

**INSTITUTO FEDERAL DE SANTA CATARINA**

**ANDRÉ FRANCISCO PUGAS**

**MODELAGEM DOS DESASTRES HIDROMETEOROLÓGICOS EM SANTA  
CATARINA PARA ANÁLISE DA EFETIVIDADE DO SISTEMA DE ALERTA DA  
DEFESA CIVIL**

**FLORIANÓPOLIS**

**2024**

**ANDRÉ FRANCISCO PUGAS**

**MODELAGEM DOS DESASTRES HIDROMETEOROLÓGICOS EM SANTA  
CATARINA PARA ANÁLISE DA EFETIVIDADE DO SISTEMA DE ALERTA DA  
DEFESA CIVIL**

Dissertação apresentada ao  
Mestrado Profissional em  
Clima e Ambiente do Campus  
Florianópolis do Instituto  
Federal de Santa Catarina  
para a obtenção do diploma  
de Mestre em Clima e  
Ambiente.

Orientador: Adriano Vitor  
Coorientador: Mário Francisco  
Leal de Quadro

**FLORIANÓPOLIS**

**2024**

CDD 551.6  
P978m

Pugas, André Francisco

Modelagem dos desastres hidrometeorológicos em Santa Catarina para análise da efetividade do sistema de alerta da Defesa Civil [DIS] / André Francisco Pugas; orientação de Adriano Vitor; coorientação de Mário Francisco Leal de Quadro – Florianópolis, 2024.

1 v.: il.

Dissertação de Mestrado (Clima e Ambiente) – Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Inclui referências.

1. Sistemas de alertas de desastres. 2. Python. 3. Machine learning. 4. Random forest. 5. Meteorologia. I. Vitor, Adriano. II. Quadro, Mário Francisco Leal de. III. Título.

Sistema de Bibliotecas Integradas do IFSC

Biblioteca Dr. Hercílio Luz – Campus Florianópolis

Catalogado por: Ana Paula F. Rodrigues - CRB 14/1117



## Folha de Aprovação

Aluno (a): **ANDRÉ FRANCISCO PUGAS**

|                |                                                                                                                                       |
|----------------|---------------------------------------------------------------------------------------------------------------------------------------|
| <b>Título:</b> | <b>Modelagem dos desastres hidrometeorológicos em Santa Catarina para análise da efetividade do sistema de alerta da defesa civil</b> |
|----------------|---------------------------------------------------------------------------------------------------------------------------------------|

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

**Dr(a). ADRIANO VITOR**



Documento assinado digitalmente  
**ADRIANO VITOR**  
Data: 21/10/2024 14:50:40-0300  
CPF: \*\*\*.799.019-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

**Orientador(a) / Presidente / IFSC / local – SC**

Participação: ☒ Presencial ☐ Videoconferência  
(☒) **Aprovado** (☐) **Reprovado**

**Dr(a). THIAGO PEREIRA ALVES**



Documento assinado digitalmente  
**THIAGO PEREIRA ALVES**  
Data: 22/10/2024 18:09:01-0300  
CPF: \*\*\*.525.469-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

**Avaliador(a) Interno / xxxxxxxx / local - SC**

Participação: ☐ Presencial ☒ Videoconferência  
(☒) **Aprovado** (☐) **Reprovado**

**Dr(a). MICHEL NOBRE MUZA**



Documento assinado digitalmente  
**MICHEL NOBRE MUZA**  
Data: 22/10/2024 13:01:46-0300  
CPF: \*\*\*.090.260-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

**Avaliador(a) Interno / xxxxxxxx / xxxxxxxxxxxx - SC**

Participação: ☒ Presencial ☐ Videoconferência  
(☒) **Aprovado** (☐) **Reprovado**

**Dr(a). ROGÉRIO DE SOUZA VERSAGE**



Documento assinado digitalmente  
**ROGERIO DE SOUZA VERSAGE**  
Data: 21/10/2024 15:02:32-0300  
CPF: \*\*\*.961.631-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

**Avaliador(a) Externo / xxxxxxxx / xxxxxxxxxxxx - SC**

Participação: ☒ Presencial ☐ Videoconferência  
(☒) **Aprovado** (☐) **Reprovado**

*Este trabalho foi aprovado por:*

- ( ) maioria simples  
( X ) unanimidade

**Florianópolis, 17 de outubro de 2024**



Dedico este trabalho aos meus pais, Marlene Cavalheiro Pugas (*in memoriam*) e Ilton Pugas, à minha esposa Cristiane Pereira Camargo, à minha filha Mariáh Camargo Pugas, que é a luz dos meus olhos e a minha maior inspiração, dedico este trabalho com todo o amor e carinho. A vocês, minha família, que sempre me motivaram a ser melhor e me ajudaram em todos os momentos, meu eterno agradecimento e amor.

## **AGRADECIMENTOS**

Primeiramente, agradeço ao meu orientador Adriano Vitor, e ao meu coorientador Mario Francisco Leal de Quadro, pela orientação e apoio inestimáveis ao longo de todo o processo de pesquisa. Suas experiências e conhecimentos foram fundamentais para a conclusão deste trabalho e para o meu desenvolvimento como pesquisador.

Agradeço também aos professores e colegas de curso, que compartilharam seus conhecimentos e experiências, tornando possível a realização deste trabalho. Em especial, gostaria de agradecer a Alfeu Luz Losso e Eliseo Breda da Silva, que marcaram este curso pela sua amizade, momentos de descontração e conhecimento compartilhado.

Agradeço ao Instituto Federal de Santa Catarina, por oferecer a oportunidade de realizar este mestrado e por todo o apoio logístico e administrativo.

À minha esposa Cristiane Pereira Camargo, que me apoiou e encorajou em todos os momentos, mesmo quando a pesquisa parecia impossível, sou grato por todo o amor e paciência dedicados a mim. À minha filha Maria Camargo Pugas, que trouxe luz e alegria a cada dia da minha vida, sou grato por me mostrar o verdadeiro significado da felicidade e por inspirar a persistência em mim.

Por fim, agradeço a todas as pessoas que contribuíram para a pesquisa, com destaque a Roseli de Oliveira, mestre em Clima e Ambiente e Frederico de Moraes Rudorff, Coordenador do Monitoramento e Alerta da Defesa Civil de Santa Catarina, sem as quais este trabalho não seria possível. Agradeço a todos os envolvidos, cujas contribuições foram essenciais para a realização deste estudo.

A todos, meu muito obrigado!

Faça o teu melhor, na condição que você tem, enquanto você não tem condições  
melhores, para fazer melhor ainda!  
(Mario Sergio Cortella, 2017)

## RESUMO

Nas últimas décadas, a ocorrência de desastres naturais intensificou-se devido às mudanças climáticas, causando graves impactos econômicos e humanos. Santa Catarina, um estado frequentemente atingido por eventos hidrometeorológicos extremos, tem investido em sistemas de alerta para mitigar esses impactos. No entanto, qual é a efetividade dessa iniciativa nas diferentes regiões e cidades de Santa Catarina? Esta pesquisa propõe um método de avaliação sobre a efetividade dos alertas de desastres emitidos pela Defesa Civil de Santa Catarina, por meio de um modelo de *Machine Learning*, baseado no algoritmo *Random Forest*, denominado *Chronocast*, que incorpora dados meteorológicos, alertas emitidos e registros de danos. A pesquisa caracteriza-se por sua natureza aplicada, predominantemente descritiva, combinando uma abordagem quantitativa e qualitativa, com técnicas de cunho experimental utilizando a linguagem *Python* e suas bibliotecas. Os dados meteorológicos foram coletados de estações automáticas do INMET em 24 cidades do estado, enquanto os alertas e registros de danos foram obtidos da Defesa Civil e do Sistema Integrado de Informações sobre Desastres (S2ID). A metodologia incluiu a utilização do algoritmo *Random Forest*, com 60% dos dados para teste e 40% de dados para treino, calibrado para otimizar a precisão das previsões e validado por meio de técnicas de validação cruzada e *SMOTE* para tratar o desequilíbrio de classes nos dados. Os principais resultados indicam que a média geral de assertividade dos alertas emitidos pela Defesa Civil foi de 30,54%, classificando-o como de efetividade moderada. O *Chronocast* conseguiu prever com eficácia a ocorrência de danos associados a desastres hidrometeorológicos em diversas cidades de Santa Catarina, demonstrando uma média geral de acertos de 52,20%. O modelo integra uma análise detalhada das variáveis climáticas e de alerta, capturando nuances específicas que podem ser perdidas nos métodos tradicionais de avaliação. Em mesorregiões onde o modelo superou a Defesa Civil, como Norte Catarinense, Vale do Itajaí, Mesorregião Serrana e Oeste Catarinense, a precisão do modelo foi particularmente elevada. Cidades como Indaial, Itapoá, Chapecó, Lages, Urussanga, Curitiba, Rio do Campo, Dionísio Cerqueira e Bom Jardim da Serra apresentaram as melhores performances, com um alto grau de

acurácia nas previsões, enquanto cidades como Araranguá e Xanxerê tiveram menor desempenho. A comparação entre os resultados do modelo e a efetividade dos alertas emitidos pela Defesa Civil revelou que o modelo pode ser uma ferramenta auxiliar valiosa, proporcionando uma avaliação mais precisa dos riscos e melhorando a tomada de decisão na emissão de alertas. Contudo, o modelo apresentou limitações em capturar a complexidade de certas regiões, indicando a necessidade de aprimoramentos contínuos. A conclusão reforça que a metodologia empregada é promissora para avaliar a efetividade dos alertas de desastres, contribuindo significativamente para a otimização dos sistemas de alerta em Santa Catarina. Futuras pesquisas devem focar na integração de mais variáveis climáticas e socioeconômicas, além de explorar técnicas avançadas de *Machine Learning*, *Deep Learning* e redes neurais para melhorar a precisão das previsões em regiões com menor desempenho.

**Palavras-chave:** Sistemas de alertas de desastres, Python, *Machine learning*, *Random forest*, Meteorologia.

## **ABSTRACT**

In recent decades, the occurrence of natural disasters has intensified due to climate change, causing severe economic and human impacts. Santa Catarina, a state frequently affected by extreme hydrometeorological events, has invested in early warning systems to mitigate these impacts. However, what is the effectiveness of this initiative in the different regions and cities of Santa Catarina? This research aims to propose a method and evaluation of the effectiveness of early warning systems issued by the Civil Defense of Santa Catarina, through a Machine Learning model, based on the Random Forest algorithm, called Chronocast, which incorporates meteorological data, issued alerts, and damage records. The research is characterized by its applied nature, predominantly descriptive, combining a quantitative and qualitative approach, with experimental techniques using the Python tool. Meteorological data were collected from automatic stations of INMET in 24 cities of the state, while alerts and damage records were obtained from the Civil Defense and the Integrated Disaster Information System (S2ID). The methodology included the use of the Random Forest algorithm, with 60% of the data for testing and 40% of data for training, calibrated to optimize prediction accuracy and validated through cross-validation techniques and SMOTE to address class imbalance in the data. The main results indicate that the overall accuracy of the alerts issued by the Civil Defense was 30.54%, classifying it as moderately effective. Chronocast successfully predicted the occurrence of damage associated with hydrometeorological disasters in various cities in Santa Catarina, demonstrating an overall accuracy rate of 52.20%. The model integrates a deeper and more detailed analysis of climatic and alert variables, capturing specific nuances that may be missed by traditional evaluation methods. In mesoregions where the model outperformed the Civil Defense, such as Norte Catarinense, Vale do Itajaí, Mesorregião Serrana, and Oeste Catarinense, the model's accuracy was particularly high. Cities like Indaial, Itapoá, Chapecó, Lages, Urussanga, Curitibanos, Rio do Campo, Dionísio Cerqueira, and Bom Jardim da Serra showed the best performances, with a high degree of accuracy in predictions, while cities like Araranguá and Xanxerê had lower performance. The comparison

between the model's results and the effectiveness of the alerts issued by the Civil Defense revealed that the model could be a valuable auxiliary tool, providing a more accurate risk assessment and improving decision-making in alert issuance. However, the model showed limitations in capturing the complexity of certain regions, indicating the need for continuous improvements. The conclusion reinforces that the employed methodology is adequate for evaluating the effectiveness of disaster alerts, significantly contributing to the optimization of early warning systems in Santa Catarina. Future research should focus on integrating more climatic and socioeconomic variables, as well as exploring advanced Machine Learning techniques, Deep Learning, and neural networks to improve prediction accuracy in regions with lower performance.

Keywords: Early warning systems, Python, Machine learning, Random forest, Meteorology.

## LISTA DE FIGURAS

|                                                                                                                                                 |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 1: Estratégia Internacional das Nações Unidas para a Redução dos riscos de desastres. ....                                               | 25  |
| Figura 2: Comparativo do impacto dos desastres registrados entre 1980 - 1999 e 2000 - 2019. ....                                                | 37  |
| Figura 3: Comparativo do total de desastres por tipo de evento registrados entre 1980 - 1999 e 2000 - 2019. ....                                | 39  |
| Figura 4: Linha do tempo dos desastres hidrometeorológicos registrados no Estado de Santa Catarina. ....                                        | 44  |
| Figura 5: Escala espacial e temporal dos sistemas meteorológicos. ....                                                                          | 46  |
| Figura 6: Células de circulação geral, ventos globais predominantes e centros de Alta (A) e Baixa (B) pressão atmosféricas. ....                | 59  |
| Figura 7: Elementos chave que compõem os sistemas de alerta de desastres. ....                                                                  | 82  |
| Figura 8: Levantamento geoespacial dos países que relatam ou possuem sistemas de alerta multi ameaças pela metodologia do Marco de Sendai. .... | 84  |
| Figura 9: Funcionamento do sistema de alerta no Brasil. ....                                                                                    | 93  |
| Figura 10: Elementos do sistema de alerta de desastres em Santa Catarina. ....                                                                  | 95  |
| Figura 11: Fluxograma do CoMAI. ....                                                                                                            | 98  |
| Figura 12: Fluxograma do processo de monitoramento em Santa Catarina. ....                                                                      | 100 |
| Figura 13: Carta de SC, com as mesorregiões e distribuição da rede de estações automáticas do INMET. ....                                       | 129 |
| Figura 14: Tela inicial do sistema S2ID da Defesa Civil Nacional. ....                                                                          | 131 |
| Figura 15: Esquema gráfico da metodologia aplicada à pesquisa. ....                                                                             | 140 |
| Figura 16: Média dos Tempos de Execução do Algoritmo com Intervalo de Confiança por Estação (99%). ....                                         | 142 |
| Figura 17: Média de $R^2$ de Teste com intervalo de confiança por cidade (99%). ...                                                             | 145 |
| Figura 18: Média de $R^2$ de Treino com intervalo de confiança por cidade (99%). .                                                              | 148 |
| Figura 19: Média geral da representatividade das variáveis para a mesorregião da Grande Florianópolis. ....                                     | 152 |
| Figura 20: Representatividade geral por variável para a mesorregião Norte. ....                                                                 | 156 |
| Figura 21: Representatividade geral por variável para a mesorregião Sul. ....                                                                   | 160 |
| Figura 22: Representatividade geral por variável para a mesorregião Oeste. ....                                                                 | 164 |

|                                                                                                                                                                 |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 23: Representatividade geral por variável para a mesorregião Serrana. ....                                                                               | 167 |
| Figura 24: Representatividade geral por variável para a mesorregião Vale do Itajaí.<br>.....                                                                    | 169 |
| Figura 25: Média da representatividade geral das variáveis em toda Santa Catarina.<br>.....                                                                     | 171 |
| Figura 26: Percentual de assertividade dos alertas em relação aos danos registrados<br>pela Defesa Civil e pelo Modelo <i>Chromecast</i> por cidade. ....       | 184 |
| Figura 27: Comparativo da assertividade da emissão do alerta e dano registrado<br>pela Defesa Civil e do Modelo <i>Chronocast</i> por cidades cidades.<br>..... | 189 |
| Figura 28: Representatividade das variáveis nas cidades com altas performances de<br>acordo com o Modelo <i>Chronocast</i> . ....                               | 191 |
| Figura 29: Representatividade das variáveis nas cidades com baixas performances<br>de acordo com o Modelo <i>Chronocast</i> . ....                              | 193 |
| Figura 30: Comparativo da representatividade das variáveis nas cidades com altas e<br>baixas performances de acordo com o Modelo <i>Chronocast</i> . ....       | 195 |
| Figura 31: Cartaz da V Jornada Clima e Ambiente. ....                                                                                                           | 201 |
| Figura 32: Cartaz do Simpósio em clima, água, energia e alimentos de 2022. ....                                                                                 | 202 |
| Figura 33: Cartaz do IV Simpósio Ibero - Afro - Americano de RISCOS. ....                                                                                       | 203 |
| Figura 34: <i>Layout</i> inicial da execução do <i>Chronocast</i> no <i>VSCode</i> . ....                                                                       | 205 |
| Figura 35: Imagem ilustrativa do relatório técnico conclusivo sobre os resultados da<br>avaliação dos alertas da Defesa Civil de Santa Catarina. ....           | 207 |

## LISTA DE QUADROS

|                                                                                                                          |     |
|--------------------------------------------------------------------------------------------------------------------------|-----|
| Quadro 1: Frequência, tipo e subtipo de desastres naturais e número de afetados e óbitos no período de 1970 a 2016. .... | 37  |
| Quadro 2: Variáveis utilizadas pelo Modelo <i>Chronocast</i> .....                                                       | 131 |
| Quadro 3: Parâmetros utilizados como entrada no Modelo <i>Chronocast</i> . ....                                          | 136 |

## LISTA DE TABELAS

|                                                                                                                       |     |
|-----------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1: Consequências ambientais e socioeconômicas dos desastres provocados por fenômenos hidrometeorológicos. .... | 33  |
| Tabela 2: Matriz de severidade dos avisos. ....                                                                       | 106 |
| Tabela 3: Matriz de severidade de alertas. ....                                                                       | 106 |
| Tabela 4: Comparativo da classificação das performances da Defesa Civil e do Modelo <i>Chromecast</i> . ....          | 186 |

## LISTA DE ABREVIATURAS E SIGLAS

|         |                                                                                       |
|---------|---------------------------------------------------------------------------------------|
| ABNT    | Associação Brasileira de Normas Técnicas                                              |
| ANA     | Agência Nacional de Águas                                                             |
| ANATEL  | Agência Nacional de Telecomunicações                                                  |
| ASAS    | Anticiclone Subtropical do Atlântico Sul                                              |
| ASPS    | Anticiclone Subtropical do Pacífico Sul                                               |
| CAT     | Centro de Alerta Temprana                                                             |
| Cb      | Cumulonimbus                                                                          |
| CCMs    | Complexos Convectivos de Mesoescala                                                   |
| CEMADEN | Centro Nacional de Monitoramento e Alertas de Desastres Naturais                      |
| CENAD   | Centro Nacional de Gerenciamento de Riscos e Desastres                                |
| CEPED   | Centro de Estudos e Pesquisas em Engenharia e Defesa Civil                            |
| CIGERD  | Centro Integrado de Gerenciamento de Riscos e Desastres                               |
| CIASC   | Centro de Informática e Automação do Estado de Santa Catarina                         |
| CIRAM   | Centro de Informações de Recursos Ambientais e de Hidrometeorologia de Santa Catarina |
| CLA     | Camada Limite da Atmosfera                                                            |
| CNN     | Convolutional Neural Network                                                          |
| COBRADE | Código Brasileiro de Desastres                                                        |
| CoMAL   | Coordenadoria de Monitoramento e Alerta                                               |
| CPRM    | Serviço Geológico do Brasil                                                           |
| CREWS   | Climate Risk and Early Warning Systems                                                |
| DCSC    | Defesa Civil do Estado de Santa Catarina                                              |
| DGRI    | Diretoria de Gestão de Riscos                                                         |
| DOL     | Distúrbio Ondulatório de Leste                                                        |
| EAM     | Emergency Alert Mail                                                                  |
| EEWS    | Earthquake Early Warning System                                                       |
| EM-DAT  | Emergency Events Database                                                             |
| ENSO    | El Niño Oscilação Sul                                                                 |
| EPAGRI  | Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina                   |

|                |                                                   |
|----------------|---------------------------------------------------|
| EUMETNET       | European Meteorological Service Network           |
| F1-Score       | Medida F                                          |
| FDMA           | Fire and Disaster Management Agency               |
| FEMA           | Federal Emergency Management Agency               |
| Fold           | Processo de Validação Cruzada em Machine Learning |
| GHE            | Green House Effect                                |
| GLAM           | Global Agricultural Monitoring                    |
| HIGHWAY        | High Impact Whether Lake System                   |
| IA             | Inteligencia Artificial                           |
| IDAP           | Interface de Divulgação de Alertas Públicos       |
| IFSC           | Instituto Federal de Santa Catarina               |
| INMET          | Instituto Nacional de Meteorologia                |
| INPE           | Instituto Nacional de Pesquisas Espaciais         |
| IoT            | Internet das Coisas                               |
| IPAWS          | Integrated Public Alert & Warning System          |
| IPCC           | Intergovernmental Panel on Climate Change         |
| JBN            | Jatos de Baixos Níveis                            |
| LI             | Linhas de Instabilidade                           |
| MAE            | Erro Médio Absoluto                               |
| ML             | Machine Learning                                  |
| MSA            | Moção Sul Americana                               |
| NASA           | National Aeronautics and Space Administration     |
| NN             | Neural Networking                                 |
| ODS            | Objetivos do Desenvolvimento Sustentável          |
| OLR            | Radiação de onda longa emitida                    |
| OMJ            | Oscilação de Madden-Julian                        |
| ONU            | Organização das Nações Unidas                     |
| PDO            | Pacific Decadal Oscillation                       |
| PNPDEC         | Política Nacional de Proteção e Defesa Civil      |
| R <sup>2</sup> | Coeficiente de Determinação                       |
| RNN            | Recurrent Neural Network                          |
| ROC            | Receiver Operating Characteristic                 |

|         |                                                                                             |
|---------|---------------------------------------------------------------------------------------------|
| SCMs    | Sistemas Convectivos de Mesoescala                                                          |
| SDE     | Secretaria de Estado do Desenvolvimento Econômico Sustentável                               |
| SEDEC   | Secretaria Nacional de Proteção e Defesa Civil                                              |
| SIMEPAR | Sistema Meteorológico do Paraná                                                             |
| SINPDEC | Sistema Nacional de Proteção e Defesa Civil                                                 |
| SIFAP   | Sistema Integrado de Ferramentas de Análise e Previsão Hidrometeorológica de Santa Catarina |
| SisDC   | Sistema Informatizado de Proteção e Defesa Civil                                            |
| SMOTE   | Synthetic Minority Over-sampling Technique                                                  |
| SMS     | Short Message Service                                                                       |
| SOMAR   | Southern Marine Weather Services                                                            |
| SVM     | Support Vector Machine                                                                      |
| UFSC    | Universidade Federal do Estado de Santa Catarina                                            |
| UNDP    | United Nation Development Programme                                                         |
| UNDRR   | United Nation Office for Disaster Risk Reduction                                            |
| UNISDR  | United Nation Office Strategy for Disaster Reduction                                        |
| UNOOSA  | United Nation Office for Outer Space Affairs                                                |
| USGS    | United States Geological Survey                                                             |
| VCAN    | Vórtices Ciclônicos de Altos Níveis                                                         |
| WISE    | Weather Climate and Information Services                                                    |
| WMO     | World Meteorological Organization                                                           |
| WRF     | Weather Research and Forecasting                                                            |
| ZCAS    | Zona de Convergência do Atlântico Sul                                                       |
| ZCASO   | Zona de Convergência do Atlântico Sul Oceânica                                              |
| ZCIT    | Zona de Convergência Intertropical                                                          |
| ZCOU    | Zona de Convergência de Umidade                                                             |
| Z-Score | Escore Padronizado                                                                          |

## SUMÁRIO

|                                                                                                                                                                                          |           |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>MODELAGEM DOS DESASTRES HIDROMETEOROLÓGICOS EM SANTA CATARINA<br/>PARA ANÁLISE DA EFETIVIDADE DO SISTEMA DE ALERTA DA DEFESA CIVIL.....</b>                                           | <b>0</b>  |
| <b>MODELAGEM DOS DESASTRES HIDROMETEOROLÓGICOS EM SANTA CATARINA<br/>PARA ANÁLISE DA EFETIVIDADE DO SISTEMA DE ALERTA DA DEFESA CIVIL.....</b>                                           | <b>1</b>  |
| Modelagem dos Desastres hidrometeorológicos em Santa Catarina para análise da<br>Efetividade do Sistema de Alerta da Defesa Civil / André Francisco Pugas. -<br>Florianópolis, 2024..... | 2         |
| AGRADECIMENTOS.....                                                                                                                                                                      | 5         |
| RESUMO.....                                                                                                                                                                              | 7         |
| ABSTRACT.....                                                                                                                                                                            | 9         |
| LISTA DE FIGURAS.....                                                                                                                                                                    | 11        |
| LISTA DE QUADROS.....                                                                                                                                                                    | 13        |
| LISTA DE TABELAS.....                                                                                                                                                                    | 14        |
| LISTA DE ABREVIATURAS E SIGLAS.....                                                                                                                                                      | 15        |
| SUMÁRIO.....                                                                                                                                                                             | 18        |
| <b>1 INTRODUÇÃO.....</b>                                                                                                                                                                 | <b>21</b> |
| <b>2 JUSTIFICATIVA.....</b>                                                                                                                                                              | <b>22</b> |
| 2.1 OBJETIVOS.....                                                                                                                                                                       | 26        |
| <b>2.1.1 Objetivo geral.....</b>                                                                                                                                                         | <b>26</b> |
| <b>2.1.2 Objetivo(s) específico(s).....</b>                                                                                                                                              | <b>26</b> |
| 2.1.3 Estrutura do Trabalho.....                                                                                                                                                         | 27        |
| <b>3 REVISÃO BIBLIOGRÁFICA.....</b>                                                                                                                                                      | <b>29</b> |
| 3.1 DESASTRES NATURAIS.....                                                                                                                                                              | 30        |
| 3.1.1 Mudanças climáticas no contexto de desastres.....                                                                                                                                  | 34        |
| 3.1.2 Desastres Associados a Eventos Hidrometeorológicos em Santa Catarina.....                                                                                                          | 39        |
| 3.2 SISTEMAS METEOROLÓGICOS ATUANTES EM SANTA CATARINA.....                                                                                                                              | 44        |
| 3.2.1 Sistemas de Escalas Interdecadais e Interanuais.....                                                                                                                               | 47        |
| 3.2.2 Sistemas de Escalas Intrasazonal.....                                                                                                                                              | 49        |
| 3.2.3 Sistemas Sinóticos.....                                                                                                                                                            | 52        |
| 3.2.4 Sistemas de Mesoescala.....                                                                                                                                                        | 68        |
| 3.2.5 Sistemas de Microescala.....                                                                                                                                                       | 72        |
| 3.3 PESQUISAS SOBRE EVENTOS EXTREMOS RELACIONADOS A DESASTRES.....                                                                                                                       | 73        |
| 3.4 SISTEMAS DE ALERTAS DE DESASTRES.....                                                                                                                                                | 79        |
| 3.4.1 Função e objetivos.....                                                                                                                                                            | 79        |
| 3.4.2 Elementos dos sistemas de alertas.....                                                                                                                                             | 81        |
| 3.4.3 Modelos de Sistemas de Alertas Aplicados pelo Mundo.....                                                                                                                           | 83        |
| 3.4.4 Cenário Brasileiro e Catarinense dos Sistema de Alerta.....                                                                                                                        | 92        |
| 3.5 MONITORAMENTO HIDROMETEOROLÓGICO E CLIMÁTICO.....                                                                                                                                    | 94        |
| 3.5.1 Sistema de monitoramento e alerta de desastres em Santa Catarina.....                                                                                                              | 95        |

|                                                                                                    |            |
|----------------------------------------------------------------------------------------------------|------------|
| 3.5.2 Boletins diários de monitoramento.....                                                       | 99         |
| 3.5.3 Avisos e alertas hidrometeorológicos.....                                                    | 102        |
| 3.5.4 Limiares de alertas hidrometeorológicos.....                                                 | 106        |
| 3.6 USO DE MACHINE LEARNING NO CONTEXTO DE DESASTRES.....                                          | 109        |
| 3.6.1 Introdução à Modelagem com Machine Learning.....                                             | 110        |
| 3.6.2 Desafios na Coleta de Dados para Modelagem.....                                              | 113        |
| 3.6.3 Modelagem e Seleção de Recursos.....                                                         | 115        |
| 3.6.4 Preparação e Pré-processamento dos Dados.....                                                | 117        |
| 3.6.5 Tipos de modelagem aplicado a questões Meteorológica e de Desastres.....                     | 120        |
| 3.6.6 Validação do modelo de Machine Learning.....                                                 | 122        |
| 3.6.7 Interpretação dos Dados do Modelo de predição.....                                           | 124        |
| <b>4 METODOLOGIA.....</b>                                                                          | <b>127</b> |
| 4.1 COLETA DE DADOS.....                                                                           | 128        |
| 4.2 PREPARAÇÃO DOS DADOS.....                                                                      | 130        |
| 4.3 MODELAGEM ESTATÍSTICA.....                                                                     | 133        |
| 4.4 PARAMETRIZAÇÃO DO MODELO.....                                                                  | 133        |
| 4.5 ANÁLISE DOS DADOS.....                                                                         | 137        |
| 4.5.1 Análise das variáveis representativas.....                                                   | 137        |
| 4.5.2 Comparação de desempenho entre cidades.....                                                  | 138        |
| 4.5.3 Avaliação de variáveis críticas em cidades com alto desempenho.....                          | 138        |
| <b>5 RESULTADOS E DISCUSSÕES.....</b>                                                              | <b>140</b> |
| 5.1 TEMPO COMPUTACIONAL DO MODELO.....                                                             | 140        |
| 5.2 RESULTADOS GERAIS DE DESEMPENHO DO MODELO.....                                                 | 142        |
| 5.3 IDENTIFICAÇÃO E CONTRIBUIÇÃO DAS VARIÁVEIS EM RELAÇÃO ÀS MESORREGIÕES E SUAS PERFORMANCES..... | 150        |
| 5.3.1 Variáveis da Grande Florianópolis.....                                                       | 150        |
| 5.3.2 Variáveis do Norte Catarinense.....                                                          | 153        |
| 5.3.3 Variáveis do Sul Catarinense.....                                                            | 157        |
| 5.3.4 Variáveis do Oeste Catarinense.....                                                          | 161        |
| 5.3.5 Variáveis da Mesorregião Serrana.....                                                        | 165        |
| 5.3.6 Variáveis do Vale do Itajaí.....                                                             | 167        |
| 5.4 CONTRIBUIÇÃO DAS VARIÁVEIS EM RELAÇÃO ÀS CIDADES.....                                          | 170        |
| 5.4.1 Variável Alertas.....                                                                        | 171        |
| 5.4.2 Variável Dif_Prec48_24.....                                                                  | 172        |
| 5.4.3 Variável Prec_120h.....                                                                      | 172        |
| 5.4.4 Variável ZCAS.....                                                                           | 173        |
| 5.4.5 Variável Prec_48h.....                                                                       | 174        |
| 5.4.6 Variável Dif_Prec72_48.....                                                                  | 174        |
| 5.4.7 Variável Rad_48.....                                                                         | 175        |
| 5.4.8 Variável Prec_72h.....                                                                       | 176        |
| 5.4.9 Variável Rad_96h.....                                                                        | 176        |
| 5.4.10 Variável Dif_Rad96_72.....                                                                  | 177        |

|                                                                   |            |
|-------------------------------------------------------------------|------------|
| 5.4.11 Variável Dif_Prec96_72.....                                | 178        |
| 5.4.12 Variável Prec_24h.....                                     | 179        |
| 5.4.13 Variável Prec.....                                         | 180        |
| 5.4.14 Variável Precipitação Total Horário(mm).....               | 180        |
| 5.4.15 Variável Dif_Rad48_24.....                                 | 181        |
| 5.4.16 Variável Rad_120h.....                                     | 182        |
| 5.4.17 ANÁLISE DAS PERFORMANCES DAS CIDADES.....                  | 182        |
| 5.5 COMPARATIVO ENTRE AS CIDADE COM ALTA E BAIXA PERFORMANCE..... | 189        |
| 5.6 COMPORTAMENTO DO MODELO.....                                  | 195        |
| <b>6 CONSIDERAÇÕES FINAIS.....</b>                                | <b>197</b> |
| <b>7 PRODUTOS TÉCNICOS/TECNOLÓGICOS.....</b>                      | <b>200</b> |
| 7.1 APRESENTAÇÃO DE PESQUISA.....                                 | 200        |
| 7.2 RESUMOS EXPANDIDOS.....                                       | 202        |
| 7.3 ARTIGOS PUBLICADOS.....                                       | 202        |
| 7.4 MODELO CHRONOCAST.....                                        | 203        |
| 7.5 AVALIAÇÃO DE TECNOLOGIA INSTITUCIONAL.....                    | 205        |
| <b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>                            | <b>208</b> |

## 1 INTRODUÇÃO

Nas últimas décadas, houve um aumento notável na ocorrência de desastres naturais, intensificados pelas mudanças climáticas. Fenômenos como enchentes, inundações e geohidrológicos tornam-se cada vez mais frequentes e severos, exacerbados pelo aquecimento global. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021) alerta que nenhuma região do globo está imune aos impactos das mudanças climáticas, que prometem custos humanos e econômicos substanciais, ultrapassando os investimentos em prevenção e preparação.

Particularmente, em Santa Catarina, o impacto desses eventos é evidente. Segundo Rodrigues (2020), o estado enfrentou uma série de desastres naturais, incluindo ciclones e tempestades, desafiando os órgãos públicos estaduais, como Epagri/CIRAM e a Defesa Civil, a monitorar esses fenômenos e adotar medidas eficazes de preparação e mitigação. A necessidade de sistemas eficazes de alerta de desastres é preconizada pela Organização Mundial de Meteorologia (WMO) (WMO A, 2019) e se alinha com o objetivo de desenvolvimento sustentável (ODS) número 11 das Nações Unidas, visando reduzir significativamente as perdas humanas e econômicas decorrentes de desastres naturais até 2030.

Neste sentido, os sistemas de alerta de desastres naturais, específicos ou multi ameaças, são desenvolvidos justamente para realizar o monitoramento das condições climáticas e ambientais com potencial deflagrador de algum tipo de desastre e alertar a população ou públicos específicos ao qual tenham interesse em tais informações como os setores do agronegócio, forças de segurança e defesas civis municipais (UNISDR, 2006).

As observações e os serviços de monitoramento constituem o cerne dos sistemas de alerta, pois fomentam com dados as previsões de eventos críticos de maneira confiável. Normalmente os sistemas de alerta operam 24 horas por dia e realizam o monitoramento contínuo de parâmetros de perigo para a produção de avisos precisos de forma oportuna(WMO B, 2019).

Embora a disponibilidade dos serviços meteorológicos tenha aumentado, ao mesmo tempo que o número de instituições de monitoramento, eventualmente, as informações sobre riscos e prevenção não chegam a toda população. Neste sentido, há necessidade de estratégias e instrumentos que possibilitem a comunicação entre a população em situação de risco e gestores públicos (SORIANO e HOFFMANN, 2016).

No ano de 2016, por meio de um projeto piloto desenvolvido em parceria com a Agência Nacional de Telecomunicações (ANATEL) e a Defesa Civil do Estado de Santa Catarina, foi criado o *Nowcasting*. “É um serviço gratuito de envio de mensagens de alerta de riscos de desastres e emergências por SMS, serviço de mensagens curtas disponível aos aparelhos telefônicos móveis (SANTA CATARINA, 2020).

A eficácia desses sistemas de alerta, fundamentais para a redução de riscos de desastres, tornou-se um foco de atenção internacional, conforme evidenciado por tratados e estratégias globais. Tais sistemas operam continuamente, monitorando parâmetros de perigo para emitir avisos precisos e oportunos. No entanto, a comunicação efetiva desses alertas à população, especialmente em Santa Catarina, enfrenta desafios, como ilustrado pela implementação do serviço de *Nowcasting*, (SANTA CATARINA, 2020).

Embora os sistemas de alerta em Santa Catarina sejam tecnicamente avançados, desafios relacionados à precisão dos dados e à efetividade dos alertas em relação aos seus efeitos práticos à sociedade persistem, como danos e prejuízos. Estes desafios podem comprometer a capacidade dos alertas de alcançar e proteger todas as populações vulneráveis, o que motiva uma investigação mais aprofundada sobre como esses sistemas podem ser otimizados.

## 2 JUSTIFICATIVA

O Marco de Sendai (2015) estabelece a colaboração entre a comunidade acadêmica, instituições públicas, privadas e as comunidades em geral a níveis globais e regionais para desenvolver instrumentos e ferramentas para redução do risco de desastres de maneira significativa para as mudanças climáticas, proteção a biodiversidade, desenvolvimento sustentável, erradicação da pobreza, meio ambiente, agricultura, saúde.

A Organização das Nações Unidas (ONU), por meio do objetivo de desenvolvimento sustentável (ODS) número 11 define que até 2030, é necessário reduzir significativamente o número de mortes e pessoas afetadas por desastres naturais de origem hidrometeorológica e climatológica, além de diminuir as perdas econômicas diretas causadas por esses desastres (ONU, 2015).

Neste viés, a figura 1 exemplifica graficamente as estratégias para a redução dos riscos de desastres, que visam promover ações de capacitação, sensibilização e integração entre os entes governamentais, privados e a população para melhorar as condições de vida das pessoas, qualificar a assistência oferecida e colaborar no cumprimento de metas internacionais, além qualificar a resposta das pessoas aos desastres, visto que, nas últimas décadas houve um aumento de ocorrências relacionadas ao clima e ações antrópicas em diversas partes do planeta.

Figura 1. Estratégia internacional das Nações Unidas para a redução dos riscos de desastres.

## Quadro estratégico da UNISDR 2016-2021



Fonte: UNISDR, 2015

De acordo com a WMO (B, 2019), haverá um aumento da demanda por serviços meteorológicos, hidrológicos e climatológicos e há necessidade de tornar as comunidades vulneráveis mais resilientes às consequências socioeconômicas de eventos meteorológicos, hidrológicos e climáticos extremos e melhorar os serviços de monitoramento e previsão climática das instituições.

Os sistemas de alertas são de suma importância para as estratégias de adaptação e redução de risco de desastres. Esses sistemas têm recebido atenção dentro das estruturas de tratados internacionais e se tornaram um dos principais elementos estratégicos internacionais reconhecidos e utilizados como ferramenta para identificar as mudanças climáticas tanto a níveis globais quanto locais (UNDP, 2018).

Segundo Heffer (2013) diversas cidades têm destinado investimentos consideráveis no desenvolvimento de sistemas de alerta para eventos extremos na América Latina, devido ao potencial que estas ferramentas apresentam em preparar as pessoas e retirá-las do perigo em tempo hábil. Os severos danos e perdas de vidas humanas são mitigados quando um sistema de alerta é implementado adequadamente em se tratando de eventos extremos.

É preciso fortalecer o conhecimento científico sobre a climatologia local, por meio de pesquisas sistemáticas, observação do sistema climático e dos sistemas de alertas de desastres, de forma que informações geradas por esses serviços apoie a redução do risco de desastres e a tomada de decisão na disseminação dos alertas de desastres (CALSTER; REINS, 2021). Da mesma forma, eventos extremos como ondas de calor, precipitação extrema e inundações costeiras, apresentam grandes riscos à sociedade moderna a níveis de moderado a alto, diminuindo a confiança nas previsões meteorológicas e aumentando o ambiente de incerteza (BARCELLOS et al. 2016).

Apesar dos avanços nos serviços meteorológicos e no número de instituições de monitoramento, a comunicação de riscos e prevenções não alcança efetivamente toda a população, que por vezes, evidencia a necessidade de estratégias inovadoras e eficazes para melhorar a disseminação e a assertividade dos alertas de desastres. A análise da assertividade desses alertas, especialmente os de origem hidrometeorológica em Santa Catarina, torna-se fundamental para avaliar sua eficácia em preparar a população e mitigar os impactos dos desastres naturais.

A implementação de um modelo baseado em *Machine Learning* para avaliar e prever a efetividade dos alertas de desastres pode oferecer uma oportunidade para abordar essas lacunas. Esta abordagem permite uma análise quantitativa e qualitativa dos fatores que afetam a efetividade dos alertas, proporcionando uma base sólida para recomendações práticas e políticas direcionadas.

Este trabalho se propõe a preencher essa lacuna, analisando a eficácia dos alertas emitidos pelo sistema de Nowcasting da Defesa Civil de Santa Catarina, correlacionando-os com a ocorrência real de eventos extremos de chuva. Ao fortalecer o conhecimento científico sobre a climatologia local e os sistemas de alerta, esta pesquisa visa contribuir para a redução do risco de desastres e apoiar a tomada de decisão na disseminação de alertas efetivos.

Dessa forma, almeja-se não apenas qualificar a resposta da população aos desastres, mas também colaborar para o cumprimento de metas internacionais,

promovendo ações de capacitação e sensibilização para uma sociedade mais segura e preparada.

A hipótese central desta dissertação propõe que a efetividade dos alertas de desastres varia significativamente entre diferentes cidades do Estado de Santa Catarina, sendo esta variação influenciada principalmente por variáveis meteorológicas específicas e regionalizadas, e pela variabilidade na qualidade dos dados de alertas e danos registrados. Sugere-se que as discrepâncias na efetividade dos alertas entre diferentes regiões podem ser atribuídas tanto às diferenças nas condições meteorológicas locais quanto às inconsistências na forma como os danos são reportados e os alertas são emitidos.

Portanto, um modelo computacional avançado, que integre essas variáveis meteorológicas, alertas emitidos e registros de danos, poderia fornecer uma medida auxiliar para avaliar a efetividade dos alertas, melhorando a resposta a desastres em diferentes localidades.

## **2.1 OBJETIVOS**

### **2.1.1 Objetivo geral**

Avaliar a efetividade dos alertas do sistema de alerta Nowcast de desastres em Santa Catarina, e propor a ferramenta *Chronocast*, baseada em *Machine Learning*.

### **2.1.2 Objetivo(s) específico(s)**

Analisar quais variáveis utilizadas pelo modelo são mais representativas para a efetividade dos alertas em diferentes mesorregiões do Estado de Santa Catarina.

Comparar a performance dos alertas entre as cidades com desempenho mais alto e mais baixo em termos de efetividade a partir do modelo.

Identificar, entre as cidades com melhor performance, quais variáveis utilizadas pelo modelo se destacam na previsão de alertas efetivos.

Desenvolver um modelo funcional que permita realizar a avaliação dos alertas emitidos pela Defesa Civil nas diferentes cidades de Santa Catarina.

### 2.1.3 Estrutura do Trabalho

Este trabalho está estruturado da seguinte maneira: **Revisão Bibliográfica, Metodologia, Resultados e Discussões, Considerações Finais, Produtos Técnicos Tecnológicos e Referências Bibliográficas.**

A **Revisão Bibliográfica** da dissertação abrange uma ampla gama de temas relacionados aos desastres naturais e sistemas meteorológicos em Santa Catarina, focando em entender as mudanças climáticas e seus efeitos sobre eventos hidrometeorológicos na região. Examina os sistemas meteorológicos que influenciam o clima local, desde escalas interdecadais até microescalas, detalhando fenômenos como ciclones, Zona de Convergência do Atlântico Sul, e sistemas frontais. Também, explora a função e estrutura dos sistemas de alerta de desastres, comparando modelos nacionais e internacionais, e discute as práticas de monitoramento climático e hidrometeorológico, fundamentais para a previsão e mitigação de desastres.

No capítulo **Metodologia** da dissertação, inicia com a coleta de dados relevantes para a análise, seguida da preparação desses dados para assegurar sua adequação ao modelo preditivo. A modelagem do problema é delineada para ajustar o desafio de pesquisa às capacidades do *machine learning* e o desenvolvimento da parametrização do modelo para realizar o ajuste fino das variáveis e algoritmos para otimizar resultados. A análise detalhada dos dados abrange desde a avaliação das

variáveis representativas até a comparação de desempenho entre diferentes cidades, foca nas variáveis críticas que influenciam as cidades com melhores resultados. Este processo visa não só entender as dinâmicas dos alertas de desastres, mas também aprimorar a eficácia dos sistemas de alerta em uso.

O capítulo de **Resultados e Discussões** explora os achados obtidos com a implementação do modelo, começando pela análise do tempo computacional necessário para o processamento dos dados. A seção seguinte discute o desempenho geral do modelo, focando na justificação do coeficiente de determinação ( $R^2$ ) para avaliar a assertividade das previsões. Segue-se a identificação e contribuição das variáveis em relação às mesorregiões e suas performances, detalhando como diferentes variáveis impactam as previsões em diversas partes de Santa Catarina. A análise se aprofunda nas variáveis específicas relacionadas a cada cidade, explorando sua relevância para a efetividade dos alertas de desastres. O capítulo culmina com uma comparação entre as cidades com alta e baixa performance, proporcionando um entendimento aprofundado das forças e fraquezas do modelo em diferentes contextos locais.

As **Considerações Finais** resumem as principais percepções dos autores, refletindo sobre a eficácia do modelo desenvolvido para prever a efetividade dos alertas de desastres e como ele pode ser aprimorado. Essa seção destaca as implicações práticas dos resultados para a gestão de desastres e a política de alertas, sugerindo direções futuras para pesquisa e desenvolvimento baseados nas descobertas.

Na seção **Produtos Técnicos/Tecnológicos**, a dissertação apresenta uma variedade de outputs gerados ao longo da pesquisa. Isso inclui a apresentação de pesquisa em conferências, resumos expandidos, artigos publicados em periódicos acadêmicos, e o desenvolvimento do modelo *Chronocast*, um produto inovador na avaliação da efetividade dos alertas de desastres. Também é descrita a Avaliação de Tecnologia Institucional da Defesa Civil de Santa Catarina, um relatório técnico conclusivo que analisa o impacto e a aplicabilidade do modelo dentro de uma estrutura institucional, fornecendo um recurso valioso para tomadores de decisão na área de gestão de desastres.

### 3 REVISÃO BIBLIOGRÁFICA

Este capítulo de revisão bibliográfica apresenta uma análise estruturada das literaturas fundamentais e das correntes de pesquisa relacionadas aos desastres naturais, com foco especial em eventos hidrometeorológicos e sistemas de alerta de desastres. A revisão está organizada em diversas seções temáticas, cada uma explorando diferentes aspectos dos sistemas meteorológicos e suas implicações para o monitoramento e resposta a desastres.

A seção **Desastres Naturais** está subdividida para discutir, inicialmente, o papel das mudanças climáticas nos desastres naturais, seguido por uma análise específica dos desastres associados a eventos hidrometeorológicos em Santa Catarina, proporcionando um contexto regional relevante.

Na sequência, na seção **Sistemas Meteorológicos**, aprofunda-se uma ampla gama de sistemas meteorológicos, detalhando desde escalas interdecadais até microescalas. Subseções detalhadas cobrem sistemas sinóticos, como ciclones e correntes de jato, além de sistemas de mesoescala e microescala, revelando a complexidade e a diversidade das dinâmicas atmosféricas que influenciam os padrões climáticos locais e regionais.

Na seção **Pesquisas sobre Eventos Extremos Relacionados a Desastres**, são exploradas as abordagens metodológicas e os resultados das pesquisas sobre como eventos extremos conduzem a desastres naturais, destacando as lacunas no conhecimento e as oportunidades para futuras investigações.

Da mesma forma, na seção **Sistemas de Alertas de Desastres**, está detalhado os sistemas de alerta existentes, com foco nas funções e objetivos desses sistemas, elementos constituintes dos sistemas e exemplos de aplicação em diferentes regiões do mundo, incluindo uma visão sobre o cenário brasileiro e catarinense, oferecendo uma perspectiva comparativa.

No que se refere **Monitoramento Hidrometeorológico**, discute-se o estado atual do sistema de monitoramento e alerta de desastres em Santa Catarina, complementado por uma revisão dos procedimentos para boletins diários, avisos e alertas meteorológicos, com ênfase nos níveis de criticidade e limiares de alertas hidrometeorológicos.

Na Seção final denominada **Machine Learning**, é explorado seu uso no contexto meteorológicos e alertas de desastres, destacando a importância de coletar e pré-processar dados de alta qualidade para alimentar modelos, técnicas de modelagem, incluindo redes neurais, que são particularmente úteis devido à sua capacidade de processar grandes conjuntos de dados e capturar padrões complexos, a seleção e modelagem de recursos apropriados e a validação rigorosa dos modelos para garantir precisão e generalização.

Por fim, a interpretação dos resultados é enfatizada como essencial para transformar dados brutos em alertas acionáveis e confiáveis, essenciais para a gestão eficaz de desastres e a mitigação de riscos, contribuindo significativamente para a preparação e resposta a eventos extremos.

### 3.1 DESASTRES NATURAIS

Atualmente, existem diversas definições de desastres na literatura nacional e internacional. Contudo, até o momento não existe um conceito universal de desastre o que prejudica a compreensão dos fenômenos e os debates científicos sobre o tema, gerando inúmeras dúvidas sobre quais fenômenos podem ser associados a determinada definição. (FAVERO et al., 2014).

Segundo a *United Nation Office for Disaster Risk Reduction* (UNDRR, 2019) os desastres podem ser definidos como uma perturbação do funcionamento de uma comunidade ou sociedade de maneira severa independente da escala. As condições de exposição, vulnerabilidade e capacidade dessas comunidades associado a interação de eventos perigosos acarretam em perdas e impactos humanos, materiais, econômicos e ambientais.

Contudo, os desastres também podem ser definidos como resultado de eventos considerados adversos, de origem natural ou em decorrência da ação humana sobre a vulnerabilidade de um ecossistema. Esse grave distúrbio no funcionamento de uma comunidade quando envolve extensivas perdas e danos humanos, materiais, econômicos ou ambientais, excede a sua capacidade de lidar com o problema usando meios próprios (BRASIL, 2012).

Ainda assim, o desastre é o resultado da combinação de ameaças/perigo, condições de vulnerabilidade e da insuficiente capacidade ou medidas para reduzir as consequências negativas e potenciais do risco (TRAJBER et al., 2017). Em resumo, um desastre ocasiona danos e prejuízos às pessoas de maneira direta e indireta. Atinge as fontes de alimentação, água, saúde (meio ambiente), moradias, transportes, hospitais (infraestrutura) devido ao impacto de uma ameaça que ultrapassa a capacidade local de responder e atender as consequências de maneira adequada.

Os desastres podem causar efeitos imediatos e pontuais, porém normalmente seu impacto atinge de forma ampla e generalizada e pode durar um longo período. Tais efeitos podem pôr a prova ou mesmo exceder a capacidade da sociedade de gerir com seus próprios recursos e, portanto, exige a assistência de fontes externas, que podem incluir auxílio de comunidades adjacentes ou suporte à nível nacional ou internacional (OLIVER-SMITH et al. 2017).

Assim, os desastres podem reduzir as atividades entre as fronteiras de municípios e países, acrescentando substancialmente os custos de negociação e diminuir os recursos e capacidades das empresas. Reduz o fluxo comercial, o que varia de acordo com as regiões, municípios, países, envolvidos e a natureza do desastre, além de provocar o colapso temporal na produção local, causar danos a cadeias de suprimentos e infra estruturas domésticas (HOON OH, 2015).

Desastres de origem hidrometeorológicas também resultam em sérios problemas de saúde pública quer seja pela magnitude dos eventos, como também pelos seus impactos nas áreas socioeconômicas, ambientais e sanitárias. Esses impactos muitas vezes afetam as populações locais de maneira irreparável e

agravam as condições das comunidades, que por diversas vezes já se encontram em condições precárias exigindo que setores públicos intervenham no auxílio e socorro às populações (SOBRAL et al., 2010).

De acordo com Freitas et al. (2014), vários problemas de saúde surgem no período subsequente à ocorrência dos desastres naturais, em conjunto com danos oriundos dos eventos extremos. O nível de vulnerabilidade socioambiental e a capacidade de resiliência locais determinam a magnitude dos efeitos danosos à sociedade. Na tabela 1 é demonstrada as consequências ambientais e socioeconômicas decorrentes de desastres hidrometeorológicos.

Tabela 1 - Consequências ambientais e socioeconômicas dos desastres provocados por fenômenos hidrometeorológicos.

| Inundações, enxurradas e alagamentos | Consequências Ambiental                                                                                                    | Consequência Socioeconômicas                                                                                        |
|--------------------------------------|----------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------|
|                                      | Contaminação biológica e química da água para consumo humano, alimentos e solo                                             | Interrupção total ou parcial de pontes, ruas e estradas por inundação ou destruição por inundação                   |
|                                      | Comprometimento da rede e fontes alternativas de abastecimento de água                                                     | Rompimento de diques de contenção                                                                                   |
|                                      | Comprometimento da rede de serviço de coleta e tratamento de esgoto                                                        | Rompimento de tanques de combustíveis                                                                               |
|                                      | Comprometimento dos serviços de coleta e disposição do lixo                                                                | Interrupção total ou parcial do fornecimento de serviços de água, eletricidade, gás, transporte e comunicação       |
|                                      | Alteração nos ciclos dos vetores, hospedeiros e reservatórios de doenças e nas formas de exposições ambientais dos humanos | Interrupção total ou parcial do funcionamento de escolas, comércio, serviços funerários, serviços de saúde e outros |
|                                      |                                                                                                                            | Comprometimento total ou parcial das atividades agrícolas e pecuárias                                               |
|                                      |                                                                                                                            | Prejuízos econômicos pela destruição total ou parcial de propriedades, casas e construções                          |
|                                      |                                                                                                                            | Prejuízos econômicos pela destruição total ou parcial das fontes de renda e trabalho                                |
|                                      |                                                                                                                            | Perdas de bens pessoais e de valor sentimental                                                                      |



Rompimento ou fortalecimento da amizade, cooperação e laços afetivos entre os membros de uma comunidade afetada

Fonte: Freitas et al., 2014

Em detrimento aos danos proporcionados, os desastres aumentam o ambiente de incerteza dentro de uma comunidade. Segundo Hoon Oh (2015), com a redução do número de pessoas dispostas a se engajar no consumo e no investimento econômico local, e com o aumento dos custos na produção comercial e do risco existente, a comunidade torna-se incapaz de manter-se sem o apoio financeiro externo como dos setores públicos e privados.

Diversas pesquisas apresentam como elemento principal durante a ocorrência de eventos de desastres relacionados ao clima a variável “risco natural” do desastre. No entanto, os autores Chmutina e Medingem (2019) consideram que a epistemologia da pesquisa está mais alinhada com uma lente de construção social, a expressão “desastres naturais” não é adequada para a caracterização dos elementos causadores de um evento crítico na maioria das vezes, em particular a compreensão contemporânea do papel da vulnerabilidade em relação aos impactos dos desastres na sociedade.

Atualmente a maioria dos desastres ocorridos em diversas partes do globo pode ser considerado um produto resultante da relação complexa entre três fatores, o desequilíbrio ecossistêmico, as atividades humanas exercidas nesses ambientes e a ocorrência de fenômenos naturais. A falta de aplicação e desenvolvimento de planejamento urbano e do uso do solo, ocupações irregulares de áreas de risco e a degradação ambiental, são alguns exemplos da interação desses três fatores (SOBRAL et al., 2010).

Por muitos anos, a comunidade científica de diversas áreas sociais tentaram descobrir as verdadeiras causas por trás dos desastres. Diante disso, torna-se complexo distinguir e definir desastres como resultado de ações humanas, seja por omissão ou por ação direta, em vez de atribuí-los apenas a fenômenos naturais. Tal complexidade se deve ao fato de que muitos desastres são mais influenciados por fatores socioeconômicos do que por causas naturais (CHMUTINA; MEDING, 2019).

Decorrente disso, afirmar que eventos de desastres, de maneira isolada, têm sido causados pelas mudanças climáticas são imprecisas e falhas. Porém, analisando diversas variáveis de um conjunto de dados disponibilizados por um sistema, como o monitoramento climático, é possível identificar tendências, variabilidade de proporção, extensão e frequência dos potenciais desastres climáticos (XAVIER et al., 2019).

### **3.1.1 Mudanças climáticas no contexto de desastres**

Nos últimos anos, em diversas partes do mundo foram registrados a quebra de recordes de temperatura e o aparecimento de grandes desastres climáticos. A população em geral como a própria comunidade científica questionam se as mudanças climáticas podem estar associadas a esses eventos (LIZARRALDE et al., 2021).

Segundo Hansen (2021) as mudanças climáticas representam perigos potenciais que tornaram evidente as preocupações políticas por parte do poder público e da sociedade civil. Atualmente há uma melhor compreensão dos danos duradouros em relação à capacidade do planeta de sustentar a vida. As mudanças físicas regionais nos padrões climáticos, em termos de frequência e extensão, apresentam relevância para estudos científicos das consequências dos eventos climáticos.

As consequências das mudanças climáticas são diversas e estão afetando setores de maneira negativa e causam embates ideológicos no âmbito científico. À exemplo, a média da temperatura pode ser atribuída exclusivamente à ação antrópica no meio ambiente. Por outro lado, gestores e tomadores de decisão divergem sobre a destinação e aplicação de recursos financeiros em medidas mitigatórias ao controle do fenômeno nos campos econômico e político (REIS; SILVA; FIGUEIREDO, 2015).

Eventualmente, as controvérsias geradas desse tema estão intimamente ligadas com a complexidade da matéria. Pode-se considerar que eventos climáticos extremos são sistemas complexos, composto por subsistemas distintos que possuem comportamentos singulares, com atributos físicos e químicos específicos (LEITE; SILVA, 2020).

Conforme as afirmações de Guerra (2021) as mudanças climáticas são vistas por diversos países como a maior ameaça global na perspectiva de possíveis cenários de catástrofes naturais, para, ao final, acentuar a necessária observância de entidades públicas e privadas, pois seus efeitos perpassam os limites municipais, estaduais e internacionais.

Diversos pesquisadores acreditam que as mudanças climáticas estão influenciando a ocorrência e impacto de desastres, principalmente porque o número e a gravidade dos desastres tem aumentado em todo o mundo (BOUWER, 2010). Eventos individuais não podem ser atribuídos diretamente às mudanças climáticas. É necessário olhar atentamente para as tendências gerais e para os fatores que podem levar ao aumento da temperatura.

Os registros de desastres oriundos das mudanças climáticas alcançaram altos patamares. De acordo com o relatório do Escritório das Nações Unidas para Redução do Risco de Desastres de 2020, o número de desastres naturais dobrou nos últimos vinte anos, como mostra a figura 2.

Figura 2 - Comparativo do impacto dos desastres registrados entre 1980 - 1999 e 2000 - 2019.



Fonte: UNDRR, 2020

O levantamento aponta os desastres que envolvem perigos naturais relacionados ao clima, deixando de lado os desastres provenientes de atividades humanas ou de natureza tecnológica. Dados do EM-DAT (Emergency Events Database) no quadro 1 demonstram como foram contabilizados os alguns dos desastres naturais associados às mudanças climáticas no período de 1970 a 2016.

Quadro 1 - Frequência, tipo e subtipo de desastres naturais e número de afetados e óbitos no período de 1970 a 2016.

| Desastre Natural      |                     | Frequência Absoluta | Óbitos Absolutos | Média    | Total de Afetados |              |
|-----------------------|---------------------|---------------------|------------------|----------|-------------------|--------------|
| Tipo                  | Subtipo             |                     |                  |          | Total             | Média        |
| Terremoto             | Movimento de terra  | 1.003               | 1.066.764        | 1.063,60 | 181.401.660       | 180.859,10   |
| Tempestades           | Ciclone tropical    | 1.747               | 772.174          | 442      | 713.145.455       | 408.211,50   |
| Seca                  | Seca                | 621                 | 700.644          | 1.128,30 | 2.513.998.310     | 4.048.306,50 |
| Terremoto             | Tsunami             | 36                  | 251.968          | 6.999,10 | 6.618.951         | 183.859,80   |
| Temperaturas Extremas | Ondas de calor      | 164                 | 157.213          | 958,6    | 4.836.879         | 29.493,20    |
| Epidemias             | Doenças bacterianas | 712                 | 147.354          | 207      | 4.689.263         | 6.586,00     |
| Inundação             | Inundação gradual   | 2.561               | 123.268          | 48,1     | 2.514.108.010     | 981.690,00   |

|                       |                         |               |                  |              |                      |                   |
|-----------------------|-------------------------|---------------|------------------|--------------|----------------------|-------------------|
| Inundação             | Indeterminado           | 1.212         | 105.793          | 87,3         | 873.293.130          | 720.538,90        |
| Inundação             | Enxurradas              | 588           | 58.015           | 98,7         | 166.032.203          | 282.367,70        |
| Epidemias             | Doenças virais          | 437           | 53.683           | 122,8        | 7.003.471            | 16.026,20         |
| Deslizamentos         | Deslizamento            | 519           | 32.000           | 61,7         | 9.895.028            | 19.065,60         |
| Epidemias             | Indeterminado           | 138           | 27.032           | 195,9        | 2.988.058            | 21.652,60         |
| Atividade Vulcânica   | Queda de cinzas         | 190           | 26.104           | 137,4        | 4.980.188            | 26.211,50         |
| Tempestades           | Indeterminado           | 724           | 18.709           | 25,8         | 57.811.678           | 79.850,40         |
| Temperaturas Extremas | Ondas de frio           | 283           | 16.741           | 59,2         | 14.441.111           | 51.028,70         |
| Tempestades           | Tempestades convectivas | 874           | 16.040           | 18,4         | 197.285.952          | 225.727,60        |
| Epidemias             | Doenças parasitárias    | 46            | 10.156           | 220,8        | 10.556.528           | 229.489,70        |
| Outros Tipos          | Outros subtipos         | 874           | 17.281           | 19,8         | 119.787.814          | 137.057,00        |
| <b>Total</b>          |                         | <b>12.729</b> | <b>3.600.939</b> | <b>282,9</b> | <b>7.402.873.689</b> | <b>581.575,40</b> |

Fonte: EM-DAT, 2016


As mudanças climáticas ocorrem devido às variações naturais de baixa frequência, e por causa da alta concentração constituintes de poluição atmosférica por meio de emissões antropogênicas de gases de efeito estufa. O problema evoluiu consideravelmente nos últimos anos a ponto de se tornar uma questão ambiental de grande relevância (IPCC, 2021).

O *Green House Effect* (GHE) ou popularmente conhecido como efeito estufa é um fator importante para manter a vida em nosso planeta. Caso não haja esse fenômeno natural, a temperatura média da superfície da Terra seria de aproximadamente -21°C, bem menor do que a temperatura agradável de 14°C que experimentamos hoje (ANDERSON et al., 2016). Porém o efeito estufa também é apontado como causador das mudanças climáticas.

O efeito estufa ocorre principalmente pela interação da energia proveniente do sol com os gases relacionados ao efeito estufa como dióxido de carbono, metano, óxidos e gases fluorados encontrados na atmosfera do planeta. Esses gases têm a capacidade de absorver o calor e mantê-lo dentro da atmosfera, tornando o planeta como uma espécie de estufa (KWEKU et al., 2017).

Conforme as afirmações realizadas pela *National Academy of Sciences* (2014), a emissão de gases de efeito estufa está tornando cada vez mais quente e úmida a camada mais baixa da atmosfera da Terra, o que propicia um ambiente mais favorável para o surgimento de tempestades e determinados eventos climáticos extremos. A figura 3 apresenta um comparativo das últimas quatro décadas em relação aos desastres naturais associados às mudanças climáticas.

Figura 3 - Comparativo do total de desastres por tipo de evento registrados entre 1980 - 1999 e 2000 - 2019.



Fonte: UNDRR, 2020

As percepções sobre o atual cenário das mudanças climáticas que estão ocorrendo, remete a reflexão se tais efeitos são resultantes das forças naturais ou forçantes antropogênicas e se essas mudanças afetam a frequência, intensidade ou a duração de vários desastres naturais (BLANK, 2015).

De acordo com Phillips et al. (2015) as opiniões sobre as mudanças climáticas bem como os efeitos potenciais sobre os desastres naturais são inferidas pelo conhecimento tanto das mudanças climáticas quanto dos desastres naturais. Deste modo, o nível de conhecimento sobre qualquer assunto pode ser parametrizado pela

perspectiva da população sobre a relação entre mudanças climáticas e desastres naturais.

Recentemente, em 2021 na Alemanha, chuvas extremas causaram diversas mortes por inundação, considerada uma das mais devastadoras da história moderna da região europeia. Pesquisas iniciais sugerem que o evento foi causado por tempestades consideradas extremas que se moviam lentamente sobre a Europa central (ZSCHEISCHLER, 2021). As mudanças climáticas contribuíram para acelerar a evaporação e tem como forte hipótese aumentar a probabilidade de tempestades lentas (KAHRAMAN et al., 2021).

De acordo com Herring et al. (2018) os eventos extremos são condições meteorológicas e climáticas excepcionalmente severas com potencial impactos devastadores na sociedade e nos ecossistemas agrícolas e naturais. Os eventos meteorológicos extremos, em regra, têm curta duração e podem ser exemplificados como ondas de calor, congelamentos, chuvas torrenciais, tornados, ciclones tropicais e inundações (WALSH et al., 2014). Contudo, Lindsay (2016) explica que eventos climáticos extremos perduram por mais tempo do que os eventos meteorológicos ou emergem do acúmulo de eventos meteorológicos que persistem por um período mais longo de tempo. Neste sentido, a seca resultante de longos períodos de precipitação abaixo do normal ou a eclosão de incêndios florestais quando um período prolongado de calor e seca segue uma estação do ano de crescimento anormal úmida e produtiva.

### **3.1.2 Desastres Associados a Eventos Hidrometeorológicos em Santa Catarina**

Os desastres naturais estão cada vez mais presentes no cotidiano das comunidades catarinenses nas últimas décadas. A frequência de eventos extremos aumentaram substancialmente juntamente com os danos e prejuízos ocasionados pelos impactos cada vez mais intensos. Dos dez (10) municípios mais atingidos por

desastres no Brasil no período de 1991 a 2012, oito (8) municípios estão localizados em Santa Catarina: Abelardo Luz, Canoinhas, Chapecó, Concórdia, Florianópolis, Joinville, Tangará e Seara (UFSC/CEPED, 2013).

O Estado apresenta um grande número de eventos extremos e também pelo maior número de pessoas atingidas. Dentre os quase 5.500 municípios do País, 70 são considerados os de maior incidência de danos e dentro desse universo, o Estado catarinense contabiliza 34 municípios dentro dessa triste estatística (CARDOSO et al. 2014). Grande parte de tais eventos extremos podem ser associados resultante das mudanças climáticas.

Apesar dos impactos ocasionados pelos eventos extremos serem cada vez evidentes, as metodologias para adaptar-se a esses impactos, o grau de nossa compreensão e capacidade de previsão variam amplamente entre os diferentes setores e disciplinas (SILLMANN et al., 2019).

O histórico de desastres hidrometeorológicos em Santa Catarina, de grandes proporções, tem como destaque o município de Tubarão, no sul do Estado. Após um longo período de chuvas e trombas d'água, o município foi atingido por uma enchente em meados de março de 1974 considerado um dos maiores desastres ocorridos no em Santa Catarina (SANTA CATARINA, 2021).

Registros indicavam que o rio Tubarão chegou a um nível com cerca de dez metros acima do normal e culminou na decretação de estado de calamidade no município. Aproximadamente 97% do município ficou debaixo da lama, com 60 mil pessoas desabrigadas e diversos prédios públicos e residências foram destruídos e cerca de 199 mortes (ASSUNÇÃO, 2014).

O Vale do Itajaí sofreu com inundações desde 1850 durante sua colonização, porém, com uma realidade muito mais urbanizada, esse processo se intensificou devido a transformações demográficas e econômicas dos anos 1970, de acordo com Guimarães (2012). A Bacia do Rio Itajaí-Açu sofreu nas décadas de 1950, 1970 e 1980 um aumento expressivo na recorrência de enchentes e inundações, onde vários municípios sofreram com inundações.

Proporcionalmente, a década de 1980 foi um marco na memória das enchentes na região, o volume considerável do nível das águas resultou em 135 cidades atingidas, principalmente Blumenau, Rio do Sul e Itajaí, registrando cerca de 198 mil desabrigados, pelo menos 49 mortos e 32 dias de isolamento total. Em Rio do Sul a cota chegou a 15,58m em julho de 1983 e em agosto de 1984 a 12,8 metros (ESPINDOLA; NODARI, 2013).

Do mesmo modo, eventos de inundações e enxurradas se destacaram devido à sua magnitude entre entre Natal e Ano Novo em 1995. A Defesa Civil do Estado calcula que entre os dias 23 e 24 de dezembro deste ano, choveu cerca de 165 milímetros, acima da média de todo o mês (140 milímetros) e afetaram principalmente as mesorregiões Sul Catarinense e Grande Florianópolis (UFSC/CEPED, 2013).

Em tal evento extremo houve uma enxurrada catastrófica, devido ao deslocamento de um sistema frontal ao passo que um ciclone extratropical posicionava-se sobre o continente. Nuvens cúmulos-nimbus avançaram do oceano para o continente, concentrando chuvas intensas na região do rio Araranguá e na Serra Geral. No município de Palhoça, por exemplo, 60% da cidade ficou debaixo d'água, houve registro de três pessoas mortas, graves danos em residências, prédios públicos e comerciais, sistema viário e agricultura (SANTA CATARINA, 2021).

Nesse ínterim, o Alto Vale e Vale do Itajaí ficaram marcados com as inundações e deslizamentos ocorridos em novembro de 2008, em particular os municípios como Rio do Sul, Blumenau, Itajaí, Ilhota, Gaspar e Brusque. Elevados índices de precipitações e enxurradas associados a cerca de 3000 registros de deslizamentos e geohidrológicos transformaram o Vale em campo de guerra (MATTEDI; AVILA, 2017).

Cerca de quatorze municípios decretaram estado de calamidade pública e mais de sessenta cidades estavam em situação de emergência. As cidades de Blumenau, Gaspar, Ilhota, Jaraguá do Sul e Luís Alves registram aproximadamente 85% do total de vítimas fatais pelo evento extremo. Os números chegaram a 135

óbitos, 80 mil desalojados e mais de 1,5 milhões de atingidos e cerca de 4,75 bilhões de reais de prejuízos econômicos (JONER et al., 2021).

Próximo ao litoral dos estados de Santa Catarina e Rio Grande do Sul, foi registrado um fenômeno atmosférico inédito no Brasil em 27 e 28 de março de 2004, o furacão Catarina. O fenômeno desenvolveu-se no Oceano Atlântico, cerca de 1.000km da costa e deslocou para oeste, o que ocasionou em elevados danos e prejuízos sociais, econômicos e ambientais (POSSIDONIO, 2011).

Por conseguinte, foi o primeiro furacão registrado no Estado, apresentando rajadas de ventos com velocidade próximas a 180 km/h no Estado de Santa Catarina. Cerca de quarenta municípios foram impactados no Sul e litoral Norte de SC contabilizando cerca de 33 mil pessoas desabrigadas, 518 feridas e 11 óbitos decorrentes do evento extremo. (JONER et al., 2021).

Durante a classificação do fenômeno extremo, em razão da sua complexidade e ineditismo, gerou grande controvérsia entre especialistas e pesquisadores. Marcelino et al. (2005) afirma que alguns cientistas consideraram o fenômeno como um ciclone tropical (furacão).

Por outro lado, outros classificam-no como um ciclone extratropical ou mesmo um fenômeno híbrido. O Instituto Nacional de Pesquisas Espaciais (INPE) concluiu que o Catarina, apesar de não apresentar características típicas durante seu processo de formação, publicou no Jornal da Ciência nº. 2802, sua classificação como furacão (MARCELINO et al., 2005).

Outrossim, na tarde do dia 20 de abril de 2015 na cidade de Xanxerê, no oeste do Estado de Santa Catarina registrou a formação de um tornado classificado estando entre F2 e F3, onde seus ventos alcançaram a velocidade de 250 km/h, 500 metros de destruição em largura em mais ou menos 3 km de extensão segundo a defesa civil do estado (S2iD, 2021).


De acordo com Souza (2017) foram registrados 2 óbitos, 3 amputação traumática de membros, 2000 pessoas desabrigadas, 3500 habitações danificadas e

164 totalmente destruídas. Em se tratando de prejuízos econômicos, o município registrou aproximadamente 46 milhões somente em danos materiais.

Igualmente, no ano de 2020 entre os dias 30 de junho e 1º de julho de 2020, houve o registro de um evento climático com fortes rajadas de ventos e tempestade que atingiram 257 municípios de Santa Catarina. Um ciclone extratropical denominado de “Ciclone Bomba” instalou-se no Estado, apresentando ventos que ultrapassaram 130 km/h (GIEHL, 2020).

A estimativa apurada pela Defesa Civil de Santa Catarina é de que cerca de 192 pessoas ficaram desabrigadas e aproximadamente 11,5 mil desalojadas. Esses prejuízos foram registrados apenas em 165 municípios e passaram de 277 milhões de reais (S2iD, 2021). A figura 4 apresenta uma linha do tempo dos desastres hidrometeorológicos de maior intensidade registrados no Estado de Santa Catarina.

Figura 4 - Linha do tempo dos desastres hidrometeorológicos registrados no Estado de Santa Catarina.



Fonte: Próprio autor, 2021.

### **3.2 SISTEMAS METEOROLÓGICOS ATUANTES EM SANTA CATARINA**

Os desastres considerados naturais, tem como o principal elemento deflagrador, as atividades atmosféricas severas e eventos meteorológicos intensos, dos quais muitos são decorrentes da atuação de sistemas ou a associação deles que interferem na regularidade meteorológica/climática de determinada região.

Conforme os estudos de Easterling et al. (2000), Smith (2000), Berz et al. (2001) e Mcbean (2004), grande parte dos eventos de desastres, com destaque aqueles de natureza hidrometeorológica, tem seu surgimento mediante instabilidades atmosféricas severas e intensas, as quais resultam em danos socioeconômicos em virtude de ameaças concretas como vendavais, granizos, tornados e episódios de chuvas intensas.

Essa dinâmica climática pode estar associada a processos complexos atmosféricos que variam em relação ao lapso temporal, que podem ir desde uma semana a milhares de anos. Muito se deve a atmosfera estar ligada e reagente aos fenômenos do oceanos e à superfície terrestre, portanto, a oceanografia, a geografia e a física da superfície do planeta também devem ser consideradas parte integrante desse conceito de dinâmica climática (VECCHIA et al., 2020).


Hermann (2001) afirma que a maioria dos desastres ocorridos em Santa Catarina, que ensejaram a decretação de situação de emergência e estado de calamidade pública, de instabilidades e fenômenos atmosféricos e resultaram em episódios de inundação, enxurradas, vendavais e deslizamentos considerando o período de 1980 até 2000.

Marcelino et al. (2006) corrobora com essa afirmação e destaca ainda que nesse período o Estado registrou 3.373 desastres naturais, sendo 2.881 associados às instabilidades atmosféricas severas, o que representa 85% do total de desastres ocorridos e que tais números ainda podem ser maiores, pois, essa estatística representa apenas os desastres registrados como de níveis III e IV de acordo com a Defesa Civil do Estado.

Frequentemente, sistemas atmosféricos e seus fenômenos possuem dimensões tanto espaciais quanto temporais típicas em que os atributos ou variáveis climáticas/meteorológicas apresentam-se de maneira heterogênea e com flutuações no espaço-tempo. De acordo com Oliva (2019) tais sistemas atuam em distintas escalas espaciais e temporais e contribuem expressivamente para a ocorrência de extremos de tempo e de clima podendo resultar em chuvas intensas, estiagens prolongadas, ventos fortes ou ondas de frio e de calor.

Assim, os fenômenos que acontecem com grande escala espacial geralmente estão associados também à grande escala de tempo. Por consequência, esses fenômenos atmosféricos podem ser analisados de maneira fractal, ou seja, as partes de um fenômeno podem ser analisadas em suas partes separadas as quais repetem os traços do todo completo mesmo ocorrendo em diversas escalas de tempo. Conforme Vecchia et al. (2020) os fenômenos atmosféricos podem ser separados em três grandes categorias, sendo elas, macro, meso e micro-escala. a figura 5 exemplifica graficamente essa estratificação de escalas.

Figura 5. Escala espacial e temporal dos sistemas meteorológicos.



Fonte: Próprio autor, 2021

No que se refere ao contexto brasileiro, o que inclui o Estado de Santa Catarina, Ferreira e Melo (2005) caracterizaram os principais sistemas atmosféricos que atuam na microescala, mesoescala e macroescala, que influenciam o tempo e o clima nas regiões do Brasil, além de descreverem o papel da interação dos oceanos Pacífico e Atlântico no clima desta região.

Os fenômenos de macroescala são aqueles de escala regional ou geográfica, que caracterizam o clima de áreas amplas devido a fatores geográficos como altitude e latitude, e utilizado quando se refere a mudanças climáticas. Possuem dimensões maiores que algumas centenas de quilômetros e duração da ordem de um dia a meses (SOUZA, 2013).

Por conseguinte, os de mesoescala recaem em uma delimitação a nível local, de 1 a 100 quilômetros com duração de horas dias, em que a topografia condiciona o clima principalmente pelas condições de relevo local (SILVA, 2006). Já os fenômenos de microescala são aqueles que, em função do tipo de cobertura do terreno, balanço local de energia, inclinação do terreno e sua configuração determinam o clima local com dimensões de 1 metro a 1 quilômetro e duração de segundos a minutos (KOBAYAMA, 2006).

Da mesma forma outros autores também afirmam a relação de sistemas atmosféricos com determinadas condições críticas do tempo ou do clima em regiões específicas do Brasil, onde é possível analisar os impactos associados, ou dos mecanismos físicos dos sistemas atuantes (BARBOSA; CORREIA, 2005; BARROS; OYAMA, 2010; SANTOS; FIALHO, 2016). De maneira similar, e com análises mais recentes, Ferreira e Cavalcanti (2022) apresentam os sistemas meteorológicos e climáticos atuantes no cenário brasileiro e catarinense, os quais alguns serão abordados nos tópicos seguintes.

### 3.2.1 Sistemas de Escalas Interdecadais e Interanuais

A *Pacific Decadal Oscillation* - PDO é descrita por Mantua e Hare (2002) e por diversos pesquisadores como um fenômeno padrão de longa duração semelhante ao que ocorre em ciclos de variabilidade climática do Pacífico de El Niño e La Niña. Quando ocorre extremos no padrão da PDO, estes são marcados por variações cíclicas irregulares nas temperaturas da superfície do mar no Oceano Pacífico, nas escalas de tempo em interanual para interdecadal, classificadas como quentes ou frias.

Durante a alternância das fases quente e fria podem resultar em impactos significativos no clima global, o que implica na formação e intensidade de ciclones, mudanças no trajeto da correntes de jato, interferência nos episódios de secas e inundações em torno da bacia do Pacífico, na produtividade dos ecossistemas marinhos, além de influenciar os padrões globais de temperatura (CHEN et al., 2022). Em análise a algumas séries temporais, foi possível identificar que esse fenômeno exerceu influência na mudança de tendência em diversas séries de precipitação, com destaque na região oeste de Santa Catarina, onde houve inversão de tendência nas quatro estações do ano (BAPTISTA et al., 2017).

De maneira idêntica, o PDO também pode influenciar em outros sistemas como o El Niño Oscilação Sul - ENSO, o que pode intensificar ou diminuir os impactos desse fenômeno de acordo com sua fase. Segundo os pensamento de Souza e Reboita (2021), caso haja o encontro do ENSO e o PDO durante a mesma fase, é possível que os impactos do El Niño ou mesmo do La Nina possam ser potencializados ou ou atenuados. Em suma, os eventos do PDO apresentam similaridade aos do ENSO, exceto em sua temporalidade, onde o ENSO ocorre predominantemente com variações interanuais, o PDO ocorre com variabilidade decadal.

No que se refere aos fenômenos de escala interanual que ocorrem no Oceano Pacífico, onde as águas apresentaram alterações de temperatura significativas em relação à distribuição da temperatura na da superfície da água e acarreta grandes

alterações no clima a nível global (SAMPAIO, 2001). Quando essa variação aumenta a temperatura das águas, esse fenômeno é comumente conhecido como El Niño, entretanto, quando ocorre o inverso, a diminuição da temperatura das águas esse fenômeno é denominado La Niña.

Essa variação periódica no sistema oceano-atmosfera no Pacífico, que normalmente ocorre a cada 3 a 7 anos com duração de 9 a 24 meses e impacta drasticamente o clima global, é denominado El Niño Oscilação Sul - ENOS. Tal evento está relacionado com as variações que ocorrem nos padrões da Temperatura Superficial do Mar - TSM e dos ventos alísios na região entre a costa peruana e a Austrália e, em escala global, é o fenômeno interanual oceano/atmosfera relacionado a variabilidade climática mais evidente (NUNES, 2019).

De acordo com os estudos realizados por Hermann (2001) o fenômeno El Niño tem influenciado de maneira significativa a incidência de desastres naturais no território catarinense. A exemplo, os maiores períodos que ocorreram desastres estão associados aos anos de El Niño, com exceção dos anos de 1984 e 2001 onde tais eventos foram associados ao período de La Niña (MARCELINO et al., 2006). Durante a primavera e verão austral, Santa Catarina apresentou eventos extremos de precipitação mais numerosos em episódios de El Niño causados pelo desenvolvimento de Complexos Convectivos de Mesoescala - CCMs e potencializados pela atuação dos jatos de altos e baixos níveis associados à sistemas frontais e ainda à advecção de umidade do Atlântico subtropical, oriunda da Zona de Convergência do Atlântico Sul - ZCAS (DUARTE, 2017).

Da mesma forma, o El Niño exerce forte influência na circulação atmosférica na escala global, e quando associados, desencadeiam a progressão de sistemas frontais e conseqüentemente eventos de desastres hidrometeorológicos em Santa Catarina, como inundações, granizo, vendavais e tornados, os quais tendem a se intensificar nos períodos de primavera e verão, em que há a associação das intensas instabilidades atmosféricas, como os sistemas convectivos isolados, os Complexos Convectivos de Mesoescala e as frentes frias (MARCELINO et al., 2006).

De acordo com os apontamentos de Sampaio (2001) esse fenômeno atua em escala global e são capazes de influenciar o clima e as condições atmosféricas de vários locais de maneira simultânea. Em Santa Catarina, ele é responsável pelo aumento da temperatura média e pela incidência de tempestades severas e sua ausência por longos períodos de estiagem, além de influenciar a atuação da Zona de Convergência Intertropical - ZCIT.

Vale destacar que, durante os períodos de La Niña, há uma intensificação dos ventos alísios, o que altera a distribuição de calor e umidade em diversas regiões do mundo (DUARTE; RIBEIRO, 2023). Esse fenômeno é geralmente associado a um clima mais frio e úmido em algumas áreas e seco em outras, impactando diretamente o regime de chuvas e as temperaturas. O fenômeno La Niña ocorre quando há um resfriamento anômalo das águas superficiais do Oceano Pacífico Equatorial, resultando em mudanças nas condições climáticas globais (BEZERRA, 2023).

Em Santa Catarina, esse fenômeno pode contribuir para temperaturas mais amenas, aumento da ocorrência de estiagens prolongadas e menor probabilidade de tempestades severas, contrastando com os efeitos mais intensos de calor e tempestades associados ao fenômeno El Niño. A La Niña também afeta a atuação de sistemas atmosféricos, como a Zona de Convergência Intertropical (ZCIT), influenciando assim o padrão climático da região.

### **3.2.2 Sistemas de Escalas Intrasazonal**

Durante os período onde a precipitação é mais intensa no Brasil, diversos sistemas meteorológicos exercem grande influência sobre o regime de chuvas, a exemplo as zonas de convergência, as frentes frias e os fenômenos de macroescala, como o ENOS, contudo, além desses sistemas já são bem conhecidos, outro fenômeno também tem uma grande importância é a Oscilação de Madden-Julian - OMJ (SIQUEIRA, 2015).

O OMJ se apresenta na forma de uma célula de convecção tropical que permeia do oeste para leste na faixa equatorial dentro de um período de 30 a 60 dias. Tal fenômeno normalmente se inicia no Oceano Índico como uma grande área de convecção que desenvolve precipitação acima do normal na região, e por conseguinte, essa convecção com o passar dos dias se desloca para leste, até o Oceano Pacífico Oeste, gerando chuvas no norte da Austrália e na Indonésia (MILLER et al., 2022).

Concluída a dinâmica no Pacífico Oeste, a oscilação não permanece mais acoplada com a área de convecção, ou seja, se desprende dos grandes acúmulos de nuvens convectivas, porém, essa convecção perturba a circulação atmosférica de baixos e altos níveis. Neste sentido Magina (2018) afirma que devido atmosfera possuir o comportamento de um fluido, qualquer perturbação nela é propagada, então a perturbação gerada pela convecção se propaga pelo restante do globo através do Pacífico, a América do Sul, o Oceano Atlântico e o continente africano, até retornar para o Oceano Índico (MAGINA, 2018).

Sob esse ponto de vista, a OMJ altera as áreas de movimentos ascendentes e subsidentes, que eventualmente acaba por favorecer ou desfavorecer a formação de chuvas no Brasil, com maior ênfase nas regiões Norte e Nordeste, porém também afeta as demais regiões como a região sul e o Estado de Santa Catarina (SILVA; HAAS, 2020). Porém, é conveniente destacar que a OMJ não realiza a geração de precipitação de maneira autônoma, pois sua contribuição no processo de formação de chuva se materializa na condição de intensificar ou inibir as chuvas formadas por outros sistemas meteorológicos.

Quando a área de convecção mais intensa está próxima à Indonésia, movimentos subsidentes anômalos ocorrem sobre o Norte e Nordeste do Brasil, inibindo a formação de chuvas, ao contrário de quando os movimentos subsidentes estão inibindo a formação de chuvas sobre a Indonésia, uma área de movimentos ascendentes favorece a formação de chuvas no Brasil (OLIVEIRA, 2012).

De maneira similar, a Oscilação Antártica, também conhecida como Modo Anular do Sul (Southern Annular Mode - SAM), representa o principal padrão de

variabilidade climática no Hemisfério Sul, especialmente notável por influenciar significativamente as condições meteorológicas e climáticas da região antártica e áreas adjacentes (AÍMOLA; ALBUQUERQUE, 2016). Este fenômeno é caracterizado pela flutuação na intensidade e na posição dos ventos circumpolares oeste que circunda a Antártica, impactando a distribuição de pressão atmosférica entre as latitudes médias e altas do Hemisfério Sul.

A SAM é determinada pela diferença de pressão atmosférica entre as latitudes médias, com cerca de 40°S a 50°S, e as altas latitudes, com aproximadamente 65°S a 70°S (CARPENEDO; SILVA, 2022). De maneira pragmática, ela alterna entre duas fases, a positiva e a negativa. Nas fases positivas, há uma maior diferença de pressão entre as regiões, resultando em ventos mais fortes circundando a Antártica, o que leva a um confinamento mais efetivo das massas de ar frio próximas ao polo, potencialmente causando temperaturas mais elevadas nas latitudes médias e impactando os padrões de precipitação (EGUCHI; ALBINO, 2021). Por outro lado, em sua fase negativa, apresenta uma menor diferença de pressão entre as latitudes médias e altas, enfraquecendo os ventos circumpolares permitindo uma maior movimentação de massas de ar frio em direção às latitudes médias, afetando as temperaturas e padrões de precipitação de maneira oposta à fase positiva (SOUZA; REBOITA, 2021).

Os impactos da Oscilação Antártica são amplos e variados, afetando não apenas o clima antártico, mas também influenciando condições climáticas em áreas distantes, como América do Sul, África do Sul e Austrália (L'ECUYER; THOMPSON, 2022). Durante a fase positiva do SAM, caracterizada por anomalias positivas de pressão nas latitudes médias, o ASAS tende a se posicionar mais ao sul, o que consequentemente influencia a ZCIT a se deslocar na mesma direção, resultando em um aumento da precipitação na Região Norte do Brasil (VASCONCELLOS; PIZZOCHERO; CAVALCANTI, 2019).

Em decorrência disso, o ASAS é fortalecido e induz o aumento da atividade de bloqueios atmosféricos e/ou presença de anti-ciclones mais intensos no Atlântico Sudoeste. Como consequência, há um déficit de precipitação na região centro-sul do

Brasil (exceto no outono) e um fortalecimento dos ventos em áreas específicas do sul do país, como Santa Catarina (CARPENEDO; AMBRIZZI, 2020).

A SAM influencia a distribuição e intensidade de precipitação, padrões de temperatura, e até mesmo a ocorrência de eventos extremos em várias partes do Hemisfério Sul, influenciando a disponibilidade de água doce, recarga de aquíferos e padrões de escoamento superficial em regiões específicas. De acordo com Pizzochero, Cavalcanti e Vasconcellos (2016), durante a fase negativa do SAM, há predominância de anomalias negativas de temperatura em grande parte do Brasil, indicando temperaturas mais baixas que o normal, com exceção o litoral da Bahia até Santa Catarina, onde uma variação regional na influência desse fenômeno.

### **3.2.3 Sistemas Sinóticos**

#### **3.2.3.1 Ciclones**

Dentre os fenômenos com maior potencial de severidade, quando se trata de escala sinótica, e que desempenham um papel fundamental nas condições e dinâmica da atmosfera, são os ciclones. Tais eventos podem ser caracterizados como ventos em deslocamento em sentido espiral interna que giram em torno de uma zona de baixa pressão atmosférica, ou seja, é uma grande massa de ar que gira em torno de um centro de baixa pressão no sentido anti-horário no quando se refere ao Hemisfério Norte e sentido horário no Hemisfério Sul, oposto a um anticiclone (AMS, 2022).

Outrossim, os ciclones podem ser considerados como elementos reguladores dos contrastes de temperatura entre os pólos e a região do equador e também mantém os ventos oriundos de oeste em latitudes médias contra a dissipação friccional, e por isso, é um dos responsáveis pelo balanço de energia e vapor d'água na atmosfera (OLIVEIRA, 2022). Ainda podem os ciclones apresentam distintas variações em relação a sua formação, contudo, independentemente do tipo de

ciclone, quer seja ele extratropical, subtropical ou tropical, são caracterizados por apresentarem menor pressão atmosférica do que o ambiente ao seu redor (REBOITA; MARRAFON, 2021).

No que se refere ao processo de formação ou intensificação desse fenômeno, ocorre quando há uma diminuição da pressão atmosférica da superfície em baixos e médios níveis da troposfera e por consequência há a formação de uma circulação ciclônica denominada de ciclogênese (HAKIM, 2015). Esse processo pode ocorrer tanto em microescala quanto a escala sinótica, e a classificação de tais fenômenos se dá de acordo com as variáveis que levam sua formação como associação de frente fria, temperatura da superfície do mar e quanto a localidade onde se formam. Quando essa formação ciclônica enfraquece ou se dissipa, devido a um aumento da pressão atmosférica e os gradientes horizontais de temperatura enfraquecem e o sistema perde intensidade, ou seja, quando ocorre o processo oposto da ciclogênese, tal processo é denominado ciclólise (AMS, 2022).

Conforme os estudos de Marrafon et al. (2022), determinados eventos de ciclone apresentam um padrão em relação à região do globo onde surgem, o que reflete em sua classificação. A exemplo, em geral os ciclones denominados como tropicais, como a própria denominação sugere, tendem a se formar entre os trópicos de câncer e capricórnio, na faixa de latitude entre 20° ao sul (20°S) e 20° de latitude norte (20°N). Já entre as latitudes de 20° e 30°, em ambos os hemisférios, é possível identificar também a formação tanto dos ciclones tropicais, quanto os extratropicais, contudo, nessa banda os ciclones subtropicais são mais frequentes de ocorrerem (GOZZO et al. 2017). Entretanto, nas latitudes consideradas maiores, além dos 30°S e 30°N, apresentam o registro somente de ciclogênese de ciclones extratropicais.

Uma das questões que sugerem que os ciclones extratropicais ocorram nessa região e que distingue tal fenômeno das demais variantes de ciclone, é que os extratropicais tem sua ciclogênese associada a frentes frias diferentemente dos ciclones subtropical e tropical, os quais não têm frente fria associada em sua formação (REBOITA; MARRAFON, 2021). No Hemisfério Sul, a Antártica é a região de formação de quase todas as frentes frias e dos ciclones extratropicais associados

a cada uma delas, tornando-a essencial para o surgimento de tais tipos de eventos (DE JESUS et al., 2022).

Além disso, outro fator que diferencia as classificações de ciclones, está relacionado com a temperatura encontrada no seu centro de tais eventos. De acordo com Marrafon et al. (2022) próximo da superfície, o centro dos ciclones extratropicais apresenta uma menor temperatura, ou seja, mais frio do que atmosfera ao redor, enquanto que o centro dos ciclones subtropicais tendem a ser mais quente do que a atmosfera ao redor. Essa diferença, apresentada pelos ciclones subtropicais, influencia a atmosfera tornando-a mais instável e aumenta as condições para o surgimento de tempestades severas.

Segundo as afirmações de De Jesus et al. (2022) os ciclones subtropicais apresentam uma estrutura horizontal menor do que os ciclones extratropicais e, devido a essa característica, pode causar condições de tempo mais severas em regiões localizadas e, por consequência, provocam volumes de chuva e ventos mais elevados do que os extratropicais. Vale também destacar, como uma característica apresentada pelos ciclones subtropicais e tropicais é que os núcleos de baixa pressão em diferentes níveis da atmosfera ficam sobrepostos, como se estivessem “empilhados” um sobre o outro, desde a superfície até níveis mais altos da atmosfera, o que faz com que tais eventos variem muito de tamanho (ROCHA et al., 2021).

No que se refere aos ciclones extratropicais, seus centros de baixa pressão não apresentam um alinhamento na vertical, semelhante ao que ocorre nos fenômenos tropicais e subtropicais, pois sua formação está associado à presença de gradientes horizontais de temperatura do ar em superfície e a ondas que viajam de oeste para leste na média e alta troposfera a aproximadamente 5.500 a 10.000 metros de altura (REBOITA; MARRAFON, 2021), ou seja, as áreas de baixa pressão em altitude ficam deslocadas para leste em relação ao centro de baixa em superfície.

De acordo com os estudos de Reboita e Marrafon (2021), os ciclones classificados como extratropicais são sistemas que apresentam uma maior

frequência na costa brasileira, onde as regiões mais suscetíveis a esse fenômeno, as quais foram identificadas por tal estudo, são a costa sudeste e a região sul do país, auferindo o destaque e preocupação a Santa Catarina, devido a formação desse fenômeno próximo a costa do Estado. Tal fenômeno é mais frequente nessas regiões por consequência dessas localizações apresentarem condições ideais para essa formação, a variação de temperatura na horizontal perto da superfície e a presença de frentes frias que ocorrem constantemente na atmosfera (REBOITA et al., 2017).

Por outro lado, os ciclones subtropicais e tropicais se desenvolvem a partir de elementos constituintes distintos, como altas temperaturas da superfície do mar, o acúmulo de muita umidade próximo da superfície, e a presença de um ciclone frio em desenvolvimento em médios níveis da atmosfera, próximo a 5 quilômetros de altura, o que não é comum de ocorrer na referida região próxima ao Brasil e sendo a condição necessária a formação desse tipo de ciclone (MARRAFON et al., 2022).

Outrossim, no que se refere a monitoramento e previsão dos eventos de ciclones por meio de imagens de satélite, os ciclones subtropicais e tropicais são reconhecidos como uma massa de nuvens em que apresentam um formato com características mais arredondadas, diferente do que ocorre com os ciclones extratropicais, os quais são identificados por apresentar um formato em espiral (SELMO, 2020).

#### 3.2.3.2 Zona de Convergência do Atlântico Sul (ZCAS)

A Zona de Convergência do Atlântico Sul (ZCAS) pode ser definida como uma banda persistente de nebulosidade e precipitação, orientada no sentido noroeste-sudeste, semi-estacionária, a qual normalmente ocorre entre os meses de outubro a março (primavera e verão), que se estende desde o sul da Amazônia, passando pela Região Centro-Oeste e prolongando-se para o Oceano Atlântico, acarretando chuvas que podem ser intensas (ALVES et al., 2015).

Conforme os estudos realizados por Quadro (2012), esse fenômeno é observado principalmente no verão, em que essa linha de nebulosidade atravessa o Brasil de noroeste a sudeste e ao longo de toda a sua extensão é possível observar fortes tempestades, tornando-a uma das principais responsáveis pelo regime de chuva na América do Sul e nas regiões onde atua. Ela se forma pela interação de diversos outros fenômenos meteorológicos típicos desta estação e é a principal responsável pela precipitação no Centro-oeste, Sudeste e Sul do Brasil.

Resultante da atuação da circulação de ventos de vários sistemas meteorológicos que atuam simultaneamente, denominado Moção Sul Americana - MSA, a qual produz alta concentração de umidade em meados da primavera sobre a Amazônia equatorial, ocorre a formação da ZCAS (SILVA et al., 2019). Referente aos fatores locais que favorecem a ocorrência de tal fenômeno, destacando-se a atuação dos ventos alísios que quando se intensificam transportam mais umidade para a região norte do Brasil no período de primavera do que nos demais épocas do ano (DURÁN-QUESADA et al., 2012) como também a confluência entre o anticiclone do Atlântico Sul - ASAS com o ar de latitudes mais altas próximas da linha do equador (OLIVEIRA, 2022).

Outrossim, a umidade que é transportada do oceano Atlântico Tropical para a região Norte do Brasil, associada com a evapotranspiração da floresta Amazônica, além de contribuir para a precipitação em tal região, é em parte transportada para o Sul e Sudeste do Brasil, devido a presença de cavado a leste da Cordilheira dos Andes, que propiciam o escoamento de umidade da região amazônica pelos ventos a leste da Cordilheira dos Andes conhecidos como Jatós de Baixos Níveis - JBN (SANTOS e REBOITA, 2019).

Segundo as afirmações de Reboita et al. (2012), quando essa umidade é formada no período de verão, decorrente da interação dos sistemas de JBN, frentes, ventos do anticiclone subtropical do Atlântico Sul, torna-se uma Zona de Convergência de Umidade - ZCOU sobre o continente. Conforme o entendimento do Grupo de Previsão de Tempo do Instituto Nacional de Pesquisas Espaciais – GPT/INPE, a ZCOU se estende no sentido noroeste-sudeste desde a Amazônia até o sudeste do Brasil e oceano Atlântico Sul e atua durante três dias ou mais passa a

ser denominada de Zona de Convergência do Atlântico Sul (PALLOTTA; NAKAZATO, 2010; SILVA et al., 2019; BARCELLOS; QUADRO, 2019).

Por consequência, uma característica preponderante desse fenômeno é a persistência e intensidade de chuvas, é devido ao fato desse sistema ser uma conexão entre frentes frias no oceano e a extensas áreas de instabilidade sobre o interior do Brasil, o que faz com que ocorram abalos no clima decorrente do registro de calor intenso durante o dia seguido de tempestades intensas. Conforme as ideias de Seluchi e Chou (2009), Reboita et al. (2017) e Alves et al. (2015), tal característica desse sistema pode causar enchentes, inundações, enxurradas e deslizamentos de terra e de encostas em determinadas regiões suscetíveis e vulneráveis, ou mesmo enfraquecer e inibir durante alguns dias a convecção além de ser responsável por sequências de dias chuvosos, o que geralmente acabam causando eventos extremos de precipitação.


Em Santa Catarina, e nas demais regiões do sul do Brasil, a Zona de Convergência do Atlântico Sul exerce influência indireta como os demais sistemas que a formam ou conduzem sua direção mais ao sul, pois tal sistema atua climatologicamente sobre o sudeste do Brasil, porém induzir movimentos descendentes intensos no sul do Brasil, inibindo a formação de nuvens e precipitação (SELUCHI;CHOU, 2009; REBOITA et al., 2012; SILVA et al., 2019).

### 3.2.3.3 Anticiclone Subtropical do Atlântico Sul (ASAS) e Pacífico Sul (ASPS)

Os fenômenos denominados como anticiclone são definidos como uma área de alta pressão, geralmente acima de 1013Pa, com cerca de 1000 a 3000 quilômetros de diâmetro, onde a pressão atmosférica é maior do que a pressão do ar circundante e aumenta da periferia em direção ao centro no sentido horário no hemisfério Norte e anti horário no hemisfério Sul. De acordo com Oliveira (2022), afirma que sua formação está associada com a circulação geral da atmosfera, pois tal fenômeno envolve a força de coriolis, na convergência de correntes de jato e os

ventos de subsidência desenvolvidos no encontro das células de Hadley e Ferrel a 30° Norte ou Sul (COLUCCI, 2016), conforme mostra a figura 6.

Figura 6. Células de circulação geral, ventos globais predominantes e centros de Alta (A) e Baixa (B) pressão atmosféricas



Fonte: Vieira, 2020

Segundo as afirmações de Reboita et al. (2019), os anticiclones podem ser classificados em dois grandes grupos, os do tipo migratório ou transitórios, os quais ocorrem eventualmente, com tempo de duração de 2 a 6 dias associado a baroclínicas (onde as isóbaras e isotermas não se coincidem) e as do tipo Semi Permanentes, que perduram a maior parte do ano em regiões com latitudes subtropicais chamadas de Anticiclones Subtropicais ou Altas Subtropicais. No Hemisfério Sul, sobre os oceanos, existem três anticiclones subtropicais que exercem influência no clima e no tempo nessa região, o Anticiclone Mascarenhas que está localizado no oceano Índico, a Alta Subtropical do Atlântico Sul - ASAS, e o Pacífico Sul - ASPS, sendo os dois últimos os que apresentam maior influência no clima na América do Sul (ALVES et al., 2015; OLIVEIRA, 2022).

O ASAS, também conhecido como Anticiclone Santa Helena, devido à localização próxima da ilha de Santa Helena, única porção de terra mais próxima a esta latitude, é um sistema de alta pressão semi permanente que é responsável pela regulação das estações seca e chuvosa em boa parte da América do Sul, com destaque na região brasileira. Dependendo da posição deste sistema e seu deslocamento sazonal, o ASAS pode influenciar fortemente o regime de precipitação e de eventos meteorológicos em determinadas regiões do Brasil ou impedir a formação de precipitação (OLIVEIRA, 2022).

Durante os períodos de inverno, esse sistema atua mais próximo do continente e pode inibir a entrada de frentes frias, causar inversão térmica e concentrar os constituintes poluentes nos principais centros urbanos das regiões sudeste e sul devido a formação de um bloqueio atmosférico realizado pela subsidência atmosférica a qual reduz a umidade da região (VIEIRA, 2020). Com isso o ASAS contribui para o menor regime de chuvas, a queda de temperaturas e também favorece a formação de nevoeiros e geadas no sul e sudeste do Brasil (REBOITA et al., 2012).

Ainda Vieira e Cupolillo (2021) destacam que, entre os meses de junho a setembro, a incidência do ASAS resulta na constituição de uma atmosfera quente, seca, estável, com ausência de nebulosidade e precipitação, e ainda apresenta nesse período, episódios extremos de baixa umidade relativa quando ocorre o processo de continentalização de tal fenômeno. No início da estação chuvosa pode ocorrer o enfraquecimento dos ventos de leste/nordeste e intensificação do escoamento de noroeste, que é responsável pelo transporte de umidade da Amazônia para o Sudeste e Sul do Brasil (QUADRO, 2012).

Por outro lado, no verão, o qual é caracterizado pelo período mais chuvoso, o ASAS normalmente se encontra posicionado mais a leste, no oceano Atlântico, e desta forma, influencia substancialmente o transporte de umidade no que se refere aos baixos níveis troposféricos ao longo da ZCAS, a qual também é afetada pela circulação associada a ASAS (QUADRO, 2012). Reboita et al. (2018) também corrobora com essa afirmação quando sugere em seus estudos que na região Sudeste, além da umidade proveniente da Amazônia, outra fonte primordial de

umidade é o oceano Atlântico Sul, que é proveniente da ASAS, quando está mais ao leste, durante a estação chuvosa.

Por consequência da intensificação dos ventos alísios do Nordeste, o transporte de umidade para a Amazônia aumenta consideravelmente quando os Jatos de Baixos Níveis - JBN realiza o retorno de parte desta umidade como também recebe umidade advinda da influência do ASAS e assim favorece o transporte de umidade para o continente quando a Alta está deslocada sobre o oceano Atlântico (REBOITA et al., 2015).

Ainda Cupolillo (2015) destaca que mesmo quando o fenômeno ASAS encontra-se mais afastado do continente, na estação chuvosa, existe a possibilidade do seu avanço sobre o Brasil, o que implica na redução da precipitação e aumento das temperaturas denominado como veranico climático, ou seja, períodos curtos de estiagem ao longo da estação chuvosa, o qual pode apresentar duração média entre dez a vinte dias.

De maneira similar, o Anticiclone ou Alta Subtropical Pacífico Sul - ASPS, como o denominam sugere, é um sistema semi permanente que atua sobre o oceano Pacífico próximo a Costa do Chile e influencia de maneira direta o clima do Chile, Peru, Equador, Bolívia e Argentina. De acordo com Reboita et al. (2012) a ASPS é o sistema atmosférico que influencia o regime de precipitação sobre as regiões sul e sudoeste dos países da América do Sul, em que se observa a região mais ao sul, demonstra uma precipitação homogênea ao longo dos anos, diferente da região sudeste, a qual apresenta máxima anual durante o período de inverno e a mínima anual ocorre no período de verão.

A ASPS atinge sua posição mais ao norte durante os períodos de inverno, o que resulta no encontro dos ventos de oriundos de oeste com os Andes e, ao cruzá-lo, favorecem a ocorrência de chuva à barlavento em relação às regiões montanhosas. Entretanto, o fenômeno desloca-se para o sul durante os períodos de verão, em que ocorre o predomínio de movimento descendente decorrente da alta pressão e inibe a formação de nuvens e precipitação (OLIVEIRA, 2022).

Diante disso, Aguirre (2020) comenta que o ASPS contribui significativamente para com o clima árido extremo que abrange desde o deserto do Pacífico, o qual está situado no norte do Chile (deserto de Atacama) até a costa do Peru (deserto costeiro). Este sistema de alta pressão faz um papel fundamental como impulsor dos ventos alísios do Pacífico do sudeste, também como impulsor da corrente de Humboldt e como um dos elementos do padrão climático ENSO.

Em relação ao impacto do ASPS no Brasil, estudos de Lucyrio et al. (2019) foi observado em superfície que houve a incursão de ar polar para latitudes mais baixas devido às características de circulação do ASPS associada a baixa pressão no oceano Atlântico favorecem a advecção de ar frio, ou seja, a ocorrência de ondas de frio intensas na região sudeste e sul do Brasil. Ribeiro e Nunes (2011) identificaram em seus estudos que a ASPS também pode influenciar o sul do Brasil quando atua como bloqueio atmosférico impedindo a passagem de sistemas frontais, o que pode ensejar em ondas de calor na região em curtos períodos.

#### 3.2.3.4 Vórtices Ciclônicos de Altos Níveis (VCAN)

O Vórtice Ciclônico de Altos Níveis (VCAN) pode ser classificado como um sistema de circulação de ventos fechada, de baixa pressão e que gira no sentido horário, o qual se origina em altos níveis da atmosfera e pode se estender até os baixos níveis conforme a nebulosidade e condições da atmosfera e apresenta um núcleo frio (FERREIRA; CAVALCANTI, 2022). Conforme a estação do ano, a área de formação da VCAN pode variar conforme a estação do ano, por exemplo no Brasil, o fenômeno usualmente ocorre durante os meses de verão na região Nordeste e ao longo do inverno e primavera próximo à região Sul.

Gan et al., (2022) destacam que os VCANs podem ser distinguidos em dois tipos de fenômenos, aqueles que se forma em latitudes subtropicais denominados Palmén, como os que atuam na região Sudeste e Sul do Brasil e os que se formam

em regiões tropicais, como o que atua no nordeste do Brasil, os do tipo Palmén. No caso do nordeste brasileiro, tal sistema possui o potencial de provocar precipitações sobre determinadas áreas, ao mesmo tempo que em outras localidades atua como bloqueio atmosférico inibindo a precipitação (SANTOS, 2015).

Diversos fatores e variáveis, quando associadas, podem influenciar a formação das VCANs, contudo, algumas variáveis apresentam uma maior influência para sua formação e aparecem com maior frequência quando tais vórtices são identificados. A formação clássica do VCAN no nordeste está associada às frentes frias quando avançam em direção a costa norte do Sudeste e costa sul da Bahia, como também é intensificado quando o sistema Alta da Bolívia - AB atua em altos níveis da atmosfera próximo ao Centro-Oeste do Brasil e contribui de maneira significativa para a formação do vórtice (GERMANO, 2016).

Na América do Sul, a circulação atmosférica de verão demonstra que a Alta da Bolívia tem sua formação associada com a liberação de calor latente na região Amazônica e, quando isso ocorre, as correntes de ar abaixo da AB formam um cavado entre o Nordeste do Brasil e o oceano Atlântico, o que eventualmente podem resultar no aparecimento de VCANs no interior do cavado. (REBOITA et al., 2017). A formação do VCAN na região Nordeste também está associada à intensificação da ZCAS, que é um dos principais sistemas responsáveis por chuvas intensas durante os meses de dezembro, janeiro e fevereiro entre o Norte e Sudeste do país (ALVES et al., 2015).

De maneira semelhante, as VCANs subtropicais que influenciam na meteorologia do Brasil, formam-se no extremo leste do oceano Pacífico Sul com certa frequência e, quando conseguem ultrapassar a Cordilheira dos Andes, provocam alterações meteorológicas no Centro Sul do Brasil e em alguns países da América do Sul como Uruguai e Argentina. De acordo com as afirmações de Gan e Pinheiro (2022) os VCANs, quando avançam para o continente, podem causar instabilidade na atmosfera da região, como exemplo, quando o ar frio e seco no interior do vórtice influencia a formação de ondas de frio por meio da perda radiativa em níveis médios, o que favorece o surgimento de geadas no Sul do Brasil, provocar

ventos fortes e até mesmo neve em regiões com altitudes acima de 1000 metros, além de ocasionar a ciclogênese em superfície.

As VCANs que incidem no Nordeste, geralmente tem seu tempo de vida, em média de aproximadamente 7 dias, e ao longo desse período é capaz de provocar temporais na região Nordeste, e fornecer suporte para a configuração de ciclones extratropicais próximos à região Sul (FERREIRA; CAVALCANTI, 2022). No centro do VCAN formado no Nordeste, a tendência é de tempo firme, enquanto em sua periferia o risco de tempestades aumenta de forma considerável. De maneira análoga as VCANs do Nordeste, as subtropicais que incidem nas Regiões Sul e Sudeste do Brasil, geralmente apresentam períodos de 1 ou 2 dias, provocam chuvas e ventos fortes (ALVES et al., 2015).

#### 3.2.3.5 Sistemas Frontais

Dentre os fenômenos e sistemas que alcançam dimensões entre centenas e milhares de quilômetros, os quais podem durar vários dias ou semanas e que são frequentes no Brasil como a ZCAS, são os Sistemas Frontais, os quais causam variações na distribuição de precipitação e temperatura em quase todo o Brasil e América do Sul (ESCOBAR et al., 2016). Para abordar de maneira didática os sistemas frontais, é necessário compreender mais a fundo os fenômenos denominados frentes, que estão relacionados com formações dos sistemas frontais.

As frentes se formam quando ocorre o encontro de massas de ar com características distintas em relação a seus gradientes térmicos, e neste caso, a região Sul e Sudeste são consideradas propícias à frontogênese (ALVES et al., 2015). O ar frio oriundo dos pólos e o ar quente proveniente dos trópicos e subtropicais estão separados pelas frentes ou sistemas frontais. Conforme as afirmações de Vecchia et al. (2020), por meio da dinâmica das ondas atmosféricas e das frentes, o calor é distribuído, onde reduz o excesso nos trópicos e o déficit nos polos. Quando o ar frio avança sobre determinado setor terrestre, a frente é

denominada de frente fria, ao contrário de quando o ar quente se sobrepõe sobre outro setor terrestre, denomina-se de frente quente.

Desta forma, quando há o encontro de duas frentes com características térmicas diferentes são denominadas como sistemas frontais. A exemplo, quando o ar frio de uma massa de ar avança e substitui o ar quente de outra massa, é delineada uma borda anterior da zona frontal, a qual é marcada por uma frente fria (KOUSKY; ANDRADE, 2022). Neste sentido, Alves et al. (2015) ainda considera como um sistema frontal clássico aquele que possui em sua composição frente fria, frente quente e um centro de baixa pressão (ciclone) em superfície.

Outrossim, os sistemas frontais ocorrem ao longo de todo o ano, sendo que o segundo semestre apresenta um maior destaque, uma vez que o maior número de ocorrência em latitudes mais altas são identificadas entre o período de abril a novembro (ALVES et al. 2015). Escobar et al. (2016) considera que o período entre os meses de maio e setembro, é onde as frentes frias mais atingem Santa Catarina com maior frequência, diferente do período entre outubro e abril, o qual essa frequência é menor.

As frentes frias se deslocam do sul para o norte (em relação ao hemisfério sul) e podem chegar até o sul do Pará, onde causam as “friagens”. Ela é responsável por grandes acumulados de precipitação, seguida por tempo bom e frio. Entretanto, a frente quente se desloca de norte para sul, no hemisfério sul, não causa muita chuva e deixa o tempo mais quente após sua passagem.

Durante o inverno, esses sistemas são acompanhados de massas de ar de latitudes altas que, às vezes, causam geadas e friagens em áreas agrícolas no Sudeste e Sul do Brasil. Algumas vezes, as frentes frias alcançam latitudes muito baixas sobre o oeste da Amazônia e também ao longo da costa nordeste do Brasil (REBOITA et al., 2012). Quando as frentes frias avançam para norte (em direção ao equador), durante a estação de verão, algumas vezes elas interagem (FERREIRA, CAVALCANTI, 2022).

As frentes frias são os sistemas meteorológicos mais comuns que modificam as condições de tempo sobre o centro-sul do continente sul-americano. Estudos de

Kousky e Andrade (2022) demonstram que a distribuição espacial da atividade frontal sobre a América do Sul, possui duas regiões preferenciais com maior frequência de passagens frontais, sendo a primeira a leste da Cordilheira dos Andes e a segunda sobre o litoral das regiões Sul e Sudeste, por influência da presença da Serra do Mar. Reboita et al. (2012) e Escobar et al. (2016) discutem que diante desse resultado, a região leste de Santa Catarina pode ser considerada como uma das regiões com maior frequência de passagens de sistemas frontais no Brasil.

#### 3.2.3.6 Correntes de Jato (Jatos de Altos Níveis e Jatos de Baixos Níveis)

As correntes de jato podem ser consideradas como o intenso escoamento do ar que ocorre na atmosfera, as quais atuam como um elemento de regulação da atmosfera e responsáveis pelas mudanças nas condições meteorológicas em todo o mundo. Quando essas correntes se encontram na tropopausa, no intervalo de transição entre a tropopausa e estratosfera, essas correntes são denominadas Jatos de Altos Níveis. Entretanto, quando esse escoamento intenso de ar ocorre na baixa troposfera, essas correntes são denominadas de Jatos de Baixos Níveis - JBN. Esses fortes ventos estão presentes em ambos os hemisférios e são extremamente influentes para o desenvolvimento de sistemas meteorológicos.

Em altos níveis, as correntes de jato ocorrem devido a rotação do planeta e a variação de temperatura entre os trópicos e os polos, guiadas de Oeste para Leste de maneira indireta, transitando de Norte para Sul em um padrão ondulatório, alternando de regiões de alta pressão para baixa pressão (STENDEL et al., 2021). Nos trópicos a troposfera é mais profunda (16km) em relação aos pólos (11km), devido ao calor que faz a coluna de ar se expandir. Contudo, apesar das colunas de ar nos trópicos e nos polos possuírem em média a mesma massa, a pressão atmosférica é diferente em altitudes iguais, em função da densidade do ar na vertical decai mais rapidamente nos polos (FONSECA et al., 2022).

De acordo com Oliveira (2022), às JAN podem ser classificados em Jato Subtropical, que se apresenta como uma estreita faixa de vento intenso em ambos

os lados do equador de aproximadamente 200hPa, os quais têm sua formação associada a Células de Hadley, localizadas em latitudes entre 20° e 35° Sul e são mais intensos e próximos do equador no inverno, como também em Jato Polar, localizado entre as latitudes 35° e 70° Sul, tem sua formação ligada ao gradiente horizontal de temperatura apresentada em estreitas zonas frontais e atua com maior frequência no inverno, principalmente em latitudes mais baixas, onde sua posição é mais próxima do equador.

De maneira geral, os Jatos de Altos Níveis podem aumentar em determinadas regiões o gradiente de vorticidade a tal ponto que as ondas atmosféricas dessas correntes possam ser afetam vórtices atmosféricos, como blocos anticiclônicos, e podem criar condições climáticas prolongadas que podem levam a impactos climáticos extremos (STENDEL et al., 2022). No Brasil, durante o inverno as frentes frias atingem latitudes mais baixas e geralmente são acompanhadas pelo Jato Polar em seus deslocamentos. Diferente do que ocorre no verão, em que o Jato Polar fica restrito a latitudes mais altas, tendo sua posição mais ao norte próximo dos 35° Sul. Ainda quando os Jatos Subtropicais incidem em latitudes baixas, o Jato Polar sempre aparece acoplado a esse sistema, uma vez que está associado aos sistemas transientes (FERREIRA; CAVALCANTI, 2022).

Por outro lado, os JBN são correntes de ar de alta velocidade que ocorrem próximas à superfície terrestre, geralmente a uma altitude de 1 a 2 quilômetros. Esses jatos podem ocorrer em diferentes escalas, desde pequenas áreas locais até grandes regiões continentais. Os JBN desempenham um papel considerável na circulação atmosférica global devido a serem responsáveis pela advecção de calor e umidade dos trópicos para regiões de latitudes médias. Brizola et al. (2018) define os JBN como fluxos meridionais que podem ser encontrados nos primeiros quilômetros da atmosfera, tendo como velocidade máxima em torno de 2.000 metros acima da superfície terrestre.

Os JBNs podem ser considerados como um mecanismo essencial de transporte atmosférico de umidade, semelhante aos Rios Atmosféricos, e são responsáveis na ocorrência de eventos de precipitação, uma vez que intensificação ou reduzem o transporte de umidade e resultando em anomalias de chuva

principalmente a leste do Andes (MARENGO, 2022). Esses fenômenos meteorológicos podem afetar o clima e o tempo em diversas regiões do mundo, principalmente quando são intensos, pois podem influenciar a formação e a intensidade de outros sistemas como ciclones e frentes frias, além de afetar também o transporte de umidade e poluentes na atmosfera, afetando a qualidade do ar e a saúde humana.

Em relação a formação dos JBNs, podem estar associados a dois tipos de processos, aqueles associados a processos de camada limite atmosférica - CLA ou podem estar associados a fenômenos de escala sinótica. O JBN da CLA normalmente apresenta uma forte oscilação, durante o período diurno, e está intrinsecamente ligado com gradiente horizontal de temperatura produzido por terrenos inclinados nesse período. Porém os JBN sinóticos estão associados à intensificação de gradientes horizontais de pressão induzidos por sistemas baroclínicos migratórios, os quais podem estar também ligados a correntes de jatos de altos níveis decorrente da circulação ageostrófica transversa (KANNENBERG, 2019).

A Cordilheira dos Andes atua como uma barreira topográfica e canaliza os ventos alísios provenientes do Atlântico Norte Tropical e perpassam a bacia Amazônica em direção aos subtrópicos, o que modifica a dinâmica seca pela convecção úmida nas encostas dos Andes e ocasiona perturbações ciclônicas no escoamento de oeste no norte da Argentina, causando variações no campo de pressão, contribuindo para que o escoamento se dirija do Atlântico Norte em direção a bacia do Prata através da bacia Amazônica (REBOITA; SANTOS, 2018).

No Brasil, os JBN são frequentes durante o período de verão, especialmente na região Centro-Sul, onde esses jatos são gerados pelo contraste entre as áreas quentes e úmidas da Amazônia e as áreas mais secas e frias do Sul do Brasil. Por consequência desse transporte de umidade, Santa Catarina, a região Sul e países adjacentes como Uruguai, Paraguai e parte da Argentina, tem suas condições meteorológicas e de clima afetadas pelo JBN advindos do leste do Andes. Esse fenômeno também regula o regime de chuva na região, pois influenciam tanto na desestabilização da atmosfera como no disparo de convecção profunda ao interagir

com os sistemas transientes e com a topografia local, que por consequência desempenha papel fundamental na formação e desenvolvimento de tempestades severas que se desenvolvem na região de saída do Jato (OLIVEIRA, 2022).

Quando os JBN ocorrem, podem trazer umidade da Amazônia para o Centro-Sul do país, o que pode resultar em chuvas intensas e prolongadas. No entanto, os JBN também podem causar secas em algumas regiões, especialmente quando ocorrem de forma persistente. Os JBN são um importante desafio para a previsão do tempo e do clima, pois são fenômenos de pequena escala que podem ser difíceis de detectar e simular com precisão em modelos numéricos. Por isso, são necessários estudos e observações cuidadosas para melhor entender esses fenômenos e aprimorar a previsão meteorológica e climática.

#### **3.2.4 Sistemas de Mesoescala**

##### **3.2.4.1 Complexos Convectivos de Mesoescala**

No que se refere a eventos de mesoescala, os fenômenos são um pouco maiores, com extensão de algumas dezenas e duração de algumas horas. Eles são influenciados pelas características da superfície e, principalmente, pelo processo de convecção. Os Sistemas Convectivos de Mesoescala - SCMs são os principais fenômenos dessa escala e podem ocorrer de forma isolada ou em grupos. Esses sistemas são tipicamente formados em regiões tropicais e subtropicais, onde há forte gradiente de temperatura e umidade, como também são responsáveis por grande parte da precipitação em muitas regiões do mundo e podem ser acompanhados de ventos fortes, raios e granizo.

Neste viés, dentre os sistemas convectivos de mesoescala, os Complexos Convectivos de Mesoescala - CCMs são um tipo específico com organização espacial e temporal particular. Os CCMs são compostos por uma área de nuvens convectivas organizadas em um padrão circular ou oval, com diâmetro típico

variando de 100 a 500 km, os quais consistem em um conjunto de nuvens convectivas do tipo Cumulonimbus (Cb), espessas e frias, com crescimento vertical em um período de 6 a 12 horas. Os CCMs estão frequentemente associados a eventos de precipitação intensa (MADDOX, 1980).

Outrossim, as características mais marcantes dos CCMs são observadas durante o período noturno, tanto em regiões subtropicais como tropicais. Esses sistemas geralmente iniciam seu ciclo de vida algumas horas após a formação de células convectivas, que ocorrem no final da tarde ou início da noite. No entanto, sua máxima extensão ocorre durante a madrugada, persistindo até a manhã seguinte (LYRA et al., 2020). Esses sistemas são de grande interesse devido às consequências dos diversos fenômenos adversos associados aos CCM, como precipitações intensas e trovoadas.

Os Complexos Convectivos de Mesoescala (CCMs) apresentam intensa atividade convectiva, com nuvens que se estendem verticalmente a grandes altitudes, resultando em um grande volume de precipitação em um curto período de tempo. Esse fenômeno pode causar danos marcantes à sociedade, incluindo alagamentos, enchentes e deslizamentos de terra, resultando em grandes perdas econômicas e sociais (LIMA; AQUINO; MORAES, 2018). Por outro lado, a convecção provocada pelos CCMs pode fornecer uma quantidade significativa de chuva em épocas de grande estiagem, sendo de importância crítica para populações em áreas como o sertão nordestino (LYRA; FREITAS, 2019).

De acordo com Ferreira (2016), a maioria dos CCMs é de origem continental e ocorre durante a noite, e nesse sentido, embora haja uma maior frequência de CCMs de pequeno porte nos Estados Unidos em comparação com a América do Sul, as características desses sistemas nos dois continentes são bastante semelhantes. No entanto, uma diferença significativa é que os CCMs sul-americanos podem ser até 60% maiores do que os que se formam nos Estados Unidos.

Em relação à América do Sul, esses fenômenos estão relacionados à escala sinótica e processos de mesoescala que favorecem o seu desenvolvimento, com destaque nos períodos de verão, em que a máxima atuação dos CCMs ocorre no

Paraguai, norte da Argentina e sul do Brasil, indicando uma estabilidade estática comum nesta estação (DURKEE; MOTE, 2010). Tais fenômenos são responsáveis por tempestades intensas na região sul do Brasil e podem causar danos representativos, relacionados a ventos fortes, descargas elétricas atmosféricas, chuva intensa, e, em casos mais extremos, até granizo (FERREIRA, 2016).

#### 3.2.4.2 Linhas de Instabilidade

As Linhas de Instabilidade - LI são provavelmente a forma mais frequente de organização convectiva de mesoescala no qual várias células de tempestade se agrupam em uma linha, que pode não ser necessariamente contínua, e se deslocar por quilômetros e pode durar várias horas, em ocasiões especiais, uma linha pode durar mais de um dia são provavelmente a forma mais frequente de organização convectiva de mesoescala (OLIVEIRA et al., 2016).

São áreas ou zonas onde há uma grande quantidade de energia acumulada na atmosfera, geralmente associada a mudanças bruscas de temperatura, pressão atmosférica e umidade, as quais podem dissipar essa energia em forma de tempestades e sistemas meteorológicos intensos, como chuvas torrenciais, granizo, ventos fortes e tornados (CAVALCANTI, 2009).

Essas linhas de instabilidade geralmente ocorrem em regiões onde há um gradiente de temperatura e umidade acentuado, como em frentes frias, áreas de baixa pressão e zonas de convergência de massas de ar. Além disso, fatores como a topografia, a presença de corpos d'água e a influência de sistemas meteorológicos maiores, como furacões e ciclones, podem aumentar a instabilidade atmosférica em uma determinada região (COHEN et al., 2022).

As linhas de instabilidade podem se manifestar de diferentes maneiras, dependendo das condições meteorológicas locais. Em alguns casos, elas aparecem como uma linha nítida de nuvens carregadas, enquanto em outros casos, elas podem se apresentar como uma área ampla de instabilidade atmosférica, com

nuvens carregadas espalhadas em várias direções. Ferreira e Cavalcanti (2022) sustentam que no Brasil, é comum a formação de Linhas de Instabilidade na costa norte-nordeste da América do Sul, as quais têm o potencial de se deslocarem para o interior do continente e provocar consideráveis volumes de chuva.

Esses fenômenos podem ter um impacto notável no clima e na meteorologia local. As linhas de instabilidade podem causar tempestades intensas, enchentes e deslizamentos de terra, prejudicando a agricultura e a infraestrutura urbana (OLIVA, 2019). Ventos fortes e tempestades de granizo também podem causar danos em edifícios e equipamentos, além de interromper o fornecimento de energia elétrica e de serviços de transporte.

No Sul do Brasil, durante a primavera, é mais comum a ocorrência de Linhas de Instabilidade, sendo que nessa época também ocorrem os maiores percentuais de eventos severos, embora a maioria ocorram durante a madrugada e manhã, pois o maior percentual de LIs severas é registrado no período da tarde (RIBEIRO, 2018). Vale ressaltar que tais eventos com deslocamento mais rápido têm maior probabilidade de serem severas, especialmente se o deslocamento for superior a 50 km/h (FERREIRA; CAVALCANTI, 2022).

De acordo com Ribeiro (2018), as Linhas de Instabilidade presentes no Sul do Brasil possuem características diferentes das tropicais e recebem pouca atenção da comunidade meteorológica. Isso resulta em um conhecimento científico limitado e baixa previsibilidade desses sistemas. Além disso, um estudo realizado pelo CEPED/UFSC (2013) constatou que vendavais são responsáveis por 5% a 15% dos desastres naturais no Sul do Brasil, gerando prejuízos anuais de centenas de milhões de reais. Cabe destacar que tais valores são significativos em relação aos prejuízos anuais causados por fenômenos meteorológicos na região.

Como esses sistemas têm uma escala temporal associada à variabilidade diurna (brisa marítima e aquecimento terrestre), sua máxima atividade convectiva pode ser notada nas imagens de satélite no final da tarde ou no dia posterior à sua formação (COHEN et al., 2022). Essas informações são preciosas para prever a ocorrência de fenômenos meteorológicos extremos, uma vez que esses fenômenos

são monitoradas pelos serviços meteorológicos, que utilizam modelos computacionais avançados e dados de satélite para prever sua ocorrência e intensidade com vistas a permitir que as autoridades possam emitir alertas e tomar medidas de precaução para minimizar os danos causados por esses eventos.

### **3.2.5 Sistemas de Microescala**

Nesta escala estão os fenômenos com extensão de centímetros até poucos quilômetros e de curtíssima duração, eles podem se formar e se dissipar em questão de segundos, pois nesta escala tais fenômenos estão muito associados com a interação entre a atmosfera e os elementos da superfície, como vegetação e solo, logo, estão profundamente associados com as características de cada área. Foken em seu livro (2017) explica que nesta escala, por exemplo, é estudado o transporte de carbono e calor dentro do dossel de uma floresta ou de uma plantação. Devido à curta duração e extensão destes fenômenos, o seu estudo demanda equações e considerações específicas para esta escala, além de instrumentos capazes de realizar medições em alta frequência.

Os sistemas de microescala são fenômenos meteorológicos que ocorrem em escalas menores do que os sistemas convencionais de mesoescala e macroescala, geralmente com diâmetros menores que 10 km. Esses sistemas atuam principalmente na camada limite planetária, que é a camada mais baixa da atmosfera, onde ocorre a interação entre a superfície da Terra e a atmosfera (AMS, 2022).

Da mesma forma, tais sistemas podem se manifestar de diferentes maneiras, incluindo brisas terrestres e marítimas, células convectivas isoladas, tempestades supercelulares de pequena escala, nuvens lenticulares e correntes, pois esses sistemas são influenciados por processos locais de convecção, ventos em baixa altitude, topografia e outros fatores (FOKEN, 2017). Da mesma forma, eventos de menor e mais curta duração são considerados parte da microescala, com duração

de apenas alguns segundos ou minutos e ocorrem em áreas menores que dois quilômetros.

De maneira complementar, um bom exemplo de evento em microescala são as correntes ascendentes ou descendentes, que são pequenos tufo de ar que se movem em pequenas áreas, uma vez que tais eventos, curtos e pequenos, geralmente não possuem a proporção razoável para serem representados em um mapa meteorológico., sem mencionar que a microescala também aborda a transferência de calor entre o ar e o solo, bem como a troca gasosa entre as folhas de uma planta o que torna difícil sua representação (MONTEITH; UNSWORTH, 2013).

Os impactos dos sistemas de microescala na meteorologia e clima local podem ser determinantes, influenciando a temperatura, umidade, ventos e outras variáveis meteorológicas em uma área restrita, como exemplo, as brisas terrestres e marítimas são sistemas de microescala que ocorrem em regiões costeiras e podem influenciar a temperatura e a umidade do ar local, afetando a vida das pessoas que moram nessas áreas (AYOADE, 1994).

Outro exemplo de sistema de microescala é a tempestade supercélula de pequena escala, que pode ocorrer em regiões de clima temperado e afetar áreas restritas, produzindo ventos fortes, granizo e tornados. Essas tempestades podem causar danos graves em estruturas e na agricultura. As regiões do mundo mais afetadas por sistemas de microescala variam dependendo do tipo de fenômeno. Por exemplo, as brisas terrestres e marítimas são comuns em regiões costeiras de todo o mundo, enquanto as tempestades supercelulares de pequena escala são mais frequentes em regiões de clima temperado, como as Grandes Planícies dos Estados Unidos (WALLACE; HOBBS, 2006).

### **3.3 PESQUISAS SOBRE EVENTOS EXTREMOS RELACIONADOS A DESASTRES**

A expressão "evento extremo" é frequentemente utilizada para descrever fenômenos naturais inesperados de grande impacto, como enchentes, tsunamis, terremotos e erupções vulcânicas. Seu surgimento na literatura científica data da década de 1950 e, desde então, tem sido adotado em diferentes áreas do conhecimento, incluindo economia, psicologia, medicina e engenharia (STEWART et al., 2022). A aplicação do termo tem se ampliado cada vez mais para o estudo de eventos históricos, pré-históricos e de longo prazo em uma vasta escala, sendo amplamente reconhecido que tais eventos têm causado profundos impactos na biodiversidade e nas culturas terrestres (BROSKA et al., 2020). Em decorrência disso, é compreensível que a forma como as pessoas concebem, definem e pesquisam eventos extremos varie consideravelmente.

Para um melhor delineamento do conceito empregado no estudo, os eventos extremos são aqueles eventos tão raro quanto ou mais raro do que o 10º ou 90º percentil de uma função de densidade de probabilidade estimada a partir de observações em um determinado local e época do ano (IPCC, 2021). Quando um padrão de clima extremo persiste por um período prolongado, como uma estação, ele pode ser classificado como um evento climático extremo, especialmente se produzir uma média ou um total que seja extremo, como uma seca ou chuvas intensas durante uma estação (ALIMONT et al., 2022).

Por ocasião deste estudo, é considerado eventos extremos aqueles de origem climática ou meteorológica intensos e raros, que podem ter um impacto substancial na vida das pessoas, quer seja pelos danos à integridade física humana ou prejuízos patrimoniais e econômicos, além daqueles que afetam o meio ambiente e aos ecossistemas. É necessário distinguir os eventos extremos de seus impactos, para avaliar a resiliência em sistemas sociais-ecológicos-tecnológicos, uma vez que evento extremo pode basear-se em probabilidades de ocorrência ou no ponto em que há potenciais consequências ou impactos, mas não deve ser confundido com os impactos efetivamente observados (McPHILLIPS et al., 2018).

De acordo com o IPCC (2021) os eventos extremos relacionados a desastres estão se tornando cada vez mais comuns em todo o mundo, caracterizado pelas inundações, chuvas intensas, tempestades, secas e outros fenômenos climáticos

extremos que estão causando perdas humanas e econômicas significativas em muitas partes do mundo. Diante desse cenário, é fundamental entendermos melhor os eventos extremos relacionados a desastres, a fim de desenvolver medidas e estratégias de gerenciamento de riscos mais eficazes.

Muitos dos eventos extremos têm como sua causa raiz associada às mudanças no clima e no sistema climático global, que podem ser influenciados por fatores naturais, como a atividade solar e vulcânica, e por fatores antrópicos, como as emissões de gases de efeito estufa. O aquecimento global desde o período de 1850 a 1900 resultou em um aumento na frequência, intensidade e duração de eventos extremos em várias regiões do mundo, contudo de maneira específica, houve aumento na intensidade das chuvas intensas, frequência e intensidade das secas, desertificação em algumas áreas secas e frequência e intensidade das tempestades de poeira (EBI et al., 2021).

Nesse ínterim, as projeções de eventos extremos são feitas usando modelos climáticos que simulam a dinâmica do sistema climático global e regional. Esses modelos são baseados em princípios físicos e matemáticos e incorporam variáveis e dados históricos sobre o clima e eventos extremos passados, que são usados para validar os modelos e ajustar as previsões (WMO, 2019). Projeta-se que as tendências de eventos extremos continuarão no futuro, com a frequência, intensidade e duração aumentada, principalmente em eventos de calor extremo em todas as regiões do mundo, acompanhado do aumento na frequência e intensidade das secas em várias regiões, e das chuvas intensas em muitas regiões do globo (REN et al., 2018).

O Brasil tem experimentado um aumento na frequência e intensidade das ondas de calor nos últimos anos, conforme indicado por estudos e análises climáticas, além das projeções climáticas que indicam as ondas de calor se tornarem mais frequentes e intensas no país nas próximas décadas, como resultado das mudanças climáticas (BITTENCOURT et al., 2016). Os resultados indicam um aumento no número de ondas de calor em Santa Catarina na última década (2010-2018) e essa tendência deve persistir até 2091-2100, conforme projeções do modelo climático do Hadley Centre. Nas capitais do sul do Brasil, espera-se que

essas ondas sejam mais intensas, duradouras e frequentes, com eventos extremos simultâneos nas três cidades (FAGUNDES, 2019).

Outro evento extremos associado a desastres são os vendavais, os quais, no Brasil, ocorrem principalmente nos estados da região sul (Rio Grande do Sul, Paraná e Santa Catarina respectivamente), o que representa cerca de 77% do total dos eventos acontecem nessa região, onde as ocorrências se concentram nos meses de setembro, outubro e novembro (UFSC/CEPED, 2013). De acordo com Fonseca e Ferentz (2020) os vendavais ocorrem principalmente na primavera e no verão, especialmente em setembro, outubro e novembro, nas mesorregiões Metropolitana de Curitiba, Norte Central, Oeste e Sudoeste. Esses eventos costumam resultar em grandes danos a patrimônio e perdas econômicas, além de que também são frequentemente acompanhados por granizo, alagamentos e tempestades de raios.

Em relação aos eventos extremos de granizo, devido o Brasil ser um país com extensão territorial muito grande e possuir diferentes regiões climáticas, acaba favorecendo a ocorrência de eventos extremos de granizo em diferentes partes do país, onde esse fenômeno é mais suscetível. As ocorrências de granizo são frequentes em áreas de clima tropical e/ou subtropical, pois geralmente ocorrem em ambientes com alta instabilidade atmosférica e amplitudes térmicas mais elevadas (BALICKI, 2022). Os eventos de granizo não são raros na região sul do Brasil, devido ao seu clima e relevo, levando os Estados do Rio Grande do Sul e Santa Catarina os que se destacam mais em relação ao registros desses eventos (BEREZUK, 2009).

Outro estudo relacionado a eventos extremos que tem despertado considerável interesse na comunidade científica, são as relacionadas com tempestades com descargas atmosféricas, uma vez que, por meio do monitoramento dos períodos com maior incidência de descargas elétricas, é possível emitir alertas sobre as características das tempestades, como intensidade, duração e severidade (SANTOS, 2017). Esses eventos podem variar em intensidade, duração e frequência, com alguns eventos sendo extremamente poderosos e destrutivos, os quais os alertas permitem que sejam tomadas medidas preventivas para minimizar os impactos causados por fenômenos climáticos severos.

De acordo com Barretto et al. (2021) o Brasil é o país com maior incidência de descargas atmosféricas no mundo, com uma média de 77,8 milhões registros por ano. Esses registros mostram que entre os anos 2000 e 2019, foram registrados 2.194 óbitos causados por raios no país, o que equivale a uma morte por raios a cada 50 no mundo. De acordo com o estudo global conduzido por Kaplan e Lau (2021) e baseado em dados provenientes da Rede Mundial de Localização de Relâmpagos, foi possível identificar um aumento no número de relâmpagos entre as regiões tropicais durante o período de 2012 a 2015, dentre outros resultados. No último ano, houve um aumento considerável de raios nas regiões Sul e em partes das regiões Sudeste e Centro-Oeste, o qual é atribuído ao fenômeno El Niño (BARRETTO et al., 2021).

Os raios não representam apenas riscos conhecidos para pessoas e propriedades, mas também desempenham um papel fundamental no sistema terrestre. Eles influenciam a composição química da atmosfera e são a principal causa de incêndios florestais de origem não antropogênica (COUTO; SALGADO, 2019). Os raios provenientes de descargas elétricas atmosféricas do tipo nuvem-solo são a principal fonte natural de ignição de incêndios florestais e contribuem significativamente para a área ardida em muitas regiões (GANTEAUME; SYPHARD, 2018).

Há configurações atmosféricas que aumentam a probabilidade de um raio iniciar um incêndio, como quando ocorre em uma trovada de base alta e uma camada de ar mais seca em níveis baixos favorece a evaporação da precipitação antes que ela alcance o solo (DOWDY; MILLS, 2012). Além disso, os raios são uma fonte significativa de radiação de alta energia que afeta a eletricidade atmosférica, como a propagação de ondas de rádio.

Os extremos climáticos e de tempo atmosférico, especialmente os de chuvas intensas, foco deste trabalho, impactam a sociedade de diferentes formas e a magnitude de tais impactos está condicionada à natureza do evento, às características físico-naturais do ambiente e à infraestrutura e planejamento da área afetada. Esta questão relaciona-se ao problema recorrente de transtornos em sítios urbanos e que afeta diversas cidades brasileiras, sobretudo aquelas com elevado

adensamento populacional e que sofreram grandes modificações em seus ambientes originais (OLIVA, 2019).

O conceito de evento extremo de chuva ou chuva intensa não é simples e não há uma única definição na literatura. Enquanto alguns autores se baseiam em limiares fixos (KONRAD, 1997, p. 59), outros levam em conta os percentuais de acumulados anuais ou sazonais e, ainda, em valores de percentis (GROISMAN et al., 2001, p. 232). Ademais, os valores de precipitação podem ser obtidos de uma única estação ou de várias estações, englobando uma área maior. Para este trabalho, será considerada como chuva intensa o que foi discutido em Prito et al. (2018, p. 615) onde eventos de chuva intensa são aqueles que apresentam grandes acumulados em um único dia, como também em um intervalo curto de apenas quinze minutos e que geraram danos materiais e transtornos à população (OLIVA, 2019).

Muitos desastres resultam de combinações de eventos extremos, chamados de eventos compostos, interativos, interconectados ou em cascata. Ebi et al. (2021) explica que eventos extremos compostos envolvem a interação de dois ou mais eventos no tempo e/ou espaço, tais como ondas consecutivas de calor ou a coincidência de um evento de calor extremo com uma seca, os quais podem colocar em risco a vida humana e há falta de compreensão dos riscos presentes e projetados, incluindo fatores sociais de vulnerabilidade. O estudo de extremos compostos é uma área de pesquisa em rápida evolução.

Para lidar com os eventos extremos de chuva, é necessário implementar medidas de prevenção e resposta, o que inclui investir no desenvolvimento e aprimoramento de sistemas de alertas, planejamento urbano que leve em conta a possibilidade de enchentes e deslizamentos de terra, construção de infraestrutura de drenagem e contenção de enchentes, e educação pública sobre os riscos e medidas de segurança (UNDRR, 2022). Compreender eventos extremos é essencial para avaliar sistemas de alerta, identificar suas características e antecedência necessária para emitir alertas confiáveis, e definir medidas de precaução e resposta adequadas.

### 3.4 SISTEMAS DE ALERTAS DE DESASTRES

Em consonância com a gestão dos riscos de desastres, os processos de informação, previsão, comunicação e educação têm prestado suporte às políticas preventivas de maneira que as pessoas convivam com o risco. Há uma tendência a promover e disseminar conhecimentos técnico-científicos que possibilitem compreender os fenômenos naturais e identificar áreas de risco, bem como propor ações de prevenção e resposta para reduzir os impactos de eventos extremos (SULAIMAN; ALEDO, 2016).

De acordo com *United Nations Office for Outer Space Affairs* (UNOOSA, 2020) é necessário haver a colaboração através de produtos de informação como monitoramento via satélite, e outras tecnologias disponíveis para gestão de desastres. A combinação desses recursos de observação do planeta realizado por diferentes agências, permite o desenvolvimento de novas tecnologias e experiência integrada para coordenar medidas para responder rapidamente a grandes desastres.

Diversos países consideram que os sistemas de alertas de desastres desenvolvidos ou ainda em estágio de produção, são ferramentas úteis para evitar as perdas humanas, prevenir danos econômicos e ambientais além de aumentar a resiliência de uma sociedade. Apesar do avanço tecnológico e do conhecimento científico, os principais desafios permanecem na previsão dos fenômenos em tempo hábil, a comunicação de informações sobre riscos à população e adoção de ações de resposta (COOLS et al., 2016).

#### 3.4.1 Função e objetivos

Como uma das formas de prevenção de risco a desastres é fundamental o desenvolvimento de sistemas de alerta para eventos extremos. Estes sistemas têm a função de dar publicidade à informações do andamento de uma possível ameaça a

população, como também quais são as medidas adequadas que as pessoas devem adotar para promover sua autoproteção de forma mais segura e que gere menos danos ou prejuízos (LUZ; FILGUEIRA, 2018).

De acordo com Basher (2006) o termo sistema de alerta é utilizado multidisciplinarmente, para representar o fornecimento de informações sobre uma condições de perigo iminente, com vistas a adotar medidas para reduzir os riscos envolvidos de maneira antecipada.

Atualmente, são reconhecidos diversos tipos de sistemas de alerta: geofísicos, biológicos, sócio-políticos, industriais, riscos para a saúde pessoal e muitos outros riscos relacionados. Sorensen (2000) reconhece que os sistemas de alertas são complexos devido ao envolvimento multidisciplinar do conhecimento e das instituições e públicos envolvidos. Geralmente envolvem os campos da ciência, governo, engenharia, iniciativa privada, tecnologia de informação, mídias televisivas digitais e a população.

Segundo Cools et al. (2016) na última década houve um aumento substancial no desenvolvimento e implementação de sistemas de alertas para desastres naturais. Dos quais tem sido constantemente afirmado como uma medida eficiente na redução do risco de desastres e principal ferramenta na comunicação de eventos meteorológicos extremos.

Dentro desse processo existem diversos tipos de dados, informações, conhecimento, especialistas, stakeholders, profissionais, políticos, e cidadãos envolvidos. O monitorando das ameaças e a tomada a decisão em relação a emissão dos alertas de potenciais riscos de desastres, normalmente são realizadas em salas de controle, operada por profissionais qualificados para analisar as variáveis ambientais, reconhecer as ameaças e vulnerabilidades, e disseminar os alertas como medida de preparação e resposta de emergência (HORITA, et al., 2018).

### 3.4.2 Elementos dos sistemas de alertas

A UNDRR (2019) caracteriza os sistemas de alertas de desastres como um sistema integrado de monitoramento de ameaças, previsão e avaliação de risco de desastres. Além de realizar a comunicação das informações e preparar as pessoas, comunidades, governos, empresas a adotarem medidas oportunas para reduzir os riscos de desastres na iminência de eventos deletérios. A figura 7 exemplifica como os sistemas de alertas são compostos.

Figura 7. Elementos chave que compõem os sistemas de alerta de desastres.



Fonte: UNISDR, 2006

Ainda assim, os sistemas de alerta estabelecem atividades além da compreensão dos riscos existentes como as de monitoramento e alerta. Quando se fala em monitoramento nos sistemas de alerta, os serviços meteorológicos são o que mais frequentemente vem à mente e essa infra estrutura fornece as previsões para a produção dos alertas (UNDP, 2018).

O monitoramento de potenciais ameaças é realizado por meio da coleta de dados e informações para identificar condições propícias para a instalação de iminentes riscos. Este monitoramento visa fundamentar a disseminação de alertas antecipados de possíveis ocorrência de desastres (MARCHEZINI et al., 2017).

Da mesma forma, os dados e informações quer sejam em relação aos aspectos físicos, quer sejam associados à meteorologia, são analisados para a caracterização dos alertas como acumulados de precipitação, descargas atmosféricas e temperatura do mar. Porém, é necessário também o acréscimo de aspectos de vulnerabilidade, os quais não são objeto de monitoramento por parte dos sistemas de alerta (KELMAN;GLANTZ, 2014).

Neste sentido, a UNDP (2018) define que o monitoramento é o ato de coletar informações em conjunto as variáveis relacionadas ao risco, como chuva ou ondas sísmicas, feito por meio de observações diretas. Entretanto, tais observações apresentam certa limitação devido ao ambiente caótico inerente à proximidade das ameaças meteorológicas e limitando também a adoção de ações de redução de risco.

O termo previsão é muitas vezes considerado como uma expressão qualitativa de probabilidade com o objetivo de determinar a responsabilidade ou culpa quando o evento crítico se instala. Isso se aplica claramente a desastres, o que remete a importância dos serviços de monitoramento nos sistemas de alerta (KELMAN;GLANTZ, 2014).

Segundo Basher (2006) os meteorologistas utilizam o termo *End to End* para os sistemas de alerta que realizam previsões e avisos mais notáveis e utilizáveis para a população em geral. Sistemas de alerta baseados no método *End-to-End* tem como objetivo avaliar e gerenciar as ameaças por meio de previsões como os perigos hidrometeorológicos, geológicos e eventos extremos, associados às mudanças climáticas e variabilidade climatológica (UNOOSA, 2020).


### **3.4.3 Modelos de Sistemas de Alertas Aplicados pelo Mundo**

Com a evolução dos efeitos ocasionados pelas mudanças climáticas, quer seja pela perturbação decorrente da ação humana ou pelo curso natural do clima, todas as regiões do globo apresentam danos e prejuízos, muitos deles oriundos de eventos extremos. Segundo o relatório do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021), apresenta de maneira detalhada as adversidades ocorridas e que estão para acontecer, em detrimento do aquecimento global e suas consequências, o aumento na frequência e na intensidade de eventos climáticos extremos nas mais variadas regiões do planeta.

Neste sentido, houve a implementação de sistemas de alerta em diversos países visando se adaptar a tais mudanças e tornar suas assentamentos humanos mais resilientes, por meio da disseminação de informações que permitam às pessoas preparar-se de maneira antecipada a eventos de tempestades, ondas de calor, inundações, secas e terremotos (ALASALI et al., 2021).

De acordo com Kumar et al. (2022) apenas menos da metade dos países do mundo está protegida por sistemas de alertas de desastres naturais. Em países em desenvolvimento e pequenos Estados insulares, onde os impactos das mudanças climáticas são mais contundentes, apenas um terço apresenta sistemas de alerta para multi ameaças. Tal deficiência na cobertura de sistemas de alertas resulta em taxas de mortalidade decorrente de desastres oito vezes maiores do que aqueles com sistemas de alertas mais robustos. A atual cobertura de sistemas de alertas pelo mundo pode ser graficamente expressa pela figura 8.

Figura 8. Levantamento geoespacial dos países que relatam ou possuem sistemas de alerta multi ameaças pela metodologia do Marco de Sendai.



Fonte: UNISDR, 2022

Neste sentido, devido às constantes ameaças enfrentadas por alguns países em detrimento às mudanças climáticas associado ao investimento econômico, científico e tecnológico desenvolvidos pelas nações, é possível apresentar alguns exemplos de sistemas de alertas de desastres robustos ou que apresentam resultados significativos na redução dos danos às pessoas e aos bens antes da chegada de perigos iminentes.

#### 3.4.3.1 Ásia

No ano de 2007, a Agência de Gerenciamento de Incêndios e Desastres do Japão (FDMA) lançou o J-Alert, um sistema de alerta que transmite informações de emergência instantâneas sobre ameaças como terremotos, tsunamis e mísseis balísticos por meio de sirenes, para que as pessoas possam responder imediatamente. Lkhamjav (2013) afirma que as autoridades, que antes contavam apenas com formas de baixa tecnologia para espalhar alertas, com esse sistema podem enviar alertas instantâneos por meio de sirenes de tsunamis iminentes, erupções vulcânicas ou outros tipos de desastres.

Neste mesmo período, o país também implementou de maneira conjunta o Earthquake Early Warning System (EEWS) que monitora os movimentos sísmicos ou a iminência deles e dispara alertas de terremoto segundos antes de um evento, permitindo que indivíduos e organizações adotem ações imediatas (KODERA et al., 2021). Esses alertas são disseminados por meio do J-Alert e do Emergency Alert Mail (EAM), outra tecnologia utilizada para informar a população sobre a ocorrência de desastres naturais.

Segundo o World Bank (2019) o EAM faz parte integrante do J-Alert e tem o objetivo de transmitir, de forma gratuita, os alertas de desastres aos celulares da população japonesa, emitidos por instituições responsáveis e governos municipais, informando simultaneamente a ocorrência de eventos desastres, avisos de evacuação e demais informações pertinentes. Por meio da tecnologia *Cell Broadcast*, as operadoras de telefonia móvel disseminam os alertas para determinadas áreas que de acordo com o monitoramento e previsão podem ser atingidas por tais ameaças.

Essas três tecnologias de comunicação e informação, integram e desenvolvem juntas, parte de um ecossistema de alerta maior no Japão, onde cada uma desempenha um papel único. Soluções tecnológicas como o J-Alert necessitam de informações e dados aprimoradas sobre eventos de desastres para que os operadores dos sistemas possam realizar o monitoramento, previsão e avaliação de risco adequadas.

Neste sentido, em uma visão mais ampla sobre os países asiáticos, iniciativas desenvolvidas pelas WMO e o World Bank desenvolveram ainda uma plataforma virtual compartilhada, para que haja a troca de dados, previsão do tempo e de possíveis inundações, o Central Asian Flood Early Warning System (WORLD BANK, 2021). Tal sistema tem o intuito de gerenciar melhor os riscos transfronteiriços representados pelos eventos meteorológicos, climáticos e hidrológicos.

### 3.4.3.2 Europa

No continente europeu, foram desenvolvidos alguns tipos de serviços, que de forma integrada, compõe os sistema de alerta dos países, com o objetivo de alertar a população vulnerável e demais partes interessadas sobre os riscos relacionados ao clima, eventos meteorológicos, geofísicos e emergências que possam ameaçar a vida das pessoas que habitam tal região. Tais serviços subsidiam os sistemas de alerta implementados na Europa, que realizam a detecção, análise, previsão de possíveis ameaças e disseminam os alertas à população, com vistas a auxiliar na tomada de decisão e implementação da resposta adequada (CLIMATE ADAPT, 2022).

Por exemplo, o Meteoalarm é o site oficial que disponibiliza informações de serviços meteorológicos para diversos países da Europa, onde fornece uma visão geral das condições do tempo e avisos meteorológicos excepcionais, destinado a qualquer pessoa que se encontre em algum dos países. Esse site disponibiliza seus dados para serem implementados nos sistemas de alertas europeus as informações disponibilizadas, as quais são apresentadas por meio de mapas com sinalização coroplética, indicando a previsão meteorológica anômala (CVASNIUC, 2020).

Vale destacar que em toda a Europa, cada país possui seu próprio serviço meteorológico, os quais inclui o monitoramento e observação. Conforme a *European Meteorological Services Network* (EUMETNET, 2019) na década de 90, foi reconhecido pelos países europeus a necessidade de estreitar os laços sobre esses serviços meteorológicos e o compartilhamento de dados observacionais sobre a Europa e o Atlântico Norte, o que levou 31 agências de serviços meteorológicos unirem seus esforços, com o objetivo de desenvolver o primeiro conjunto de programas regionalizado eficiente, em que não seria possível realizar por apenas um país, e também a criação da EUMETNET.

Dessa forma, os produtos derivados dos dados compartilhados entre esses serviços meteorológicos são disseminados por meio da *European Public Warning Service* - EU-Alert. O EU-Alert é um sistema de alerta baseado em tecnologia de

telefonia móvel, muito semelhante ao usado nos Estados Unidos, o qual utiliza o Cell Broadcast para informar a população sobre riscos relacionados a eventos extremos, terremotos e tsunamis, ciclones tropicais, vulcões, secas, inundações e incêndios florestais (ROSSI et al., 2018).

Segundo VIVIER et al. (2019), o Cell Broadcast envia mensagens de texto a aparelhos telefônicos móveis utilizando a localização do usuário, independente de cadastro ou de adesão ao serviço. As mensagens trazem em seus conteúdos informações de ocorrências de desastres e emergências para áreas específicas que podem ser atingidas ou possuem íntima relação com o evento. Países como Alemanha, Bélgica, Grécia, Espanha, Finlândia, Holanda, Suíça e República Tcheca utilizam essa tecnologia em seus sistemas de alertas nacionais.

#### 3.4.3.3 África

O continente africano o continente é assolado por diversos tipos de desastres de origem natural, entretanto, alguns tipos de desastres impactam de sobremaneira esse território, devido a sua vulnerabilidade a determinados tipos de ameaças e que muitas vezes acabam em perdas humanas. Segundo pesquisas da Statista Research Department (2022), a seca é a tipologia de desastre que ocorre com maior frequência e intensidade no continente africano e registra o maior índice de mortalidade, superior aos eventos de inundações e deslizamentos, principalmente no Chifre da África e África Oriental.

De acordo com o relatório de avaliação sobre os sistemas de alertas do United Nations Office for Disaster Risk Reduction (KUMAR et al., 2022), a África possui uma frágil cobertura de sistemas de alertas, o que atinge cerca de 40% de todo o seu território, além de ser ainda muito dependente de tecnologia e de estratégias de outros países. Muitos dos seus esforços em implantar sistemas de alertas são decorrentes de projetos, políticas e de iniciativas com o propósito de aprimorar tais aspectos atinentes à redução do risco de desastres.

Nos anos de 1995 a 2000, foram implementados no Quênia o Drought Preparedness Intervention and Recovery Programme, um projeto financiado por Holandeses e o World Bank com o objetivo de gerir adequadamente as terras áridas e propor medidas mitigatórias diante os eventos de seca no país por meio de coleta de dados de alertas, porém tal iniciativas foram limitadas acerca do período vigente de tal projeto (AKERKAR et al., 2020).

Na África Oriental, há o desenvolvimento de um sistema de alerta chamado High Impact Weather Lake system - HIGHWAY, que tem o intuito de alertar a população sobre eventos climáticos de alto impacto, como fortes ventos e ondas nas regiões próximas ao Lago Vitória, na Tanzânia, os quais causam diversos acidentes e mortes decorrentes da navegação, atingindo uma média de até 5000 mortes ano (WMO, 2021). Esse sistema articula as informações relativas à previsão e monitoramento de ameaças meteorológicas, fornecidas pelo Weather Climate and Information Services - WISER.

Outro sistema de alerta existente na África é o Global Agricultural Monitoring - GLAM, projeto de cooperação técnica com a *National Aeronautics and Space Administration* - NASA, United States Department of Agriculture - USDA que visa monitorar e prever possíveis precipitações acima da média que tenham potencial de impactar a agricultura na Etiópia, Iêmen, Somália, Quênia, Tanzânia, Uganda, Ruanda e Burundi. Tal sistema realiza a divulgação de informações de sensoriamento remoto com validação científica, produtos de previsão, além de ferramentas de análise de dados sobre a cultura e avaliação da produção (BECKER-RESHEF et al., 2010).

Outrossim, a África apresenta ainda o desenvolvimento do projeto *Climate Risk and Early Warning Systems* - CREWS, voltado para o Chifre da África, com objetivo de fortalecer a capacidade de entes nacionais e regionais para desenvolver e usufruir de produtos e serviços climáticos, meteorológicos e hidrológicos, bem como estimular a tomada de medidas adequadas diante ameaças relacionadas a estas naturezas (UNDRR, 2022). Esse projeto permitirá que os Serviços Nacionais de Meteorologia e Hidrologia disponham de uma melhor previsão do clima sazonal, por exemplo, antecipar em até 3 meses a ocorrência de secas, e subsidiar os

governos e as comunidades locais na tomada de decisão à adaptação, variabilidade e mudança do clima (KULESHOV et al., 2019).

#### 3.4.3.4 América do Norte

No intuito de reduzir os danos ocasionados pelos impactos de eventos de desastres como ciclones tropicais, inundações, tornados, secas, tempestades de inverno, granizo severo e vendavais e tsunamis, os Estados Unidos iniciaram no final da década de 1940, o desenvolvimento de sistema um sistema de alerta para informar a população sobre as ameaças que os ameaçavam.

Neste sentido, houve a construção de uma rede de observação meteorológica, os quais contava com o uso de radares de vigilância, a criação de centros regionais de previsão fluvial e método de comunicação de emergências e desastres. Tais iniciativas resultaram na criação do *National Response Framework*, que estabelece diretrizes de resposta a desastres domésticos, o *Incident Command System*, ferramenta empregada por diversas forças de segurança no gerenciamento de crises, incluindo o Brasil, e o *Emergency Alert System*, desenvolvido para projetado permitir a transmissão de alertas de emergência e mensagens ao público por meio de Broadcast, satélites, televisão aberta, rádio AM/FM e via satélite (KEENEY; BUAN; DIAMOND, 2012) .

De maneira sintética, a previsão e emissão de alertas relacionados a ameaças hidrometeorológicas e tsunamis, são realizados pelo *National Oceanic and Atmospheric Administration's National Weather Service*, em conjunto com outras instituições governamentais da esfera federal como o United States Geological Survey - USGS, United States Army Corps of Engineers e a Federal Emergency Management Agency - FEMA. Outras iniciativas complementam o sistema de alerta nacional desse país, como o ShakeAlert, que proporciona alertas de terremotos para os cidadãos da Costa Oeste (McBRIDE et al., 2020).

De acordo com a FEMA (2022), os produtos resultantes desse serviços e que constituem o sistema de alerta nacional são divulgados pela *Integrated Public Alert & Warning System - IPAWS*, o qual integra os serviços nos níveis Federal, Estadual, Tribal, Territorial e Local, e enviam alertas para suas comunidades por meio de uma variedade de canais de disseminação, principalmente como redes sociais, serviços de telefonia móvel, rádio e televisão, além de integrar tecnologias emergências, como órgão de segurança e sirenes em locais de estratégicos, para que aumente a probabilidade de uma determinada mensagem chegar às pessoas em risco.

De acordo com Keeney, Buan e Diamond (2012), apesar desses sistemas de alerta específicos não terem sido desenvolvidos para compor parte de um único sistema multi-ameaças, eles apresentam elementos fundamentadores em comum, o que contribui substancialmente para a redução dos riscos de desastres nos Estado Unidos e estão vinculados aos vários sistemas de resposta a emergências do país.

#### 3.4.3.5 América Latina e Caribe

A América latina juntamente com a região do Caribe apresenta uma grande vulnerabilidade às mudanças climáticas, principalmente no que tange às regiões costeiras, que devido a sua latitude e proximidade com os oceanos estão sujeitos a uma maior incidência de impactos climáticos que as demais regiões, entretanto, medidas de adaptação climática eficientes como são os sistemas de alertas, ainda são precários tanto nessa região quanto na África, principalmente a América do Sul (MARENGO et al., 2020).

Conforme as análises realizadas por Collymore (2016), os países que compõem o Caribe possuem um sistema de alerta relativamente desenvolvido, em que é possível realizar a previsão de alguns tipos de eventos de desastres, a exemplo os furacões, por meio de radares Doppler e análise de imagens de satélite de determinados locais mais suscetíveis a tal evento como Barbados, Belize,

Guiana, Trinidad, Guiana Francesa, Martinica, Guadalupe, República Dominicana e Jamaica.

Alguns países ainda dispõe de sistemas de alertas telemetria, a exemplo Cuba, que utiliza um sistema de alerta para rompimentos de barragens e galgamento, enquanto outros países ainda contam com um tipo de sistema de alerta comunitário, como a Jamaica, que possui registros históricos desse tipo de sistema desde a década de 1980 (Opadeyi 2004, Spence et. al 2004; PNUD 2008). Ambos os países, juntamente com Ilhas Virgens e Ilhas Cayman também apresentam uma rede de sismógrafos, disponibilizados pela *Institut de Physique du Globe de Paris*, espalhados por seus territórios, os quais provêm dados para o sistema de alerta desenvolvido pelo Centro de Pesquisas Sísmicas da *University of the West Indies* (SRC, 2016).

Ainda assim, na Colômbia, de acordo com o estabelecido na Guia para a Implementação de Sistemas de Alerta Temprana publicada pela *Unidad Nacional para la Gestión del Riesgo de Desastres - UNGRD* (2016), foi implementado um sistema de alertas no país, com o apoio das Nações Unidas e da Organização Mundial de Meteorologia, em que foram unidas as redes de monitoramento hidrometeorológico internacionais para emissão de alertas de diferentes fenômenos naturais desde os anos 60,t além de realizar intercâmbio de dados e interação com centros mundiais de processos de coleta de dados e comunicação (UNGRD, 2022).

De maneira similar, alguns países possuem sistemas de alerta multi-ameaças como o Brasil e Chile, onde o sistema integra todo o território do país e realiza o monitoramento, previsão e emissão de alertas de maneira direta ou por meio de órgão e instituições parceiras. O *Centro de alerta Temprana*, do Chile - CAT, atua como órgão diretor do sistema de alerta e realiza o monitoramento de ameaças de maneira ininterrupta, estabelece a coordenação necessária dos recursos disponíveis, de forma a mitigar o risco às diferentes ameaças e subsidiar de informações o Sistema de Prevenção e Resposta a Catástrofes (CHILE, 2022).


### 3.4.4 Cenário Brasileiro e Catarinense dos Sistema de Alerta

No Brasil, o Centro Nacional de Gerenciamento de Riscos e Desastres (CENAD) é responsável pela sistematização dos alertas hidrometeorológicos e de riscos de movimentos de massa. Também realiza a disseminação de boletins informativos sobre as possibilidades de eventos extremos (BRASIL, 2021).

O CENAD analisa e gerencia essas informações com o objetivo de assistir os estados e municípios do Brasil nas ações de preparação para desastres junto às comunidades mais vulneráveis. Este órgão é coordenado pela Secretaria Nacional de Proteção e Defesa Civil (SEDEC) e atua 24 horas por dia no monitoramento de possíveis desastres no país (HORITA et al., 2017).

Ao mesmo tempo, de acordo com Marchezini (2017), o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) é responsável a nível federal por realizar o monitoramento de desastres relacionados a enchurradas e deslizamentos, e ainda, realiza de forma compartilhada o monitoramento de ameaças por outras agências federais: como a Agência Nacional de Águas (ANA) em relação aos dados hidrológicos e o Serviço Geológico do Brasil (CPRM). A figura 9 exemplifica graficamente essa articulação a nível federal.

Figura 9. Funcionamento do sistema de alerta no Brasil.



Fonte: CEMADEN, 2021

A Política Nacional de Proteção e Defesa Civil (PNPDEC) prevê que as ações de proteção e defesa civil sejam integradas e contínuas, no monitoramento dos eventos meteorológicos, hidrológicos, geológicos, biológicos, nucleares, químicos e outros potencialmente causadores de desastres. Além de realizar a produção de alertas prévios sobre a possibilidade de ocorrência de desastres naturais. (BRASIL, 2012b).


A integração dessas ações representa a gestão colaborativa para a redução dos riscos de desastres no Brasil e define a composição do Sistema Nacional de Proteção e Defesa Civil (SINPDEC) com diferentes órgãos públicos federais, estaduais e municipais.

Entretanto, em Santa Catarina, a partir de janeiro de 2017, os alertas de desastres são comunicados por meio de serviço de mensagens curtas (SMS) pela Defesa Civil Estadual. Este projeto foi aderido por alguns estados nos anos de 2018 e 2019 como Espírito Santo, Sergipe, Mato Grosso do Sul, Goiás, Rio de Janeiro, São Paulo, Rio Grande do Sul, Paraná e Distrito Federal (BRASIL, 2018).

Os serviços de alerta por SMS informam sobre a incidência de fenômenos meteorológicos relacionados a inundações, deslizamentos de terra, granizo e tempestades de vento para os usuários deste serviço gratuito. O usuário realiza a adesão do serviço enviando uma mensagem de texto para o número 40199 para receber o SMS gratuitamente, informando o Código Postal do local de interesse (SAITO et al., 2019).

A Defesa Civil Estadual conta com o Centro Integrado de Gerenciamento de Riscos e Desastres do Estado (CIGERD), localizado na capital do Estado, Florianópolis. Neste local é realizado o monitoramento, previsão e disseminação dos alertas onde é possível visualizar, em tempo real, os níveis de pluviosidade em determinadas regiões, focos de incêndio, velocidade dos ventos, a umidade relativa do ar e também a temperatura média (VAZQUEZ, 2018). A figura 10 demonstra sucintamente o sistema de alerta em Santa Catarina.

Figura 10. Elementos do sistema de alerta de desastres em Santa Catarina.



Fonte: Defesa Civil Santa Catarina, 2020

O processo integrado dos dados e informações produzidas pelo CIGERD pode determinar o lançamento de um alerta. Profissionais de diversas áreas, como meteorologistas, hidrólogos, geotécnicos e militares realizam presencialmente a análise dos dados 24 horas por dia.

### 3.5 MONITORAMENTO HIDROMETEOROLÓGICO E CLIMÁTICO

A observação realizada sobre as ameaças meteorológicas e climáticas são de extrema importância para o desenvolvimento das previsões de possíveis impactos ao ser humano e ao meio ambiente, o que reflete substancialmente na redução do risco de desastres e na implementação de sistemas de alerta. Segundo as afirmações de Akerkar (2020) o eixo monitoramento corresponde ao cerne de qualquer tipo de sistema de alerta, pois é decorrente dessa etapa, que acontecem as previsões que subsidiam os alertas disseminados à população.

Em geral, alguns tipos de fenômenos meteorológicos ou climáticos são considerados ameaças, dependendo de variáveis como magnitude, local onde ocorre, vulnerabilidade e exposição, pois podem resultar em desastres vultosos, pois provocam danos humanos e ambientais e prejuízos de ordem econômica. Segundo o pensamento de Siddhartha (2017) devido ao fato do ser humano ser incapaz de evitar eventos de desastres deflagrados ou na iminência de ocorrer, é necessário adotar certas precauções para reduzir o risco, principalmente utilizando a atual, em que seja possível prever e estimar o impacto de tais desastres e seus respectivos danos e prejuízos.

Neste viés, o monitoramento hidrometeorológico ou do clima é essencial para entender os recursos que podem estar disponíveis ou em risco, com vistas a proteger as populações de ameaças e identificar mudanças nas condições ambientais ao longo do tempo (MORAES et al., 2020). De maneira sintética a atividade de monitoramento realizada em Santa Catarina pela Defesa Civil consiste em observar, identificar e coletar dados de variáveis relacionadas às ameaças, os quais devem ser sistematizados e tratados com o intuito de gerar e disseminar informações úteis ao adequado gerenciamento de ações de preparação e resposta aos desastres como também fornece estimativas antecipadas dos riscos potenciais aos quais comunidades, infraestruturas, serviços e o meio ambiente estão expostos (SOMAR, 2019).

### **3.5.1 Sistema de monitoramento e alerta de desastres em Santa Catarina**

Para realizar o monitoramento dos desastres naturais, independente de sua origem ou do país em que se é realizado, são utilizados um grande aparato de sistemas operacionais voltado a realizar a previsão, monitoramento e alerta das condições ambientais, suscetíveis ou favoráveis à ocorrência de desastres em determinados locais. É de suma importância o emprego de tais sistemas, tanto a nível local, quanto a níveis mais amplos pois, todos os sistemas devem ter o intuito


de fortalecer os conhecimentos dos níveis dos alertas e fomentar a articulação dos sistemas de alertas federal, estadual e municipal (BRASIL, 2021).

Em Santa Catarina o eixo de monitoramento, que compõe o sistema de alerta estadual, o *Nowcasting*, é realizado pela Defesa Civil de Santa Catarina por meio do Centro Integrado de Gerenciamento de Riscos e Desastres - CIGERD, o qual é coordenado pela Coordenadoria de Monitoramento e Alerta (CoMAI), em articulação com diversas entidades públicas e privadas das esferas estaduais, municipais e federais, e atua no setor de Planejamento, Pesquisas e Alertas do CIGERD. Esta coordenadoria está vinculada à Diretoria de Gestão de Riscos (DGRI), setor de execução das atividades-fim da Defesa Civil Estadual e tem como responsabilidade planejar, promover e articular com os demais setores a implantação e participação desses segmentos nas ações de gestão de riscos nos campos de prevenção, mitigação, preparação, monitoramento e alerta, manutenção e operação de equipamentos especiais, com foco na redução de riscos e preparação para o enfrentamento de desastres (SOMAR, 2019).

De acordo com a Defesa Civil do Estado (SANTA CATARINA A, 2019), as principais instituições colaboradoras e que compõem o sistema estadual de monitoramentos, são a Secretaria de Estado do Desenvolvimento Econômico Sustentável (SDE), a Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina SA. (Epagri), o Centro de Informática e Automação do Estado de Santa Catarina (CIASC), o Centro Nacional de Gerenciamento de Riscos e Desastres (CENAD), o Centro Nacional de Monitoramento e Alerta de Desastres (CEMADEN), a Agência Nacional de Águas (ANA), o Serviço Geológico do Brasil (CPRM), o Instituto Nacional de Pesquisas Espaciais (INPE), o Instituto Nacional de Meteorologia (INMET), a Universidade Federal do Estado de Santa Catarina (UFSC), o Instituto Federal de Santa Catarina (IFSC) e o Sistema Meteorológico do Paraná (Simepar) além de empresas privadas prestadoras de serviço como a Southern Marine Weather Services - SOMAR e Fractal Engenharia, as quais atualmente colaboram com a previsão de curtíssimo prazo e com a área de hidrologia junto à Defesa Civil.

De acordo com as suas competências legais estabelecidas a essa coordenadoria (SANTA CATARINA, 2019 B), o CoMAI visa minimizar danos e prejuízos, evitar perdas de vidas e promover uma sociedade catarinense mais segura e preparada para o enfrentamento de desastres, com a missão de ser referência mundial no monitoramento e alerta de desastres. Ainda institui como valores a essa coordenadoria a inovação, colaboração, assertividade, confiabilidade e serviço voltado para as pessoas, os quais são concretizados pela atual estrutura apresentada, ou seja, representado pelos setores de meteorologia, de hidrologia e de geoinformação (fig. 11).

Figura 11. Fluxograma do CoMAI.



Fonte: Defesa Civil Santa Catarina, 2019

No que se refere ao setor de meteorologia, existem algumas responsabilidades específicas desse setor, que são essenciais para que sejam realizadas as análises de risco e, decorrente dessa análise, a emissão de informações de risco à população. Esse setor é composto com uma equipe de 6 meteorologistas, que atuam de forma escalonada em turno de 6 horas, durante 24 horas por dia, onde realizam o monitoramento de eventuais ameaças utilizando o Sistema Informatizado de Proteção e Defesa Civil - SisDC, além de utilizar ferramentas tecnológicas avançadas com de imagens de satélite, modelagem como

a do *Weather Research and Forecasting* - WRF com assimilação, produtos de previsão disponibilizado pela plataforma do Sistema Integrado de Ferramentas de Análise e Previsão Hidrometeorológica de Santa Catarina - SIFAP e de outros órgãos relacionados ao monitoramento de ameaças, mediante alertas e avisos emitidos por tais instituições (DCSC D, 2019).


Da mesma forma, tal equipe subsidia informações necessárias para a definição dos critérios e limites para os níveis de normalidade, observação, atenção, alerta e emergência para as áreas de monitoramento do Estado em razão da ameaça existente, como também implementam operações e demandas das diversas agências que atuam no CIGERD e emitem previsões, avisos e alertas customizados. Apoia o planejamento para a expansão da rede estadual de monitoramento e alerta e provê orientação técnica para os elementos da Defesa Civil e, presta também o suporte aos projetos de pesquisa da Defesa Civil e demais demandas de instituições de ensino e pesquisa, além de promover e participar de treinamentos e simulados com o objetivo de manter as ações de gestão e resposta ao desastre (SANTA CATARINA A, 2019).

De acordo com o Ministério da Integração (BRASIL, 2021), as informações produzidas pelas agências de monitoramento sobre as possibilidades de desastres, em geral, podem ser apresentadas por meio do envio de documentos específicos, a exemplo dos boletins, avisos e alertas. No contexto catarinense, são elaborados relatórios hidrometeorológicos em diversos espaços de tempo, semanais, mensais, trimestrais, semestrais e anuais ou para períodos específicos dos avisos e alertas emitidos e dos principais eventos ocorridos. Tais relatórios e informes derivados contêm a estatística de assertividade dos avisos e dos alertas emitidos, como também informações sobre eventos adversos observados, tais como acumulados proeminentes, rajadas de ventos e temperatura registrados nas estações (DCSC D, 2019).

Conforme os Procedimentos Operacionais 025 e 026 da Defesa Civil de Santa Catarina (2019) o monitoramento desenvolve produtos de previsão meteorológica em 3 níveis, os quais podem ser definidos como previsões de curto prazo (nível 1), previsões de muito curto prazo (nível 2) e previsões de curtíssimo prazo (nível 3).

Esses níveis estabelecem os critérios para a emissão de avisos, alertas e os padrões de boletins relacionados com os níveis (1, 2 e 3) de operação e a integração de sistemas, definição de responsabilidades, regras e atividades operacionais (SOMAR, 2019), demonstrados pela figura 12.

Figura 12. Fluxograma do processo de monitoramento em Santa Catarina.



Fonte: Defesa Civil Santa Catarina, 2019

### 3.5.2 Boletins diários de monitoramento

O guia para elaboração de alertas do Governo Federal (BRASIL, 2021), apresenta a definição de boletins de monitoramento como instrumentos desenvolvidos para comunicação de informações de potenciais riscos relacionados com o estudo de dados e informações que apontem situação anormal em um determinado intervalo de tempo, ao qual está em análise. Tal instrumento possui enfoque exclusivo na variável de evento adverso, seja ele de origem meteorológica, hidrológica, geológica, e demais classificações de desastres.

Devido a emissão e envio de informações tanto às instituições quanto à população em geral, ser responsabilidade da Defesa Civil em Santa Catarina, mediante do CoMAI, além da produção de dados de inteligência e consciência

situacional, com vistas a execução e promoção de avaliações de riscos ambientais, as previsões hidrometeorológica no Estado e monitoramento externadas por meio de Boletins Diários de Monitoramento (DCSC D, 2019).

Esses boletins basicamente são relatórios diários onde são registrados os eventos proeminentes durante as atividades de monitoramento, bem como os avisos e alertas vigentes. São elaborados com base na previsão do tempo, clima ou sistemas hidrológicos atuantes ou que impactam na região e tem o objetivo de antecipar a ocorrência de ameaças, como chuvas intensas, tempestades, vendavais, granizo, inundações, alagamentos, estiagens, entre outros (SOMAR, 2019). Apesar desse instrumento ser um produto de previsão do tempo voltada para a Defesa Civil, também tem o intuito de informar à população e às autoridades relacionadas a Defesa Civil ou interessadas nas condições de tempo previstas para um espaço de tempo de até 5 dias e antecipar eventos meteorológicos com condições potencialmente perigosas (SANTA CATARINA A, 2019).

Relativo a sua operacionalidade, os boletins devem ser emitido sempre às 18h, de acordo com as diretrizes e procedimentos que versam sobre possíveis mobilizações de instituições, equipes de resposta, que variam em níveis de 0 a 3, em função da classe de dano da possível ameaça e define quais os órgãos devem ser mobilizados e quem coordena as ações (DCSC A, 2019). A exemplo, caso haja a definição de uma ameaça que enseje em um desastre classificado como nível de mobilização II, o boletim diário de monitoramento passa a ser emitido a cada 12 horas, ou seja, às 6h00min e às 18h00min. Já para desastres classificados como nível de mobilização III, os boletins são emitidos a cada 6 horas, sendo as 6h00min, às 12h00min, as 18h00min e as 00h00min (DCSC B, 2019).

Outrossim, tal instrumento apresenta 3 níveis de produtos de previsão, boletim de previsão nível 1, 2 e 3. Os boletins de previsão nível 1 proporcionam um prognóstico de curto prazo, tipicamente, com dois a cinco dias de antecedência, caracterizando uma previsão de escala sinótica (SOMAR, 2019). Análise dos mapas com padrões atmosféricos de escala sinótica que sabidamente favorecem a formação e influenciam a severidade das tempestades. A emissão desse tipo de previsão deverá ocorrer preferencialmente às 8h00min, salvo situações

extraordinárias como evolução de eventos de escala sinótica e mesoescala das condições meteorológicas (DCSC D, 2019).

Tal qual os boletins de previsão nível 1, o nível 2 se materializam em prognóstico de muito curto prazo, com até 12 horas de antecedência, elaborados pelos resultados apresentados pelo SIFAP, com a utilização do modelo WRF com assimilação, com a inserção de alguns produtos específicos para detecção de eventos extremos. Tais boletins devem ser emitidos diariamente, de preferência às 5h00min, 17h00min e 22h00min. Quando o status de criticidade apresentarem níveis amarelo e vermelho poderão ser emitidos boletins adicionais às 10h00min (SANTA CATARINA A, 2019).

Já os boletins de previsão nível 3, consistem em previsões consideradas de curtíssimo prazo considerado o *Nowcasting* propriamente dito, cujo horizonte máximo de previsão tipicamente não ultrapassa três horas. Conforme os conceitos disseminados por Organização Mundial de Meteorologia (WMO, 2019) o Nowcasting é a previsão do tempo relacionado a sistemas de mesoescala, em um espaço temporal curtíssimo, de 2 até seis horas, em que há uma extrapolação no tempo de parâmetros meteorológicos obtidos por meio de sensoriamento remoto e técnicas que levam em consideração uma possível evolução da massa de ar ou detalhes que não podem ser resolvidos por modelos numéricos de previsão do tempo que utilizam a parâmetros de previsão com prazos mais longos.

Os boletins deverão conter a estimativa de quantidade de precipitação, e condições de temperatura, vento e mar por região (Oeste, Meio Oeste, Planalto Sul, Planalto Norte, Litoral Sul, Litoral Norte, Grande Florianópolis Serrana e Grande Florianópolis Litorânea e Vale do Itajaí e áreas costeiras). Conforme o estado de criticidade, os boletins hidrometeorológicos podem configurar um aviso, uma atenção ou uma observação ou alertas moderados, altos ou muito altos (DCSC A, 2019).

### **3.5.3 Avisos e alertas hidrometeorológicos**

No que se refere à produção de avisos e alertas pela Defesa Civil de Santa Catarina, existe uma série de procedimentos operacionais necessários à realização de tais instrumentos. A equipe de meteorologistas e profissionais atuantes do CoMAI analisam e revisam boletins de previsão do tempo e avisos meteorológicos emitidos e publicados por órgãos e instituições de meteorologia oficiais e observam continuamente os modelos meteorológicos, dados de estações hidrometeorológicas, radares, satélite, descargas elétricas, e demais informações pertinentes (SANTA CATARINA A, 2019).

Paralelamente é realizado também o acompanhamento de informações divulgadas em mídia digital e TV e canais de comunicação da Defesa Civil e junto aos órgãos de meteorologia como CENAD e CEMADEN, com foco no recebimento de e-mail com avisos e alertas para realizar a emissão boletins de previsão de curto e muito curto prazo, ou seja, de 6 a 12 horas e de até 3 horas respectivamente, e caso seja identificada a necessidade da emissão de avisos ou alertas, inicia-se o procedimento (SANTA CATARINA B, 2019). Nesse ínterim, vale destacar que existem algumas diferenças no que se refere a aviso e alertas emitidos por órgãos, principalmente no caráter informativo e público alvo de tais instrumentos.

Os avisos são instrumentos que possuem o enfoque na análise técnica para prever algum tipo de situação anormal para um período futuro. As informações contidas nesses instrumentos estão relacionadas a eventos adversos causadores do risco, principalmente, aqueles relacionados a questões meteorológicas (BRASIL, 2021). De maneira sintética, o aviso pode ser considerado como uma notificação que tem por objetivo comunicar uma ameaça ou um risco potencial com seu grau de severidade, podendo ser definido como baixa, significativa e severa, com sua respectiva probabilidade, classificada em baixa, média e alta ou antecipação de 48, 24 e 12 horas (DCSC A, 2019).

O aviso é emitido quando um evento meteorológico e hidrológico está acontecendo, é iminente ou provável, com estado de criticidade alta. Um aviso

significa que as condições do tempo configuram uma ameaça à vida ou à propriedade. As pessoas no caminho de tempestades, por exemplo, precisam tomar ações de preparação e/ou proteção (DCSC B, 2019). A constituição de avisos e alertas hidrometeorológicos no CIGERD é iniciada a partir das previsões meteorológicas de nível 1 e 2, com horizontes de 12 a 72 horas, e abrange as atividades de monitoramento das condições do tempo, a geração e acompanhamento dos avisos e a transmissão destes aos órgãos de comunicação para difusão das informações (SANTA CATARINA A, 2019).

Já os alertas são instrumentos mais completos e detalhados conceitualmente, os quais são gerados principalmente pelas instituições de monitoramento e alerta que relatam informações sobre o evento adverso causador, a análise do impacto da previsão sobre suscetibilidade da área afetada e vulnerabilidade da população exposta (BRASIL, 2021). Considerando o conceito que a Defesa Civil para alertas, esse instrumento pode ser considerado uma espécie de sinal para advertir sobre a ameaça de algum perigo iminente emitido por meio de notificações padronizadas, os quais podem ser transmitidas via sistema, aplicativo Web para troca de mensagens, e-mail ou telefone, dependendo do seu estado de criticidade e probabilidade de ocorrência.

#### 3.5.3.1 Níveis de criticidade

Níveis de criticidade são condições, estados ou situações em que agentes de defesa civil, que seja técnicos federais, estaduais, municipais ou agentes comunitários, são notificados de uma possível ameaça que possa ensejar algum tipo de desastre (SOMAR, 2019). Tais estados podem ser acionados automaticamente com base no monitoramento em tempo real de estações hidrometeorológicas ou a partir de análises combinadas do monitoramento e previsão, a depender do tipo de ameaça em destaque, pois os critérios que deflagram os diferentes estados de

criticidade são específicos e as respectivas ações decorrentes devem ser previamente definidos nos planos de contingência (SANTA CATARINA A, 2019).

Por exemplo, os critérios para deflagrar avisos ou alertas de deslizamentos são diferentes daqueles utilizados para divulgar alertas de inundações, além de que os termos utilizados podem variar de acordo com a região ou instituição que estabelece tais níveis de criticidade. Algumas instituições utilizam por exemplo os estados de observação, atenção, alerta e alerta máximo (DCSC C, 20019), enquanto outras podem utilizar níveis de risco, como alerta de risco moderado, alto e muito alto (SOMAR,2019). Contudo, independente da nomenclatura adotada, o nível de criticidade determina quando a Defesa Civil, órgãos correlatos e equipes de resposta estarão em estado em prontidão ou iniciam de forma ordenada as operações de preparação e resposta.

Em se tratando de níveis de criticidade para avisos em Santa Catarina, se referem à probabilidade de um evento adverso ocorrer, o qual considera sua abrangência e potencialidade de causar danos (severidade), previsto a partir da análise de imagens de satélite e modelos numéricos (DCSC D, 2019). Particularmente em relação às ameaças hidrometeorológicas, ou seja, eventos que apresentem elevados volumes de precipitação e ventos de alta velocidade e as possíveis consequências em termos de danos como inundações, enxurradas, alagamentos, deslizamentos, vendavais, os níveis de criticidade estabelecidos para as notificações de avisos “Aviso de Observação - AMARELO”, “Aviso de Atenção - LARANJA” e “Aviso Especial - VERMELHO” ( DCSC B, 2019).

Ainda assim, níveis de criticidade dos avisos são elaborados a partir da matriz de severidade que concatena as análises de níveis de impactos esperados e da probabilidade/antecipação de tais impactos ocorrerem. Quanto maior é o nível de severidade e quanto mais provável ou quanto mais próximo do evento está para acontecer, maior será o nível de risco e consequentemente maior será o nível do aviso, conforme a seguinte matriz:

Tabela 2. Matriz de severidade dos avisos.

|                           |             |            |       |               |        |
|---------------------------|-------------|------------|-------|---------------|--------|
| Probabilidade/Antecipação | Alta (12h)  |            |       |               |        |
|                           | Média (24h) |            |       |               |        |
|                           | Baixa (48h) |            |       |               |        |
|                           |             | Mínima     | Baixa | Significativa | Severa |
|                           |             | Severidade |       |               |        |

Fonte: Defesa Civil Santa Catarina, 2019

A priori, os avisos de **Observação** (amarelo) são emitidos com 12 horas de antecedência quando a severidade é baixa e a probabilidade é alta e com 24 horas de antecedência quando a severidade é significativa e a probabilidade é média. Já quando o evento previsto é severo, o aviso é emitido com 48 horas de antecedência. No momento que os avisos apresentam o *status* de **Atenção** (laranja) são emitidos com 12 horas de antecedência, quando a severidade é significativa e a probabilidade é alta e com 24 horas de antecedência quando o evento é severo e a probabilidade é média. Por fim, são considerados **Especial** (vermelho) quando o evento é severo e a probabilidade é alta, emitidos com 12 horas de antecedência (DCSC B, 2019).

Tal qual os avisos, os alertas também são produzidos com base na matriz de severidade, em que os níveis de impactos esperados são relacionados com a probabilidade de impactos se concretizarem, em que considera quanto maior o nível de severidade e mais provável ou próximo do evento, maior o nível de risco e maior o nível do aviso será.

Tabela 3. Matriz de severidade de alertas.

|               |       |            |       |               |        |
|---------------|-------|------------|-------|---------------|--------|
| Probabilidade | Alta  |            |       |               |        |
|               | Média |            |       |               |        |
|               | Baixa |            |       |               |        |
|               |       | Mínima     | Baixa | Significativa | Severa |
|               |       | Severidade |       |               |        |

Fonte: Defesa Civil Santa Catarina, 2019

Em relação ao alerta, os níveis de referem-se à probabilidade de um evento ocorrer e causar danos, determinada a partir de análises combinadas do

monitoramento radares, imagens de satélite e modelos numéricos (SANTA CATARINA A , 2019). Os alertas **Moderados** (amarelo) são aqueles em que os valores de acumulados pluviométricos sejam moderados, nas últimas horas e previsão meteorológica de continuidade de chuvas com intensidade forte ou muito forte, indicando probabilidade moderada de ocorrência de danos relacionados à ocorrência de inundações, enxurradas e deslizamentos. Neste caso há demanda a intensificação das atividades de monitoramento e estado de prontidão para os órgãos locais de Defesa Civil.

Também os alertas considerados **Alto** (laranja) são os que apresentam valores de acumulados pluviométricos altos nas últimas horas e previsão meteorológica de continuidade de chuvas de intensidade forte ou muito forte, com potencial de causar vítimas e danos relacionados à ocorrência de inundações, enxurradas e deslizamentos (DCSC A, 2019). Além da demanda de intensificação das atividades de monitoramento, há também a verificação em campo das áreas de risco pelos órgãos locais de Defesa Civil e informar a população residente nas áreas em risco.

Enfim, os alertas **Muito Alto** (vermelho) possuem valores de acumulados pluviométricos excepcionais nas últimas horas, associados ou não acumulados de chuvas volumosas nos últimos dias, indicando probabilidade muito alta de deslizamentos generalizados e/ou inundações abruptas e inundação em bacias de resposta rápida com alta probabilidade de causar danos e resultar em vítimas (DCSC A, 2019). Neste caso há necessidade de verificação em campo das áreas de risco pelos órgãos locais de Defesa Civil, a deflagração dos Planos de Contingência e bem como deixar em prontidão a população residente nas áreas em risco.

#### **3.5.4 Limiares de alertas hidrometeorológicos**

A emissão dos avisos e alertas está diretamente associada à revisão dos limiares associados aos eventos extremos, principalmente os eventos

hidrometeorológicos do estado de Santa Catarina. De acordo com a *Southern Marine Weather Services* (2019) estes limiares geralmente, são apresentados de maneira não definitiva ou temporânea, uma vez que o conhecimento do risco adquirido pelas experiência dos elementos da equipe de monitoramento, histórico de desastres, estudos de suscetibilidade ao longo do monitoramento de desastres, fornecem subsídios para um aperfeiçoamento constante destes limiares específicos para determinado tipo de ameaça e região a ser afetada (SOMAR, 2019).

De acordo com os estudos de Mendes et al. (2015) para eventos hidrometeorológicos a definição dos limiares considerados críticos para o desencadeamento de eventos de desastres e que ensejam a necessidade de emissão de avisos e alertas, consideram o volume de água precipitada e o tempo de exposição, que é o principal agente deflagrador de tais eventos. Estudos apontam que cada região ou localidade possui um limiar específico que poderá desencadear diferentes tipos de eventos, como inundações, alagamentos, enxurradas e deslizamentos (TATIZANA et al., 1987; TOMINAGA et al., 2009; MOLINA et al., 2015; MENDES et al., 2015; KOBIYAMA et al., 2015; SANTOS et al., 2019).

Diante disso, é de fundamental importância que seja estabelecido normas técnicas baseada no conhecimento científico com vistas a obter a padronização e automação dos limiares de determinadas áreas ou localidades suscetíveis e vulneráveis a ameaças específicas para maximizar a eficiência das atividades de monitoramento e alerta, otimizar o tempo operacional e diminuir a margem de erros e a emissão de falsos alertas. De acordo com a SOMAR (2019) tais procedimentos só atingem o *status* de padronizado quando seus operadores possuem amplo conhecimento do que deve ser feito e como devem ser emitidos os avisos e alertas para cada tipo de localidade de Santa Catarina.

Para que esses limiares sejam estabelecidos, a Defesa Civil estadual utiliza o conhecimento de áreas suscetíveis e vulneráveis a eventos de desastres, considerando os aspectos de cada tipo de ameaça existente, por exemplo os acumulados de chuvas intensas dentro do período de 72 horas, e estabelece tal região como área de interesse. Conforme estabelecido nas normativas de gestão de risco de desastres no Estado (SANTA CATARINA A, 2019), as áreas de interesse

são definidas por um polígono no Sistema Integrado de Defesa Civil - SisDC com propriedades relacionadas à localização geográfica e às características de natureza e de nível do risco, em termos de probabilidade de ocorrência e magnitude de danos e classificação de impactos.

Em Santa Catarina, a Defesa Civil estabelece a classificação de impactos de desastres em relação a emissão de avisos e alertas em impacto **mínimo**, **baixo**, **significativo** e **severo** (DCSC B, 2019). São considerados impactos situações consideradas habituais, onde é identificado alguns alagamentos pontuais em ruas, estradas e em assentamentos precários, deslizamentos e quedas de blocos isolados em áreas de alta suscetibilidade. Nesta classificação as atividades do dia a dia não são interrompidas, ruas e rodovias ficam molhadas e as condições de tráfego se intensificam.

Já impactos baixos são aqueles eventos localizados, em que apresentam alagamentos e inundações localizados em ruas, estradas e assentamentos precários com interrupções localizadas e temporárias de alguns serviços essenciais aos municípios, como energia, abastecimento de água. Nestes impactos as estradas são as principais afetadas, mas ainda podem ser utilizadas. Também há o aumento do tempo de percursos, com a ocorrência de alguns acidentes com veículos devido a pista escorregadia, além de algumas pontes baixas podem ser interditadas por inundações, deslizamentos e quedas de blocos localizados (DCSC A, 2019).

Em contrapartida, quando um ou poucos municípios são afetados, em que haja tensão de curto prazo nos serviços de emergência, inundação de bairros e interrupção de serviços essenciais são classificados como impactos substanciais (DCSC D, 2019). Há a interrupção de tráfego em algumas rodovias principais devido à inundação, possíveis danos em estradas e pontes, danos em infra estrutura, propriedades e meios de subsistência. Também podem ocorrer deslizamentos e quedas de blocos que causem risco à vida em áreas com águas rápidas e profundas, algumas comunidades podem ficar temporariamente isoladas e os deslocamentos entre bairros são afetados.

Contudo, quando os danos são generalizados, muitos municípios são afetados pela tensão prolongada nos serviços de emergência, há inundações amplas em rodovias e bairros e ocorre a interrupção generalizada e prolongada de serviços essenciais, a classificação é de impactos severos (DCSC C, 2019). Nesta situação as rodovias principais e pontes são danificadas ou destruídas, além de grandes comunidades ficaram isoladas por períodos prolongados e diversas comunidades desalojadas. Os danos registrados em propriedades e edificações são generalizados e ocorrem a perda dos meios de subsistência.

### **3.6 USO DE MACHINE LEARNING NO CONTEXTO DE DESASTRES**

Na era atual, marcada por avanços tecnológicos rápidos e desafios ambientais crescentes, o uso de *machine learning* no contexto de gestão de desastres tornou-se um campo de interesse para pesquisadores, formuladores de políticas e praticantes. Os desastres ditos e classificados como naturais muitas vezes quando ocorrem, são inevitáveis, mas seus riscos podem ser mitigados por meio de várias estratégias. Uma dessas estratégias é a implementação de programas de redução de desastres, prática já adotada por diversos países desenvolvidos mas também por meio tecnologias de inteligência artificial, como *big data*, *Machine Learning* e *Deep Learning*, as quais podem ser utilizadas para prever e reduzir os riscos associados a desastres naturais pois facilitam tarefas de visualização, análise e previsão, contribuindo para uma gestão mais eficaz dos desastres (DRAKAKI et al., 2018). Deste modo, é pertinente explorar como as técnicas de *machine learning* podem ser empregadas para aprimorar a eficácia dos sistemas de alerta de desastres, especialmente em um cenário onde as mudanças climáticas aumentam a frequência e a intensidade de eventos extremos.

De acordo com Sun et al. (2020), o interesse em aplicar tecnologias como *machine learning* e inteligência artificial (IA) para prever e mitigar os impactos de desastres naturais não é apenas uma questão de avanço tecnológico, mas trata-se de uma necessidade urgente para aumentar a resiliência das comunidades e

melhorar as capacidades de resposta a emergências. Neste contexto, o *machine learning* oferece ferramentas poderosas capazes de analisar grandes volumes de dados com uma precisão e velocidade que métodos tradicionais não conseguem alcançar. Essas ferramentas podem identificar padrões complexos e fazer previsões precisas sobre a probabilidade de ocorrência de eventos adversos e seus potenciais impactos (RANIA; EMANUEL, 2020) .

### **3.6.1 Introdução à Modelagem com *Machine Learning***

Nos últimos anos, a utilização de modelos de *Machine Learning* (ML) tem transformado radicalmente a capacidade de prever e responder a desastres naturais. Esta tecnologia, que permite a análise e interpretação de grandes volumes de dados com precisão surpreendente, está no coração da transformação digital em muitos setores, incluindo a gestão de desastres (LINARDOS et al., 2022). No contexto dos alertas de desastres hidrometeorológicos, os modelos de ML oferecem um meio avançado para entender padrões complexos e dinâmicos que governam eventos climáticos extremos.

D.J. Lary et al. (2016) destaca que, em ML, é criado um conjunto de dados de treinamento abrangente para cobrir o máximo possível do espaço de parâmetros do sistema, e que um subconjunto desses dados é usado para validação independente. O aprendizado de máquina é ideal para problemas onde o conhecimento teórico é incompleto, mas há um número relevante de observações e dados disponíveis. Ou seja, de maneira simplificada, *Machine learning*, ou aprendizado de máquina, é uma forma de ensinar os computadores a fazerem previsões ou tomarem decisões com base em dados, onde se detém uma enorme quantidade de informações, como a temperatura, a quantidade de chuva, a velocidade do vento e outros dados coletados ao longo de vários anos. Com essa tecnologia, é possível ensinar um computador a usar esses dados para prever o clima futuro.

A utilização de modelos de ML na previsão e resposta a desastres naturais é uma área de crescente interesse e desenvolvimento no campo da gestão de desastres. Essa abordagem tecnológica oferece uma série de ferramentas poderosas que podem processar grandes conjuntos de dados meteorológicos e climáticos, identificando padrões e correlações que não são facilmente discerníveis através de métodos analíticos tradicionais (GFDRR, 2018). Os modelos de ML são particularmente úteis devido à sua capacidade de aprender continuamente e melhorar suas previsões com base em novos dados, o que é essencial em um campo onde as condições podem mudar rapidamente.

A aplicabilidade do *Machine Learning* neste campo é motivada pela necessidade de sistemas de alerta que não apenas reajam às condições em tempo real, mas também antecipem eventos futuros com suficiente antecedência para permitir ações preventivas eficazes. Segundo as avaliações realizadas nos estudos de D.J. Lary et al. (2016), os modelos de ML, mediante algoritmos como Redes Neurais (*Neural Networking* - NN), Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM) e Florestas de Decisões Aleatórias (*Random Forests*), são capazes de integrar e analisar dados de diversas fontes meteorológicas e geográficas, oferecendo previsões que são essenciais para a emissão de alertas precisos e confiáveis.

No contexto de ML associado a previsão meteorológica, os modelos, são como um passo a passo que o computador usa para fazer previsões, um conjunto de regras e fórmulas matemáticas que o computador cria após analisar muitos dados, os quais servem para fazer previsões ou tomar decisões baseadas em novos dados que ainda não foram vistos. A criação de um modelo começa com o treinamento, onde alimentamos o computador com muitos exemplos de dados históricos, como registros do tempo de muitos anos, e os resultados correspondentes, como se comporta a precipitação, a radiação vento e demais componentes meteorológicos (GUPTA et al., 2024). O computador analisa esses dados e encontra padrões, e com base nesses padrões, cria um conjunto de regras, o qual denominamos de modelo.

A relevância dos modelos de *Machine Learning* para pesquisa decorre da necessidade de abordar a lacuna existente dentro de cada contexto de pesquisa a que se tem interesse para solucionar questões com grande complexidade. Ao aplicar técnicas de ML, os modelos podem indicar a relação entre os alertas emitidos, as condições meteorológicas observadas e suas consequências, fornecendo assim fundamento para testar hipóteses que podem ser significativamente explicada por variáveis meteorológicas regionais e especificidades na emissão e recepção desses alertas (ABDULLAHI et al., 2018).

Este enfoque não só alinha os avanços tecnológicos na área de *data science* aplicada à meteorologia e gestão de desastres, mas também responde diretamente aos objetivos estratégicos definidos pela Organização Mundial de Meteorologia (MYLNE et al., 2021) e pelo Marco de Sendai para a Redução de Riscos de Desastres 2015-2030 (ONU, 2015). Estes objetivos enfatizam a importância de melhorar a capacidade de previsão e resposta a desastres naturais como uma medida essencial para mitigar os impactos humanos e econômicos adversos associados a esses eventos.

Assim como, existe a necessidade do uso de ML associado ao uso de abordagens interdisciplinares e inovadoras no estudo de desastres naturais, enfatizando a necessidade de integração entre tecnologia, conhecimento científico e práticas operacionais (AGUIAR; SILVA, 2022). Esta perspectiva é fundamental para o desenvolvimento de estratégias mais eficazes e proativas na gestão de riscos de desastres em Santa Catarina e além.

Os benefícios de implementar ML na previsão de desastres e na emissão de alertas são substanciais. Estes incluem a capacidade de processar e analisar volumes de dados muito além da capacidade humana, a habilidade de detectar automaticamente as mudanças nas condições climáticas que precedem os desastres, e a possibilidade de adaptar rapidamente os alertas com base em informações em tempo real. Tal capacidade resulta em alertas mais oportunos e precisos, o que é fundamental para a eficácia das medidas de preparação e resposta a desastres.

### 3.6.2 Desafios na Coleta de Dados para Modelagem

A coleta de dados é de extrema importância no processo de modelagem de *Machine Learning*, especialmente quando aplicada à previsão e gestão de desastres naturais. A qualidade, a abrangência e a precisão dos dados coletados influenciam diretamente a eficácia dos modelos preditivos, como também em tecnologias digitais, incluindo aplicativos móveis e sistemas de suporte à decisão baseados em dados, ainda estão em processo de implementação para melhorar a gestão de desastre (LEMIALE et al., 2020). Neste contexto, a coleta de dados envolve desafios eminentes que podem impactar tanto a construção quanto a aplicação do modelo de ML.

Primeiramente, a heterogeneidade dos dados meteorológicos e de desastres apresenta uma complexidade considerável, uma vez que os dados meteorológicos, como precipitação, temperatura, velocidade do vento e outros fatores, precisam ser coletados de múltiplas fontes, incluindo estações terrestres e satélites. Neste sentido, Mhlanga e Lall (2021) afirmam que muitas vezes esses dados variam em termos de resolução temporal e espacial, exigindo um processo de normalização e padronização para garantir que sejam comparáveis e compatíveis para análise.

Outro desafio é a integridade e a completude dos dados, os quais, em muitos casos, os registros de eventos de desastres podem ser incompletos ou imprecisos devido à dificuldade de coleta em situações de crise ou devido à falta de recursos para monitoramento contínuo (PACHAR et al., 2023). Tal fato é particularmente verdadeiro em regiões menos desenvolvidas ou em áreas remotas, onde a infraestrutura de monitoramento pode ser deficiente ou mesmo onde tal estrutura não tem o apoio integral dos entes governamentais responsáveis pela viabilidade desses dados (PUGAS, 2023). A falta de dados históricos detalhados e confiáveis pode limitar a capacidade do modelo de aprender efetivamente e de prever com precisão.

A temporalidade dos dados também é um desafio, pois a relevância das informações pode diminuir rapidamente, especialmente em contextos de rápido desenvolvimento de eventos hidrometeorológicos como tempestades, vendavais, enxurradas ou inundações. A capacidade de coletar e processar dados fidedignos, em tempo real, ou quase real, é essencial para a eficácia dos sistemas de alerta (VERMIGLIO et al., 2021). No entanto, isso exige tecnologias avançadas de processamento e análise de dados, além de uma infraestrutura robusta para suportar a coleta e a análise contínua (BLUM et al., 2014).

Além disso, a integração de diferentes tipos de dados, como dados meteorológicos com registros de danos ou respostas de emergência, impõe desafios de compatibilidade e interoperabilidade. Segundo Blum et al. (2014) tais fatores são questões centrais, pois diferentes fontes de dados frequentemente utilizam formatos variados para representar informações, ao passo que o alinhamento temporal e espacial é outro desafio significativo, pois frequentemente dados provenientes de diversas origens têm resoluções temporais e espaciais distintas.

Para que a análise resultante seja precisa e útil, é essencial alinhar essas diferentes resoluções temporais e espaciais adequadamente e a fusão de dados de diversas origens requer um alinhamento preciso em termos de formatos, escalas e referências temporais e espaciais. Inness e Dorling (2013) enfatizam que o primeiro passo para estudar a atmosfera e prever o tempo é fazer observações, levantar questões e tentar respondê-las.

Durante essas observações, coletam-se dados chamados variáveis, que são essenciais para realizar previsões do tempo e especificam que as principais variáveis meteorológicas para utilizar na modelagem preditiva são temperatura, vento, precipitação e pressão atmosférica, uma vez que a observação contínua dessas variáveis, juntamente com outras e a aplicação das leis da física, permite a realização de estudos para a predição do tempo.

Outro aspecto importante, é em relação à privacidade e a segurança dos dados, que são preocupações críticas, especialmente quando se trata de informações que podem ser sensíveis ou sujeitas a regulamentações legais. Voigt e

Von Dem Bussche (2017) comentam que ferramentas de *Deep Learning* são ideais para empregar em modelos que aprendem e fazem previsões a partir de grandes conjuntos de dados. No entanto, essa técnica pode ter problemas de segurança, como o ataque de inferência de associação, pois eventualmente permite que alguém consiga identificar se uma determinada informação estava presente no conjunto de dados usado para treinar o modelo de ML, o que pode comprometer a privacidade das informações. Dessa forma, é necessário garantir que os dados sejam coletados, armazenados e processados de maneira segura e em conformidade com as leis de proteção de dados é fundamental para a sustentabilidade de sistemas de alerta baseados em ML.

O desenvolvimento de estratégias eficazes para superar esses desafios na coleta de dados não apenas aprimora a acurácia dos modelos preditivos, mas também amplia as capacidades dos sistemas de alerta e para os tomadores de decisão na emissão dos alertas, para responder de maneira proativa. Tais estratégias incluem o investimento em tecnologias avançadas de coleta de dados, a colaboração entre diferentes agências e a capacitação contínua dos profissionais envolvidos (HORITA et al., 2017). Essas ações são fundamentais para assegurar que os modelos de *Machine Learning* possam operar eficientemente no dinâmico campo dos alertas de desastres, onde a rapidez e a precisão são vitais.

### **3.6.3 Modelagem e Seleção de Recursos**

O cerne da aplicação de *Machine Learning* na previsão de alertas de desastres reside na modelagem precisa dos dados coletados, o que envolve a seleção criteriosa de recursos que serão utilizados para treinar o modelo. Esta etapa é de suma importância, dado a qualidade e a relevância dos recursos selecionados diretamente influenciam a eficácia do sistema de alerta (PACHAR et al., 2023). Dessa forma, a seleção de recursos no contexto de alertas de desastres pode ser

materializada em um processo de identificação das variáveis meteorológicas e de danos que mais impactam a previsibilidade e a precisão dos alertas.

Este processo começa com uma análise exploratória detalhada dos dados, onde cada variável é examinada para entender sua contribuição individual e sua interação com outras variáveis no contexto de eventos extremos (GFDRR, 2018). Variáveis como precipitação, temperatura, velocidade do vento, e outros indicadores meteorológicos podem ser correlacionados com registros históricos de desastres para determinar padrões e tendências significativas (INNESS; DORLING, 2013).

Uma vez que as variáveis são pré-selecionadas por meio de análises estatísticas, técnicas avançadas de seleção de recursos, como análise de componentes principais (PCA) e métodos de eliminação recursiva de atributos, são aplicadas para refinar a lista de recursos. Segundo Hongyu et al. (2015) essa técnica é amplamente reconhecida por sua capacidade de reduzir a quantidade de dados, ou a "massa de dados", minimizando a perda de informação devido a redistribuição da variação observada nos eixos originais para criar um novo conjunto de eixos ortogonais, ou seja, que não apresentam correlação entre si. Estas técnicas auxiliam a eliminar redundâncias e a focar nos recursos que realmente contribuem para a capacidade preditiva do modelo em desenvolvimento.

O modelo de *Machine Learning*, então, deve ser treinado com estes recursos selecionados para avaliar sua eficácia. O treinamento é realizado utilizando conjuntos de dados que são representativos de condições variáveis, assegurando que o modelo possa generalizar bem em diferentes cenários meteorológicos e geográficos (SHI, 2014).

Durante este processo, é interessante realizar a validação cruzada, onde o modelo é testado repetidamente em diferentes subconjuntos dos dados para verificar sua estabilidade e confiabilidade. A validação cruzada é uma técnica para verificar sua estabilidade e confiabilidade, pois testa o modelo repetidamente em diferentes subconjuntos dos dados, possibilitando identificar problemas como *overfitting* e garantir que o modelo seja robusto (JAMES et al., 2021).

Do mesmo modo, a seleção de recursos não é um processo estático, considerando que o modelo requer revisões contínuas e ajustes à medida que novos dados são coletados e novas técnicas de análise se tornam disponíveis. À medida que mais dados são coletados ao longo do tempo, novos padrões podem emergir ou padrões antigos podem se alterar, de modo que pode fazer com que recursos anteriormente substanciais se tornem menos relevantes e vice-versa (KUHN; JOHNSON, 2013). Esses aspectos asseguram que o modelo desenvolvido evolua e se adapte às mudanças nos padrões climáticos e nas tecnologias de monitoramento.

#### **3.6.4 Preparação e Pré-processamento dos Dados**

No que se refere a preparação e o pré-processamento de dados, pode ser considerado como etapas imprescindíveis na modelagem preditiva, especialmente em contextos de aprendizado de máquina aplicados à preditividade de desastres naturais. De acordo com Brownlee (2020), esta etapa é fundamental para garantir a integridade do modelo, pois envolve a remoção ou correção de dados corrompidos ou imprecisos e tratar valores faltantes e eliminar *outliers* que podem distorcer significativamente os resultados do modelo. Seguindo a limpeza, a transformação de dados é realizada para adequar os dados às exigências específicas dos algoritmos de ML. Tal procedimento pode incluir a normalização e padronização dos dados, bem como transformações mais específicas, para ajustar a distribuição dos dados de maneira mais apropriada para análise.

Inicialmente, o conjunto de dados coletados de diversas fontes, requer pré-processamento envolvendo a remoção de entradas duplicadas, a correção de erros de digitação e a tratativa de valores ausentes. Corrigir erros de digitação é primordial para manter a integridade dos dados e garantir que as análises sejam realizadas com informações corretas, ao mesmo tempo que a tratativa de valores ausentes é necessária porque muitos algoritmos não podem processar dados

faltantes e requerem um conjunto de dados completo para funcionar adequadamente (KUHN; JOHNSON, 2013).

Após a limpeza inicial, os dados passam por um processo de transformação, onde variáveis como a precipitação acumulada, a velocidade máxima do vento durante rajadas e a radiação solar são calculadas para janelas temporais específicas. Wilks (2011) discute em seu livro uma variedade de técnicas estatísticas que são específicas para a análise de dados atmosféricos, inclusive métodos para transformar e manipular dados meteorológicos de modo a melhor capturar as características essenciais que precedem eventos de desastre, como inundações ou tempestades. Essas transformações são essenciais para capturar as características dinâmicas do clima que precedem os eventos de desastre

Além disso, O pré-processamento de dados, incluindo a categorização e codificação adequadas, é uma etapa necessária para a preparação de dados em modelos de *machine learning*. A categorização transforma dados brutos, muitas vezes textuais ou desorganizados, em formatos que são mais facilmente analisados por algoritmos de computador (KAUFMANN, 2011). Variáveis categóricas também necessitam ser codificadas usando técnicas como de codificação one-hot ou codificação de label, dependendo do modelo e da necessidade de preservação da ordem das categorias.

Conforme as explicações de Garcia et al. (2015), converte variáveis categóricas em uma forma que pode ser usada com algoritmos de *machine learning* que esperam entrada numérica. Na codificação *one-hot*, cada categoria é representada por uma coluna binária (0 ou 1), garantindo que não haja presunção de ordem entre as categorias enquanto a codificação de *label* atribui a cada categoria um valor inteiro único, o que pode ser útil para modelos que podem tirar proveito dessa ordenação para melhorar o desempenho.

Outra etapa significativa no pré-processamento é a integração de dados, onde informações de diferentes fontes são combinadas para formar um conjunto de dados coeso. Tal fato é particularmente desafiador quando se lida com dados que vêm de sistemas de monitoramento distintos, que podem ter diferentes granularidades

temporais e espaciais, devido a integração que pode permitir análises mais complexas e resultados mais profundos, proporcionando uma base sólida para o treinamento do modelo de *Machine Learning* (DONG; SRIVASTAVA, 2014).

Outrossim, a normalização dos dados é aplicada para garantir que o modelo não seja indevidamente influenciado por variáveis com escalas significativamente diferentes. Modelos de ML, especialmente aqueles baseados em algoritmos que calculam distâncias ou gradiente (como regressão linear, logística, SVM e redes neurais), podem ser indevidamente influenciados por variáveis que estão em escalas muito grandes em comparação com outras Mhlanga e Lall (2021). Sem normalização, uma variável com uma faixa de valores maior pode dominar o processo de aprendizagem, o que pode levar a modelos enviesados ou ineficazes.

Técnicas como a normalização min-max ou a padronização (remoção da média e escala pela variância) são comumente utilizadas para garantir que cada variável contribua de maneira equitativa para a aprendizagem do modelo. De acordo com James et al. (2021) a técnica de normalização min-max reescala os dados para um intervalo fixo, geralmente 0 a 1, por meio da subtração do valor mínimo do dado e dividindo pelo alcance (máximo - mínimo) dos dados, o que garante que todas as variáveis contribuam igualmente, independentemente de sua escala original. Já a padronização ou *Z-score*, remove a média e divide pela variância, resultando em dados com média zero e variância um, normalizando os dados, mas também os centra, o que pode ser especialmente útil para algoritmos que assumem uma distribuição normal dos dados de entrada (KUHN; JOHNSON, 2013).

Essas etapas de preparação e pré-processamento são essenciais para maximizar a precisão e a eficácia do modelo de previsão, não só melhoram a qualidade dos dados, mas também asseguram que o modelo seja treinado de forma robusta, capaz de generalizar bem quando exposto a novos dados durante situações reais de desastre. Este tratamento zeloso dos dados prepara o terreno para a modelagem efetiva e a aplicação prática dos resultados do modelo, visando melhorar seu potencial. A integridade e a precisão dos dados são, portanto, imperativas para o sucesso da modelagem preditiva em contextos tão críticos quanto os de gestão de desastres naturais.

### 3.6.5 Tipos de modelagem aplicado a questões Meteorológica e de Desastres

Nos últimos anos, a previsão meteorológica e a gestão de desastres têm se beneficiado significativamente das avançadas técnicas de *machine learning*, que são capazes de processar grandes volumes de dados e identificar padrões complexos que desafiam os métodos tradicionais (MONTELEONI et al., 2013). Entre as diversas técnicas utilizadas, as redes neurais artificiais (ANNs) se destacam pela capacidade de modelar relações complexas e não lineares entre entradas e saídas, sendo particularmente eficazes em cenários com grande volatilidade dos dados. As máquinas de vetores de suporte (SVMs) também são valorizadas por sua robustez em classificação e regressão, especialmente úteis para prever dias propensos a eventos climáticos extremos (LARY et al., 2016).

As árvores de decisão, apesar de mais simples e transparentes, muitas vezes podem superar outros métodos mais sofisticados, especialmente em contextos com ruídos ponderosos nos dados. São modelos bastante intuitivos e fáceis de interpretar, pois oferecem uma visão clara de como as decisões são tomadas, o que é valioso para compreender a lógica por trás das previsões (ALI-TALESKI et al., 2024). Da mesma forma, os métodos *ensemble*, como o *Random Forest*, representam uma evolução desses modelos ao combinar múltiplas árvores de decisão para aprimorar tanto a confiabilidade quanto a precisão das previsões (MEENAL et al., 2021). Diante disso, o *Random Forest*, especificamente, pode ser um método adequado para a avaliação da efetividade dos alertas de desastres por várias razões críticas.

Primeiramente, a robustez do *Random Forest* contra o *overfitting* é uma de suas características mais valiosas, pois ao invés de depender de uma única árvore de decisão, ele utiliza uma média de várias árvores para fazer previsões, o que melhora significativamente a generalização do modelo para novos dados (JAMES et al., 2016). Tal fato, pode ser de grande valia na previsão de eventos raros, como

desastres naturais, onde os modelos precisam ser capazes de performar bem em situações não encontradas durante a fase de treinamento.

Além disso, o *Random Forest* pode processar grandes quantidades de dados e numerosas variáveis de entrada sem exigir uma redução significativa da dimensionalidade, o que o torna com uma vantagem ao lidar com os complexos conjuntos de dados meteorológicos que incluem uma variedade de variáveis que influenciam os eventos climáticos. Ao contrário de uma única árvore de decisão, que pode facilmente se ajustar demais aos dados de treinamento (*overfitting*), o *Random Forest* constroi muitas árvores de decisão independentes e toma a média de suas previsões, onde cada árvore é treinada com uma amostra diferente dos dados (*bootstrap sampling*), e normalmente, em cada divisão, apenas um subconjunto aleatório de variáveis é considerado (BELYADI; HAGHIGHAT, 2021). Outra vantagem é a capacidade do modelo de fornecer *insights* sobre a importância das variáveis de entrada, permitindo aos cientistas identificar quais fatores são mais influentes na previsão de eventos de desastres (UMOH et al., 2022).

Esta flexibilidade é complementada pela capacidade do Random Forest de se adaptar a diferentes tipos de dados, seja para classificação ou regressão, o que permite prever tanto a categoria quanto a magnitude dos eventos. Tal modelo pode ser aplicado tanto para tarefas de classificação quanto de regressão, o que o torna extremamente versátil, por exemplo, em tarefas de classificação, ele pode prever categorias ou classes de dados enquanto em regressão, pode estimar valores contínuos ou magnitudes (UMOH et al., 2022) Essa capacidade o torna ideal para prever tanto a ocorrência quanto a intensidade de eventos, como no contexto de previsões meteorológicas. Adicionalmente, o desempenho do modelo em condições variáveis garante que ele permaneça robusto mesmo quando as condições meteorológicas mudam rapidamente e de forma imprevisível, uma ocorrência comum em climatologia (KUHN; JOHNSON, 2013).

Portanto, ao selecionar uma técnica de ML para prever eventos meteorológicos e avaliar a efetividade dos sistemas de alerta de desastres, o *Random Forest* se destaca como uma escolha excelente devido à sua robustez, eficácia e profundidade analítica. Estas características fazem dele uma potencial

ferramenta para aprimorar as estratégias de resposta a desastres, garantindo que as previsões sejam não apenas precisas, mas também práticas e aplicáveis em cenários reais de gestão de desastres.

### **3.6.6 Validação do modelo de Machine Learning**

A validação de um modelo em *machine learning* é um processo fundamental para garantir sua confiabilidade e eficácia antes de ser aplicado em situações reais. Para o uso de resolução de problemas via modelos preditivos, a validação assegura que o modelo não apenas se ajusta bem aos dados com os quais foi treinado, mas também generaliza corretamente para novos dados, uma característica essencial dada a diversidade e a imprevisibilidade de eventos aleatórios ou complexos (CZOCHER, 2018).

O processo de validação de um modelo de previsão de desastres começa com a divisão do conjunto de dados em conjuntos de treinamento e teste. Esta prática é padrão no desenvolvimento de modelos para evitar o *overfitting*, fenômeno onde um modelo se ajusta tão bem aos dados de treinamento que falha em fazer previsões precisas em dados novos ou não vistos anteriormente (JAMES et al., 2021). Normalmente, 70% do conjunto de dados é utilizado para treinamento e os restantes 30% são reservados para teste, embora essa proporção pode variar dependendo do volume e da variabilidade dos dados disponíveis (GUPTA et al., 2024).

Uma vez que o modelo é treinado no conjunto de treinamento, ele é testado usando o conjunto de testes. As métricas de desempenho, como a precisão, e revocação, o *F1-score*, e a área sob a curva ROC (*Receiver Operating Characteristic*), são calculadas para avaliar como o modelo se comporta em relação aos dados não vistos (POWERS, 2007). Essas métricas fornecem aspectos indispensáveis sobre a capacidade do modelo de capturar verdadeiros positivos

enquanto minimiza os falsos positivos e falsos negativos, fatores essenciais para sistemas de alerta onde cada previsão pode ter implicações significativas.

Goodfellow et al. (2016) comenta que as técnicas de validação cruzada são frequentemente empregadas para uma avaliação mais robusta uma vez que, o conjunto de dados é dividido em  $k$  partes (ou *folds*), e o modelo é treinado e testado  $k$  vezes, cada vez com um fold diferente como o conjunto de teste e os outros  $k-1$  *folds* combinados como o conjunto de treinamento. Esse tipo de validação ajuda a garantir que o modelo é testado em todas as partes do conjunto de dados, proporcionando uma medida de desempenho mais confiável.

Outro aspecto oportuno da validação de modelos preditivos e que podem ser também análogos para alertas de desastres é a análise de sensibilidade, que examina como as variações nos dados de entrada afetam as saídas do modelo, pois é particularmente relevante para modelos que dependem de dados meteorológicos, que são inerentemente ruidosos e incertos (CHASE et al., 2022). A análise de sensibilidade pode ajudar a identificar quais variáveis são mais influentes e quais configurações do modelo são mais sensíveis a mudanças nessas variáveis.

Cabe destacar também que a validação externa, onde o modelo é aplicado a dados completamente independentes e fora da amostra, pode ser conduzida, se disponível, para testar a aplicabilidade do modelo em diferentes contextos geográficos ou temporais. A validação externa testa a capacidade do modelo de generalizar para novos dados que não foram usados durante a fase de treinamento e validação e é possível identificar potenciais problemas de *overfitting* e *underfitting* que não seriam evidentes apenas com a validação interna (VAROQUAUX, et al., 2017). Desastres naturais podem ocorrer em muitos ambientes diferentes, cada um com suas próprias características únicas. A validação externa contribui para que o modelo possa lidar com essa diversidade.

Ao validar um modelo de *machine learning* para a previsão de desastres naturais e avaliação de alertas, é importante realizar um processo meticuloso e holístico de validação para garantir que o modelo é não apenas técnico e cientificamente sólido, mas também prático e confiável para uso em situações reais

de emergência. A integridade e a robustez do processo de validação refletem diretamente na confiança que os operadores de sistemas de alerta e os tomadores de decisão podem depositar nos alertas gerados pelo modelo.

### **3.6.7 Interpretação dos Dados do Modelo de predição**

Entender e interpretar corretamente os resultados de modelos de machine learning é fundamental para a pesquisa aplicada, especialmente em campos críticos como a previsão meteorológica e a avaliação de alertas de desastres. Molnar (2020) esclarece que é fundamental entender como um modelo de ML faz suas previsões para construir confiança entre os usuários finais, sejam eles cientistas, gestores de desastres ou formuladores de políticas. Modelos que são “caixas-pretas” podem ser relutantemente aceitos, especialmente se as consequências das decisões baseadas nestes modelos são significativas, tornando essa fase de interpretação como facilitador para que pesquisadores e decisores não apenas vejam o que o modelo prevê, mas também compreendam como essas previsões são feitas e quais fatores são mais influentes.

A capacidade de interpretar os resultados permite que os tomadores de decisão entendam as nuances das previsões e as considerem dentro do contexto mais amplo de outras informações e análises, devido ser necessário para garantir que as decisões tomadas sejam não apenas baseadas em dados, mas também contextualmente apropriadas (RIBEIRO et al., 2016). A interpretação dos resultados de um modelo de ML envolve uma série de técnicas e abordagens que ajudam a traduzir números e previsões complexas em insights compreensíveis e acionáveis. Essa etapa é especialmente crítica em áreas como meteorologia e gestão de desastres, onde as decisões baseadas em modelos podem ter implicações significativas para a segurança pública e a gestão de recursos.

Além dessa interpretação ajuda a construir transparência em torno dos modelos de ML, esclarecendo os processos de decisão para todos os envolvidos, é

fundamental para estabelecer confiança nas previsões do modelo, permitindo a identificação de possíveis vieses nos dados ou na modelagem, garantindo que o modelo não perpetue erros sistêmicos ou desigualdades e ajustando-o para refletir mais precisamente a complexidade dos fenômenos meteorológicos. Compreender quais variáveis são mais influentes para as previsões de um modelo pode auxiliar a identificar áreas prioritárias para intervenção, monitoramento ou pesquisa adicional (DOSHI-VELEZ; KIM, 2017). Em previsão meteorológica e gestão de desastres, isso pode incluir ajustar o foco em certos indicadores ambientais ou geográficos que o modelo identifica como pertinentes.

Explicar os dados de um modelo também é determinante para aprimorar e otimizar o modelo. A análise de quais variáveis são mais ou menos influentes pode levar a ajustes precisos na seleção e tratamento de variáveis. Se algumas variáveis têm pouco impacto nas previsões, reconsiderar sua inclusão pode reduzir a complexidade do modelo sem comprometer a performance, ou até mesmo melhorá-la ao reduzir o ruído (MOLNAR et al., 2020). Da mesma forma que a interpretação efetiva dos resultados também é vital para a comunicação das previsões aos tomadores de decisão (RIBEIRO et al., 2016). A capacidade de traduzir resultados técnicos em uma linguagem acessível melhora a disseminação de informações críticas durante eventos de desastres, facilitando a resposta das comunidades e autoridades.

Deste modo, o adequado entendimento sobre os dados de modelos de *machine learning* é fundamental não só para melhorar as respostas imediatas, mas também para informar o desenvolvimento da emissão de informações de desastres a longo prazo para a gestão de riscos de desastres, com vistas a formulação de estratégias para a aprimorar a análise dos riscos, aprimoramento da infraestrutura e resultados pragmáticos sobre preparação para desastres. Em suma, a interpretação dos dados não apenas melhora a eficácia dos modelos, mas também amplia significativamente seu impacto positivo na sociedade e na gestão de desastres.



## 4 METODOLOGIA

Para efeitos de enquadramento metodológico, esta pesquisa é caracterizada como uma **pesquisa aplicada**, pois visa gerar conhecimentos para aplicação prática direcionada à solução de problemas específicos relacionados à efetividade dos alertas de desastres hidrometeorológicos. De forma complementar, a pesquisa é predominantemente **descritiva**, pois descreve as características das variáveis que influenciam a efetividade dos alertas de desastres e a variabilidade de sua eficácia entre diferentes cidades do estado. Além de identificar padrões, associações ou relações entre os dados analisados, fornece uma compreensão aprofundada das dinâmicas e dos fatores que impactam os resultados dos alertas emitidos. O projeto tem o foco em contribuir para a melhoria das práticas e estratégias da Defesa Civil de Santa Catarina, utilizando o desenvolvimento e a aplicação de um modelo computacional baseado em *Machine Learning*.

A abordagem é **quanti qualitativa**, combinando a análise quantitativa, que inclui a coleta e análise de dados numéricos para testar a eficácia do modelo preditivo, com elementos qualitativos, que envolvem a interpretação das variáveis meteorológicas e dos processos de alerta. Esta abordagem combinada permite uma exploração mais completa do fenômeno estudado, aproveitando as vantagens de ambas as metodologias para uma análise mais robusta e detalhada. Os procedimentos técnicos adotados nesta pesquisa são de cunho **experimental**, uma vez que envolve a manipulação de variáveis independentes (dados meteorológicos, danos e de alertas) para observar o efeito sobre a variável dependente (efetividade dos alertas).


Para a avaliação da efetividade foi adotado o algoritmo de *Random Forest*, utilizando a ferramenta *Python*, o qual foi aplicado para simular e prever a efetividade com base nas entradas variadas associado de diferentes configurações do modelo, testados para determinar qual apresenta o melhor desempenho. Além disso, foi adotado para a validação do modelo, técnicas de validação cruzada e comparação com dados reais visando assegurar a confiabilidade dos resultados.

#### 4.1 COLETA DE DADOS

A coleta de dados para este estudo envolveu a integração de várias fontes de informações consideradas fundamentais para a criação das variáveis de entrada do modelo de previsão da efetividade dos alertas de desastres emitidos pela Defesa Civil de Santa Catarina.

Primeiramente, foram utilizados dados meteorológicos provenientes do Instituto Nacional de Meteorologia (INMET). As séries históricas de variáveis meteorológicas foram coletadas para 24 cidades, com dados de estações automáticas do INMET, do estado de Santa Catarina entre o período entre 2017 e 2022 (fig. 13). As variáveis incluíram precipitação (mm), radiação solar ( $\text{Kj/m}^2$ ), e velocidade do vento (m/s), tanto em termos de média quanto de rajadas.

Figura 13. Carta de SC, com as mesorregiões e distribuição da rede de estações automáticas do INMET.




Foram catalogados os alertas de fenômenos hidrometeorológicos emitidos no período entre 2017 a 2022. Utilizou-se o banco de dados da ANATEL, devido os alertas serem emitidos por meio da Interface de Divulgação de Alertas Públicos (IDAP) utilizado pela Defesa Civil para a comunicação dos alertas por SMS e TV. Os alertas foram classificados por origem dos desastres, conforme o Código Brasileiro de Desastres (COBRADE), para destacar a data de emissão do alerta e a localidade informada, permitindo uma análise precisa da correspondência entre os alertas emitidos e os eventos ocorridos.

Para complementar os dados, também foi utilizado o Produto de Previsões de Atuação de Zonas de Convergência do Atlântico Sul (ZCAS), desenvolvido por Rosa et al. (2020), um algoritmo automatizado de detecção da ZCAS. O algoritmo, baseado na análise de dados de radiação de onda longa emitida (OLR) de satélites, foi integrado ao modelo de avaliação de alertas de desastres.

Este algoritmo identifica episódios de ZCAS e sua contraparte oceânica (ZCASO) com alta precisão, fornecendo uma ferramenta para o monitoramento contínuo deste fenômeno. Essas previsões foram úteis para correlacionar os períodos de emissão de alertas com a presença de ZCAS, que são frequentemente associadas a eventos climáticos severos na região.

Os relatórios de danos registrados pelas Defesas Civas Municipais, disponíveis no Sistema Integrado de Informações sobre Desastres (S2ID) da Defesa Civil Nacional, foram outra fonte de dados. Esses relatórios detalham os danos causados por eventos hidrometeorológicos em edificações públicas e privadas, bem como outros danos associados e inseridos nesse sistema (fig. 14).

Figura 14. Tela inicial do sistema S2IS da Defesa Civil Nacional.



Fonte: Defesa Civil, 2024

Os registros de danos do S2iD foram destacados para identificar os danos associados a eventos hidrometeorológicos registrados nas datas dos alertas emitidos, bem como a incidência das ZCAS nesses períodos.

## 4.2 PREPARAÇÃO DOS DADOS

Os dados meteorológicos do INMET foram ajustados para criar variáveis consideradas determinantes. O modelo incorpora uma variedade de variáveis meteorológicas derivadas das originais. Essas variáveis não apenas refletem os aspectos diretos do clima, como precipitação e vento, mas também incluem transformações e combinações desses dados. No quadro abaixo é apresentado quais variáveis foram consideradas no modelo e suas descrições.

Quadro 2: Variáveis utilizadas pelo Modelo *Chronocast*.

| VARIÁVEIS                       | DESCRIÇÃO                                                 |
|---------------------------------|-----------------------------------------------------------|
| Precipitação Total, Horário(Mm) | Quantidade total de chuva em milímetros durante uma hora. |

| VARIÁVEIS                            | DESCRIÇÃO                                                          |
|--------------------------------------|--------------------------------------------------------------------|
| VENTO,<br>VELOCIDADE<br>HORARIA(m/s) | Velocidade média do vento em metros por segundo durante uma hora.  |
| VENTO, RAJADA<br>MAXIMA(m/s)         | Velocidade máxima do vento em rajadas durante uma hora.            |
| RADIACAO<br>GLOBAL(Kj/m²)            | Energia solar recebida por metro quadrado durante uma hora.        |
| Prec_Base                            | Valor de referência ou base para precipitação.                     |
| Prec_Base_72h                        | Valor de precipitação base acumulada em 72 horas                   |
| Prec                                 | Acumulado de precipitação em um período não detalhado diretamente. |
| Vento                                | Medida geral ou índice composto relacionado à velocidade do vento. |
| Rad                                  | Valor médio ou índice derivado de radiação solar.                  |
| VentoB                               | Possível medição de vento base ou média específica.                |
| Prec_24h                             | Precipitação acumulada nas últimas 24 horas.                       |
| Prec_48h                             | Precipitação acumulada nas últimas 48 horas.                       |
| Prec_72h                             | Precipitação acumulada nas últimas 72 horas.                       |
| Prec_96h                             | Precipitação acumulada nas últimas 96 horas.                       |
| Prec_120h                            | Precipitação acumulada nas últimas 120 horas.                      |
| Rad_24h                              | Radiação acumulada nas últimas 24 horas.                           |
| Rad_48h                              | Radiação acumulada nas últimas 48 horas.                           |
| Rad_72h                              | Radiação acumulada nas últimas 72 horas.                           |
| Rad_96h                              | Radiação acumulada nas últimas 96 horas.                           |
| Rad_120h                             | Radiação acumulada nas últimas 120 horas.                          |
| Vento_24h                            | Velocidade do vento acumulada nas últimas 24 horas.                |
| Vento_48h                            | Velocidade do vento acumulada nas últimas 48 horas.                |
| Vento_72h                            | Velocidade do vento acumulada nas últimas 72 horas.                |
| Vento_96h                            | Velocidade do vento acumulada nas últimas 96 horas.                |
| Vento_120h                           | Velocidade do vento acumulada nas últimas 120 horas.               |
| Dif_Prec48_24                        | Diferença na precipitação entre os períodos de 48 e 24 horas.      |

| VARIÁVEIS      | DESCRIÇÃO                                                            |
|----------------|----------------------------------------------------------------------|
| Dif_Prec72_48  | Diferença na precipitação entre os períodos de 72 e 48 horas.        |
| Dif_Prec96_72  | Diferença na precipitação entre os períodos de 96 e 72 horas.        |
| Dif_Rad48_24   | Diferença na radiação entre os períodos de 48-24 horas.              |
| Dif_Rad72_48   | Diferença na radiação entre os períodos de 72 e 48 horas.            |
| Dif_Rad96_72   | Diferença na radiação entre os períodos de 96 e 72 horas.            |
| Dif_Vento48_24 | Diferença na velocidade do vento entre os períodos de 48 e 24 horas. |
| Dif_Vento72_48 | Diferença na velocidade do vento entre os períodos de 72 e 48 horas. |
| Dif_Vento96_72 | Diferença na velocidade do vento entre os períodos de 96 e 72 horas. |
| Zcas           | Período de incidência de ZCAs na região.                             |
| Alertas        | Alertas emitidos para aquela região.                                 |

Fonte: Próprio autor, (2024)

Cada uma dessas variáveis contribui de maneira específica para a análise e previsão de eventos meteorológicos no contexto de Santa Catarina, fornecendo ao modelo as informações necessárias para avaliar os riscos associados a diferentes tipos de desastres hidrometeorológicos.

Não foi necessário adotar procedimento específico para tratar dados faltantes, os casos em que não havia qualquer dados disponíveis foram simplesmente descartados. Dessa forma, para avaliar a efetividade dos alertas, foram utilizados apenas dados completos e substanciais, o que significa que o modelo se baseou exclusivamente em registros reais de danos e dados de alertas completos, garantindo que as previsões fossem baseadas em informações verificáveis e consistentes.

Ao se referir a registro de danos e dados de alertas completos, significa que, tais registros contêm informações detalhadas que permitam a verificação do caso concreto emitido (alerta) e dano real auferido. Vale destacar que os danos representam a intensidade das perdas humanas, materiais ou ambientais ocorridas. Diferente dos prejuízos, que são as medidas de perdas relacionadas com o valor

econômico, social e patrimonial de um determinado bem, em função da emergência ou desastre.

#### 4.3 MODELAGEM ESTATÍSTICA

O modelo ***Chronocast*** foi utilizado para avaliar a efetividade dos alertas de desastres. Seu nome combina "*Chrono*", do grego Chronos, representando o aspecto temporal dos alertas, e "*Cast*", de *Forecast*, destacando sua função de avaliação/previsão do sistema *Nowcasting* da Defesa Civil de Santa Catarina. O *Chronocast* é projetado para melhorar a precisão e eficácia dos alertas hidrometeorológicos, combinando análise temporal com previsão de desastres.

Foi escolhido o algoritmo *Random Forest* para avaliar a efetividade dos alertas de desastres em Santa Catarina devido à sua robustez e eficácia no tratamento de *datasets* complexos e heterogêneos, característicos dos desastres hidrometeorológicos.

O *Random Forest* é um método de aprendizado *ensemble* que constroi múltiplas árvores de decisão durante o treinamento e produz a média das previsões de todas as árvores para obter resultados mais precisos e estáveis. Cada árvore é construída a partir de uma amostra aleatória do conjunto de dados de treinamento, usando o método de "*bootstrap sampling*" (BREIMAN, 2021).

Em cada divisão de uma árvore, um subconjunto aleatório de características é selecionado para aumentar a diversidade entre as árvores, ou seja, nem todas as variáveis são usadas em cada divisão, o que gera maior diversidade entre as árvores. Tal processo ajuda a evitar que as árvores se tornem muito semelhantes entre si e previne o problema de sobreajuste. Desta forma, reduz a variância sem aumentar o viés, o que é um problema comum em modelos de árvore de decisão únicos, que tendem a sobre ajustar os dados, pois a média das previsões de várias árvores reduz o impacto de flutuações aleatórias.

Em modelos de árvores de decisão única, é comum que ocorram *overfitting*. A seleção aleatória de variáveis reduz a variabilidade (ou variância) do modelo, foi desenhado sem aumentar o viés, o que significa que o modelo não perde a capacidade de capturar a verdadeira relação entre as variáveis, evitando o super ajuste e permite uma análise detalhada da importância das variáveis, pois permite identificar quais variáveis são mais úteis para prever um resultado específico, identificando quais fatores são mais influentes na previsão da efetividade dos alertas.

#### 4.4 PARAMETRIZAÇÃO DO MODELO

Para garantir a boa generalização do modelo ao conjunto de testes, foram realizados ajustes e calibrações nos parâmetros do *Random Forest*, otimizando sua acurácia e robustez.

Há diversos parâmetros necessários para a performance do modelo. O primeiro parâmetro, **estação**, alterna entre as 24 estações meteorológicas automáticas do INMET em 24 cidades distintas. Essas estações fornecem dados meteorológicos que alimentam o modelo, fornecendo os dados para cobertura espacial e temporal das condições climáticas nas cidades de Santa Catarina.

O parâmetro **n\_estimators** define o número de árvores de decisão que serão construídas no conjunto do modelo. Para este estudo, foram utilizados 100 estimadores com uma profundidade máxima de 6 e um mínimo de 6 amostras por divisão, balanceando adequadamente entre aprendizado profundo dos dados e prevenção de fit excessivo às peculiaridades do conjunto de treinamento.

O **test\_size** determina a proporção ou o número absoluto de amostras a serem incluídas no conjunto de teste. Foi configurado para 40% dos dados disponíveis para teste, enquanto os 60% restantes foram utilizados para treinar o modelo.

O modelo foi executado 25 vezes para cada cidade com diferentes *seeds* aleatórias para validar a consistência de seu desempenho. Esta abordagem de repetição ajuda a identificar qualquer variabilidade na performance do modelo devido a diferentes inicializações e particionamentos dos dados.

A profundidade máxima que cada árvore no conjunto de árvores é definida pelo parâmetro **max\_depth** e o número mínimo de amostras necessárias para dividir um nó (**min\_samples\_split**). Foi estabelecido um valor de 6 para este parâmetro. Limitar a profundidade das árvores ajudou a evitar o *overfitting*, onde o modelo se ajusta demasiadamente aos dados de treinamento e perde a capacidade de generalizar para novos dados.

O parâmetro **random\_state** controla a aleatoriedade do algoritmo, garantindo a reprodutibilidade dos resultados. Foi utilizado arbitrariamente o valor 42 como *seed*, mas poderia-se fixar qualquer outro valor. Este parâmetro foi necessário para que o fracionamento entre conjunto de testes e treinamento pudesse ser o mesmo em cada uma das 25 execuções para cada cidade. O quadro 3 apresenta um resumo detalhado dos parâmetros de entrada do modelo, suas descrições e os valores inseridos.

Quadro 3: Parâmetros utilizados como entrada no Modelo *Chronocast*.

| Parâmetro    | Descrição                                                                                                 | Valor inserido no modelo |
|--------------|-----------------------------------------------------------------------------------------------------------|--------------------------|
| estação      | Alterna entre as 24 estações meteorológicas automáticas INMET                                             |                          |
| n_estimators | Define o número de árvores de decisão que serão construídas no conjunto                                   | 100                      |
| test_size    | Esse parâmetro define a proporção ou o número absoluto de amostras a serem incluídas no conjunto de teste | 0,60                     |
| Execuções    |                                                                                                           | 25                       |
| max_depth    | Ele define a profundidade máxima que cada árvore no conjunto de árvores pode ter                          | 6                        |

| Parâmetro         | Descrição                                                                                                                                                                  | Valor inserido no modelo |
|-------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------|
| min_samples_split | determina o número mínimo de amostras que um nó deve ter para ser considerado para uma divisão. Se um nó possuir menos amostras do que este número, ele não será dividido. | 6                        |
| random_state      | controla a aleatoriedade do algoritmo na geração do conjunto de testes                                                                                                     | 42                       |

Para validar o modelo de forma adequada, foi utilizada a validação cruzada estratificada, dividindo o conjunto de dados em múltiplas sub amostras para treinamento e teste em diferentes iterações. Essa técnica assegurou uma avaliação mais confiável da robustez e eficiência do modelo, evitando que os resultados fossem influenciados por divisões específicas dos dados.

Para evitar o desequilíbrio de classes nos dados, foi aplicada a técnica **SMOTE** (*Synthetic Minority Over-sampling Technique*), que realiza a superamostragem da classe minoritária. Tal técnica foi essencial, pois certos eventos de desastres são menos frequentes. O uso do **SMOTE** ajudou a equilibrar as classes no treinamento, permitindo que o modelo aprendesse melhor a identificar e prever eventos críticos raros.

Durante o treinamento, foram realizados ajustes nos pesos das amostras, denominado como *sample\_weights*, para que o modelo desse maior importância aos eventos de classes minoritárias. Esse ajuste foi essencial para adequar o aprendizado do modelo às peculiaridades dos dados, onde eventos mais raros, como extremos de chuva por exemplo, porém de grande importância, como grandes desastres, necessitam ser reconhecidos e previstos com precisão.

A combinação das estratégias de seleção de parâmetros e validação visou aumentar a confiabilidade do modelo, garantindo que as recomendações resultantes sejam aplicáveis para melhorar as práticas de alerta de desastres hidrometeorológicos em Santa Catarina.

As métricas de avaliação do modelo são fundamentais para avaliar sua eficácia, indicando como ele executa previsões com dados reais. Neste trabalho, foram escolhidas as métricas clássicas para avaliar a precisão e a capacidade de generalização do modelo.

O **Erro Médio Absoluto (MAE)** foi utilizado para medir a média dos erros absolutos entre as previsões do modelo e os valores reais. Essa métrica é útil para manter os erros mínimos, sendo fácil de entender e interpretar. Um *MAE* baixo indica que o modelo faz previsões próximas dos valores verdadeiros, o que é crucial para avaliar a precisão dos alertas de desastres.

A métrica do **Coeficiente de Determinação ( $R^2$ )**, ou  **$R^2$  Score**, foi utilizada para medir a proporção da variância nos dados de alerta de desastres, explicada pelas variáveis independentes do modelo. Um  $R^2$  próximo de 1 indica que o modelo explica grande parte da variância, enquanto um valor próximo de 0 sugere baixa eficácia. No estudo, um  $R^2$  alto indicaria que o modelo é muito eficaz na previsão de alertas de desastres.

No modelo, foi utilizada a métrica do  **$R^2$  Score Arredondado para Valores de Teste**, aplicada ao  $R^2$  regular com valores de teste arredondados. Essa abordagem é elementar porque, na prática, a efetividade dos alertas de desastres pode depender da precisão dentro de uma margem útil para a tomada de decisões em situações de risco. O  **$R^2$  arredondado** mede como o modelo atende a essa necessidade de precisão prática.

Essas métricas foram calculadas repetidamente a partir de várias iterações do modelo buscando maior confiabilidade dos resultados. Cada iteração ajudou a robustecer o modelo, lidando melhor com a variabilidade dos dados de desastres. Avaliar o modelo em múltiplas métricas permitiu uma visão holística de seu desempenho, destacando sua precisão e capacidade de generalização.

#### 4.5 ANÁLISE DOS DADOS

#### **4.5.1 Análise das variáveis representativas**

A primeira etapa da análise focou em identificar quais variáveis utilizadas pelo modelo são mais representativas para a efetividade dos alertas em diferentes grupos de cidades. Utilizando o modelo com o algoritmo *Random Forest*, a importância de cada variável foi quantificada com base na sua contribuição para a acurácia das previsões do modelo.

Esse processo envolveu a análise de "*feature importance*" (BREIMAN, 2001), que destaca quais variáveis têm o maior impacto nas previsões do modelo. As variáveis mais importantes foram então analisadas para entender como influenciam os resultados dos alertas de desastres em cada grupo de cidades, permitindo uma compreensão detalhada das dinâmicas regionais específicas.

#### **4.5.2 Comparação de desempenho entre cidades**

Neste estágio, foi realizada uma comparação entre as cidades com desempenho mais alto e mais baixo em termos de efetividade dos alertas a partir do modelo. A análise envolveu a aplicação de método qualitativo para explorar as diferenças significativas no desempenho dos alertas. O objetivo foi identificar padrões ou fatores que poderiam explicar por que algumas cidades apresentaram melhores resultados do que outras, oferecendo *insights* para possíveis melhorias nas estratégias de alerta.

#### **4.5.3 Avaliação de variáveis críticas em cidades com alto desempenho**

Focando nas cidades que demonstraram os melhores resultados de efetividade, esta parte da análise procurou determinar quais variáveis se destacam na previsão de alertas efetivos. Esta análise aprofundada ajudou a discernir quais

fatores são preponderantes para o sucesso dos alertas nas condições mais favoráveis, proporcionando uma base para recomendações sobre como otimizar a emissão de alertas em outras regiões. Na figura 17 é apresentado o esquema gráfico da metodologia dessa pesquisa.

Figura 16. Esquema gráfico da metodologia aplicada à pesquisa.



Fonte: Próprio autor, 2024


## 5 RESULTADOS E DISCUSSÕES

Nesta seção são explorados os resultados gerados pelo modelo *Chronocast*, por sua performance na avaliação da efetividade dos alertas em diferentes cidades de Santa Catarina. Detalha-se a análise dos dados, incluindo uma discussão sobre o comportamento geral do modelo em termos de acertos e erros nas previsões do modelo e da Defesa Civil.

### 5.1 TEMPO COMPUTACIONAL DO MODELO

Observou-se baixa variação no tempo de processamento entre diferentes estações meteorológicas, refletindo não apenas as peculiaridades dos dados de cada localidade, mas também a complexidade inerente ao próprio modelo. No gráfico 16 são apresentados os resultados.

Figura 16: Média dos Tempos de Execução do Algoritmo com Intervalo de Confiança (IC) por Estação (99%).



Fonte: Próprio autor, 2024

Mesmo pequenas, as variações podem ser atribuídas a vários fatores fundamentais. Regiões com uma ampla variedade de fenômenos meteorológicos e dados coletados em intervalos mais curtos exigem mais tempo de processamento.

Além das características dos dados, as configurações do próprio modelo de *Random Forest*, incluindo o número de estimadores, a profundidade máxima das árvores e o número mínimo de amostras por divisão, também desempenham um papel significativo na determinação do tempo computacional. Enquanto essas configurações visam otimizar a precisão e a eficácia das previsões, paralelamente, aumentam o tempo de processamento.

Embora existam variações, a diferença máxima observada nos tempos de execução é inferior a um minuto. Essa pequena variação, não afeta a prontidão em relação a emissão dos alertas e consequentemente sua avaliação.

A capacidade do modelo de operar dentro de um intervalo de tempo tão curto, mesmo com um conjunto de dados limitado, é promissor. Tal fato implica que o modelo não só é capaz de realizar avaliações rápidas da efetividade dos alertas, mas também pode ser utilizado repetidamente em um curto período de tempo, facilitando o monitoramento contínuo e a reavaliação das condições meteorológicas conforme evoluem.

A questão do tempo computacional não é apenas técnica, mas também prática, pois impacta diretamente a eficácia dos sistemas de alerta, principalmente se essa avaliação for utilizada para validar a emissão do alerta como ferramenta que corrobora com o processo decisório da emissão. Em situações de emergência, onde minutos podem significar a diferença entre prevenção e desastre, a velocidade de processamento do modelo é essencial.

A capacidade de fornecer resultados rápidos não apenas aumenta a eficácia dos alertas emitidos, mas também oferece suporte crucial para as decisões estratégicas tomadas pelos operadores e meteorologistas da Defesa Civil de Santa Catarina. Nesse contexto, o modelo não é apenas uma ferramenta de verificação retrospectiva, mas um ativo proativo que contribui para a melhoria contínua das estratégias de prevenção e resposta a desastres.

Outrossim, a robustez do modelo é evidenciada pela consistência dos tempos de execução, com intervalos de confiança de 99% mostrando pouca dispersão através das diversas cidades analisadas. Em resumo, o modelo se mostrou eficiente para características apresentadas pelo Estado de Santa Catarina, a partir dos dados que foram disponibilizados e implementados.

## **5.2 RESULTADOS DE DESEMPENHO DO MODELO**

Avaliar o desempenho de um modelo é fundamental para determinar sua eficácia e confiabilidade na prática. Neste segmento, foi explorado o desempenho


geral do modelo, focando nos coeficientes de determinação ( $R^2$ ) obtidos tanto para o conjunto de testes quanto de treino.

Estas métricas são essenciais, pois oferecem uma percepção sobre a capacidade do modelo de capturar e replicar as complexidades dos fenômenos meteorológicos que está tentando prever. A análise dos  $R^2$  não só avalia como os resultados de efetividade dos alertas têm relação com os dados, como também a precisão das previsões do modelo em condições controladas, mas também serve como base para discussões sobre as necessidades, ou não, de ajustes ou melhorias.

Os valores de  $R^2$  obtidos pelo modelo, no que se refere a previsão de eventos com potenciais de geração de danos, os números apresentados pelo modelo estão predominantemente abaixo de zero, indicando que o modelo não está totalmente adequado para prever eventos futuros com precisão superior à média dos dados observados pela Defesa Civil (figura 17).

Este fenômeno pode ser atribuído a várias causas, como a insuficiência ou inadequação dos dados utilizados para treino, a complexidade dos fenômenos meteorológicos que não são totalmente capturados pelas variáveis disponíveis, ou ainda, a necessidade de ajustes nos parâmetros do modelo.

Figura 17 - Média de  $R^2$  de Teste com intervalo de confiança por cidade (99%).



A variação observada entre diferentes cidades é outro fator pertinente a ser destacado. Algumas cidades apresentam  $R^2$  próximos de 1, sugerem uma melhor capacidade de previsão, enquanto outras exibem valores significativamente mais baixos, indicando baixo desempenho.

Os intervalos de confiança de 99% associados a cada média de  $R^2$  de teste proporcionam uma melhor concepção sobre a estabilidade das previsões do modelo. Em geral, intervalos de confiança estreitos em torno de médias muito baixas reforçam a estabilidade das estimativas, no entanto, dado a quantidade de médias próximas de zero, ou mesmo negativas, confirmam a necessidade de melhorias no modelo.

A consistência dos intervalos, indicam que apesar de sua baixa eficácia geral por esta métrica em particular, fornece previsões estáveis, o que é um ponto de partida para avaliações dos alertas e investigações futuras, ou mesmo uma ferramenta de apoio em desenvolvimento para a tomada de decisão da emissão dos alertas.

A inclusão de um maior número de variáveis e dados pode ser o fator para o aprimoramento do modelo. Além disso, a compreensão das características específicas de cada região coberta pelas estações meteorológicas e a adaptação do modelo a essas particularidades são fundamentais.


Por outro lado, a média dos  $R^2$  de treino, referente a avaliação dos alertas emitidos, revela um cenário distinto em comparação aos apresentados pelo conjunto de testes. Com valores predominantemente altos, sendo a maioria acima de 0,8, a figura 18 indica que o modelo é eficiente em aprender e ajustar-se aos dados de treinamento. Esta eficácia na fase de treinamento sugere que o modelo é capaz de capturar as relações e padrões expressivos dos dados históricos.

A análise dos valores de  $R^2$  para treino também destaca uma variação entre as cidades, atribuída às características específicas de cada localidade, como posição geográfica, variabilidade climática e qualidade dos dados.

A estabilidade dos resultados indica que, pelos intervalos de confiança estreitos na maioria das cidades, é um aspecto positivo, pois demonstra que o modelo não sofre instabilidade durante o treinamento, conforme é explicitado no gráfico da figura 18.

No entanto, a discrepância entre os altos valores de  $R^2$  de treino e os baixos valores de  $R^2$  de teste sugere a ocorrência de *overfitting*. Considerando os ajustes aplicados ao modelo, esse fenômeno também pode ocorrer devido à quantidade de dados históricos disponíveis de determinadas cidades.

Figura 18 - Média de  $R^2$  de Treino com intervalo de confiança por cidade (99%).



Ao realizar a comparação entre as médias dos  $R^2$  de teste e de treino, é observado uma disparidade que auxilia para entender a eficácia do modelo. Enquanto o  $R^2$  de treino apresentou valores altos, indicando um bom ajuste do modelo aos dados históricos, o  $R^2$  de teste apresentou valores predominantemente baixos e, em muitos casos, negativos, sugerindo um possível déficit de capacidade para generalizar as previsões para novos dados.

Ao que se refere ao fenômeno de *overfitting*, é problemático em aplicações práticas como a avaliação ou mesmo a previsão de alertas de desastres naturais, onde a capacidade de generalizar dados históricos para condições futuras desconhecidas é essencial. Porém, o algoritmo *Random Forest*, tem como principal característica, a tendência de diminuir tal fenômeno, em modelos baseados nessa ferramenta.

Atualmente, não existe uma ferramenta específica que auxilie o operador ou meteorologista da Defesa Civil a decidir sobre a emissão de um alerta, muito menos com base no potencial de dano do evento adverso. A decisão de emitir ou não um alerta, apesar da padronização de muitos processos decisórios, ainda permeiam o fator personalístico. Em outras palavras, não existe uma ferramenta de suporte ao operador, responsável pela emissão dos alertas ou uma maneira estruturada de medir se os alertas emitidos realmente ajudaram a reduzir danos ou aumentar a segurança da população. Neste caso, o modelo pode contribuir, de alguma forma, a preencher essa lacuna no processo de comunicação e disseminação de alertas.

O *overfitting* é uma conclusão comum quando um modelo apresenta alta precisão nos dados de treino e baixo desempenho nos dados de teste, mas não é a única explicação possível. A discrepância também pode ser devido a uma série de outras características específicas do fenômeno modelado que não são completamente capturadas pelo modelo atual.

Anjomshoaa e Curry (2020) entendem que o sub-ajuste ocorre quando um modelo é demasiadamente simples para capturar as relações subjacentes nos dados, resultando em um desempenho inadequado tanto nos dados de treino quanto

nos de teste. Tal evidência é particularmente crítica em aplicações onde a precisão das previsões é vital para a tomada de decisões.

Entretanto, essa não é a realidade do processo de emissão de alertas em Santa Catarina, pois a decisão da emissão do alerta à população baseia-se, não apenas na modelagem, a proposta na pesquisa e a efetivamente implementada, mas no conhecimento do risco de determinadas regiões e localidades, relacionadas ao cálculo de risco proeminente a cada caso e o conhecimento do operador ou meteorologista da Defesa Civil.

No contexto da avaliação da efetividade dos alertas, onde a precisão das previsões é crítica, entender e incorporar a natureza estocástica dos dados e do fenômeno em estudo é vital. A capacidade do *Random Forest* de integrar essas incertezas e proporcionar uma análise probabilística dos resultados faz dele uma ferramenta útil.

Ainda que os valores de  $R^2$  sejam baixos, isso não necessariamente reflete uma falha do modelo, mas sim a complexidade e a dificuldade de prever com precisão eventos que são altamente dependentes de condições ambientais e meteorológicas variáveis.

De maneira geral, o modelo é aplicável em relação a suporte ao processo decisório de emissão do alerta e mais adequado a avaliação da efetividade dos alertas, no que se refere ao coeficiente de determinação. Contudo, não é descartado a necessidade do aprimoramento do modelo, para que possa generalizar além dos dados de treinamento como em várias outras áreas de foco para melhorias futuras.

Ao analisar os resultados do modelo em outros aspectos, indicam que, embora o desempenho nos dados de teste não tenha sido ideal, a performance nos dados de treino foi alta, o que indica que o modelo tem capacidade de aprender com os dados fornecidos, mas talvez não tenha sido exposto a um conjunto de dados suficientemente amplo ou diversificado para generalizar efetivamente suas previsões para novas condições.

Adicionalmente, a necessidade de ajustes no modelo é clara. As estratégias que envolvem o refinamento da configuração do modelo, a recalibração dos pesos das amostras, e a revisão das variáveis incluídas poderiam proporcionar melhorias substanciais nos coeficientes  $R^2$ .

### **5.3 IDENTIFICAÇÃO E CONTRIBUIÇÃO DAS VARIÁVEIS EM RELAÇÃO ÀS MESORREGIÕES E SUAS PERFORMANCES**

Para aprimorar a precisão e relevância dos alertas, é crucial compreender a contribuição das variáveis para cada mesorregião, considerando suas características geográficas e meteorológicas. Essa compreensão permite adaptar o modelo às condições locais, garantindo alertas mais precisos e pertinentes. Identificar variáveis críticas, como precipitação acumulada em áreas propensas a inundações, orienta a Defesa Civil na implementação de sistemas de monitoramento e otimiza recursos de emergência.

Essa análise também é essencial para validar e calibrar o modelo, ajustando-o para refletir as dinâmicas regionais, como calibrar parâmetros ou introduzir novas variáveis, conforme necessário. Compreender o impacto das variáveis em cada mesorregião também auxilia no desenvolvimento de estratégias de políticas públicas e práticas de planejamento, especialmente em áreas vulneráveis a eventos climáticos extremos.

Avaliar os resultados do modelo em diferentes regiões permite ajustes contínuos nos sistemas de alerta, otimizando a gestão de desastres e melhorando a eficácia dos alertas emitidos, integrando ciência com práticas operacionais.


#### **5.3.1 Variáveis da Grande Florianópolis**

Inicialmente, a variável **Prec\_120h**, que representa a precipitação acumulada em 120 horas, teve um grande destaque com cerca de 86,47% de contribuição para

a efetividade nas previsões, períodos prolongados de chuva refletidos nesta variável são decisivos para prever eventos que podem resultar em alertas de desastres (figura 19).

Sendo uma região costeira e com variações topográficas significativas, acumulações de chuva, as quais podem levar a diferentes tipos de desastres como enxurradas, enchentes e deslizamentos. A importância desta variável no modelo aponta que eventos de chuvas intensas são elementares para a previsão do modelo em relacionar os danos aos desastres.

Figura 19 - Média geral da representatividade das variáveis para a mesorregião da Grande Florianópolis.



Fonte: Próprio autor, 2024

Embora as variáveis **Dif\_Prec72\_48** e **Precipitação\_total, Horário(mm)** tenham apresentado um peso relativamente baixo na mesorregião da Grande Florianópolis, com cerca de 1,34% cada, elas ainda fornecem *insights* sobre o

comportamento do modelo nesta mesorregião e sua resposta a padrões meteorológicos identificados na análise da efetividade dos alertas.

**Dif\_Prec72\_48** tem como objetivo, detectar mudanças na precipitação entre 72 e 48 horas, essencial para alertas imediatos e pertinentes para a Grande Florianópolis de acordo com o modelo. Já a **Precipitação\_total, Horário(mm)** oferece uma visão pontual da intensidade das chuvas, sendo crucial para respostas rápidas a eventos súbitos, como chuvas intensas que podem causar enxurradas.

De acordo com estudos de Pereira e Junior (2022), nessa mesorregião a precipitação é bastante variada, devido às diferenças no relevo da região, como montanhas e vales. A quantidade e a distribuição da chuva mudaram de acordo com a estação do ano, sendo que no inverno e nas estações de transição (primavera e outono), a chuva varia mais entre o leste e o oeste, enquanto no verão, a variação foi maior entre o norte e o sul.

Os sistemas meteorológicos, como frentes frias e bloqueios atmosféricos, também influenciam as chuvas, causando períodos de muita ou pouca chuva. Eventos extremos de chuva podem acontecer em qualquer época do ano devido a esses padrões.

Por meio de dados estatísticos sobre a variabilidade da precipitação realizados nessa mesorregião, há uma tendência descendente no que se refere aos extremos de chuva, ou seja, nos dias em que mais ocorre a precipitação a recorrência das chuvas vem diminuindo, o que é mais acentuado nos períodos de inverno (Pugas et al., 2024).

Com menor intensidade, as variáveis **Rad\_72h (2,10%)** e **Rad\_96h (2,07%)**, que representam a radiação global em 72 e 96 horas respectivamente, mostram a importância das condições de radiação solar acumuladas em um determinado período para a região. O modelo sinaliza que as variações na radiação solar podem influenciar diretamente o impacto dos alertas.

Nesta região, no verão, o aquecimento do solo é mais intenso, o que provoca a ascensão de ar quente. Esse ar quente, ao subir, encontra camadas mais frias na

atmosfera, provocando a condensação do vapor de água e a formação de nuvens de tempestade, resultando em chuvas convectivas.

Dados da EPAGRI/CIRAM (2024) registraram volumes extremos na Grande Florianópolis, quebrando recordes históricos de precipitação na cidade de Florianópolis, Santo Amaro da Imperatriz e Águas Mornas. A inclusão dessas métricas implica que o modelo leva em conta variáveis tais como a radiação solar pré-evento que pode predispor a região a condições meteorológicas que favorecem a ocorrência de desastres.

Para a mesorregião da Grande Florianópolis, o modelo revelou uma leve discrepância entre sua precisão e a da Defesa Civil, com o modelo acertando 34,38% das vezes enquanto a Defesa Civil, 38,36%.

A limitação de dados de danos disponíveis para o modelo, que utilizou apenas séries temporais de duas cidades da mesorregião da Grande Florianópolis, as únicas disponíveis dentro das bases de dados utilizadas, e que resultaram em 44 registros para treino e 20 registros para teste, apresenta desafios significativos na representatividade e precisão das previsões.

Com dados de tão poucas localidades, o modelo pode resultar em previsões menos precisas para áreas não representadas. Essa falta de diversidade nos dados pode levar a um super ajuste às condições específicas das cidades com dados disponíveis, reduzindo a capacidade do modelo de generalizar e responder eficazmente a eventos em outras partes da mesorregião.

### **5.3.2 Variáveis do Norte Catarinense**


A região é afetada por diferentes sistemas meteorológicos, incluindo frentes frias, massas de ar polar e, ocasionalmente, remanescentes de ciclones tropicais. Esses sistemas podem provocar eventos de chuva intensa e tempestades severas. Devido à sua topografia e condições climáticas, a região é suscetível a diversos desastres naturais, como enchentes, deslizamentos de terra e inundações,

especialmente em áreas urbanas densamente povoadas e zonas rurais com relevo acidentado (MAGNAGO et al., 2021).

Diferente das variáveis mais representativas da mesorregião da Grande Florianópolis, a variável **Alertas** é particularmente significativa no modelo para a mesorregião Norte com mais de 50%, o que indica que os tais informações emitidas anteriormente, são extremamente pertinentes para prever a eficácia dos alertas futuros (figura 20). Tal fato indica que o modelo aprende com a frequência e as condições sob as quais os alertas anteriores foram emitidos, utilizando essa informação para avaliar a probabilidade e o impacto de eventos futuros.

Essa variável pode estar diretamente ligada à capacidade do modelo de aprender com o histórico de alertas, ajustando-se para prever com maior precisão os danos potenciais de eventos semelhantes no futuro para essa determinada região.

Figura 20 - Representatividade geral por variável para a mesorregião Norte.



Fonte: Próprio autor, 2024

A variável alerta engloba uma gama de produtos que frequentemente desafiam uma representação por meio de variáveis isoladas, pois sintetiza dados provenientes de instrumentos variados, focalizando especificamente em eventos adversos, sejam meteorológicos, hidrológicos e geológicos (BRASIL, 2021).

Já variável **Prec\_48h**, que corresponde a precipitação acumulada nas últimas 48 horas, surge como a segunda influente na mesorregião Norte com 5,95% e, apesar da grande diferença em termos de números em relação aos **Alertas**, pode-se dizer que há uma correlação substancial entre eventos recentes de precipitação e a eficácia dos alertas de desastres.

Tal fato também pode indicar que eventos de chuva intensa em períodos de 48 são críticos tanto para avaliar quanto para desencadear eventos de riscos associados a desastres na região, os quais ocorrem devido à influências de sistemas que podem favorecer inundações.

A diferença na radiação entre 96 e 72 horas, (**Dif\_Rad96\_72**), mostra-se em destaque (4,63%), sendo interpretado como um indicativo de mudanças significativas no padrão meteorológico que impactam a intensidade ou a probabilidade de eventos adversos. Essa variabilidade na radiação influencia diretamente a dinâmica atmosférica, afetando a formação de sistemas de precipitação.

Também há o fato de que a diferença na radiação não só afeta a temperatura e a umidade, mas também altera o gradiente de pressão na região, influenciando a direção e a velocidade dos ventos e intensidade de chuvas em determinados locais (LEITE et al., 2020). As diferenças de temperatura geradas pela radiação podem causar variações na pressão atmosférica.

Por exemplo, áreas mais aquecidas tendem a ter pressões mais baixas, enquanto áreas mais frias mantêm pressões mais altas. Essa diferença na pressão entre duas regiões próximas cria o chamado gradiente de pressão. Esse gradiente, pode influenciar a dinâmica e a velocidade dos ventos, já que o ar tende a se mover de regiões de alta pressão para regiões de baixa pressão, mesmo a níveis locais, dependendo da altitude em que a região se encontra, topografia e relevo. Esse fenômeno pode alterar a intensidade e a direção dos ventos, o que, em alguns casos, também pode afetar a distribuição e a intensidade das chuvas a nível local.

Já a variável **Dif\_Prec48\_24** que representa a diferença na precipitação entre 48 e 24 horas antes de um possível alerta, atuou como indicador relevante para o

modelo com 4,11%, ajudando a identificar tendências de aumento ou diminuição na intensidade das chuvas.

A **ZCAS** não é uma das variáveis com maior peso, mas seu papel ainda é considerável com quase 3%. A Zona de Convergência do Atlântico Sul é uma região de convergência de alta variabilidade convectiva, onde ocorrem encontros de massas de ar, e que, frequentemente, podem resultar em precipitação intensa e tempestades. Ao incluir a incidência desse fenômeno como uma variável no modelo, é possível identificar, verificar e dentro do possível, prever com maior precisão os períodos e locais onde esses fenômenos intensos, mesmo que de maneira indireta, podem incidir, melhorando assim a precisão dos alertas emitidos.

Estudos de Quadro (2012), Barcelos e Quadro (2019) e Escobar (2019) apontam que a ZCAS tem forte atuação próximo ao norte de Santa Catarina na formação de tempestades e linhas de instabilidade e nebulosidade ao longo da banda influenciando a precipitação na região.

A radiação acumulada ao longo de 96 horas, **Rad\_96h** (2,39%), oferece uma perspectiva de longo prazo sobre as condições de energia solar que afetam diretamente os padrões climáticos no norte de Santa Catarina, essencial para entender as dinâmicas de aquecimento e resfriamento que influenciam a meteorologia local.

De maneira geral, o modelo desenvolvido demonstrou um acerto de 74,19%, superando a eficácia dos alertas emitidos pela Defesa Civil, que acertou 40,17% das vezes em que os alertas coincidiram com danos registrados.

Esta diferença substancial pode ser atribuída à capacidade do modelo de integrar e aprender de um conjunto complexo de variáveis e de dados históricos para produzir previsões mais precisas. A variável Alertas provavelmente sintetiza dados de eventos anteriores, incluindo a severidade dos desastres e a resposta subsequente, o que ajuda a aprimorar as previsões do modelo.

Cabe destacar que, a disponibilidade limitada de séries temporais de dados reais e a utilização de dados de apenas cinco cidades na mesorregião Norte

Catarinense certamente influenciaram os resultados do modelo. Ainda assim, o fato de o modelo ter superado a Defesa Civil em termos de acurácia na previsão de alertas eficazes relacionados a danos sugere que, mesmo com dados limitados, a metodologia adotada é capaz de extrair insights dos dados disponíveis.


### 5.3.3 Variáveis do Sul Catarinense

A mesorregião Sul de Santa Catarina, como boa parte do Estado, é diversificada em suas características geográficas que inclui tanto planícies litorâneas quanto áreas montanhosas, particularmente ao longo da Serra Geral. Essa variedade topográfica tem um impacto considerável nos padrões climáticos locais, contribuindo para a formação de diferentes tipos de eventos climáticos.

A **Prec\_96h** destacou-se como a variável com maior representatividade nessa mesorregião (28,93%), sugerindo que as informações de precipitação acumulada ao longo de 96 horas são fundamentais para a modelagem dos alertas nesta região (figura 21).

Essa variável é elementar para entender eventos extremos. A exemplo, podemos fazer um paralelo com a enchente de 1974 em Tubarão, Santa Catarina, considerada o maior desastre já ocorrido em Santa Catarina, em termos de número de mortos.

Figura 21 - Representatividade geral por variável para a mesorregião Sul.



Fonte: Próprio autor, 2024

Observa-se que essa mesorregião apresenta, nos últimos 16 anos, uma tendência ascendente nos seus níveis pluviométricos em relação a extremos de chuva, principalmente em decorrência das chuvas orográficas às quais essa região apresenta maior tendência (PUGAS et al., 2024).

Ao entender que esse acúmulo de chuva é o fator de maior risco, na percepção do modelo, e que afeta diferentes áreas, os operadores da Defesa Civil e envolvidos podem identificar locais mais vulneráveis e trabalhar em melhorias na infraestrutura e planejamento das estratégias de gerenciamento de risco e disseminação mais efetivo de alertas associados a esses acúmulos.

Na sequência, a variável **ZCAS** aparece como destaque, embora menos influente que a **Prec\_96h**, com 16,22%. Apesar desse fenômeno, apresentar maior probabilidade lógica de influência mais ao norte de Santa Catarina, o modelo apresentou correlações pertinentes quando houve eventos de incidência desse fenômeno no Estado, emissão de alertas e danos nessa mesorregião. A consistência de seu impacto entre diferentes mesorregiões sugere que esta variável, associada a condições específicas ou condições relacionadas aos fatores de risco apresentados por essa mesorregião, podem ter um papel considerável em capturar nuances regionais que afetam a eficácia dos alertas.

Na mesorregião Sul de Santa Catarina, essa influência pode ser decisiva para antecipar períodos de precipitação significativa que podem levar a enchentes e outros desastres relacionados, uma vez que esse sistema é considerada por ser uma das principais causadoras de chuvas intensas e extensivas no Brasil, especialmente durante o verão (BACK et al., 2012).

A ZCAS pode ajudar a identificar padrões atmosféricos mais amplos que afetam a região e pode influenciar diretamente a eficácia dos alertas de desastres. Quando ativa, ela aumenta a probabilidade e a severidade de eventos meteorológicos adversos, tornando os alertas baseados em sua atividade mais críticos.

Outra variável detectada pelo modelo como pertinente para o Sul Catarinense foi a radiação entre 96 e 72 horas, demonstrada pela variável **Dif\_Rad96\_72** com 9,73%. Um aumento na radiação pode sugerir períodos de estabilidade atmosférica, enquanto a diminuição pode indicar a formação de sistemas de nuvens densas, que são precursores de precipitação ou tempestades.

Similar à diferença de radiação, a **Dif\_Prec72\_48** (8,69%) mostra a mudança na precipitação entre 72 e 48 horas, oferecendo uma percepção sobre como variações na quantidade de chuva podem impactar a previsão e eficácia dos alertas.

Já a **Rad\_96h** (4,11%) indica a radiação acumulada em 96 horas, refletindo a longa duração de períodos ensolarados ou nublados que podem influenciar a evolução das condições meteorológicas na região.

As variáveis **Prec** e **Precipitação Total Horário (mm)**, embora tenham obtido uma participação relativamente menor no modelo (2,45% e 2,40% respectivamente), ainda desempenham um papel influente na avaliação da efetividade dos alertas de desastres hidrometeorológicos de acordo com o modelo.

A variável **Prec**, que captura a precipitação acumulada ao longo de um período não especificado, é importante para monitorar tendências de longo prazo em chuvas e ajuda a entender a persistência e a severidade de padrões de precipitação.

Por outro lado, **Precipitação Total Horário (mm)** fornece uma visão instantânea da intensidade da chuva, essencial para a resposta imediata a mudanças rápidas no clima que exigem ajustes de alerta em tempo real.

Diferente de outras regiões onde períodos mais curtos de chuva ou mudanças rápidas na radiação são determinantes, para a mesorregião Sul, sugere que a acumulação de chuva ao longo de quatro dias é um indicador de destaque para a previsão de desastres.

O desempenho do modelo para a mesorregião Sul Catarinense apresentou resultados muito próximos aos da Defesa Civil, indicando uma precisão de 33,33% contra 35,02% da Defesa Civil. Este resultado é semelhante ao observado na Grande Florianópolis, onde o modelo também manteve sua eficácia próxima à da Defesa Civil.


#### **5.3.4 Variáveis do Oeste Catarinense**

A topografia da mesorregião Oeste, apresenta altitudes que podem variar significativamente em curtos intervalos de distância e que contribui para uma diversidade de microclimas.

Caracterizada principalmente por seu extenso planalto, que gradualmente desce em direção à Argentina, o Oeste Catarinense é definido por um clima mesotérmico úmido, com verões quentes e invernos frios, sendo ocasionalmente atingido por geadas e, mais raramente, neve. As chuvas são bem distribuídas ao longo do ano, mas com uma tendência a períodos mais úmidos durante o verão, quando a convecção é intensificada pela interação das massas de ar quente e úmido que avançam do norte, com as frentes frias que chegam do sul.

Dentre as variáveis apresentadas está a precipitação acumulada em 96 horas, **Prec\_96h** que é a mais significativa com 14,40%(figura 22). Essa variável é um indicador decisivo para a previsão de eventos que podem influenciar no impacto dos alertas de desastres para o oeste de Santa Catarina.

Figura 22 - Representatividade geral por variável para a mesorregião Oeste.



Fonte: Próprio autor, 2024

A radiação acumulada em 48 horas, (**Rad\_48h**) também é destacada com 12,52%, refletindo a importância das condições de radiação solar que podem influenciar a dinâmica atmosférica e os padrões de precipitação.

Em um cenário onde há radiação solar significativa dentro desse período anterior, há uma maior probabilidade de que haja suficiente umidade e calor para

sustentar sistemas convectivos, como tempestades severas e até supercélulas, que são mais propensas a causar sérios danos.

Grandes sistemas convectivos associados a nuvens Cumulonimbus (Cb), conhecidas por sua capacidade de crescimento vertical e formação de tempestades severas geralmente caracterizados pela sua forma aproximadamente circular e pelo rápido desenvolvimento, que normalmente ocorre em um período de 6 a 12 horas (LYRA; FREITAS, 2020).

A precipitação em 48 horas, **Prec\_48h** (8,11%), semelhante à precipitação em 96 horas, a indica a importância de considerar tanto intervalos longos quanto períodos mais curtos de chuva intensa, que são decisivas para prever e responder a possíveis desastres de maneira oportuna no Oeste de Santa Catarina.

A variável **Alertas**, que está relacionada à quantidade ou à gravidade dos alertas emitidos anteriormente, aparece como uma influência significativa com 7,87%, sugerindo que o histórico de alertas pode ser um indicador positivo para ajustar e calibrar o modelo em termos de resposta a eventos futuros.

Outra variável expressiva para o oeste de Santa Catarina foi a variável **Dif\_Prec72\_48** (6,79%) e **Dif\_Prec48\_24** (5,87%), que indica a diferença na precipitação entre 72 e 48 horas e 48 e 24 horas respectivamente, apontando para a importância de mudanças rápidas na precipitação.

A presença significativa da variável **ZCAS** como influente na mesorregião Oeste com 5,35%, oferece uma perspectiva interessante sobre os padrões meteorológicos que afetam esta região. Sua influência marcante no modelo sugere que os períodos durante os quais essa zona está ativa podem estar fortemente associados a eventos de precipitação intensa na região Oeste de Santa Catarina, que frequentemente resultam em inundações e outros desastres hidrometeorológicos.

A Zona de Convergência do Atlântico Sul é um dos principais sistemas meteorológicos que causam chuvas intensas nas regiões Centro-Oeste e Sudeste do Brasil e quando esse sistema se desloca mais ao sul, pode afetar também os

estados do Paraná e Santa Catarina (VERDAN; SILVA, 2022). Esse deslocamento inclui a mesorregião Oeste de Santa Catarina, impactando significativamente as condições climáticas dessas áreas.


Da mesma forma que a variável anterior, praticamente alcançando o mesmo grau de importância nessa mesorregião, a **Rad\_96** também apresentou significância ao modelo com 5,33%. Variáveis como **Dif\_Rad72\_48**, **Prec\_72** alcançaram índices entre 4,19% a 3,81%. As demais variáveis nessa mesorregião obtiveram índices menores que 2,4%. A precisão de 41,34% do modelo na previsão de eventos de desastres com base nos registros de danos é notável, especialmente ao superar a eficácia da Defesa Civil, que registrou 29,80%.

### 5.3.5 Variáveis da Mesorregião Serrana

A Mesorregião Serrana está localizada no centro-leste de Santa Catarina e é composta por duas microrregiões, a de Curitibanos, com 12 municípios como Curitibanos, Campos Novos e Ponte Alta, e a Campos de Lages, com 18 municípios como Lages, São Joaquim e Urubici. A região é caracterizada por um relevo montanhoso, com muitas áreas situadas acima de 800 metros e altitudes que chegam a 1.820 metros no Planalto Serrano, consequentemente faz com que seja uma das regiões com maior ocorrência de neve no Brasil durante o inverno (SANTA CATARINA, 2016).

A variável **Alertas** foi a mais predominante na mesorregião Serrana de Santa Catarina com mais de 66% (figura 23). Pode indicar que condições meteorológicas que previamente desencadearam alertas tendem a se repetir, e que o modelo pode estar se adaptando eficazmente para avaliar priorizando o sistemas de alertas, aprendendo com eventos passados para melhorar a precisão das previsões e alertas subsequentes.

Figura 23 - Representatividade geral por variável para a mesorregião Serrana.



Fonte: Próprio autor, 2024

A Prec\_120h, que mede a precipitação acumulada em 120 horas, é uma variável significativa no modelo para a mesorregião Serrana, embora sua influência seja menor em comparação com a variável **Alertas**, com 20,56%. Na Serra Catarinense, períodos prolongados de precipitação, consideradas persistentes e seguem um padrão de identificados entre latitudes 25° e 29° S (CARDOSO et al., 2020). são vitais e essa capacidade de prever chuvas acumuladas pode permitir que

a Defesa Civil planeje e emita alertas de desastres com antecedência, adaptando-se a cenários em desenvolvimento.

Variáveis como **ZCAS (1,96%)**, **Prec (1,84%)**, **Prec\_24h (1,66%)** e **Precipitação Total, Horário (mm) (1,59%)** apresentam baixa representatividade na mesorregião, indicando que, embora influenciam o modelo, sua contribuição é limitada para determinar a severidade ou a natureza dos eventos climáticos que levam a alertas de desastres.


O modelo alcançou uma taxa de acerto de 59,58%, superando os resultados da própria Defesa Civil, que registrou um acerto de 28,46%. Esta diferença significativa pode ser atribuída a vários fatores que refletem a eficácia do modelo e as peculiaridades da região. O desempenho superior do modelo pode ser explicado pela alta influência da variável Alertas, que dominou a modelagem com mais de 66% de importância.

### 5.3.6 Variáveis do Vale do Itajaí

O Vale do Itajaí, situado no estado de Santa Catarina, Brasil, é uma região de grande relevância para estudos hidrometeorológicos devido às suas características geográficas e climáticas peculiares. A região é marcada por um relevo variado, que inclui áreas planas nas proximidades dos rios e elevações significativas nas áreas montanhosas circundantes. Esse contraste topográfico é um fator crítico que influencia os padrões de precipitação e o comportamento hidrológico da área.

Da mesma forma que ocorre nas mesorregiões Norte e Serrana, a variável **Alertas** se destaca nessa mesorregião, embora sua influência seja menor, com apenas 39,52% (figura 24). Considerando as características únicas do Vale do Itajaí, como a variação de relevo e a resultante complexidade hidrológica e meteorológica, a variável serve como um indicador significativo da sensibilidade da região a eventos extremos.

Figura 24 - Representatividade geral por variável para a mesorregião Vale do Itajaí.



Fonte: Próprio autor, 2024

Em seguida, as variáveis de diferenças temporais na precipitação, como **Dif\_Prec48\_24** (8,70%), **Dif\_Prec72\_48** (7,15%), e **Dif\_Prec96\_72** (5,61%), que foram destacadas pelo modelo na mesorregião do Vale do Itajaí, com 21,46% na soma total da influência no modelo. Essas variáveis mostram a mudança na precipitação entre diferentes intervalos temporais, indicando a dinâmica climática de médio a curto prazo na região.

Com menor intensidade do que as diferenças de precipitação, com cerca de 8,5%, às diferenças na radiação solar ao longo do tempo, (**Dif\_Rad48\_24 e 120Rad**) oferecem percepções interessantes sobre o desenvolvimento diário e mudanças na energia disponível para processos atmosféricos com 4,64% e 3,85%. A radiação solar é uma fonte primária de energia para a atmosfera, influenciando fenômenos como convecção e precipitação.

Por outro lado, a variável **120Rad**, que mede a radiação acumulada ao longo de cinco dias, fornece uma perspectiva mais prolongada sobre a quantidade de energia solar presente em um ambiente. Esta medida é útil para compreender tendências mais amplas, como períodos prolongados de alta ou baixa radiação.

Da mesma forma, a variável **ZCAS**, teve sua posição relativamente elevada que as demais, 4,09%, sugere um impacto determinante, possivelmente relacionado a um parâmetro local ou condição meteorológica específica relevante para a região.

A ZCAS, quando ativa, traz uma quantidade significativa de umidade do Norte e do Oceano Atlântico para o interior do Brasil, incluindo regiões como o Vale do Itajaí. As áreas montanhosas do Vale, particularmente no Alto Vale, são propícias para a ocorrência de chuvas orográficas. Quando as massas de ar úmido impulsionadas pela ZCAS encontram essas elevações geográficas, elas são forçadas a ascender, resultando em condensação e precipitação.


O conjunto de variáveis **Prec\_Base e Prec\_Base\_72h**, com 6,71% somadas, indicam a precipitação acumulada em uma base regular e após 72 horas, respectivamente, possui impacto no modelo. Esses parâmetros de precipitação sugerem que o registro de dados anteriores é vital para o Vale do Itajaí, uma vez que tal região é conhecida por seus eventos de precipitação intensa que podem rapidamente evoluir para situações de risco.

Em relação a comparação entre o modelo e a atuação da Defesa Civil na mesorregião do Vale do Itajaí, revela um desempenho significativamente superior ao da defesa civil, com o modelo acertando 73,13% das vezes contra 19,60% da defesa civil.

5.4 CONTRIBUIÇÃO DAS VARIÁVEIS EM RELAÇÃO ÀS CIDADES

Para realizar uma análise sistemática e organizada, foi calculada a média da soma das influências de cada variável sobre as cidades envolvidas no estudo. Esses resultados foram expressos em percentuais, permitindo a comparação quantitativa da importância relativa de cada variável conforme é apresentada na figura 25.

Figura 25 - Média da representatividade geral das variáveis em toda Santa Catarina.



Fonte: Próprio autor, 2024

Com efeito, ao mostrar o nível de sensibilidade das variáveis em relação a cada cidade, a pesquisa destaca a necessidade de adaptações e calibrações locais dos modelos de previsão, considerando que essa abordagem personalizada assegura que o modelo seja não apenas cientificamente robustos, mas também pragmaticamente úteis, melhorando a precisão das previsões e a eficácia dos alertas de desastres em contextos específicos.

#### 5.4.1 Variável Alertas

A variável **Alertas**, que detém uma influência global significativa de 31,45%, desempenha um papel fundamental na compreensão e avaliação da eficácia dos alertas emitidos pelas cidades de Santa Catarina. Inicialmente, as cidades de Bom Jardim da Serra e Caçador, onde a variável alcançou uma representatividade de 100%, evidencia que esta variável é um indicador decisivo. Esse fato sugere que os sistemas de alerta nesses locais estão bem calibrados e que os alertas emitidos estão fortemente alinhados com as condições e eventos reais.

Em Lages, Curitibanos, e Itajaí, com influências variando entre 98,19% e 56,77%, a variável também se mostra preponderante, indicando que os alertas passados fornecem um subsídio robusto para a previsão de desastres. A alta correlação nesta região pode reforçar a ideia de que os dados históricos de alertas são um aspecto indispensável para entender a dinâmica dos desastres e para ajustar as estratégias de prevenção e resposta.

Ao mesmo tempo que cidades como Itapoá, Indaial, Florianópolis e Rio Negrinho, apesar de apresentarem percentuais um pouco menores, ainda demonstram uma influência considerável dessa variável. Enquanto os alertas continuam sendo um fator pertinente, outras variáveis podem ter um peso relativo na modelagem dos eventos de desastres e estas cidades podem se beneficiar de uma análise mais aprofundada para entender como outras condições locais, além dos alertas, contribuem para a efetividade dos alertas.

No outro extremo, cidades como São Miguel do Oeste, Major Vieira, e Chapecó mostram uma influência menor desta variável, o que indica que os alertas anteriores nessas localidades ou não foram suficientemente informativos ou precisos, ou que há uma maior variabilidade nos eventos de desastres que torna os alertas passados menos preditivos de futuras ocorrências.

#### **5.4.2 Variável Dif\_Prec48\_24**

Assim também a variável "**Dif\_Prec48\_24**", apresentou um percentual de influência global de 7,56% na efetividade dos alertas a partir do modelo. Este valor indica que mudanças rápidas na precipitação podem ser um indicativo de eventos meteorológicos iminentes que requerem atenção ao se tratar da emissão do alerta. Em Araranguá, a variável destacou-se com uma influência de 78,88%, para esta cidade, a rápida variação na precipitação é um forte preditor de desastres hidrometeorológicos.

Já as cidades de Ituporanga e Curitiba apresentam influências consideravelmente menores, com 23,08% e 17,70% respectivamente. Embora para estas cidades ainda se reconheça a importância da variável, as diferenças sugerem que outros fatores ou uma combinação de variáveis podem ser mais determinantes para prever a necessidade de alertas de desastres nessas localidades.

Tal qual as cidades anteriores, Novo Horizonte e São Miguel do Oeste mostram influências ainda menores, alcançando marcas de 17,25% e 11,56%, respectivamente.

#### **5.4.3 Variável Prec\_120h**

Um indicador precioso da intensidade e duração das condições meteorológicas que podem levar a desastres hidrometeorológicos é a variável que representa a precipitação acumulada ao longo de 120 horas. Com um percentual de

influência global de 7,07%, esta variável desempenhou um papel significativo na determinação da efetividade dos alertas emitidos em certas cidades com características e localidades bem distintas.

Na cidade em que faz a ligação do litoral com a serra, Rancho Queimado destaca-se com uma influência substancial de 86,47% dessa variável. Esta elevada influência sugere que em Rancho Queimado, eventos de longa duração de precipitação são especialmente convenientes para a previsão de desastres.

Com uma influência de 61,68%, São Joaquim também mostra uma dependência considerável da variável para a efetividade dos alertas. Em uma região conhecida por suas condições climáticas diferenciadas, compreender a acumulação de chuvas ao longo de cinco dias pode fornecer uma perspectiva substancial sobre a preparação para inundações ou outros tipos de desastres relacionados ao clima.

Por outro lado, o município de São Miguel do Oeste apresenta uma influência relativamente menor de 10,96%, indicando que enquanto a precipitação acumulada é importante, outros fatores podem ser mais críticos ou a cidade pode ter características que dissipam o impacto de longos períodos de chuva mais eficientemente.

#### **5.4.4 Variável ZCAS**

Com um percentual de influência global de 5,29%, essa variável pode ser um indicador relevante, desempenha um papel considerável na modulação das condições climáticas nas regiões sul do Brasil, incluindo impactos diretos nas cidades de Laguna, Campos Novos, Rio do Campo, Indaial e São Joaquim.

Como representante dos municípios costeiros do sul do Estado, Laguna demonstra a maior influência da variável, com 45,44%. Este município, sensível às dinâmicas oceânicas e atmosféricas, pode experimentar variações climáticas acentuadas devido à atividade do sistema que essa variável representa.

Com uma influência de 31,36%, Campos Novos também mostra um impacto considerável do fenômeno. Esta região, por estar situada em um planalto, pode ter características meteorológicas que são especialmente afetadas pelas dinâmicas de convergência de umidade trazidas por esse sistema.

#### **5.4.5 Variável Prec\_48h**

Ao se aferir o impacto substancial na efetividade dos alertas, a precipitação acumulada nas últimas 48 horas, representada pela variável **Prec\_48h**, foi influente nos municípios de Xanxerê, Major Vieira, São Miguel do Oeste e Araranguá. Com um percentual de influência global de 4,69%.

Destacando-se como um município onde eventos de precipitação de curta duração podem rapidamente escalar para situações de risco, Xanxerê demonstrou ser maior influência desta variável com 44,53%.

Já os municípios de São Miguel do Oeste e Araranguá mostram influências de 11,04% e 12,05%, respectivamente. Embora menor em comparação com as outras cidades, a contribuição da variável ainda está presente para essas localidades.

#### **5.4.6 Variável Dif\_Prec72\_48**

A diferença na precipitação entre 72 e 48 horas antes do momento atual, mostra uma influência global de 4,39% na efetividade dos alertas de desastres hidrometeorológicos e particularmente de interesse em cidades como Chapecó, Rio do Campo, Novo Horizonte, Urussanga e Laguna, onde a dinâmica rápida de mudança no volume de chuvas aparenta ser determinante para decisões relacionadas a emissão de alertas de desastres.

O modelo contribuiu para identificar como mudanças rápidas no padrão de chuvas afetam a probabilidade de ocorrência de eventos extremos na cidade de

Chapecó, fornecendo condições baseadas em dados para a tomada de decisões críticas em tempo real. Este município apresenta a maior influência desta variável, com 29,11%.

Com um pouco menos intensidade, em Rio do Campo, com 20,71% de influência da variável, o modelo captura a importância de monitorar as variações de chuvas para entender como essas mudanças podem desencadear condições propícias para desastres.

Assim como influências de 17,04% e 16,28%, respectivamente, Novo Horizonte e Urussanga demonstram que mesmo variações moderadas na precipitação podem ter impactos sobre a segurança e a gestão de riscos de desastres.

Na cidade de Laguna, com uma influência de 9,52%, também ressalta a utilidade desta variável, ainda que em menor grau. A variabilidade menor sugere que outras dinâmicas meteorológicas ou mesmo geográficas desempenham papéis mais determinantes nesta região, mas ainda assim, a variável ajuda na compreensão dos padrões climáticos que afetam a eficácia dos alertas.

#### **5.4.7 Variável Rad\_48**

De acordo com o modelo, a variável que representa a radiação solar acumulada em um período de 48 horas, foi consideravelmente significativa onde exerce uma influência global de 4,02% na efetividade dos alertas. Esta métrica indica a importância relativa da radiação acumulada no contexto das previsões e alertas emitidos para desastres hidrometeorológicos, principalmente em Joaçaba com 66,64% e em menor grau em Campos Novos com 13,03%.

A radiação de 48 horas é uma variável significativa no modelo e deve ser utilizada não apenas para entender melhor os padrões climáticos locais mas também para aprimorar os sistemas de alerta existentes, tornando-os mais adaptativos e eficazes.

#### **5.4.8 Variável Prec\_72h**

O Vale do Itajaí, situado no estado de Santa Catarina, Brasil, é uma região de grande relevância para estudos. No que se refere a precipitação acumulada ao longo de 72 horas, o modelo demonstrou que a variável desempenha um papel influente na efetividade dos alertas, com um percentual de influência global de 3,40%.

Esta variável mostra impactos específicos nas cidades de Dionísio Cerqueira, Xanxerê, São Miguel do Oeste e Major Vieira, destacando a importância de analisar a precipitação prolongada e sua capacidade de prever condições potencialmente perigosas em tais cidades.

Em Dionísio Cerqueira, oeste de Santa Catarina, mostra a maior influência da variável, com 38,75%. Esta alta percentagem indica que a acumulação de chuva em um período de três dias é um fator categórico na previsão de desastres nesta cidade. O município, situado em uma região propensa a variações climáticas severas.

No município de Xanxerê, que compõem a mesma região, a influência é de 14,57%, mostrando que, embora a precipitação acumulada seja proveitosa, outros fatores podem também desempenhar critérios influentes na previsão de eventos extremos.

Os municípios de São Miguel do Oeste e Major Vieira apresentam influências mais modestas, com 10,96% e 10,76%, respectivamente. Tais valores indicam que a precipitação ao longo de 72 horas ainda contribui para a avaliação da situação de risco.

#### **5.4.9 Variável Rad\_96h**

Da mesma maneira que a variável que indica a radiação solar de 48 horas, essa variável ao longo de 96 horas também apresentou-se como significativa para o modelo de avaliação, alcançou um percentual de influência global de 3,03% na efetividade dos alertas.

O município de Novo Horizonte apresentou a maior influência desta variável, com 30,10%, a radiação solar acumulada em um período extenso pode estar diretamente relacionada com a intensificação ou redução de fenômenos meteorológicos.

Em menor proporção, Urussanga e Itapoá mostram influências moderadas de 8,56% e 7,38%, respectivamente, indicando que, embora a radiação acumulada seja proveitosa, não é o fator ambiental e climático predominante, pois outros também desempenham aspectos expressivos na eficácia dos alertas.

Semelhante às cidades anteriores, Joaçaba teve influência de 5,39% da variável, que, embora não seja predominante, ainda é significativa. Curitiba, Laguna e Rancho Queimado exibem influências mais baixas da variável, com valores de 3,44%, 2,77% e 2,07%, respectivamente. Estas percentagens indicam que a radiação solar acumulada tem um impacto menos direto nas condições meteorológicas dessas localidades.

#### **5.4.10 Variável Dif\_Rad96\_72**

A variável que representa a diferença na radiação solar entre 96 e 72 horas antes do evento, apresenta uma influência modesta na análise global de 2,78% na efetividade dos alertas, mas exibe variações significativas nas cidades específicas. Devido a seu potencial para o entendimento sobre as dinâmicas meteorológicas locais e aprimorar a precisão dos alertas, reflete mudanças cruciais na energia disponível que pode influenciar condições climáticas rápidas e potencialmente severas.

O modelo indica variações na radiação solar em curtos períodos podem ser indicativos influentes de mudanças meteorológicas iminentes na cidade de Laguna, registrando a cidade com maior influência sobre essa variável com 29,00%. Nesta cidade, a variável pode ser especialmente relevante para prever eventos como nebulosidade intensa que precede tempestades, ou mudanças bruscas na temperatura que podem afetar a estabilidade atmosférica.

Com uma influência significativa de 21,21%, o município Rio Negrinho mostra que a variação na radiação solar também possui relevância considerável na previsão de eventos meteorológicos nesta cidade.

Contudo, os municípios de Chapecó e Major Vieira, com influências menores de 5,41% e 4,43% respectivamente, ainda podem se beneficiar da integração desta variável no modelo.

#### **5.4.11 Variável Dif\_Prec96\_72**

Com parâmetros semelhantes a variável anterior, porém de natureza similar a da segunda maior variável valia ao modelo, a diferença na precipitação entre 96 e 72 horas antes de um evento, tem um percentual global de influência na efetividade dos alertas de desastres hidrometeorológicos de 2,12%. Embora este percentual global seja modesto, sua influência varia significativamente entre algumas cidades, sugerindo que em contextos locais específicos, a variável pode ser preponderante para a previsão de eventos extremos.

A cidade de Florianópolis, conhecida por seu clima variável e tempestades súbitas, pode se beneficiar significativamente de monitorar mudanças rápidas na precipitação, onde mostrou uma influência da variável na efetividade dos alertas de 9,06%. Tal variável pode contribuir positivamente a identificar a aproximação de frentes climáticas que trazem precipitação intensa em curtos períodos, permitindo uma resposta mais rápida e eficaz em situações de potenciais desastres com danos.

Com influências de 8,16% e 8,47% respectivamente, Ituporanga e Rio do Campo, também destacam a importância desta variável. Assim também o município de Campos Novos, com uma influência de 7,81%, também demonstra que a diferença na precipitação em um intervalo de 24 horas pode ser um indicador vital para a preparação contra inundações, enxurradas e deslizamentos.

#### **5.4.12 Variável Prec\_24h**

No que concerne a efetividade dos alertas de desastres hidrometeorológicos, a variável que representa a precipitação acumulada nas últimas 24 horas, possui um percentual de influência global de 2,06%, indicando que, embora sua contribuição geral seja modesta, ela possui importância crítica em situações e locais específicos.

Por exemplo, em São Miguel do Oeste, o comportamento do modelo mostra a maior influência desta variável, com 11,92%. Com influências de 7,37% e 6,95%, respectivamente, os municípios de Dionísio Cerqueira e Urussanga, também evidenciam que a variável é um potencial indicador para a avaliação de alertas, uma vez que nessas localidades, as condições meteorológicas podem mudar rapidamente, e um acompanhamento atento às precipitações dentro desse lapso temporal, pode ser essencial para emitir alertas precisos e tempestivos.

Ao verificar as cidades de Florianópolis, Major Vieira e São Joaquim, onde a variável tem influências que variam de 3,74% a 4,97%, observa-se que, embora a contribuição do acúmulo de precipitação em 24 horas não seja a mais dominante, ela ainda é significativa.

Em Itajaí, a influência de variável é ainda mais modesta, com uma contribuição de 2,78%. Essa cidade, situada em uma região costeira, pode ser menos afetada por precipitações de curta duração devido à influência de condições oceânicas, que tendem a moderar variações rápidas de tempo ou mesmo outros indicadores como ventos marítimos e padrões de corrente, que podem ter um impacto mais determinante na dinâmica climática local.

#### **5.4.13 Variável Prec**

Ao avaliar a efetividade dos alertas de desastres hidrometeorológicos nas cidades da amostra, a variável que representa a precipitação total embora com um percentual menor de influência global que as demais, alcançou marcas de 1,99%. Ao comparar com a variável anterior, observa-se precipitação em um intervalo de 24 horas, englobando a precipitação acumulada em um período não especificado, que é importante para avaliar a sustentabilidade e o impacto prolongado dos eventos meteorológicos.

Representando contrastes geográficos, as cidades de São Miguel do Oeste e Urussanga, com influências de 10,68% e 7,21% respectivamente, ilustram como um acúmulo significativo de chuva impacta diretamente a necessidade e a precisão dos alertas. Estas cidades, que podem experimentar eventos de chuvas intensas e prolongadas, utilizam tanto os dados de precipitação total quanto de intervalos para prever potenciais eventos de desastres.

Com quase metade dessa relevância, os municípios de Dionísio Cerqueira e São Joaquim, com influências de 6,49% e 5,51%, também mostram a importância de considerar tanto a precipitação de curta quanto de longa duração. Em cidades costeiras como Florianópolis, Itajaí, e do planalto norte como Major Vieira, com influências menores variando de 3,15% a 3,94%,

#### **5.4.14 Variável Precipitação Total Horário(mm)**

Com um percentual de influência global similar às variáveis anteriores, de 1,98%, e de mesma natureza, a variável a qual representa a precipitação horária, demonstra uma dimensão complementar nas previsões, oferecendo uma perspectiva imediata sobre as condições meteorológicas locais.

Essa variável, assim como outras de natureza semelhante, apresenta similaridades na representatividade em diversas cidades. Por exemplo, em São Miguel do Oeste e Urussanga, com percentuais de influência de 10,52% e 7,08%, respectivamente, evidencia a importância crítica de monitorar as variações horárias da precipitação. Nesse contexto, a variável fornece dados essenciais e complementares para a emissão de alertas, especialmente em situações de chuvas intensas que podem resultar em inundações rápidas ou deslizamentos.

Dionísio Cerqueira e São Joaquim, seguem a mesma tendência, com influências de 6,66% e 4,78%, e utilizam esta variável para ajustar as estratégias de alerta baseadas nas mudanças rápidas das condições locais.

Com influências menores, similarmente às outras variáveis de precipitação, Florianópolis, Itajaí e Major Vieira, variam entre 3,49% e 3,91%, e ainda beneficiam-se da utilização desta variável, embora seu impacto seja relativamente menor.

#### **5.4.15 Variável Dif\_Rad48\_24**

A diferença na radiação solar entre 48 e 24 horas antes de um evento é um influenciador básico na avaliação da efetividade dos alertas hidrometeorológicos, especialmente em regiões com alta variabilidade climática.

Com uma influência global de 1,96%, essa variável ajuda a entender como mudanças rápidas na radiação podem afetar o microclima e a precisão dos alertas. Cidades como Xanxerê e Ituporanga, com influências de 13,85% e 13,80%, respectivamente, mostram uma alta correlação entre as variações na radiação solar e a efetividade dos alertas.

Embora em menor escala, os municípios de Florianópolis, Dionísio Cerqueira e Major Vieira, com influências de 4,27%, 3,96% e 3,59% respectivamente, também demonstram a relevância da variável.

#### **5.4.16 Variável Rad\_120h**

Representando apenas 1,89% da influência global no modelo, a radiação solar acumulada ao longo de cinco dias interage na avaliação do modelo de maneira sutil, na antecipação de fenômenos climáticos de longa duração que podem precipitar eventos de desastres.

Foi identificado que os municípios de Novo Horizonte e Itajaí, com influências significativas de 10,28% e 8,77%, respectivamente, demonstram como variações sustentadas na radiação solar podem ser decisivas em moldar a dinâmica de seus microclimas.

Os valores apresentados pelas cidades Itapoa e Joaçaba sugerem que, embora a radiação de longo prazo seja um componente útil do modelo de alerta, sua contribuição direta pode ser complementada por outros fatores locais, como variações geográficas e climáticas mais imediatas.

#### **5.4.17 ANÁLISE DAS PERFORMANCES DAS CIDADES**


É de interesse a efetividade dos alertas nas diversas cidades de Santa Catarina, tanto para avaliar o impacto do modelo quanto para compreender a eficácia dos alertas emitidos pela Defesa Civil.

A ideia apresentada por Czocher (2018) sobre a validação da resposta em um contexto científico ou analítico enfoca a importância de confrontar os resultados com a realidade observada e as informações pré-existentes. Esta parte do processo envolve verificar se os resultados de um modelo correspondem aos dados e informações já conhecidos.

Visto essa a necessidade desta comparação de maneira detalhada, emerge da observação de que diferentes cidades podem apresentar variações significativas na eficácia dos alertas, devido a fatores geográficos, infraestruturais e de

capacidade de resposta, conforme podemos identificar graficamente nos percentuais na figura 26.

Figura 26 - Percentual de assertividade dos alertas em relação aos danos registrados pela Defesa Civil e pelo Modelo *Chromecast* por cidade.



Fonte: Próprio autor, 2024

Em cidades como Araranguá, Florianópolis, Joaçaba, Laguna, Rancho Queimado, São Joaquim, São Miguel do Oeste e Xanxerê, observa-se uma eficácia maior nos resultados da Defesa Civil, sugerindo que fatores locais podem não ter sido totalmente captados pelo modelo.

Para a cidade de **Araranguá** a Defesa Civil registrou uma efetividade de 33,33%, significativamente superior ao modelo, que alcançou apenas 14,29%. A

análise destes resultados indica a necessidade de integrar mais variáveis locais, revisar o dados de danos ou ajustar os algoritmos.

Em **Florianópolis**, a performance foi de 43,75% contra 48,15% da Defesa Civil. A diferença ainda aponta para a necessidade de integração de mais dados locais ou uma revisão nas variáveis meteorológicas utilizadas.

**Rancho Queimado** mostra uma menor diferença (25,00% do modelo contra 28,57% da Defesa Civil), sugerindo que enquanto o modelo tem alguma capacidade preditiva, ainda há espaço para melhorias na captação das especificidades climáticas da região.

Um dos fatores que podem influenciar essa performance considerada regular, tanto da Defesa Civil quanto do modelo, pode ser devido uma tendência do declínio de chuvas para a mesorregião da Grande Florianópolis pelos estudos de Pugas et al. (2024),

Da mesma forma que as estruturas que captam e conduzem água da chuva, como calhas e condutores naturais, influenciam as consequências relacionados a precipitação que nem sempre podem estar associado a intensidade das chuvas locais, como a cidade de Rancho Queimado, que neste sentido apresenta altos valores, com uma média de 176,5 mm/h, considerando intensidade da chuva com duração de 5 minutos e período de retorno de 25 anos, fazendo com que a cidade esteja na faixa média das regiões que apresentam as mais altas médias registradas no Estado (BACK et al., 2023).

Outra cidade que apresenta uma performance muito inferior em comparação a Defesa Civil é **Xanxerê**, com 12,50% de eficácia, enquanto a Defesa Civil teve melhores desempenhos, com 50%.

De acordo com Luz (2018) ilustra que mesmo com o investimento em tecnologia de ponta, robusta e inovadora não pode garantir o sucesso na previsão de desastres em Xanxerê, onde recebeu um radar de alto custo destinado a prever eventos meteorológicos e no entanto, apesar desse investimento egrégio, o radar não conseguiu cumprir seu papel efetivamente quando falhou em alertar a

população sobre a formação e deslocamento de um tornado que afetou a região e causou danos a mais de 12 mil pessoas.

Por outro lado, nas cidades onde o modelo superou a efetividade dos alertas emitidos pela Defesa Civil, observa-se um padrão notável de precisão e adaptabilidade. Cidades como Indaial, Itajaí, Chapecó, Itapoá, Urussanga, Lages, Curitiba, Rio do Campo, Dionísio Cerqueira e Bom Jardim da Serra, destacaram-se com alta performance, variando de 75% a 100%, demonstrando a considerável robustez do modelo em prever efetivamente os danos associados a eventos de desastres hidrometeorológicos com maior acerto do que as avaliações realizadas pela Defesa Civil. As cidades de Major Vieira, Campos Novos, Rio Negrinho e Caçador apresentaram uma performance com percentuais entre 50% e 74%.

A tabela 4 fornece uma classificação das performances de cada cidade, em relação a assertividade da Defesa Civil de Santa Catarina em comparação a previsão apresentada pelo modelo Chromecast, em cinco categorias: **Alta performance**, na cor **verde** (100% a 75% de assertividade), **Ótima performance** na cor **azul** (menos de 75% a 50% de assertividade), **Boa performance** na cor **amarelo** (menos de 50% a 25% de assertividade), **Regular performance** na cor **laranja** (menos de 25% a 1% de assertividade) e **Insuficiente** na cor **vermelha** (0% de assertividade).

Tabela 4 - Comparativo da classificação das performances da Defesa Civil e do Modelo *Chromecast*.

| CHRONOCAST |               | DEFESA CIVIL |               |
|------------|---------------|--------------|---------------|
| CIDADE     | ASSERTIVIDADE | CIDADE       | ASSERTIVIDADE |
| INDAIAL    | 100,00%       | SÃO JOAQUIM  | 54,55%        |
| ITAJAÍ     | 87,50%        | RIO NEGRINHO | 50,00%        |
| CHAPECÓ    | 85,71%        | XANXERÊ      | 50,00%        |

|                     |        |                     |        |
|---------------------|--------|---------------------|--------|
| ITAPOÁ              | 85,71% | FLORIANÓPOLIS       | 48,15% |
| URUSSANGA           | 85,71% | LAGUNA              | 44,44% |
| LAGES               | 83,33% | MAJOR VIEIRA        | 41,94% |
| CURITIBANOS         | 80,00% | CAMPOS NOVOS        | 41,67% |
| RIO DO CAMPO        | 80,00% | ARARANGUÁ           | 33,33% |
| DIONÍSIO CERQUEIRA  | 77,78% | RIO DO CAMPO        | 33,33% |
| BOM JARDIM DA SERRA | 75,00% | SÃO MIGUEL DO OESTE | 33,33% |
| MAJOR VIEIRA        | 73,68% | CACADOR             | 28,57% |
| CAMPOS NOVOS        | 71,43% | ITAPOÁ              | 28,57% |
| RIO NEGRINHO        | 63,16% | RANCHO QUEIMADO     | 28,57% |
| CACADOR             | 50,00% | URUSSANGA           | 27,27% |
| FLORIANÓPOLIS       | 43,75% | DIONÍSIO CERQUEIRA  | 26,67% |
| NOVO HORIZONTE      | 33,33% | CURITIBANOS         | 25,00% |
| ITUPORANGA          | 25,00% | ITUPORANGA          | 23,08% |
| RANCHO QUEIMADO     | 25,00% | JOACABA             | 20,00% |
| ARARANGUÁ           | 14,29% | LAGES               | 20,00% |
| XANXERÊ             | 12,50% | NOVO HORIZONTE      | 20,00% |
| JOACABA             | 0,00%  | CHAPECÓ             | 18,18% |
| LAGUNA              | 0,00%  | BOM JARDIM DA SERRA | 14,29% |
| SÃO JOAQUIM         | 0,00%  | ITAJAÍ              | 14,29% |
| SÃO MIGUEL DO OESTE | 0,00%  | INDAIAL             | 7,69%  |

Fonte: Próprio autor, 2024

Quanto às cidades consideradas com boa performance, o qual apresenta uma faixa 25% e abaixo do 50%, estão as cidades de Florianópolis, Novo Horizonte, Ituporanga e Rancho Queimado, as quais o modelo também demonstrou superioridade em relação aos resultados da Defesa Civil em alguns municípios (Novo Horizonte e Ituporanga), enquanto outros, apesar de inferiores, com menor diferença entre nos resultados comparados a Defesa Civil, evidenciando a

capacidade do modelo de adaptar-se a uma variedade de condições locais e meteorológicas específicas com um número menor de dados.

A cidade de **Indaial** destaca-se com uma performance perfeita do modelo (100% de assertividade), em contraste com a Defesa Civil (7,69%). Este caso exemplifica o potencial do modelo em situações onde as configurações tradicionais falham em prever ou reagir adequadamente às condições que levam a desastres.

De acordo com os estudos de Schorn e Vieira (2023), o município de Indaial em Santa Catarina enfrenta problemas de inundações e enxurradas frequentes, exacerbados pela ocupação desordenada de áreas que deveriam ser protegidas, como as Áreas de Preservação Permanente (APPs) e zonas ribeirinhas que são naturalmente suscetíveis a esses desastres.

Em **Chapecó**, por exemplo, o modelo alcançou uma assertividade de 85,71%, significativamente superior aos 18,18% registrados pela Defesa Civil. Os municípios costeiros de **Itajaí** e **Itapoá**, também apresentam performances superiores do modelo, com 87,50% e 85,71% de assertividade, respectivamente, em comparação com menos de 30% pela Defesa Civil.

Da mesma forma, **Lages** e **Urussanga**, com 83,33% e 85,71% de assertividade, respectivamente, mostram como o modelo adapta suas previsões às características geográficas internas e aos microclimas específicos dessas áreas.


Em **Bom Jardim da Serra**, o modelo alcançou uma notável efetividade de 75,00%, substancialmente mais alta que os 14,29% registrados pela Defesa Civil. Nos municípios de **Caçador** e **Campos Novos** também mostraram resultados interessantes considerados com efetividade ótima, com efetividades de 50,00% e 71,43%, respectivamente, comparadas a menores eficiências da Defesa Civil.

Com performance regular e ótima, **Rio do Campo Major Vieira** e **Rio Negrinho**, com 80,00%, 73,68% e 63,16% de efetividade respectivamente, ilustram como o modelo pode ser sensível às variações nas práticas de coleta de dados e nas características específicas do clima local.

**Novo Horizonte**, Ituporanga e **Rio Negrinho** apresentaram efetividades de 33,33% e 25,00% pelo modelo, respectivamente. Esses resultados destacam como o modelo pode captar, de maneira regular com eficácia as dinâmicas específicas de cada área, como padrões de precipitação localizados e a influência de corpos d'água, bacias hidrográficas e formações geográficas locais na modulação de eventos climáticos.

A análise dos resultados obtidos tanto pelo modelo quanto pela Defesa Civil revela superioridade do modelo em termos de efetividade dos alertas de desastres nas cidades analisadas. Com uma média geral de efetividade de 52,20%, o modelo supera significativamente a efetividade da Defesa Civil, que se situa em 30,54%. O detalhamento dos percentuais de efetividade comparados são demonstrados graficamente na figura 27.

Figura 27 - Comparativo da assertividade da emissão do alerta e dano registrado pela Defesa Civil e do Modelo *Chronocast* por cidades.



No entanto, a efetividade moderada ou baixa da Defesa Civil em várias dessas localidades onde o modelo é bem-sucedido levanta questões sobre as técnicas atuais de análise e resposta aos desastres. A falta de cidades na categoria de alta performance pela Defesa Civil pode indicar limitações nos métodos de análise ou na integração de dados e tecnologias que poderiam permitir uma resposta mais eficaz.


## 5.5 COMPARATIVO ENTRE AS CIDADE COM ALTA E BAIXA PERFORMANCE

Comparar as cidades com diferentes desempenhos permite identificar sua consistência em diversos cenários e condições locais, destacando seus pontos fortes e fracos. Isso facilita a avaliação da precisão geral do modelo e sua aplicabilidade em diferentes situações.

Essas comparações contribuem para que os operadores da Defesa Civil e pesquisadores interessados na efetividade do alerta partam um ponto de referência em estudos futuros, além de utilizarem suas saídas na prática.

As cidades de **Indaial**, **Itajaí**, **Itapoá**, **Chapecó**, **Lages** e **Urussanga** foram apresentaram as melhores performances em termos de eficácia. Na figura 28, é apresentado o gráfico dos resultados gerais por contribuição das variáveis.

Figura 28 - Representatividade das variáveis nas cidades com altas performances de acordo com o Modelo *Chronocast*.



Fonte: Próprio autor, 2024

Ao verificar a média das variáveis básicas é possível verificar aspectos semelhantes ao identificado nas análises individuais, com maior relevância para a variável **Alertas**.

A variável **Dif\_Prec72\_48**, com 9,80% de influência, enfatiza a importância de capturar flutuações rápidas na precipitação para a previsão acurada. Os municípios de Chapecó e Urussanga apresentaram substancial contribuição dessa variável para a performance do modelo.

Ao mesmo tempo que a radiação acumulada, destacada por **Rad\_96h** (3,64%), **Rad\_120h** (2,91%) e **Dif\_Rad72\_48** (2,74%), reforça a ideia de que a análise prolongada de padrões de radiação é fundamental para que o modelo entenda as condições meteorológicas que podem culminar em desastres.

Tal qual as demais variáveis de destaque, a variável **ZCAS** (2,64%) apresenta uma influência na performance do modelo, o que sugere uma influência moderada na eficácia dos alertas nas cidades com melhores performances. A presença desta variável reforça a importância de fatores climáticos regionais oportunos que podem impactar diretamente a ocorrência de desastres hidrometeorológicos.


De maneira similar a variável de segunda maior relevância, as variáveis relacionadas à precipitação, como **Dif\_Prec48\_24** (2,33%), **PRECIPITAÇÃO TOTAL, HORÁRIO(mm)** (2,30%), **Prec** (2,27%) e **Prec\_24h** (2,15%), somando-se ao todo pouco mais de 9%, também mostram influências significativas, indicando que alterações nas condições de precipitação, acumuladas, apresentam um alto impacto para a previsão precisa do modelo.

Com uma representatividade média mais discreta, com cerca de 2,22%, a variável **Vento\_120h** (2,22%) demonstra que para uma performance ideal, é necessário que o modelo capture influências prolongadas do vento sobre o clima.

O modelo demonstra uma aplicabilidade prática potencial ao responder eficientemente às flutuações e variáveis meteorológicas. A capacidade de adaptar-se rapidamente a mudanças climáticas oferece à Defesa Civil uma ferramenta auxiliar com potencial para a emissão de alertas mais precisos.

Todavia, as cidades de **Araranguá, Xanxerê, São Miguel do Oeste, Joaçaba, São Joaquim, e Laguna** foram classificadas com as menores taxas de acerto ou mesmo com nenhum acerto no modelo. A contribuição de cada variável considerada relevante para o modelo em cada uma dessas cidades com essa baixa performance, podem ser verificadas na figura 29.

Figura 29 - Representatividade das variáveis nas cidades com baixas performances de acordo com o Modelo *Chronocast*.



Fonte: Próprio autor, 2024

Variáveis relacionadas à precipitação por períodos prolongados apresentam uma alta média de representatividade, com **Prec\_120h** liderando (14,68%) e de maneira semelhante a variável **Prec\_48h** (11,76%), as quais sugere que o modelo identificou que para essas cidades, o impacto cumulativo da chuva está associado de maneira significativa.

Já a radiação em diferentes intervalos também mostra uma alta representatividade tanto pela segunda variável destaque, **Rad\_48h** (13,38%) como

pelas de mesma natureza **Dif\_Rad96\_72** (5,86%), **Dif\_Rad72\_48** (4,08%). A radiação solar influencia diretamente a evapotranspiração e, por extensão, a dinâmica da umidade e formação de nuvens.


Outras variáveis relacionadas a precipitação também obtiveram destaque para essas previsões realizadas pelo modelo como **Prec\_72h**, **Prec\_24h**, **Prec** e **PRECIPITACAO TOTAL, HORARIO(mm)**, somando pouco mais de 15%. Estas variáveis visam indicar mudanças em curto prazo.

A presença significativa da variável **ZCAS** com 10,30% de representatividade reforça a importância deste fenômeno nas previsões de desastres hidrometeorológicos, particularmente em regiões propensas a eventos extremos de chuva.

Com 2,78% de representatividade, a variável **Alertas** mostra que os históricos de alertas não foram representativos o suficiente para desempenhar o potencial que os ventos anteriormente registrados.

A partir dos resultados que indicam baixas performances, especialmente nas cidades com índices de acerto muito baixos, é possível que as variáveis destacadas pelo modelo não estejam efetivamente capturando os fatores mais críticos que conduzem aos desastres. A comparação entre as variáveis das cidades com altas e baixas performances demonstra essa distinção na influência do modelo (figura 30).

Figura 30 - Comparativo da representatividade das variáveis nas cidades com altas e baixas performances de acordo com o Modelo *Chronocast*.



Fonte: Próprio autor, 2024

O gráfico permite identificar diferenças significativas nas médias das variáveis que impactam a efetividade dos alertas de desastres hidrometeorológicos entre cidades com alta e baixa performance. Notavelmente, a variável Alertas é preponderante nas cidades com alta performance, mostrando uma representatividade de quase 50%, o que justifica novamente que o histórico e a gravidade dos alertas anteriores são fundamentais para uma previsão eficaz de desastres nestas áreas.

Outras variáveis como ZCAS e Dif\_Vento96\_72 também se mostram significativas, indicando que condições climáticas específicas e mudanças rápidas

na intensidade do vento são bem capturadas pelo modelo nas cidades de alta performance.

Por outro lado, nas cidades com baixa performance, observa-se uma maior influência de variáveis relacionadas à precipitação, como **Prec\_24h**, **Prec\_48h**, e **Prec\_120h**. Embora essas variáveis sejam pertinentes, sua alta representatividade nessas cidades pode sugerir que, isoladamente, não são suficientes para prever eficazmente a eficácia dos alertas. Variáveis de radiação, como **Rad\_48h**, também são mais proeminentes nessas cidades, sugerindo que, apesar de sua relevância, as mudanças na radiação solar, embora monitoradas, não são tão efetivas para prever desastres nessas regiões.

## 5.6 COMPORTAMENTO DO MODELO

A análise do comportamento do modelo, considerando os resultados de efetividade dos alertas para cada cidade em Santa Catarina, apresenta interações distintas entre as variáveis meteorológicas para cada cidade.

As variáveis como precipitação e temperatura variam em parte nas regiões e cidades, em decorrência da posição geográfica de Santa Catarina, situada na transição entre os trópicos e as latitudes médias além do relevo acidentado contribui para essas disparidades climáticas, intensificando certos padrões de precipitação (GRIMM, 2021).

A variabilidade desses resultados da modelagem em relação a efetividade dos alertas sugere que o modelo apresenta diferentes níveis de adequação dependendo das condições específicas de cada localidade.

Os registros de danos causados por eventos climáticos foram fundamentais para validar e aprimorar os modelos. Esses dados permitiram correlacionar eventos específicos com seus impactos reais, ajustando as previsões para refletirem as consequências observadas. Em cidades onde esses registros eram abundantes, as previsões alinharam-se melhor com as realidades locais.

Nesse contexto, os registros de danos, além de validar o modelo, forneceram informações valiosas para ajustes e calibrações. Por exemplo, se um modelo subestima consistentemente a severidade dos eventos em uma determinada localidade, a análise dos registros de danos indicava a necessidade de ajustar os pesos das variáveis ou a metodologia de treinamento para capturar melhor a gravidade dos eventos. Isso foi efetivamente realizado com a função *Sample Weights* no modelo.

As configurações de *max\_depth*, *min\_samples\_split* e o número de *n\_estimators* são consistentes em todas as cidades, sendo possível padronizar a abordagem do modelo em todo o estado.

É necessário a ampliação e melhoria na qualidade e disponibilidade dos dados meteorológicos e dos registros de danos nas regiões com previsões menos precisas, pois pode fornecer informações adicionais necessárias para melhorar a eficácia das previsões de danos.

## 6 CONSIDERAÇÕES FINAIS

Abordou-se a efetividade dos alertas de desastres hidrometeorológicos em Santa Catarina, um estado amplamente afetado por eventos dessa natureza, com o objetivo de avaliar essa eficácia, por meio do uso de um modelo de *machine learning*. O problema central investigado foi o impacto da variabilidade entre diferentes variáveis meteorológicas e seus efeitos nas mesorregiões e cidades, bem como na precisão dos alertas emitidos em relação à concretização dos fenômenos previstos e aos danos por eles ocasionados. As hipóteses iniciais sugeriram que a efetividade dos alertas poderiam não ser as mesmas para todas as regiões e cidade de Santa Catarina, dado a influência de fatores específicos regionais e a variabilidade nos dados de registros de danos, a qual foi confirmada pelo resultado do modelo.

A metodologia adotada, mediante o uso do modelo *Chronocast* (que embarcou o algoritmo *random forest*) conseguiu identificar as variáveis que mais contribuem para a precisão dos alertas, revelando que fatores como a frequência e padrões de eventos anteriores que ensejaram alertas, variações rápidas na precipitação e períodos de incidência ou não da radiação solar são determinantes em regiões e cidades específicas do Estado, enquanto, não são tão úteis ou com um peso considerável para outras.

Os resultados mostraram que o modelo foi capaz de realizar a avaliação dos alertas emitidos pela Defesa Civil, com base nas variáveis de entrada do modelo definida neste estudo, como também a capacidade de previsão do modelo, o qual superou em alguns casos a assertividade dos alertas que realmente culminaram em danos registrados pelos métodos convencionais da Defesa Civil, especialmente em cidades como Indaial, Itapoá, Chapecó, Lages, Urussanga, Lages, Curitiba, Rio do Campo, Dionísio Cerqueira e Bom Jardim da Serra onde obtiveram performances excelentes.

O tempo computacional do modelo e seu comportamento mostrou-se adequado para aplicações operacionais, uma vez que foi capaz de processar e

analisar grandes volumes de dados em um período de tempo compatível com as demandas de resposta rápida exigidas em situações de emergência.

Quanto a análise do desempenho do modelo, quantificada pelo coeficiente de determinação, mostrou que o modelo apresentou consistência tanto na avaliação quanto na previsão de potenciais eventos que podem gerar danos, mas requer melhorias no que se refere à previsão dos eventos, principalmente, de acordo com o estudo, pela limitação do conjunto de dados disponíveis para esses locais, tanto de dados meteorológicos quanto de variáveis de entrada, e também pela quantidade de registros de danos disponíveis no S2ID.

Em mesorregiões onde o modelo superou a Defesa Civil, como Norte Catarinense, Vale do Itajaí, mesorregião Serrana e Oeste Catarinense, a precisão do modelo foi maior, sugerindo que as variáveis e parâmetros utilizados estavam bem alinhados com as dinâmicas meteorológicas e os padrões de resposta locais. Nos locais onde a eficácia do modelo foi menor do que a Defesa Civil, os percentuais de acerto estão próximos, o que indica um potencial para avaliar os alertas emitidos dentro do espectro das mesorregiões.

Foi possível identificar a contribuição das variáveis, com vistas a efetividade dos alertas nas mesorregiões e cidades, e em relação às estações analisadas, o modelo demonstrou que há diferenças significativas na influência dos fatores meteorológicos sobre a eficácia dos alertas em relação aos danos decorrentes de desastres. A variável Alertas mostrou uma influência preponderante em muitas mesorregiões e cidades.

Em termos de variáveis meteorológicas, as diferenças de precipitação, desenvolvidas para avaliar as variações rápidas na precipitação, teve impacto substancial em áreas susceptíveis a mudanças abruptas no aspecto meteorologia local, enquanto as variáveis derivadas de períodos de incidência da radiação solar, em cidades litorâneas, apresentou maior relevância, dado que tais locais normalmente são onde a dinâmica solar afeta significativamente as condições meteorológicas locais.

Nas cidades com alta performance, a variável **Alertas** manteve a tendência, com uma representatividade média de 49,52%. As variáveis relacionadas à precipitação e à radiação solar foram altamente influentes, principalmente quando as variáveis de mesma natureza foram associadas.

Nas cidades com baixa performance, observou-se uma maior representatividade das variáveis relacionadas à precipitação acumulada. Embora essas variáveis sejam úteis, isoladamente, elas não são suficientes para prever com precisão os desastres hidrometeorológicos nessas regiões. Da mesma forma, as variáveis de radiação apresentaram alta representatividade nas cidades de baixa performance.

A avaliação dos alertas emitidos pela Defesa Civil, de acordo com os resultados obtidos pelo modelo, revelou que a efetividade dos alertas emitidos pela Defesa Civil para o Estado de Santa Catarina foi de 31,90%. A capacidade de previsão do modelo, alcançou uma efetividade de 52,66% em todo o Estado, ao mesmo tempo que apresenta uma análise mais profunda e detalhada das variáveis meteorológicas que tem mais influência em determinada mesorregião ou cidade, e influencia a assertividade dos alertas de maneira variada e distinta, capturando nuances específicas que podem ser perdidas nos métodos tradicionais de avaliação.

## 7 PRODUTOS TÉCNICOS/TECNOLÓGICOS

### 7.1 APRESENTAÇÃO DE PESQUISA

PUGAS, André Francisco; Vitor, Adriano. Nowcasting: Análise do Sistema de Monitoramento e Alerta da Defesa Civil do Estado de Santa Catarina. In: **V Jornada Clima e Ambiente do Instituto Federal de Santa Catarina**. IFSC, 2022, Itajai, Anais IFSC, Clima e Ambiente, p. 1 - 8, Set 2021.

Figura 31 - Cartaz da V Jornada Clima e Ambiente.



Fonte: IFSC, 2021

PUGAS, André Francisco; BARBOZA DA SILVA, Ariana Pereira; DA SILVA, Eliseo Breda; ROIDÃO, Helena Pures; QUADRO, Mário Francisco Leal de; VITOR, Adriano; MUZA, Michel Nobre. Analysis of Temporal Precipitation Variability in The State of Santa Catarina - Brazil. In: **SIMCLEA - Simpósio em Clima, Água, Energia e Alimentos 13 a 15 de outubro de 2021**. VI Encontro de Meteorologia do Estado

do Rio de Janeiro. III Encontro de Meteorologia do Estado de Santa Catarina. II Semana Acadêmica da Engenharia Meteorologia. Rio de Janeiro, Out. 2021.

Figura 32 - Cartaz do Simpósio em clima, água, energia e alimentos de 2022.



Fonte: SIMCLEA, 2022

PUGAS, André Francisco; VITOR, Adriano; QUADRO, Mário Francisco Leal de. Análise do Sistema de Alertas de Desastres Nowcasting: um panorama dos alertas emitidos de 2017 a 2021. In: **IV Simpósio Ibero - Afro - Americano de RISCOS**. Colômbia, 18 de julho de 2022.

Figura 33: Cartaz do IV Simpósio Ibero - Afro - Americano de RISCOS.



Fonte: RISCOS, 2022

## 7.2 RESUMOS EXPANDIDOS

PUGAS, André Francisco; Vitor, Adriano. Nowcasting: Análise do Sistema de Monitoramento e Alerta da Defesa Civil do Estado de Santa Catarina. In: **V Jornada Clima e Ambiente do Instituto Federal de Santa Catarina**. IFSC, 2022, Itajaí, Anais IFSC, Clima e Ambiente, p. 1 - 8, Set 2021.

PUGAS, André Francisco; VITOR, Adriano; QUADRO, Mário Francisco Leal de. Análise do Sistema de Alertas de Desastres Nowcasting: um panorama dos alertas emitidos de 2017 a 2021. In: **Simpósio Ibero - Afro - Americano de RISCOS**. Colômbia, 18 de julho de 2022.

## 7.3 ARTIGOS PUBLICADOS

PUGAS, André Francisco; Vitor, Adriano. Nowcasting: Análise do Sistema de Monitoramento e Alerta da Defesa Civil do Estado de Santa Catarina. **Estrabão**. v. 2, p. 157 - 169, Set 2021. <https://doi.org/10.53455/re.v2i.38>

PUGAS, André Francisco. The Hunt for Data: obstacles faced by researchers in the search for accurate information on precipitation in Brazil. **International Journal of Hydrology**. v. 7, n. 2, p. 88-91, Maio 2023. <https://doi.org/10.15406/ijh.2023.07.00344>

PUGAS, André Francisco; BARBOZA DA SILVA, Ariana Pereira; DA SILVA, Eliseo Breda; ROIDÃO, Helena Pures; QUADRO, Mário Francisco Leal de; VITOR, Adriano; MUZA, Michel Nobre. Analysis of Temporal Precipitation Variability in The State of Santa Catarina - Brazil. **Brazilian Journal of Climatology**. v. 34, Jan/Jun 2024. ISSN 2237-8642 <https://doi.org/10.55761/abclima.v35i20.17906>

PUGAS, André Francisco; VITOR, Adriano; QUADRO, Mário Francisco Leal de. Identification of active meteorological systems in Santa Catarina with potencial socioeconomic impact. **International Journal of Hydrology**. v. 4, n. 1, p. 81-91, Jun. 2024. <https://doi.org/10.15406/ijh.2024.08.00378>


PUGAS, André Francisco; VITOR, Adriano; QUADRO, Mário Francisco Leal de. Sazonalidade e Espacialização dos Desastres em Santa Catarina: uma análise sobre os alertas por SMS do Sistema da Defesa Civil de Santa Catarina Nowcasting. **Territorium**. v. 32, n. 1, p. 67 - 85, 2024.

#### 7.4 MODELO *CHRONOCAST*

O modelo desenvolvido, denominado *Chronocast*, utiliza técnicas avançadas de aprendizado de máquina, especificamente o algoritmo *Random Forest*, para avaliar a eficácia dos alertas de desastres baseados em dados meteorológicos. Utilizando dados específicos coletados de diversas fontes meteorológicas, o modelo processa informações como variáveis climáticas e históricos de eventos para prever a ocorrência e intensidade de danos em áreas vulneráveis. A abordagem desenvolvida nesse modelo permite uma análise detalhada e preditiva, com o objetivo de avaliar e aprimorar a precisão dos alertas emitidos pela Defesa Civil.

Ao aplicar o modelo, são carregados múltiplos modelos pré-treinados, cada um adaptado para uma localização específica. Esses modelos são integrados para gerar uma previsão final que reflete a máxima expectativa de danos em um determinado evento meteorológico. A validação do modelo é feita por meio de métricas como o coeficiente de determinação ( $R^2$ ), proporcionando ao usuário uma medida robusta da capacidade preditiva do sistema para cada cidade que utilizar, com possibilidade de averiguar cada detalhe do processo de avaliação. A figura 33 apresenta o layout inicial do modelo.

Figura 34 - *Layout* inicial da execução do *Chronocast* no VSCode.



```
1  #Cronocast
2  #Modelo de Avaliação de Alertas da Defesa Civil de Santa Catarina
3
4  # Backprop on the Seeds Dataset
5  from random import seed
6  from random import randrange
7  from random import random
8  from csv import reader
9  from math import exp
10 import os
11 import pdb
12
13 # Load a CSV file
14 def load_csv(filename):
15     dataset = list()
16     with open(filename, 'r') as file:
17         csv_reader = reader(file)
18         for row in csv_reader:
19             if not row:
20                 continue
21             dataset.append(row)
22     return dataset
23
24 # Convert string column to float
25 def str_column_to_float(dataset, column):
26     for row in dataset:
27         row[column] = float(row[column].strip())
28
29 # Convert string column to integer
30 def str_column_to_int(dataset, column):
31     class_values = [row[column] for row in dataset]
32     unique = set(class_values)
33     lookup = dict()
34     for i, value in enumerate(unique):
35         lookup[value] = i
36     for row in dataset:
```

O modelo inclui funcionalidades para o tratamento de desbalanceamento de dados, utilizando técnicas de *oversampling* como o *SMOTE*, garantindo que as previsões sejam equilibradas e representativas das diferentes condições de risco. Esse enfoque não apenas aumenta a precisão das previsões, mas também contribui significativamente para a eficiência operacional da Defesa Civil ao emitir seus alertas pelo sistema *Nowcasting*.

## 7.5 AVALIAÇÃO DE TECNOLOGIA INSTITUCIONAL

O relatório técnico conclusivo, intitulado Avaliação de Tecnologia Institucional, constitui um produto tecnológico essencial desenvolvido como parte da pesquisa. Este documento oferece uma análise abrangente e detalhada dos resultados obtidos pelo modelo de previsão que avalia a efetividade dos alertas de desastres emitidos pela Defesa Civil de Santa Catarina. Este relatório desempenha um marco insigne na comunicação dos avanços tecnológicos na gestão dos riscos de desastres no âmbito catarinense, servindo como uma ferramenta de referência para a melhoria contínua dos processos de alerta (figura 34).

Figura 35 - Imagem ilustrativa do Relatório Técnico Conclusivo sobre os resultados da avaliação dos alertas da Defesa Civil de Santa Catarina.

# EFETIVIDADE


## DOS ALERTAS DA DEFESA CIVIL EM SANTA CATARINA



INSTITUTO FEDERAL  
Santa Catarina  
Câmpus Florianópolis

### RELATÓRIO TÉCNICO CONCLUSIVO

ANDRÉ FRANCISCO PUGAS



### AVALIAÇÃO DO IMPACTO EM 24 CIDADES

E como os alertas impactam as diferentes mesorregiões do  
Estado



Fonte: Próprio autor, 2024.

O relatório inclui uma descrição dos métodos utilizados, incluindo de maneira sucinta a arquitetura do modelo *Chronocast*, a integração de dados, os procedimentos de treinamento e as estratégias de validação empregadas. Além disso, apresenta uma análise estatística dos resultados e a comparação entre os resultados do modelo e da Defesa Civil, destacando as taxas de precisão, a eficácia na predição de danos, e como esses se comparam com as métricas históricas da Defesa Civil.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABDULLAHI, Salami Ifedapo; HABAEBI, Mohamed Hadi; MALIK, Noreha Abdul. Flood disaster warning system on the go. In: **Proceedings of The 2018 7th International Conference on Computer and Communication Engineering (ICCCE)**. IEEE, 2018. p. 258-263. <https://doi.org/10.1109/ICCCE.2018.8539253>

AÍMOLA, Luís; ALBUQUERQUE, Monik. A Influência do Modo Anular Sul sobre o Ciclo do Carbono no Oceano Sul: Uma breve revisão do conhecimento atual. **Revista Brasileira de Climatologia**. v. 18, p. 1 - 10, Jan/Jun. 2016. <https://doi.org/10.5380/abclima.v18i0.43746>.

AGUIAR, Guilherme de Oliveira, SILVA, Victor Rodrigues. **Sistema de previsão climática baseado em Machine Learning**. 117 p. Monografia (Graduação em Engenharia de Software). Universidade de Brasília - UnB, Faculdade UnB Gama - FGA, Distrito Federal, 2022.

AGUIRRE, Rosa Carolina Zamora. **Processos de Desertificação Associados a Pastagens no Chile para o Clima Presente e Futuro**. 2020. 101 f. Tese (doutorado) - Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2020.

AKERKAR, S., AYERS, J., BOSWELL, C., DECOSTER, M., JIMERSON, A., WOODSIDE ALEGRE, L. Early Warning for Early Action: Toward More Behaviorally Informed Early Warning Systems. Resilience Evaluation, Analysis and Learning (REAL) Associate Award. Washington, DC, p. 58, Nov. 2020.

ALASALI, F.; TAWALBEH, R.; GHANEM, Z.; MOHAMMAD, F.; ALGHAZZAWI, M. A Sustainable Early Warning System Using Rolling Forecasts Based on ANN and Golden Ratio Optimization Methods to Accurately Predict Real-Time Water Levels and Flash Flood. *Sensors*. v. 21, n. 13, p. 4598, Jul. 2021. <https://doi.org/10.3390/s21134598>

ALIMONTI, Gianluca; MARIANI, Luiz; PRODI, Franco; RICCI, Renato Ângelo. A critical assessment of extreme events trends in times of global warming. **The**

**European Physical Journal Plus.** v. 137, p. 112, Jan. 2022.  
<https://doi.org/10.1140/epjp/s13360-021-02243-9>

ALI-TALESCHI, Mohammad Saleh; RIYABI BAKHTIARI, Alireza; HOPKE, Philip K. Meteorologically normalized spatial and temporal variations investigation using a machine learning-random forest model in criteria pollutants across Tehran, Iran. **Urban Climate.** v. 53, p. 101790, 2024. <https://doi.org/10.1016/j.uclim.2023.101790>

ALVES, R.C.M.; SOUZA, L.P.; MOLLMANN, R.A.; RODRIGUES, B.D. **Descrição e Caracterização dos Fenômenos Atmosféricos mais Frequentes no Território Brasileiro.** Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ). Rio Grande do Sul, 2015. 82 p.

AMS. American Meteorological Society. Cyclone. **Meteorological Glossary.** Disponível em: <https://glossary.ametsoc.org/wiki/Cyclone> Acesso em 25 Dez. 2022.

AMS. American Meteorological Society. Microscale Meteorology. **Meteorological Glossary.** Disponível em: <https://glossary.ametsoc.org/wiki/Cyclone> Acesso em 25 Dez. 2022.

ANDERSON, T.R.; HAWKINS, E.; JONES, P.D. CO<sub>2</sub>, the greenhouse effect and global warming: from the pioneering work of Arrhenius and Callendar to today's Earth System Models. **Endeavour.** v. 40, n. 3, p. 178 - 187, Set. 2016.  
<https://doi.org/10.1016/j.endeavour.2016.07.002>

ANJOMSHOAA, Amin; CURRY, Edward. Inter-space Machine Learning in Smart Environments. In: HOLZINGER, Andreas; KIESEBERG, Peter; TJOA, A Min; WEIPPL, Edgar (Eds.). **Machine Learning and Knowledge Extraction.** Cham: Springer International Publishing, 2020. p. 535-549. ISBN 978-3-030-57321-8.  
[https://doi.org/10.1007/978-3-030-57321-8\\_30](https://doi.org/10.1007/978-3-030-57321-8_30)

ASSUNÇÃO, Viviane Kraieski de. Enchente de 1974 como drama social: relações entre percepção de risco, conflito e gentrificação. **Ambiente & Sociedade,** v. 17, n. 4, p. 195 - 212, São Paulo, Dez. 2014.  
<https://doi.org/10.1590/1809-4422ASOC1109v1742014>

AVILA, Maria Roseli Rossi; MATTEDI, Marcos Antonio. Disaster and territory: the production of vulnerability to disasters in the city of Blumenau/SC. **URBE. Revista Brasileira de Gestão Urbana**. v. 09, n. 02, p. 187 - 202, Mar. 2017.

<https://doi.org/10.1590/2175-3369.009.002.AO03>.

AYOADE, Johnson Olaniyi. **Introdução à Climatologia para os Trópicos**. Ed. 10. São Paulo: Editora Bertrand Brasil, 18 Out. 1994. ISBN 978-8528604276

BACK, Alvaro José; CORSEUIL, C. W.; GONÇALVES, F. N.; BACK, L.; LADDWIG, N. I. Análise de Tendências nas séries de Precipitação das Regiões Hidrográficas de Santa Catarina. **XXII Simpósio Brasileiro de Recursos Hídricos**, Florianópolis, p. 1 - 8, 2017.

BACK, Alvaro José; SOUZA, Gavriel da Silva; PANATTO, Marina Patricio. Chuvas Intensas para Dimensionamento de Calhas e Condutores Pluviais no Estado de Santa Catarina. **Agropecuária Catarinense**. v. 36, n. 2, p. 34 - 41, Maio 2023.

<http://doi.org/10.52945/rac.v36i2.1579>

BÁEZ PRIETO, Raidel. **Mapeamento Multiescalar de Áreas Suscetíveis a Chuvas Persistentes, Extremas e Abrangentes em Santa Catarina entre 1986-2016**. 114 p. 2022. Tese (Doutorado em Planejamento Territorial e Desenvolvimento Socioambiental), Universidade do Estado de Santa Catarina - UDESC, Florianópolis, 2022.

BALICKI, M.; ANDRADE, A. R. DE; HORNES, K. L. Fatores dinâmicos locais e ocorrências de tempestades com granizo. **Boletim de Geografia**. v. 40, p. 37-52, e60413, 13 maio 2022. <https://doi.org/10.4025/bolgeogr.v40.a2022.e60413>

BAPTISTA, G.Z.Z.; PINHEIRO, A. KAUFMANN, V. **Mudança na Tendência em Séries de Precipitação em Santa Catarina devido à Oscilação Interdecadal Do Pacífico**. In: Conference: XXII Simpósio Brasileiro de Recursos Hídricos. Florianópolis, Dez. 2017.

BARBOSA, T. F.; CORREIA, M. F. Sistemas Convectivos Intensos no Semiárido Brasileiro: o controle da grande escala. **Revista Brasileira de Meteorologia**. v. 20, n. 3, p. 395 - 410, Jan. 2005.

BARROS, S. S., OYAMA, M. D. Sistemas meteorológicos associados à ocorrência de precipitação no centro de lançamento de Alcântara. **Revista Brasileira de Meteorologia**. v. 25, n. 3, p. 333 - 344. Set. 2010.

<https://doi.org/10.1590/S0102-77862010000300005>

BECKER-RESHEF, I.; JUSTICE, C.; SULLIVAN, M.; VERMOTE, E.; TUCKER, C.; ANYAMBA, A.; SMALL, J.; PAK, E.; MASUOKA, E.; SCHMALTZ, J.; HANSEN, J.; PITTMAN, K.; BIRKETT, C.; WILLIAMS, D.; REYNOLDS, C.; DOORN, B. Monitoring Global Croplands with Coarse Resolution Earth Observations: The Global Agriculture Monitoring (GLAM) Project. *Remote Sensing*. v.2, p. 1589 - 1609, Jun. 2010.

<https://doi.org/10.3390/rs2061589>

BARCELLOS, P.C.L.; SILVA, F.P.; VISSIRINI, F.S.B.; MAGALHÃES, C.A.; TERRA, J.M.; DUTRA, M.R.F.; AMARAL, I.C.F. Diagnóstico Meteorológico dos Desastres Naturais Ocorridos nos Últimos 20 Anos na Cidade de Duque de Caxias. **Revista Brasileira de Meteorologia**, v. 31, n. 3, p. 319-329, 08 Mar.2016.

BARCELLOS, DEISE RODRIGUES; QUADRO, MÁRIO FRANCISCO LEAL DE. Classificação de Eventos Extremos de Precipitação quanto sua Intensidade, Persistência e Abrangência na Região das ZCAS. **Metodologias e Aprendizado**. v. 2, p. 76 - 81, Nov. 2019.

BARRETTO, Ubiraci Alves Muniz; NOVAIS, Renato Lima; BARBOSA, Frederico Jorge Ribeiro. Uma Análise Visual da Espacialização das Descargas Elétricas Atmosféricas e do Comportamento das Mortes Causadas por Raios no Estado da Bahia. **Revista Brasileira de Geografia Física**. v. 14, n. 4, p. 1909 - 1923, Jun. 2021. ISSN:1984-2295

BASHER, Reid. Global early warning systems for natural hazards: systematic and people-centred. **Philosophical Transactions of The Royal Society A**. n. 364, p. 2167-2182, 28 Jun. 2006. <http://doi:10.1098/rsta.2006.1819>

BELYADI, Hoss; HAGHIGHAT, Alireza. Chapter 5 - Supervised learning. In: **Machine Learning Guide for Oil and Gas Using Python: A Step-by-Step Breakdown with**

**Data, Algorithms, Codes and Applications**. 2021. p. 169-295.

<https://doi.org/10.1016/B978-0-12-821929-4.00004-4>.

BEREZUK, André Geraldo. Eventos Extremos: Estudo da chuva de granizo de 21 de abril de 2008 na cidade de Maringá-PR. **Revista Brasileira de Climatologia**. p. 153 - 164, Set. 2009. <http://dx.doi.org/10.5380/abclima.v5i0.50483>

BERZ, W.; KRON, G.; LOSTER, T.; RAUCH, E.; SCHIMETSCHKE, J.; SCHMIEDER, J.; SIEBERT, A.; SMOLKA, A.; WIRTZ, A. World map of natural hazards – a global view of the distribution and intensity of significant exposures. **Natural Hazards**. v. 23, p. 443 – 465, 2001. <https://doi.org/10.1023/A:1011193724026>

BEZERRA, Breno Pacely de Souza. **Impactos dos eventos de El Niño e La Niña fortes no regime de precipitação no Nordeste brasileiro: uma revisão**. 2023. 54 f. Monografia (graduação) - Universidade Federal do Rio Grande do Norte, Centro de Ciências Exatas e da Terra, Departamento de Ciências Atmosféricas e Climáticas, Curso de Bacharelado em Meteorologia. Natal, RN, 2023.

BI, Kaifeng; XIE, Lingxi; ZHANG, Hengheng; CHEN, Xin; GU, Xiaotao. Accurate medium-range global weather forecasting with 3D neural networks. **Nature**, v. 619, p. 533 - 538, 2023. <https://doi.org/10.1038/s41586-023-06185-3>.

BITENCOURT, Daniel Pires; FUENTES, Márcia Vetromilla.; MAIA, Paulo Alves; AMORIM, Fabiano Tigueiro. Frequência , Duração , Abrangência Espacial e Intensidade das Ondas de Calor no Brasil. **Revista Brasileira de Meteorologia**. v. 31, n. 4, p. 506–517, Dez. 2016. <https://doi.org/10.1590/0102-778631231420150077>

BLANK, D. M. P. The context of climate changes and its victims. **Mercator**, Fortaleza, v. 14, n. 2, p. 157-172, mai./ago. 2015. DOI: 10.4215/RM2015.1402. 0010

BLUM, Jeffrey R.; EICHHORN, Alexander; SMITH, Severin; CONTALA, Michael Sterle; COOPERSTOCK, Jeremy R. Real-time emergency response: improved management of real-time information during crisis situations. **Journal of Multimodal User Interfaces**. v. 8, p. 161-173, Jun. 2014. <https://doi.org/10.1007/s12193-013-0139-7>

BOUWER, L.M. **Disasters and climate change: analyses and methods for projecting future losses from extreme weather**. 144 p. 2010. Tese, Institute for Environmental Studies (IVM), Amsterdã, Holanda, 2010.

BRASIL. Instrução normativa n.º 1, de 24 de agosto de 2012. Disponível em: <[http://www.mi.gov.br/c/document\\_library/get\\_file?uuid=822a4d42-970b-4e80-93f8-dae395a52d1&groupId=301094](http://www.mi.gov.br/c/document_library/get_file?uuid=822a4d42-970b-4e80-93f8-dae395a52d1&groupId=301094)>. Acesso em: 18 fev. 2021.

BRASIL. Política Nacional de Proteção e Defesa Civil - PNPDEC. Brasília. Lei Federal nº 12.608. Presidência da República, 2012b. Disponível em: ([http://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2012/lei/l12608.htm](http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12608.htm)) Acesso: 18 fev. 2021.

BRASIL. Agência Nacional de Telecomunicações. RJ, RS e ES passam a contar com serviço de alerta de desastres naturais por SMS. Brasília. 03 Jan. 2018. Disponível em: (<https://www.gov.br/anatel/pt-br/assuntos/noticias/rj-rs-e-es-passam-a-contar-com-servico-de-alerta-de-desastres-naturais-por-sms>) Acesso: 15 Ago. 2021.

BRASIL. Ministério do Desenvolvimento Regional. **Guia Prático de Utilização de Alertas do Governo Federal para Ações de Preparação para Desastres**. 1 ed. Brasília: PNUD Brasil, 2021.

BRASIL. Ministério da Integração e do Desenvolvimento Regional. Secretaria de Proteção e Defesa Civil. Universidade Federal de Santa Catarina. Centro de Estudos e Pesquisas em Engenharia e Defesa Civil. **Atlas Digital de Desastres no Brasil**. Brasília: MIDR, 2023.

Breiman, L. Random Forests. *Machine Learning*, v. 45, n. 1, p. 5-32, out. 2001. <https://doi.org/10.1023/A:1010933404324>

BRIZOLLA, Mayara Carvalho; CARDOSO, Camila de Souza; FRANKE, Alberto Elvino. A Influência dos Jatos de Baixos Níveis da América do Sul no Regime Pluviométrico do Verão no Oeste de Santa Catarina. In: **XIII Simpósio Brasileiro de Climatologia Geográfica**, 6 a 10 de novembro de 2018, Juiz de Fora - MG, 2018.

BROSKA, Lisa Hanna; POGANIETZ, Witold-Roger; VÖGELE, Stefan. Extreme events defined - A conceptual discussion applying a complex systems approach. **Futures**. v. 115, Jan. 2020. ISSN 0016-3287.

<https://doi.org/10.1016/j.futures.2019.102490>

BROWNLEE, Jason. **Data Preparation for Machine Learning: Data Cleaning, Feature Selection, and Data Transforms in Python**. Machine Learning Mastery, 2020.

CALSTER, G.V.; REINS, L. **The Paris Agreement on Climate Change: A Commentary**. Ed. 1, Cheltenham, UK: Edward Elgar. 2021.

CARDOSO, Daniel. **Enchentes, deslizamentos e a sociedade em rede: um estudo sobre o fluxo de informação em desastres naturais a partir do caso de Petrópolis 2013**. 132 p. 2015. Dissertação (Mestrado em Ciência da Informação), Universidade Federal de Santa Catarina, Florianópolis, 2015.

CARDOSO, Camila de Souza; QUADRO, Mario Francisco Leal de.; BONETTI, Carla. Persistência e Abrangência dos Eventos Extremos de Precipitação no Sul do Brasil: Variabilidade Espacial e Padrões Atmosféricos. **Revista Brasileira de Meteorologia**, v. 35, n. 2, p. 219–231, abr. 2020.

CARPENEDO, Camila Bertoletti; AMBRIZZI, Tercio. Anticiclone Subtropical do Atlântico Sul Associado ao Modo Anular Sul e Impactos Climáticos no Brasil. **Revista Brasileira de Meteorologia**, v. 35, n. 4, p. 605–613, out. 2020.

CARPENEDO, Camila Bertoletti; DA SILVA, Carlos Batista. Influência de Teleconexões na Precipitação Pluvial do Cerrado Brasileiro. **Revista Brasileira de Climatologia**. v. 30, n. 18, p. 26–46, Fev. 2022. DOI: 10.55761/abclima.v30i18.14607. Disponível em: <https://ojs.ufgd.edu.br/index.php/rbclima/article/view/14607>. Acesso em: 21 fev. 2024.

CAVALCANTI, Iracema Fonseca de Albuquerque; FERREIRA, Nelson Jesus; SILVA DIAS, Maria Assunção Faus; JUSTI, Maria Gertrudes Alvarez. **Tempo e clima no Brasil**. São Paulo: Oficina de Textos, 2009, 463 p.

CHASE, Randy; HARRISON, David; BURKE, Amanda; LACKMANN, Gary; MCGOVERN, Amy. A machine learning tutorial for operational meteorology. Part I: Traditional machine learning. **Weather and Forecasting**. v. 37, p. 1509-1529, 01 ago. 2022. <https://doi.org/10.1175/WAF-D-22-0070.1>

CHEN, S.; CHEN, W.; YING, J.; ZHENG, Y.; LAN, X. Interdecadal Modulation of the Pacific Decadal Oscillation on the Relationship Between Spring Arctic Oscillation and the Following Winter ENSO. **Frontiers in Earth Science**. v. 9, Fev. 2022. <https://doi.org/10.3389>

CHILE. La Oficina Nacional de Emergencia del Ministerio del Interior y Seguridad Pública - ONEMI. Centro de Alerta Temprana - CAT. 2022. Disponível em: <<https://www.onemi.gov.cl/cat/>> Acesso em: 12 Dez. 2022.

CHMUTINA, Ksenia; MEDING, Jason von. A Dilemma of Language: “Natural Disasters” in Academic Literature. **International Journal Disaster Risk Science**. v. 10, p. 283 - 292, Set. 2019. <https://doi.org/10.1007>

CLIMATE ADAPT. Sharing Adaptation Knowledge for a Climate Resilient Europe. European Early warning Systems. Disponível em: <<https://climate-adapt.eea.europa.eu/en/observatory/evidence/health-early-systems/european-early-warning-systems>>. Acesso em: 18 Jan. 2022.

CLIMATEMPO. Meteorologia. Zona de Convergência Intertropical e os temporais no Nordeste. São Paulo, 24 Mar. 2015. Disponível em: [https://www.youtube.com/watch?v=SHbQbII\\_7wQ](https://www.youtube.com/watch?v=SHbQbII_7wQ) Acesso em 12 Dez. 2022.

COHEN, Julia C.P. e SILVA DIAS, Maria Assunção Faus da; NOBRE, Carlos A. **Environmental conditions associated with amazonian squall lines: a case study**. Monthly Weather Review, v. 1995, n. 11, p. 3163-3174, Nov. 1995.

COLLYMORE, Jeremy. Early Warning Systems in the Caribbean: A Desk Review (Final Report) – Feb 2016. 86p.

COLUCCI, Stephen J. Synoptic Meteorology | Anticyclones. **Encyclopedia of Atmospheric Sciences**. 2 ed, v. 5, p. 273 - 279, 2015. <https://doi.org/10.1016/B978-0-12-382225-3.00071-2>

COOLS, Jan; INNOCENTI, Demetrio; O'BRIEN, Sarah. Lessons from flood early warning systems. **Environmental Science & Policy**. v. 58, p. 117 - 122, Fev. 2016. <http://dx.doi.org/10.1016/j.envsci.2016.01.006>

COUTO, Flávio; SALGADO, Rui. **Modelação de Descargas Elétricas Atmosféricas com Modelo de Investigação de Alta Resolução Espacial**. Relatório técnico do Instituto de Ciências da Terra - ICT, 2019, 44pp.

CUPOLILLO, Fulvio. **Diagnóstico Hidroclimatológico da Bacia do Rio Doce**. 1ª. ed. Saarbrücken - Alemanha: Novas Edições Acadêmicas, 2015. v. 1. 224p.

CVASNIUC, Artiom. **Plataforma de Alerta Meteorológico – Membro integrante do Projeto Meteoalarm**. Orientador: Lucia Stadler. 2018. 55 f. Mestrado (Programa de Estudos em Gestão de Aplicação de Informações) - Universidade Tecnológica da Moldavia, Kishinev, 2020.

CZOCHER, Jennifer Ann. How does validating activity contribute to the modeling process? **Educational Studies in Mathematic**. v. 99, n. 2, p. 137-159, Ago. 2018. <https://doi.org/10.1007/s10649-018-9833-4>

LARY, David J.; ALAVI, Amir H.; GANDOMI, Amir H.; WALKER, Annette L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**. v. 7, n. 1, p.3 - 10, Jan. 2016. <https://doi.org/10.1016/j.gsf.2015.07.003>

DCSC A. Defesa Civil de Santa Catarina. **PRC.OP.025.1709**: Procedimento Operacional Gerar e Transmitir Alertas Hidrometeorológicos. Florianópolis: Defesa Civil de Santa Catarina, 29 Abr. 2019.

DCSC B. Defesa Civil de Santa Catarina. **PRC.OP.026.1709**: Procedimento Operacional Gerar e Transmitir Avisos Hidrometeorológicos. Florianópolis: Defesa Civil de Santa Catarina, 29 Abr. 2019.

DCSC C. Defesa Civil de Santa Catarina. **PRC.OP.028.1709**: Procedimento Operacional Elaborar Boletim Diário de Monitoramento. Florianópolis: Defesa Civil de Santa Catarina, 29 Mar. 2019.

DCSC D. Defesa Civil de Santa Catarina. **PRC.OP.030.1903**: Procedimento Operacional Realizar o Monitoramento de Risco Hidrometeorológico e Climático. Florianópolis: Defesa Civil de Santa Catarina, 29 Mar. 2019.

DE JESUS, E.M.; ROCHA, R.P.; CRESPO, N.M.; REBOITA, M.S.; GOZZO, L.F.. Future climate trends of subtropical cyclones in the South Atlantic basin in an ensemble of global and regional projections. **Climate Dynamics**, v. 58, p. 1221 - 1236, Fev. 2022. <https://doi.org/10.1007/s00382-021-05958-8>

DONG, Xin Luna; SRIVASTAVA, Divesh. **Big Data Integration**. 1. ed. Synthesis Lectures on Data Management, 40. San Rafael: Morgan & Claypool, 2014. 178 p. ISBN 978-1627052238.

DOSHI-VELEZ, Finale; KIM, Been. Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*, 28 fev. 2017. Disponível em: <https://arxiv.org/abs/1702.08608>. Acesso em: 25 Mar. 2024.

DOWDY, Andrew J.; MILLS, Graham A. Atmospheric and fuel moisture characteristics associated with lightning-attributed fires. **Journal of Applied Meteorology and Climatology**. v. 51, p. 2025 - 2037, Jun. 2012. <https://doi.org/10.1175/JAMC-D-11-0219.1>

DRAKAKI, Maria; GÖREN, Hacer Güner; TZIONAS, Panagiotis. An intelligent multi-agent based decision support system for refugee settlement siting. **International Journal of Disaster Risk Reduction**. v. 31, p. 576–588, Out. 2018. <https://doi.org/10.1016/j.ijdrr.2018.06.013>

DUARTE, Laís Gonçalves Fernandes. **O fenômeno El Niño-Oscilação Sul e os eventos extremos de precipitação em Santa Catarina**. 2017. 86 f. Tese (doutorado) - Universidade Federal de Santa Catarina, Centro de Filosofia e Ciências Humanas, Programa de Pós-Graduação em Oceanografia, Florianópolis, 2017.

DUARTE, Marciel Lelis; RIBEIRO, Aristides. Influência do El Niño e La Niña na produtividade de plantios de Eucalipto em distintas regiões no Brasil. **Ciência Florestal**, v. 33, n. 1, p. e61334, 2023. <https://doi.org/10.5902/1980509861334>

DURÁN-QUESADA, A.M.; REBOITA, M. S.; GIMENO, L. Precipitation in tropical America and the associated sources of moisture: a short review. **Hydrological Sciences Journal**, v. 57, n. 4, p. 1 - 13, Abr. 2012. <https://doi.org/10.1080/02626667.2012.673723>

DURKEE, J. D.; MOTE, T. L. A climatology of warm-season mesoscale convective complexes in subtropical South America. **International Journal of Climatology**. v. 30, n. 3, p. 418 - 431, Mar. 2010. <https://doi.org/10.1002/joc.1893>

EASTERLING, D. R.; MEEHL, G. A.; PARMESAN, C.; CHANGNON, S. A.; KARL, T. R.; MEARNS, L. O. Climate extremes: observations, modeling, and impacts. **Science**. v. 289, n. 5487, p. 2068 - 2074, Set. 2000. <http://doi.org/10.1126/science.289.5487.206>

EBI, K. L., VANOS, J., BALDWIN, J. W., BELL, J. E., HONDULA, D. M., ERRETT, N. A., HAYES, K., REID, C. E., SAHA, S., SPECTOR, J., & BERRY, P. Extreme Weather and Climate Change: Population Health and Health System Implications. **Annual Review of Public Health**. v. 42, p. 293 - 315, Abr. 2021. <https://doi.org/10.1146/annurev-publhealth-012420-105026>

EGUCHI, Branco; ALBINO, Jacqueline. INFLUÊNCIA DOS MODOS DE VARIABILIDADE CLIMÁTICA SOBRE EVENTOS DE RESSACAS NO LITORAL SUL DO ESPÍRITO SANTO, BRASIL. **Revista Brasileira de Climatologia**. v. 28, p. 165–183, Jan/Jun. 2021. Disponível em: <https://ojs.ufgd.edu.br/index.php/rbclima/article/view/14344>. Acesso em: 21 fev. 2024.

EPAGRI/CIRAM. Chuva do Litoral resulta em quebra de recorde histórico em Florianópolis. *Relatorio Tecnico*, 17 abr. 2024. Disponível em: <https://ciram.epagri.sc.gov.br/index.php/2024/04/17/chuva-do-litoral-resulta-em-quebra-de-recorde-historico-em-florianopolis/>. Acesso em: 15 mar. 2024.

ESPINDOLA, Marco Aurelio; NODARI, Eunice Sueli. Unexpected flooding? Vulnerabilities and public policies in Rio do Sul – SC, Brazil. **Revista Esboços**, Florianópolis, v. 20, n. 30, p. 9 - 34, Dez. 2013. <http://dx.doi.org/10.5007/2175-7976.2013v20n30p9>

ESCOBAR, G.C.J.; SELUCHI, M.E.; ANDRADE, K. Classificação Sinótica de Frentes Frias Associadas a Chuvas Extremas no Leste de Santa Catarina (SC). **Revista Brasileira de Meteorologia**. v. 31, n. 4(suppl.), p. 649 - 661, Fev. 2016. <http://dx.doi.org/10.1590/0102-7786312314b20150156>

ESCOBAR, Gustavo Carlos Juan. **Zona De Convergência do Atlântico Sul (ZCAS): Critério de Detecção para Uso em Centros Operacionais de Previsão de Tempo**. 2019. 19f. Relatório Técnico - Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2019.

EUMETNET. European Meteorological Services Network. Improving Meteorological Services Together. Brochure Report, v. 2, 2019. Disponível em: <<https://www.eumetnet.eu/wp-content/uploads/2020/11/Eumetnet-Online-V2.pdf>> Acesso em: 18 Jan 2022.

FAGUNDES, Cintia Luciane de Quadros. **Climatologia e Projeções de Ondas de Calor nas Capitais do Sul do Brasil**. 2019. 52 f. Dissertação (Mestrado em Desastres naturais) Universidade Federal de Santa Catarina - UFSC, Florianópolis - SC, 2019.

FAVERO, E.; SARRIERA, J.C.; TRINDADE, M.C. O Desastre na Perspectiva Sociológica e Psicológica. **Psicologia em Estudo**, Maringá, v. 19, n. 2, p. 201-209, abr./jun. 2014. <http://dx.doi.org/10.1590/1413-737221560003>

FEMA. Federal Emergency Management Agency. **The Integrated Public Alert and Warning System (IPAWS) Program Management Office**. Strategic Plan Fiscal Year 2022-2026. Washington, D.C., 2022, 24p.

FOKEN, Thomas. Micrometeorology. 2ª Ed., Berlim, Alemanha: Springer, Out. 2017. <https://doi.org/10.1007/978-3-642-25440-6>

FERREIRA, A. G., MELLO, N. G. S. Principais sistemas atmosféricos atuantes sobre a região nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região. **Revista Brasileira de Climatologia**. v. 1, p. 15 - 28. Dez. 2005.

FERREIRA, RUTE COSTA. **Estudo de sistemas convectivos de mesoescala com uso de assimilação de dados de radar**. 2016. 123 f. Dissertação (Mestrado em Meteorologia) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos - SP, 2016.

FERREIRA, Nelson Jesus; CAVALCANTI, Iracema Fonseca de Albuquerque. **Sistemas meteorológicos atuantes no Brasil**. São Paulo : Oficina de Textos, 2022. ISBN 978-65-86235-52-4

FONSECA, Murilo Noli da; FERENTZ, Larissa Maria da Silva. Ocorrência de Vendavais no Estado do Paraná: um panorama entre 2013 e 2017. **Revista nacional de Gerenciamento de Cidades**. v. 8, n. 57, p. 62 - 78, 2020. ISSN 2318-8472.

FONSECA, Xavier; MIGUEZ-MACHO, Gonzalo; CORTES-VAZQUEZ, José A.; VAAMONDE, Antonio. A physical concept in the press: the case of the jet stream. **Geoscience Communication**. , v. 5, n. 3, p. 177 – 188, Jul. 2022. <https://doi.org/10.5194/gc-5-177-2022>

FREITAS, Carlos Machado De; XAVIER SILVA, Diego Ricardo; SENA, Aderita Ricarda Martins de; SILVA, Eliane Lima; SALES, Luiz Belino Ferreira; CARVALHO, Mauren Lopes de; MAZOTO, Maíra Lopes; BARCELLOS, Christovam; COSTA, André Monteiro, OLIVEIRA, Mara Lúcia Carneiro; CORVALÁN, Carlos. Desastres naturais e saúde: uma análise da situação do Brasil. **Ciência & Saúde Coletiva**. v. 19, n. 9, p. 3645 - 3656, Set. 2014. <https://doi.org/10.1590/1413-81232014199.00732014>

GANTEAUME, Anne.; SYPHARD, Alexandra D. Ignition Sources. In: MANZELLO, Samuel L. (Ed.). **Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires**. Cham: Springer, 2018. p. 1-12. [https://doi.org/10.1007/978-3-319-51727-8\\_43-1](https://doi.org/10.1007/978-3-319-51727-8_43-1)

GAN, M.A.; MORAIS, M.D.C.; FERREIRA, N.J.; VALVERDE, M.C. Vórtices Ciclônicos de Altos Níveis que atuam na vizinhança do Nordeste do Brasil. *In*: FERREIRA, Nelson Jesus; CAVALCANTI, Iracema Fonseca de Albuquerque. **Sistemas meteorológicos atuantes no Brasil**. São Paulo : Oficina de Textos, 2022. ISBN 978-65-86235-52-4

GARCÍA, Salvador; LUENGO, Julián; HERRERA, Francisco. **Data Preprocessing in Data Mining**. Intelligent Systems Reference Library. Cham: Springer, 2015. <https://doi.org/10.1007/978-3-319-10247-4>.

GERMANO, Alaerte da Silva. **Aspectos Sinóticos de Vórtices Ciclônicos em Altos Níveis que Provocaram Precipitações Extremas nas Cidades de Recife, Maceió e Aracaju no Período de 2011 à 2015: estudo de Casos**. 2016. 88 f. Dissertação (Mestrado em Meteorologia) Universidade Federal de Alagoas - UFA, Maceió - AL, 2016.

GFDRR. **Machine Learning for Disaster Risk Management**. Washington, DC: GFDRR, 2018. License: Creative Commons Attribution CC BY 3.0. Disponível em: [https://www.gfdr.org/sites/default/files/publication/181222\\_WorldBank\\_DisasterRiskManagement\\_Ebook\\_D6.pdf](https://www.gfdr.org/sites/default/files/publication/181222_WorldBank_DisasterRiskManagement_Ebook_D6.pdf) Acesso em: 15 Out. 2023.

GIEHL, A.L.; LUCA, F.V. de; PADRÃO, G.de A.; REITER J.M.W.; ALVES, J.R.; GUGEL, J.T.; MONDARDO, M.; GOULART JÚNIOR, R.; MARCONDES, T. **Efeitos socioeconômicos causados pelo ciclone extratropical no estado de Santa Catarina em 2020**. Florianópolis: Epagri, 2020, 57p. (Epagri. Documentos, 318).

GOMES, H.B.; AMBRIZZI, T.; PONTES DA SILVA, B.F.; HODGES, K.; SILVA DIAS, P.L.; HERDIES, D.L.; SILVA, M.C.L.; GOMES, H.F.B. Climatologia das perturbações das ondas de leste sobre o Atlântico Sul tropical. **Climate Dynamics**. v. 53, p. 1393 - 1411, Fev. 2019. <https://doi.org/10.1007/s00382-019-04667-7>

GONÇALVES, Fabiane Nunes. **Índices de precipitação para o estado de Santa Catarina**. 2017. 202f. Dissertação (Mestrado em Ciencias Ambientais) - Universidade do Extremo Sul Catarinense, Programa de Pós-Graduação em Ciências Ambientais, Criciúma, 2017.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: The MIT Press, 2016. ISBN 9780262035613.

GOZZO, L.F.; ROCHA, R.P.; GIMENO, L.; DRUMOND, A. Climatology and numerical case study of moisture sources associated with subtropical cyclogenesis over the southwestern Atlantic Ocean. **Journal of Geophysical Research: Atmospheres**, v. 122, n. 11, p. 5636 - 5653, Mai. 2017. <https://doi.org/10.1002/2016JD025764>

GUERRA, Sidney. Climate changes as global catastrophe and the global refugee. **Journal of Institutional Studies**. v. 7, n. 2, p. 537 - 559, Ago. 2021. <https://doi.org/10.21783/rei.v7i2.641>

GUIMARÃES, Paulo Cesar Vaz. As enchentes em Santa Catarina e o aprendizado em políticas públicas. **Casoteca de Gestão Pública**. Jan. 2012.

GUPTA, Ruchi; SHARMA, Anupama; ALAM, Tanweer. Building Predictive Models with Machine Learning. In: SINGH, Pushpa; MISHRA, Asha Rani; GARG, Payal. (Ed.). **Data Analytics and Machine Learning. Studies in Big Data**. v. 145. Singapore: Springer, 2024. p. 39 - 59. [https://doi.org/10.1007/978-981-97-0448-4\\_3](https://doi.org/10.1007/978-981-97-0448-4_3)

HAKIM, G.J. Cyclogenesis. **Encyclopedia of Atmospheric Sciences**. 2 ed, v. 5, p. 589 - 594, 2015. <http://dx.doi.org/10.1016/B978-0-12-382225-3.00129-8>

HAKIM, Gregory J.; PATOUX, Jérôme. *Weather: A Concise Introduction*. Cambridge: Cambridge University Press, 2017. ISBN 9781108404655.

HANSEN, Lars Peter. Central banking challenges posed by uncertain climate change and natural disasters. **Journal of Monetary Economics**. v. 125, p. 1 - 15, Set. 2021. <https://doi.org/10.1016/j.jmoneco.2021.09.010>

HEFFER, C.O. Rio de Janeiro City's Early Warning System for Heavy Rain. **ELLA Policy Brief**, Practical Action Consulting, Lima, Peru, p. 1-7, 01 Jan. 2013.

HERRMANN, Maria Lúcia de Paula. Levantamento dos desastres naturais ocorridos em Santa Catarina no período de 1980 a 2000. Florianópolis: IOESC, 2001. 89 p.

HERRING, S.C., CHRISTIDIS, N., HOELL, A., KOSSIN, J.P., SCHRECK C.J., STOTT, P.A. Explaining Extreme Events of 2016 from a Climate Perspective. **Special Supplement to the Bulletin of the American Meteorological Society**, v. 99, n. 1, p. 1-157, Jan. 2018.

HONGYU, Kuang; SANDANIELO, Vera Lucia Martins; JUNIOR, Gilmar Jorge de Oliveira. Principal Component Analysis: theory, interpretations and applications. **Engineering and Science**. v. 5, n. 1, p. 83 - 90, 2016. <https://doi.org/10.18607/ES20165053>

HOON OH, Chang. How do natural and man-made disasters affect international trade? A country-level and industry-level analysis. **Journal of Risk Research**. v. 20, n. 2, p. 195 - 217, Mai. 2015. <http://dx.doi.org/10.1080/13669877.2015.1042496>

HORITA, F. E., ALBUQUERQUE, J. P. D., MARCHEZINI, V. & MENDIONDO, E. M. M., Bridging the gap between decision making and emerging big data sources: an application of a model-based framework to disaster management in Brazil. **Decision Support Systems**, v. 97, p. 12-22, Mai. 2017. <https://doi.org/10.1016/j.dss.2017.03.001>

IMAN, Mohammadreza; ARABNIA, Hamid Reza; RASHEED, Khaled. A Review of Deep Transfer Learning and Recent Advancements. **Technologies**. v. 11, n. 2, p. 40, Fev. 2023. <https://doi.org/10.3390/technologies11020040>

INNESS, Peter Michael; DORLING, Steve. **Operational Weather Forecasting**. Nova Jersey: Wiley-Blackwell, 2013. ISBN 978-0-470-71159-0.

IPCC, AR6. The Intergovernmental Panel on Climate Change. **Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press, Cambridge, Reino Unido, 2021.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. **An Introduction to Statistical Learning: with Applications in R**. Springer Texts in Statistics. Nova York: Springer, 2021. <https://doi.org/10.1007/978-1-0716-1418-1>.

JONER, Késia; AVILA, Maria Roseli Rossi; MATTEDI, Marcos Antonio. Territoriality and disaster: the management of disasters in Brazil based on case study of Civil Defense in Santa Catarina. **URBE. Revista Brasileira de Gestão Urbana**, v. 13, Out. 2021. <https://doi.org/10.1590/2175-3369.013.e20200061>

KAHRAMAN, A.; KENDON, E.J.; CHAN, S.C.; FOWLER, H.J. Quasi-stationary intense rainstorms spread across Europe under climate change. **Geophysical Research Letters**. v. 48, n. 13, p. 1–11, 30 Jun. 2021. <https://doi.org/10.1029/2020GL092361>.

KAPLAN, Jed O.; LAU, Katie Hong-Klu. The WGLC global gridded Lightning climatology and time series. **Earth System Science Data**. v. 13, p. 3219 – 3237, Jul. 2021. <https://doi.org/10.5194/essd-13-3219-2021>.

NNENBERG, C. **Uma Visão Ampliada Sobre os Jatos de Baixos Níveis na América do Sul**. Dissertação (Mestrado em Meteorologia) Universidade Federal de Santa Maria - UFSM, Santa Maria, 2019.

KEENEY, J. H.J.; BUAN, S.; DIAMOND, L. Multi-Hazard Early Warning System of the United States National Weather Service. In: GOLNARAGHI, M. (eds) **Institutional Partnerships in Multi-Hazard Early Warning Systems**. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-642-25373-7\\_6](https://doi.org/10.1007/978-3-642-25373-7_6)

KELMAN, I.; GLANTZ, M.H. Early warning systems defined. *Reducing Disaster: Early Warning Systems For Climate Change*. p. 89-108, 27 Jan. 2014. [https://doi.org/10.1007/978-94-017-8598-3\\_5](https://doi.org/10.1007/978-94-017-8598-3_5)

KOBIYAMA, M. **Apostila da disciplina Hidrologia e Climatologia**. Florianópolis: UFSC/CTC/ENS/LabHidro, 2013.

KOBIYAMA, M.; MICHEL, G.P.; ENGSTER, E.C.; PAIXÃO, M.A. Historical analyses of debris Flow disaster occurrences and of their scientific investigation in Brazil. **Labor & Engenho**. v. 9, n. 4, p. 76 - 89, Out./Dez 2015.

KODERA, Y.; HAYASHIMOTO, N.; TAMARIBUCHI, K.; NOGUCHI, K.; MORIWAKI, K.; TAKAHASHI, R.; MORIMOTO, M.; OKAMOTO, K.; HOSHIBA, M. Developments

of the Nationwide Earthquake Early Warning System in Japan After the 2011  $M_w$  9.0 Tohoku-Oki Earthquake. **Frontiers in Earth Science**. n. 9:726045, 04 Out. 2021. <https://doi.org/10.3389/feart.2021.726045>

KOUSKY, Vernon E.; ANDRADE, Kelen M. Frentes Frias Sobre o Brasil. *In*: FERREIRA, Nelson Jesus; CAVALCANTI, Iracema Fonseca de Albuquerque. **Sistemas meteorológicos atuantes no Brasil**. São Paulo : Oficina de Textos, 2022. ISBN 978-65-86235-52-4

KOWALEK, Rosangela Maria; ALMEIDA, Lourdes Maria Werle. Um Olhar sobre a Validação em uma Atividade de Modelagem Matemática. **IX Encontro Paranaense de Modelagem na Educação Matemática**, Anais. União da Vitória, p. 1 - 15, 2022. ISBN 2674-7707

KULESHOV, Y.; INAPE, K.; WATKINS, A.B.; BEAR-CROZIER, A.; CHUA, Z.W.; XIE, P.; KUBOTA, T.; TASHIMA, T.; STEFANSKI, R.; KURINO, T. **Climate Risk and Early Warning Systems (CREWS) for Papua New Guinea**. *In*: ONDRASEK, Gabriel. Drought - Detection and Solutions. IntechOpen. <https://doi.org/10.5772/intechopen.85962>

KUMAR, A.; SPECK, R.M.; HONORÉ, C. **Global status of multi-hazard early warning systems: Target G**. United Nations Office for Disaster Risk Reduction and World Meteorological Organization. 27 p. Out. 2022. Disponível em: <https://www.undrr.org/publication/global-status-multi-hazard-early-warning-systems-target-g> Acessado em: 15 Out. 2022.

KUHN, Max; JOHNSON, Kjell. **Applied Predictive Modeling**. Nova York: Springer, 2013. <https://doi.org/10.1007/978-1-4614-6849-3>.

KWEKU, D.W.; BISMARCK, O.; MAXWELL, A.; DESMOND, K.A.; DANSO, K.B.; OTI-MENSAH, E.A.; QUACHIE, A.T.; ADORMAA, B.B. Greenhouse Effect: Greenhouse Gases and Their Impact on Global Warming. *Journal of Scientific Research & Reports*. v. 17, n. 6, p. 1 - 9, Nov. 2017. <https://doi.org/10.9734/JSRR/2017/39630>

L'ECUYER, J.; THOMPSON, David W. J. Annular Modes Website. Disponível em:

<http://www.atmos.colostate.edu/ao/introduction.html>. Acesso em: 15 de janeiro de 2022.

LEITE, Danielle Aparecida Reis; SILVA, Luciano Fernandes. O tema mudanças climáticas em teses e dissertações brasileiras de educação ambiental. **Actio Docência em Ciências**. v. 5, n. 2, p. 1 - 2, Ago. 2020.

<https://doi.org/10.3895/actio.v5n2.12132>

LEITE, Marcos Esdras; SILVA, Lucas Augusto Pereira da; VELOSO, Gabriel Alves; FILHO, Raul de Magalhaes. Comportamento e Influencia do Albedo e Temperatura de Superfície no Balanço de Radiação em Areas do Cerrado. **Caminhos da Geografia**. v. 21, n. 73, p. 131 - 147, Mar. 2020.

<http://doi.org/10.14393/RCG217347387>

LEMIALE, Vicent; PRAKASH, Mahesh; CRUZ, Ana Maria. Data-driven approaches to integrated disaster risk management. **International Journal of Disaster Risk Science**. v. 11, p. 693-695, Dez. 2020. <https://doi.org/10.1007/s13753-020-00324-4>

LIMA, Karina Bruno; AQUINO, Francisco Eliseu; MORAES, Flávia Dias de Souza. Impactos Gerados Por Dois Complexos Convectivos De Mesoescala De Diferentes Extensões No Sul do Brasil. **Revista Gestão e Sustentabilidade Ambiental**. Florianópolis, v. 7, n. esp, p. 186 - 205, Jun. 2018.

<https://doi.org/10.19177/rgsa.v7e02018186-205>

LINARDOS, Vasileios; DRAKAKI, Maria; TZIONAS, Panagiotis; KARNAVAS, Yannis L. Machine Learning in Disaster Management: Recent Developments in Methods and Applications. **Machine Learning and Knowledge Extraction**. v. 4, n. 2, p. 446–473, 2022. <https://doi.org/10.3390/make4020020>

LINDSEY, Rebecca. Extreme event attribution: the climate versus weather blame game, **Climate Watch Magazine**, NOAA, 15 Dez 2016. Disponível em:

(<https://www.climate.gov/news-features/understanding-climate/extreme-event-attribution-climate-versus-weather-blame-game>). Acesso: 12 Ago 2021.

LYRA, Matheus José Arruda; FREITAS, Ismael Guidson Farias Freitas. Desenvolvimento dos Complexos Convectivos de Mesoescala no Nordeste Brasileiro em 2017. **Revista Brasileira de Geografia Física**. v. 12, n. 6, p. 2152 - 2162, Dez. 2019. <https://doi.org/10.26848/rbgf.v12.6.p2152-2162>

LIZARRALDE, G.; BORNSTEIN, L.; ROBERTSON, M.; GOULD, K.; HERAZO, B.; PETTE, A.M.; PÁEZ, H.; DÍAZ, J.H.; OLIVERA, A.; GONZÁLEZ, G.; LÓPEZ, O.; LÓPEZ, A.; ASCUI, H.; BURDILES, R.; BOUCHEREAU<sup>1</sup>, K. Does climate change cause disasters? How citizens, academics, and leaders explain climate-related risk and disasters in Latin America and the Caribbean. **International Journal of Disaster Risk Reduction**. v. 58, Mar. 2021. <https://doi.org/10.1016/j.ijdrr.2021.102173>

LKHAMJAV, Chinbaata. Final Report ADRC Visiting researcher. Asian Disaster Reduction Center. p. 68, Ago./Nov. 2013.

LUCYRIO, Vinicius; REBOITA, Michele Simões; ALBIERI, Marcelo de Campos Garcia. Ondas de Frio Intensas sobre o Nordeste do Estado de São Paulo entre 1961 a 2017. **Revista Brasileira de Climatologia**. v. 25, p. 571 - 593, Jul./Dez. 2019. ISSN:2237-8642

LUZ, Maiane Barbalho; FILGUEIRA, Halmicar José Almeida. Sistemas de alerta a desastres relacionados com fenômenos naturais: algumas alternativas no brasil e no mundo. In: **I Encontro Nacional de Desastres. Associação Brasileira de Recursos Hídricos**, Porto Alegre - RS. p. 1-8, 25 a 27 de Jun. 2018. Disponível em: (<https://files.abrhidro.org.br/Eventos/Trabalhos/79/END130.pdf>) Acesso em: 23 Jul. 2021.

LUZ, Maiane Barbalho. **Sistemas de alerta de risco a desastres: aplicabilidade para o município de João Pessoa/PB**. 52f. Monografia (Curso de Graduação em Engenharia Ambiental). Universidade Federal da Paraíba - UFPB, João Pessoa, 2018.

LYRA, M. J. A.; FEDOROVA, N.; LEVIT, V.; FREITAS, I.G.F. Características dos Complexos Convectivos de Mesoescala no Nordeste Brasileiro. **Revista Brasileira**

**De Meteorologia**, n. 35, p. 727 – 734, Dez. 2020.

<https://doi.org/10.1590/0102-7786355000001>

MACHADO, Celia Cristina Clemente; NÓBREGA, Ranyére Silva; OLIVEIRA, Tiago Henrique; ALVES, Keyla Manuela Alencar da Silva. Distúrbio Ondulatório De Leste Como Condicionante A Eventos Extremos De Precipitação em Pernambuco. **Revista Brasileira de Climatologia**. v. 11, Jul./Dez. 2012. ISSN: 1980-055x

MACHADO, L.A.T.; FERREIRA, N.J.; LAURENT, H.; DIEDHIOU, A..Distúrbios Ondulatorios de Leste. *In*: FERREIRA, Nelson Jesus; CAVALCANTI, Iracema Fonseca de Albuquerque. **Sistemas meteorológicos atuantes no Brasil**. São Paulo : Oficina de Textos, 2022. ISBN 978-65-86235-52-4

MADDOX, R.A. Mesoscale Convective Complexes. **Bulletin of the American Meteorological Society** v. 61, n. 11, p. 1374 - 1387, Nov. 1980.

MAGINA, Leandro José Rocha. **Estudo dos Processos Envolvidos e da Previsibilidade da Oscilação Madden-Julian com o Modelo OLAM**. 2018. 98 f. Trabalho de Conclusão de Curso (Graduação em Oceanografia) - Universidade Federal de Santa Catarina - UFSC, Florianópolis, 2018.

MAGNAGO, Rachel Faverzani; MEDEIROS, Patricia; RAIMUNDO, Rodrigo Paulo; COSTA, Susana Claudete. DESASTRES NATURAIS NO ESTADO DE SANTA CATARINA - 1998 A 2019. **MIX Sustentável**, [S. l.], v. 7, n. 4, p. 105–114, Ago. 2021. <https://doi.org/10.29183/2447-3073.MIX2021.v7.n4.105-114>

MANTUA, Nathan J.; HARE, Steven. The Pacific Decadal Oscillation. **Journal of Oceanography**. v. 58, n. 1, p. 35 - 44, Fev. 2002. <http://dx.doi.org/10.1023/A:1015820616384>

MEENAL, Rajasekaran; PRAWIN, Anjo; PÂMELA, D.; RAJASEKARAN, Ekambaram. Weather prediction using random forest machine learning model. **Indonesian Journal of Electrical Engineering and Computer Science**. v. 22, n. 2, p. 1208-1215, Maio 2021. <http://doi.org/10.11591/ijeecs.v22.i2.pp1208-1215>

MHLANGA, Sandile Thamie; LALL, Manoj. Influence of Normalization Techniques on Multi-criteria Decision-making Methods. **Journal of Physics: Conference Series**. v. 2224, p. 012076, Jan. 2022. <http://doi.org/10.1088/1742-6596/2224/1/012076>

MARCELINO, Emerson Vieira; NUNES, Luci Hidalgo; KOBAYAMA, Masato. Mapeamento de Risco de Desastres Naturais do Estado de Santa Catarina. **Caminhos de Geografia**. v. 8, n. 17, p. 72 - 84, Fev. 2006. ISSN 1678-6343

MARCHEZINI, V.; LONDE, L.R.; BERNARDES, T.; CONCEIÇÃO R.S; EV SANTOS, E.V.; SAITO, S.M.; SOLER, L.; SILVA, A.E.P.; BORTOLETTO, K.C.; MEDEIROS, M.D.S.; GONÇALVES, D.A. Sistema de alerta de risco de desastres no Brasil: desafios à redução da vulnerabilidade institucional. **Reduction of vulnerability to disasters: from knowledge to action**. p. 287-310, 2017.

MARENGO, José A. State of the Climate in Latin America and the Caribbean 2020. WMO-No. 1272. **World Meteorological Organization**. Geneva, Switzerland, 2020, 35 p.

MARRAFON, V.H.; REBOITA, M.S.; ROCHA, R.P.; DE JESUS, E.M. Classification of the cyclone types over the South Atlantic Ocean in projections with RegCM4 and GCMs. **Brazilian Journal of Climatology**. v. 30, p. 1 - 25, Jan./Jul. 2022. ISSN 2237-8642

MCBEAN, Gordon. Climate change and extreme weather: a basis for action. **Natural Hazards**. v. 31, p. 177 – 190, Jan. 2004. <https://doi.org/10.1023/B:NHAZ.0000020259.58716.0d>

MCBRIDE, S. K.; BOSTROM, A.; SUTTON, J.; DE GROOT, R. M.; BALTAY, A. S.; TERBUSH, BODIN, P.; DIXON, M.; HOLLAND, E.; ARBA, R.; LAUSTSEN, P.; LIU, S.; VINCI, M. Developing post-alert messaging for ShakeAlert, the earthquake early warning system for the West Coast of the United States of America. **International Journal of Disasters Reduction**. v. 50, Nov. 2020.

MCPHILLIPS, L. E., CHANG, H., CHESTER, M. V., DEPIETRI, Y., FRIEDMAN, E., GRIMM, N. B., KOMINOSKI, J. S., MCPHEARSON, T., MÉNDEZ-LÁZARO, P., ROSI, E. J., & SHAFIEI SHIVA, J. Defining Extreme Events: A Cross-Disciplinary

Review. **Earth's Future**. v. 6, p. 441 - 455, Mar.2018.

<https://doi.org/10.1002/2017EF000686>

MENDES, R. M.; FILHO, M. V.; BERTOLDO, M. A.; SILVA, M. F. Estudo De Limiares Críticos de Chuva Deflagradores de Deslizamentos no Município de São José dos Campos/SP (Brasil). **Revista Territorium**. n. 22, p. 119 - 129, Ago. 2015.

[http://dx.doi.org/10.14195/1647-7723\\_22\\_8](http://dx.doi.org/10.14195/1647-7723_22_8)

MELO, Frederico. **Acoplamento modelos mesoescala/microescala - calibração para aplicações de análise dinâmica da capacidade de transmissão de linhas eléctricas**. 2020. 119 f. Dissertação (Mestrado em Engenharia da Energia e do Ambiente) - Universidade de Lisboa, Lisboa, 2020. Disponível em:

[https://repositorio.ul.pt/bitstream/10451/45457/1/ulfc125990\\_tm\\_Frederico\\_Melo.pdf](https://repositorio.ul.pt/bitstream/10451/45457/1/ulfc125990_tm_Frederico_Melo.pdf).

Acesso em: 29 mar. 2023.

MILLER, D.E.; GENSINI, V.A.; BARRET, B.S. Madden-Julian oscillation influences United States springtime tornado and hail frequency. **NPJClimate and Atmospheric Science**. v. 5, n. 7, p. 1 - 8, Mai. 2022. <https://doi.org/10.1038/s41612-022-00263-5>

MOLINA, E.; CARDOSO, A.; NOGUEIRA, F. Relação precipitação-deslizamento no Município de São Bernardo do Campo - SP. **Ciência e Natura**, n. 37, p. 46 - 54, 2015. <http://dx.doi.org/10.5902/2179460X16214>.

MOLNAR, Christoph. **Interpretable Machine Learning**. 31 jul. 2024. Lulu.com, 24 fev. 2019. 318 p. ISBN 0244768528.

MONTEITH, John L. & UNSWORTH, Mike H. **Micrometeorology: Turbulent Transfer, Profiles and Fluxes**. In: Principles of Environmental Physics. Ed. 4. Cambridge: Elsevier. 26 Jul. 2013. ISBN: 9780123869104

<https://doi.org/10.1016/B978-0-12-386910-4.00016-0>

MONTELEONI, Claire; SCHMIDT, Gavin A.; MCQUADE, Scott. Climate informatics: Accelerating discovering in climate science with machine learning. **Computing in Science & Engineering**. v. 15, n. 5, p. 32-40, Set./Out.2013.

MORAES, André Geraldo de Lima; BOWLING, Laura Christine; ZEBALLOS-VELARDE, Carlos Renzo; DANESHVAR, Fariborz; WATKINS, Alec Hale; CHERKAUER, Keith Aric. Terrain sensitive climate mapping for the Arequipa Department in Peru. **International Journal of Climatology**, v. 171, n. 43, p. 76 - 98, Dez. 2020. <https://doi.org/10.1111/j.1936-704X.2020.3343.x>

MORTEAN, Marcella Vogelsanger; ROSENFELDT, Yuzi Anai Zanardo. The Action of Civil Defense in the Territorial Management of the Santa Catarina State. In: Anais do COBRAC 2018 - Florianópolis –SC – Brasil - UFSC – de 21 a 24 de outubro de 2018. 19 p.

MYLNE, Ken; CHEN, Jing; ERFANI, Amin; HAMILL, Tom; RICHARDSON, David; VANNITSEM, S.; WANG, Yong; ZHU, Yuejian. **Guidelines on Ensemble Prediction System Postprocessing**. 2021 Ed. WMO-Nº 1254, Genebra, Suíça: World Meteorological Organization, Jun 2021. ISBN 978-92-63-11254-5

NATIONAL ACADEMY OF SCIENCES. **Climate Change: Evidence and Causes**. The Royal Society. Washington, DC: The National Academies Press, 2014. <https://doi.org/10.17226/18730>

NUNES, Mayara Monique Almeida Moura. **Análise das Variabilidades Interanuais e Interdecenais de Índices Climáticos para o Estado do Rio Grande do Norte**. 2019. 78 f. Dissertação (Programa de Pós-Graduação em Meteorologia) - Universidade Federal de Campina Grande - UFCG, Paraíba, 2019.

OLIVA, Fábio Guimarães. Climatologia e Variabilidade dos Principais Sistemas Meteorológicos Atuantes no Brasil, Relação com Chuvas Intensas e Impactos Relacionados. **Revista da Pós-Graduação em Geografia da PUC-Rio**. v. 12, n. 23, p. 74-99, jul.-dez. 2019. ISSN 1983-3644

OLIVEIRA, Juarez Ventura de. **A oscilação Madden - Julian na Amazônia Oriental: variáveis superficiais**. 2012. 112 f. Dissertação (Programa de Pós-Graduação em Ciências Ambientais) - Universidade Federal do Pará - UFPA, Belém, 2012.

OLIVEIRA, Gabrielle Bezerra; ALCÂNTARA, Clênia Rodrigues; SOUZA, Enio Pereira de. Caracterização de perfis de vento no ambiente de formação das linhas de instabilidade amazônicas. **Ciencia e Natura**. v. 38, n.1, p. 393 – 403, Jan.- Abr. 2016. <https://doi.org/10.5902/2179-460X18337>

OLIVEIRA, Roseli de. **Sistema de Detecção de Frentes Frias associadas a Eventos Meteorológicos de Médio e Alto Impacto no Centro Sul da América do Sul**. 2022. 131 f. Dissertação (Programa de Pós-Graduação em Clima e Ambiente) - Instituto Federal de Santa Catarina - IFSC, Florianópolis, 2022.

OLIVER-SMITH, A., ALCANTARA-AYALA, I.; BURTON, I.; LAVELL, A. The social construction of disaster risk: Seeking root causes. **International Journal of Disaster Risk Reduction**. v. 22, p. 469-474, Jun. 2017.  
<https://doi.org/10.1016/j.ijdrr.2016.10.006>

ONU. Sendai framework for disaster risk reduction 2015–2030. In: **UN world conference on disaster risk reduction**, 2015 March 14–18, Sendai, Japan. Geneva: United Nations Office for Disaster Risk Reduction; 2015.

ONU. Organização das Nações Unidas. Transformando Nosso Mundo: A Agenda 2030 para o Desenvolvimento Sustentável. 2015. Disponível em: <<https://nacoesunidas.org/wp-content/uploads/2015/10/agenda2030-pt-br.pdf> >  
Acesso em 01 Ago.2021.

PACHAR, Sunita; DUDEJA, Deepak; BATRA, Neha; TOMAR, Vinam; BHIMAVARAPU, John Philip.; SINGH, Avadh Kishor. Recent developments in machine learning predictive analytics for disaster resource allocation. **Engineering Proceedings**. v. 59, p. 19, Dez. 2023. <https://doi.org/10.3390/engproc2023059019>

PALLOTTA, M.; NAKAZATO, R. Y. **Caracterização de episódios de Zona de Convergência do Atlântico Sul (ZCAS) e Zona de Convergência de umidade (ZCOU) em janeiro e fevereiro de 2010**. In: Congresso Brasileiro de Meteorologia, 16, 2010, Belém, Anais do XVI Congresso Brasileiro de Meteorologia, Rio de Janeiro: Sociedade Brasileira de Meteorologia, 2010.

PEREIRA, Emilly Lais; NASCIMENTO JÚNIOR, Lindberg. As chuvas em Florianópolis/SC: um ensaio sobre a gênese, dinâmica e distribuição espaço-temporal das precipitações. **Revista Brasileira de Climatologia**, [S. l.], v. 30, n. 18, p. 246 – 273, 2022. <https://doi.org/10.55761/abclima.v30i18.15327>.

PINHEIRO, Henri Rossi; GAN, Manoel Alonso. Vórtices Ciclônicos de Altos Níveis que atuam em Regiões Subtropicais da América do Sul. *In*: FERREIRA, Nelson Jesus; CAVALCANTI, Iracema Fonseca de Albuquerque. **Sistemas meteorológicos atuantes no Brasil**. São Paulo : Oficina de Textos, 2022. ISBN 978-65-86235-52-4

PIZZOCHERO, Renan Martins; CAVALCANTI, Iracema Fonseca de Albuquerque; VASCONCELLOS, Fernanda Cerqueira. **Impacto do Modo Anular Sul na América do Sul**. Relatório do Projeto de Iniciação Científica (PIBIC/CNPq/INPE), UFRJ, Jun. 2016.

PHILLIPS, M.C.K.; CINDERICH, A.B.; BURRELL, J.L.; RUPER, J.L.; WILL, R.G.; SHERIDAN, S.C. The Effect of Climate Change on Natural Disasters: A College Student Perspective. **WEATHER CLIMATE AND SOCIETY**. Kent State University, Ohio. v.7, p. 60-68, 1 Jan. 2015.

PONTES, Alana de Lima; DIAS, Maria Assunção Faus da Silva. Análise das características física e termodinâmicas de uma linha de instabilidade ocorrida no dia 08 de outubro de 2002 em Rondônia durante o experimento LBA: um estudo de caso. São José dos Campos: **Instituto Nacional de Pesquisas Espaciais - INPE**, 2006. Disponível em:

[http://mtc-m16b.sid.inpe.br/col/sid.inpe.br/mtc-m15@80/2006/11.14.18.35/doc/Ponte s.AnaliseCarac..pdf](http://mtc-m16b.sid.inpe.br/col/sid.inpe.br/mtc-m15@80/2006/11.14.18.35/doc/Ponte%20s.AnaliseCarac..pdf). Acesso em: 29 mar. 2023.

POWERS, David Martin Ward. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. **Journal of Machine Learning Technologies**, v. 2, n. 1, p. 37-63, 2011.

PRUSTY, Sashikanta; PATNAIK, Srikanta; DASH, Sujit Kumar. SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer. **Frontiers**

**Nanotechnology.**, v. 4, 972421, Ago. 2022.  
<https://doi.org/10.3389/fnano.2022.972421>

PUGAS, André Francisco. Comunicação em Desastres: Uma análise sobre os meios de comunicação utilizados em sistemas de alertas na America Latina e Caribe. In: ASENSI, Felipe. **Reflexões Acadêmicas Plurais**. Deerfield Beach, Florida: Pembroke Collins, 2022 ISBN: 979-8-88670-030-5

PUGAS, André Francisco; PEREIRA BARBOZA DA SILVA, Ariana; BREDÁ DA SILVA, Eliseo; ROLDÃO, Helena Pures; QUADRO, Mário Francisco Leal de; VITOR, Adriano; NOBRE MUZA, Michel. Analysis of temporal precipitation variability in the State of Santa Catarina - Brazil. **Revista Brasileira de Climatologia**. [S. l.], v. 34, n. 20, p. 51–78, 2024. <https://doi.org/10.55761/abclima.v34i20.17164>.

PUGAS, André Francisco. **Tecnologia Social dos Alertas de Desastres: Uma avaliação da abordagem técnica sob o olhar das pessoas**. 1ª Ed. Florianópolis: Editora Soriana, 2024.

QUADRO, M.F.L. **Estudo de Vórtices Ciclônicos de Mesoescala associados à Zona de Convergência do Atlântico Sul**. 2012. 141 f. Tese (Doutorado em Meteorologia) - Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2012.

RANIA, Rizki Arinta; EMANUEL, Andi Wahyu R. Natural Disaster Application on Big Data and Machine Learning: A Review. In: **2019 4th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)**. Yogyakarta, Indonesia, 2019. p. 249-254.  
<https://doi.org/10.1109/ICITISEE48480.2019.9003984>

REBOITA, M.S.; KRUSCHE, N.; AMBRIZZI, T.; ROCHA, R.P. Entendendo o Tempo e o Clima na América do Sul. **Terra e Didática**. v. 8, n. 1, p. 34 - 50, 2012.

REBOITA, M.S.; GAN, M.A.; ROCHA, R.P.; CUSTÓDIO, I.S. Ciclones em superfície nas latitudes austrais: Parte I Revisão bibliográfica. **Revista Brasileira de**

**Meteorologia.** v. 32, n. 2, p. 171 - 186, Abr./Jun. 2017.  
<https://doi.org/10.1590/0102-77863220010>

REBOITA, Michelle Simões; SANTOS, Diego Felipe dos. Jatos de Baixos Níveis a Leste dos Andes: comparação entre duas reanálises. **Revista Brasileira de Climatologia.** v. 22, Jan./Jun. 2018. ISSN: 2237-8642

REBOITA, M.S.; AMBRIZZI, T. SILVA, B.A.; PINHEIRO, R.F.; ROCHA, R.P. The South Atlantic Subtropical Anticyclone: Present Climate and Future Projections. **Frontiers in Earth Science.** v. 7, n. 8, p. 1 - 15, Fev. 2019.  
<https://doi.org/10.3389/feart.2019.00008>

REBOITA, Michelle Simões; MARRAFON, Vitor Hugo. Extratropical Cyclones: what are, climatology and impacts in Brazil. **Terra e Didática.** v. 17, p. 1 - 13, e021032, Set. 2021. <http://doi.org/10.20396/td.v17i00.8666028>.

REIS, D. A.; SILVA, L. F.; FIGUEIREDO, N. As complexidades inerentes ao “tema mudanças climáticas”: desafios e perspectivas para o Ensino de Física. **Ensaio Pesquisa em Educação em Ciências**, Belo Horizonte, v. 17, n. 3, p. 535 - 554, Dez. 2015. <http://dx.doi.org/10.1590/1983-21172015170301>

REN, Fu-Min; TREWIN, Blair; BRUNET, Manola; PATTANAIK, Dushmanta; WALTER, Andreas; BADDOUR, Omar; KORBER, Maya. A research progress review on regional extreme events. **Advances in Climate Change Research.** v. 9, n. 3, p. 161-169, 2018. ISSN 1674-9278. <https://doi.org/10.1016/j.accres.2018.08.001>.

RIBEIRO, Bruno Zanetti; NUNES, André Becker. **Onda de Calor Associada a Bloqueio Atmosférico: estudo de caso em Pelotas - RS.** In: XX Congresso de Iniciação Científica, III Mostra Científica, Universidade Federal de Pelotas, Anais, 2011.

RIBEIRO, Marco Tulio; SINGH, Sameer; GUESTIN, Carlos. Why Should I Trust You? Explaining the Predictions of Any Classifier. In: **KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.** 2016, São Francisco, Califórnia, EUA. Associação para Máquinas de Computação, 2016. p. 1135-1144. <https://doi.org/10.1145/2939672.2939778>.

RIBEIRO, Bruno Zanetti. **Linhas de Instabilidade no Sul do Brasil**. 2018. 255 p. Tese (Doutorado em Meteorologia) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2018.

ROCHA, L.B.; REBOITA, M.S.; DUTRA, L.M.M.; CAPUCIN, B.C. Evolução da Estrutura. Térmica de um Ciclone Tropical e sua Transição Extratropical: Caso Talim. **Revista Brasileira de Meteorologia**, v. 36, n. 2, P. 137 - 152, Jan. 2021. <http://dx.doi.org/10.1590/0102-77863610012>

RODRIGUES, M. L. G. O monitoramento e avisos de eventos meteorológicos extremos de Santa Catarina em 2020. **Agropecuária Catarinense**, v. 33, n. 3, p. 5-6, 2020. Disponível em: <https://publicacoes.epagri.sc.gov.br/RAC/article/view/1082>. Acesso em: 20 jun. 2021.

ROSA, Marcelo Barbio; SILVA, Luiz Tadeu. Alguns Aspectos Climatológicos da ZCIT sobre o Atlântico. **CPTEC/INPE**. p. 37 - 42, 24 Ago. 2016.

ROSSI, Claudio; FALCONE, Giacomo; FRISIELLO, Antonella; DOMINICI, Fabrizio. Best Practices on Public Warning Systems for Climate Induced Natural Hazards. European Commission. Set. 2018. Disponível em: [https://drmkc.jrc.ec.europa.eu/Portals/0/innovation/SupportSystem/11\\_Lithuania/JRC\\_PublicWarningonNaturalHazard\\_05\\_PWS\\_final.pdf](https://drmkc.jrc.ec.europa.eu/Portals/0/innovation/SupportSystem/11_Lithuania/JRC_PublicWarningonNaturalHazard_05_PWS_final.pdf)> Acesso em: 15 Set. 2021.

S2iD (2021) Sistema Integrado de Informações Sobre Desastres - S2iD. Ministério da Integração – MI. Disponível em: <http://S2iD.mi.gov.br/>. Acesso em 22/11/2021.

SAITO, S.M.; LIMA, G.R.T.; DIAS, M.C.A. Evaluation by the end-users of disaster risk warnings in Brazil. **Sustainability in Debate** - Brasília, v. 10, n.2, p. 38-53, Ago.2019. <http://doi:10.18472/SustDeb.v10n2.2019.24908>

SANTA CATARINA. Secretaria de Estado do Planejamento. Diretoria de Estatística e Cartografia. Atlas geográfico de Santa Catarina : diversidade da natureza – fascículo 2. Santa Catarina. Secretaria de Estado do Planejamento. Diretoria de Estatística e Cartografia ; Isa de Oliveira Rocha (Org.) – 2.ed. – Florianópolis: Ed. da UDESC, 2016

SANTA CATARINA A. Defesa Civil de Santa Catarina. Desenvolvimento de Práticas para a Gestão do Conhecimento Ligadas aos Processos de Atuação o CIGERD - Manual De Procedimentos – Desenvolver & Revisar. Santa Catarina: Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC), 2019.

SANTA CATARINA B. Lei Complementar n. 741, de 12 de junho de 2019. Dispõe sobre a estrutura organizacional básica e o modelo de gestão da Administração Pública Estadual, no âmbito do Poder Executivo, e estabelece outras providências. Florianópolis. Disponível em: [http://leis.alesc.sc.gov.br/html/2019/741\\_2019\\_lei\\_complementar.html](http://leis.alesc.sc.gov.br/html/2019/741_2019_lei_complementar.html). Acesso em: 15 jun. 2021.

SANTA CATARINA. Defesa Civil de Santa Catarina. Nowcast – Alerta SMS. Santa Catarina, 2021. Disponível em: <<https://www.defesacivil.sc.gov.br/alertas-sms/>>. Acesso em: 03 Jun. 2021.

SANTOS, Lais Alves. **Acurácia do Modelo Regional ETA Utilizado no CPTEC/INPE em Detectar os Vórtices Ciclônicos de Altos Níveis Atuantes no Nordeste do Brasil**. 2015. 73 p. Dissertação (Mestrado em Meteorologia) Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2015.

SANTOS, V. J.; FIALHO, E. S. Zona de Convergência do Atlântico Sul (ZCAS) e impactos pluviais intensos: o caso da cidade de Ubá/MG. **Revista Brasileira de Climatologia**. v. 10, p. 218 - 238. Jul./Dez. 2016. <http://dx.doi.org/10.5380/abclima.v19i0.35684>

SANTOS, Ana Paula Paes dos. **Eventos Extremos de Descargas Atmosféricas no Estado de São Paulo: casos observados e cenários futuros**. 2017. 193f. Tese (Doutorado em Ciencia do Sistema Terrestre) - Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2017.

SANTOS, D. L.; FRAGOSO JR., C. R.; SOUZA, V. C. B. Limiar de precipitação com potencial de gerar deslizamentos nos complexos de risco em uma zona urbana.

**Revista de Gestão de Água da América Latina.** v. 16, e12, 2019.  
<https://dx.doi.org/10.21168/reg.a.v16e12>.

SANTOS, D.F.; REBOITA, M.S. Jatos de baixos níveis a leste dos andes: comparação entre duas reanálises. **Revista Brasileira de Climatologia.** v. 22, Jan./Jun. 2018. ISSN: 2237-8642

SAMPAIO, Gilvan de Oliveira. **El Niño e Você - O Fenômeno Climático.** São Paulo: Editora Transtec, 2001.

SELMO, Luigi. **Os Impactos Socioambientais Provocados pelo Ciclone Subtropical Eçaí, em Florianópolis.** 2020. 102 f. Trabalho de Conclusão de Curso (Bacharel em Geografia) - Universidade Federal de Santa Catarina - UFSC, Florianópolis, 2020.

SELUCHI, Marcelo Enrique; CHOU, Sin Chan. Synoptic patterns associated with landslide events in the Serra do Mar, Brazil. **Theoretical and Applied Climatology.** v. 98, p. 67 - 77, Set. 2009. <https://doi.org/10.1007/s00704-008-0101-x>

SHI, Guangren. Chapter 2 - Probability and Statistics. In: SHI, Guangren (Ed.). **Data Mining and Knowledge Discovery for Geoscientists.** Amsterdam: Elsevier, 2014. p. 23-53. ISBN 9780124104372.  
<https://doi.org/10.1016/B978-0-12-410437-2.00002-3>.

SILLMANN, J.; SIPPEL, S.; RUSSO, S. 2019. **Climate Extremes and Their Implications for Impact and Risk Assessment.** 1 ed. Oxford, Reino Unido: Elsevier, 2019. <https://doi.org/10.1016/C2017-0-01794-9>.

SILVA, M. A V. **Meteorologia e Climatologia.** Recife: Versão Digital 2, 2006. 463p.

SILVA, M.J.; GALVÍNCIO, J.D.; COSTA, V.S.O. Interdisciplinary Approach on The Influence of The Intertropical Convergence Zone - ITCZ in The Northeast Brazil. **Revista Movimentos Sociais e Dinâmicas Espaciais.** Recife, v. 6, n. 1, p. 107 - 117, Dez. 2017. ISSN: 2238-8052

SILVA, J.P.R.; REBOITA, M.S.; ESCOBAR, G.C.J. Caracterização Da Zona De Convergência Do Atlântico Sul Em Campos Atmosféricos Recentes. **Revista**

**Brasileira de Climatologia.** v. 25, p. 355 - 377, Jul./Dez. 2019. ISSN: 2237-8642

SILVA, Renato Ramos da; HAAS, Reinaldo. A Oscilação Madden Julian. In: SILVA-MATOS, R.R.S.; MACHADO, N.A.F.; ANDRADE, H.A.F. **As ciências exatas e da terra e a interface com vários saberes 2.** p. 227 - 238, 2020. <https://doi.org.br/10.22533/at.ed.080201301>

SILVA, PONTES DA; ROCHA, Rosimeri Porfírio; GOMES, Helber Barros. Atuação dos Distúrbios Ondulatórios de Leste Sobre o Leste do Nordeste do Brasil Durante os Períodos Chuvosos de 2006 a 2010. **Revista Científica Foz**, v. 3, n. 2, 22 Nov. 2022. ISSN: 2594-8849

SIDDHARTHA, V. Forecasting and Early Warning Systems & Communication and Information Technology for Various Types of Disasters. **International Journal of Engineering Research & Technology.** v. 6, n. 1, p. 143 - 146, Jan. 2017. ISSN: 2278-0181

SIQUEIRA, Anderlan Henrique Batista. Oscilação Madden-Julian e seus Impactos nas Chuvas sobre a América do Sul. Panorama Comerc. São Paulo, 11 Ago. 2015.

SMITH, Keith. **Environmental hazards: assessing risk and reducing disaster.** 6 ed. Florence, USA: Routledge, Jan. 2013. 478 p. ISBN: 978-0415681063

SOBRAL, A.; FREITAS, C.M.; ANDRADE, E.V.; LYRA, G.F.D.; MASCARENHAS, M.S.; ALENCAR, M.R.F.; CASTRO, R.A.L.; FRANÇA, R.F. Natural Disasters - Information Systems and Surveillance System: A review literature. **Epidemiologia e Serviço de Saúde.** v. 19, n. 4, p. 389 - 402, Brasília, Dez. 2010. <http://dx.doi.org/10.5123/S1679-49742010000400009>

SOMAR. Southern Marine Weather Services. **Serviços de Previsão de Curto e de Curtíssimo Prazo junto ao CIGERD, obtido pelo melhor entendimento dos Processos Físicos relacionados À Eventos de Tempo Severo, através do Monitoramento Contínuo para a Defesa Civil do Estado de Santa Catarina - DCSC:** Mapeamento de Processos, Florianópolis, 24 Out. 2019.

SORENSEN, J.H. Hazard warning systems: Review of 20 years of progress. **Natural Hazards Review**. v. 1, n. 2, p. 119-125, Mai. 2000. [https://doi.org/10.1061/\(ASCE\)1527-6988\(2000\)1:2\(119\)](https://doi.org/10.1061/(ASCE)1527-6988(2000)1:2(119))

SORIANO, E.; HOFFMANN, W. The evolution of the protection systems against natural disasters in Brazil: laws, agencies, information and knowledge. In: **Management of Natural Disasters**. Southampton: WIT Press, v. 150, p. 49-58. 2016. <https://doi.org/10.2495/DMAN150051>

SOUZA, Aline. **Meteorologia e Climatologia Agrícola**. Bahia: Instituto Formação, 2013, 32 p. 2013.

SOUZA, Fabiano de. **Prevenção e Preparação para o Risco de Desastres**: Um Estudo de Caso sobre a Gestão do Tornado de Xanxerê/SC. 2017. 187 p. Dissertação (Mestrado) Universidade do Estado de Santa Catarina, Centro de Ciências Humanas e da Educação, Programa de Pós-Graduação em Planejamento Territorial e Desenvolvimento Socioambiental, Florianópolis, 2017.

SOUZA, Christie Andre de; REBOITA, Michelle Simões. Ferramenta para o Monitoramento dos Padrões de Teleconexão na América do Sul. **Terrae Didática**. Campinas, SP, v. 17, n. 00, p. e02109, 2021.

STENDEL, M.; FRANCIS, J.; WHITE, R.; WILLIAMS, P.D.; WOOLLINGS, T. The jet stream and climate change. In: LETCHER, T. M. **Climate Change Observed Impacts on Planet Earth**. 3 ed., Amsterdã: Elsevier, 2021. ISBN 978-0-12-821575-3 <https://doi.org/10.1016/C2019-0-01498-7>

SULAIMAN, S.M.; ALEDO, A. Desastres naturais: convivência com o risco. Dilemas ambientais e fronteiras do conhecimento. **Estudos Avançados**. v. 30, n. 88, p. 11-23, Set-Dez 2016. <https://doi.org/10.1590/S0103-40142016.30880003>

SUN, Wenjuan; BOCCHINI, Paolo; DAVISON, Brian D. Applications of artificial intelligence for disaster management. **Natural Hazards**. v. 103, p. 2631–2689, 2020. <https://doi.org/10.1007/s11069-020-04124-3>.

STULL, Rolland B. **An Introduction to Boundary Layer Meteorology**. Ed. 2. Suíça: Springer, 31 Jun 1988. ISBN 978-9027727695

STEWART, Mathew; CARLETON, W. Christopher; GROUCUTT, Huw S. Extreme events in biological, societal, and earth sciences: A systematic review of the literature. **Frontiers in Earth Science**. v. 10, 786829, 24 Ago. 2022. <https://doi.org/10.3389/feart.2022.786829>

TATIZANA, C.; OGURA, A.T.; CERRI, L.E.S.; ROCHA, M.C.M. Análise de correlação entre chuvas e escorregamentos na Serra do Mar, Município de Cubatão. In: Congresso Brasileiro de Geologia de Engenharia, 5, São Paulo: ABGE, v.2, p. 225 - 236, 1987.

TRAJBER, R.; OLIVATO, D.; MARCHEZINI, V. Conceitos e Termos para a Gestão de Riscos de Desastres na Educação. **CEMADEN**. 03 Abr. 2017. Disponível em: (<http://educacao.cemaden.gov.br/site/mediaLibrary/MTAwMDAwMDAwMTg=%20>) Acesso: 19 Ago. 2021.

TOMINAGA, L.K.; SANTORO, J.; AMARAL, R. Desastres naturais. Escorregamentos, inundações e enchentes. p. 25 - 37, 39 - 52. São Paulo, 2009.

UFSC/CEPED. Universidade Federal de Santa Catarina. Centro Universitário de Estudos e Pesquisas sobre Desastres. **Atlas Brasileiro de Desastres Naturais: 1991 a 2012**. 2. ed. rev. ampl. Florianópolis: CEPED/UFSC, 2013.

UMOH, Uduak A.; EYOH, Imo J.; MURUGESAN, Vadivel S.; NYOHO, Emmanuel E. Capítulo 14 - Fuzzy-machine learning models for the prediction of fire outbreaks: A comparative analysis. In: **Artificial Intelligence and Machine Learning for EDGE Computing**. 2022. p. 207-233. <https://doi.org/10.1016/B978-0-12-824054-0.00025-3>.

UNDRR, United Nations Office For Disaster Risk Reduction. Terminology - Early Warning System. Disponível em: (<https://www.undrr.org/terminology/disaster>). Acesso: 22 Set. 2021.

UNDRR, United Nations Office For Disaster Risk Reduction. **Human cost of disasters: An overview of the last 20 Years (2000-2019)**. Estado Unidos. p. 17, Out. 2020 Disponível em: <https://www.undrr.org/publication/human-cost-disasters-overview-last-20-years-2000-2019>). Acesso: 20 Dez. 2021.

UNDRR, United Nations Office For Disaster Risk Reduction. **Launching of CREWS Greater Horn of Africa: Strengthening early warning and early action systems for meteorological, hydrological, and climate extremes**. Ago. 2022 Disponível em: <https://www.preventionweb.net/news/launching-crews-greater-horn-africa-strengthening-early-warning-and-early-action-systems>> Acesso em : 20 Dez. 2022.

UNISDR, United Nations Office For Disaster Risk Reduction. **Early Warning – From Concept to Action: the Conclusions of the Third International Conference on Early Warning (EWC III)**. Bonn. Alemanha. 10 p. 27-29 Mar. 2006.

UNDP, United Nations Development Programme. **Five approaches to build functional early warning systems**. p. 67, Servia, 2018.

UNGRD. Unidad Nacional para la Gestión del Riesgo de Desastres. **Sistemas de Alerta Temprana como elementos para la gestión del riesgo de desastres**. Bogotá, 31 Ago. 2020. Disponível em: <http://portal.gestiondelriesgo.gov.co/Paginas/Noticias/2020/Sistemas-de-Alerta-Temprana-como-elementos-para-la-gestion-del-riesgo-de-desastres.aspx>> Acesso em: 14 Set. 2022.

UNOOSA, United Nation Office for Outer Space Affairs, **UN-SPIDER Newsletter**. v.1, p. 1-6, 24 Jan. 2020. Disponível em: [https://www.un-spider.org/sites/default/files/20-01-UN-SPIDER-Newsletter-Emergency-Response\\_web.pdf](https://www.un-spider.org/sites/default/files/20-01-UN-SPIDER-Newsletter-Emergency-Response_web.pdf)) Acesso: 26 Mar. 2021

VAROQUAUX, Gaël; RAAMANA, Pradeep R.; ENGEMANN, Denis A.; HOYOS-IDROBO, Andrés; SCHWARTZ, Yves; THIRION, Bertrand. **Assessing and**

tuning brain decoders: Cross-validation, caveats, and guidelines. **Neuroimage**. v. 145, p. 166-179, 15 Jan. 2017. <https://doi.org/10.1016/j.neuroimage.2016.10.038>

VASCONCELLOS, Fernanda Cerqueira; PIZZOCHERO, Renan Martins; CAVALCANTI, Iracema Fonseca de Albuquerque. Month-to-month impacts of Southern Annular Mode over South America climate. **Anuário do Instituto de Geociências - UFRJ**, v. 41, n. 1, p. 783 - 792, 2019. DOI: [https://doi.org/10.11137/2019\\_1\\_783\\_792](https://doi.org/10.11137/2019_1_783_792)

VAZQUEZ, Fabio Guimarães. **Alertas de desastres socioambientais no Estado de Santa Catarina sob a perspectiva da Ciência da Informação**. 2018. 155 p. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Centro de Ciências da Educação, Programa de Pós Graduação em Ciência da Informação, Florianópolis, 2018.

VECCHIA, Francisco Arthur da Silva; TECH, Adriano Rogério Bruno; NEVES, Gustavo Zen de Figueiredo. **Climatologia dinâmica: conceitos, técnicas e aplicações**. São Carlos: Rima editora, Jan. 2020. 288 p. ISBN: 978-65-990488

VERDAN, Ian; SILVA, Maria Elisa Siqueira. Variabilidade da Zona de Convergência do Atlântico Sul em relação a eventos ENOS de 2000 a 2021. **Revista do Departamento de Geografia**. v. 42, p. e193110, 2022. <https://doi.org/10.11606/eISSN.2236-2878.rdg.2022.193110>

VERMIGLIO, Carlo; NOTO, Guido; RODRÍGUEZ BOLÍVAR, Manuel Pedro; ZARONE, Vincenzo. Disaster management and emerging technologies: a performance-based perspective. **Meditari Accountancy Research**. v. 30, n. 4, p. 1093-1117, 2022. <https://doi.org/10.1108/MEDAR-02-2021-1206>

VIEIRA, Cristiano Alexandre. **Estudo da Atuação do Anticiclone Subtropical do Atlântico Sul (Asas) sobre a Região do Parque Estadual do Rio Doce (PERD) e seu entorno**. 177 p. Dissertação (Mestrado em Sustentabilidade e Tecnologia Ambiental) - Instituto Federal de Minas Gerais - IFMG, Bambuí, 2020.

VIEIRA, Cristiano Alexandre; CUPOLILO, Fulvio. Estudo da Atuação do Anticiclone Subtropical do Atlântico Sul (ASAS) no Parque Estadual do Rio

Doce (PERD) e seu entorno na Estação Chuvosa. **Revista Brasileira de Climatologia**. v. 28, p. 830 - 857, Jan./Jun. 2021. <http://dx.doi.org/10.5380/rbclima.v28i0.73276>

VOIGT, Paul; VON DEM BUSSCHE, Axel. **The EU General Data Protection Regulation (GDPR): A Practical Guide**. 1. ed. Cham: Springer International Publishing, 2017. ISBN 978-3-319-57958-0 <https://doi.org/10.1007/978-3-319-57959-7>

WALLACE, John M.; HOBBS, Peter V. **Atmospheric Science: An Introductory Survey**. Ed. 2. Cambridge: Academic Press, 24 Mar. 2006. ISBN 978-0127329512

WALISER, D.E.; JIANG, X. TROPICAL METEOROLOGY AND CLIMATE | Intertropical Convergence Zone. **Encyclopedia of Atmospheric Sciences**. 2 ed. p. 121 - 131, 2015. <https://doi.org/10.1016/B978-0-12-382225-3.00417-5>.

WALSH, J., D. WUEBBLES, K. HAYHOE, J. KOSSIN, K. KUNKEL, G. STEPHENS, P. THORNE, R. VOSE, M. WEHNER, J. WILLIS, D. ANDERSON, S. DONEY, R. FEELY, P. HENNON, V. KHARIN, T. KNUTSON, F. LANDERER, T. LENTON, J. KENNEDY, AND R. SOMERVILLE. CHAPTER 2 OUR CHANGING CLIMATE. **Climate Change Impacts in the United States: The Third National Climate Assessment**. J. M. Melillo, Terese (T.C.) Richmond, and G. W. Yohe, Eds., U.S. Global Change Research Program, p. 19-67, Out. 2014. <https://doi:10.7930/J0KW5CXT>.

WANDERLEY, L.S.A.; NÓBREGA, R.S.; DUARTE, C.C.; MOREIRA, A.B.; ANJOS, R.S. Tipos de Tempo Associados a Eventos Diários de Chuva Intensa na Cidade de Recife – PE, Brasil. **Sociedade e Natura**. v. 33, p. 1 - 14, Jul. 2021. <https://doi.org/10.14393/SN-v33-2021-60520>

WILKS, Daniel S. **Statistical Methods in the Atmospheric Sciences**. 3. ed. Volume 100. São Paulo: Academic Press, 2011. 704 p. ISBN 9780123850225

WMO A. World Meteorological Organization (2019). Basic Documents No. 1. **World Meteorological Organization**. Geneva, Switzerland, v. 15, nº 15, p. 206, 2019.

WMO B. World Meteorological Organization (2019). WMO Strategic Plan 2020-2023. **World Meteorological Organization**. Geneva, Switzerland, v. 1225, p. 20, nº 15, 2019.

WMO. World Meteorological Organization (2021). Early warnings protect lives on Africa's Lake Victoria. Disponível em: [https://public.wmo.int/en/media/news/early-warnings-protect-lives-africa%E2%80%99s-lake-victoria?utm\\_source=miragenews&utm\\_medium=miragenews&utm\\_campaign=news](https://public.wmo.int/en/media/news/early-warnings-protect-lives-africa%E2%80%99s-lake-victoria?utm_source=miragenews&utm_medium=miragenews&utm_campaign=news) Acesso em: 16 Dez. 2021.

WMO Strategic Plan 2020-2023. **World Meteorological Organization**. Geneva, Switzerland, v. 1225, p. 20, nº 15, 2019.

WORLD BANK. (2019) Information and Communication Technology for Disaster Risk Management in Japan: How Digital Solutions are Leveraged to Increase Resilience through Improving Early Warnings and Disaster Information Sharing. **World Bank**. Washington, D.C. p.166, 2019.

WORLD BANK. (2021) Central Asian Flood Early Warning System. Infographic. Disponível em: <https://www.worldbank.org/en/news/infographic/2021/12/10/cafews> Acesso em: 22 Set. 2022.

WORLD BANK. Information and Communication Technology for Disaster Risk Management in Japan: How Digital Solutions are Leveraged to Increase Resilience Through Improving Early Warning and Disaster Information Sharing. **World Bank**. Washington, D.C. p.166, 2019.

XAVIER, R.D.; BARCELLOS, C.; BARROS, H.S.; MAGALHÃES, M.A.F.M.; MATOS, V.P.; PEDROSO, M.M. Organization, availability and possibility of analysis of disaster data of climate related origin and its impacts on health. *Ciência e Saúde Coletiva*. v. 19, n. 9, p. 3657 - 3668, Rio de Janeiro, Set. 2014. <https://doi.org/10.1590/1413-81232014199.00992014>

ZSCHEISCHLER, Jakob. Introduction to the special issue: Compound weather and climate events. p. 1-3, **Weather and Climate Extremes**. 27 Ago. 2021. <https://doi.org/10.1016/j.wace.2021.100381>

## **APÊNDICE A – Título**

Os apêndices são textos e/ou documentos elaborados pelo próprio autor para complementar o texto principal. É UM ELEMENTO OPCIONAL.

## **ANEXO A – Título**

Elemento opcional. O anexo é um “texto ou documento não elaborado pelo autor, que serve de fundamentação, comprovação e ilustração”