados estavam disponíveis não apresentam uma densidade que permitem uma avaliação mais detalhada. Esse aspecto afecta a qualidade dos resultados.

Capítulo 5 - Resultados e Discussão

5.1. Avaliação da previsão da trajectória

O ciclone Freddy teve dois episódios de entrada à região continental de Moçambique. O primeiro foi na região Sul do país e o segundo na região Centro. Esta secção apresenta a avaliação das previsões de trajectória do modelo GFS desde a chegada do ciclone Freddy sobre o canal de Moçambique até o seu primeiro *landfall* incluindo o seu deslocamento sobre a região Sul de Moçambique. São também avaliadas as previsões de trajectória do modelo GFS durante o seu movimento para o segundo *landfall* incluindo o seu deslocamento sobre a região Centro de Moçambique. O modelo GFS foi avaliado comparando as suas previsões com os dados de melhor trajectória (MT). As previsões são correspondentes a 12UTC com um *lead time* de 24h, 48h e 72h.

5.1.1. Primeiro *landfall*

As previsões de trajectória do modelo GFS durante o deslocamento do ciclone Freddy até a sua primeira entrada em Moçambique são apresentadas nesta secção. Os resultados mostram que durante a passagem do ciclone pelo canal de Moçambique, as previsões do modelo GFS dos dias 21, 22 e 23 de Fevereiro estavam mais aceleradas em relação a posição de MT para todos os *lead times* (24h, 48h e 72h) tal como indica a Figura 5.1a e b. Para o dia 21 de Fevereiro (Figura 5.1a), a previsão de 24h do modelo GFS indicava que o ciclone estaria na costa oeste de Madagáscar, o que está de acordo com os dados de MT. Para o mesmo dia, a previsão de 48h indicava que o ciclone estaria sobre o canal de Moçambique, estando mais uma vez de acordo com os dados de MT. Para a previsão de 72h o modelo GFS indicava que o ciclone estaria na região continental de Moçambique sobre a região Sul, porém os dados de MT indicavam que o centro do ciclone estava na costa este de Moçambique, próximo a província de Inhambane. As previsões do dia 22 de Fevereiro (Figura 5.1b), não estavam de acordo com os dados de MT em todos os *lead times*, excepto a previsão de *lead time* de 24h onde o modelo previu que o ciclone estaria sobre o canal de Moçambique, estando de acordo com os dados de MT. Em relação a previsão do dia 23 de Fevereiro (Figura 5.1c), apenas a previsão de 24h mostrou alguma aproximação aos dados de MT, portanto as previsões de 48h e 72h mostraram maior dispersão em relação aos dados de MT, tal como as previsões do dia anterior. Porém, as previsões do dia 24 (Figura 5.1d) indicava que o modelo previu com alguma precisão a localização do centro do ciclone Freddy, estando alinhado

com os dados de MT para 24h e 48h de *lead time*, embora a previsão de 72h indicava um afastamento para o Norte em relação à MT. No geral o modelo mostra um viés ao Noroeste, isso significa que na maior parte das previsões o modelo GFS mostra que o ciclone Freddy estaria a Norte da posição observada. A Figura 5.1 ilustra de forma esquemática as posições do centro do ciclone Freddy previstas pelo modelo GFS e as dos dados de melhor trajectória.

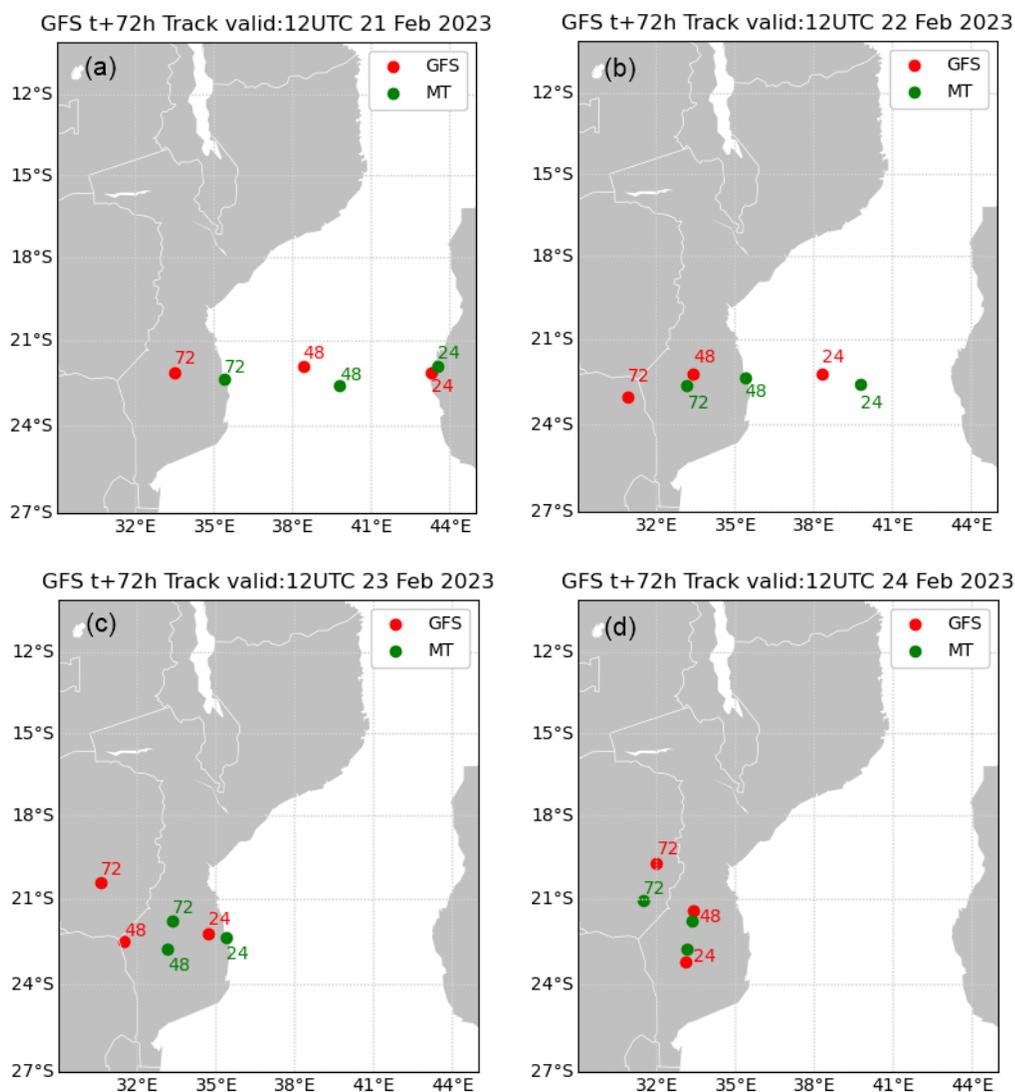


Figura 5.1: Localização do centro do ciclone Freddy previsto pelo modelo GFS (representado pelo ponto vermelho) e a localização do centro do ciclone segundo os dados de melhor trajectória (indicado pelo ponto verde) para os dias 21, 22, 23 e 24 (Figura a, b, c, d, respectivamente) de Fevereiro de 2023. As previsões foram realizadas as 12h, com um “lead time” de 24h, 48h e 72h.

Estes resultados permitem tirar quatro conclusões: Primeiro é que o ciclone estava mais acelerado quando se deslocava sobre as águas do canal de Moçambique, tendo percorrido mais de 845 km em 48h, e desacelerou ao atingir o continente, visto que percorreu uma distância de aproximadamente 343 km em 48h, ou seja, menos que a metade da distância percorrida sobre o canal de Moçambique durante o mesmo intervalo de tempo. De acordo com Tu et al. (2022), a velocidade de translação do ciclone tropical afecta a sua taxa de precipitação. Eles afirmam que a taxa de precipitação aumenta com o aumento da velocidade de translação do ciclone tropical e diminui com a redução da velocidade de translação. Porém, ciclones tropicais que se movem lentamente podem causar maiores volumes de precipitação devido a duração da sua influência sobre uma determinada região (Yamaguchi et al., 2020). Torn et al. (2015) sugerem que observações adicionais em regiões com precipitações de grande escala fora do núcleo do ciclone tropical podem beneficiar as previsões de trajectória.

Em segundo lugar, embora o modelo tenha mostrado um bom desempenho em prever a trajectória em termos de deslocamento, as previsões do modelo GFS estavam relativamente mais aceleradas do que o próprio ciclone Freddy, isto significa que o modelo é capaz de prever com alguma precisão o local onde o ciclone irá passar, porém não consegue prever o momento exato do impacto. Estes resultados são similares aos resultados obtidos por (Sridevi et al., 2022).

Terceiro é que durante o deslocamento sobre o canal de Moçambique as previsões da posição do ciclone do GFS estavam mais distantes dos dados de MT, e mais próximos da MT após a chegada do ciclone sobre a região continental (após o *landfall*), ou seja, o modelo mostrou melhor desempenho na previsão da localização do centro do ciclone quando ele se deslocava sobre o continente e menos desempenho quando o ciclone estava sobre o canal de Moçambique;

Quarto é que a medida que o *lead time* aumenta, as previsões da posição do centro do ciclone se afastavam ainda mais da posição real do centro do ciclone, embora a Figura 5.1a e b não mostrem uma grande diferença entre as previsões de 48h e 72h. Em outras palavras o modelo tem melhor desempenho para prever a posição do centro do ciclone para intervalos mais curtos de *lead time*. Chen et al. (2013), também notaram um desempenho melhor de outros modelos globais para previsões de *lead time* inferior a 48h, porém em condições de cisalhamento de vento relativamente menor e para ciclones inicialmente grandes. Além de Chen et al. (2013), outros autores mostraram

que o aumento do *lead time* pode afectar negativamente a previsão da trajectória do ciclone, por exemplo Marchock et al. (2007). Eles acreditam que as possíveis causas desse efeito sejam as parametrizações físicas e os esquemas de inicialização de cada modelo.

5.1.1.1. Erro de previsão da trajectória para o primeiro *landfall*

A previsão de trajectória também foi avaliada de forma quantitativa através do cálculo dos erros. Os resultados são apresentados na Figura 5.2. Esses erros foram calculados usando os procedimentos descritos na secção 3.6.1. Estes gráficos apresentam de forma quantitativa as constatações que foram tiradas dos mapas apresentados da secção anterior. Para o dia 21 de Fevereiro Figura 5.2a, nota-se uma tendência de aumento do erro de previsão a medida que aumenta o *lead time*, tendo se registado um erro de 34 km para uma previsão de 24h e um erro de 204 km para uma previsão de 72h. Os erros de previsão do dia 22 de Fevereiro para todos os *lead times* não mostram uma tendência clara (Figura 5.2b). Neste dia, a previsão de *lead time* de 48h foi a pior de todas com um erro de até 211 km, sendo seguido pela previsão de 72h com um erro de 161 km. A previsão de 24h foi a melhor de todas as previsões, porém não muito satisfatório, com um erro de 157 km. Os erros de previsão do dia 23 (Figura 5.2c) mostram a mesma tendência identificada nas previsões do dia 21 de Fevereiro. No dia 24 de Fevereiro, o erro de previsão de 24h da posição do ciclone foi maior que o erro de previsão de 48h, embora não haja muita diferença entre as duas previsões em termos quantitativos. A previsão de 72h estava bastante afastada da real posição do centro do ciclone. A Figura 5.2 ilustra os gráficos dos erros de previsão para todos os *lead times*.

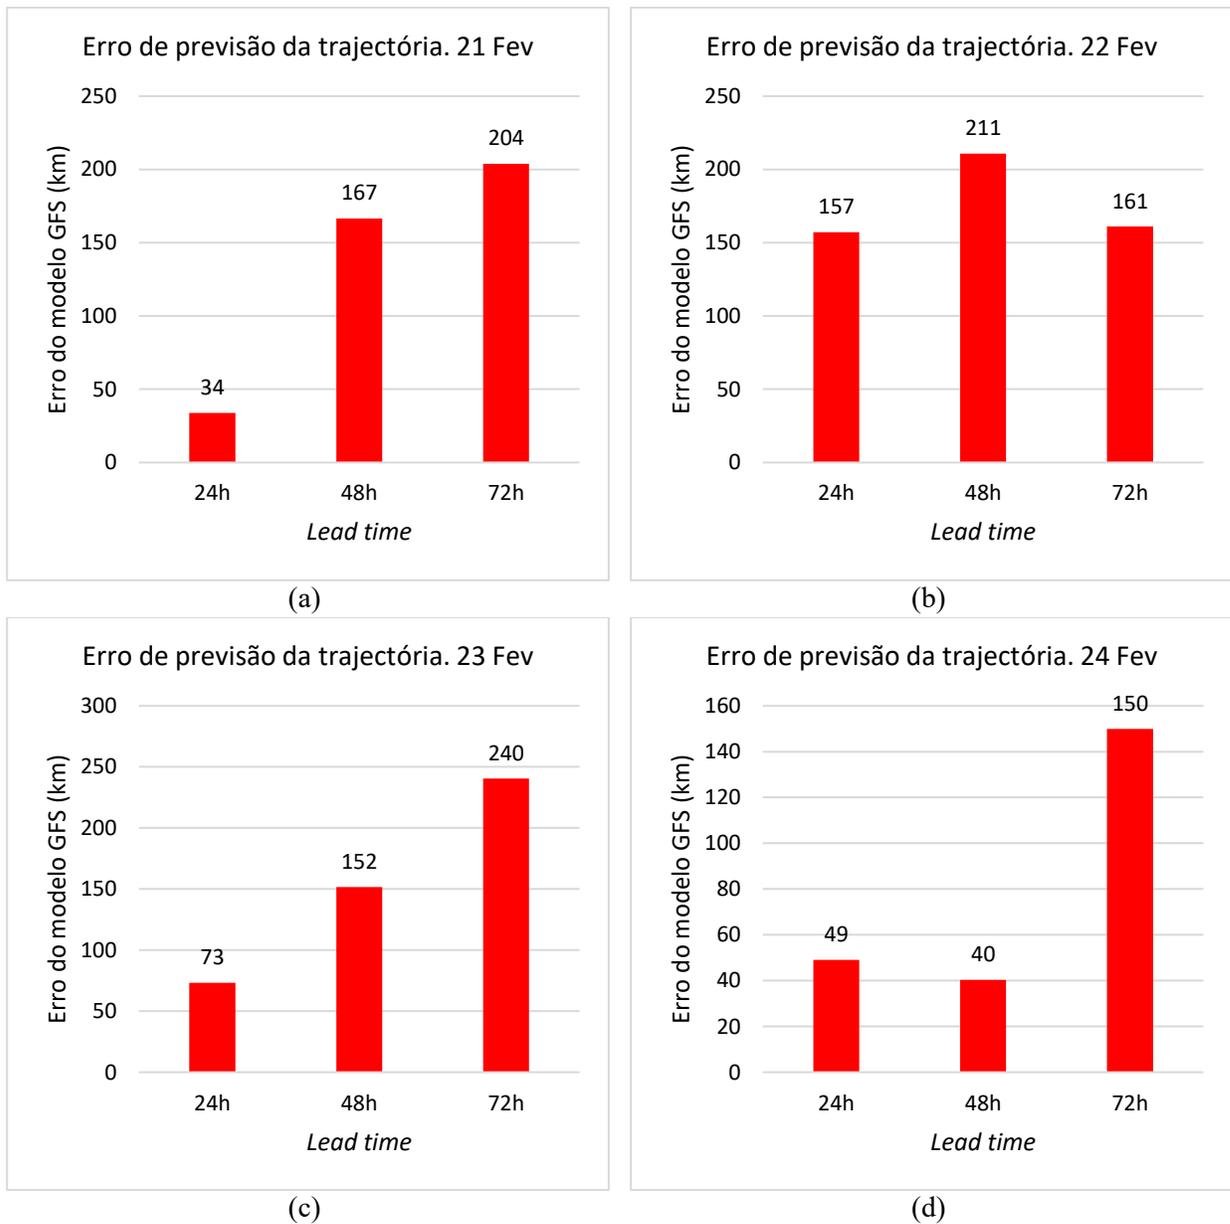


Figura 5.2: Erros de previsão de trajetória do modelo GFS para lead times de 24h, 48h e 72h durante o movimento do ciclone para a região Sul de Moçambique.

Os resultados apresentados na Figura 5.2 são relativamente contraditórios aos resultados obtidos por Moses e Ramotonto (2018). Estes autores avaliaram a habilidade do modelo GFS em prever a trajetória do ciclone Dineo sobre Botswana para previsões de 24h de *lead time*. Eles mostraram que os erros de previsão da trajetória diminuíam a medida que o ciclone Dineo se deslocava para interior do continente, porém a Figura 5.2 não mostra uma relação entre a localização do ciclone e a habilidade de previsão quando avaliado cada *lead time* isoladamente.

A Figura 5.3 ilustra o gráfico do erro médio das previsões da trajectória do ciclone Freddy todos os *lead times*. Os valores médios foram obtidos através do cálculo da média aritmética dos erros apresentados na Figura 5.2 para cada *lead time*. Os resultados revelam que o modelo GFS tem melhor desempenho para realizar previsões da trajectória para períodos mais curtos de previsão, ou seja, as previsões mais confiáveis são os de 24h em relação aos outros *lead times*. De modo a aumentar a confiança nas previsões de trajectória do modelo GFS, as previsões de 48h e 72h devem ser confirmadas pelas previsões de 24h, ou seja, após realizar previsões de 72h ou 48h, ainda deve-se esperar até 24h antes do dia previsto para confirmar (através de uma previsão de 24h) as previsões anteriormente realizadas de modo a aumentar a confiabilidade das previsões.

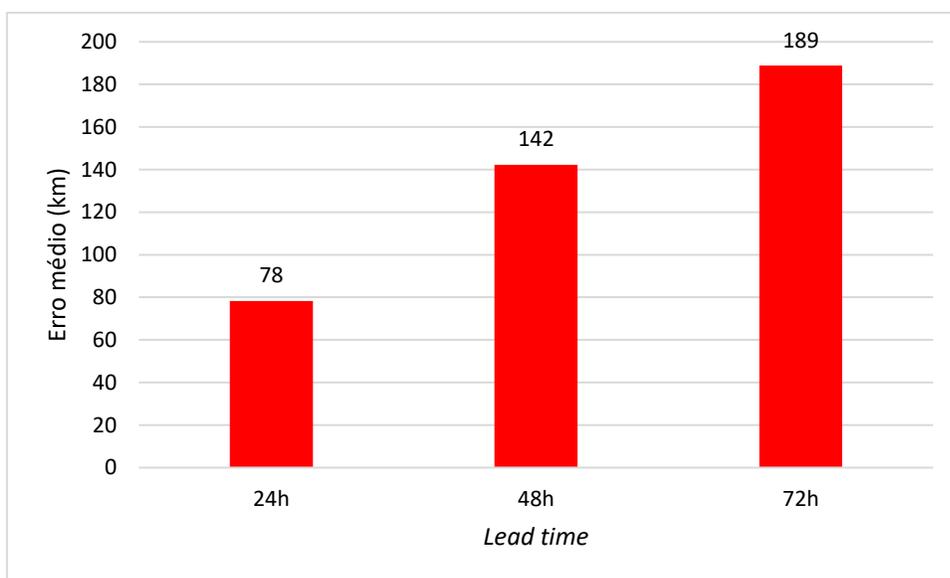


Figura 5.3: Erro médio de previsão de trajectória do modelo GFS durante o seu deslocamento para a primeira entrada em Moçambique.

5.1.2. Segundo *landfall*

Depois que o ciclone Freddy entrou na zona Sul, ele retornou ao canal de Moçambique, se reintensificou e posteriormente se deslocou para o Norte de Moçambique (La Reunion, 2023i). O ciclone Freddy fez a segundo *landfall* em Quelimane, na província da Zambézia. A Figura 5.4 ilustra o deslocamento do ciclone para o segundo *landfall*. Infelizmente não foi possível incluir a posição do dia 9 e 15 de Março de 2023 devido a falta de dados de previsão e dados de melhor trajectória, respectivamente.

Para o dia 8 de Março Figura 5.4a, a previsão do modelo GFS para *lead time* de 24h estava de acordo com os dados de MT, ambos indicando que o ciclone Freddy estaria sobre o canal de Moçambique. A previsão de 48h indicava que o ciclone estaria na região costeira, o que não estava de acordo com os dados de MT visto que estes indicavam que o ciclone ainda estava sobre o canal de Moçambique numa região relativamente distante da costa. A previsão de 72h de *lead time* indicava que o ciclone Freddy já teria entrado para o interior do país, porém nesta data os dados de melhor trajectória indicavam que o sistema estava sobre a região costeira. Este foi o dia em que o ciclone fez o *landfall* na província da Zambézia (La Reunion, 2023n). No dia 10 de Março (Figura 5.4b), a previsão de 24h (11 de Março) o modelo foi capaz de fazer uma previsão perfeita da real localização do centro do ciclone (nesse caso o ponto de entrada no continente), por essa razão na Figura 5.4b apenas conseguimos observar o ponto verde, uma vez que os pontos vermelho e verde estão sobrepostos. Para previsões de 48h e 72h de *lead time* do mesmo dia 10, a dispersão entre a previsão e a MT continuou a ser notável, sendo a previsão do GFS indicando que a posição do ciclone estaria a Sul da posição observada. Após a segunda entrada do ciclone Freddy em Moçambique, ou seja, depois do dia 11 de Março, o modelo GFS mostrou dificuldades crescentes para prever a posição do ciclone Freddy, principalmente as previsões do dia 11. De acordo com as previsões do modelo GFS, o ciclone retornou para o canal de Moçambique, porém os dados de MT indicam que o ciclone se deslocou para o interior de Moçambique na fronteira entre a província de Tete e Malawi. De acordo com Badarinath et al. (2012), é importante incluir os dados de uso e cobertura do solo no processo de parametrização dos modelos de previsão de modo a reduzir os erros de previsão da trajectória do ciclone. A possível falta de consideração das características da região continental no modelo GFS pode ter sido uma das razões pelas quais as previsões pioraram depois do segundo *landfall*. A Figura 5.4 ilustra a comparação das previsões de trajectória do ciclone Freddy com os dados de MT.

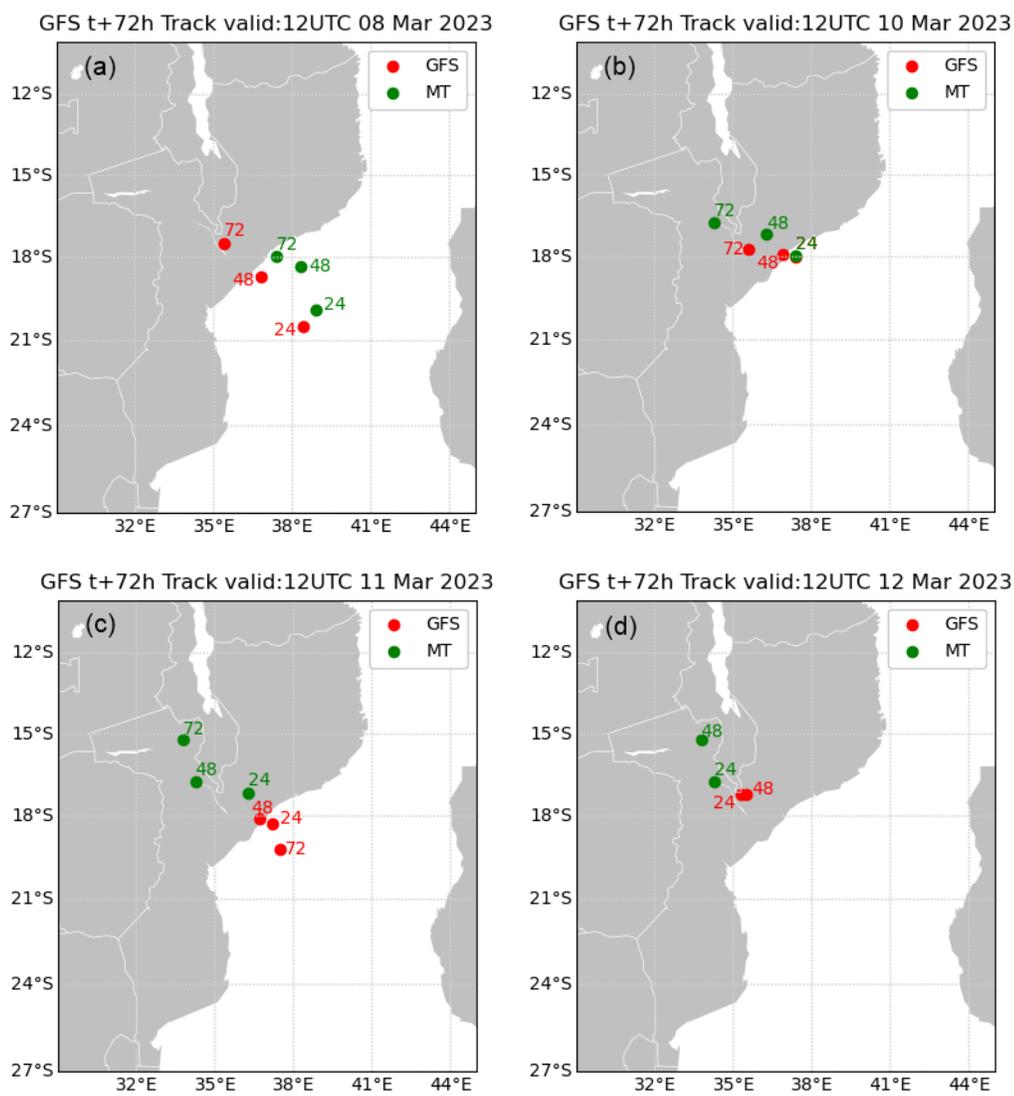
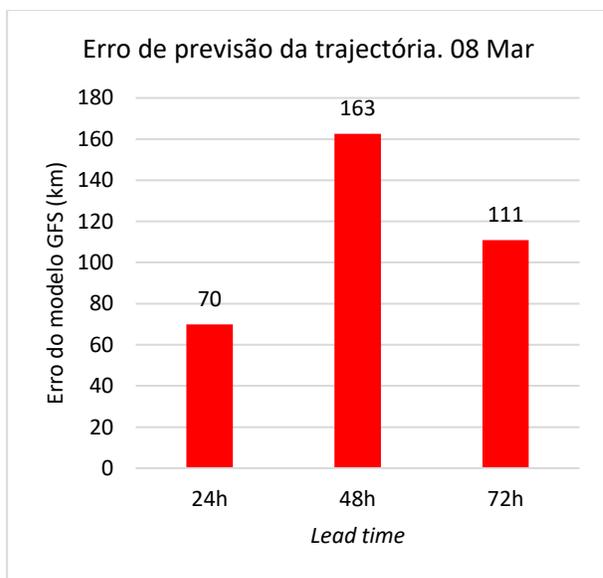


Figura 5.4: Localização do centro do ciclone Freddy previsto pelo modelo GFS (representado pelo ponto vermelho) e a localização do centro do ciclone segundo os dados de melhor trajectória (indicado pelo ponto verde) para os dias 8, 10, 11 e 12 (a, b, c, d, respectivamente) de Março de 2023. Os ciclos de previsão utilizados foram de 12h, com um lead time de 24h, 48h e 72h.

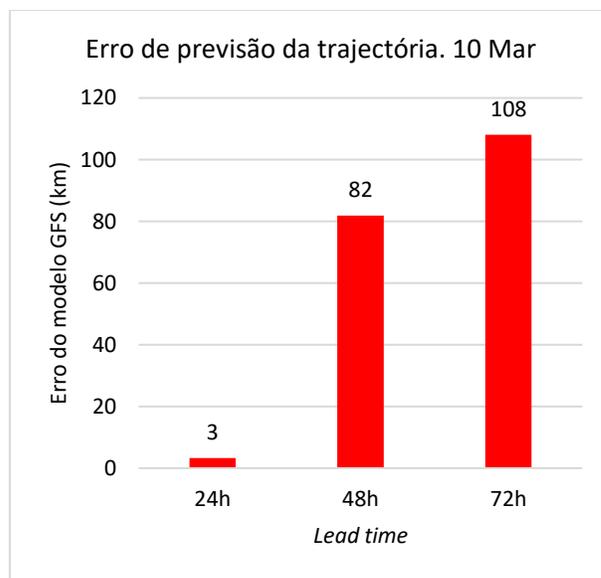
Diferente das previsões do primeiro *landfall*, que mostravam um viés ao Noroeste das observações para a maior parte das previsões, as previsões da trajectória até ao segundo *landfall* não mostram um padrão claro dos erros em termos espaciais.

5.1.2.1. Erros de previsão de trajectória do segundo *landfall*

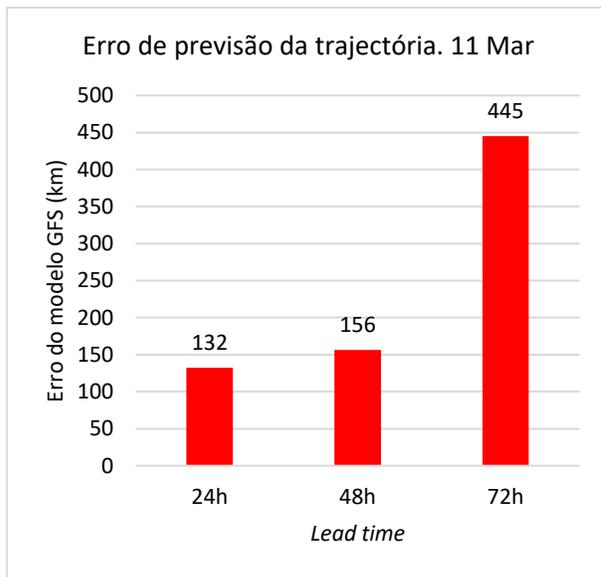
Os erros de previsão para a segunda entrada do ciclone no país (deslocamento para o Norte) mostram que o modelo GFS teve um comportamento similar ao dos erros de previsões da primeira entrada (deslocamento zonal) em alguns aspectos. Por exemplo, as previsões de 24h são as melhores em relação as previsões de outros *lead times*. Os erros de previsão do dia 8 de Março são similares aos erros de previsão do dia 22 de Fevereiro porque ambos tiveram um erro de previsão de 48h pior que os de 24h e 72h. O erro de previsão de 24h para o dia 10 de Março (Figura 5.5b) foi o mais baixo de todos os erros de previsão de trajectória, com um erro de apenas 3 km. Este foi o dia em que o ciclone chegou na costa da província da Zambézia, mostrando que o modelo GFS foi capaz de prever o ponto de entrada do ciclone Freddy com precisão tal como pode ser observado na Figura 5.4b, que mostra que os pontos vermelho e verde estão quase sobrepostos. A pior previsão de trajectória do modelo GFS foi a previsão de 72h realizada no dia 11, com um erro de trajectória de aproximadamente 445 km. A Figura 5.5 ilustra os erros de previsão da trajectória do modelo GFS. É importante notar que no dia 12 de Março não foi realizada nenhuma avaliação da previsão de 72h de *lead time*.



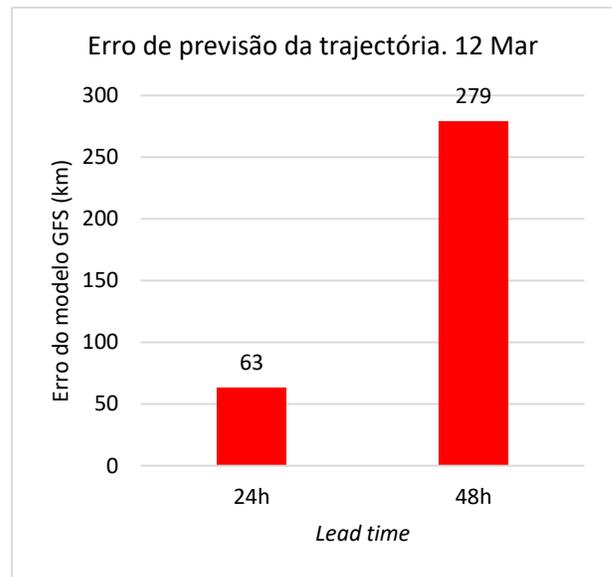
(a)



(b)



(c)



(d)

Figura 5.5: Erros de previsão de trajetória do modelo GFS para 24h, 48h e 72h de lead time durante o movimento do ciclone para a região Norte de Moçambique.

O erro médio de previsão da trajetória do modelo GFS durante o deslocamento para o segundo *landfall* é apresentado na Figura 5.6. O erro médio das previsões de 72h não incluem a previsão de 72h do dia 12 de Março devido a indisponibilidades de dados. Os resultados mostram a mesma tendência que as previsões da trajetória para o primeiro *landfall* na região Sul do país. Nota-se que o erro médio de previsão de 24h para o segundo *landfall* é menor que o erro médio de previsão do primeiro *landfall*.

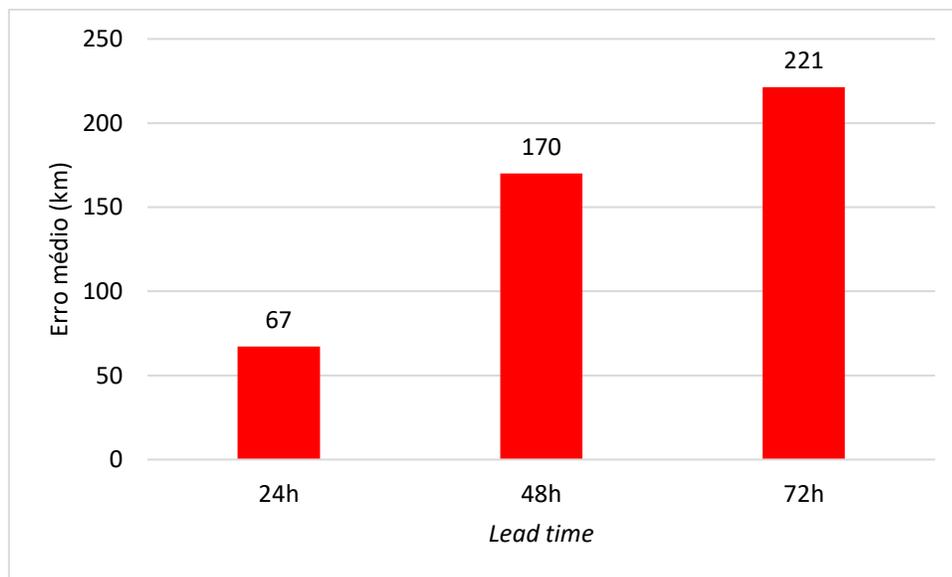


Figura 5.6: Erro médio da previsão da trajetória do modelo GFS durante o deslocamento para a segunda entrada no Norte de Moçambique.

Para o *lead time* de 48h e 72h, os erros de previsão são maiores no segundo *landfall* em relação aos do primeiro *landfall*. De acordo com Chen et al. (2013), os erros de previsão de trajetória dos modelos globais tende a se concentrar em regiões de baixas latitudes. Uma vez que a região Norte de Moçambique está mais próxima do equador em relação a região Sul, a descoberta de Chen et al. (2013) pode ser uma das razões pelas quais o modelo GFS apresentou maiores erros de previsão de trajetória a medida que o ciclone Freddy se deslocava para a zona Norte. No entanto, todos os erros de previsões de trajetória do modelo GFS mostraram uma tendência de aumentar a medida que o *lead time* aumentava.

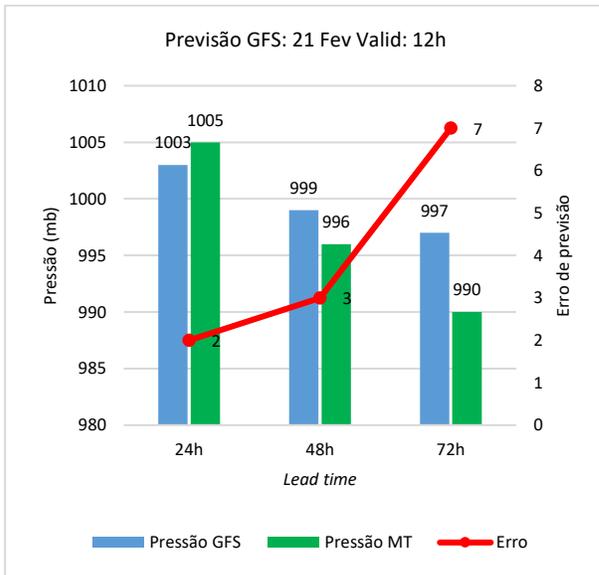
5.2. Avaliação das previsões de intensidade

A pressão a nível médio do mar pode ser usada como uma medida de intensidade de um ciclone (Zhang et al., 2019; Sridevi et al., 2022). Quanto menor for a pressão mínima central do ciclone maior é a sua intensidade (Rosendal & Shaw, 1982; Wada & Usui, 2007). As previsões da intensidade foram avaliadas de forma quantitativa através do cálculo do erro. O erro é o valor absoluto da diferença entre o valor da pressão prevista e observada (Cangialosi et al., 2020). Os

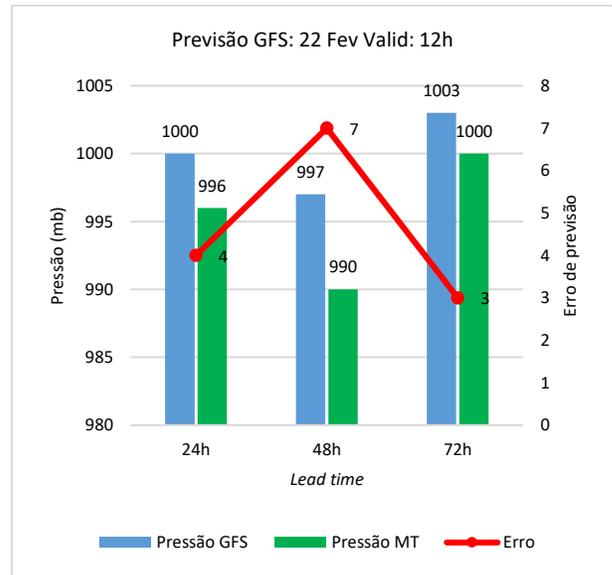
resultados do cálculo do erro são plotados junto com os dados previstos e dados de pressão estimados dos dados de melhor trajetória (observados) de modo a simplificar a comparação. Os resultados são apresentados tanto para o primeiro *landfall* assim como para o segundo *landfall*.

5.2.1. Primeiro *landfall*

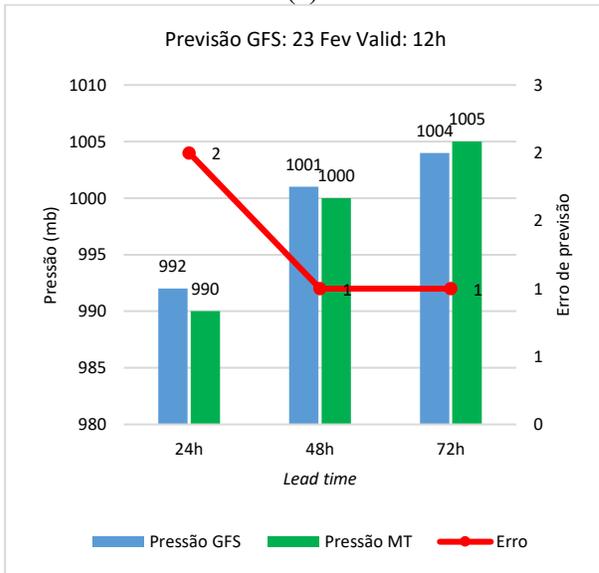
Durante o deslocamento do ciclone Freddy para a o primeiro *landfall*, o modelo GFS previu com alguma precisão a pressão central mínima, visto que não são muito distantes do valor observado. Para o dia 21 de Fevereiro (Figura 5.7a), a previsão de 24h indicou uma pressão de 1003 mb enquanto que os dados de MT indicaram o valor de 1005 mb, ou seja o modelo superestimou a intensidade do ciclone no valor de 2 mb. Para previsão de 48h e 72h o modelo subestimou a intensidade, tendo previsto um valor de pressão superior a pressão indicada pelos dados de MT. O erro de previsão foi maior para o *lead time* de 72h em relação ao *lead time* de 48h e 24h. No dia 22 de Fevereiro (Figura 5.7b) o modelo subestimou a intensidade para todos os *lead times* e, além disso, nota-se que os erros de previsão de 24h e 48h foram maiores que o de 72h. Algo interessante é que o modelo foi capaz de detectar o aumento da pressão com 72h de antecedência, que está associada ao deslocamento do ciclone sobre a terra firme, uma vez perdida a sua fonte de energia (oceano). A previsão de 72h realizada no dia 22 de Fevereiro é referente ao dia 25 de Fevereiro quando o ciclone já estava sobre a terra. Os erros de previsão do dia 23 e 24 de Fevereiro são iguais (Figura 5.7c e d). Em ambos casos o modelo teve um erro de 2 mb para previsões de 24h e 1 mb para previsões de 48h e 72h, respectivamente. Porém a diferença é que para o dia 23 de Fevereiro o modelo subestimou a intensidade do ciclone nas previsões de 24h e 48h e superestimou a pressão na previsão de 72h, enquanto que as previsões do dia 24 de Fevereiro mostram que o modelo superestimou a intensidade do ciclone em todos os *lead times*.



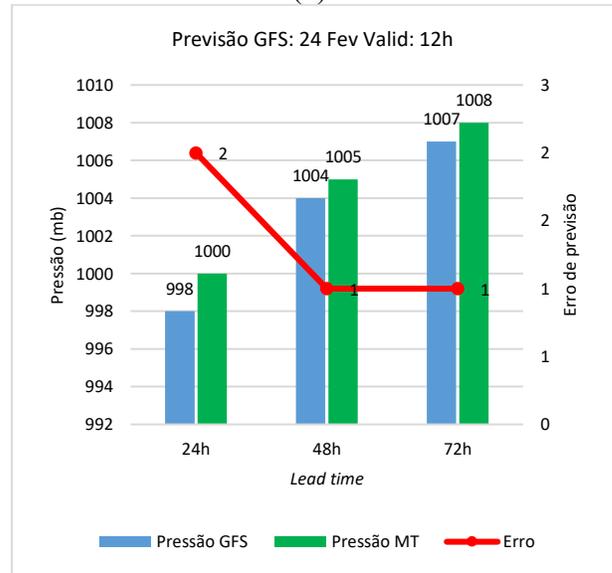
(a)



(b)



(c)



(d)

Figura 5.7: Pressão prevista pelo modelo GFS, pressão dos dados de melhor trajectória e o erro de previsão.

Uma característica notável do modelo GFS é o facto de ter subestimado a intensidade do ciclone Freddy durante todo os dias que esteve sobre o canal de Moçambique e o facto de ter superestimado a intensidade durante os dias em que esteve sobre a região continental. Moses e Romotonto (2018) também avaliaram a habilidade do modelo GFS em prever a intensidade do ciclone Dineo (2017), onde notaram que o modelo subestimou a pressão durante todos os dias analisados. Porém, a análise foi feita apenas durante os dias em que o ciclone Dineo estava sobre o canal de Moçambique porque não havia dados observados após o *landfall*. Portanto, considerando os dias em que o ciclone

Freddy esteve sobre o canal de Moçambique, nota-se que os resultados encontrados nesta pesquisa vão de acordo com os resultados obtidos por Moses e Romotonto (2013).

O erro médio mostra que as previsões de intensidade do modelo GFS é constante para todos os *lead times*, ou seja, o erro de previsão não mostra nenhuma tendência, diferente das previsões de trajetória. Isto mostra que, em média, os erros de previsão da intensidade do ciclone Freddy não dependem do *lead time*, o que está de acordo com as observações feitas por Sridevi et al. (2022). Porém, embora a média dos erros de previsão da intensidade seja a mesma, o gráfico mostra que os maiores erros de previsão ocorrem nas previsões de 48h e 72h, o que mostra alguma semelhança com as previsões de trajetória em termos de erros individuais. A Figura 5.8 mostra o gráfico do erro médio de previsão de intensidade durante o deslocamento para a região Sul de Moçambique.

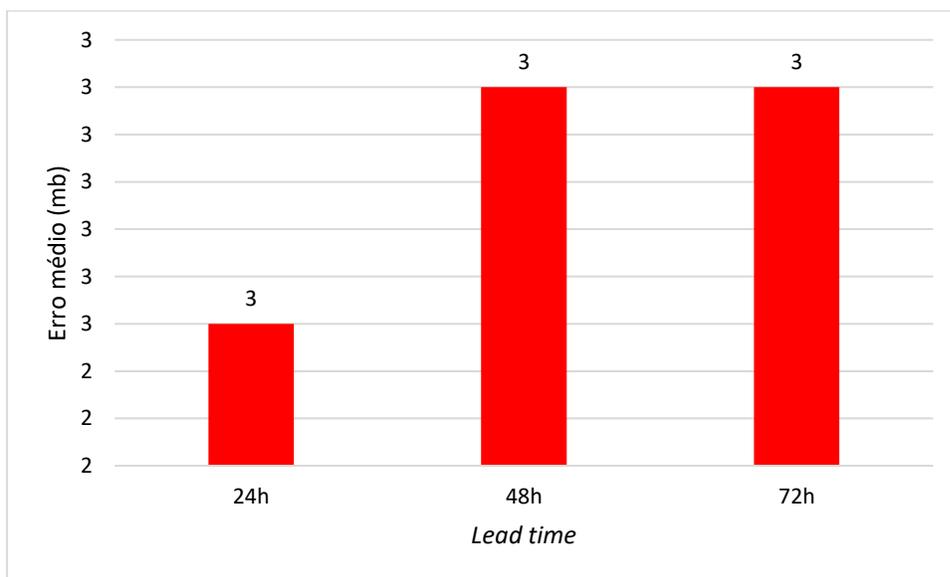
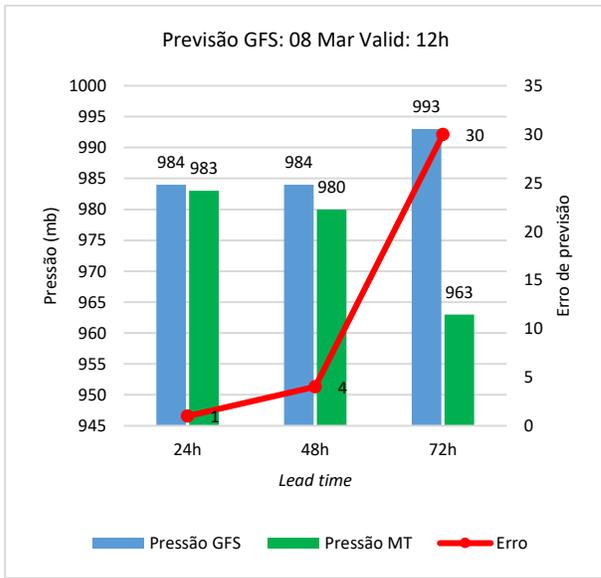


Figura 5.8: Erro médio da previsão de intensidade do ciclone Freddy para o primeiro landfall.

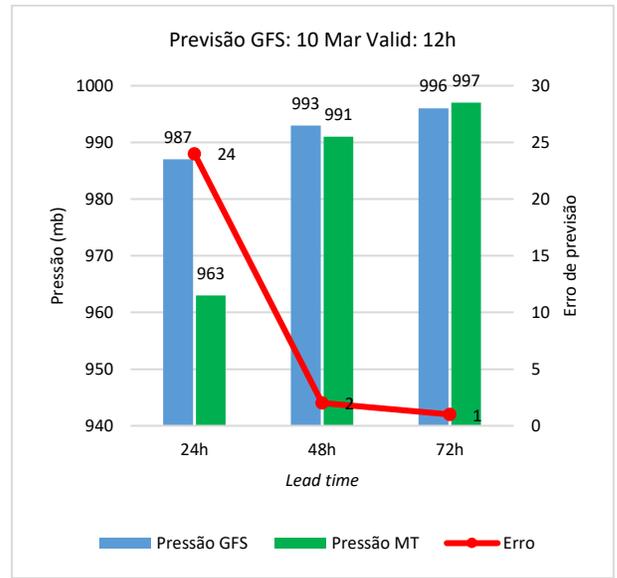
5.2.2. Segundo landfall

O erro de previsão foi avaliado de forma quantitativa também durante o deslocamento para a segunda entrada do ciclone no país. No dia 8 de Março, o modelo subestimou a intensidade do ciclone em todos os *lead times*, porém tal como mostra a Figura 5.9a, para a previsão de 24h o erro foi de 1 mb, o erro da previsão de 48h foi de 4 mb e o erro de previsão de 72h foi de 30 mb tornando-se o maior erro de previsão da intensidade em relação todos os dias analisados. Os resultados

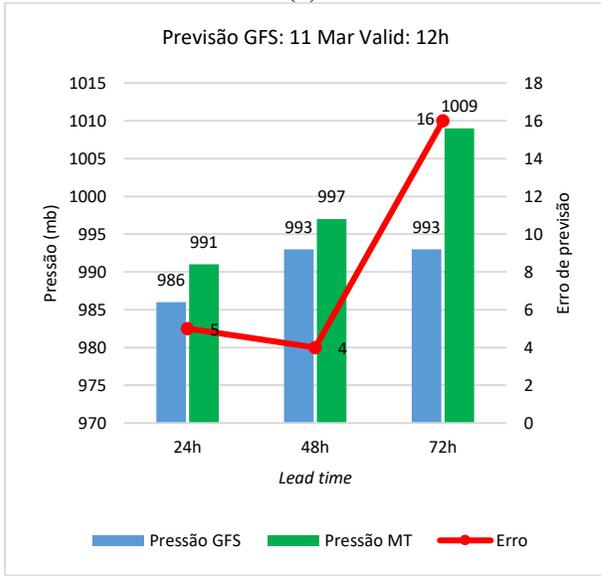
mostram uma tendência de aumento de erro com o aumento do *lead time*. No dia 10 de Março (Figura 5.9b), a previsão de 24h foi de 987 mb, mas os dados de MT mostravam uma pressão de 963 mb, tendo subestimado a intensidade em 24 mb. O modelo também subestimou a intensidade do ciclone em 2 mb na previsão de *lead time* de 48h. Porém, para a previsão de 72h o modelo superestimou a pressão em 1 mb, tendo previsto uma pressão de 996 mb porém os dados de MT indicavam uma pressão de 997 mb. Os erros de previsão da intensidade do dia 10 de Março mostraram uma tendência de diminuição a medida que aumenta o *lead time* embora não haja uma tendência de superestimação ou subestimação. Para o dia 11 de Março (Figura 5.9c), o modelo GFS superestimou a intensidade do ciclone Freddy em todos os *lead times*, se opondo completamente as previsões do dia 8 do mês em análise. A previsão de 24h indicavam uma pressão de 986 enquanto que a pressão dos dados de MT era de 991, tendo superestimado a intensidade em 5 mb. A previsão de 48h teve um erro menor que a previsão de 24h, tendo superestimado a intensidade em 4 mb. O erro de previsão da pressão de 72h mostrou uma pressão de 993 mb, porém os dados de melhor trajetória indicavam o valor de 1009 mb, resultando em um erro de 16 mb. Para o dia 12 de Fevereiro (Figura 5.9d) o modelo previu uma pressão de 1002 mb para 24h de *lead time* enquanto que os dados de MT identificaram uma pressão de 997 mb, o que resultou em um erro de 5 mb, o que indica que o modelo subestimou a pressão. Por outro lado, a previsão de *lead time* de 48h indicou uma pressão de 1006 mb enquanto que os dados de melhor trajetória indicavam um valor de 1009, superestimando a pressão em 3 mb. A Figura 5.9 ilustra, de forma gráfica, os valores de pressão prevista, pressão dos dados de MT e o erro de previsão da pressão.



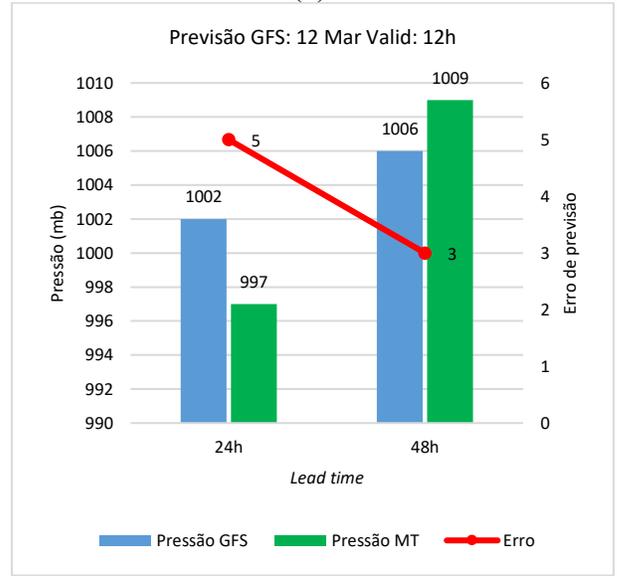
(a)



(b)



(c)



(d)

Figura 5.9: Pressão prevista, pressão dos dados de Melhor trajectória e o erro de previsão da pressão.

O erro médio indica que os erros de previsão da intensidade para 24h de lead time é maior que os de 48h, contrariando a tendência de todas as previsões que foram avaliadas até então. Como em todas as análises anteriores, o erro médio indica que as previsões de 72h são as que mais se desviam do valor observado. A Figura 5.10 ilustra os erros médios de previsão da intensidade do ciclone durante o deslocamento para o segundo *landfall*.

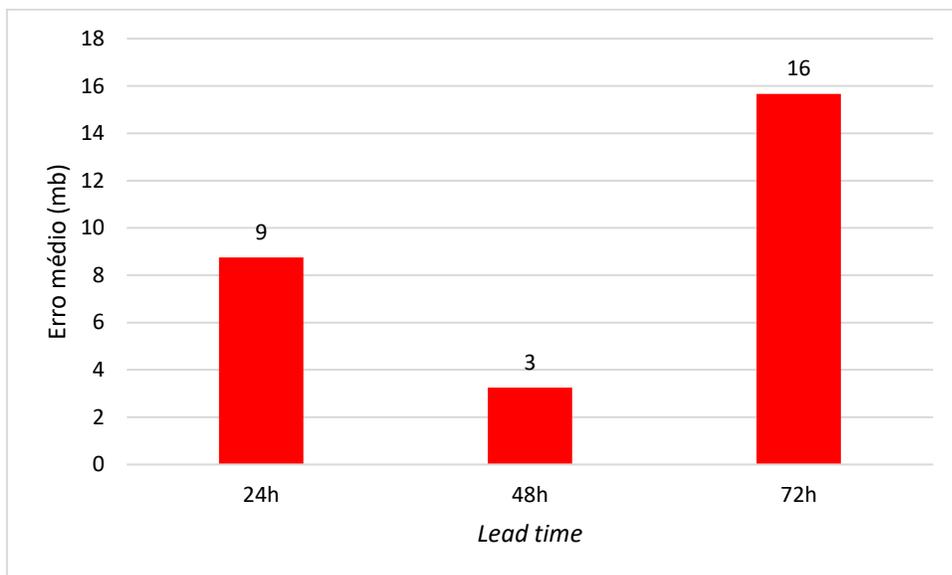


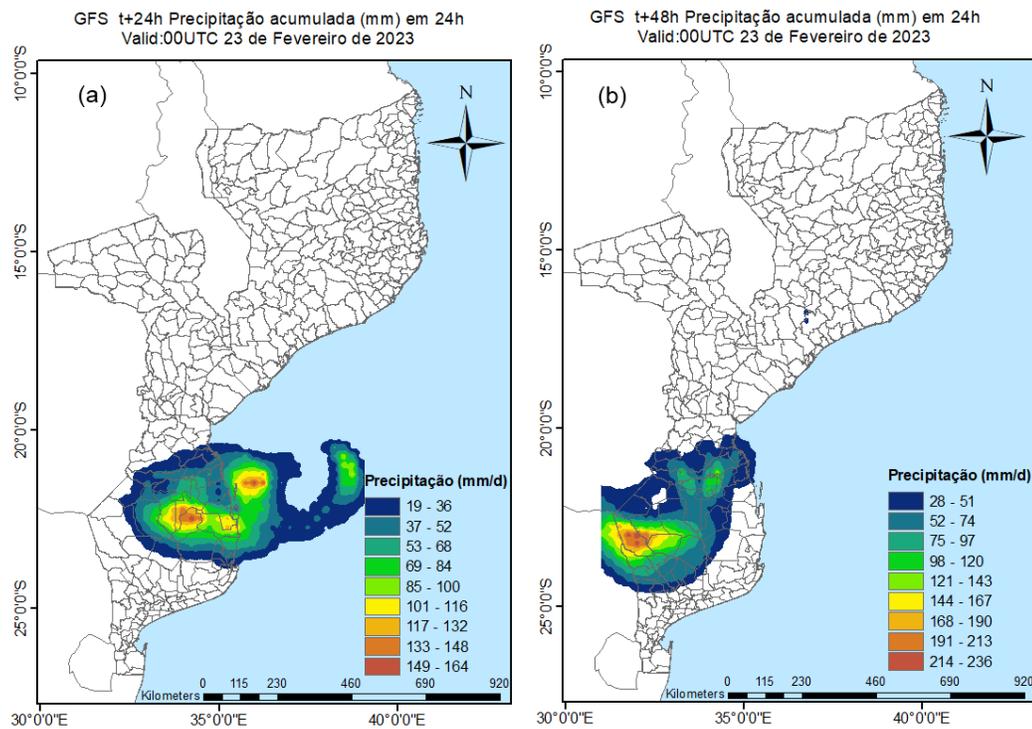
Figura 5.10: Erro médio da previsão da intensidade do ciclone Freddy para todos os lead times durante o deslocamento para o segundo landfall.

Os resultados apresentados na Figura 5.10 têm uma semelhança e uma diferença com os erros apresentados na avaliação do primeiro *landfall*. A semelhança é que em ambos casos (primeiro *landfall* e segundo *landfall*) deixam claro que não há uma relação entre o *lead time* e o desempenho do modelo GFS. A diferença é que os erros do primeiro *landfall* são inferiores aos erros do segundo *landfall*. Isto mostra que as dificuldades que o modelo GFS tem em prever a trajetória a medida que se aproxima do equador (latitudes mais baixas) são os mesmos que o modelo apresenta para prever a intensidade. De acordo com Cangialosi et al. (2020), a previsão da trajetória do ciclone tropical sofreu melhorias significativas durante a última metade do século passado. Porém, os erros de previsão da intensidade não sofreram mudanças significativas no mesmo período. No entanto, recentemente tem se notado uma redução significativa dos erros da previsão da intensidade (Cangialosi et al., 2020; Wang et al., 2023).

5.3. Avaliação da previsão da precipitação

5.3.1. Primeiro *landfall*

As previsões da precipitação acumulada em 24h foram avaliadas com base em observações da precipitação acumulada para 24h e 48h de *lead time*. Os dados observacionais da precipitação para a primeira entrada do ciclone em Moçambique estavam disponíveis apenas para a província de Gaza. Por padrão, a precipitação acumulada de um determinado dia é registada no dia seguinte (WMO, 2012). Assim a precipitação do dia 24 de Fevereiro foi registada no dia 25, a precipitação do dia 25 foi registada no dia 26 de Fevereiro e assim por diante. A Figura 5.11 ilustra a distribuição espacial da precipitação acumulada em 24h prevista pelo modelo GFS às 00UTC. A esquerda são previsões da precipitação de 24h de *lead time* e a direita são previsões da precipitação de 48h de *lead time*. A Figura 5.11a e b são previsões do dia 23 de Fevereiro, a Figura 5.11c e d são previsões do dia 24 de Fevereiro e a Figura 5.11e e f são previsões do dia 25 de Fevereiro.



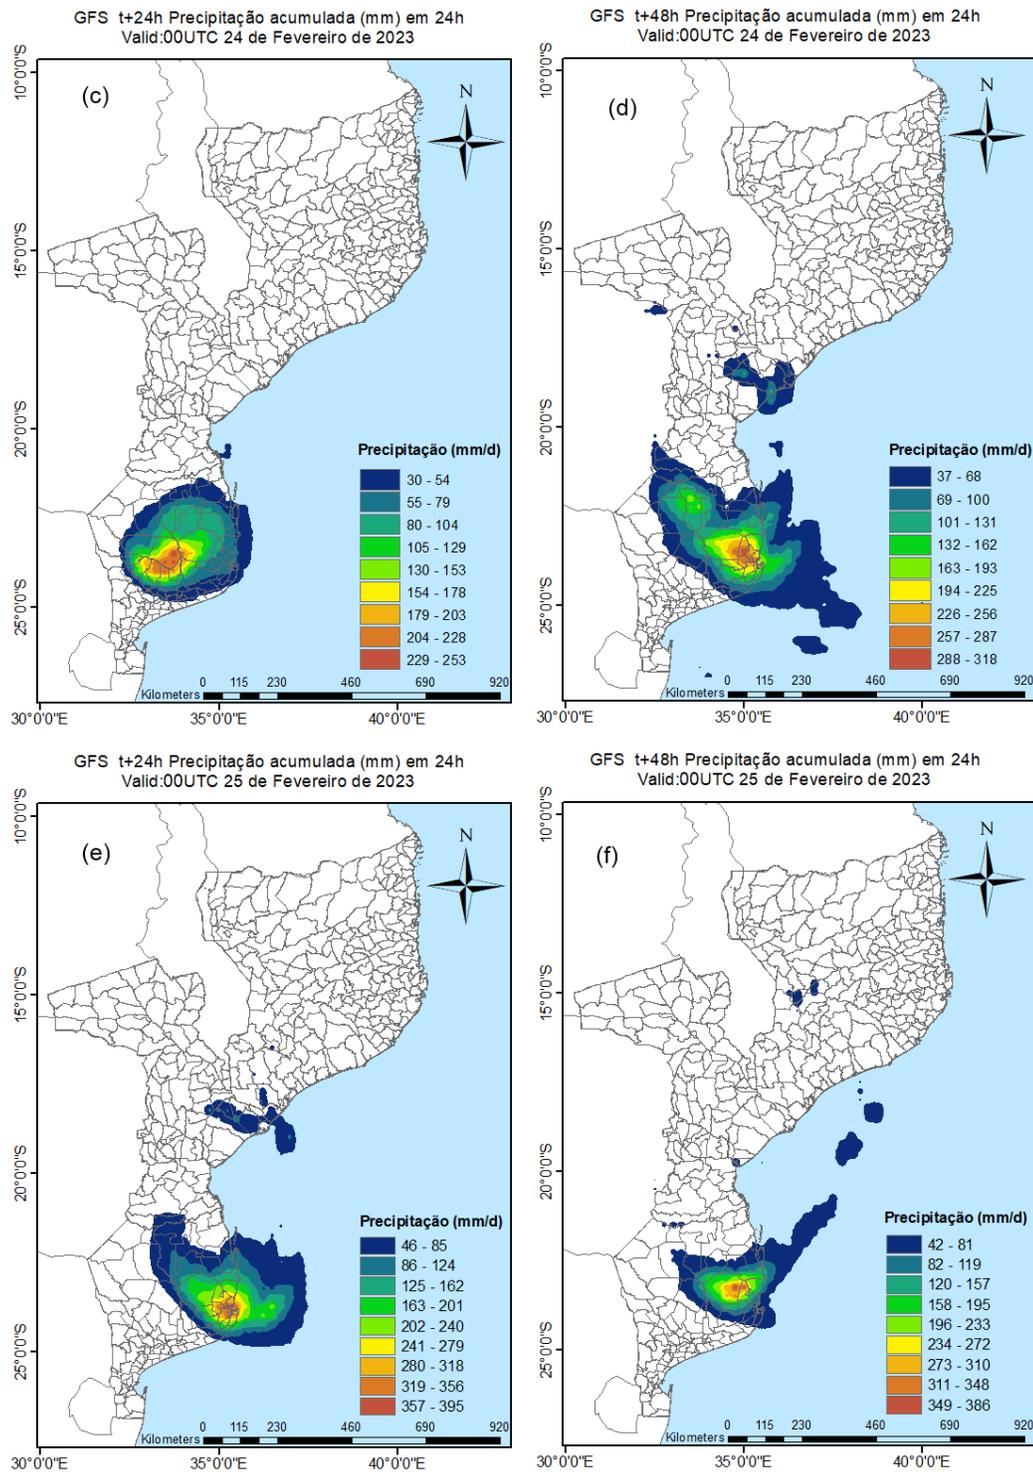
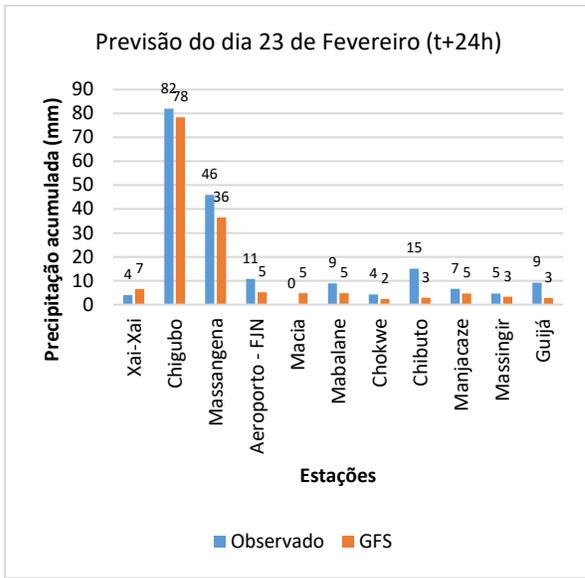


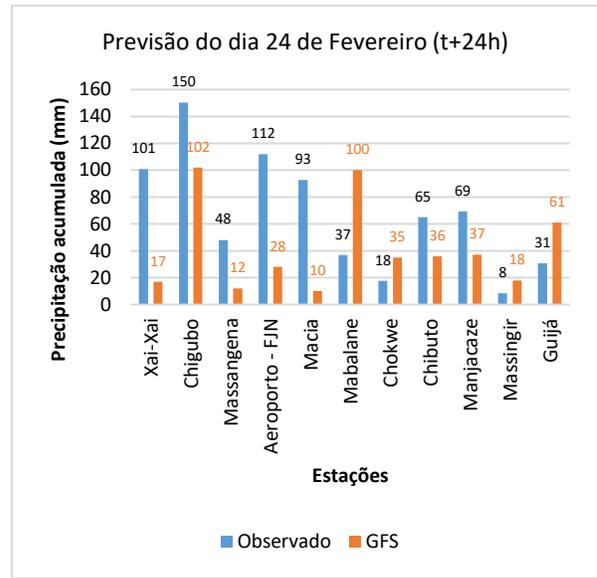
Figura 5.11: Precipitação acumulada prevista pelo modelo GFS. A data registada em cada figura refere-se a data em que a previsão foi realizada. Assim a previsão do dia 23 de Fevereiro é ilustrada na Figura (a e b), 24 de Fevereiro (b e c) e 25 de Fevereiro (“e” e f). A esquerda são previsões de 24h de *lead time* e a direita são previsões de 48h de *lead time*. As previsões foram realizadas as 00UTC de cada dia.

A avaliação da precipitação foi feita de forma quantitativa através da comparação da precipitação observada com a precipitação prevista para o mesmo ponto onde se encontra a estação de observação. A Figura 5.12 ilustra a comparação entre a precipitação acumulada observada e prevista de 24h de *lead time*. Os resultados mostram que o modelo subestimou a precipitação acumulada do dia 24 de Fevereiro (previsão do dia 23 de Fevereiro) para a maior parte das estações excepto para a estação de Xai-Xai e Macia onde o modelo superestimou a precipitação (Figura 5.12a). Isso significa que para a maior parte das estações o modelo previu uma precipitação acumulada inferior a precipitação observada, porém para Xai-Xai e Macia o modelo previu uma precipitação superior a precipitação observada. As previsões do dia 23 de Fevereiro mostram uma característica interessante do modelo; Embora o modelo não tenha sido capaz de prever com precisão a precipitação observada, ele foi capaz de acompanhar a tendência dos volumes acumulados. Ou seja, para estações onde ocorreram precipitações maiores, o modelo previu precipitações maiores e vice-versa. As previsões do dia 24 de Fevereiro mostram que o modelo teve um comportamento relativamente parecido com as previsões do dia anterior (Figura 5.12b). Porém para o dia 25 de Fevereiro (Figura 5.12c), os resultados mostram que as previsões têm um equilíbrio entre previsões superestimadas e subestimadas, mas o comportamento observado nas previsões do dia 23 de Fevereiro permanece, onde o modelo mostrou que consegue acompanhar as quantidades do volume acumulado, embora não consiga quantificar com precisão.

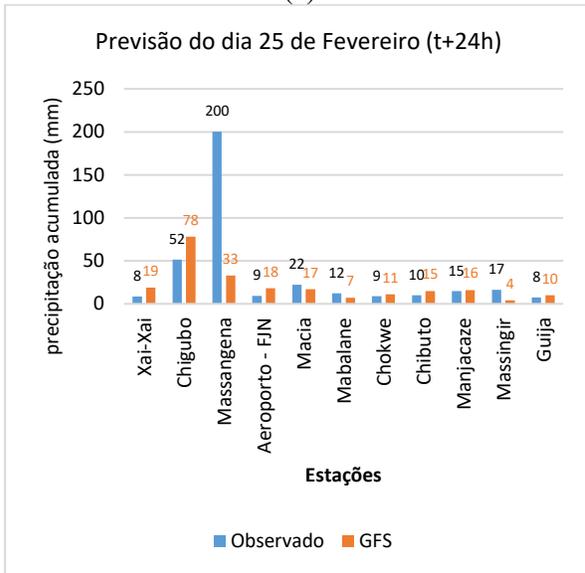
A melhor previsão da precipitação acumulada do modelo GFS foi a do dia 25 de Fevereiro para a estação de Manjacaze, onde o modelo previu uma precipitação de 16 mm e foi observado uma precipitação de 15 mm, resultando num erro de 1 mm apenas. Porém no mesmo dia foi também realizada a pior previsão da precipitação acumulada para a estação de Massangena. O modelo previu uma precipitação de 33 mm, porém foi observado um total acumulado de 200 mm na estação de Massangena (Figura 5.12c), resultando num erro de 167 mm.



(a)



(b)



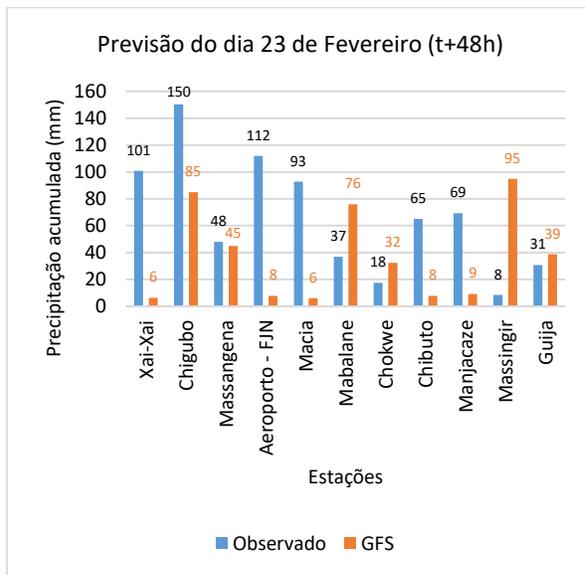
(c)

Figura 5.12: Precipitação acumulada em 24h observada nas estações de superfície e precipitação prevista pelo modelo GFS. À esquerda mostra previsão e observação da precipitação do dia 23 e do dia 25 de Fevereiro e a direita a precipitação acumulada prevista pelo modelo GFS junto com a precipitação observada do dia 24 de Fevereiro.

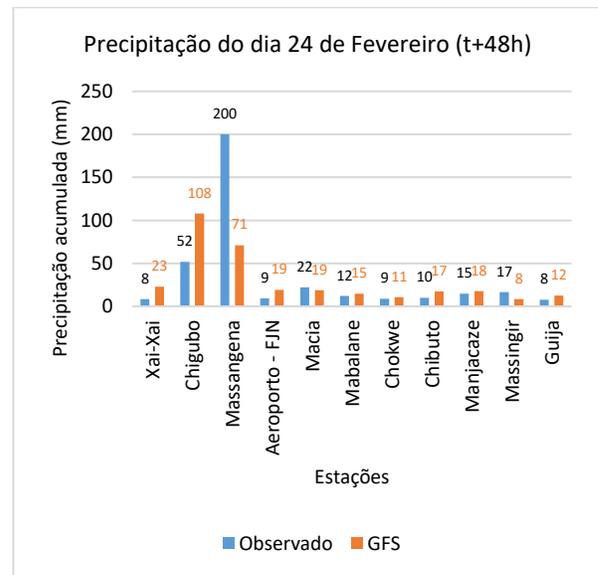
A habilidade do modelo foi também testada para previsões de 48h de *lead time* da precipitação acumulada em 24h (Figura 5.13). As previsões de 48h de *lead time* referem-se à precipitação de dois dias a frente do dia da previsão. Desse modo, as previsões da precipitação acumulada realizadas no dia 23 de Fevereiro são referentes a precipitação acumulada do dia 25 de Fevereiro.

Similarmente, as previsões realizadas no dia 24 de Fevereiro são referentes a precipitação acumulada do dia 26 de Fevereiro.

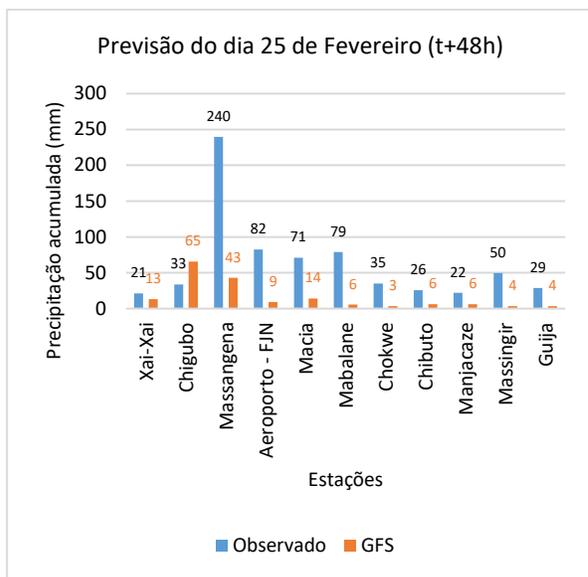
As previsões do dia 23 de Fevereiro (Figura 5.13a) mostram um equilíbrio entre a precipitação subestimada e superestimada, não mostrando uma tendência clara. Porém a previsão do dia 24 de Fevereiro (Figura 5.13b) mostra que o modelo superestimou a precipitação acumulada observada na maior parte das estações de observação. No dia 25 de Fevereiro (Figura 5.13c), as previsões de 48h de *lead time* mostram que o modelo subestimou a precipitação acumulada observada na maior parte das estações, excepto para a estação de Chigubo, onde superestimou o valor da precipitação da estação com uma diferença de 32 mm do valor observado. A melhor previsão foi a do dia 24 de Fevereiro, onde o modelo previu uma precipitação de 11 mm e foi observada uma precipitação acumulada de 9 mm (Figura 5.13b), resultando num erro de 2 mm. A pior previsão foi realizada no dia 25 de Fevereiro, onde o GFS previu uma precipitação de 43 mm, porém foi registada uma precipitação de 240 mm na estação de Massangena (Figura 5.13c), resultando num erro de 197 mm.



(a)



(b)



(c)

Figura 5.13: Precipitação acumulada em 24h observada nas estações de superfície e a precipitação prevista pelo modelo GFS. As previsões são de 48h de lead time para os dias 23 (a), 24 (b) e 25 (c).

A habilidade do modelo foi avaliada em termos quantitativo através do cálculo da raiz do erro médio quadrático (RMSE). É calculado usando a fórmula apresentada na secção 3.6.2. Esta métrica permite saber o quão bom um modelo é para prever uma determinada variável (Wang & Lu, 2018; Hodson, 2022). A Figura 5.14 ilustra os resultados obtidos ao calcular o RMSE do modelo GFS para previsões de 24h e 48h de *lead time*. Os resultados mostram que o modelo tem menor precisão para prever grandes volumes de precipitação. Tal como indica a Figura 5.14a, o RMSE é menor para previsões de 24h de *lead time* do dia 23 de Fevereiro, que foi na verdade antes da chegada do ciclone Freddy na província de Gaza, tendo atingido apenas estações de Chigubo e Massangena. Isto resultou em precipitações muito baixas na maior parte das estações da província, onde algumas não registaram nenhuma precipitação. Porém, no dia 25 de Fevereiro (previsões do dia 24 de Fevereiro), nota-se que o RMSE é muito maior que o das revisões do dia 23 de Fevereiro. Neste dia grande parte das estações registaram precipitações superiores a 40 mm e modelo mostrou menos habilidade de prever as precipitações acumuladas. O mesmo prevalece para as previsões do dia 25 de Fevereiro (24h de *lead time*).

Para previsões de 48h de *lead time* mostram também que o RMSE é maior que as previsões de 24h de *lead time* excepto para previsões do dia 24 de Fevereiro, onde os resultados mostram que o RMSE é de 43 mm. Isto pode ter duas razões: primeiro porque a precisão do modelo de previsão tende a reduzir à medida que aumenta o *lead time*; Segundo porque o próprio modelo GFS tem menos habilidade de prever precipitações mais altas. Além disso, é importante notar que a própria métrica usada para avaliar os erros de previsão do modelo GFS (o RMSE) é sensível a valores fora do padrão (*outliers*) (Olumide, 2023), ou seja, grandes erros de previsão podem afectar o resultado final do RMSE.

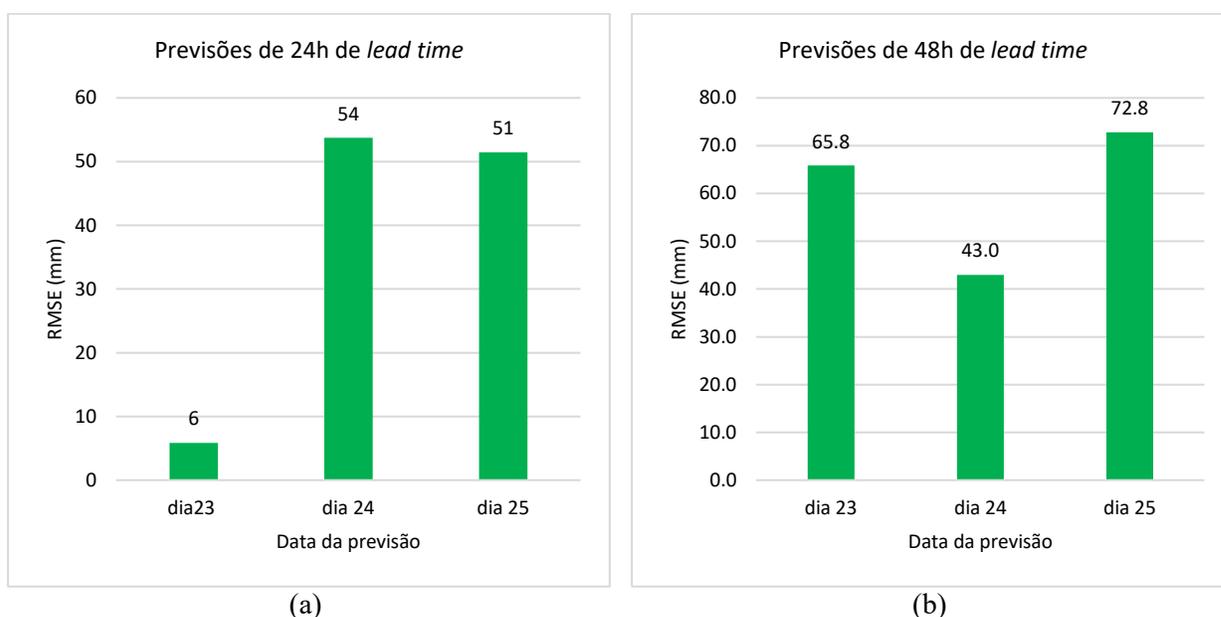


Figura 5.14: Raiz do erro médio quadrático médio das previsões de precipitação acumulada em 24h. O RMSE foi calculado para previsões de 24h (a) e 48h (b) de *lead time*.

A habilidade do modelo GFS foi testando também para a previsão da precipitação máxima em termos quantitativos e a habilidade de o modelo prever o ponto onde a precipitação máxima poderia ocorrer. Esta avaliação foi feita apenas para a província de Gaza, visto que é o único local onde havia dados observacionais da precipitação do ciclone Freddy com uma densidade relativamente maior (pelo menos uma estação por distrito). A avaliação quantitativa é apresentada na Figura 5.15 e a avaliação espacial da precipitação máxima é apresentada na Tabela 5.1 e na Tabela 5.2 para previsões de 24h e 48h de *lead time*, respectivamente.

Os resultados mostram que a precipitação máxima acumulada diária ocorreu apenas nos distritos de Chigubo e Massangena durante os dias analisados. Além disso, notou-se que o modelo GFS superestimou a precipitação máxima no distrito de Chigubo e subestimou a precipitação no distrito de Massangena para todos os *lead times* (veja a Figura 5.15a e b). De acordo com a trajetória do ciclone Freddy, a estação de Chigubo estava mais próxima do centro do ciclone Freddy em relação à estação de Massangena. Isto mostra que o modelo GFS tende a prever mais precipitação próximo do centro do ciclone e menos precipitação acumulada nas bordas do ciclone (por exemplo, a estação de Massangena). No passado, esse comportamento foi observado por outros autores ao avaliarem outros modelos de previsão, por exemplo (Marchock et al., 2007; Chen et al., 2018).

Em termos quantitativos o modelo mostrou maior precisão para a previsão do dia 23 de Fevereiro para 24h de *lead time*. Nesta data o modelo previu uma precipitação máxima de 85 mm mas foi observada uma precipitação máxima de 82 mm, tendo superestimado a precipitação em 3 mm. De acordo com o modelo GFS a precipitação máxima acumulada do dia 24 de Fevereiro (previsão de 24h do dia 23 de Fevereiro) iria ocorrer a (22.50°S, 33.25°E), porém a precipitação máxima ocorreu a (22.83°S, 33.52°E) que corresponde à estação de Chigubo. Esses dois pontos se encontram a uma distância de 45.9 km, o que pode ser considerado razoável considerando que de acordo com Reboita et al. (2017), os ciclones tropicais têm em média um diâmetro entre 500 a 1000 km. É importante notar que essa foi a precipitação máxima acumulada mais baixa de todos os registros. Previsões da precipitação máxima acumulada no dia 25 de Fevereiro (previsão do dia 24 para 24h de *lead time*) mostram que o modelo GFS superestimou a precipitação em 104 mm, tendo sido previsto uma precipitação acumulada de 254 mm e observado 150 mm de precipitação acumulada máxima. A distância entre a estação que registou a precipitação máxima acumulada diária e a previsão do modelo GFS reduziu para 43.6 km.

Para previsões de 48h de *lead time*, as previsões mostram que a precipitação máxima acumulada reduziu a medida que o ciclone Freddy se deslocava para o interior da região Sul de Moçambique, porém os dados observacionais mostram que a precipitação máxima acumulada foi aumentando nesse mesmo intervalo. A Figura 5.15 mostra a precipitação máxima acumulada observada e prevista em forma de gráficos de barras.

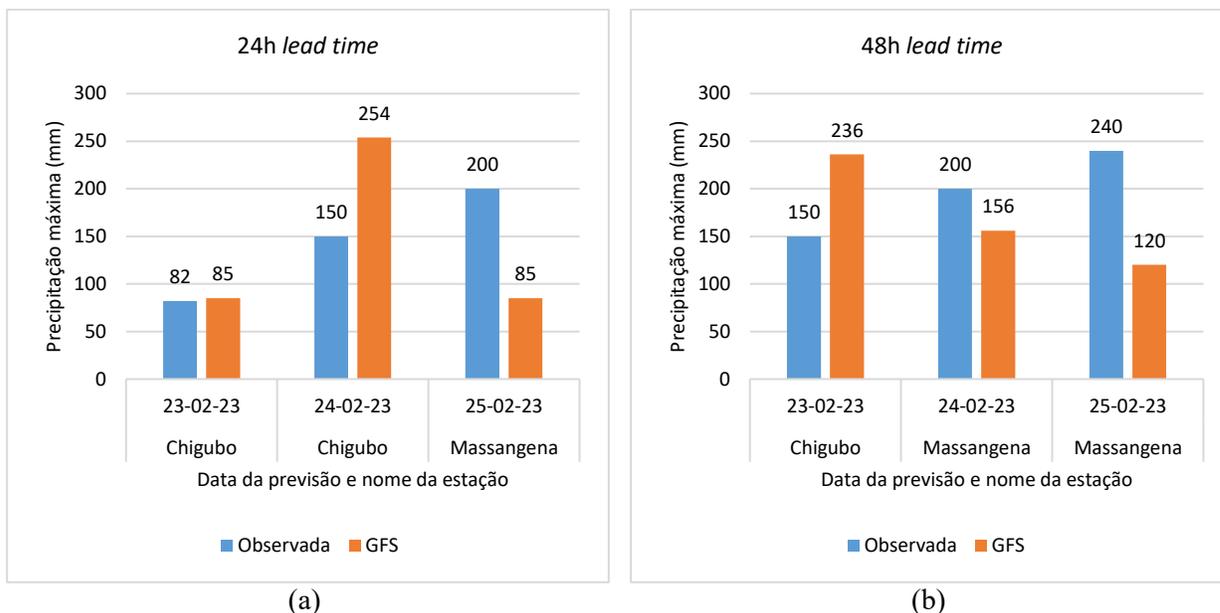


Figura 5.15: Precipitação máxima acumulada em 24h observada e precipitação máxima prevista pelo modelo GFS. As previsões são de lead times de 24h (a) e 48h (b).

A precipitação máxima acumulada em 24h foi avaliada em termos espaciais. De acordo com os resultados apresentados nas Tabelas 5.1 e 5.2, não existe uma clara dependência entre a previsão do ponto de ocorrência da precipitação máxima e o *lead time*. Por exemplo, para a estação de Chigubo, a distância entre o ponto de precipitação máxima prevista pelo modelo GFS e a estação de Chigubo aumentou com o *lead time*, mas não se verificou o mesmo em relação a estação de Massangena, onde ponto previsto manteve-se constante. A Tabela 5.1 e a Tabela 5.2 ilustram os dados das coordenadas da estação que registou a precipitação máxima acumulada e as coordenadas do ponto de precipitação máxima prevista pelo modelo GFS.

Tabela 5.1: Ponto central da precipitação máxima observada e prevista pelo modelo GFS para 24h de lead time.

Nome da estação	Data da previsão	Coordenada da estação		Coordenada do GFS		Distância entre os pontos (km)
		Lat (°S)	Lon (°E)	Lat (°S)	Lon (°E)	
Chigubo	23-02-23	22.83	33.52	22.50	33.25	45.9
Chigubo	24-02-23	22.83	33.52	23.50	33.75	43.6
Massangena	25-02-23	21.55	32.97	23.25	33.75	205.3

Tabela 5.2: Ponto central da precipitação máxima observada e prevista pelo modelo GFS para lead time de 48h.

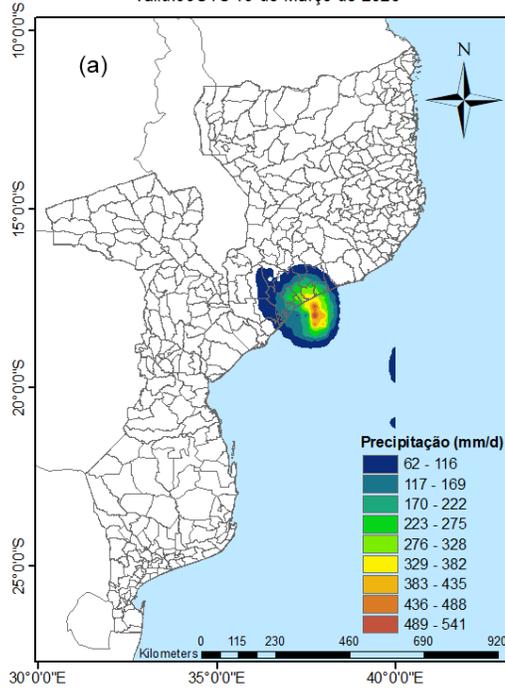
Nome da estação	Data da previsão	Coordenada da estação		Coordenada do GFS		Distância entre os pontos (km)
		Lat (°S)	Lon (°E)	Lat (°S)	Lon (°E)	
Chigubo	23-02-23	22.83	33.52	23.00	32.00	156.8
Massangena	24-02-23	21.55	32.97	22.00	33.25	57.79
Massangena	25-02-23	21.55	32.97	23.25	33.75	205.3

Os dados apresentados na tabela são muito melhores em relação aos resultados obtidos por Moses e Romotonto (2018). Estes autores estudaram o desempenho do modelo GFS em prever a precipitação do ciclone Dineo (2016). Isso mostra que o modelo GFS sofreu grandes melhorias desde o ano de 2017. Porém, é importante notar que a habilidade de previsão quantitativa da precipitação pode variar de acordo com a localização, estação, intensidade e o tipo de sistema em questão (Cuo et al., 2011).

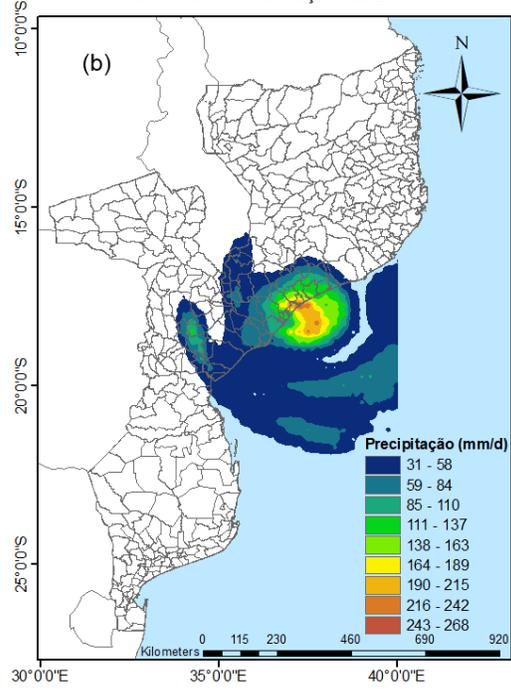
5.3.2. Segundo *landfall*

A habilidade de previsão da precipitação do modelo GFS foi avaliada também para a região Centro de Moçambique. Infelizmente apenas dados da precipitação acumulada da estação de Quelimane é que estavam disponíveis. Além disso, no dia 12 de Março não foi registada a precipitação acumulada, ou seja, a precipitação que caiu no dia 11 de Março não tem registo. A Figura 5.16 ilustra a distribuição espacial da precipitação prevista pelo modelo GFS durante o seu deslocamento na região Centro do país. Tal como na secção anterior, aqui apenas foram incluídos os dados a partir da data do *landfall* (11 de Março). Tal como na Figura 5.11, a Figura 5.16 ilustra as previsões de 24h e 48h de *lead time*, à esquerda e à direita, respectivamente. A Figura 5.16a e b são previsões do dia 10 de Março, a Figura 5.16c e d são previsões do dia 11 de Março e a Figura 5.16e e f são previsões do dia 12 de Março.

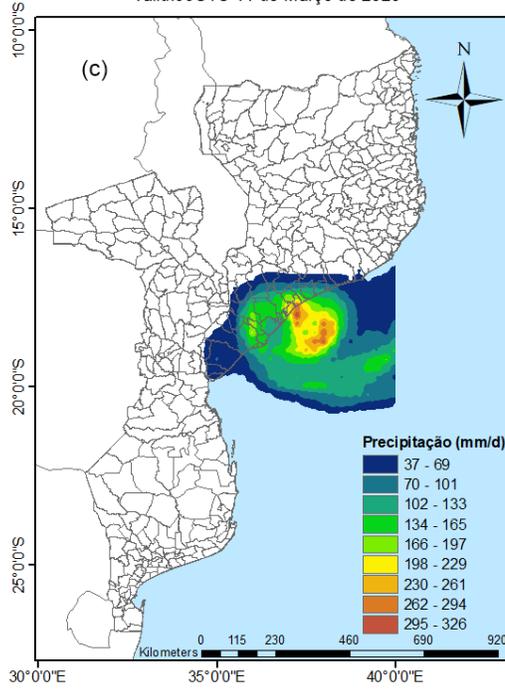
GFS t+24h Precipitação acumulada (mm) em 24h
Valid:00UTC 10 de Março de 2023



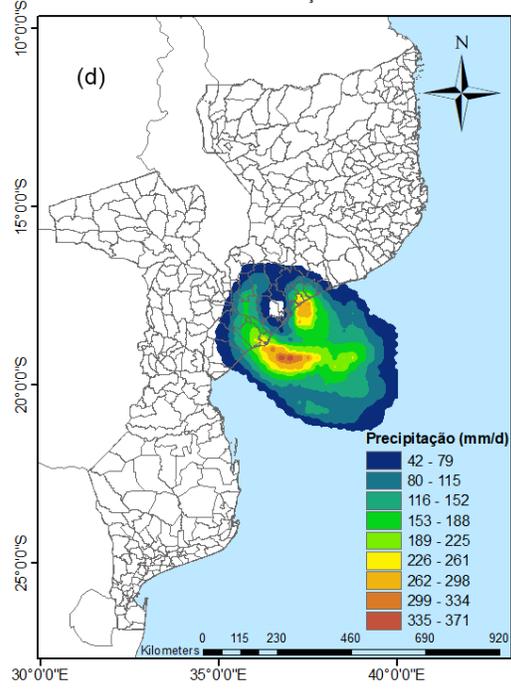
GFS t+48h Precipitação acumulada (mm) em 24h
Valid:00UTC 10 de Março de 2023



GFS t+24h Precipitação acumulada (mm) em 24h
Valid:00UTC 11 de Março de 2023



GFS t+48h Precipitação acumulada (mm) em 24h
Valid:00UTC 11 de Março de 2023



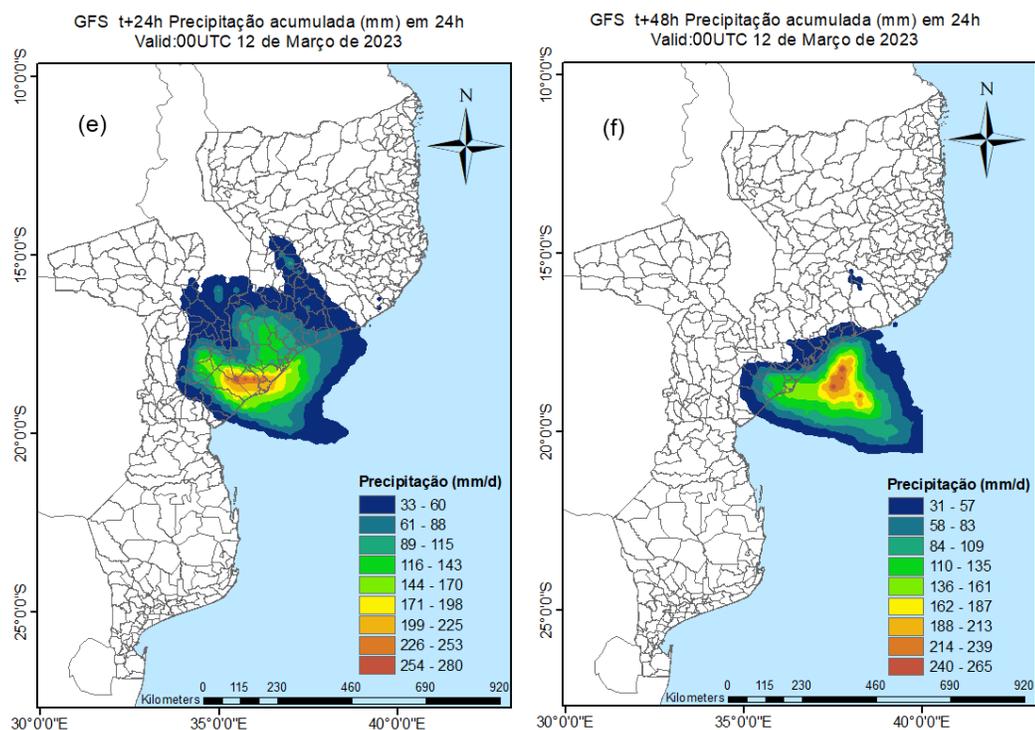


Figura 5.16: Precipitação acumulada em 24h prevista pelo modelo GFS durante o segundo landfall do ciclone Freddy. À esquerda são previsões de 24h de lead time e a direita são previsões de 48h de lead time. Estas previsões foram realizadas as 00UTC.

A avaliação feita para o primeiro *landfall* foi feita também feita para o segundo *landfall*. Foi comparada a precipitação acumulada prevista pelo modelo GFS com a precipitação observada na estação de Quelimane. Os resultados mostram que o modelo superestimou a precipitação em todas as previsões. O erro de previsão para 24h de *lead time* dos dias 11 e 12 de Março foi aproximadamente o mesmo. A melhor previsão foi a previsão de 48h de *lead time* realizado no dia 11 de Março (referente a precipitação do dia 13 de Março), o modelo previu uma precipitação de 69 mm e foi observado uma precipitação acumulada de 34 mm resultando num erro de 30 mm. A Figura 5.17 ilustra a comparação das previsões do modelo GFS e as observações da precipitação acumulada para de 24h e 48h de *lead time* à esquerda e à direita, respectivamente. Devido a falta de dados não foi possível realizar o cálculo da RMSE.

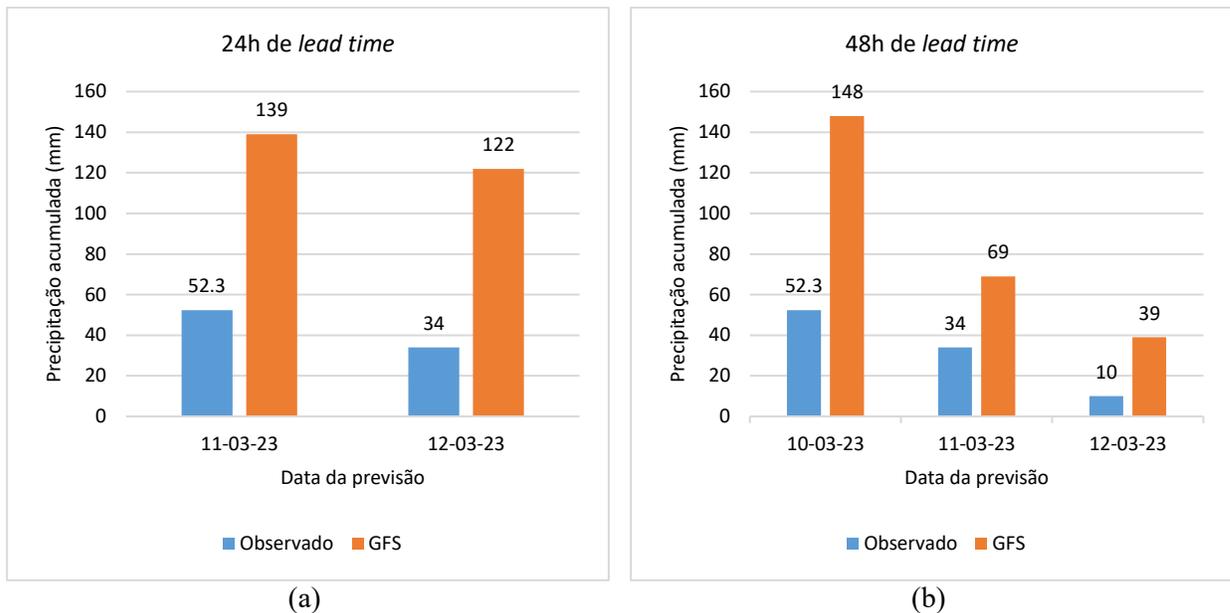


Figura 5.17: Precipitação observada (barras azuis) na estação de Quelimane durante o segundo landfall do ciclone Freddy e as previsões do modelo GFS (barras cor de laranja) para lead time de 24h (à esquerda) e 48h (à direita).

Embora o modelo GFS não tenha tido um bom desempenho para prever a precipitação acumulada em termos quantitativos, ele foi capaz de detectar a redução da precipitação associada ao deslocamento do ciclone Freddy sobre a terra firme desde o dia 11 de Março em diante. Os ciclones tropicais tendem a reduzir a sua intensidade e a respectiva precipitação associada a medida que se deslocam sobre terra firme uma vez que perdem a sua fonte de energia que são as águas quentes dos oceanos (Han et al., 2022). Por esse motivo, embora o clone Freddy tenha enfraquecido depois do primeiro *landfall* no Sul de Moçambique, o ciclone Freddy voltou a se intensificar quando retornou as águas quentes do canal de Moçambique (La Reunion, 2023i).

Tartaglione et al. (2005) afirmam que deve-se tomar muito cuidado quando a verificação da precipitação modelada é realizada sobre um domínio menor que a resolução do modelo. Isto porque os modelos numéricos fornecem informações médias de área sobre pontos de grade, não valores pontuais. Além disso, prever a precipitação é desafiador porque ela é uma variável descontínua e varia rapidamente no espaço e no tempo (Habets et al., 2004; Shrestha et al., 2013). A principal dificuldade é que o processo de precipitação depende não apenas da situação sinóptica, mas também dos processos condensacionais em escala de sub-grade, das transições de fase entre vapor de água, água da nuvem e gelo, respectivamente, e nos transportes convectivos verticais de calor e

humidade (e momento) (Damrath et al., 2000). É importante recordar que uma das fontes de erros na previsão quantitativa da precipitação de ciclones tropicais é o erro da previsão de trajectória (Marchock et al., 2007). Isso pode explicar o porquê de na maior parte das vezes o modelo GFS tenha sido incapaz de detectar com exatidão precipitação associada ao ciclone Freddy. Como foi possível ver nos resultados da avaliação das previsões de trajectória, o modelo apresentou uma baixa precisão para prever a trajectória do ciclone Freddy, especialmente para a região Norte de Moçambique. De alguma forma essa dificuldade em prever a trajectória do ciclone afectou a previsão da precipitação. Por exemplo, embora o modelo tenha previsto com alguma precisão a trajectória do ciclone Freddy durante o seu deslocamento para o primeiro *landfall*, o facto de as previsões estarem mais aceleradas que as observações, implica que mesmo que o modelo faça uma boa previsão quantitativa da precipitação, essa precipitação não irá ocorrer no momento previsto, ocasionando um alarme falso.

Estudos passados sobre avaliação de modelos de previsão mostraram que é difícil ter uma rede de estações meteorológicas suficientes para obter resultados satisfatórios. Por isso Alguns autores acreditam que um número maior de estações de observação pode melhorar os resultados da avaliação dos modelos de previsão numérica de tempo (Shrestha et al., 2013; Moses & Ramotonto, 2018). Essa pode ser uma das razões pelas quais os resultados da avaliação do modelo GFS não tenha sido muito satisfatório. Por exemplo, se o ponto onde o modelo GFS previu a precipitação máxima tivesse alguma estação de observação, permitiria uma comparação mais justa entre a previsão da precipitação máxima acumulada e observada. Mesmo que o local onde foi prevista a precipitação máxima tenha realmente ocorrido a maior precipitação não há como saber visto que não há nenhuma estação de observação para registar a precipitação no local. De acordo com Habets (2004), um pequeno erro de previsão da localização da precipitação pode resultar em ocorrência da precipitação em um local inesperado. Por isso, ter uma densidade de estações relativamente alta pode permitir uma maior confiabilidade nos resultados da avaliação do modelo.

Existem poucos esquemas de validação voltados especialmente para avaliação das previsões de precipitação de ciclones tropicais (Chen et al., 2018). O método usado nesta pesquisa para avaliação do modelo GFS é uma abordagem tradicional comumente usada para avaliar a qualidade das previsões dos modelos de previsão numérica de tempo. Porém, este tipo de abordagem, onde a

precipitação prevista é comparada ponto-a-ponto com a precipitação observada, apesar de simples de calcular e entender, muitas vezes não levam em conta a correlação espacial intrínseca existente entre a variável e o domínio espacial. Os resultados desses métodos de verificação padrão são muitas vezes difíceis de interpretar em termos físicos significativos (Casati et al., 2008). Por essa razão os resultados desta pesquisa podem não ser úteis para todos tipos de usuários de modelos globais de previsão do tempo. Mesmo assim, o esquema de validação usado nesta pesquisa pode ser usado para identificar limitações e vieses do modelo e orientar esforços futuros para o desenvolvimento e melhoria do modelo (Marchock et al., 2007).

Algumas novas abordagens que abordam especificamente a verificação de previsões definidas em domínios espaciais foram desenvolvidas na última década. Estas abordagens levam em conta a natureza espacial dos campos de previsão e visam fornecer feedback sobre a natureza física do erro de previsão, acrescentando informações novas e complementares aos métodos tradicionais de verificação categórica e contínua (Casati et al., 2008). Portanto, uma avaliação do modelo GFS usando outros métodos é aceitável pois pode permitir perceber se o modelo apresenta o mesmo desempenho sob outras métricas de avaliação.

Capítulo 6 – Conclusões

6.1. Conclusões

O principal objectivo do presente trabalho era avaliar a habilidade do myDewetra na previsão da precipitação induzida pelo ciclone Freddy. Uma vez que o myDewetra é composto por diferentes modelos de previsão, foi avaliado apenas o modelo GFS. Visto que a precipitação pode ser fortemente afectada pela trajectória e intensidade do ciclone tropical, notou-se a necessidade de avaliar também a habilidade do modelo GFS em prever trajectória e intensidade do ciclone Freddy. Por isso, várias métricas foram identificadas como críticas para avaliar o desempenho do modelo GFS em prever a precipitação do ciclone Freddy. Essas características incluem a habilidade do modelo prever a precipitação máxima acumulada em 24h, o ponto onde a precipitação máxima iria ocorrer, a habilidade do modelo em prever a quantidade da precipitação acumulada observada nas diferentes estações meteorológicas atingidas pelo ciclone Freddy. Além disso era importante perceber a habilidade do modelo prever a pressão central mínima do ciclone Freddy e também a localização do centro do ciclone que nos permite avaliar as previsões da trajectória.

Os resultados desta avaliação mostram que o modelo GFS teve bom desempenho para prever a trajectória do ciclone, porém as previsões eram mais aceleradas em relação aos dados de MT. Como consequência, o modelo é capaz de prever com alguma precisão os locais por onde o ciclone irá passar, porém o momento exacto não é bem previsto. Além disso o modelo GFS mostrou ter melhor desempenho para prever a trajectória durante o deslocamento do ciclone Freddy para o primeiro *landfall* na região Sul de Moçambique em relação ao deslocamento para região Centro. As previsões de trajectória para a região Norte pioraram principalmente depois do *landfall*. No geral, o uso e cobertura do solo, a rugosidade e a humidade pode afectar a trajectória do ciclone. Caso estas características presentes na região continental não sejam incorporados no modelo, podem afectar a previsão da trajectória. Apesar disso, o modelo GFS previu com precisão o ponto e o momento de entrada do ciclone Freddy na província da Zambézia, tornando-se a melhor previsão realizada pelo modelo. Outro aspecto bastante notável é a forte ligação entre a previsão da trajectória e o *lead time*. Notou-se que na maioria das previsões, os erros de previsão aumentavam à medida que aumentava o *lead time*. No geral as previsões de *lead time* de 24h são as melhores que dos outros *lead times*.

Diferente das previsões de trajectória, as previsões de intensidade não dependem do *lead time*. Em outras palavras isso significa que o aumento do *lead time* não afecta necessariamente as previsões, nesse caso os erros podem aumentar ou diminuir para qualquer *lead time*. Porém, é importante apontar que, embora o modelo não tenha previsto com precisão a pressão observada, ele foi capaz de acompanhar as variações da pressão na maior parte das vezes, ou seja, quando a pressão prevista era mais alta num determinado dia em relação ao dia anterior, a pressão observada também era relativamente mais alta em relação ao dia anterior. Além disso, as melhores previsões de intensidade do ciclone Freddy ocorreram durante o seu deslocamento para a região Sul de Moçambique (primeiro *landfall*) em relação a região Norte. Isso pode esta relacionado ao tipo de deslocamento. Por exemplo, as melhores previsões, sejam de intensidade ou trajectória, ocorreram durante o deslocamento zonal em relação deslocamento quase-meridional.

Em relação a precipitação, o modelo GFS teve um comportamento relativamente comparável a outras variáveis em alguns aspectos. Um deles é o facto de que as previsões de 24h de *lead time* serem melhores que as de *lead times* maiores. Isso pode ser um indicativo de que a previsões trajectória e intensidade podem afectar as previsões da precipitação acumulada isto porque na mesma região onde o modelo teve melhor desempenho na previsão da trajectória e intensidade, foi observado o mesmo para precipitação. A recíproca também é verdadeira: na mesma região onde o modelo teve um baixo desempenho para prever trajectória e intensidade, foi observado o mesmo para a precipitação. Além disso, o modelo GFS tende a prever mais precipitação próximo ao centro do ciclone em relação as bordas.

No geral, o modelo GFS tem mais dificuldades para prever precipitações extremas em relação a precipitações mais baixas. Isso tornaria difícil usar o modelo para previsões de precipitação associada ciclones tropicais. Normalmente os ciclones tropicais estão associados a precipitações bastante elevadas, nesse caso seria desejável que o modelo GFS fosse capaz de fornecer previsões de precipitação confiáveis em situações de ocorrência de ciclones tropicais. Portanto, os resultados desta pesquisa confirmam a hipótese de que o modelo não tem um bom desempenho para prever a precipitação de ciclones tropicais.

6.3. Recomendações

Mediante os resultados apresentados recomenda-se que:

As todas previsões sejam sempre confirmadas pelas previsões de 24h visto que são as melhores que as de outros *lead times*. Isso significa que mesmo após realizar uma previsão com *lead time* de 72h, esta previsão deve ser realizada novamente no dia seguinte (48h antes) e finalmente confirmar a previsão com 24h de antecedência de modo a aumentar a confiabilidade dos resultados. Porém, para previsões de trajetória do ciclone, o modelo pode ser usado para prever a trajetória mesmo para *lead time* de 72h, mas um cuidado deve se tomar em relação ao momento de impacto previsto pelo modelo, visto que não são confiáveis.

Uma vez que o modelo GFS é um modelo global, não se espera que suas previsões sejam precisas, principalmente para previsão quantitativa da precipitação. Por isso é necessário que as suas previsões sejam complementadas por previsões de modelos regionais que apresentem melhor resolução.

6.4. Próximos passos

Esta pesquisa permitiu responder algumas perguntas sobre a aplicabilidade da plataforma myDewetra para a previsão da precipitação de ciclones tropicais em Moçambique, porém deixou algumas questões em aberto. Nesta pesquisa foi avaliado apenas o desempenho do o modelo GFS, no entanto a plataforma myDewetra é composta também pelo modelo ECMWF. Portanto, em pesquisas futuras será necessário avaliar este modelo para compreender como é que as suas previsões podem complementar as previsões do modelo GFS.

Referências Bibliográficas

- Abel, L. S. (2011). *Mapeamento Geotécnico e Caracterização dos Materiais Naturais de Construção da Província de Maputo*. Brasília: G.TD - 68/11.
- Acharya, R. (2017). *Satellite Signal Propagation, Impairments and Mitigation*. Space Applications Centre - Indian Space Research Organisation. <https://doi.org/10.1016/C2015-0-06267-0>
- Adelino, J. M., & Bagtasa, G. (2023). Analysis of Landfalling Rapidly Weakening Tropical Cyclones in the Philippines. *Philippine Journal of Science*, 152, 17-32.
- Ahmad, L., Kanth, R. H., Parvaze, S., & Mahdi, S. S. (2017). *Experimental Agrometeorology: A Practical Manual*. Springer. https://doi.org/10.1007/978-3-319-69185-5_11
- Ahrens, C. D. (2009). *Meteorology Today: An Introduction to Weather, Climate, and the Environment*. Brooks/Cole, Cengage Learning.
- Anticipation Hub. (31 de Janeiro de 2022). *Acting ahead of Licungo floods: Tropical Storm Ana causes flooding in northern Mozambique*. Anticipation Hub: <https://www.anticipation-hub.org/acting-ahead-of-licungo-floods-tropical-storm-ana-causes-flooding-in-northern-mozambique>
- ARC. (2020). *Post-Event Briefing - Tropical Cyclone Chalane*. African Risk Capacity.
- ARC. (2021). *Post-Event Briefing - Tropical Cyclone Eloise*. African Risk Capacity.
- ARC. (2022). *Post-Event Briefing - Tropical Cyclone Gombe*. African Risk Capacity.
- Argete, J. C., & Francisco, R. V. (2007). Detection and Tracking of Tropical Cyclones on a Seasonal Scale in the Philippines. *Journal of Pure and Applied Sciences*, 19, 35-48.
- Atallah, E. H., & Bosart, L. F. (2003). The Extratropical Transition and Precipitation Distribution of Hurricane Floyd (1999). *Monthly Weather Review*, 131, 1063-1081. [https://doi.org/10.1175/1520-0493\(2003\)131<1063:tetapd>2.0.co;2](https://doi.org/10.1175/1520-0493(2003)131<1063:tetapd>2.0.co;2)
- Badarinath, K., Mahalakshmi, D., & Ratna, S. B. (2012). Influence of Land Use Land Cover on Cyclone Track Prediction – A Study During Aila Cyclone. *The Open Atmospheric Science Journal*, 6, 33-41. <https://doi.org/10.2174/1874282301206010033>

- Bagtasa, G. (2017). Contribution of Tropical Cyclones to Rainfall in the Philippines. *Journal of Climate*, 30, 3621-3633. <https://doi.org/10.1175/JCLI-D-16-0150.1>
- Bagtasa, G. (2020). Analog forecasting of tropical cyclone rainfall in the Philippines. *Weather and Climate Extremes*, 32, 1-12. <https://doi.org/10.1016/j.wace.2021.100323>
- Barker, D. M., Huang, W., Guo, Y.-R., Bourgeois, A. J., & Xiao, Q. N. (2004). A Three-Dimensional Variational Data Assimilation System for MM5: Implementation and Initial Results. *Monthly Weather Review*, 132, 897-914.
- Barker, D., Huang, W., Guo, Y.-R., & Bourgeois, A. (2003). *A Three-Dimensional Variational (3DVAR) Data Assimilation System For Use With MM5*.
- Barlow, M. (2011). Influence of hurricane-related activity on North American extreme precipitation. *Geophysical Research Letters*, 38, 1-5. <https://doi.org/10.1029/2010GL046258>
- Barry, R. G., & Chorley, R. J. (2004). *Atmosphere, Weather and Climate*. Routledge.
- Bender, M. A., & Ginis, I. (2000). Real-Case Simulations of Hurricane–Ocean Interaction Using A High-Resolution Coupled Model: Effects on Hurricane Intensity. *Monthly Weather Review*, 128, 917-946. [https://doi.org/10.1175/1520-0493\(2000\)128<0917:RCSOHO>2.0.CO;2](https://doi.org/10.1175/1520-0493(2000)128<0917:RCSOHO>2.0.CO;2)
- Bhatia, K. (19 de Fevereiro de 2023). <https://twitter.com/BhatiaKieran/status/1627789897720266753>
- Bié, A. J., & Camargo, R. d. (2023). Tropical cyclones position and intensity in the Southwest Indian Ocean as represented by CFS and ERA5 atmospheric reanalysis datasets. *International Journal of Climatology*, 43, 4532–4551. <https://doi.org/10.1002/joc.8101>
- Bié, A. J., Camargo, R. d., Mavume, A. F., & Harari, J. (2017). Numerical modeling of storm surges in the coast of Mozambique: the cases of tropical cyclones Bonita (1996) and Lisette (1997). *Ocean Dynamics*, 67, 1443–1459. [https://doi.org/DOI 10.1007/s10236-017-1095-](https://doi.org/DOI 10.1007/s10236-017-1095-7)

- Bister, M. (1996). *Development of Tropical Cyclones from Mesoscale Convective Systems*. MIT Libraries.
- Bousquet, O., Barbary, D., Bielli, S., Kebir, S., Raynaud, L., Malardel, S., & Faure, G. (2019). An evaluation of tropical cyclone forecast in the Southwest Indian Ocean basin with AROME-Indian Ocean convection-permitting numerical weather predicting system. *Atmospheric Science Letters*, 1-9. <https://doi.org/10.1002/asl.950>
- Cangialosi, J. P., Blake, E., DeMaria, M., Penny, A., Latto, A., Rappaport, E., & Tallapragada, V. (2020). Recent Progress in Tropical Cyclone Intensity Forecasting at the National Hurricane Center. *Weather and Forecasting*, 35, 1913 - 1922. <https://doi.org/10.1175/WAF-D-20-0059.1>
- Cappucci, M. (16 de Fevereiro de 2023). *Cyclone Freddy teeters on brink of Category 5 strength in Indian Ocean*. The Washington Post: <https://web.archive.org/web/20230217084340/https://www.washingtonpost.com/weather/2023/02/16/cyclone-freddy-indian-ocean-madagascar/>
- Casati, B., Wilson, L. J., Stephenson, D. B., Nurmi, P., Ghelli, A., Pocerlich, M., Damrath, U., Ebert, E. E., Browne, B. G., & Mason, S. (2008). Forecast verification: current status and future directions. *Meteorological Applications*, 15, 3–18. <https://doi.org/10.1002/met.52>
- Chalise, D. R., Aiyyer, A., & Sankarasubramanian, A. (2021). Tropical Cyclones' Contribution to Seasonal Precipitation and Streamflow Over the Southeastern and Southcentral United States. *Geophysical Research Letters*, 48, 1-11. <https://doi.org/10.1029/2021GL094738>
- Chavas, D. R., Reed, K. A., & Knaff, J. A. (2017). Physical understanding of the tropical cyclone wind-pressure relationship. *nature communications*, 8, 1-11. <https://doi.org/10.1038/s41467-017-01546-9>
- Chen, G., Yu, H., Cao, Q., & Zeng, Z. (2013). The Performance of Global Models in TC Track Forecasting Over the Western North Pacific from 2010 to 2012. *Tropical Cyclone Research and Review*, 149-158. <https://doi.org/10.6057/2013TCRR03.02>

- Chen, L., Li, Y., & Cheng, Z. (2010). An Overview of Research and Forecasting on Rainfall Associated with Landfalling Tropical Cyclones. *Advances in Atmospheric Sciences*, 27, 967-976. <https://doi.org/10.1007/s00376-010-8171-y>
- Chen, R., Zhang, W., & Wang, X. (2020). Machine Learning in Tropical Cyclone Forecast Modeling: A Review. *Atmosphere*, 11, 1-29. <https://doi.org/10.3390/atmos11070676>
- Chen, S.-H., Lin, Y.-L., & Zhao, Z. (2008). Effects of Unsaturated Moist Froude Number and Orographic Aspect Ratio on a Conditionally Unstable Flow over a Mesoscale Mountain. *Journal of Meteorological Society of Japan*, 86(2), 353-367.
- Chen, Y., Ebert, E. E., Davidson, N. E., & Walsh, K. J. (2018). Application of Contiguous Rain Area (CRA) Methods to Tropical Cyclone Rainfall Forecast Verification. *Earth and Space Science*, 5, 736-752. <https://doi.org/10.1029/2018EA000412>
- Cho, W., Park, J., Moon, J., Chal, D.-H., Moon, Y.-m., Kim, H.-S., Noh, K.-j., & Park, S.-H. (2022). Effects of topography and sea surface temperature anomalies on heavy rainfall induced by Typhoon Chaba in 2016. *Geoscience Letters*, 9, 1-18. <https://doi.org/10.1186/s40562-022-00230-1>
- CIMA. (2021). *myDEWETRA.world in Mozambique on the occasion of the International Day for Disaster Risk Reduction*. myDewetra.world: <https://www.infomydewetra.world/2021/10/mydewetra-world-in-mozambique-on-the-occasion-of-the-international-day-for-disaster-risk-reduction/>
- Clegg, P., Earl-Spurr, C., & Paterson, L. (2023). *Severe Tropical Cyclone Freddy*. Australian Bureau of Meteorology.
- Clyde & Co LLP. (2018). *Parametric Insurance: closing the protection gap*. Clyde & Co LLP.
- Colle, B. A. (2003). Numerical Simulations of the Extratropical Transition of Floyd (1999): Structural Evolution and Responsible Mechanisms for the Heavy Rainfall over the Northeast United States. *Monthly Weather Review*, 131, 2905 - 2926. [https://doi.org/10.1175/1520-0493\(2003\)131<2905:nsotet>2.0.co;2](https://doi.org/10.1175/1520-0493(2003)131<2905:nsotet>2.0.co;2)

- Cuo, L., Pagano, T. C., & Wang, Q. J. (2011). A Review of Quantitative Precipitation Forecasts and Their Use in Short- to Medium-Range Streamflow Forecasting. *Journal of Hydrometeorology*, *12*, 713-728. <https://doi.org/10.1175/2011JHM1347.1>
- Damrath, U., Doms, G., Fruhwald, D., Heise, E., Richter, B., & Steppeler, J. (2000). Operational quantitative precipitation forecasting at the German Weather Service. *Journal of Hydrology*, *239*, 260 – 285. [https://doi.org/10.1016/S0022-1694\(00\)00353-X](https://doi.org/10.1016/S0022-1694(00)00353-X)
- Das, D., Chiao, S., Roychoudhury, C., Khan, F., Chaudhuri, S., & Mukherjee, S. (2023). Tropical Cyclonic Energy Variability in North Indian Ocean: Insights from ENSO. *Climate*, *11*(12), 232. <https://doi.org/10.3390/cli11120232>
- Daves, R. (28 de February de 2023). *Mozambique – Thousands Displaced as Cyclone Freddy Brings Flooding Rain*. floodlist.com: <https://floodlist.com/africa/mozambique-floods-cyclone-freddy-february-2023>
- Deshpande, M., Johny, C., Kanase, R., Tirkey, S., Sarkar, S., Goswami, T., Roy, K., Ganai, M., Krishna, R. M., Prasad, V., Mukhopadhyay, P., Durai, V., Nanjundiah, R. S., & Rajeevan, M. (2020). *Implementation of Global Ensemble Forecast System (GEFS) at 12km Resolution*. Indian Institute of Tropical Meteorology.
- Deshpande, M., Kanase, R., Krishna, R. P., Tirkey, S., Mukhopadhyay, P., Prasad, V. S., Johny, C. J., Durai, V. R., Devi, S., & Mohapatra, M. (2021). Global Ensemble Forecast System (GEFS T1534) evaluation for tropical cyclone prediction over the North Indian Ocean. *MAUSAM*, 119-128.
- DG ECHO. (2019). *Tropical Cyclone Idai Impact Overview*. Directorate-General for European Civil Protection and Humanitarian Aid Operations.
- Ding, C., Ren, F., Liu, Y., McBride, J. L., & Feng, T. (2020). Improvement in the Forecasting of Heavy Rainfall over South China in the DSAEF_LTP Model by Introducing the Intensity of the Tropical Cyclone. *Weather Forecast*, *35*, 1967-1980. <https://doi.org/10.1175/WAF-D-19-0247.1>

- ECMWF. (s.d.). *About our forecasts*. ecmwf: <https://www.ecmwf.int/en/forecasts/documentation-and-support>
- ECMWF. (sd). *Advancing global NWP through international collaboration*. ECMWF: <https://www.ecmwf.int/>
- Erdman, J., & Dolce, C. (22 de Fevereiro de 2023). *Cyclone Freddy Tracking Across Madagascar, Then A Flood Danger For Mozambique*. Weather Underground: <https://www.wunderground.com/article/storms/hurricane/news/2023-02-20-tropical-cyclone-freddy-forecast-madagascar-mozambique>
- Evans, J. L. (2017). Tropical Cyclone Intensity, Structure, and Structure Change. Em WMO, *Global Guide to Tropical Cyclone Forecasting* (pp. 126-127). Chairperson.
- Fan, D. (2006). Variations in Tropical-Cyclone Activity and Storm-Surge Devastation since the 1950s in China. *Gulf Coast Association of Geological Societies Transactions*, 56, 185-192.
- Feng, X., & Shu, S. (2018). How Do Weak Tropical Cyclones Produce Heavy Rainfall When Making Landfall Over China. *Journal of Geophysical Research: Atmospheres*, 123, 1-20. <https://doi.org/10.1029/2018JD029228>
- Fernández-Alvarez, J. C., Pérez-Alarcon, A., Batista-Leyva, A. J., & Díaz-Rodríguez, O. (2020). Evaluation of Precipitation Forecast of System: Numerical Tools for Hurricane Forecast. *Advances in Meteorology*, 2020, 1-16. <https://doi.org/10.1155/2020/8815949>
- Ficchi, A., Ascenso, G., Giuliani, M., Scoccimarro, E., Magnusson, L., Emerton, R., Stephens, E., & Castelletti, A. (2024). Machine-learning enhanced forecast of tropical cyclone rainfall for anticipatory humanitarian action. *General Assembly*. <https://doi.org/10.5194/egusphere-egu23-15188>
- Fink, A. H., & Speth, P. (1998). Tropical Cyclones. *Springer-Verlag*, 482-493. <https://doi.org/10.1007/s001140050536>

- Fiorino, M., Goerss, J. S., Jensen, J. J., & Harrison, E. J. (1993). An Evaluation of the Real-Time Tropical Cyclone Forecast Skill of the Navy Operational Global Atmospheric Prediction System in the Western North Pacific. *Weather and Forecasting*, 8, 3-24.
- Frank, W. M., & Ritchie, E. A. (2001). Effects of Vertical Wind Shear on the Intensity and Structure of Numerically Simulated Hurricanes. *Monthly Weather Review*, 2249-2269.
- FSC. (2 de Fevereiro de 2022). *Mozambique: Tropical Storm Ana*. Food Security Cluster: <https://fscluster.org/news/mozambique-tropical-storm-ana-update-30>
- Fudeyasu, H., Hirose, S., Yoshioka, H., Kumazawa, R., & Yamasaki, S. (2014). A Global View of The Landfall Characteristics of Tropical Cyclone. *Tropical Cyclone Research and Review*, 3(3), 178-192. <https://doi.org/10.6057/2014TCRR03.04>
- Galarneau, T. J., Zeng, X., Dixon, R. D., Ouyed, A., Ouyed, A., & Cui, W. (2022). Tropical mesoscale convective system formation environments. *Atmospheric Science Letters*, 24, 1-9. <https://doi.org/10.1002/asl.1152>
- Gao, Y., Leung, L. R., Zhao, C., & Hagos, S. (2017). Sensitivity of U.S. summer precipitation to model resolution and convective parameterizations across gray zone resolutions. *Journal of Geophysical Research: Atmospheres*, 122, 2714-2733. <https://doi.org/10.1002/2016JD025896>
- Gov-UK. (18 de Março de 2023). *UK sends life-saving support to cyclone-hit Malawi*. Gov.UK: <https://www.gov.uk/government/news/uk-sends-life-saving-support-to-cyclone-hit-malawi>
- Goyal, S., Mohapatra, M., Dube, S. K., Kumari, P., & De, I. (2016). Mesoscale convective systems in association with tropical cyclones over Bay of Bengal. *Natural Hazards*, 82. <https://doi.org/10.1007/s11069-016-2229-9>
- Guambe, G. (2017). *Módulo 5 de Geografia*. Maputo: Ministério da Educação e Desenvolvimento Humano.

- Habets, F., LeMoigne, P., & Noilhan, J. (2004). On the utility of operational precipitation forecasts to served as input for streamflow forecasting. *Journal of Hydrology*, *293*, 270–288. <https://doi.org/10.1016/j.jhydrol.2004.02.004>
- Han, W., Wang, Y., & Liu, L. (2022). The relationship between pre-landfall intensity change and post-landfall weakening of tropical cyclones over China. *Frontiers in Earth Science*, *10*, 1-13. <https://doi.org/10.3389/feart.2022.1082181>
- Harr, P. A., & Elsberry, R. L. (2000). Extratropical Transition of Tropical Cyclones over the Western North Pacific. Part I: Evolution of Structural Characteristics during the Transition Process. *Monthly Weather Review*, *128*, 2613-2633. [https://doi.org/https://doi.org/10.1175/1520-0493\(2000\)128<2613:ETOTCO>2.0.CO;2](https://doi.org/10.1175/1520-0493(2000)128<2613:ETOTCO>2.0.CO;2)
- Head, T. (12 de Março de 2023). *Tropical cyclone Freddy: Breaking records and still going strong*. Citizen: <https://www.citizen.co.za/zululand-observer/lmn/article/tropical-cyclone-freddy-breaking-records-and-still-going-strong/>
- Hendricks, E. A. (2012). Internal Dynamical Control on Tropical Cyclone Intensity Variability - A Review. *Tropical Cyclone Research and Review*, *1*(1), 97-105. <https://doi.org/10.6057/2012TCRR01.11>
- Hill, K. A., & Lackmann, G. M. (2009). Influence of Environmental Humidity on Tropical Cyclone Size. *Monthly Weather Review*, *137*, 3294 - 3315. <https://doi.org/10.1175/2009MWR2679.1>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, *15*, 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Hou, Z., Zha, W., Wang, H., Liao, W.-H., & Cao, C. R. (2022). Bistable energy harvesting backpack: Design, modeling, and experiments. *Energy Conversion and Management*, *259*, 115441. <https://doi.org/10.1016/j.enconman.2022.115441>
- Houze, R. A. (2004). Mesoscale Convective Systems. *Reviews of Geophysics*, *42*, 1-43.

- Hu, P., Zhang, Q., Shi, P., Chen, B., & Fang, J. (2018). Flood-induced mortality across the globe: Spatiotemporal pattern and influencing factors. *Science of the Total Environment*, 643, 171–182. <https://doi.org/10.1016/j.scitotenv.2018.06.197>
- Huang, C.-Y., Chou, C.-W., Chen, S.-H., & Xie, J.-H. (2020). Topographic Rainfall of Tropical Cyclones past a Mountain Range as Categorized by Idealized Simulations. *Weather and Forecasting*, 35(1), 25-49. <https://doi.org/10.1175/WAF-D-19-0120.1>
- Huang, X., Peng, X., Fei, J., Cheng, X., Ding, J., & Yu, D. (2021). Evaluation and Error Analysis of Official Tropical Cyclone Intensity Forecasts during 2005 – 2018 for the Western North Pacific. *Journal of the Meteorological Society of Japan*, 99, 139–163. <https://doi.org/10.2151/jmsj.2021-008>
- IFRC. (2020). *Learning from Cyclone Idai and Cyclone Kenneth to Strengthen Early Warning Systems in Mozambique*. The Zurich Flood Resilience Alliance PERC.
- INAM. (2023). *Relatório do Estado do Clima de Moçambique em 2023*. Instituto Nacional de Meteorologia. https://en.wikipedia.org/wiki/Meteorological_history_of_Cyclone_Freddy#/media/File:Freddy_2023_path.png
- INGD. (2022). *Estratégia Nacional para o Estabelecimento de um Sistema Integrado de Fluco de Informação de Aviso Prévio de Cheias e Ciclones em Moçambique*. Instituto Nacional de Gestão e Redução de Risco de Desastres.
- IOM. (2022). *Flash Report Update 1 - Tropical Cyclone Ana*.
- IOM. (2023). *Tropical Cyclone Freddy- Situation Report #2*. United Nations International Organization for Migration.
- Irwandi, I., Ilhamsyah, Y., Permana, D. S., Haloho, M. P., Prasetyo, B., & Dana, I. N. (2019). Application of C-band Doppler Weather Radar (CDR) for Detecting Volcanic Ash Dispersion of Sinabung Eruption 19 February 2018. *IOP Conference Series: Earth and Environmental Science*, 273, 1-8. <https://doi.org/10.1088/1755-1315/273/1/012019>

- Jaffrés, J. B., & Gray, J. L. (2023). Chasing rainfall: estimating event precipitation along tracks of tropical cyclones via reanalysis data and in-situ gauges. *Environmental Modelling and Software*, *167*, 105773. <https://doi.org/10.1016/j.envsoft.2023.105773>
- Jia, L., Jia, Z., Ren, F., Ding, C., Wang, M., & Feng, T. (2020). Introducing TC intensity into the DSAEF_LTP model and simulating precipitation of super-typhoon Lekima (2019). *Quarterly Journal of the Royal Meteorological Society*, *146*, 1-15. <https://doi.org/10.1002/qj.3882>
- Jia, L., Ren, F., Ding, C., Jia, Z., Wang, M., Chen, Y., & Feng, T. (2022). Improvement of the Ensemble Methods in the Dynamical–Statistical–Analog Ensemble Forecast Model for Landfalling Typhoon Precipitation. *Journal of the Meteorological Society of Japan*, *100*(3), 575-592. <https://doi.org/10.2151/jmsj.2022-029>
- Jiang, X., Ma, Y., Ren, F., Ding, C., Han, J., & Shi, J. (2023). Research on Typhoon Precipitation Prediction over Hainan Island Based on Dynamical–Statistical–Analog Technology. *Atmosphere*, *14*, 1-14. <https://doi.org/10.3390/atmos14081210>
- Jones, S. C., Harr, P. A., Abraham, J., Bosart, L. F., Bowyer, P. J., Evans, J. L., Hanley, D. E., Hanstrum, B. N., Hart, R. E., Lalaurette, F., Sinclair, M. R., Smith, R. K., & Thorncroft, C. (2003). The Extratropical Transition of Tropical Cyclones: Forecast Challenges, Current Understanding, and Future Directions. *Weather Forecasting*, *18*, 1052-1092.
- Jonkman, S. N., Maaskant, B., Boyd, E., & Levitan, M. L. (2009). Loss of Life Caused by the Flooding of New Orleans After Hurricane Katrina: Analysis of the Relationship Between Flood Characteristics and Mortality. *Risk analysis: an official publication of the Society for Risk Analysis*, *29*, 676-698. <https://doi.org/10.1111/j.1539-6924.2008.01190.x>
- Kaplan, J., & DeMaria, M. (2003). Large-Scale Characteristics of Rapidly Intensifying Tropical Cyclones in the North Atlantic Basin. *Weather and Forecasting*, *18*, 1093-1108. [https://doi.org/10.1175/1520-0434\(2003\)018<1093:LCORIT>2.0.CO](https://doi.org/10.1175/1520-0434(2003)018<1093:LCORIT>2.0.CO)

- Khouakhi, A., Villarini, G., & Vecchi, G. A. (2017). Contribution of Tropical Cyclones to Rainfall at the Global Scale. *American Meteorological Society*, 359-372. <https://doi.org/10.1175/JCLI-D-16-0298.1>
- Klein, P. M., Harr, P. A., & Elsberry, R. L. (2000). Extratropical Transition of Western North Pacific Tropical Cyclones: An Overview and Conceptual Model of the Transformation Stage. *Weather and Forecasting*, 15, 373-395.
- Kossin, J. P. (2018). A global slowdown of tropical-cyclone translation speed. *Macmillan Publishers Limited*, 104-107. <https://doi.org/10.1038/s41586-018-0158-3>
- Kotal, S. D., Bhattacharya, S. K., & Bhowmik, S. K. (2019). Estimation of tropical cyclone intensity and location over the north Indian Ocean – a challenge. *Meteorological Applications*, 26, 245–252. <https://doi.org/10.1002/met.1758>
- Krajewski, W., & Smith, J. (2002). Radar hydrology: rainfall estimation. *Advances in Water Resources*, 25, 1387–1394.
- Kurniawan, R., Harsa, H., Nurrahmat, M. H., Sasmito, A., Florida, N., Makmur, E. E., Swarinoto, Y. S., Habibie, M. N., Hutapea, T. F., Hendri, Sudewi, R. S., Fitria, W., Praja, A. S., & Adrianita, F. (2021). The Impact of Tropical Cyclone Seroja to The Rainfall and Sea Wave Height in East Nusa Tenggara. *Earth and Environmental Science*, 925, 1-12. <https://doi.org/10.1088/1755-1315/925/1/012049>
- La Reunion. (2023a). *Bulletin For Cyclonic Activity and Significant Tropical Weather in Southwest Indian Ocean*.
- La Reunion. (2023b). *Cyclone e Actividade Ciclonica La Reunion*. Meteo France: <https://meteofrance.re/fr/cyclone>
- La Reunion. (2023c). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - A Warning Number: 19/7/20222023*. Meteo France.
- La Reunion. (2023d). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - A Warning Number: 36/7/20222023*. Meteo France.

- La Reunion. (2023e). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 1/7/20222023*. Meteo France.
- La Reunion. (2023f). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 23/7/20222023*. Meteo France.
- La Reunion. (2023g). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 28/7/20222023*. Meteo France.
- La Reunion. (2023h). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 41/7/20222023*. Meteo France.
- La Reunion. (2023i). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 46/7/20222023*. Meteo France.
- La Reunion. (2023j). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 47/7/20222023*. Meteo France.
- La Reunion. (2023k). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 57/7/20222023*. Meteo France.
- La Reunion. (2023l). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 63/7/20222023*. Meteo France.
- La Reunion. (2023m). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 73/7/20222023*. Meteo France.
- La Reunion. (2023n). *Tropical Cyclone Forecast Warning (South-West Indian Ocean) - Warning Number: 81/7/20222023*. Meteo France.
- Lamers, A., S, S. D., Sharma, M., Berg, R., Galvez, J. M., Yu, Z., Kriat, T., Cardos, S., Grant, D., & Moron, L. A. (2023). Forecasting tropical cyclone rainfall and flooding hazards and impacts. *Tropical Cyclone Research and Review*, 12, 100-112. <https://doi.org/10.1016/j.tcr.2023.06.005>
- Langa, J. V. (2007). Problemas na zona costeira de Moçambique com ênfase para a costa de Maputo. *Revista de Gestão Costeira Integrada*, 37-44.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*, 436-444. <https://doi.org/10.1038/nature14539>
- Lee, J.-T., Ko, K.-Y., Leec, D.-I., You, C.-H., & Liou, Y.-C. (2018). Enhancement of orographic precipitation in Jeju Island during the passage of Typhoon Khanun (2012). *Atmospheric Research*, *201*, 58–71. <https://doi.org/10.1016/j.atmosres.2017.10.013>
- Li, Y., & Chen, L. (2007). Numerical Study on Impact of the Boundary Layer Fluxes over Wetland on Sustention and Rainfall of Landfalling Tropical Cyclones. *Acta Meteorologica Sinica*, *21*, 34-46.
- Li, Y., Tang, Y., Toumi, R., & Wang, S. (2022). Revisiting the definition of Rapid Intensification of Tropical Cyclones by Clustering the Initial Intensity and Inner-Core Size. *JGR: Atmospheres*.
- Lin, G. F., & Wu, M. C. (2009). A hybrid neural network model for typhoon-rainfall forecasting. *Journal of Hydrology*, *375*, 450–458. <https://doi.org/10.1016/j.jhydrol.2009.06.047>
- Lin, G.-F., & Chen, L.-H. (2005). Application of an artificial neural network to typhoon rainfall forecasting. *Hydrological Processes*, *19*, 1825-1837. <https://doi.org/10.1002/hyp.5638>
- Lin, G.-F., & Jhong, B.-C. (2015). A real-time forecasting model for the spatial distribution of typhoon rainfall. *Journal of Hydrology*, *521*, 302–313. <https://doi.org/10.1016/j.jhydrol.2014.12.009>
- Lin, G.-F., Chen, G.-R., Wu, M.-C., & Chou, Y.-C. (2009). Effective forecasting of hourly typhoon rainfall using support vector machines. *Water Resources Research*, *45*, 1-11. <https://doi.org/10.1029/2009WR007911>
- Lin, G.-F., Jhong, B.-C., & Chang, C.-C. (2013). Development of an effective data-driven model for hourly typhoon rainfall forecasting. *Journal of Hydrology*, *495*, 52-63. <https://doi.org/10.1016/j.jhydrol.2013.04.050>

- Lin, Y., Zhao, M., & Zhang, M. (2015). Tropical cyclone rainfall area controlled by relative sea surface temperature. *Nature Communications*, 6, 6591. <https://doi.org/10.1038/ncomms7591>
- Lin, Y.-L., Chiao, S., Wang, T.-a., Kaplan, M. L., & Weglarz, R. P. (2001). Some Common Ingredients for Heavy Orographic Rainfall. *Weather and Forecasting*, 16, 633-660. [https://doi.org/https://doi.org/10.1175/1520-0434\(2001\)016<0633:SCIFHO>2.0.CO;2](https://doi.org/https://doi.org/10.1175/1520-0434(2001)016<0633:SCIFHO>2.0.CO;2)
- Liu, M., Smith, J. A., Yang, L., & Vecchi, G. A. (2022). Tropical Cyclone Flooding in the Carolinas. *Journal of Hydrometeorology*, 23, 53-70. <https://doi.org/10.1175/JHM-D-21-0113.1>
- Liu, M., Yang, L., Smith, J. A., & Vecchi, G. A. (2020). Response of Extreme Rainfall for Landfalling Tropical Cyclones Undergoing Extratropical Transition to Projected Climate Change: Hurricane Irene (2011). *Earths Future*, 8, 1-13. <https://doi.org/10.1029/2019EF001360>
- Liu, Y., Zhang, T., Duan, H., Wu, J., Zeng, D., & Zhao, C. (2021). Evaluation of Forecast Performance for Four Meteorological Models in Summer Over Northwestern China. *Frontiers in Earth Science*, 9, 771207. <https://doi.org/10.3389/feart.2021.771207>
- Liu, Y.-Y., Li, L., Liu, Y.-S., Chan, P.-W., Zhang, W.-H., & Zhang, L. (2021). Estimation of precipitation induced by tropical cyclones based on machine-learning-enhanced analogue identification of numerical prediction. *Meteorological Applications*, 28, 1-11. <https://doi.org/10.1002/met.1978>
- Liu, Y.-y., Li, L., Zhang, W.-h., Chan, P.-w., & Liu, Y.-s. (2019). Rapid identification of rainstorm disaster risks based on an artificial intelligence technology using the 2DPCA method. *Atmospheric Research*, 227, 157-164. <https://doi.org/10.1016/j.atmosres.2019.05.006>
- Llasat, M. C., Rigo, T., & Villegas, J. J. (2017). Techniques and Instruments to Aid in the Monitoring of Flood Events. Em F. Vinet, *Floods* (pp. 94-98). International Society for Technology in Education (ISTE).

- Lockwood, J. W., Loridan, T., Lin, N., Oppenheimer, M., & Hannah, N. (2023). A machine learning approach to model over ocean tropical cyclone precipitation. *American Meteorological Society*. <https://doi.org/10.1175/JHM-D-23-0065.1>
- Longshore, D. (2008). *Encyclopedia of Hurricanes, Typhoons and Cyclones*. Facts on File Science Library.
- Loughe, A. F., Madine, S., & Mahoney, J. (n.d.). *A Lead-Time Metric for Assessing Skill in Forecasting the Onset of IFR Conditions*. NOAA.
- Ma, L.-M., & Tan, Z.-M. (2009). Improving the behavior of the cumulus parameterization for tropical cyclone prediction: Convection trigger. *Atmospheric Research*, *92*, 109-211. <https://doi.org/10.1016/j.atmosres.2008.09.022>
- Ma, Y., Jia, Z., Ren, F., Jia, L., & McBride, J. L. (2022b). Introducing TC Translation Speed into the Dynamical–Statistical–Analog Ensemble Forecast for Landfalling Typhoon Daily Precipitation Model and Simulating the Daily Precipitation of Supertyphoon Lekima (2019). *Weather and Forecasting*, *37*, 2005-2020. <https://doi.org/10.1175/WAF-D-21-0135.1>
- Ma, Y.-q., Ren, F.-m., Jia, L., & Ding, C.-c. (2022a). Experiments with the Improved Dynamical-Statistical-Analog Ensemble Forecast Model for Landfalling Typhoon Precipitation over South China. *Journal of Tropical Meteorology*, *28*, 139-153. <https://doi.org/10.46267/j.1006-8775.2022.011>
- Mahoney, K. M. (2016). The Representation of Cumulus Convection in High-Resolution Simulations of the 2013 Colorado Front Range Flood. *Monthly Weather Review*, *144*, 4265-4278. <https://doi.org/10.1175/MWR-D-16-0211.1>
- Makarieva, A. M., Gorshkov, V. G., Nefiodov, A. V., Chikunov, A. V., Sheil, D., Nobre, A. D., & Li, B.-L. (2017). Fuel for cyclones: The water vapor budget of a hurricane as dependent on its movement. *Atmospheric Research*, *193*, 216-230. <https://doi.org/10.1016/j.atmosres.2017.04.006>

- Marchock, T., Rogers, R., & Tuleya, R. (2007). Validation Schemes for Tropical Cyclone Quantitative Precipitation Forecasts: Evaluation of Operational Models for U.S. Landfalling Cases. *Weather and Forecasting*, 22, 726-746. <https://doi.org/10.1175/WAF1024.1>
- Maria, E., Budiman, E., H., H., & Taruk, M. (2020). Measure distance locating nearest public facilities using Content from this work may be used under the terms of the Creative Commons Attribution 3.0 licence. Any further distribution. *Journal of Physics: Conference Series*, 1450, 012080. <https://doi.org/10.1088/1742-6596/1450/1/012080>
- Mavume, A. F., Banze, B. E., Macie, O. A., & Queface, A. J. (2021). Analysis of Climate Change Projections for Mozambique under the Representative Concentration Pathways. *Atmosphere*, 12, 1-51. <https://doi.org/10.3390/atmos12050588>
- Mavume, A. F., Rydberg, L., Rouault, M., & Lutjeharms, J. R. (2009). Climatology and Landfall of Tropical Cyclones in the South West Indian Ocean. *Western Indian Ocean Journal of Marine Science*, 8, 15-36.
- Mendelsohn, R., Emanuel, K., Chonabayashi, S., & Bakkensen, L. (2012). The impact of climate change on global tropical cyclone damage. *Nature Climate Change*, 2, 205-209. <https://doi.org/10.1038/NCLIMATE1357>
- Meteo France. (sd). *About RSMC*. meteo.fr: http://www.meteo.fr/temps/domtom/La_Reunion/webcmrs9.0/anglais/index.html
- Meteo france. (sd.b). *Classification for the tropical systems, in use in the South-West Indian Ocean*. meteo: http://www.meteo.fr/temps/domtom/La_Reunion/webcmrs9.0/anglais/index.html
- Molini, L. (04 de Abril de 2023). *ECMWF Ensemble Forecast*. myDewiki: https://mydewiki.cimafoundation.org/en/myDW/Forecasts/ECMWF_ens
- Moses, O., & Ramotonto, S. (2018). Assessing forecasting models on prediction of the tropical cyclone Dineo and the associated rainfall over Botswana. *Weather and Climate Extremes*, 21, 102-109. <https://doi.org/10.1016/j.wace.2018.07.004>

- Myronets, A. (5 de Abril de 2023). *Tropical Cyclone Freddy: Key Facts*. rainviewer: <https://www.rainviewer.com/blog/tropical-cyclone-freddy.html>
- National Geographic. (19 de Outubro de 2023). *The Saffir-Simpson Hurricane Wind Scale*. NationalGeographic: <https://education.nationalgeographic.org/resource/saffir-simpson-hurricane-wind-scale/>
- National Geographic. (19 de Outubro de 2023). *The Saffir-Simpson Hurricane Wind Scale*. National Geographic: <https://education.nationalgeographic.org/resource/saffir-simpson-hurricane-wind-scale/>
- Nelson, S. A. (19 de Agosto de 2014). *Tropical Cyclones (Hurricanes)*. Tulane: https://www2.tulane.edu/~sanelson/New_Orleans_and_Hurricanes/tropical_cyclones.htm
- NOAA. (19 de Fevereiro de 2021). National Environmental Satellite, Data, and Information Service: <https://www.nesdis.noaa.gov/news/tracking-tropical-cyclone-guambe>
- NOAA. (26 de 12 de 2023a). *Thunderstorm Types*. www.nssl.noaa.gov: [https://www.nssl.noaa.gov/education/svrwx101/thunderstorms/types/#:~:text=A%20Meso%20scale%20Convective%20System%20\(MCS,or%20a%20cluster%20of%20cells.](https://www.nssl.noaa.gov/education/svrwx101/thunderstorms/types/#:~:text=A%20Meso%20scale%20Convective%20System%20(MCS,or%20a%20cluster%20of%20cells.)
- NOAA. (23 de Fevereiro de 2023b). *Tropical Cyclone Freddy Breaks Records before Lashing Madagascar*. National Environment Satellite, Data and Information Service: <https://www.nesdis.noaa.gov/news/tropical-cyclone-freddy-breaks-records-lashing-madagascar>
- NOAA. (20 de Janeiro de 2023c). *How Do We Use Models in Our Forecasting?* National Weather Service: https://www.weather.gov/ilx/about_models#:~:text=The%20fundamental%20difference%20between%20the,the%20CMCE%20is%2020%20solutions
- NOAA. (1 de Dezembro de 2023d). *NCEP Products Inventory*. NCEP Central Operations: <https://www.nco.ncep.noaa.gov/pmb/products/gens/>

- NOAA. (n.d.a). *GFS*. National Oceanic and Atmospheric Administration: https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs.php
- NOAA. (n.d.b). *Global Forecast System (GFS)*. National Center for Environmental Information: <https://www.ncei.noaa.gov/products/weather-climate-models/global-forecast>
- Nogueira, D. F. (2019). *Mobile-Based Early Warning Systems in Mozambique*. Uppsala University.
- Nordhaus, W. D. (2010). The Economics of Hurricanes and Implications of Global Warming. *World Scientific*, 1, 1–20. <https://doi.org/10.1142/S2010007810000054>
- OCHA. (2019). *Southern Africa - Cyclones Idai and Kenneth Snapshot*. Office for the Coordination of Humanitarian Affairs.
- OCHA. (2022a). *Mozambique - Tropical Cyclone Gombe Flash Update No.3*. Office for the Coordination of Humanitarian Affairs.
- OCHA. (2022b). *Mozambique - Tropical Storm Ana*. Office for the Coordination of Humanitarian Affairs.
- OCHA. (2023a). *Southern Africa: Snapshot of Tropical Cyclone Freddy's Impact*. Office for the Coordination of Humanitarian Affairs.
- OCHA. (2023b). *Mozambique-Severe Tropical Storm Freddy - Flash Update No. 9*. United Nations Office for the Coordination of Humanitarian Affairs.
- OCHA. (2023c). *SOUTHERN AFRICA: Tropical Cyclone Freddy Flash Update No. 5*. United Nations Office for the Coordination of Humanitarian Affairs.
- Oliveira, M. (15 de Setembro de 2018). *Qual a diferença entre furacões, tufões e ciclones?* TudoGeo: <https://www.tudogeo.com.br/2018/09/15/qual-a-diferenca-entre-furacoes-tufoes-e-ciclones/>
- Olumide, S. (08 de Agosto de 2023). *Root Mean Square Error (RMSE) In AI: What You Need To Know*. Arize: <https://arize.com/blog-course/root-mean-square-error-rmse-what-you-need-to->

- Racoma, B. A., David, C. P., Crisologo, I. A., & Bagtasa, G. (2016). The Change in Rainfall from Tropical Cyclones Due to Orographic Effect of the Sierra Madre Mountain Range in Luzon, Philippines. *Philippine Journal of Science*, 145, 313-326.
- Rappaport, E. N. (2000). Loss of Life in the United States Associated with Recent Atlantic Tropical Cyclones. *Bulletin of the American Meteorological Society*, 2065-2074.
- Rappaport, E. N. (2014). Fatalities in the United States from Atlantic Tropical Cyclones. *Insights and Innovations*, 341-346. <https://doi.org/10.1175/BAMS-D-12-00074.1>
- Reason, C. J., & Keibel, A. (2004). Tropical Cyclone Eline and Its Unusual Penetration and Impacts over the Southern African Mainland. *Weather and Forecasting, Volume 19*, 789-805. [https://doi.org/10.1175/1520-0434\(2004\)019<0789:TCEAIU>2.0.CO;2](https://doi.org/10.1175/1520-0434(2004)019<0789:TCEAIU>2.0.CO;2)
- Reboita, M. S., Gan, M. A., Rocha, R. P., & Custódio, I. S. (2017). Ciclones em Superfície nas Latitudes Austrais: Parte I - Revisão Bibliográfica. *Revista Brasileira de Meteorologia*, 32(2), 171-186. <https://doi.org/10.1590/0102-77863220010>
- Ren, F., Ding, C., Zhang, D.-L., Chen, D., Ren, H.-L., & Qiu, W. (2020). A Dynamical-Statistical-Analog Ensemble Forecast Model: Theory and an Application to Heavy Rainfall Forecasts of Landfalling Tropical Cyclones. *Monthly Weather Review*, 1503-1517. <https://doi.org/10.1175/MWR-D-19-0174.1>
- Ren, F., Qiu, W., Ding, C., Jiang, X., Wu, L., Xu, Y., & Duan, Y. (2018). An Objective Track Similarity Index and Its Preliminary Application to Predicting Precipitation of Landfalling Tropical Cyclones. *Weather and Forecasting*, 33, 1725-1742. <https://doi.org/10.1175/WAF-D-18-0007.1>
- Rogers, R., Chen, S., Tenerelli, J., & Willoughby, H. (2003). A Numerical Study of the Impact of Vertical Shear on the Distribution of Rainfall in Hurricane Bonnie (1998). *Monthly Weather Reaview*, 131, 1577-1599. <https://doi.org/10.1175//2546.1>
- Roose, S., Ajayamohan, R. S., Ray, P., Xie, S.-P., Sabeerali, C. T., Mohapatra, M., Taraphdar, S., Mohanakumar, K., & Rajeevan, M. (2023). Pacific decadal oscillation causes fewer near-

- equatorial cyclones in the North Indian Ocean. *Nature Communications*, *14*, 5099. <https://doi.org/10.1038/s41467-023-40642-x>
- Rosendal, H. E., & Shaw, S. L. (1982). *Relationship of Maximum Sustained Winds to Minimum Sea Level Pressure in Central North Pacific Tropical Cyclones*. NOAA.
- Schumacher, R. S., & Rasmussen, K. L. (2020). The formation, character and changing nature of mesoscale convective systems. *Nature Reviews Earth & Environment*, *1*, 300-314. <https://doi.org/10.1038/s43017-020-0057-7>
- Shi, X., & Wang, Y. (2022). Impacts of Cumulus Convection and Turbulence Parameterizations on the Convection-Permitting Simulation of Typhoon Precipitation. *Monthly Weather Review*, *150*, 2977-2997. <https://doi.org/10.1175/MWR-D-22-0057.1>
- Shrestha, D. L., Robertson, D. E., Q. J. Wang¹, T. C., & Hapuarachchi, H. A. (2013). Evaluation of numerical weather prediction model precipitation forecasts for short-term streamflow forecasting purpose. *Hydrology and Earth System Sciences*, *17*, 1913–1931. <https://doi.org/10.5194/hess-17-1913-2013>
- Singh, M., & Schoenmakers, E. (2023). Comparative Impact Analysis of Cyclone Ana in the Mozambique Channel Using Satellite Data. *Applied Sciences*, *13*, 4519. <https://doi.org/10.3390/app13074519>
- Singh, V. K., & Roxy, M. (2020). A review of the ocean-atmosphere interactions during tropical cyclones in the north Indian Ocean. *Earth Science Reviews*.
- Sokol, Z., Szturc, J., Orellana-Alvear, J., Popová, J., Jurczyk, A., & Céleri, R. (2021). The Role of Weather Radar in Rainfall Estimation and Its Application in Meteorological and Hydrological Modelling - A Review. *Remote Sensing*, *13*(351), 1-37. <https://doi.org/10.3390/rs13030351>
- South African Weather Service. (2017). *Ex tropical cyclone “Dineo” now over southern Mozambique*.

- Sridevi, C., Pattanaik, D., Das, A., Srivastava, A., Durai, V., Johny, C., Deshpande, M., Suneetha, P., & Kanase, R. (2022). Tropical cyclone track and intensity prediction skill of GFS model over NIO during 2019 & 2020. *Tropical Cyclone Research and Review*, *11*, 36-49. <https://doi.org/10.1016/j.tcr.2022.04.002>
- Steenkamp, S. C., Kilroy, G., & Smith, R. K. (2019). Tropical cyclogenesis at and near the Equator. *Royal Meteorological Society*, *145*, 1846–1864. <https://doi.org/10.1002/qj.3529>
- Strangeways, I. (2003). *Precipitation: Theory, Measurement and Distribution*. Cambridge University Press 2003.
- Stull, R. (2017). *Practical Meteorology: An Algebra-based Survey of Atmospheric Science*. University of British Columbia.
- Tang, L., Wang, Y., Yu, Z., & Wang, L. (2018). The Asymmetric Precipitation Evolution in Weak Landfalling Tropical Cyclone Rumbia (2018) Over East China. *Frontiers in Earth Science*, *9*, 1-9. <https://doi.org/10.3389/feart.2021.747271>
- Tapiador, F. J., Turk, J., Petersen, W., Hou, A. Y., Garc'ia-Ortega, E., Machado, L. A., Angelis, C. F., Salio, P., Kidd, C., Huffman, G. J., & Castro, M. d. (2011). Global Precipitation Measurement: Methods, Datasets and Applications. *Preprint submitted to Atmospheric Research*, 1-29.
- Tartaglione, N., Mariani, S., Accadia, C., Speranza, A., & Casaioli, M. (2005). Comparison of rain gauge observations with modeled precipitation over Cyprus using Contiguous Rain Area analysis. *Atmospheric Chemistry and Physics*, *5*, 2147–2154.
- Tinga, S. O. (2023). *Contribuição dos Ciclones Tropicais para a Precipitação em Moçambique no Período de 1982 a 2022*. Universidade de Aveiro.
- Torn, R. D., Whitaker, J. S., Pegion, P., Hamill, T. M., & Hakim, G. J. (2015). Diagnosis of the Source of GFS Medium-Range Track Errors in Hurricane Sandy (2012). *Monthly Weather Review*, *143*, 132-152. <https://doi.org/10.1175/MWR-D-14-00086.1>

- Tu, S., Chan, J. C., Xu, J., & Zhong, Q. (2022). Increase in tropical cyclone rain rate with translation speed. *Nature Communications*, *13*, 1-8. <https://doi.org/10.1038/s41467-022-35113-8>
- Tuleya, R. E., & Kurihara, Y. (1981). A Numerical Study on the Effects of Environmental Flow on Tropical Storm Genesis. *Monthly Weather Review*, *109*, 2487-2506.
- UNICEF. (01 de Janeiro de 2022). *Tropical Storm Ana in Mozambique*. unicef: <https://www.unicef.org/mozambique/en/tropical-storm-ana-mozambique>
- USAID. (2012). *Mozambique Climate Vulnerability Profile*. Annex to USAID Agency Sustainability Plan and Agency Adaption Plan.
- USAID. (2018). *Perfil de Risco Climático: Moçambique*. United States Agency International Development.
- USAID. (2019). *Mozambique - Tropical Cyclone Idai*. United States Agency International Development.
- Villarini, G., Goska, R., Smith, J. A., & Vecchi, G. A. (2014). North Atlantic Tropical Cyclones and U.S. Flooding. *American Meteorology Society*, 1381-1388. <https://doi.org/10.1175/BAMS-D-13-00060.1>
- Vitart, F., Anderson, D., & Stockdale, T. (2003). Seasonal Forecasting of Tropical Cyclone Landfall over Mozambique. *Journal of Climate*, *16*, 3932-3945. [https://doi.org/10.1175/1520-0442\(2003\)016<3932:SFOTCL>2.0.CO;2](https://doi.org/10.1175/1520-0442(2003)016<3932:SFOTCL>2.0.CO;2)
- Wada, A., & Usui, N. (2007). Importance of Tropical Cyclone Heat Potential for Tropical Cyclone Intensity and Intensification in the Western North Pacific. *Journal of Oceanography*, *63*, 427 - 447. <https://doi.org/10.1007/s10872-007-0039-0>
- Wadler, J. B., Rudzin, J. E., Cruz, B. J., Chen, J., Fischer, M., Chen, G., Qin, N., Tang, B., & Li, Q. (2023). A review of recent research progress on the effect of external influences on tropical cyclone intensity change. *Tropical Cyclone Research and Review*, *12*, 200–215. <https://doi.org/10.1016/j.tcr.2023.09.001>

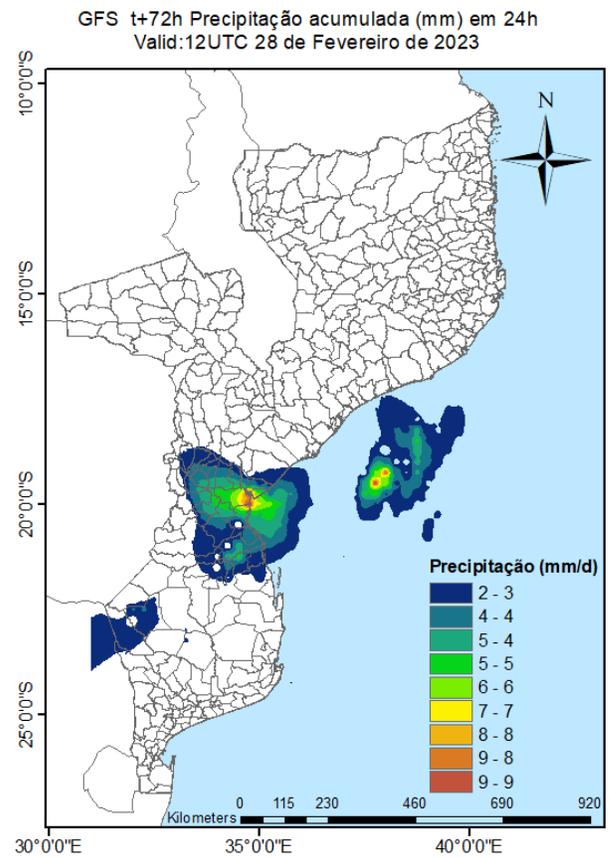
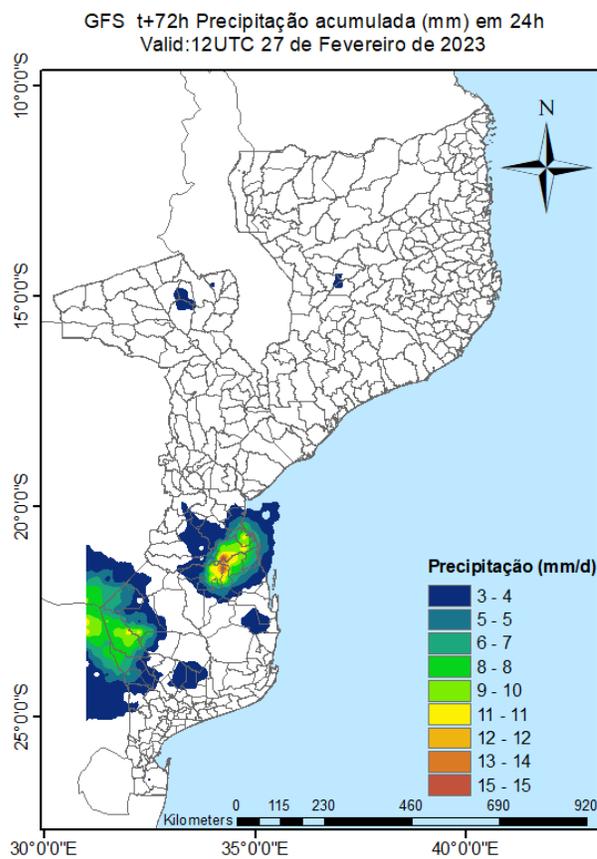
- Wang, W., & Lu, Y. (2018). Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. *IOP Conference Series: Materials Science and Engineering*, 324, 1-11. <https://doi.org/10.1088/1757-899X/324/1/012049>
- Wang, W., Zhang, Z., Cangialosi, J. P., Brennan, M., Cowan, L., Clegg, P., Takuya, H., Masaaki, I., Das, A. K., Mohapatra, M., Sharma, M., Knaff, J. A., Kaplan, J., Birchard, T., & D, J. (2023). A review of recent advances (2018–2021) on tropical cyclone intensity change from operational perspectives, part 2: Forecasts by operational centers. *Tropical Cyclone Research and Review*, 12, 50-63. <https://doi.org/10.1016/j.tcr.2023.05.003>
- Wang, Y., & Wu, C.-C. (2004). Current understanding of tropical cyclone structure and intensity changes – a review. *Meteorological Atmospheric Physics*, 87, 257–278. <https://doi.org/10.1007/s00703-003-0055-6>
- Wang, Z., Zhao, J., Huang, H., & Wang, X. (2022). A Review on the Application of Machine Learning Methods in Tropical Cyclone Forecasting. *Frontiers in Earth Science*, 10, 1-17. <https://doi.org/10.3389/feart.2022.902596>
- Witcraft, N. C., Lin, Y.-L., & Kuo, Y.-H. (2005). Dynamics of Orographic Rain Associated with the Passage of a Tropical Cyclone over a Mesoscale Mountain. *Terrestrial, Atmospheric and Oceanic Sciences*, 16, 1133-1161. [https://doi.org/10.3319/TAO.2005.16.5.1133\(A\)](https://doi.org/10.3319/TAO.2005.16.5.1133(A))
- WMO. (2012). *Guide to Meteorological Instruments and Methods of Observation*. World Meteorological Organization.
- WMO. (26 de Abril de 2019). *Another unprecedented tropical cyclone and flooding hits Mozambique*. World Meteorological Organization: <https://wmo.int/media/news/another-unprecedented-tropical-cyclone-and-flooding-hits-mozambique>
- WMO. (22 de Janeiro de 2021). *Tropical Cyclone Eloise hits Mozambique*. World Meteorological Organization: <https://wmo.int/media/news/tropical-cyclone-eloise-hits-mozambique#:~:text=Tropical%20Cyclone%20Eloise%20made%20landfall%20at%20Category%201%20strength%2C%20with,24%20hours%2C%20according%20to%20INAM.>

- WMO. (20 de Setembro de 2023a). *Classification of tropical cyclones*. World Meteorological Organization: <https://wmo.int/content/classification-of-tropical-cyclones>
- WMO. (10 de Março de 2023b). *Tropical Cyclone Freddy may set new record*. public.wmo.int: <https://public.wmo.int/en/media/news/tropical-cyclone-freddy-may-set-new-record>
- World Bank. (2018). *Improving Lead Time for Tropical Cyclone Forecasting*. <https://doi.org/https://doi.org/10.1596/29825>
- Wu, W., & Chen, J.-L. (2012). Sensitivity of Tropical Cyclone Precipitation to Atmospheric Moisture Content: Case Study of Bilis (2006). *Atmospheric and Oceanic Science Letters*, 5, 420–425. <https://doi.org/10.1080/16742834.2012.11447030>
- Xiao, Q., Kuo, Y.-H., Sun, J., Lee, W.-C., Barker, D. M., & Lim, E. (2007). An Approach of Radar Reflectivity Data Assimilation and Its Assessment with the Inland QPF of Typhoon Rusa (2002) at Landfall. *Journal of Applied Meteorology and Climatology*, 46, 14-22. <https://doi.org/10.1175/JAM2439.1>
- Yamada, K., & Kuribayashi, M. (2021). Topographic Effect on Heavy Rainfall Caused by Typhoon Hagibis (2019) in Nagano, Japan. *SOLA*, 17A, 45-50. <https://doi.org/10.2151/sola.17A-008>
- Yamaguchi, M., Chan, J. C., Moon, I.-J., Yoshida, K., & Mizuta, R. (2020). Global warming changes tropical cyclone translation speed. *Nature Communications*, 11, 1-7. <https://doi.org/10.1038/s41467-019-13902-y>
- Yu, X., Park, S. K., Lee, Y. H., & Choi, Y. S. (2013). Quantitative Precipitation Forecast of a Tropical Cyclone through Optimal Parameter Estimation in a Convective Parameterization. *SOLA*, 9, 36-39. <https://doi.org/10.2151/sola.2013-009>
- Yu, Z., & Wang, Y. (2018). Rainfall Distribution in Landfalling Tropical Cyclones. Em *Extreme Weather* (pp. 49-84). IntechOpen. <https://doi.org/10.5772/intechopen.75910>
- Yurchak, B. S. (2022). Intensity Measurements of a Landfalling Tropical Cyclone Using Conventional Coastal Weather Radar. *Meteorology*, 1, 113–126. <https://doi.org/10.3390/meteorology1020007>

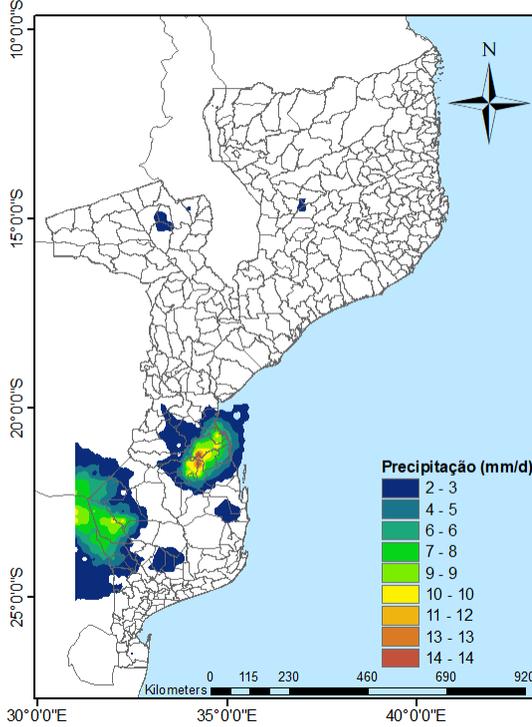
- Zhang, H., & Pu, Z. (2014). Influence of Assimilating Surface Observations on Numerical Prediction of Landfalls of Hurricane Katrina (2005) with an Ensemble Kalman Filter. *Monthly Weather Review*, *142*, 2915-2934. <https://doi.org/10.1175/MWR-D-14-00014.1>
- Zhang, Z., Dong, X., Hon, K., & Liu, L. (2019). Tropical Cyclone Surface Pressure Field Estimation Using Satellite Passive Microwave Observations over the Oceans. *Journal of Geophysical Research: Oceans*, *124*, 7854–7872. <https://doi.org/10.1029/2019JC015136>
- Zhao, K., Li, X., Xue, M., Jou, B. J.-D., & Lee, W.-C. (2012). Short-term forecasting through intermittent assimilation of data from Taiwan and mainland China coastal radars for Typhoon Meranti (2010) at landfall. *Journal of Geophysical Research*, *117*, 1-20. <https://doi.org/10.1029/2011JD017109>
- Zhu, L., Wan, Q., Shen, X., Meng, Z., Zhang, F., Weng, Y., Sippel, J., Gao, Y., Zhang, Y., & Yue, J. (2016). Prediction and Predictability of High-Impact Western Pacific Landfalling Tropical Cyclone Vicente (2012) through Convection-Permitting Ensemble Assimilation of Doppler Radar Velocity. *Monthly Weather Review*, *144*, 21-43. <https://doi.org/10.1175/MWR-D-14-00403.1>

Apêndices

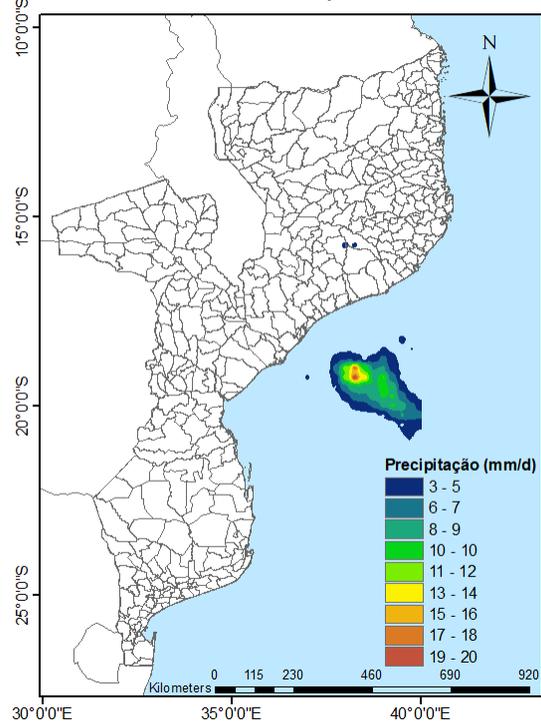
Estas Figuras são todas referentes a previsão da precipitação do ciclone Freddy para 72h de *lead time*. Quando comparados à previsão de 24h de *lead time* (que é a melhor previsão) ou com os dados observados, estas previsões são bastante abaixo daquilo que se consideraria como precipitação do ciclone Freddy. Além disso, a localização da precipitação da precipitação é outro aspecto que levanta bastantes duvidas sobre a utilidade destas previsões, visto que a precipitação é observada em locais onde o sistema não foi observado. Essa foi a razão pela qual estes dados foram excluídos da análise.



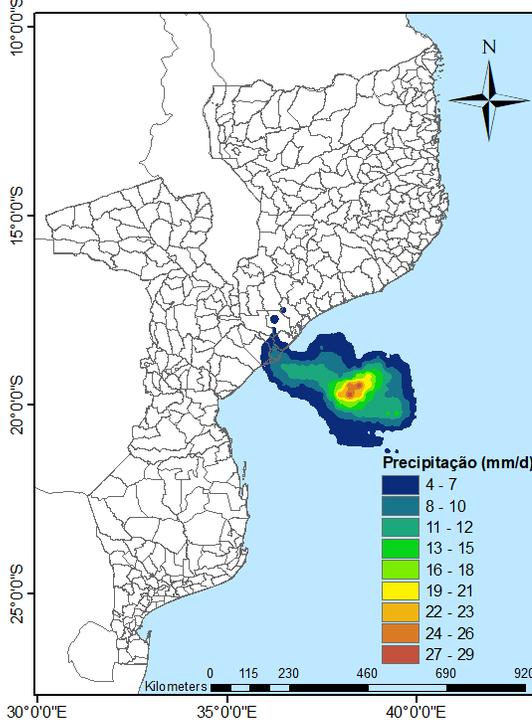
GFS t+72h Precipitação acumulada (mm) em 24h
Valid:12UTC 26 de Fevereiro de 2023



GFS t+72h Precipitação acumulada (mm) em 24h
Valid:12UTC 15 de Março de 2023



GFS t+72h Precipitação acumulada (mm) em 24h
Valid:12UTC 14 de Março de 2023



GFS t+72h Precipitação acumulada (mm) em 24h
Valid:12UTC 13 de Março de 2023

