



Taylor Oliveira Fidelis

**Uma abordagem de ciências de dados e atuaria
para fundamentação de estratégias de diluição
de riscos envolvendo ventos extremos no sul do
Brasil**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática, do Departamento de Informática da PUC-Rio .

Orientador: Prof. Hélio Côrtes Vieira Lopes

Rio de Janeiro
Abril de 2023



Taylor Oliveira Fidelis

**Uma abordagem de ciências de dados e atuaria
para fundamentação de estratégias de diluição
de riscos envolvendo ventos extremos no sul do
Brasil**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática da PUC-Rio . Aprovada pela Comissão Examinadora abaixo:

Prof. Hélio Côrtes Vieira Lopes

Orientador

Departamento de Informática – PUC-Rio

Prof. Cassio Freitas Pereira de Almeida

ENCE

Prof. Bruno Fanzeres dos Santos

PUC-Rio

Rio de Janeiro, 27 de Abril de 2023

Todos os direitos reservados. A reprodução, total ou parcial do trabalho, é proibida sem a autorização da universidade, do autor e do orientador.

Taylor Oliveira Fidelis

Graduado em ciências atuariais e em ciências econômicas pela Universidade Federal de Alfenas Minas Gerais- UNIFAL-MG.

Ficha Catalográfica

Fidelis, Taylor

Uma abordagem de ciências de dados e atuaria para fundamentação de estratégias de diluição de riscos envolvendo ventos extremos no sul do Brasil / Taylor Oliveira Fidelis; orientador: Hélio Côrtes Vieira Lopes. – 2023.

96 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, 2023.

Inclui bibliografia

1. Informática – Teses. 2. Atuaria. 3. Seguro climático. 4. Economia. 5. Ciência de dados. 6. Informática. I. Lopes, Hélio. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

Agradecimentos

Gostaria de expressar meus sinceros agradecimentos a todas as pessoas que contribuíram para a realização deste trabalho e para a minha formação como pesquisador.

Em primeiro lugar, sou imensamente grato ao meu orientador, Prof. Hélio Côrtes Vieira Lopes, por sua orientação cuidadosa, paciência e apoio constante durante todo o período do meu mestrado. Sua sabedoria, experiência e comprometimento foram fundamentais para o sucesso deste trabalho.

Também gostaria de agradecer aos membros da banca examinadora, Prof. Cassio Freitas Pereira de Almeida e Prof. Bruno Fanzeres dos Santos por terem aceitado o convite para avaliar este trabalho e contribuir com suas sugestões e críticas construtivas.

Agradeço a meus pais, Zilda de Fátima Oliveira Fidelis e Adilson Fidelis, por seu amor, apoio incondicional e incentivo constante em todos os momentos da minha vida. Sem eles, nada disso seria possível e também a minhas irmãs Thaynara Oliveira Fidelis, Taise Oliveira Fidelis e todos meus familiares que tanto amo.

Gostaria de fazer um agradecimento especial aos professores Reinaldo Antônio Gomes Marques, Luiza Pimenta Terra, Gabriel Rodrigues Gomes Pessanha e Leandro Ferreira, que tiveram um papel importante em minha formação durante a graduação e contribuíram significativamente para a minha trajetória acadêmica.

Também quero agradecer à minha namorada, Luiza Souza de Araujo, por seu apoio emocional e por sempre me encorajar a dar o meu melhor.

Agradeço aos amigos Artur de Paulo Abreu Martinez, João Pedro Jesus de Abreu Martinez, Marisa Silva e todos os outros que me auxiliaram de alguma forma durante o mestrado. Sua amizade e suporte foram fundamentais para que eu pudesse enfrentar os desafios e dificuldades deste período.

Por fim, agradeço a Deus por me proporcionar a oportunidade de conhecer todas essas pessoas incríveis e por me guiar em cada etapa do caminho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Fidelis, Taylor; Lopes, Hélio. **Uma abordagem de ciências de dados e atuaria para fundamentação de estratégias de diluição de riscos envolvendo ventos extremos no sul do Brasil**. Rio de Janeiro, 2023. 96p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Aumento de eventos climáticos extremos está colocando empresas de seguros em risco, com perdas que chegam a bilhões de dólares. No Sul do Brasil, municípios sofreram perdas devido a eventos climáticos, incluindo um ciclone bomba que causou prejuízos próximos a R\$ 2 bilhões. As perdas são em grande parte seguradas, mas avaliar a probabilidade de perdas devido a desastres naturais é difícil devido à dependência intrínseca entre os riscos expostos. Essa dissertação busca estudar ventos extremos na região Sul do Brasil, visando entender como precificar e diluir o risco em áreas de alto impacto. A pesquisa envolve a análise de dados meteorológicos, econômicos, sinistros reportados por seguradoras, prêmios reportados por seguradoras, estrutura populacional, PIB, relevo e outras variáveis relevantes para a pesquisa. O objetivo é estimar cenários de perdas decorrentes de eventos extremos e oferecer informações relevantes para avaliar estratégias de diluição de risco de perdas econômicas. A dissertação mistura distintas áreas, incluindo Economia, Atuária, Ciência de Dados, Estatística e Matemática.

Palavras-chave

Atuaria; Seguro climático; Economia; Ciência de dados; Informática.

Abstract

Fidelis, Taylor; Lopes, Hélio (Advisor). **A data science and actuarial approach for grounding risk dilution strategies involving extreme winds in Southern Brazil**. Rio de Janeiro, 2023. 96p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Increasing extreme weather events are putting insurance companies at risk, with losses reaching billions of dollars. In the South of Brazil, municipalities have suffered losses due to climate events, including a bomb cyclone that caused losses of around R\$ 2 billion. These losses are largely insured, but evaluating the probability of losses due to natural disasters is difficult due to the intrinsic dependence between exposed risks. This dissertation seeks to study extreme winds in the Southern region of Brazil, aiming to understand how to price and dilute risk in high impact areas. The research involves the analysis of meteorological and economic data, insurance claims reported by insurers, premiums reported by insurers, population structure, GDP, topography, and other relevant variables for the research. The objective is to estimate loss scenarios resulting from extreme events and offer relevant information to evaluate strategies for diluting the risk of economic losses. The dissertation blends distinct areas, including Economics, Actuarial Science, Data Science, Statistics, and Mathematics.

Keywords

Actuary; Weather insurance; Economy; Data Science; Informatics.

Sumário

Lista de figuras

Lista de tabelas

1	Introdução	13
2	Revisão da literatura	16
2.1	Formação do vento	17
2.2	Efeito do aquecimento global na formação dos ventos e perspectiva do setor segurador mundial	18
2.3	Classificação do vento e danos	20
2.4	Instrumentos brasileiros de captação de dados sobre a velocidade e direção do vento	22
2.5	Perdas econômicas provocadas por tempestades de Ventos no Sul do Brasil	24
2.6	Revisão da literatura atuarial em relação aos efeitos climáticos no setor segurador e métodos de precificação	27
2.7	Método de simulação Monte Carlo	32
2.8	Seguros climáticos	33
2.9	Interpolação espacial	35
2.10	Teoria de valores extremos	38
3	Metodologia	41
3.1	Dados e Fontes	41
3.2	Tratamento dos Dados	42
3.3	Estrutura geral da Metodologia	43
3.4	Introdução as Análises descritivas usadas	46
3.5	Distribuição Generalizada de Valores Extremos (GEV)	53
3.6	Precificação de seguro climático	57
3.7	Interpolação espacial	60
4	Resultados	61
4.1	Análises descritivas	61
4.2	Resultado dos ajustes das GEV	63
4.3	Interpolação espacial das probabilidades de ventos extremos e de prêmios por município com base nos dados das 42 estações meteorológicas	64
4.4	Classificação de locais de riscos	66
4.5	Precificação de seguros climáticos com base na estrutura de risco	71
4.6	Discussão dos resultados	73
5	Considerações finais	77
6	Referências bibliográficas	79
6.1	Anexos	88

Lista de figuras

Figura 2.1	Ilustração circulação geral da atmosfera terrestre.	17
Figura 2.2	valores de danos por tipo de evento climático entre 2013 e 2019 no Sul do Brasil e São Paulo.	25
Figura 2.3	Proporção de danos por tipo de evento climático entre 2013 e 2019 no Sul do Brasil e São Paulo.	26
Figura 2.4	Valor total de danos por tempestade de ventos por setor entre 2013 e 2019 no Sul do Brasil e São Paulo.	27
Figura 2.5	Proporção de danos por tempestade de ventos por setor entre 2013 e 2019 no Sul do Brasil e São Paulo.	28
Figura 2.6	Ideia genérica do Método de Monte Carlo	32
Figura 3.1	Posicionamento de todos municípios no mapa a esquerda e a direita o mapa com o posicionamento das estações meteorológicas.	42
Figura 3.2	Estrutura geral da Metodologia	44
Figura 3.3	Boxplot mensal dos dados de rajada máxima horária do vento(m/s) da estação meteorológica A1E3 no período de 2010 á 2020.	47
Figura 3.4	Gráfico de espectro de potência global a esquerda e o gráfico de espectro de potência wavelet a direita, da série velocidade máxima dos ventos (m/s) da estação A1E3.	49
Figura 3.5	Rosas dos ventos trimestrais no período de 2010 até 2020 da velocidade máxima do vento na estação A1E3 ,com intensidade de danos classificadas segundo a escala de Beaufort.	50
Figura 3.6	A esquerda Mapa de Densidade de probabilidade de ventos extremos por localidade e a direita Gráfico de Pontos em 3D de probabilidades de ventos extremos por localidade.	52
Figura 3.7	Mapa altimétrico com gradiente de cor do Sul do Brasil	53
Figura 4.1	A direita temos o gráfico de probabilidades de ventos acima de 20m/s e a esquerda o gráfico de perdas econômicas por vendaval reportadas por todos municípios agrupadas de 2013 até 2019 e corrigidas pela inflação.	67
Figura 4.2	A esquerda temos o gráfico de probabilidades de ventos acima de 20m/s e a direita o gráfico de densidade populacional.	68
Figura 4.3	A Direita temos o mapas das probabilidades de ventos acima de 20m/s e a esquerda o mapa de densidade do PIB de 2020 considerando apenas municípios com valores menores que R\$ 10.000.000 para melhor visualização	69
Figura 4.4	A esquerda temos o gráfico de densidade das probabilidades de ventos acima de 20m/s e a direita o mapa altimétrico com gradiente de cor	69
Figura 4.5	A esquerda o Mapa de calor por municípios das probabilidades de ventos acima de 20m/s e a direita o gráfico em 3D das probabilidades de ventos acima dos 20m/s interpoladas com base no modelo 3 onde é trazida apenas a vista frontal iniciando no Rio Grande do sul e com o fundo São Paulo	70

Lista de tabelas

Tabela 2.1	Comparação entre escalas de classificação de danos provocados pela velocidade do vento.	21
Tabela 2.2	Principais instrumentos utilizados para captação de dados climáticos.	22
Tabela 2.3	Principais métodos de análise descritiva do vento empregados na literatura.	24
Tabela 2.4	Revisão da literatura atuarial	29
Tabela 2.5	Comparação entre Métodos de precificação de seguros climáticos	34
Tabela 2.6	Resumo dos artigos sobre precificação de seguros climáticos mais Recentes	35
Tabela 2.7	Resumo dos Métodos de Interpolação	36
Tabela 2.8	Resumo dos Métodos de <i>Cross Validation</i> para Interpolação	37
Tabela 4.1	Resultados do R-squared Score para modelos de interpolação RBF	65
Tabela 6.1	Anexo 1 - Informações das estações Meteorológicas e Análises descritivas básicas da variável rajada máxima horária de vento (m/s)	88
Tabela 6.2	Anexo 2 - Resumo dos ajuste dos parâmetros de escala, forma e posição.	89
Tabela 6.3	Anexo 3 - Intervalos de confiança ao nível de 99,5% dos parâmetros de escala, forma e posição.	90
Tabela 6.4	Anexo 4 - Testes de aderência.	91
Tabela 6.5	Anexo 5 - Classificação de risco das estações meteorológicas-Parte I.	92
Tabela 6.6	Anexo 6 - Classificação de risco das estações meteorológicas-Parte II.	93
Tabela 6.7	Anexo 7 - Siglas das Tabelas do anexo 6 e 7.	93
Tabela 6.8	Anexo 8 - Escala de classificação de Riscos das Tabelas do anexo 6 e 7.	94
Tabela 6.9	Anexo 12- Área de classificação de risco correspondendo aos 6 modelos de interpolação espacial e considerando probabilidade de ventos extremos acima de 20m/s	95
Tabela 6.10	Anexo 13- Gráficos de densidade e pontos com a Variação das taxas de sinistralidade de 10%,20% e 30%	96

Lista de Abreviaturas

IBGE – Instituto Brasileiro de Geografia e Estatística
GEV – Distribuição generalizada de valores extremos
BC – Banco Central
RBF – Radial Basis Function
IDW – Inverse Distance Weighting
SpatialCV – Validação Cruzada Espacial
StratifiedCV – Validação Cruzada Estratificada
K-FoldCV – Validação Cruzada com K Dobras
Leave-One-OutCV – Validação Cruzada com Exclusão de Um por Vez
FDP – Função de Densidade de Probabilidade
PIB – Produto Interno Bruto
S2iD – Sistema Integrado de Informações sobre Desastres
FDP – Função Densidade de Probabilidade
i.i.d – igualmente identicamente distribuído
BC – Banco Central do Brasil
VAPM – Ventura Arbitrage Pricing Model
CV – Cross Validation
TVE – Teoria de Valores Extremos
SUSEP – Superintendência de Seguros Privados
IPCA – Índice Nacional de Preços ao Consumidor Amplo
INMET – Instituto Nacional de Meteorologia

*"Confia ao Senhor as tuas obras, e teus
pensamentos serão estabelecidos."*

Provérbios 16:3, .

Introdução

Empresas de seguros em todo o mundo estão em risco devido ao aumento da frequência de eventos climáticos extremos (INSTITUTE, 2021). De acordo com o Swiss Re Institute, em 2021, as perdas cobertas por seguradoras com catástrofes naturais atingiram US\$ 105 bilhões, com um padrão de aumento anual de 5% a 6% nas últimas décadas;. (INSTITUTE, 2021)

Na região Sul do Brasil, entre 2013 e 2019, os municípios sofreram perdas de R\$ 11 bilhões devido a eventos climáticos. Deste valor, R\$ 931,5 milhões foram provocados por tempestades locais, convectivas e vendavais, responsáveis por 664 ocorrências (S2ID, 2023). Dentre essas ocorrências, é possível elencar, no ano de 2020, um ciclone bomba que atingiu a região sul do Brasil em junho, deixando um rastro de destruição em diversos municípios. Segundo a Defesa Civil de Santa Catarina, os prejuízos chegaram próximos a R\$ 2 bilhões, afetando mais de um milhão de pessoas.

Uma grande parte dessas perdas é segurada, e essa tendência deve continuar à medida que mais áreas em risco são identificadas pela Defesa Civil em cada estado do sul do Brasil. Neste cenário, avaliar a probabilidade de perdas decorrentes de desastres naturais pode ser difícil, já que as perdas têm um comportamento diferente dos métodos tradicionais de precificação que o mercado vem adotando, que em sua maioria são baseados no teorema central do limite, históricos próprios de perdas ou por modelos trazidos por órgãos regulamentadores de mercado.

De acordo com (BRÖNNIMANN et al., 2019), um dos elementos chave que faltam nos modelos tradicionais é a dependência intrínseca entre os riscos expostos. Por exemplo, um vendaval pode causar várias reivindicações ao mesmo tempo, e os riscos de estarem geograficamente próximos uns dos outros são altos, o que resulta em valores de sinistros altamente correlacionados.

Esses dados evidenciam tanto uma lacuna na literatura quanto na necessidade do mercado pela procura de novos métodos e novas formas de analisar e precificar esses eventos extremos. Nesse contexto, considerando o número elevado de eventos extremos, esta dissertação se restringe ao estudo de apenas um evento climático, ventos extremos.

Ao considerar a dependência intrínseca entre os riscos expostos, fica evidente que a análise deve ser feita levando em consideração várias regiões e não apenas uma localidade. Para atender a avaliação de mais localidades, essa dissertação tem como foco toda região Sul do Brasil. A escolha dessa região se deve a essa região apresentar um número significativo de eventos catastróficos envolvendo tempestades de vento.

O fato em questão que motiva esta pesquisa é o alto impacto de ventos extremos em determinadas regiões. Será possível diluir os riscos em regiões com alto impacto de ventos extremos, seja com as regiões vizinhas ou considerando uma área maior? Quando levamos em conta outras variáveis, como o relevo, a distribuição da população e o PIB, bem como os aspectos construtivos de cada região, a variabilidade desses fatores em áreas de risco pode fornecer uma estratégia de precificação? Partindo dessas questões, esta dissertação se justifica.

O diferencial desta pesquisa é a mistura de distintas áreas para abordar esse problema, incluindo Economia, Atuária, Ciência de Dados, Estatística e Matemática. O impacto que essa dissertação proporciona, tanto para o mercado quanto para a sociedade, está na caracterização de novos problemas e na oferta de informações relevantes para avaliar estratégias de diluição de risco de perdas econômicas causadas por ventos extremos, bem como ver caminhos alternativos aos existentes.

Os objetivos específicos da pesquisa consistem em, primeiramente, adquirir conhecimento sobre a estrutura de risco por meio da análise de dados de todos os municípios localizados na região sul do Brasil. Essa análise levará em consideração dados meteorológicos, econômicos, sinistros reportados por todas as seguradoras, prêmios reportados por todas as seguradoras, estrutura populacional de cada município, produto interno bruto (PIB), relevo e outros dados relevantes para a pesquisa.

Em segundo lugar, com base no conhecimento adquirido sobre a estrutura de risco, a pesquisa tem como objetivo estimar cenários de perdas decorrentes de eventos de tempestades de vento e avaliar a utilização de seguros climáticos como uma alternativa para a precificação de prêmios por município. Por fim, a pesquisa analisa cenários em que a frequência de ventos extremos é maior devido à influência do aquecimento global.

As metodologias empregadas nesta dissertação incluem análises descritivas robustas, como a transformada de wavelet, boxplot temporal, mapas de calor, ajuste de distribuições generalizadas de valores extremos, rosa dos ventos,

interpolação espacial, seguros climáticos, entre outras análises. Quanto aos principais resultados, destacam-se a caracterização de áreas de risco no sul do Brasil, análises descritivas sobre ventos extremos e a precificação de seguros climáticos, levando em consideração a localidade e a influência do aumento da frequência de eventos extremos no mundo.

Quanto às principais limitações desta dissertação, elas incluem a variabilidade de métodos empregados e a quantidade de análises realizadas, o que a torna rica em informações e novos caminhos a seguir, mas mais complexa de se realizar uma análise totalmente conclusiva e simples. Quanto à estrutura desta dissertação, ela se divide em revisão da literatura, onde é apresentada desde uma breve explicação e aprofundamentos sobre o evento climático vento até discussões de métodos de precificação e interpolação espacial.

A metodologia é apresentada no passo a passo tanto das análises descritivas como a modelagem de distribuições generalizadas de valores extremos até como foi realizada a precificação de seguros climáticos e a interpolação espacial dos valores de prêmios e probabilidades. Os resultados apresentam todo o repertório de análises e modelagens implementadas. Por fim, as considerações finais apresentam uma análise geral dos resultados encontrados e, com base nestes, é feita a discussão de possíveis passos futuros desta pesquisa e delineamentos para os problemas encontrados por esta pesquisa.

Revisão da literatura

É possível adotar alguma estratégia de diluição de risco financeiro para danos provocados por tempestades de ventos no sul do Brasil, levando em consideração o aumento gradativo da frequência destes eventos decorrente do avanço do aquecimento global no mundo? Partindo desta questão norteadora, acabou culminando em uma série de indagações frente à literatura para busca da formulação de uma resposta, o que acabou resultando nesta dissertação sendo estas: o que vem a ser o evento climático ventos extremos? Como este pode ser caracterizado? Quais são os dados que melhor descrevem esse fenômeno? Como este afeta o sul do Brasil por localidade? Qual o histórico de perdas existentes? Como caracterizar os danos de acordo com a velocidade do vento? Como realizar o mapeamento de locais de risco? Quais modelos descritivos é possível utilizar para melhor compreensão? Quais são os modelos mais empregados para precificar seguros ou estratégias de diluição de risco para este evento e localidade? E como o avanço do aquecimento global pode afetar o mercado segurador no Sul do Brasil em específico para o evento vendaval?

Partindo destas questões, foi possível adentrar na literatura e responder cada uma delas e encontrar por meio desta uma linha de ação para construção desta dissertação. Assim, esta seção se divide nos seguintes subtópicos: Vento e sua formação, Classificação dos ventos e danos, Histórico de perdas econômicas provocadas por tempestades de Ventos no sul do Brasil, Instrumentos de captação de informação do vento, Análises descritivas do vento, Revisão da literatura atuarial em relação aos efeitos climáticos no setor segurador, Métodos de precificação de seguros climáticos, Métodos de Interpolação espacial, Métodos de *Cross Validation* para Interpolação espacial.

2.1

Formação do vento

De acordo com o estudo de (TOMASINI, 2012), o vento pode ser descrito como - a energia de movimento nas correntes de circulação de ar resultante das diferenças de temperatura e dos gradientes de pressão entre distintas regiões do planeta -. Esse mesmo estudo identifica os principais fatores que influenciam na formação dos ventos, que são: Radiação solar, Movimento de rotação da terra e Variabilidade sazonal de distribuição de energia solar, na superfície terrestre.

Dado o conhecimento dos principais fatores para formação do vento, a Figura 2.1 apresenta a circulação geral da atmosfera, que mostra como funciona a formação dos ventos levando em conta a radiação solar que incide no globo terrestre, em que, é maior nas zonas equatoriais e menor nas zonas polares, devido ao balanço energético da Terra (CORREIA, 2016). Para um aprofundamento maior em relação ao vento e sua formação é recomendado a leitura dos seguintes trabalhos (CORREIA, 2016), (CANDIDO et al., 2012), (WREGE et al., 2012) e (REIS et al., 2011).




Figura 2.1: Ilustração circulação geral da atmosfera terrestre.

Fonte: Adaptado de (CORREIA, 2016)

De acordo com (CORREIA, 2016), a Figura 2.1 apresenta a circulação geral da atmosfera, que mostra como funciona a formação dos ventos levando em conta a radiação solar que incide no globo terrestre. Quando a radiação solar incide sobre as zonas equatoriais, proporciona um aquecimento maior da superfície

terrestre, que por sua vez faz com que o ar aqueça e suba para a estratosfera, onde é resfriado devido às baixas temperaturas encontradas nesta altitude sob as zonas *Hadley cell*. Assim, o ar resfriado retorna à superfície sob as zonas terrestres, gerando um movimento cíclico de aquecimento e resfriamento do ar, o que, por decorrência deste ciclo *Hadley cell*, provoca o movimento do ar, gerando o vento.

Já nas zonas subpolares, ocorre o mesmo ciclo de aquecimento, porém no sentido inverso, conforme apresentado no *Subpolar low*. Tal inversão se deve ao efeito do movimento da massa de ar frio do ciclo *Hadley cell*, que acaba descendo sob a superfície da zona subpolar, o que acaba se aquecendo novamente nesta superfície e se resfriando na estratosfera sob os polos norte e sul. E, por fim, o ar faz o ciclo reverso até voltar ao ciclo de *Hadley cell* e começar novamente.

O movimento do ar também sofre influência da rotação da Terra, que impulsiona o ar para um movimento no sentido horário em relação à rotação da Terra, que é no sentido anti-horário. A variabilidade sazonal de distribuição de energia solar na superfície terrestre está relacionada tanto com a mudança de noite e dia como no movimento de translação e precessão da Terra.

2.2

Efeito do aquecimento global na formação dos ventos e perspectiva do setor segurador mundial

Existem algumas evidências de que o aquecimento global está afetando os ventos em todo o mundo. Um estudo publicado em 2019 no periódico científico *Nature Climate Change* analisou dados de satélite e descobriu que os ventos do Hemisfério Sul estão se intensificando devido ao aumento da temperatura do oceano e à redução da camada de ozônio sobre a Antártica. Isso pode ter implicações significativas para o clima global, incluindo um aumento da intensidade e frequência de eventos climáticos extremos (MARSHALL; THOMPSON; WAUGH, 2019).

Outro estudo, publicado em 2020 no periódico *Geophysical Research Letters*, analisou os ventos sobre a Groenlândia e descobriu que eles estão se tornando mais fracos e mais variáveis devido ao derretimento do gelo na região. Isso pode afetar a circulação oceânica e, por sua vez, o clima em todo o mundo. (HANNA; FETTWEIS; HALL, 2020)

Além disso, o aumento da temperatura do ar também pode afetar a direção e a velocidade dos ventos. Um estudo de 2018 publicado no periódico "Na-

ture Climate Change" descobriu que a mudança climática está causando uma mudança na direção dos ventos ao redor do equador, o que pode ter consequências significativas para a circulação oceânica e a distribuição de nutrientes no oceano. (LIGUORI et al., 2018)

Esses são apenas alguns exemplos de como o aquecimento global está afetando os ventos em todo o mundo. Como o clima é um sistema complexo e interconectado, é difícil prever todas as implicações das mudanças no vento para o clima global. No entanto, é claro que o aquecimento global está tendo um impacto significativo no clima em todo o mundo.

De acordo com o Swiss Re Institute, as perdas cobertas por seguradoras com catástrofes naturais aumentaram em uma taxa anual de 5% a 6% nas últimas décadas, atingindo US\$ 105 bilhões em 2021 (INSTITUTE, 2021). Essas perdas são resultado direto do aquecimento global e das mudanças climáticas em curso, que estão aumentando a frequência e a intensidade de eventos extremos, como tempestades, inundações, incêndios florestais e secas prolongadas. Como resultado, o mercado segurador mundial está cada vez mais preocupado com os impactos do aquecimento global e tem buscado formas de gerenciar melhor os riscos associados a esses eventos (FORUM, 2021; INITIATIVE, 2019; SUPERVISORS, 2019).

Em relação às taxas de evolução, um estudo de (ACKERMAN; STANTON; BUENO, 2009) analisou o impacto das mudanças climáticas nos custos de seguros em diferentes setores da economia. Os autores concluíram que os custos de seguros podem aumentar entre 10% e 40% em alguns setores até 2050 devido aos efeitos do aquecimento global.

Os estudos analisados não apresentaram uma relação direta entre as taxas de evolução do aquecimento global e os vendavais. O aquecimento global pode contribuir para a intensificação de eventos climáticos extremos, como tempestades e furacões, mas a relação exata é complexa e ainda não totalmente compreendida.

Além disso, os vendavais são eventos locais e podem ser influenciados por fatores como topografia e características geográficas da região em questão. Portanto, é difícil estabelecer uma relação direta entre o aquecimento global e as taxas de evolução dos vendavais. No entanto é possível partir de taxas variadas, entre 10% e 40% como abordado por (ACKERMAN; STANTON; BUENO, 2009) e usar estas para fins de simulação por proximidade de níveis de perdas e avaliar com o passar dos anos cada localidade de interesse.

2.3

Classificação do vento e danos

Neste tópico é explorado os efeitos que o vento proporciona na superfície terrestre, como é medida sua intensidade de dano. De acordo com os trabalhos (CANDIDO et al., 2012), (CORREIA, 2016) e (WREGGE et al., 2012) os efeitos que o vento pode proporcionar na superfície está associado a vários fatores como:

- Velocidade do vento;
- Intensidade do vento;
- Direção do vento;
- Rugosidade do terreno;
- Características das construções;
- Tipo de vegetação;
- Altitude da superfície;
- Época do ano.

O vento pode exercer tanto efeitos benéficos para a civilização humana, como auxiliando na produção energética, na polinização das plantas e na formação de chuvas, bem como pode causar grandes catástrofes, como a destruição de construções, florestas e ser responsável pela formação de tornados, ciclones, furacões e outros fenômenos atmosféricos (FIDELIS, 2020).

O estudo do vento e sua compreensão tornam-se cruciais para a realização das atividades humanas, como sobrevivência, reparos e preparação para os diversos fenômenos provocados por ele. Com isso, ao longo do tempo, vários pesquisadores desenvolveram escalas com o objetivo de obter uma classificação qualitativa para determinar os impactos causados pelos ventos nos elementos encontrados no solo ou na água (FIDELIS, 2020).

Entre as várias escalas existentes, a Tabela 2.1 apresenta uma comparação da classificação de velocidade do vento em quatro escalas utilizadas no Brasil por diversas instituições, como a Marinha do Brasil, o Instituto Nacional de Pesquisas Espaciais-INPE, a Defesa Civil, entre outras. As escalas são: (i) Escala Brasileira de Ventos-EBRAV, (ii) Escala de Beaufort, (iii) Escala Fujita (FUJITA, 1971) e (iv) Escala Torro.

Quanto à aplicação dessas escalas, pode-se classificar desde áreas para análise de potenciais eólicos até a avaliação de danos de ciclones e tornados. Exemplos de trabalhos e aplicações usando essas escalas podem ser vistos em: (STAUT, 2011), (CANDIDO et al., 2012), (RAMOS; SEIDLER, 2011), (HORNES; BALICKI, 2018), (MOREIRA; SILVEIRA, 2013) e outros.

Tabela 2.1: Comparação entre escalas de classificação de danos provocados pela velocidade do vento.

Velocidade do vento em m / s	EBRAV	Classificação aproximada da escala Beaufort	Classificação aproximada da escala fujita	Classificação aproximada da escala Torro
0 a 13,8	0	Entre 1 e 6	-	-
13,8 a 22,22	1	Entre 7 e 8	F0	T0
22,22 a 27,77	2	Entre 9 e 10	F0	T1
27,77 a 36,11	3	Entre 11 e 12	Entre F0 e F1	Entre T1 e T2
36,11 a 44,44	4	12	F1	Entre T2 e T3
44,44 a 55	5	12	Entre F1 e F2	Entre T3 e T4
55 a 72,22	6	12	Entre F2 e F3	Entre T4 e T5
Acima de 72,22	7	12	Entre F3 e F5	Entre T6 e T11

Fonte: Adaptado de (CANDIDO et al., 2012).

A Tabela 2.1 apresenta uma comparação entre escalas de classificação de danos provocados pela velocidade do vento. A tabela inclui quatro escalas: EBRV, Beaufort, Fujita e Torro. Cada escala é caracterizada por uma faixa de velocidades de vento e uma classificação aproximada dos danos causados. A coluna da esquerda indica a faixa de velocidades do vento em metros por segundo, enquanto as outras colunas indicam as classificações aproximadas das diferentes escalas para cada faixa de velocidades.

A escala EBRV é usada no Brasil para classificar o dano causado pelo vento. A escala Beaufort é uma escala de vento amplamente utilizada que vai de 0 a 12, que mede a força do vento com base na observação visual dos efeitos do vento na superfície terrestre. A escala Fujita é usada para medir a intensidade de um tornado com base na destruição observada em estruturas e árvores. A escala Torro é uma escala de tornados europeia que leva em consideração a intensidade do vento, o tipo de terreno e a quantidade de danos observados.

Realizando a comparação entre as escalas, tem-se que a escala de Beaufort é mais detalhada nas classificações para velocidade dos ventos abaixo dos 36,4 m/s e para valores acima esta é ineficaz. Já as escalas Fujita e Torro são mais eficazes para valores superiores 28,1 m/s, e ineficazes para valores menores. Por fim, a EBRV apresenta maior abrangência em detalhamento contemplando tanto valores acima como abaixo dos 28,1 m/s. Quanto aos níveis de classificação de danos com referência a escala da EBRV são os seguintes:

- Nível 0: Danos desprezíveis
- Nível 1: Danos leves
- Nível 2: Danos moderados
- Nível 3: Danos acentuados
- Nível 4: Danos graves
- Nível 5: Danos muito graves
- Nível 6: Danos catastróficos
- Nível 7: Danos devastadores

Embora estas escalas tentem repercutir o efeito do vento na provocação de danos, vale ressaltar, que os danos provocados por uma faixa de velocidade dos ventos variam de região para região, dado que cada região apresenta uma rugosidade de terreno e estruturas de construções diferentes.(CANDIDO et al., 2012)

2.4

Instrumentos brasileiros de captação de dados sobre a velocidade e direção do vento

Em relação aos instrumentos empregados para obtenção de dados a respeito do vento , são apresentados por meio da Tabela 2.2 os instrumentos utilizados, as variáveis retiradas, a fonte onde podem ser retiradas e uma breve discussão da sua utilização e vantagens.

Tabela 2.2: Principais instrumentos utilizados para captação de dados climáticos.

INSTRUMENTO	VARIÁVEIS	FONTE	DESCRIÇÃO
Estações meteorológicas automáticas	Velocidade do vento, Direção do vento, Umidade do ar, Temperatura do ar, Pressão atmosférica, Altitude, Longitude, Latitude, Precipitação e Radiação solar	Instituto Nacional de meteorologia -INMET	Dados Horários com cobertura de grande parte do Brasil e considerável histórico de dados
Satélites	Usado para monitorar o tempo e o clima da Terra. Construção de Cartas sinóticas, Formações de nuvens, luzes das cidades, queimadas, efeitos de fontes, aurora, tempestades de raios e poeira, superfícies cobertas por neve e gelo e os limites das correntes oceânicas são algumas informações ambientais coletadas por meio dos satélites meteorológicos.	Instituto Nacional de Meteorologia - INMET ,NASA, Instituto Nacional de pesquisas espaciais-INPE, Earth.nullschool e entre outros	Considerável base de imagens e cobertura de todo o Brasil, No entanto exige um poder computacional maior para análise.
Balões meteorológicos	Pressão atmosférica, Temperatura do ar, Umidade do ar, Direção e velocidade dos ventos	Instituto Nacional de Meteorologia - INMET	Cobertura de pouca área no Brasil e apresenta um histórico pequeno de dados.
Boias meteorológicas	Velocidade do vento, Direção do vento, umidade do ar, temperatura do ar, pressão atmosférica, Longitude, Latitude, Radiação solar e Temperatura da superfície do mar	Marinha do Brasil - Pnboia	Cobertura da costa brasileira com histórico considerável de dados
Estações meteorológicas Convencionais	Velocidade do vento, Direção do vento, Umidade do ar, Temperatura do ar, Pressão atmosférica, Altitude, Longitude, Latitude, Precipitação e Radiação solar	Instituto Nacional de Meteorologia - INMET	Cobertura de pequena área brasileira e obtenção de dados feita de forma manual

Fonte: Elaboração própria

Analisando a Tabela 2.2, fica evidente que os dados provindos das estações meteorológicas automáticas, Boias meteorológicas e as imagens de satélite

se demonstraram mais robustas que os demais instrumentos. No entanto, as imagens de satélite exigem mais tempo de processamento para análise das variáveis climáticas.

Quanto à aplicação em pesquisas, as estações meteorológicas automáticas são amplamente utilizadas para análise das variáveis climáticas e seus efeitos na superfície, devido à facilidade de manejo dos dados e interpretações. Diversos trabalhos apresentam a utilização de dados de estações meteorológicas automáticas em diferentes contextos e regiões do Brasil. No entanto, a confiabilidade dos dados das estações meteorológicas automáticas tem que ser analisado de forma minuciosa, dados que pode apresentar dados faltantes por conta de manutenção e eventuais anormalidades dos sensores utilizados.

O estudo realizado por (SILVA; SOUZA; MACHADO, 2018) analisou a variabilidade climática em Santa Catarina e identificou uma tendência de aumento da temperatura e diminuição nas chuvas na região oeste. Já (LIMA; SANTOS, 2019) mostrou que o aquecimento global pode estar afetando a velocidade do vento em São Paulo, enquanto (OLIVEIRA et al., 2019) avaliaram o comportamento hidrológico de uma microbacia, evidenciando a alta variabilidade hidrológica influenciada pela topografia e cobertura vegetal.

Por fim, (SILVA et al., 2017) realizaram uma análise da distribuição espacial e temporal da precipitação em bacias hidrográficas do semiárido brasileiro, identificando que a distribuição da precipitação é altamente variável na região, influenciada por fatores como altitude e localização geográfica. Todos esses trabalhos demonstram a importância das estações meteorológicas automáticas para o monitoramento e análise de diferentes aspectos relacionados ao clima e hidrologia no Brasil.

2.4.0.1

Análise descritiva do vento

Este tópico traz uma breve discussão acerca das metodologias de descrição da variável vento usualmente empregadas e validadas pela literatura. Segue por meio da Tabela 2.3, um breve resumo das principais metodologias usualmente empregadas para análise descritiva do vento, apresentando as descrições dos métodos, objetivos e algumas referências em que foram empregados.

Tabela 2.3: Principais métodos de análise descritiva do vento empregados na literatura.

Método	Descrição	Objetivo	Referências
Wavelets	A wavelet é uma técnica matemática que fornece um compromisso viável no dilema de resolução de tempo e frequência causado pelo princípio da incerteza de Heisenberg. Desde os anos 80, as wavelets têm sido amplamente aplicadas em processamento de sinais e imagens, medicina, geofísica e astronomia. No entanto, as aplicações em investigações econômicas são mais recentes.	Investigar a força geral de fenômenos periódicos em relação a frequência e o tempo.	(NASCIMENTO et al., 2020),(WREGE et al., 2012),(GOUVEIA, 2011) e (PERRUCCI, 2018)
Rosa dos ventos temporal	Fornece uma análise temporal discreta da frequência da velocidade do vento em relação a direção do vento.	Investigar as direções do vento e sua velocidade ao longo dos meses por região.	(CASTELHANO; ROSEGHINI, 2018), (LEITE; FILHO, 2006) e (BRAND, 2014)
Boxplot temporal	Fornece uma análise descritiva em relação aos meses da velocidade do vento.	Investigar possível sazonalidade e padrão de intensidade da velocidade do vento em um período específico.	(CASTELHANO; ROSEGHINI, 2018),(LEITE; FILHO, 2006)e(BRAND, 2014)
Série temporal	Fornece um estudo temporal da série de velocidade do vento ao longo do período analisado.	Investigar padrões e realizar previsões que geram informações relevantes da velocidade do vento em uma dada região considerando um dado período.	(NASCIMENTO et al., 2020),(GOUVEIA, 2011) e (PERRUCCI, 2018)
Histograma e densidade	Fornece um estudo do comportamento da frequência da velocidade do vento.	Investigar as distribuições de frequência da velocidade do vento de uma dada região.	(NASCIMENTO et al., 2020),(WREGE et al., 2012)
Mapa de calor	Fornece um estudo do comportamento espacial de uma variável associada a sua localidade.	Ter uma visão espacial sobre qualquer variável .	(MAPBOX, 2023), (WINDY, 2023)
Mapa de densidade	Fornece um estudo do comportamento espacial de uma variável associada a sua localidade e sua relação com as vizinhas.	Ter uma visão espacial sobre qualquer variável e seu entorno .	(??), (SASTRY; SHAIKH, 2019)
Gráfico em 3D	Fornece um estudo do comportamento espacial de uma variável em três dimensões .	Ter uma visão espacial sobre qualquer variável e seu entorno .	(GHOSH; CHATTERJEE; MITRA, 2019), (ABDAL; ABDELBAKY; FAKHR, 2016)

Fonte: Elaboração própria

Em relação aos métodos apresentados por meio da Tabela 2.3, cada um traz uma peculiaridade em descrever o vento e extrair características importantes dos dados. Desta forma, o uso destes se torna um diferencial para auxiliar tanto na caracterização de uma área de risco bem como entender o fenômeno em estudo com as informações disponíveis.


2.5

Perdas econômicas provocadas por tempestades de Ventos no Sul do Brasil

Neste tópico é apresentado um resumo das perdas econômicas, advindas de desastres naturais na região Sul do Brasil e no estado de São Paulo e ao fim é dado o enfoque nas perdas provocadas pela tempestade de ventos em cada

região e nos setores mais afetados. Vale ressaltar, que embora o estado de São Paulo não seja objeto de estudo neste trabalho, os dados deste foram analisados dada a importância econômica deste. Segue por meio da Figura 2.2, um resumo dos danos ocorridos entre 2013 e 2019 e seus eventos geradores.

Figura 2.2: valores de danos por tipo de evento climático entre 2013 e 2019 no Sul do Brasil e São Paulo.




Fonte: Elaboração Própria com base nos dados do sistema integrado de informações sobre Desastres-S2iD.

Ao realizar a comparação das perdas econômicas do evento de vendaval com os demais eventos, é visto que este ocupa a quinta posição, com um valor de R\$ 931 milhões, sendo que esses valores foram corrigidos pela inflação usando o IPCA. É importante ressaltar que os valores de perdas apresentados são apenas valores reportados pelos municípios e que os danos reais em cada região são muito maiores quando se leva em conta os danos particulares da população, como carros, mobília, entre outros. Para obter a perspectiva de danos por região, segue por meio da Figura 2.3.

Em que para Figura 2.3 e Figura 2.5 :

- **Danos (R\$):** corresponde às perdas econômicas agregadas do período entre 2013 e 2019;

Figura 2.3: Proporção de danos por tipo de evento climático entre 2013 e 2019 no Sul do Brasil e São Paulo.




Fonte: Elaboração Própria com base nos dados do sistema integrado de informações sobre Desastres-S2iD.

- **RS%**: corresponde a proporção de perdas econômicas em cima dos Danos(R\$), para o estado do Rio Grande do Sul e de forma análoga SC%, PR%, SP% correspondendo aos estados de Santa Catarina, Paraná e São Paulo, respectivamente.

Ao analisar a Figura 2.3, podemos perceber a proporção de perdas econômicas causadas por tempestades de vento em cada estado. Nesse sentido, os estados do Rio Grande do Sul e Santa Catarina apresentam maiores perdas em comparação com Paraná e São Paulo. Além disso, ao examinar os dados com mais detalhes, é possível observar a distribuição dos danos por setor econômico, o que é apresentado na Figura 2.4.

Ao realizar a análise da Figura 2.4 é possível identificar os setores que sofreram mais danos em cada estado. Em que , é percebido que as tempestades de ventos trazem mais danos na agricultura , unidades habitacionais e pecuária. já a proporção de danos por setor e por região pode ser conferido por meio da

Figura 2.4: Valor total de danos por tempestade de ventos por setor entre 2013 e 2019 no Sul do Brasil e São Paulo.



Fonte: Elaboração Própria com base nos dados do sistema integrado de informações sobre Desastres-S2iD.

Figura 2.5.


Ao analisar a Figura 2.5, é possível observar que os estados de Santa Catarina e Rio Grande do Sul foram os mais afetados por danos causados por tempestades de vento, em comparação com o Paraná e São Paulo. É importante salientar que as informações financeiras apresentadas nesta seção foram utilizadas para elaborar um mapa apresentado por meio da Figura 4.1, que permitiu compreender os locais a nível municipal que relataram danos.

2.6

Revisão da literatura atuarial em relação aos efeitos climáticos no setor segurador e métodos de precificação

Ao considerar os efeitos climáticos no contexto segurador, é possível observar em trabalhos como (CHARPENTIER, 2008), (CANDIDO et al., 2012) e (GOMES; JÚNIOR; AGUIRRE, 2016) que o risco climático, e mais especifi-

Figura 2.5: Proporção de danos por tempestade de ventos por setor entre 2013 e 2019 no Sul do Brasil e São Paulo.



Fonte: Elaboração Própria com base nos dados do sistema integrado de informações sobre Desastres-S2iD.

camente as catástrofes naturais, tornaram-se cada vez mais difíceis de serem seguradas. As perdas podem ser enormes e os prêmios atuariais puros podem alcançar patamares estratosféricos, devido à forte correlação geográfica entre os danos, o que impossibilita a diversificação dos riscos de perdas por meio do teorema do limite central.

Consequentemente, é possível que em um futuro próximo não haja um mercado de seguros para eventos climáticos, uma vez que o preço pedido pelas seguradoras pode ser muito mais alto do que o preço que os segurados estão dispostos a pagar. Além disso, é importante destacar que o seguro só é viável se o risco puder ser transferido não apenas para as resseguradoras, mas também para os mercados de capitais, por meio de opções de securitização, seguros Climáticos e dentre outros (CHARPENTIER, 2008).

Portanto, é necessário aprofundar a compreensão dos eventos climáticos e buscar constantemente por parte das seguradoras, melhores métodos e estratégias que possam trazer soluções inovadoras. Isso inclui a busca por formas de diluição de risco e a adoção de novos métodos de previsão de riscos.

Compreender as possíveis soluções ou tentativas de mudar o cenário futuro segurador em relação aos eventos climáticos é fundamental. Por isso, a Tabela 2.4 apresenta uma breve descrição de alguns trabalhos desenvolvidos especificamente em relação ao evento climático tempestade de vento, que é o foco deste trabalho.

Tabela 2.4: Revisão da literatura atuarial

Resumo	Resultados	Referência
Os autores propõem um modelo geral de risco de catástrofe individual que permite que as taxas de danos sejam funções aleatórias da intensidade da catástrofe.	Ilustram formalmente o fato em que o risco de catástrofe não pode ser diversificado apenas por meio da cobrança de prêmio, como é o caso com o risco usual do "dia-a-dia",	(COSSETTE; DUCHESNE; MARCEAU, 2003)
Os autores realizam a seleção, adaptação e desenvolvimento de métodos de valor extremo para uso em seguro contra tempestades de vento. Estes ajustaram uma distribuição Generalizada de Pareto (GPD) univariada e uma nova bivariada.	Constatarem que os dois modelos levam a resultados qualitativamente semelhantes. O modelo bi-variado forneceu a imagem mais realista das incertezas reais.	(BRODIN; ROOTZÉN, 2009)
Os autores ajustaram a distribuição generalizada de valores extremos (GVE) aos dados de velocidade máxima mensal de vento registrados durante um período de 43 anos (1956 a 1971 e 1974 a 2000) em Piracicaba, Estado de São Paulo.	Os autores trazem que a distribuição de Gumbel demonstrou ser a mais adequada para modelar os dados de velocidade máxima de vento em todos os meses do ano.	(BAUTISTA; ZOCCHI; ANGELO C.C.I., 2004)
Os autores estimaram o prêmio puro único e um prêmio distorcido com base em distribuições de perdas com caldas pesadas para eventos catastróficos.	Chegaram a constatação que se deve usar o prêmio distorcido no caso dos riscos catastróficos e não o prêmio puro.	(CHARPENTIER, 2007)
Os autores aplicam teoria estatística dos valores extremos a uma investigação detalhada de um problema de seguro contra tempestades de vento, usando dados de uma estação meteorológica.	Como principais resultados dizem respeito ao uso de informações meteorológicas no seguro de vendavais em que o uso destes dados foram úteis tanto para ajustar os modelos como tirar informações indispensáveis	(ROOTZÉN; TAJVIDI, 1997)

Fonte: Elaboração própria

Ao realizar a análise dos trabalhos apresentados por meio da Tabela 2.4, foi consolidado o uso da previsão probabilística da ocorrência de ventos extremos, sendo esta de vital importância para o planejamento das atividades sujeitas aos seus efeitos adversos. Além disso, foi realizado também o estudo nos trabalhos (COSSETTE; DUCHESNE; MARCEAU, 2003), (TAKIGUCHI, 2019), (SOUSA, 2014), (BAUTISTA; ZOCCHI; ANGELO C.C.I., 2004), (BRÖNNMANN et al., 2019), (ANANIAS; LISKA, 2018), (ANNAERT; OSSELAER; VERSTRAETE, 2009) e (KACZMARSKA; JEWSON; BELLONE, 2018), todos os quais abordam a teoria dos valores extremos proposta por (FISHER;

TIPPETT, 1928). Segundo esta teoria, existem três tipos de distribuições assintóticas de valores extremos: a tipo I de *Gumbel*, a tipo II de *Fréchet* e a tipo III de *Weibull*.

Tais distribuições são frequentemente utilizadas para estimar probabilidades de ocorrência de ventos acima de valores pré-estabelecidos ou para prever o valor máximo de velocidade de vento em determinados períodos de tempo. Um problema que surge na prática em relação ao ajuste é a escolha da distribuição de valores extremos mais adequada para uma amostra de dados específica.

Para lidar com esse problema, uma alternativa é utilizar a Distribuição Generalizada de Valores Extremos (GVE), proposta por (JENKINSON, 1955), que é uma família de distribuições que inclui os três tipos de distribuições assintóticas de valores extremos (Gumbel, Fréchet e Weibull) como casos particulares.

Vários estudos têm utilizado a GVE como modelo para dados extremos de ventos e tempestades, como (LIU; WANG; HE, 2020), que utilizaram essa distribuição para modelar eventos extremos de vento em usinas eólicas *offshore*, (LIU; WANG; HE, 2019), que aplicaram a GVE para modelar eventos extremos de vento em diferentes regiões da China, e (SARHADI; SAJJADI; AHMADI, 2017), que utilizaram a GVE para modelar eventos extremos de vento em um parque eólico no Irã.

Além da escolha da distribuição adequada, outro desafio é a obtenção de dados confiáveis e representativos para a modelagem de eventos extremos de ventos e tempestades. Os dados podem ser obtidos de diferentes fontes, como registros de seguradoras, simulações baseadas em parâmetros fornecidos por órgãos reguladores ou centros especializados, ou simulações baseadas em modelos probabilísticos ajustadas sobre dados meteorológicos de uma dada região ou localidade.

No contexto desse desafio, é importante considerar a qualidade dos dados disponíveis e suas limitações. Dados obtidos por meio de parcerias entre pesquisadores e seguradoras ou resseguradoras podem apresentar limitações em relação à sua disponibilidade e representatividade geográfica, enquanto dados obtidos por meio de simulações podem ter limitações em relação à sua precisão e acurácia e estão limitados pela distribuição ajustada.

Nesse sentido, ao avaliar as distintas soluções apresentadas na literatura, é fundamental levar em conta a qualidade dos dados disponíveis e a escolha da

distribuição mais adequada para a modelagem de eventos extremos de ventos e tempestades, a fim de obter resultados mais confiáveis e representativos.

Dentre os métodos de precificação de eventos climáticos extremos apontados anteriormente, os seguros climáticos estão ganhando espaço no mercado financeiro global devido à preocupação crescente com as mudanças climáticas e a volatilidade associada às condições meteorológicas extremas (INTELLIGENCE, 2021).

Esses são contratos financeiros cujo valor está vinculado às condições climáticas em determinada região ou localidade, como contratos de opções e futuros climáticos, permitindo a transferência de riscos relacionados a eventos climáticos extremos, como furacões, secas, inundações e temperaturas extremas.

Os seguros climáticos vêm sendo empregados em diversas partes do mundo, principalmente em países com grande exposição aos riscos climáticos, como Estados Unidos, Reino Unido e Austrália. A Bolsa de Valores de Londres (LME) lançou em 2021 um contrato de futuros climáticos para o mercado europeu de energia, que permite a negociação de contratos com base na temperatura média em 15 cidades europeias (REUTERS, 2021).

No Brasil, ainda não há um mercado estruturado de seguros climáticos, mas algumas iniciativas têm sido desenvolvidas nos últimos anos. A Bolsa de Mercadorias e Futuros (BM&F) lançou um índice de preços climáticos em 2020, que reflete a variação dos preços de produtos agropecuários em função das condições climáticas (FUTUROS, 2020). Além disso, empresas de energia eólica e solar têm utilizado contratos de *hedge* climático para reduzir a exposição aos riscos climáticos em seus projetos.

A literatura acadêmica sobre seguros climáticos é vasta e aborda desde aspectos teóricos até estudos de casos em diferentes regiões do mundo (SHRESTHA; KAUR; IMRAN, 2021; LI; HAN; SUN, 2021; TSE; CHAN; WONG, 2020). (SHRESTHA; KAUR; IMRAN, 2021) apresentam uma revisão da literatura sobre o uso de derivativos climáticos e seguros climáticos como instrumentos de gestão de riscos relacionados a eventos climáticos extremos. (LI; HAN; SUN, 2021) analisam o uso de derivativos climáticos como instrumento de *hedge* em projetos de energia renovável na China. (TSE; CHAN; WONG, 2020) desenvolvem um modelo para precificar *hedge* de seguros climáticos baseados em chuvas na Austrália, considerando as mudanças climáticas.

Em resumo, os seguros climáticos e derivativos climáticos são ferramentas importantes para a gestão de riscos relacionados às mudanças climáticas

e têm sido cada vez mais utilizados em diferentes partes do mundo. O desenvolvimento de um mercado estruturado de seguros climáticos no Brasil pode ser uma oportunidade para reduzir a exposição aos riscos climáticos em setores como agricultura, energia e seguros.

2.7

Método de simulação Monte Carlo

Das técnicas para obtenção de variáveis aleatórias usualmente utilizada para fins de simulação computacional, o Monte Carlo vem sendo empregado frequentemente em trabalhos atuariais. como é visto em: (SANDSTRÖM..., 2011), (BØLVIKEN; GUILLEN, 2017), (CORRÊA; QUEIROZ; RIBEIRO, 2014), (MACEDO et al., 2015), entre outros. Segundo (FILHO, 2000) - no trato computacional, essas variáveis não são, de fato, aleatórias, mas pseudoaleatórias, pois são gerados por algoritmos determinísticos...- .

O fato determinístico é explicado segundo o mesmo autor, em que a simulação de uma variável aleatória X com qualquer tipo de distribuição de probabilidade é feita a partir da transformação de uma variável uniforme U . Assim para fins explicativos segue a Figura-2.6.

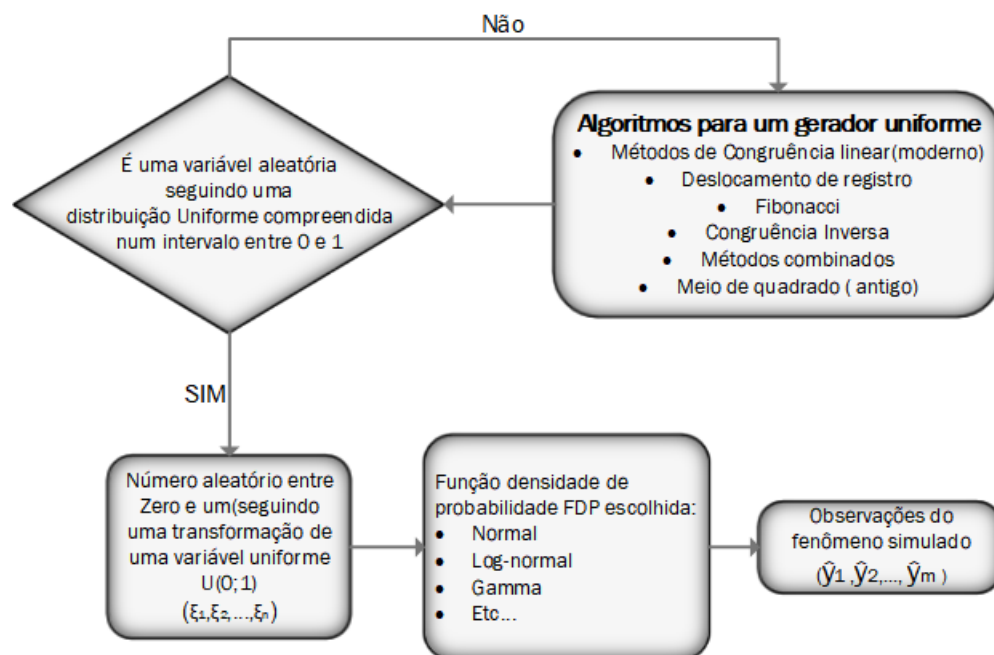


Figura 2.6: Ideia genérica do Método de Monte Carlo

A Figura-2.6 apresenta como é realizado o processo para geração de variáveis pseudo-aleatórias e possível expressar a simulação de Monte Carlo em quatro passos padrões:

1. Modelar o problema definindo uma Função de Densidade de Probabilidade(FDP) para representar o comportamento de cada uma das incertezas;
2. Gerar valores pseudo-aleatórios aderentes à FDP de cada incerteza;
3. Calcular o resultado determinístico substituindo as incertezas pelos valores gerados obtendo, assim, uma observação do problema.(Repetir os passos 2 e 3 até se obter uma amostra com o tamanho desejado de realizações.);
4. Agregar e manipular os resultados da amostra de forma a obter uma estimativa da solução do problema.

Vale ressaltar que este método como qualquer outro apenas proporciona uma aproximação da solução, portanto, é fundamental analisar o erro de aproximação. Segundo (FILHO, 2000) - A forma do erro padrão σ_g/\sqrt{n} é uma propriedade central do método de Monte Carlo, de modo que, para diminuir este erro pela metade, é necessário aumentar o número de simulações por um fator de quatro... -. Desta forma, a convergência é da ordem de raiz quadrada, devido ao fator \sqrt{n} no denominador do erro padrão. Quanto ao aprofundamento sobre Monte Carlo e demais métodos de simulação e fundamentação estatística se deu pelas seguintes literaturas: (FILHO, 2000), (CORRAR, 1993).

2.8

Seguros climáticos

Nesta seção, realizamos uma análise mais aprofundada da literatura sobre seguros climáticos, com foco nos principais métodos de precificação utilizados e em sua adequação para o mercado brasileiro. Além disso, avaliamos os métodos que consideram as principais premissas econômicas, como custo de oportunidade, taxa livre de risco, fluxo de caixa, perspectiva do agente, meta da inflação e variáveis de risco, como a probabilidade de ocorrência de ventos extremos.

Durante a revisão da literatura sobre métodos de precificação de seguros climáticos, identificamos diversos métodos. No entanto, para fins de simplificação, realizamos uma análise comparativa que inclui os métodos de precificação mais comuns, juntamente com seus pontos positivos e negativos. É importante destacar que a escolha desses métodos foi baseada em uma análise cuidadosa de diversos estudos na área. Apresentamos essa análise comparativa por meio da Tabela 2.5.

Tabela 2.5: Comparação entre Métodos de precificação de seguros climáticos

Método de Precificação	Fatores Positivos	Fatores Negativos	Referências
<i>Black-Scholes</i>	Fácil implementação, amplamente utilizado, leva em conta apenas uma fonte de risco	Pressupõe mercados eficientes, não leva em conta eventos extremos, não é adequado para ativos não negociados no mercado	(BLACK; SCHOLES, 1973)
<i>Ventura Arbitrage Pricing Model</i> (VAPM)	Incorpora múltiplas fontes de risco, leva em conta eventos extremos	Complexidade matemática, dificuldade de obtenção de dados necessários, dependência de suposições teóricas	(VENTURA, 1997)
Precificação usando Teoria de Filas	Leva em conta eventos extremos, pode incorporar preferências do agente e outras variáveis relevantes	Pode ser computacionalmente intensivo, depende da modelagem correta da fila, não leva em conta múltiplas fontes de risco	(D'AMICO; PER-SIO, 2011)
Método Baseado em Regressão	Leva em conta múltiplas fontes de risco, pode ser usado para ativos não negociados no mercado	Pressupõe relações lineares entre variáveis, sensível a <i>outliers</i> , dificuldade de obtenção de dados necessários	(HIRSHLEIFER; SHUMWAY, 2003)
Método Monte Carlo	Leva em conta eventos extremos, flexibilidade na modelagem de múltiplas fontes de risco	Computacionalmente intensivo, depende da modelagem correta dos processos estocásticos, pode ser sensível a suposições de distribuição de probabilidade	(GLASSERMAN, 2003)
Abordagens híbridas	Pode fornecer uma análise mais abrangente e precisa da precificação de seguros climáticos	Pode ser complexo de entender e de implementar	(ZHU; FUKUSHIMA, 2005)

Fonte: Elaboração própria com base nos trabalhos citados na tabela

O método Black-Scholes é amplamente utilizado e de fácil implementação, mas pressupõe mercados eficientes, não leva em conta eventos extremos e não é adequado para ativos não negociados no mercado e não leva em conta a preferências do agente. O *Ventura Arbitrage Pricing Model* (VAPM) incorpora múltiplas fontes de risco e leva em conta eventos extremos, mas possui complexidade matemática, dependência de suposições teóricas e dificuldade de obtenção de dados necessários.

A Precificação usando Teoria de Filas leva em conta eventos extremos, pode incorporar preferências do agente e outras variáveis relevantes, mas pode ser computacionalmente intensivo, depende da modelagem correta da fila e não leva em conta múltiplas fontes de risco. O método baseado em regressão leva em conta múltiplas fontes de risco e pode ser usado para ativos não negociados no mercado, mas pressupõe relações lineares entre variáveis, é sensível a *outliers* e possui dificuldade de obtenção de dados necessários.

O método Monte Carlo leva em conta eventos extremos e tem flexibilidade na modelagem de múltiplas fontes de risco, mas é computacionalmente intensivo, depende da modelagem correta dos processos estocásticos e pode ser sensível

a suposições de distribuição de probabilidade. Por fim, as abordagens híbridas podem fornecer uma análise mais abrangente e precisa da precificação de seguros climáticos, mas podem ser complexas de entender e implementar.

Considerando os trabalhos apresentados por meio da Tabela 2.5 serem mais antigos porém consistentes, foi realizado um aprofundamento em trabalhos mais recentes como apresentados por meio da Tabela 2.6.

Tabela 2.6: Resumo dos artigos sobre precificação de seguros climáticos mais Recentes

Referência	Resumo	Pontos positivos	Pontos negativos
(HU; XIE; ZHANG, 2021)	Revisão dos métodos de precificação de seguros climáticos.	Oferece uma visão geral dos métodos de precificação disponíveis para seguros climáticos. Analisa as vantagens e desvantagens de cada método.	Não apresenta novas técnicas de precificação.
(ZHANG; LI, 2021)	Precificação de seguros climáticos usando análise de componentes principais e simulação de Monte Carlo.	Combina a análise de componentes principais e a simulação de Monte Carlo para obter preços de seguros climáticos. Mostra que a abordagem proposta é eficaz na precificação de seguros climáticos.	Não considera outros fatores climáticos além da temperatura.
(RAIS; LIM; YIM, 2022)	Precificação de futuros de chuva usando o modelo oculto de Markov.	Propõe o uso do modelo oculto de Markov para a precificação de futuros de chuva. Mostra que o modelo proposto é mais preciso do que outros modelos existentes.	O modelo proposto pode não ser aplicável a outras regiões geográficas.
(VILLALOBOS; MARTINEZ; SANZ, 2021)	Revisão sistemática de métodos de precificação de seguros climáticos usando aprendizado de máquina.	Oferece uma revisão sistemática dos métodos de precificação de seguros climáticos baseados em aprendizado de máquina. Identifica as vantagens e desvantagens de cada método e discute possíveis melhorias.	Não apresenta novas técnicas de precificação.

Fonte: elaboração própria com base nos trabalhos citados na tabela

Não há um método claramente superior a todos os outros, já que cada um tem seus pontos fortes e fracos. A escolha do melhor método dependerá das características dos dados disponíveis, das preferências do agente e da complexidade que se deseja assumir. Em geral, é recomendável utilizar mais de um método para realizar uma análise mais completa e robusta.

2.9

Interpolação espacial

Para suprir a limitação de dados em áreas sem estações, torna-se necessário o uso de técnicas de interpolação espacial para estimar valores nessas regiões. Dessa forma, é possível ter uma análise mais abrangente e precisa das condições climáticas em toda a área de estudo. Existem vários métodos diferentes de interpolação espacial, cada um com suas próprias vantagens e desvantagens. Alguns dos métodos mais comuns são apresentados por meio da Tabela 2.7.

Tabela 2.7: Resumo dos Métodos de Interpolação

Método	Pontos Fortes	Pontos Fracos
IDW	Simplicidade de implementação e interpretação, facilidade de ajuste, menor custo computacional.	Possui limitações para superfícies complexas e pode apresentar resultados excessivamente suaves em regiões com poucos pontos amostrais.
Krigagem	Leva em conta a estrutura espacial dos dados e sua covariância, é eficiente para dados com alta autocorrelação espacial.	Pode apresentar dificuldades na escolha e ajuste do modelo de variograma, além de ser computacionalmente custoso para grandes conjuntos de dados.
RBF	Flexibilidade para modelar diferentes formas de superfície, incluindo superfícies com variáveis contínuas e categóricas.	Pode apresentar resultados excessivamente suaves ou com anomalias, além de demandar grande poder computacional para conjuntos de dados grandes.
Splines	Permite modelar curvaturas e mudanças de direção na superfície interpolada, além de ser robusto para outliers.	Demanda um número mínimo de pontos amostrais e pode sofrer com overfitting em superfícies complexas.
Trend Surface Analysis	Permite modelar tendências sistemáticas na superfície interpolada, é eficiente para grandes conjuntos de dados e pode ser combinado com outros métodos de interpolação.	Pode apresentar dificuldades na escolha do modelo de tendência e é menos eficiente para superfícies com alta variabilidade espacial.

Fonte: Construído com base nos seguintes trabalhos(LI et al., 2018),(HE et al., 2019),(HENGL et al., 2017),(YIN et al., 2020),(MA et al., 2021),(CARRERA; LOPEZ-CARRASCO; EGOZCUE, 2020).

A tabela apresenta um resumo dos principais métodos de interpolação, como IDW, Krigagem, RBF, Splines e Trend Surface Analysis, e seus pontos fortes e fracos. O IDW é simples e fácil de implementar, com menor custo computacional, mas pode ter limitações em superfícies complexas e resultados excessivamente suaves em regiões com poucos pontos amostrais.

A Krigagem é eficiente em dados com alta autocorrelação espacial, mas pode ser difícil escolher e ajustar o modelo de variograma e ser computacionalmente custosa para grandes conjuntos de dados. O RBF é flexível para modelar diferentes formas de superfície, mas pode ter resultados excessivamente suaves ou com anomalias e requer grande poder computacional para grandes conjuntos de dados.

As Splines permitem modelar curvaturas e mudanças de direção na superfície interpolada e são robustas para outliers, mas exigem um número mínimo de pontos amostrais e podem sofrer com overfitting em superfícies complexas. Por fim, a Trend Surface Analysis permite modelar tendências sistemáticas e é eficiente para grandes conjuntos de dados, mas pode ser difícil escolher o modelo de tendência e ser menos eficiente em superfícies com alta variabilidade espacial.

Com base em (ZHOU; HUANG; LI, 2017), a utilização de métodos de *cross validation* na interpolação espacial é importante para avaliar a qualidade do modelo utilizado e a sua capacidade de generalização para outras áreas. De acordo com (BONFILIO; WALTER; ANDRADE, 2016), esses métodos permitem determinar qual modelo de interpolação é mais adequado para cada conjunto de dados e verificar se o modelo utilizado é robusto o suficiente para lidar com diferentes formas de distribuição espacial dos dados.

Além disso, a importância dos métodos de *cross validation* na interpolação espacial é destacada por (MATHERON, 1973), que defende que a validação cruzada é essencial para a estimação de parâmetros em modelos de interpolação espacial. Já (POULSON; EPPLER, 2018) enfatizam a relevância do uso de métodos de *cross validation* na interpolação espacial para garantir a confiabilidade dos resultados obtidos.

Em relação à aplicação em estudos de precificação de seguros climáticos, (CHEN et al., 2020) destacam a importância da interpolação espacial na estimação de dados climáticos para a modelagem de preços de seguros climáticos, o que pode ser aprimorado pela utilização de métodos de *cross validation*. Segue por meio da Tabela 2.8, alguns métodos de *cross validation*.

Tabela 2.8: Resumo dos Métodos de *Cross Validation* para Interpolação

Método	Pontos Fortes	Pontos Fracos
Leave-One-Out CV	Utiliza todos os pontos disponíveis, é útil para conjuntos de dados pequenos.	Pode ser computacionalmente custoso e apresentar resultados instáveis para conjuntos de dados grandes.
K-Fold CV	Permite o uso de diferentes subconjuntos de dados para treinamento e teste, é eficiente para conjuntos de dados grandes.	Pode apresentar viés em casos de desbalanceamento ou heterogeneidade nos dados amostrais.
Monte Carlo CV	Realiza múltiplas amostragens aleatórias dos dados para treinamento e teste, reduzindo a variabilidade dos resultados.	Pode ser computacionalmente custoso para grandes conjuntos de dados.
Stratified CV	Garante uma distribuição equilibrada das classes ou valores amostrais entre os subconjuntos de treinamento e teste.	Requer que as classes ou valores amostrais sejam pré-definidos e conhecidos.
Time Series CV	Considera a ordem temporal dos dados, permitindo avaliar a capacidade de generalização do modelo para previsões futuras.	Requer que os dados amostrais tenham uma estrutura temporal e que a série temporal seja estacionária.
Spatial CV	Leva em conta a estrutura espacial dos dados, permitindo avaliar a capacidade de generalização do modelo para locais não amostrados.	Requer que os dados amostrais tenham uma estrutura espacial e que o modelo de interpolação seja capaz de capturar a dependência espacial.

Fonte: Construído com base nos seguintes trabalhos: (JAMES et al., 2013),(KUHN, 2008),(LIU; ZHANG, 2019),(MILLARD, 2013).

Ao analisar a Tabela 2.8 é possível constatar que não há um único método de cross validation que seja considerado o "melhor" para todos os casos, uma vez que a escolha depende das características específicas dos dados e do modelo de interpolação utilizado. Cada método tem seus pontos fortes e fracos.

Por exemplo, o *Leave-One-Out CV* pode ser útil para conjuntos de dados pequenos, mas pode ser computacionalmente custoso e apresentar resultados instáveis para conjuntos de dados grandes. Já o *K-Fold CV* é eficiente para conjuntos de dados grandes, mas pode apresentar viés em casos de desbalanceamento ou heterogeneidade nos dados amostrais.

Assim, a escolha do método de *cross validation* adequado para cada caso deve levar em consideração as características dos dados, o modelo de interpolação utilizado e a disponibilidade de recursos computacionais. É importante avaliar a qualidade do modelo utilizado e sua capacidade de generalização para outras áreas, utilizando as métricas adequadas para cada caso.

2.10

Teoria de valores extremos

A Teoria de Valores Extremos (TVE) em probabilidade é o campo que estuda o comportamento estocástico de extremos associados a um conjunto de variáveis aleatórias com função de distribuição qualquer $F_X(x)$. que trata dos valores extremos (máximo e mínimo) de uma série, estas séries provêm de variáveis aleatórias independentes e identicamente distribuídas (*i.i.d*), aplicadas em diversas áreas do conhecimento desde aplicações em climatologia até em precificação atuarial para catástrofes. (BAUTISTA; ZOCCHI; ANGELO C.C.I., 2004)

Esta teoria apresenta um importante resultado que se $(X_n), n \in \mathbb{N}$ é uma sequência de variáveis aleatórias reais *i.i.d.* de máximos, possui uma distribuição limite quando $n \rightarrow \infty$, que estuda o comportamento estatístico de:

$$M_n = \max(X_1, X_2, X_3, \dots, X_n) \quad (2-1)$$

Em que as variáveis aleatórias $X_1, X_2, X_3, \dots, X_n$ são independentes e têm em comum entre si, uma função de distribuição qualquer $F_X(x)$. Na prática, X_n geralmente representam medidas em intervalos de tempos regulares. Como por exemplo uma série de dados diários de velocidade máxima de vento de uma dada região. Assim temos que, M_n representa o valor máximo do processo ao longo do tempo depois de n observações, a distribuição dos valores de M_n pode

ser obtida por:

$$F_{M_n}(x) = P(M_n \leq x) = P(X_1 \leq x, \dots, X_n \leq x) = \prod_{i=1}^n P(X_i \leq x) = [F_X(x)]^n \quad (2-2)$$

Em que $x \in \mathbb{R}$ e $n \in \mathbb{N}$

A distribuição de M_n apresenta uma limitação que quando n cresce acaba sendo degenerada assim não fornecendo muita informação relevante. Esta limitação pode ser sanada pelo teorema, apresentado a seguir.

Teorema 2.1 (Fisher-Tippett, 1928) *Seja X_n uma sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d). Se existirem sequências de constantes normalizadoras $\sigma_n > 0$ e μ_n , tal que*

$$\frac{M_n - \mu_n}{\sigma_n} \rightarrow F_X^* \quad (2-3)$$

quando $n \rightarrow \infty$, em que F_X^ é uma função que segue uma distribuição não degenerada, então F_X^* pertence a uma das seguintes famílias:*

$$F_X^*(x) = \exp \left\{ \exp \left[- \left(\frac{x - \mu}{\sigma} \right) \right] \right\}, I_{[-\infty, \infty]}(x) \quad (2-4)$$

$$F_X^*(x) = \begin{cases} 0 & , \text{ se } x \leq 0 \\ \exp \left\{ - \left(\frac{x - \mu}{\sigma} \right) - \xi \right\} & , \text{ se } x > 0 \end{cases} \quad (2-5)$$

$$F_X^*(x) = \begin{cases} \exp \left\{ - \exp \left[- \left(\frac{x - \mu}{\sigma} \right) \xi \right] \right\} & , \text{ se } x \leq 0 \\ 1 & , \text{ se } x > 0 \end{cases} \quad (2-6)$$

Assim, por meio do Teorema 1 a distribuição de $\frac{M_n - \mu_n}{\sigma_n}$ converge para uma das três famílias apresentadas nas Equações 2-4, 2-5 e 2-6 denominadas de distribuições de valores extremos. Sendo estas conhecidas como Gumbel, Fréchet e Weibull. Cada uma apresenta em comum um parâmetro de posição e de escala μ e σ , respectivamente. As famílias de Fréchet e Weibull possuem um parâmetro de forma ξ .

Os três tipos de famílias de distribuições no Teorema 1 podem ser unificados em uma distribuição generalizada de valores extremos ao combinar as três famílias em uma forma generalizada. A função de distribuição acumulada de probabilidade pode ser expressa de acordo com a Equação (2-7) apresentada.

$$F_X^*(x) = \exp \left\{ - \left[1 + \xi - \left(\frac{x - \mu}{\sigma} \right) \right]^{-1/\xi} \right\} \quad (2-7)$$

sendo a Equação (2-7) definida em $\{x : 1 + \xi \left(\frac{x - \mu}{\sigma} \right) > 0\}$, em que, os

parâmetros satisfazem $-\infty \leq \mu \leq \infty$, $\sigma > 0$ e $-\infty \leq \xi \leq \infty$. Esta é a família de distribuições de valores extremos generalizada GEV que possui três parâmetros: um parâmetro de posição, μ ; um de forma ξ , e um de escala σ . Assim, se configura em um modelo tri-paramétrico, em que o parâmetro ξ determina a forma da distribuição, sendo que:

- $\xi > 0$ tem-se a distribuição Fréchet,
- $\xi < 0$ obtém-se a distribuição de Weibull,
- $\xi \rightarrow 0$ tem-se a distribuição Gumbel.

Metodologia

Neste capítulo, descrevem-se os métodos utilizados para atingir o objetivo final deste estudo. São apresentados os procedimentos adotados para classificar os locais de risco, precificar um seguro climático e interpolar os resultados para os demais municípios. Esta seção está dividida nos seguintes subtópicos: Dados e tratamentos, Estrutura geral da Metodologia, Análises descritivas, Distribuição Generalizada de Valores Extremos (GEV), Precificação de seguro climático e Interpolação espacial.

3.1

Dados e Fontes

Os dados usados por esta dissertação é configurado em seis conjuntos sendo:

- **Dados provenientes das estações meteorológicas do Sul do Brasil:** obtidas por meio do Instituto Brasileiro de Meteorologia - INMET, de 42 estações meteorológicas automáticas de coleta de dados. Em cada estação foram retiradas 95.688 (correspondendo a uma série horária de 10 anos anteriores a data 2020-11-30 23:00) observações salvo uma que apresentou 69.840 observações (correspondendo a uma série horária de 8 anos) e todas apresentaram 17 variáveis. Dentre as variáveis disponíveis, neste estudo foram utilizadas apenas duas sendo: DIREÇÃO HORÁRIA DO VENTO(°(gr)) e RAJADA MÁXIMA HORÁRIA DO VENTO (m/s).(INMET, 2023)
- **Dados do Sistema Integrado de Informações sobre Desastres (S2iD):** Dados de danos provocados por Tempestade Local/Convectiva - Vendaval, reportados pelos municípios no período de 2013 a 2019 para os estados de Santa Catarina, Paraná, Rio Grande do Sul e São Paulo, somando 4946 observações no intervalo.(S2ID, 2023)
- **Dados do mercado segurador de prêmios e sinistros SUSEP:** Dados reportados por todas as seguradoras em todos os ramos no período de 2008 a 2023, considerando 164 seguradoras. Os dados foram agrupados por todas as linhas de seguro e corrigidos pela inflação por estado. Vale ressaltar que esses dados foram utilizados apenas para compreensão geral do mercado segurador atuante nos estados, mas não trazem informações

acerca das localidades a nível de município, sendo estes restritos a cada seguradora.(SUSEP, 2023)

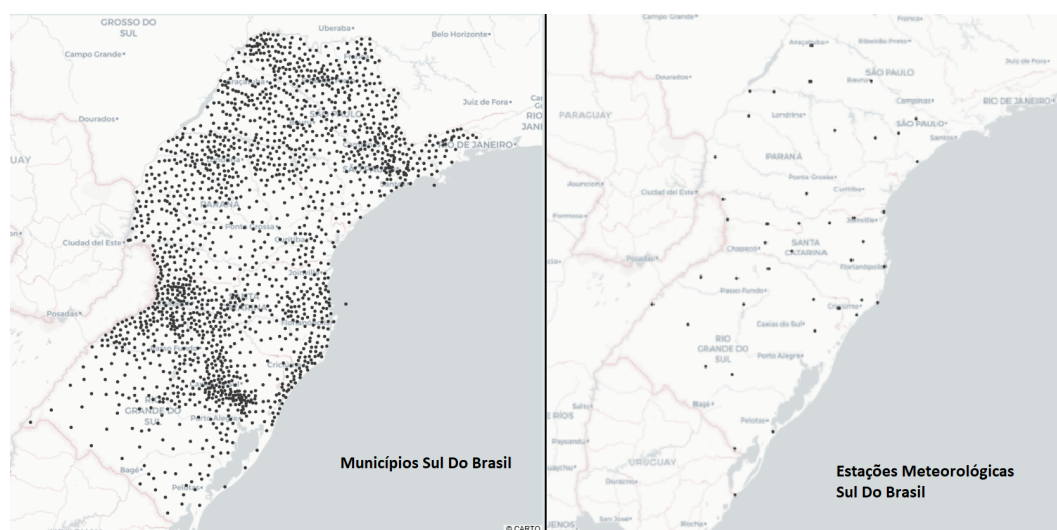
- **Dados de Informações sobre os municípios IBGE:** Dados sobre a latitude e longitude por município, área estimada, população 2019 ,nome, PIB 2020 e 2019 .Foram ao todo 1836 municípios, sendo Santa Catarina: 295 , Paraná:399 , Rio Grande do Sul:497 e São Paulo:645. (IBGE, 2023)
- **Inflação IPCA -IBGE:** Série histórica mensal de inflação para correção dos valores no tempo de danos.(BC, 2023)
- **Meta de inflação Banco central:** Inflação para correção dos valores no tempo simulados 2023:3,25%.(BC, 2023)

3.2

Tratamento dos Dados

Quanto ao tratamento dos dados, foi realizado o tratamento de dados faltantes dos Dados provenientes das estações meteorológicas do Sul do Brasil tal tratamento se deu pelo cálculo da média do valor entre os dados da mesma hora, dia e mês de todos os anos, a fim de substituir os dados faltantes. Para visualização da quantidade de dados faltantes em cada estação meteorológica é apresentado por meio do Anexo 1. já em relação a escolha das estações meteorológicas foi levado em conta as estações que apresentaram dados de no mínimo 10 anos e a distribuição de forma mais distribuída sobre o sul do Brasil conforme pode ser visto por meio da Figura 3.1.

Figura 3.1: Posicionamento de todos municípios no mapa a esquerda e a direita o mapa com o posicionamento das estações meteorológicas.



Fonte: Elaboração Própria com base nos dados do Instituto Brasileiro de Meteorologia - INMET.

Observa-se na Figura 3.1 que as estações estão distribuídas de forma bem equilibrada no Sul do Brasil. Essa preocupação foi motivada pelo objetivo de realizar a interpolação dos dados de probabilidade de ventos extremos para os demais municípios da região, a fim de auxiliar na caracterização de áreas de risco. As informações de localização e nome de cada estação, bem como a codificação usada, podem ser consultadas por meio dos Anexos 1.

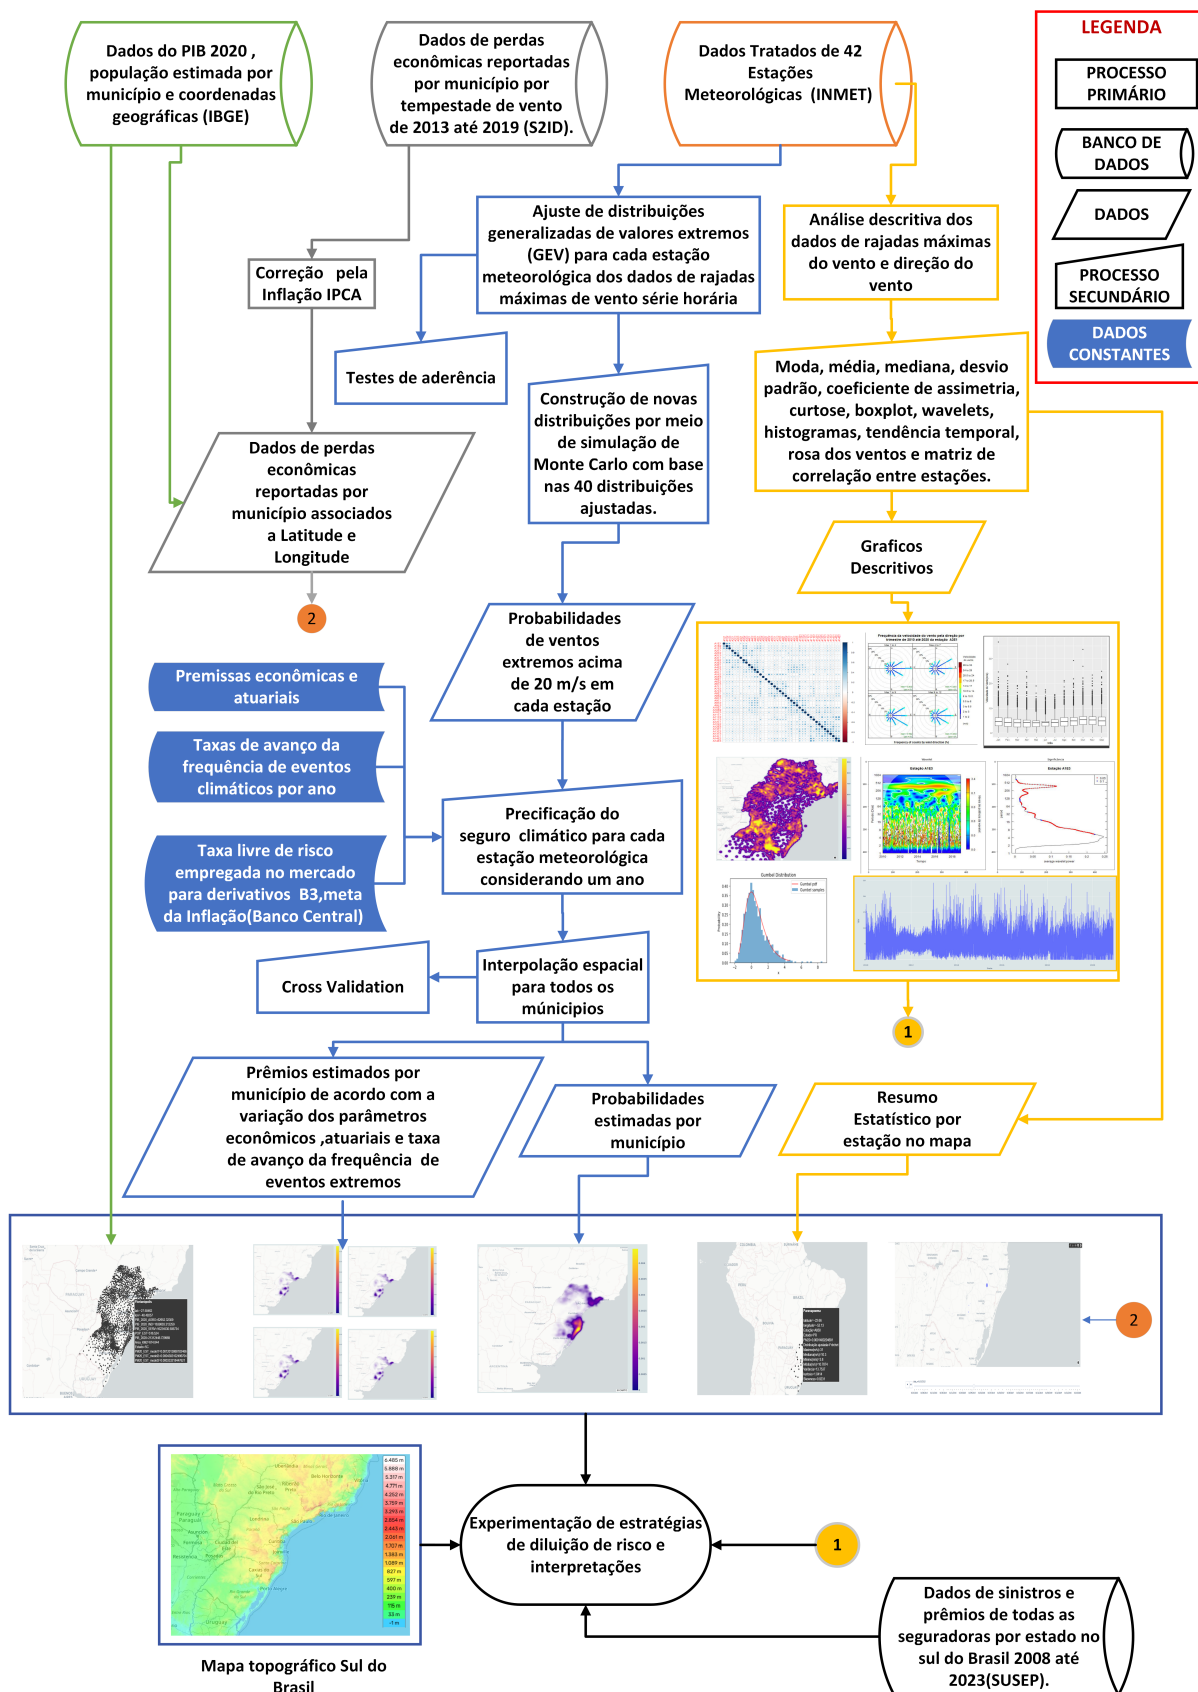
Já o mapa contendo a posição de todos os municípios, como apresentado na Figura 3.1, foi utilizado como ponto de referência tanto para interpolação como para demais análises descritivas, como população estimada, PIB e perdas econômicas reportadas por município. Para acesso a todos os dados trabalhados nesta dissertação, consultar em (DADOS, 2023). No que tange aos outros dados trabalhados, foram aplicadas apenas correções pela inflação (IPCA) se tratando de dados econômicos no tempo.

3.3

Estrutura geral da Metodologia

Para ilustrar a interligação dos processos conduzidos na metodologia, desde a utilização dos dados até os resultados finais dos objetivos específicos e gerais, é apresentado por meio da Figura 3.2 um fluxograma organizado em etapas sequenciais e interconectadas. As caixas retangulares representam as ações realizadas e as setas indicam as conexões entre elas. As caixas em formato de losango representam os resultados de cada processo. A legenda que acompanha a figura fornece informações sobre o significado de cada símbolo e sobre o tipo de dados ou resultados produzidos em cada etapa do processo.

Figura 3.2: Estrutura geral da Metodologia



Ao analisar o fluxograma, é possível entender a estruturação e a lógica do processo de forma visual e sintética, facilitando a compreensão das etapas e da relação entre elas. Com base na Figura 3.2, é possível identificar os seguintes objetivos específicos da metodologia:

- Obtenção e tratamento dos dados meteorológicos confiáveis e disponíveis, considerando as informações que descrevessem o fenômeno ventos extremos;
- Aplicação de análises descritivas que trazem uma forma diferente de entender o fenômeno tempestade de ventos, auxiliando assim, na obtenção de novas perspectivas de análises tanto qualitativas como quantitativas;
- Aplicação dos ajustes das distribuições de valores extremos nos dados meteorológicos e aplicação dos testes de aderência.
- Estimação da probabilidade de ventos acima de 20m/s com base nas distribuições ajustadas em cada estação meteorológica .
- Interpolação espacial considerando seis modelos diferentes de interpolação .
- Classificação dos locais e áreas de risco, por meio da probabilidade estimada das distribuições ajustadas em cada estação e interpolação para demais municípios no Sul do Brasil e aplicação de *cross validation* para compreensão dos ajustes dos modelos.
- Precificação de seguro climático resultando no prêmio estimado por cada localidade.
- Tratamento de dados de danos reportados pelos municípios relacionados por setor da economia em cada localidade e correção de valores pela inflação.
- Dados do PIB de 2020 usado para mapeamento por município ,informações estas relevantes para compreender a estrutura de risco em questão como por exemplo se um dado município tem uma produção mais acentuada em comercio ou agricultura que por sua vez pode afetar o seguro e a forma como este vai ser ponderado por localidade.
- Dados do mercado segurador estes dados foram agregados por estado em relação a quantidade de prêmios e sinistros emitidos por todas as seguradoras de todos os ramos atuantes no sul do Brasil. Dados importantes para compreensão do tamanho do mercado em cada uma das localidades a nível de estado.
- Mapa de altimetria Brasileiro, considerando que o relevo tem papel importante nos danos provocados por ventos extremos por meio de

um mapa de altimetria ou relevo Brasileiro é apresentado apenas para auxiliar na compreensão dos locais classificados como de risco e se o relevo proporciona alguma influência nestas áreas em relação as demais.

3.4

Introdução as Análises descritivas usadas

Neste tópico, são discutidos apenas os métodos não triviais usados, como boxplots temporal, Transformada de Wavelets e rosa dos ventos. Esses métodos foram utilizados para realizar interpretações e obter padrões importantes para auxiliar na classificação das localidades quanto aos riscos e suas características. Porém, é importante destacar que os métodos de cálculo, bem como as análises das estatísticas descritivas básicas, como a Matriz de correlação, média, moda, mediana, desvio padrão, coeficientes de assimetria e curtose, também foram realizados e estão apresentados nos Anexos 10 e 11.

3.4.1


Boxplot

O método de *Boxplot* foi empregado neste estudo com o objetivo de entender se os dados apresentam um comportamento próximo nos meses mesmo com o passar dos anos, e caracterizar os meses que apresentam maior chance de ocorrência de ventos catastróficos acima de 20 m/s segundo a escala Beaufort. Para melhor entendimento de como foram feitas as interpretações e retiradas de informações do Boxplot, segue por meio da Figura 3.3 o exemplo da estação A1E3.

A análise da Figura 3.3 indica a presença de um padrão sazonal nos velocidade de rajada máxima horária do vento ao longo dos meses, em que a mediana apresenta valores mais baixos entre maio e junho, e valores mais altos entre setembro e dezembro. Utilizando o Boxplot, é possível obter informações sobre a existência de comportamentos sazonais ao longo dos meses e identificar os períodos mais e menos prováveis de ocorrer velocidades de ventos consideradas destrutivas em uma determinada localidade. Como há um grande número de gráficos, as análises foram resumidas em uma tabela para facilitar o acesso, às informações podem ser conferidas por meio dos Anexos 6, 7, 8 e 9 ³.

³Para acesso aos gráficos de Boxplot de todas as estações acessar o link: <<https://drive.google.com/drive/folders/1S2gUbSpSjNw5P4T-ywssb49cTYJu9U9R?usp=sharing>>

Figura 3.3: Boxplot mensal dos dados de rajada máxima horária do vento(m/s) da estação meteorológica A1E3 no período de 2010 á 2020.



Fonte: Elaboração Própria com base nos dados do Instituto Brasileiro de Meteorologia - INMET.

3.4.2

Transformada de Wavelets

Diante da evidência de um comportamento sazonal nas séries de dados de velocidade de rajada máxima horária do vento, é crucial compreender esses padrões sazonais e se eles estão relacionados à ocorrência ou não de eventos extremos de tempestade de ventos. Entre os métodos de decomposição de sinais de séries temporais, destaca-se a transformada de wavelets, que é uma ferramenta recente no processamento de sinais e tem recebido muita atenção desde seu desenvolvimento teórico em 1984 por Grossman e Morlet.

A transformada de wavelets é apropriada para analisar eventos irregularmente distribuídos e séries temporais com potências não estacionárias em diferentes frequências. Por isso, ela está se tornando uma ferramenta comum para analisar variações locais de potência dentro de uma série temporal (SANTOS; FREIRE; TORRENCE, 2013).

Neste trabalho, o objetivo principal da aplicação da transformada de wavelets é decompor as séries temporais unidimensionais de velocidade máxima do vento em uma imagem bidimensional difusa simultaneamente no domínio tempo-frequência. Por meio dessa imagem bidimensional, é possível obter

informações sobre a amplitude de qualquer sinal periódico dentro da série, como essa amplitude varia com o tempo e a significância global na detecção dos padrões. Para calcular a transformada de wavelets $W_n(s)$, é utilizada a convolução da função wavelets com a série temporal original, conforme mostrado na Equação 3-1 (SANTOS; FREIRE; TORRENCE, 2013).

$$W_n(s) = \sum_{n'=0}^{N-1} x'_n \Psi_n(t) * \left[\frac{(n' - n)\delta t}{s} \right] \quad (3-1)$$

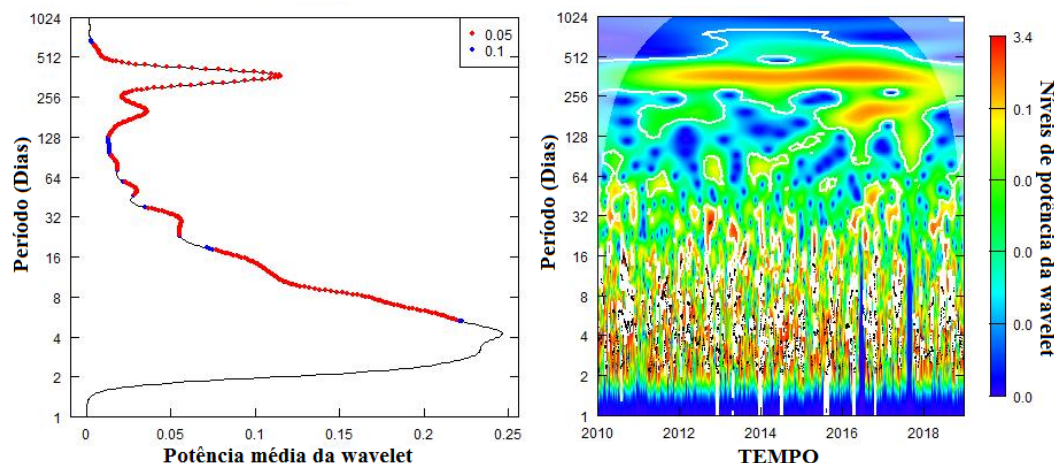
Na equação apresentada, o parâmetro s é utilizado para controlar a dilatação ou compressão da função wavelet no domínio da frequência, enquanto o parâmetro n controla o deslocamento da função wavelet no tempo. O tamanho da série temporal é denotado por N , e os valores da série são representados por x'_n . O intervalo de tempo constante entre cada valor da série é representado por δt e $\Psi_n(t)$ é a função wavelet no tempo.

A notação $W_n(s)$ representa a transformada de wavelets da série temporal x'_n em relação à função wavelet utilizada, com os parâmetros s e n determinando a escala e o tempo. O asterisco (*) denota o conjugado complexo, que é necessário para a realização da transformada de wavelets complexa. Para uma compreensão mais detalhada dos cálculos envolvidos na transformada de wavelets, recomenda-se a leitura dos trabalhos: (SANTOS; FREIRE; TORRENCE, 2013), (DOMINGUES et al., 2016) e (SOARES, 2008).

Os parâmetros utilizados para a análise wavelet neste estudo foram configurados considerando que os dados são distribuídos de forma horária, sendo $\delta t = 1$ hora e $s_0 = 2$ horas, pois $s = 2\delta t$. O cálculo para a geração dos gráficos foi realizado por meio do pacote WaveletComp desenvolvido por (ROESCH; SCHMIDBAUER, 2018).

Os resultados foram obtidos por meio da análise dos gráficos de Espectro de Potência Global (análise da significância da detecção das frequências a nível de 5% e 10%) e Espectro de Potência Wavelet (gráfico bidimensional). Para fins explicativos, a Figura 3.4 apresenta o gráfico do Espectro de Potência Global e o gráfico do Espectro de Potência Wavelet da série de velocidade máxima dos ventos (m/s) da estação A1E3.

Figura 3.4: Gráfico de espectro de potência global a esquerda e o gráfico de espectro de potência wavelet a direita, da série velocidade máxima dos ventos (m/s) da estação A1E3.



Fonte: Elaboração Própria.

Ao observar a Figura 3.4, é possível verificar que o gráfico de Espectro de potência global confirma a presença das frequências anual e semanal na série analisada, apresentando um pico significativo acima do nível de confiança de 95% para essas frequências. Essa confirmação é obtida através da integração da potência sobre o tempo e da média temporal das potências existentes entre o início e fim da série analisada.

Além disso, o espectro de potência global fornece uma estimativa não tendenciosa e consistente do espectro de potência verdadeiro da série temporal, tornando-se um meio simples e robusto para caracterizar a variabilidade das séries. Já a interpretação da potência média da wavelets, quando alta, indica horas com ventos extremos, enquanto valores baixos indicam ventos leves.

O gráfico de espectro de potência wavelets apresenta a potência (valor absoluto ao quadrado) da transformada wavelets para os totais das velocidades máximas de ventos horárias na estação A1E3. Esse gráfico fornece informações sobre a potência relativa em uma certa escala e em um certo tempo, mostrando as oscilações reais das wavelets individuais, ao invés de apenas a sua magnitude. Na imagem do espectro de potência wavelets, é possível observar que essa série temporal apresenta um sinal anual forte ao analisar o período entre 256 dias e 512 dias.

Devido ao número elevado de gráficos, as análises foram resumidas em uma tabela para apresentação dos resultados. A tabela pode ser conferida por meio dos Anexos 6,7,8 e 9. A informação relevante retirada está na variabilidade da

série e nos períodos que apresentaram alta potência média da wavelet.⁴

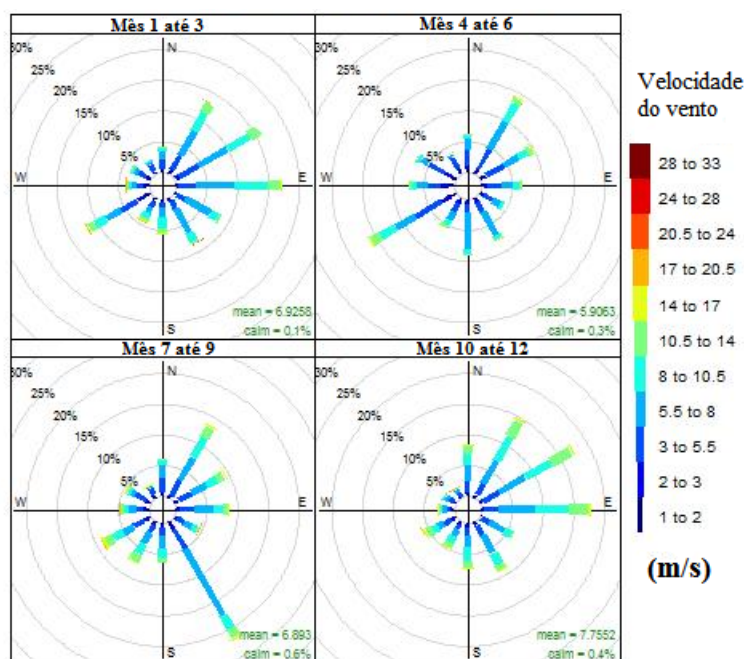
3.4.3

Rosa dos ventos

Neste trabalho, o gráfico da rosa dos ventos é utilizado para três propósitos descritivos. O primeiro é classificar a direção predominante do vento, juntamente com sua intensidade, de acordo com a escala de Beaufort. O segundo é detectar se há mudanças significativas no comportamento do vento com a mudança trimestral, simulando as estações do ano. E o terceiro é determinar se é possível caracterizar a época e direção do vento que causou ventos catastróficos.

Para explicar como foram realizadas as análises e como foram retiradas as principais informações da rosa dos ventos, apresentamos o gráfico de rosa dos ventos trimestral da estação A1E3 na Figura 3.5.

Figura 3.5: Rosas dos ventos trimestrais no período de 2010 até 2020 da velocidade máxima do vento na estação A1E3, com intensidade de danos classificadas segundo a escala de Beaufort.



Fonte: Elaboração Própria com base nos dados do Instituto Brasileiro de Meteorologia - INMET.

Na Figura 3.5, observa-se uma mudança significativa no comportamento da direção e intensidade dos ventos do segundo para o quarto trimestres, com

⁴Para acesso aos gráficos de espectro de potência global e espectro de potência wavelet acessar o link:<https://drive.google.com/drive/folders/1uCAg6bQARyiVGHIEDp_Qp_M8iyzw1Et1?usp=sharing>

um aumento significativo de ventos superiores a 8 m/s. O primeiro trimestre apresentou um cenário próximo ao quarto trimestre. Quanto à caracterização das épocas em que ocorreram mais ventos extremos, elas estão relacionadas ao primeiro e terceiro trimestres, com maior concentração no terceiro quadrante.

Os quadrantes são definidos como a divisão da circunferência em 4 partes de 90°. O primeiro quadrante varia de leste para sul, o segundo varia de norte para oeste, o terceiro varia de oeste para sul e o quarto quadrante varia de sul para leste. Devido ao grande número de gráficos, as análises foram resumidas em uma tabela para apresentação dos resultados.

Entre as informações relevantes extraídas, estão as épocas e quadrantes com maior concentração de ventos extremos e o quadrante com maior concentração de dados de direção dos ventos. o resumo das análises para cada estação podem ser conferidas por meio por meio dos Anexos 6, 7, 8 e 9 ⁵.

3.4.4

Mapa de Densidade , Gráfico de Pontos em 3D e mapa altimétrico com gradiente de cor

O Mapa de Densidade e o Gráfico de Pontos em 3D são técnicas de visualização de dados que permitem explorar a distribuição espacial de dados em três dimensões. O Mapa de Densidade mostra a densidade de pontos em uma superfície, com a variação de cores correspondendo aos valores assumidos pela variável de estudo em relação aos valores mínimos e máximos.

O Gráfico de Pontos em 3D representa os pontos como objetos tridimensionais, permitindo a visualização da posição de cada ponto no espaço. As coordenadas X e Y correspondem aos valores de latitude e longitude, enquanto a coordenada Z representa a variável de estudo. Ambas as técnicas são úteis para identificar padrões e clusters em conjuntos de dados tridimensionais e têm aplicações em diversas áreas, como geologia, biologia, engenharia e finanças.

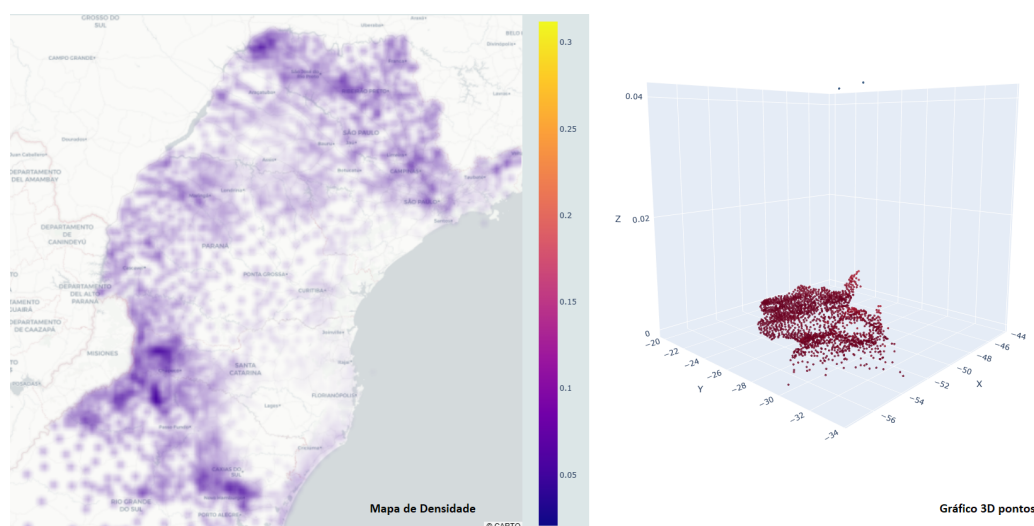
Um exemplo de aplicação do Mapa de Densidade é a análise de dados de ocorrência de terremotos em uma determinada região geográfica. Ao plotar os epicentros dos terremotos como pontos em um mapa e aplicar uma escala de cores para representar a densidade de ocorrências em diferentes áreas, é possível identificar regiões com maior concentração de terremotos e visualizar padrões espaciais na distribuição dos eventos.

⁵Para acesso aos gráficos rosa dos ventos link: <<https://drive.google.com/drive/folders/156kIb6vUIAlSy2vkDLsSXIM5P3dQZDOv?usp=sharing>>

Já o Gráfico de Pontos em 3D pode ser aplicado ao estudo da qualidade do ar em uma cidade, levando em consideração a latitude, a longitude e a concentração de poluentes em diferentes pontos. Ao representar cada ponto como um objeto tridimensional, onde as coordenadas X e Y representam a localização geográfica e a coordenada Z representa a concentração de poluentes, é possível identificar áreas com alta concentração de poluentes e visualizar como essa distribuição varia no espaço.

Esses exemplos ilustram como o Mapa de Densidade e o Gráfico de Pontos em 3D podem ser utilizados como ferramentas eficazes na análise e visualização de dados tridimensionais. Ambos gráficos podem ser visualizados por meio da Figura 3.6.

Figura 3.6: A esquerda Mapa de Densidade de probabilidade de ventos extremos por localidade e a direita Gráfico de Pontos em 3D de probabilidades de ventos extremos por localidade.



Fonte: Elaboração Própria

Tanto o mapa de densidade quanto o gráfico em 3D foram utilizados para facilitar a análise das interpolações e avaliação das áreas de risco, assim como para a visualização dos prêmios do seguro climático por localidade. Outra variável importante a ser levada em conta é o relevo, pois este auxilia na compreensão dos efeitos do comportamento de ventos extremos na superfície terrestre. Assim para auxiliar nas análises foi utilizado um mapa altimétrico com gradiente de cor.

Um mapa altimétrico é uma representação gráfica da superfície terrestre que mostra as variações de altitude do terreno. Para indicar essas variações, o mapa altimétrico utiliza linhas de contorno, que conectam pontos de mesma altitude. As áreas mais elevadas são representadas por linhas de contorno mais próximas

umas das outras, enquanto as áreas mais planas são representadas por linhas mais espaçadas.

Para indicar ainda mais claramente as variações de altitude, é comum utilizar gradiente de cor em um mapa altimétrico com gradiente de cor. O gradiente de cor é uma variação gradual de cor que é usada para indicar diferentes altitudes no mapa. Por exemplo, áreas mais baixas podem ser representadas por tons de azul ou verde, enquanto áreas mais elevadas podem ser representadas por tons de amarelo ou vermelho. Um exemplo de mapa altimétrico com gradiente de cor usado pode ser visto na Figura 3.7.

Figura 3.7: Mapa altimétrico com gradiente de cor do Sul do Brasil



Fonte: Acessar <<https://pt-br.topographic-map.com/map-g825k/Brasil/?center=-25.87899%2C-60.64453&zoom=5>>

3.5

Distribuição Generalizada de Valores Extremos (GEV)

Já em relação a função densidade de probabilidade da Distribuição GEV é expressa pela Equação 8.

$$f_X^*(x) = \frac{1}{\sigma} \left\{ \left[1 + \xi - \left(\frac{x - \mu}{\sigma} \right) \right]^{-\left(\frac{1+\xi}{\xi} \right)} \right\} \exp \left\{ - \left[1 + \xi - \left(\frac{x - \mu}{\sigma} \right) \right]^{-1/\xi} \right\} \quad (3-2)$$

sendo definida em $-\infty \leq \mu \leq \infty$, $\sigma > 0$ e $-\infty \leq \xi \leq \infty$.

Os parâmetros μ , σ e ξ apresentados na Equação 8 são desconhecidos. No entanto, neste trabalho a estimação destes parâmetros partiu dos dados de velocidade máxima do vento em cada estação meteorológica do Sul do Brasil. Já para obtenção destes parâmetros foi usada a biblioteca (STEPHENSON, 2002), em que, por meio desta foi aplicado o método de máxima verossimilhança para obter as estimativas dos parâmetros.

O método da Máxima Verossimilhança consiste de uma metodologia desenvolvida por Fisher em 1922, no qual se busca a maximização da probabilidade de um parâmetro representar uma população, maximizando a densidade conjunta dos elementos amostrais. (NAGHETTINI; PINTO, 2007)

Para maior aprofundamento em como é estimado os parâmetros por meio do método da verossimilhança e sugerido a leitura de trabalhos como (BAUTISTA; ZOCCHI; ANGELO C.C.I., 2004) e (SMITH, 1985) que é base da construção da biblioteca "evd".

Após realizado os ajustes das distribuições por meio do método de máxima verossimilhança ⁶, foi aplicado os testes de aderência de Kolmogorov-Smirnov (KS), Filliben (Fi) e de Anderson-Darling (AD) para verificar a aderência de cada distribuição ajustada. O nível de significância utilizado em todos os testes foi de 5% , sendo testada a seguinte hipótese:

$$\begin{aligned} H_0 : F_0(x) &= F_X(x), \forall x \\ H_1 : F_0(x) &\neq F_X(x) \end{aligned}$$

em que $F_0(x)$ representa a função de distribuição acumulada empírica dos dados. e $F_X(x)$ representa a função de distribuição acumulada assumida para os dados. Resultados encontrados de todos os testes aplicados podem ser conferidos por meio dos Anexos 3, 4 e 5 para cada estação meteorológica.

3.5.0.1

Teste de aderência de Kolmogorov-Smirnov (KS)

O teste de Kolmogorov-Smirnov é uma ferramenta estatística criada por Andrei Kolmogorov e Nikolai Smirnov para testar a hipótese de que as frequências observadas podem ser representadas pela distribuição de probabilidade. Para isso, é calculada a estatística do teste, que consiste na diferença máxima entre as funções de probabilidades acumuladas, empírica e teórica.

O valor crítico do teste, representado por $|\Delta F|_{tab}(n, \alpha)$, é obtido levando em conta o nível de significância testado e o tamanho da amostra. Caso o valor da estatística do teste, representado por $|\Delta F|_{max}$, supere o valor do teste crítico, a hipótese nula é rejeitada (NAGHETTINI; PINTO, 2007).

⁶Para acesso aos Gráficos Quantílico, Retorno de nível, probabilidades e gráfico do ajuste da densidade nos dados originais podem ser vistos ao acessar o link: <<https://drive.google.com/drive/folders/1gy1Z4X8AtFVhPTMLLIco85ASGx4vpcxf?usp=sharing>>

$$|\delta F|_{max} \leq |\delta F|_{tab}(n, \alpha) \quad (3-3)$$

O valor adotado de $|\delta F|_{tab}(n, \alpha)$ foi de $|\delta F|_{tab}(10000, 0.05) = 0,0368781$. Como o tamanho da amostra é maior que 50, o valor tabelado foi obtido pela fórmula $|\delta F|_{tab}(n, \alpha = 0.05) = \frac{1.36}{\sqrt{n}}$. O pacote (GROSS; LIGGES, 2015) foi utilizado para realizar o teste.

3.5.0.2

Teste de aderência de Anderson-Darling (AD)

O teste de Anderson-Darling, criado em 1954 por Theodore e Donald, é uma ferramenta estatística que procura ponderar de maneira mais efetiva as caudas das distribuições. Isso ocorre porque observações maiores ou menores da amostra podem alterar a qualidade do ajuste. O teste baseia-se na diferença entre as funções de probabilidades acumuladas empírica e teórica (FRANCO et al., 2014). A estatística de teste Anderson-Darling é dada por meio da Equação 3-4.

$$AD^2 = -N - \frac{1}{n} \sum_{i=1}^n \leq ft(2i - 1).ln[F(X)] + [2(n - i) + 1].ln[1 - F(X)] \quad (3-4)$$

onde AD^2 é a estatística do teste; i é a ordem de cada elemento da série; $F(X)$ é a probabilidade de não excedência calculada pela distribuição de probabilidade com os dados em ordem crescente; $1 - F(X)$ é a probabilidade de excedência calculada pela distribuição de probabilidade com os dados em ordem decrescente; e n é o tamanho da amostra.

Caso o valor calculado da estatística de teste AD^2 seja menor do que o valor tabelado, conclui-se que a distribuição de probabilidades se ajusta ao conjunto de dados observados. Como os valores críticos para a distribuição GEV não estão disponíveis, foram utilizados os valores da distribuição Gumbel para testar a aderência desta distribuição às séries de dados (ABREU et al., 2018).

O valor tabelado para comparação em todos os ajustes foi obtido considerando um tamanho amostral de $n = 10000$ e $AD_{Tabelado} = 0,787$. Para valores elevados de AD^2 , as funções diferem significativamente, e a adequabilidade do modelo é rejeitada. Para valores menores que os tabelados (dependendo da distribuição e do nível de significância), os modelos foram considerados adequados. O pacote utilizado para a realização do teste foi (SAEB, 2018).

3.5.0.3

Teste de aderência de Filliben (Fi)

O teste de Filliben (FILLIBEN, 1975) estima o coeficiente de correlação (r) entre as observações $F_X^{-1}(1 - q_i)$ e q_i , onde q_i representa a probabilidade empírica correspondente à ordem de classificação i . Quando $r_{Fi} > r_{Tab}$, admite-se que a amostra pode ser representada pela respectiva distribuição testada. Os valores críticos do teste de Filliben são específicos para cada distribuição, enquanto a estatística do teste de Filliben é apresentada pela Equação 3-5.

$$r_{Fi} = Corr(X, M) = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (M_i - \bar{M})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^n (M_i - \bar{M})^2}} \quad (3-5)$$

em que r_{Fi} é a estatística do teste; X_i é o i -ésimo valor observado; \bar{X} é a média dos valores observados; M_i é o i -ésimo valor estimado; \bar{M} é a média dos valores estimados. Quanto ao valor de r_{Tab} segundo a tabela apresentada no trabalho (FILLIBEN, 1975), considerando $n=10000$ e nível de significância 0,05 é $r_{Tab} = 0,525$. Para realização do teste foi usado o pacote (POHLERT, 2020).

3.5.1

Análise de tendência

A análise de tendência neste trabalho tem como foco auxiliar na avaliação do comportamento das séries dos dados de velocidade máxima do vento ao decorrer dos anos. Considerando Y_t^j a série de dados de velocidade máxima dos ventos em uma dada estação meteorológica j e assumindo que está variável é gerada por um processo estocástico simples, como pode ser descrito por meio da Equação 3-6..

$$Y_t^j = TD_t + u_t \quad (3-6)$$

Em que, $TD_t = a + bt$ é chamado usualmente de tendência determinística, sendo a e b constantes reais, t é a variável tempo e u_t é um processo estocástico estacionário com média nula. Desta forma, dado o enfoque apenas na variável tendência da série, a expressão $TD_t = a + bt$ representa uma linha reta que, quando temos $b \neq 0$, possui uma inclinação que pode ser positiva ou negativa. Neste caso, a inclinação indica que uma parte de Y_t^j cresce ou decresce persistentemente no tempo, daí representando uma tendência.

Será uma tendência de crescimento ou positiva se $b > 0$, e de decrescimento negativa se $b < 0$. (MATTOS, 2018)

3.6

Precificação de seguro climático

Os seguros climáticos funcionam de maneira semelhante aos seguros convencionais. O segurado paga um prêmio para uma seguradora em troca da garantia de uma indenização caso ocorra um evento climático adverso, como uma seca, uma enchente ou uma tempestade. O valor do prêmio é calculado com base em uma análise estatística dos históricos de eventos climáticos da região em questão, levando em consideração a probabilidade de ocorrência de um evento e o valor esperado das perdas que poderão ser cobertas pelo seguro.

A precificação de um seguro climático envolve a projeção da probabilidade de ocorrência de eventos climáticos extremos e a definição de um preço justo para o seguro, considerando os riscos envolvidos. Neste contexto, dentre os métodos de precificação discutidos anteriormente na revisão da literatura o presente estudo adotou uma precificação por meio de simulações de Monte Carlo.

Pois dentre os demais métodos este se mostra mais flexível para trabalhar com a inserção de mais variáveis de risco e também parâmetros. Para realização da precificação de um seguro climático foi estabelecido os seguintes passos:

- Definir os parâmetros do modelo, incluindo a duração do contrato (`coverage_period`), o valor segurado (`insured_amount`), o limite de velocidade do vento (`wind_speed_limit`), a taxa de prêmio (`premium_rate`), a taxa de juros livre de risco (`risk_free_rate`), a taxa de inflação (`inflation_rate`) e as taxas de custo de transação (`transaction_cost`).
- Definir a data de cálculo (`calculation_date`) e o calendário (`calendar`) para calcular as datas de vencimento e as curvas de desconto e inflação.
- Simular amostras aleatórias de velocidade do vento a partir de uma distribuição de probabilidade escolhida (Gumbel, Weibull ou Fréchet). Para cada simulação, calcular a probabilidade de ventos acima do limite de velocidade do vento. Armazenar os resultados de probabilidade em um vetor (`prob_vec`) e as amostras aleatórias de velocidade do vento em outro vetor (`wind_samples`).
- Calcular o valor segurado em caso de ocorrência de ventos acima do limite de velocidade do vento. Para isso, multiplicar o valor segurado

pelo vetor de probabilidade (*prob_vec*) e armazenar os resultados em um vetor (*insured_loss*).

- Calcular o prêmio do seguro como o valor segurado multiplicado pela taxa de prêmio e armazenar o resultado em uma variável (*premium*).
- Calcular o fluxo de caixa para cada simulação. Para isso, subtrair o valor segurado em caso de ocorrência de ventos acima do limite de velocidade do vento e o custo de transação do prêmio, ou seja, (*insured_loss* - *transaction_cost*) - (*premium* - *transaction_cost*). Armazenar os resultados em um vetor (*cash_flow*).
- Descontar o fluxo de caixa para o tempo presente usando curvas de desconto e inflação. Para isso, calcular os fatores de desconto e inflação para cada período de cobertura e multiplicá-los pelo fluxo de caixa correspondente. Armazenar os resultados em um vetor (*pv*).
- O resultado final é o valor presente do fluxo de caixa que corresponde ao valor do prêmio do seguro.

1. Definir os parâmetros do modelo:

- Duração do contrato: *coverage_period*
- Valor segurado: *insured_amount*
- Limite de velocidade do vento: *wind_speed_limit*
- Taxa de prêmio: *premium_rate*
- Taxa de juros livre de risco: *risk_free_rate*
- Taxa de inflação: *inflation_rate*
- Taxas de custo de transação: *transaction_cost*
- Data de cálculo: *calculation_date*
- Calendário: *calendar*
- Taxa de avanço de frequência de sinistros(considerando a influência do aquecimento global no aumento da frequência dos sinistros): *Tafs*
- Distribuição de probabilidade: *D*

2. Simular amostras aleatórias de velocidade do vento a partir de uma distribuição de probabilidade acumulada escolhida:

$$P(v_t > 20) = 1 - F_D(20; \mu, \sigma, \xi) \quad (3-7)$$

onde:

- F_D : função de distribuição acumulada da distribuição de probabilidade D ;
- μ : estimativa do parâmetro de localização da distribuição D ;
- σ : estimativa do parâmetro de escala da distribuição D .
- ξ : estimativa do parâmetro de forma da distribuição D .

Assim resultando ao fim um vetor *wind_samples*

$$wind_samples = \{w_1, w_2, \dots, w_n\} \sim P(wind_speed) \quad (3-8)$$

onde n é o número de simulações realizadas e $P(wind_speed)$ é a distribuição de probabilidade escolhida.

3. Calcular a probabilidade de ventos acima do limite de velocidade do vento para cada simulação:

$$prob_vec = \{P(w_1 > wind_speed_limit), \dots, P(w_n > wind_speed_limit)\} \cdot Tafs \quad (3-9)$$

4. Calcular o valor segurado em caso de ocorrência de ventos acima do limite de velocidade do vento:

$$insured_loss = \{insured_amount \cdot prob_vec\} \quad (3-10)$$

5. Calcular o prêmio do seguro:

$$premium = insured_amount \cdot premium_rate \quad (3-11)$$

6. Calcular o fluxo de caixa para cada simulação:

$$cash_flow = \{insured_loss - premium\} - transaction_cost \quad (3-12)$$

7. Descontar o fluxo de caixa para o tempo presente usando curvas de desconto e inflação:

$$pv_t = \frac{cash_flow}{(1 + risk_free_rate)^t} \cdot \frac{1}{(1 + inflation_rate)^t} \quad (3-13)$$

onde t é o número de períodos de cobertura desde a data de cálculo até a data de vencimento correspondente.

8. O resultado final é o valor presente do fluxo de caixa resultando assim no valor do prêmio do seguro:

$$PV = \sum_{t=1}^{coverage_period} pv_t \quad (3-14)$$

3.7

Interpolação espacial

Os modelos de interpolação RBF (Radial Basis Function) são métodos utilizados para interpolação espacial de dados. Eles são baseados em funções de base radial, que são funções cujo valor depende apenas da distância em relação a um ponto central. O entendimento de modelos RBF e suas aplicações se deu por meio dos seguintes trabalhos: (FASSHAUER, 2007b), (BROOMHEAD; LOWE, 1988), (WEN et al., 2018), (WU et al., 2010), (BUHMANN, 2003), (FASSHAUER, 2007a) e (MADYCH; NELSON, 1990). Existem várias funções de base radial que podem ser usadas na construção de um interpolador ou aproximador RBF. Algumas das funções de base radial mais comuns incluem:

- Função multiquádrica: $\phi(r) = \sqrt{(\frac{r}{\epsilon})^2 + 1}$
- Função inverso-quadrática: $\phi(r) = \frac{1}{1+(\frac{r}{\epsilon})^2}$
- Função gaussiana: $\phi(r) = \exp(-(\frac{r}{\epsilon})^2)$
- Função exponencial: $\phi(r) = \exp(-\frac{r}{\epsilon})$

Nesses exemplos, ϵ é um parâmetro que controla a forma da função de base radial. É importante escolher a função de base radial adequada para o problema em questão, pois diferentes funções de base radial têm diferentes propriedades e podem ser mais adequadas para diferentes tipos de dados.

A ideia básica dos modelos RBF é que os valores de um conjunto de dados espaciais podem ser aproximados por uma combinação linear de funções de base radial centradas em pontos específicos. A fórmula geral para um modelo RBF é dada por meio da Equação (3-15).

$$f(x) = \sum_{i=1}^n w_i \phi(||x - x_i||) \quad (3-15)$$

onde $f(x)$ é o valor interpolado em um ponto x , w_i são os pesos associados aos centros x_i , ϕ é a função de base radial e $||x - x_i||$ é a distância entre x e x_i .

Resultados

Este capítulo está dividido em quatro seções, sendo: análises descritivas, ajustes das distribuições generalizadas de valores extremos nos dados de velocidade máxima do vento em cada estação meteorológica, classificação das áreas de risco, precificação do prêmio do seguro por município, avaliação da influência das taxas de aumento da frequência de sinistros em 10%, 20% e 30% e por fim a discussão dos resultados encontrados.

4.1

Análises descritivas

Nesta subseção, são apresentados os resultados das análises descritivas básicas dos dados de velocidade máxima do vento em cada estação meteorológica conforme o Anexo 11. E a matriz de correlação entre as estações por meio do Anexo 10. Quanto às análises descritivas Wavelets, Rosa dos Ventos, Tendência e Boxplot temporal são apresentadas de forma resumida por meio dos Anexos 6, 7, 8 e 9.

Para facilitar a comparação das estações em relação à sua proximidade, foi realizada a codificação das estações, dividindo-as em 14 áreas. Essa divisão foi determinada pelo número total de estações dividido por 3, considerando também uma distância máxima de 450 km entre elas. Essa divisão está descrita no Anexo 11, na coluna "Estações".

Por exemplo, considere a estação "A1E1". Nesse caso, "A1" corresponde à área 1 das 14 áreas estabelecidas, e "E1" representa a primeira estação dentro da área "A1". Esse padrão se repete para as demais áreas.

Ao realizar uma análise das estatísticas descritivas básicas apresentadas no Anexo 11, observa-se que em algum momento, todas as estações tiveram valores máximos de velocidade do vento ultrapassando os 20 m/s. No entanto, é importante ressaltar que a ocorrência dessas velocidades elevadas não garante necessariamente a ocorrência de eventos catastróficos, pois isso depende das características das construções e da rugosidade do terreno.

Em relação à variância, as estações A1E1 e A6E1 apresentaram uma variância maior, o que pode indicar um comportamento de maior risco. Nessa fase inicial

de compreensão dos riscos em cada estação, foi utilizado os histogramas como ferramenta de análise.⁷ Tais análises iniciais serviram apenas de referência para realização dos ajustes e não são apresentadas neste trabalho.

Ao analisar o Anexo 10, é possível observar que todas as estações apresentaram uma correlação positiva, indicando a existência de uma correlação espacial entre os dados de velocidade de rajada máxima do vento. Quanto à intensidade do grau de correlação das estações em relação às demais estações de uma mesma área, verificou-se que as áreas A1, A2, A3, A4, A9, A10, A12, A13 e A14 apresentaram correlação média ou forte positiva, enquanto as estações das áreas A5, A6, A7, A8 e A11 apresentaram correlação baixa. Destaca-se, ainda, as estações A3E1 e A6E1 que apresentaram correlação muito baixa em relação a todas as outras estações, apesar de estarem próximas, o que pode estar atrelado a diferença de relevo entre estas com as demais.

De forma geral, percebe-se uma correlação relativamente forte entre as estações associadas a cada área e também de áreas próximas das outras, o que pode levar a uma compreensão parcial sobre a inviabilidade do uso do teorema central do limite como estratégia a ser empregada nessas regiões. No entanto, é importante destacar que não é possível afirmar isso de forma completa, pois mesmo que duas áreas apresentem forte correlação entre os dados, os efeitos que o vento proporciona podem ser totalmente diferentes.

Para compreender melhor a relação espacial entre as estações e, principalmente, o comportamento da variabilidade dos dados em relação ao tempo, foram aplicados métodos como wavelets, boxplot temporal e rosa dos ventos nos dados de direção do vento e velocidade máxima em cada estação. Os resultados da aplicação dos métodos foram resumidos em uma única tabela com os principais resultados obtidos em cada estação, proporcionando facilidade de realizar uma associação entre as análises qualitativas com a classificação das áreas de risco.

Os resultados obtidos das análises realizadas são apresentados por meio dos Anexos 6 e 7. As siglas utilizadas nessas tabelas são explicadas por meio do Anexo 8. Quanto à forma de classificação do risco de acordo com a probabilidade de ocorrência de ventos acima de 20 m/s, ela é apresentada por meio do Anexo 9.

⁷Para acesso aos Histogramas das estações acessar o link: <<https://drive.google.com/drive/folders/12mWnRuTGq2TZiY6mIV1aW1Yb5f10n25Z?usp=sharing>>

Resultado dos ajustes das GEV

Nesta subseção, são apresentados os resultados dos ajustes das distribuições generalizadas de valores extremos (GEV) por meio do método da máxima verossimilhança, bem como os resultados dos testes de aderência aplicados. Os ajustes dos parâmetros de escala, forma e posição dos dados de velocidade máxima do vento de cada estação meteorológica estão resumidos no Anexo 3, juntamente com os Intervalos de Confiança ao nível de 99,5% dos parâmetros ajustados e a probabilidade de ventos ocorrerem acima dos 20 m/s, apresentados no Anexo 4. O Anexo 5 apresenta os resultados dos testes de aderência realizados.

Ao analisar os ajustes realizados, observou-se que a distribuição Fréchet foi utilizada em trinta e três estações, seguida pela distribuição de Weibull em cinco estações e pela distribuição Gumbel em quatro estações. Quanto aos resultados dos testes de aderência, verificou-se que o teste de Kolmogorov-Smirnov (KS) e Filliben (Fi) foram rigorosos, não ajustando os nenhuma das distribuições aos dados de velocidade de rajada máxima do vento na maioria das estações em relação ao primeiro teste e não ajustando nenhuma das estações pelo segundo teste.

Tal fato de não ajuste, se deve a estes testes de aderência darem maiores pesos à forma da distribuição, em que a forma apresenta distorções de concentração de dois picos ou anormalidades de comportamento da distribuição dos valores reais. Quanto a importância destes testes foi para compreensão de quais limiares de velocidade de ventos extremos é possível levar em consideração para ter um bom ajuste de uma distribuição conhecida sabendo desta limitação da forma dos dados reais.

Em relação ao teste de Anderson-Darling (AD), este mostrou bom ajuste para 40 estações, pois ele dá mais peso ao ajuste da cauda e menos peso em relação à forma da distribuição. Como o objetivo deste trabalho é avaliar apenas valores extremos, o mais importante é o bom ajuste das caudas das distribuições. Portanto, foi considerado o ajuste das distribuições segundo o teste de Anderson-Darling (AD).

Às estações A2E2 e A14E3, que não foram ajustadas por não passarem em nenhum dos testes de aderência, o fato pode estar relacionado com a maneira como os dados estão distribuídos na estação A2E2 e pela quantidade de dados faltantes na estação A14E3. Para estimar uma distribuição para essas duas

estações, foram utilizadas as três distribuições ajustadas mais próximas e avaliada a variância dos dados e o modelo pré-testado para substituir cada uma das distribuições.

4.3

Interpolação espacial das probabilidades de ventos extremos e de prêmios por município com base nos dados das 42 estações meteorológicas

Para identificar a melhor função de base radial, um algoritmo foi utilizado para comparar o erro médio quadrático e o coeficiente de determinação (R^2) obtidos a partir de cinco modelos diferentes: multiquádrico, inverso, gaussiano, linear e cúbico. Foi utilizada a biblioteca Scipy para realizar a interpolação com o modelo escolhido e a biblioteca Scikit-learn para calcular o erro médio quadrático e o coeficiente de determinação. O resultado final é o modelo com o maior R^2 e o melhor valor de epsilon, bem como os parâmetros do modelo e o erro médio quadrático. O modelo ótimo encontrado foi o seguinte:

- Melhor: modelo de interpolação espacial: multiquadric
- Melhor valor de epsilon: 1.58262
- Maior R^2 : 0.99999
- error: 1.9881744411506617e-31

Além do modelo ótimo encontrado, outros cinco modelos foram testados com o objetivo de compreender se eles descrevem de forma coerente a interpolação dos dados ou captam alguma característica que o modelo ótimo não considera. abaixo segue a descrição dos modelos testados.

- **Modelo 1:** RBF com função *kernel* multiquádrica e parâmetro de suavização (*smooth*) = 0,5. Este modelo produz uma interpolação suave entre os pontos de dados de entrada. Exemplos semelhantes incluem o "*thin-plate spline*" e outros modelos RBF com função *kernel* multiquádrica.
- **Modelo 2:** RBF com função *kernel* multiquádrica e parâmetro de largura (*epsilon*) = 2. Este modelo produz uma interpolação mais suave do que um modelo com *epsilon* menor. Exemplos semelhantes incluem outros modelos RBF com função *kernel* multiquádrica e variação de *epsilon*.
- **Modelo 4:** RBF com função *kernel* linear. Este modelo produz uma interpolação linear entre os pontos de dados de entrada. Exemplos semelhantes incluem a interpolação por *spline* linear e outros modelos RBF com função *kernel* linear.

- **Modelo 5:** RBF com função *kernel* gaussiana e parâmetro de suavização (*smooth*) = 0,5. A função *kernel* gaussiana produz uma interpolação suave com maior peso nos pontos de dados próximos. Exemplos semelhantes incluem outros modelos RBF com função *kernel* gaussiana e variação do parâmetro de suavização.
- **Modelo 6:** RBF com função *kernel* inversa multiquádrica e parâmetro de suavização (*smooth*) = 0,5. A função *kernel* inversa multiquádrica produz uma interpolação suave com maior peso nos pontos de dados próximos. Exemplos semelhantes incluem outros modelos RBF com função *kernel* inversa multiquádrica e variação do parâmetro de suavização.

Após a interpolação espacial com os seis modelos ajustados, foi aplicado um método de *Cross validation*, para avaliar os ajustes dos modelos com base nos dados interpolados. A metodologia utilizada consiste em uma função que recebe como entrada três arrays unidimensionais: x , y e $values$, que representam as coordenadas e valores dos pontos de dados. Além disso, a função permite a escolha da função de base radial e dos parâmetros de suavização, forma e número de folds de validação cruzada (cv).

Primeiramente, a função embaralha os índices dos pontos de dados e os divide em cv folds de tamanho igual. Para cada fold, a função cria um interpolador ou aproximante RBF usando os dados de treinamento e os parâmetros especificados. Em seguida, o interpolador ou aproximante é avaliado nos pontos de dados do conjunto de validação e é calculado o coeficiente de correlação entre os valores previstos e os valores verdadeiros nesses pontos.

Esse coeficiente de correlação é armazenado em uma matriz de comprimento cv e, por fim, é retornado a média dos coeficientes de correlação calculados para cada fold de validação cruzada. Isso permite que o usuário selecione a combinação de parâmetros que produz o melhor desempenho na validação cruzada. Segue por meio da Tabela 4.1 os resultados do R-squared de cada modelo ajustado com a aplicação da *Cross validation*

Tabela 4.1: Resultados do R-squared Score para modelos de interpolação RBF

Modelo	Função RBF	R-squared Score
Modelo1	Multiquadric (smooth=0.5)	0.410353
Modelo2	Multiquadric (epsilon=2)	0.414869
Modelo3	Multiquadric (epsilon=1.58)	0.402976
Modelo4	Linear	0.336096
Modelo5	Gaussian (smooth=0.5)	0.193616
Modelo6	Inverse Multiquadric (smooth=0.5)	0.123573

Embora o Modelo 3 tenha sido considerado ótimo, ao aplicar o *cross validation* em todos os dados interpolados e compará-lo com o modelo base, o Modelo 2 apresentou um desempenho melhor em termos de R^2 , como pode ser visto na Tabela 4.1. A queda do R^2 pode ser atribuída ao fato de que os pontos interpolados aumentaram significativamente em número, passando de 42 pontos na amostra de validação inicial para 1863 pontos. Isso pode ter distorcido os resultados. No entanto, o Modelo 3 foi escolhido, dado que partimos da interpolação que está diretamente ligada aos 42 dados originais estimados.

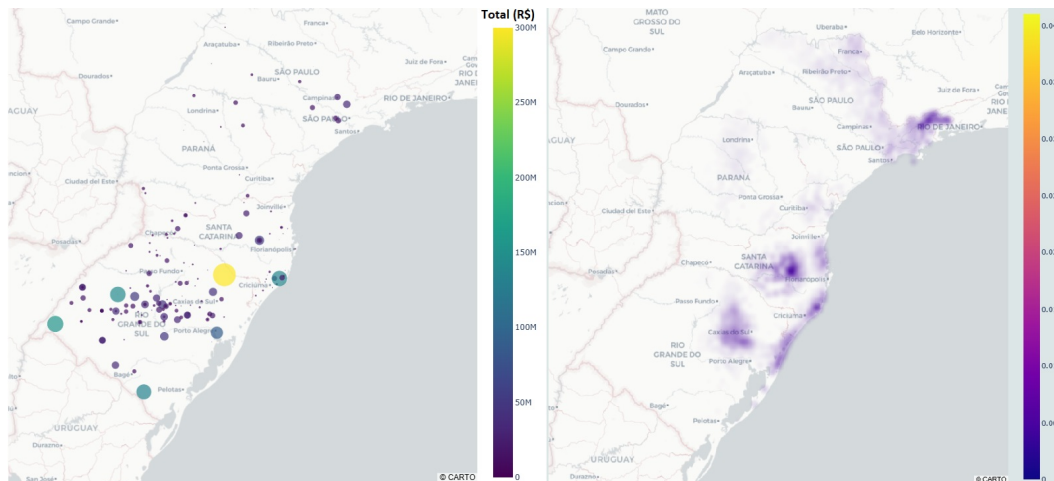
4.4

Classificação de locais de riscos

Nesta seção, é apresentada a classificação de áreas de risco de vendavais extremos no Sul do Brasil e também é feita a comparação desta com o histórico de perdas reportadas pelos municípios, mapa altimétrico com gradiente de cor, PIB de cada município e população em cada município. Conforme discutido na seção anterior sobre "Interpolação Espacial", constatou-se que o modelo 3 se ajustou melhor aos dados.

Tomando-o como referência para classificar as áreas de risco e ao utilizar os dados de perdas econômicas por tempestades de vento reportados pelos municípios no período de 2013 a 2019, foi possível fazer uma comparação entre ambos, como apresentado na Figura 4.1. Essa comparação é relevante para verificar se os locais caracterizados como de risco realmente refletem locais que apresentam perdas econômicas associadas a ventos extremos.

Figura 4.1: A direita temos o gráfico de probabilidades de ventos acima de 20m/s e a esquerda o gráfico de perdas econômicas por vendaval reportadas por todos municípios agrupadas de 2013 até 2019 e corrigidas pela inflação.

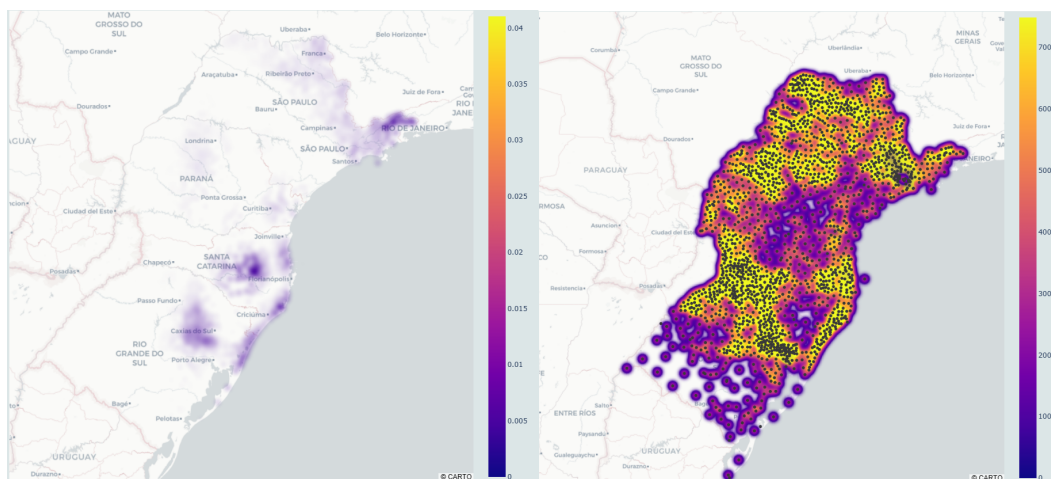


Fonte: Elaboração própria.

Ao analisar a Figura 4.1, sendo a Figura da Direita o Mapa das probabilidades de ventos acima de 20m/s e da esquerda o Mapa de perdas econômicas por vendaval reportadas por todos os municípios agrupados de 2013 até 2019 e corrigidos pela inflação, é possível estabelecer uma relação quase perfeita de caracterização dos mesmos locais com maior intensidade, exceto por alguns municípios no extremo sul do Rio Grande do Sul.

No entanto, essa comparação tem suas ponderações, como o fato de nem todos os municípios terem reportado perdas durante esse período e a intensidade das perdas poder variar para valores maiores, considerando que danos particulares da população não são levados em conta nesse relatório dos municípios. Já a comparação das áreas de risco com a população por município segue por meio da Figura 4.2.

Figura 4.2: A esquerda temos o gráfico de probabilidades de ventos acima de 20m/s e a direita o gráfico de densidade populacional.



Fonte: Elaboração própria.

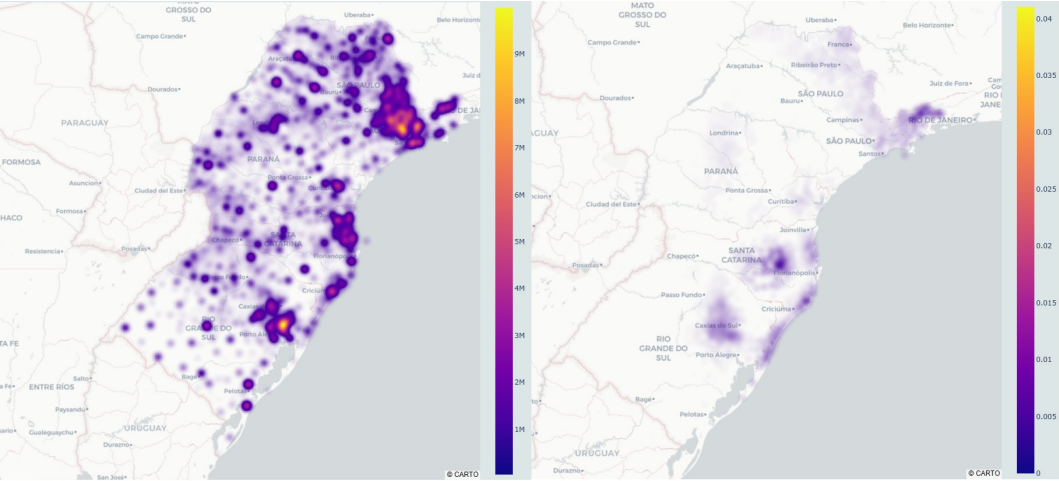
Ao analisar a Figura 4.2, sendo a Figura da esquerda o Gráfico de densidade das probabilidades de ventos acima de 20m/s e a Figura da direita o Gráfico de densidade populacional, é perceptível no gráfico de densidade populacional a existência forte de grupos de municípios. Essa concentração se apresenta próxima das capitais de cada estado.

Ao comparar com as áreas de risco, é visível que essas áreas com concentração maior de municípios estão dentro das áreas apontadas como de risco. Isso é preocupante, dado que o efeito de ventos extremos pode prejudicar um número maior de pessoas nessas localidades e, conseqüentemente, tornar o preço de alguns tipos de seguros mais caros, como os seguros de automóveis, habitação e até mesmo de vida. Já a comparação das áreas de risco com o PIB segue por meio da Figura 4.3.

Ao analisar a Figura 4.3, é possível notar que a figura da esquerda mostra o gráfico de densidade das probabilidades de ventos acima de 20m/s, enquanto a figura da direita apresenta o gráfico de densidade do PIB de 2020. É perceptível uma concentração do PIB nas capitais de cada estado, conforme destacado no gráfico de densidade do PIB. Ao comparar com as áreas de risco, é possível identificar semelhanças com a análise anterior.

Devido à massificação populacional e produtiva, áreas de risco com maior PIB sugerem a possibilidade de estratégias diferentes de diluição do risco. É importante ressaltar que a diversificação inadequada nessas regiões pode levar a uma catástrofe financeira devido ao aumento na intensidade de eventos extremos. Para implementar tais estratégias, é necessário considerar os aspectos constru-

Figura 4.3: A Direita temos o mapas das probabilidades de ventos acima de 20m/s e a esquerda o mapa de densidade do PIB de 2020 considerando apenas municípios com valores menores que R\$ 10.000.000 para melhor visualização

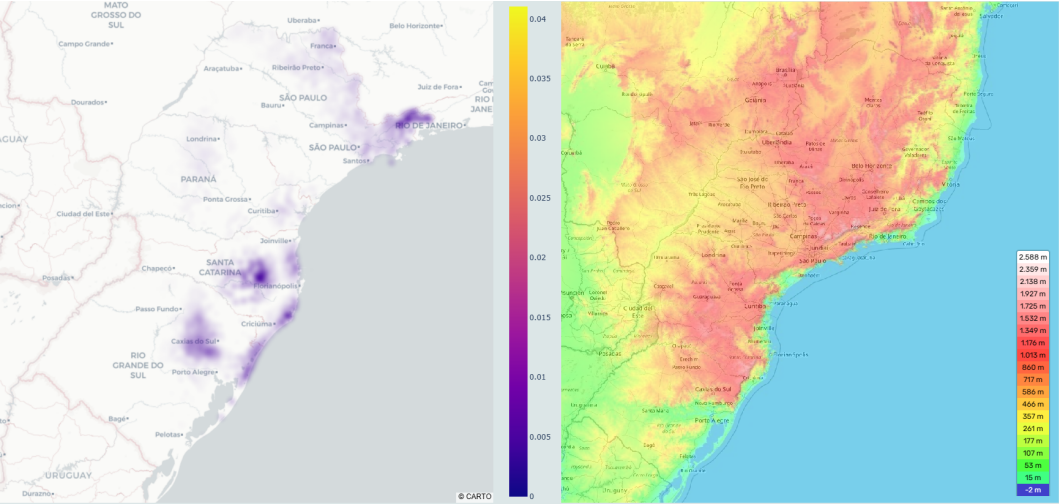


Fonte: Elaboração própria.

tivos de cada localidade, bem como a influência do relevo nessas regiões.

É importante salientar que este trabalho se baseou na escala EBRV ao considerar os danos acima de 20m/s e seus efeitos na terra. Para uma análise mais precisa, é necessário entender os aspectos de cada localidade, o que pode ser considerado pelo agente ao precificar a taxa de prêmio de referência por localidade. Além disso, para uma análise mais completa, é realizada a comparação das áreas de risco com o relevo, que pode ser visualizada na Figura 4.4.

Figura 4.4: A esquerda temos o gráfico de densidade das probabilidades de ventos acima de 20m/s e a direita o mapa altimétrico com gradiente de cor



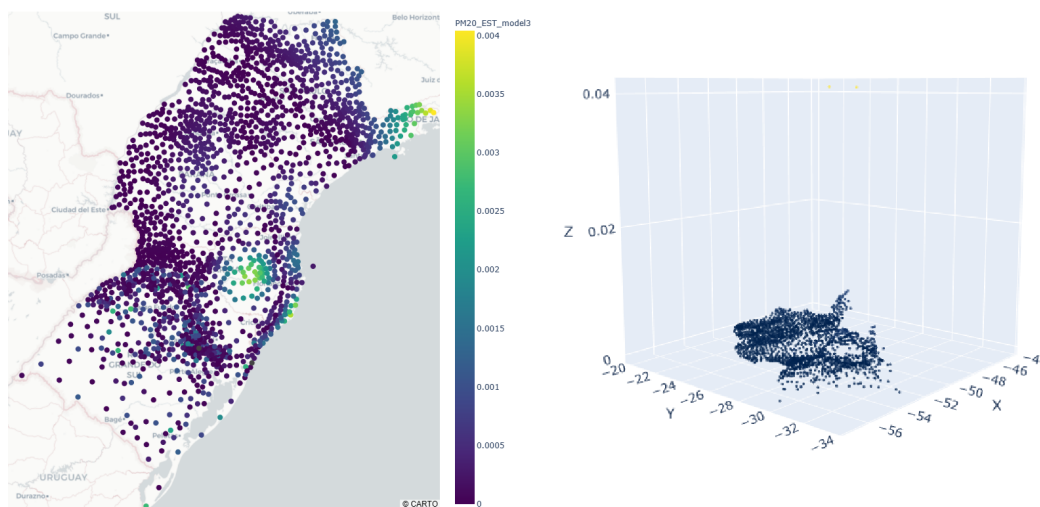
Fonte: Elaboração própria.

Ao analisar a Figura 4.4, composta pelo Gráfico de densidade das probabilidades de ventos acima de 20m/s e o mapa altimétrico com gradiente de cor, é possível observar que existe uma relação entre a altitude e as áreas de risco de ventos extremos. Áreas costeiras e altitudes mais baixas são mais vulneráveis a danos causados por ventos extremos, pois não há barreiras físicas para quebrar esses ventos. O mesmo ocorre em áreas de altas altitudes. No entanto, é importante levar em conta outras análises descritivas, como a época do ano e a direção do vento, ao analisar uma localidade específica.

É interessante notar que as áreas de risco em vales são quase nulas, o que também é uma informação importante a ser considerada. Por conta da altitude relativamente baixa, as regiões do extremo sul e centro do Rio Grande do Sul são mais propensas a sofrer danos causados por ventos extremos.

No entanto, o mapa de densidade não apresenta de forma clara os riscos pontuais, e como os municípios estão afastados, não é possível perceber a distribuição geográfica dos riscos. Para uma melhor compreensão, foi realizada a construção de gráficos 3D a partir dos dados interpolados, como mostrado na Figura 4.5.

Figura 4.5: A esquerda o Mapa de calor por municípios das probabilidades de ventos acima de 20m/s e a direita o gráfico em 3D das probabilidades de ventos acima dos 20m/s interpoladas com base no modelo 3 onde é trazida apenas a vista frontal iniciando no Rio Grande do sul e com o fundo São Paulo



Fonte: Elaboração própria.

Ao analisar a Figura 4.5, composta pelo Mapa de calor de probabilidade de ventos acima de 20m/s à esquerda e o Gráfico em 3D das probabilidades de ventos acima de 20m/s interpoladas com modelo 3D à direita, é possível observar os pontos de probabilidade de forma mais detalhada e individual do

que no mapa de densidade. O mapa em 3D apenas auxilia para a compreensão de como a interpolação está suavizada.

No extremo sul do Rio Grande do Sul e no centro, é possível notar uma variabilidade de locais de alto risco e baixos riscos. Ao comparar com o mapa altimétrico com gradiente de cor apresentado na figura 4.4, é possível constatar que os pontos com baixa probabilidade estão em vales e os de alta probabilidade em altitudes mais elevadas. No entanto, é importante destacar que essa afirmação varia de acordo com a formação do relevo e a direção do vento.

4.5

Precificação de seguros climáticos com base na estrutura de risco

Os parâmetros adotados na precificação bem como as premissas adotadas foram as seguintes:

- Duração do contrato: 1 ano, geralmente período de cobertura utilizado nos contratos de seguro, podendo variar.
- Valor segurado: 1 u.m. (uma unidade monetária), para facilitar a comparação entre as perdas por localidades.
- Limite de velocidade do vento: 20m/s, considerando que acima desta velocidade, segundo as escalas EBRV, ocorrem perdas significativas por ventos mais fortes.
- Taxa de prêmio: 0.20, representando a suposição da preferência do agente pelo preço do prêmio a ser pago. Vale ressaltar que este valor foi escolhido aleatoriamente, já que varia de acordo com a localidade, concorrência e outros fatores inerentes ao seguro.
- Taxa de juros livre de risco: 0.05, podendo ser aproximada pela taxa de juros dos títulos do Tesouro Nacional indexados à inflação, conhecidos como Tesouro IPCA+. Essa taxa varia diariamente.
- Taxa de inflação: Com base no Banco Central, a meta da inflação está em 0.035.
- Taxas de custo de transação: 0.01, considerando as taxas cobradas pela B3 para derivativos.
- Data de cálculo: Ano de 2023.
- Calendário: Considerado o calendário brasileiro.
- Taxa de avanço de frequência de sinistros: Variação sem taxa, 10%, 20% e 30%. Esses valores correspondem à suposição de aumento da frequência

de eventos extremos devido ao aquecimento global. Foram realizados testes variando essas taxas.

- Distribuição de probabilidade: Variando entre as distribuições Gumbel, Weibull ou Fréchet, correspondendo a cada localidade.

Para codificação foram utilizadas duas linguagens de programação: R e *Python*. Para o desenvolvimento em R, foram utilizados o *software "Rstudio"* (R Core Team, 2020), tanto para o tratamento dos dados quanto para as análises descritivas e o ajuste das distribuições generalizadas de valores extremos. Os códigos e os dados trabalhados podem ser acessados por (CODE..., 2023b).

Já para a criação de mapas em 3D, interpolação espacial e precificação de seguro climáticos, foi utilizada a linguagem de programação *Python*, e o ambiente de execução foi o Colab do Google (COLAB, 2023), com as seguintes especificações:

- Unidades de computação: 175.91
- Sistema operacional: *Linux*
- Versão do sistema operacional: 5.10.147+
- Processador: x86_64
- Frequência da CPU: 2199.998 MHz
- Memória RAM total: 26065.04296875 MB
- GPU disponível: *physical_device*:GPU:0
- Versão do *TensorFlow GPU*: 2.12.0

Para acessar os códigos desenvolvidos no Colab, que incluem tratamento de dados, modelagens, ajustes e interpolação espacial, bem como a precificação dos seguro climático, pode-se consultar (CODE..., 2023a).

Ao realizar o cálculo da multiplicação das taxas de 10%, 20% e 30%, sem taxa de aumento da frequência de sinistro, conforme apresentado no Anexo 13, foi evidenciado que os fatores de multiplicação apenas proporcionaram uma mudança no nível de escala no comportamento da precificação, o que já era esperado considerando que temos uma constante multiplicando uma função. Quanto aos resultados relevantes da precificação, é possível afirmar o seguinte:

- Pontos que apresentaram probabilidades altas, mas que não eram visíveis no gráfico de densidade de probabilidades ajustado pelo modelo 3, foram evidenciados no cálculo dos prêmios.
- Foi observado um número significativo de áreas com valores de prêmios próximos a zero, o que pode ser interpretado como áreas de risco quase

nulo. É necessário um aprofundamento maior nas estatísticas descritivas por localidade para validar essa afirmação para cada local, utilizando para isso todas as análises descritivas aqui apresentadas.

- Toda a costa Sul do Brasil, incluindo São Paulo, foi demonstrada como áreas de alto risco e com valores de prêmios altos.
- O mapa de densidade por si só não é suficiente para realizar análises mais precisas. Ao analisar o gráfico em 3D dos pontos, foi possível suprir essa limitação.
- Os valores dos prêmios são sensíveis às preferências do agente e às variáveis de mercado e econômicas, o que é um bom sinal.
- A inserção de novas variáveis é bem flexível na metodologia adotada de precificação, e a análise de seus resultados é relativamente simples de realizar quando associados com todas as análises descritivas e de modelagens dos dados aqui apresentados.

4.6

Discussão dos resultados

As áreas classificadas como de alto risco estão concentradas próximas à costa, o que era esperado devido à existência de poucas barreiras físicas. Já as localidades com baixo risco estão mais afastadas da costa e em vales as quais apresentam proteção do relevo, no entanto podem ser áreas de risco quando avaliado a direção do vento por épocas do ano ao analisar as localidades com os dados apresentados por meio das análises realizadas por meio das rosas do vento no Anexo 6 e 7 rosas do vento.

Em relação à análise da tendência, foram constatadas variações não muito significativas em relação aos coeficientes, com a maioria apresentando valores próximos de zero. No entanto, em algumas estações, sinais negativos foram evidenciados, o que é interessante, pois sugere que os efeitos dos ventos em determinados locais são inversos à influência das mudanças climáticas esperadas. Ressalta-se porém a necessidade de análises mais profundas para compreensão por localidade.

Os resultados dos boxplots temporais em cada estação meteorológica mostram a concentração da ocorrência de ventos fortes nos meses de agosto a dezembro em grande parte das estações. Isso pode ajudar a entender a correlação espacial entre as localidades, mas com certas limitações em relação à variabilidade dos dados.

Os resultados das rosas dos ventos evidenciaram a direção dos ventos e as épocas do ano em que estão mais concentrados. Essas informações, juntamente ao mapa altimétrico com gradiente de cor , podem ajudar a entender a correlação espacial entre as estações meteorológicas próximas, o que corrobora com os apontamentos de outros estudos sobre a existência de forte correlação entre as áreas próximas relacionadas aos efeitos de ventos extremos .

Na análise de *wavelets* é perceptível o predomínio da variabilidade do período anual, o que confirma que o vento segue um padrão sazonal anual. No entanto, em determinados locais, concentrou-se um período de 2 anos, considerando o período de alta potência média de *wavelets*. Essa variabilidade de 2 anos foi percebida em grande parte das estações e está relacionada com o fenômeno El Niño, um fenômeno atmosférico oceânico caracterizado por um aquecimento anormal das águas superficiais no Oceano Pacífico Tropical, que altera o clima regional e global, mudando os padrões de vento a nível mundial.

Após o entendimento dos principais resultados, é possível levantar uma série de informações e premissas encontradas que podem ser avaliadas para busca de novas estratégias de diluição do risco das perdas econômicas provocadas por tempestades do vento no Sul do Brasil como:

- Cada estação meteorológica ou localidade é suscetível a um risco de ocorrência de ventos extremos diferente, mesmo apresentando proximidade geográfica;
- Deve ser levado em consideração que as perdas são dinâmicas e de diferentes intensidades de danos por localidade. Um exemplo para facilitar o entendimento é que se considerarmos um vento de mesma velocidade, ao ser aplicado em lugares com características construtivas e rugosidade de terrenos diferentes acaba proporcionando perdas econômicas totalmente diferentes;
- A análise do vento e seus efeitos não deve ser realizada pautada em apenas um modelo, método ou dado, mas sim usando diversas fontes de dados, como foi visto neste estudo ao apresentar os distintos métodos aplicados e o uso de diferentes bases nos dados como histórico de perdas reportados por localidades, PIB, população , distribuição dos municípios, relevo e dentre outras informações que quando analisadas em conjunto estabelecem uma forte base para compreensão da estrutura de riscos de ventos estaremos por localidade ;
- O método de precificação adotado se apresentou bem flexível para inserção de variáveis externas o que é bom , para atribuir outras premissas

- como impostos e variação de outras variáveis;
- Quanto a sensibilidade do método de precificação, este se mostrou adequado às preferências do agente e ao modelos de interpolação espacial ajustados, como ficou evidenciado no Anexo 12. Além disso, verifica-se no método uma sensibilidade por tipo de distribuição de probabilidade, ajustada por localidade;
 - Ao comparar as perdas reais e as previstas pelo modelo desenvolvido, este se mostrou bem assertivo ao indicar maiores probabilidades de risco em localidades próximas àquelas evidenciadas com uma maior concentração de sinistro;
 - Foi evidenciado que devido a existência de uma correlação relativamente forte, entre as estações próximas e a conformidade em relação a variabilidade dos dados, a precificação com base no teorema central do limite torna-se inviável. Ademais, com o avanço das taxas de frequência de 10%, 20% e 30%, o preço do prêmio cresce de forma escalar, sem assumir a correlação entre os danos - o que poderia tornar esse crescimento exponencial;
 - Os modelos de simulação climática são ferramentas importantes para a análise de risco, mas também apresentam limitações e incertezas que precisam ser levadas em consideração;
 - A adaptação às mudanças climáticas é uma necessidade urgente para minimizar os riscos e prevenir danos irreparáveis ao meio ambiente e às comunidades humanas;
 - O uso de dados de estações meteorológicas se demonstraram relativamente precisas para classificação de locais de risco.

Já em relação às principais limitações deste estudo, temos:

- Os prêmios aqui precificados não devem ser replicados para a precificação real de seguros, uma vez que é necessário avaliar, por localidade, a preferência dos agentes envolvidos, a influência da concorrência, a experiência da seguradora, fatores construtivos de cada localidade, o tipo de seguro e outros fatores regulamentários.
- Neste estudo apenas uma das várias metodologias de precificação de seguros climáticos foi utilizada. Além disso, destaca-se que não foram consideradas outras relações entre as localidades analisadas, a menos do método de interpolação espacial e da correlação entre as estações meteorológicas.

- Considerando a quantidade de informações trabalhadas, as análises acabam se tornando complexas, o que pode levar à tomada de decisões erradas se cada detalhe dos métodos aplicados não for considerado.

Considerações finais

Considerando as principais informações e premissas retiradas das análises realizadas, foi constatada a importância do uso de diferentes técnicas descritivas nos dados e a multidisciplinaridade na facilitação da compreensão dos métodos e modelos empregados neste trabalho. Também foi possível identificar a consistência dos métodos e modelos utilizados para buscar informações relevantes sobre o fenômeno de tempestades de ventos no Sul do Brasil.

Uma das principais constatações é que as tempestades de ventos representam um risco significativo para a região, com diferentes intensidades de danos em localidades específicas, e as mudanças climáticas podem ter efeitos imprevisíveis sobre o vento, tornando necessário o aprofundamento em futuros trabalhos para avaliar o comportamento do fenômeno.

A análise do risco de tempestades de ventos deve levar em consideração os diferentes riscos individuais em cada localidade, possibilitando a adoção de estratégias de diluição de risco. Também foi identificado que a precificação com base no teorema central do limite é inviável devido à correlação relativamente forte entre estações próximas e à conformidade em relação à variabilidade dos dados. A utilização da teoria de valores extremos, em específico as distribuições generalizadas de valores extremos-GEV, permitiu tanto a caracterização do risco individual de cada localidade quanto a precificação do seguro climático para ventos extremos em cada município.

No entanto, é importante levar em consideração alguns pontos que não foram abordados neste trabalho, como a rugosidade de cada terreno, a análise conjunta dos dados meteorológicos das estações automáticas com as imagens de satélite, a busca pelo aprofundamento em bases mais antigas como os dados provenientes de estações meteorológicas manuais e o uso de outras técnicas para análise de dependência espacial entre estações próximas.

Quanto às perspectivas de futuros trabalhos, é possível simular diferentes modificações nos parâmetros na precificação do seguro climático, simular outras estratégias como derivativos climáticos, trazer outras análises de outras variáveis meteorológicas como temperatura, precipitação e dentre outras variáveis climáticas, aplicar outras abordagens envolvendo modelos climáticos mais robustos de previsão.

Por fim, este trabalho contribuiu para a compreensão dos padrões do fenômeno de tempestades de ventos na região Sul do Brasil, o que é fundamental para a adoção de medidas preventivas e mitigadoras, bem como para o desenvolvimento de estratégias de adaptação às mudanças climáticas em curso.

Referências bibliográficas

ABDAL, H.; ABDELBAKY, M.; FAKHR, M. Three-dimensional visualization of climate data using virtual reality techniques. **Journal of Applied Remote Sensing**, v. 10, n. 4, p. 046009, 2016.

ABREU, M. C. et al. Critérios para escolha de distribuições de probabilidades em estudos de eventos extremos de precipitação. **Revista Brasileira de Meteorologia**, Scielo Brasil, v. 33, n. 4, p. 601–613, 2018.

ACKERMAN, F.; STANTON, E. A.; BUENO, R. Climate risks and carbon prices: Revising the social cost of carbon. **Economics: The Open-Access, Open-Assessment E-Journal**, v. 3, n. 2009-36, 2009.

ANANIAS, D. R. S.; LISKA, G. R. Aplicação da teoria de valores extremos aos dados de velocidade de vento, em uruguaiana-rs. **Anais do Salão Internacional de Ensino, Pesquisa e Extensão**, v. 9, n. 3, 2018.

ANNAERT, J.; OSSELAER, S. V.; VERSTRAETE, B. Performance evaluation of portfolio insurance strategies using stochastic dominance criteria. **Journal of Banking & Finance**, Elsevier, v. 33, n. 2, p. 272–280, 2009.

BAUTISTA, E. A. L.; ZOCCHI, S. S.; ANGELO C.C.I., L. R. A distribuição generalizada de valores extremos aplicada ao ajuste dos dados de velocidade máxima do vento em piracicaba, são paulo, brasil. **Revista de Matemática e Estatística**, v. 22, n. 1, p. 95–111, 2004.

BC. 2023. <<https://www.bcb.gov.br/controleinflacao/historicometas>>. Central Bank of Brazil - Historical Targets.

BLACK, F.; SCHOLES, M. The pricing of options and corporate liabilities. **Journal of Political Economy**, University of Chicago Press, v. 81, n. 3, p. 637–654, 1973.

BONFILIO, R.; WALTER, B.; ANDRADE, M. Interpolation methods evaluation for spatial variability of physical attributes in a rhodic eutrudox. **Revista Brasileira de Ciência do Solo**, v. 40, p. e0160162, 2016.

BRAND, S. I. Caracterização da direção e velocidade dos ventos em santa rosa-rs. Universidade Federal da Fronteira Sul, 2014.

BRODIN, E.; ROOTZÉN, H. Univariate and bivariate gpd methods for predicting extreme wind storm losses. **Insurance: Mathematics and Economics**, v. 44, p. 345–356, 06 2009.

BRÖNNIMANN, S. et al. Historical weather data for climate risk assessment. **Annals of the New York Academy of Sciences**, Wiley-Blackwell, v. 1436, n. 1, p. 121–137, 2019.

BROOMHEAD, D. S.; LOWE, D. Radial basis function networks 1: Recent developments in theory and applications. **Research report**, University of Manchester, v. 43, n. 1, p. 1–8, 1988.

BUHMANN, M. D. Radial basis functions: theory and implementations. **Cambridge University Press**, 2003.

BØLVIKEN, E.; GUILLEN, M. Risk aggregation in solvency ii through recursive log-normals. **Insurance: Mathematics and Economics**, v. 73, p. 20 – 26, 2017. ISSN 0167-6687. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167668716302785>>.

CANDIDO, D. H. et al. Tornados e trombas-d'água no brasil: modelo de risco e proposta de escala de avaliação de danos. [sn], 2012.

CARRERA, J.; LOPEZ-CARRASCO, C.; EGOZCUE, J. J. Spatial interpolation of precipitation in mountainous regions: A case study in the andes of ecuador. **Atmosphere**, Multidisciplinary Digital Publishing Institute, v. 11, n. 12, p. 1282, 2020.

CASTELHANO, F. J.; ROSEGHINI, W. F. F. Caracterização da dinâmica dos ventos em curitiba-pr. **Geousp Espaço e Tempo (Online)**, v. 22, n. 1, p. 227–240, 2018.

CHARPENTIER, A. Insuring risks when pure premium is infinite? **Bulletin français d'actuariat**, v. 7, n. 13, p. 67–82, 2007.

CHARPENTIER, A. Insurability of climate risks. **The Geneva Papers on Risk and Insurance-Issues and Practice**, Springer, v. 33, n. 1, p. 91–109, 2008.

CHEN, X. et al. Modeling weather derivatives prices with spatial interpolation: A comparative study. **Journal of Risk and Financial Management**, v. 13, p. 66, 2020.

CODE in Python. 2023. <https://colab.research.google.com/drive/1JGV65grAoyUcmAAYY1P_DKq4l-RsPdx4?usp=sharing>. Code for Monte Carlo simulation in Python.

CODE in R. 2023. <https://drive.google.com/drive/folders/1O69ogH30AOF_cTUM8LrB3gYzN08C7kQq?usp=sharing>. Code for GEV fitting and data treatment in R.

COLAB. 2023. <<https://colab.research.google.com/>>. Google Colaboratory.

CORRAR, L. J. O modelo econômico da empresa em condições de incerteza aplicação do método de simulação de monte carlo. **Caderno de Estudos**, SciELO Brasil, 1993.

CORRÊA, C. S.; QUEIROZ, B. L.; RIBEIRO, A. J. F. Tamanho populacional e custeio previdenciário: como variações aleatórias afetam o risco de solvência de rpps municipais. **Revista Eletrônica do Departamento de Ciências Contábeis & Departamento de Atuária e Métodos Quantitativos (REDECA)**, v. 1, n. 1, p. 128–149, 2014.

CORREIA, A. F. B. Os ventos velozes em análise: Causas, danos e perdas-casos de estudo em Portugal (porto, odemira e Évora). 2016.

COSSETTE, H.; DUCHESNE, T.; MARCEAU, É. Modeling catastrophes and their impact on insurance portfolios. **North American Actuarial Journal**, Taylor & Francis, v. 7, n. 4, p. 1–22, 2003.

DADOS. 2023. <https://drive.google.com/drive/folders/1xGyUOORs_TLgv-RfQlqE_aDsLTOk138E?usp=sharing>. Access to data worked on by this dissertation.

D'AMICO, G.; PERSIO, L. D. Weather derivatives pricing: A queueing theory approach. **International Journal of Stochastic Analysis**, Hindawi, v. 2011, p. 1–16, 2011.

DOMINGUES, M. et al. Explorando a transformada wavelet contínua. **Revista Brasileira de Ensino de Física**, Scielo Brasil, v. 38, n. 3, 2016.

FASSHAUER, G. E. Meshfree approximation methods with matlab. **World Scientific**, 2007.

FASSHAUER, G. E. A practical guide to radial basis functions. **SIAM**, SIAM, v. 10, n. 4, p. 44–54, 2007.

FIDELIS, T. O. Tempestade de vento no sul do Brasil: uma abordagem atuarial. 2020. Disponível em: <https://scholar.google.pt/scholar?hl=pt-BR&as_sdt=0,5&q=taylor+oliveira+fidelis>.

FILHO, A. A. D. A simulação de variáveis aleatórias e os métodos monte carlo e quase-monte carlo na quadratura multidimensional. 2000.

FILLIBEN, J. J. The probability plot correlation coefficient test for normality. **Technometrics**, Taylor & Francis Group, v. 17, n. 1, p. 111–117, 1975.

FISHER, R. A.; TIPPETT, L. H. C. Limiting forms of the frequency distribution of the largest or smallest member of a sample. In: CAMBRIDGE UNIVERSITY PRESS. **Mathematical proceedings of the Cambridge philosophical society**. [S.l.], 1928. v. 24, n. 2, p. 180–190.

FORUM, W. E. The global risks report 2021. 2021. Disponível em: <<https://www.weforum.org/reports/the-global-risks-report-2021>>.

FRANCO, C. S. et al. Distribuição de probabilidades para precipitação máxima diária na bacia hidrográfica do rio verde, Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 18, n. 7, p. 735–741, 2014.

FUJITA, T. T. Proposed characterization of tornadoes and hurricanes by area and intensity. 1971.

FUTUROS, B. de Mercadorias e. Índice de preços climáticos. Bolsa de Mercadorias e Futuros, 2020.

GHOSH, K.; CHATTERJEE, S.; MITRA, A. Three-dimensional visualization of temperature and precipitation data using r. **Journal of Spatial Information Science**, v. 19, p. 39–56, 2019.

GLASSERMAN, P. **Monte Carlo methods in financial engineering**. [S.l.]: Springer Science Business Media, 2003.

GOMES, A. C. C.; JÚNIOR, A. H. M. da S.; AGUIRRE, M. A. C. Previsão de reservas para seguradoras do mercado brasileiro. **Revista Evidenciação Contábil & Finanças**, v. 4, n. 2, p. 19–39, 2016.

GOUVEIA, H. T. V. **Previsão de ventos e geração eólica do sistema NE: analisando diversos sítios e buscando a melhor modelagem através da inteligência artificial**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2011.

GROSS, J.; LIGGES, U. **nortest: Tests for Normality**. [S.l.], 2015. R package version 1.0-4. Disponível em: <<https://CRAN.R-project.org/package=nortest>>.

HANNA, E.; FETTWEIS, X.; HALL, R. J. Brief communication: Recent changes in summer greenland blocking captured by none of the cmip5 models. **The Cryosphere**, Copernicus GmbH, v. 14, n. 11, p. 3795–3800, 2020.

HE, S. et al. A review of spatial interpolation methods for environmental scientists. **Sustainability**, Multidisciplinary Digital Publishing Institute, v. 11, n. 16, p. 4331, 2019.

HENGL, T. et al. Soilgrids250m: global gridded soil information based on machine learning. **PloS one**, Public Library of Science, v. 12, n. 2, p. e0169748, 2017.

HIRSHLEIFER, D.; SHUMWAY, T. Good day sunshine: Stock returns and the weather. **The Journal of Finance**, Wiley Online Library, v. 58, n. 3, p. 1009–1032, 2003.

HORNES, K. L.; BALICKI, M. Caracterização do tornado ocorrido em marechal cândido rondon e quatro pontes em novembro de 2015. **Raega-O Espaço Geográfico em Análise**, v. 44, p. 36–54, 2018.

HU, F.; XIE, D.; ZHANG, H. A review of weather derivatives: from pricing to hedging. **Quantitative Finance**, Taylor & Francis, v. 21, n. 1, p. 1–20, 2021.

IBGE. 2023. <<https://www.ibge.gov.br/>>. Brazilian Institute of Geography and Statistics.

INITIATIVE, U. E. P. F. The impact of climate change on the insurance industry. 2019. Disponível em: <<https://www.unepfi.org/publications/the-impact-of-climate-change-on-the-insurance-industry/>>.

INMET. 2023. <<https://portal.inmet.gov.br/>>. National Institute of Meteorology (INMET).

INSTITUTE, S. R. Global insured losses from catastrophes reach us\$ 105bn in 2021. 2021.

INTELLIGENCE, A. M. Derivatives in climate risk management. Acuiti Management Intelligence, 2021.

JAMES, G. et al. **An introduction to statistical learning**. [S.l.]: Springer, 2013. v. 112.

JENKINSON, A. F. The frequency distribution of the annual maximum (or minimum) values of meteorological elements. **Quarterly Journal of the Royal Meteorological Society**, Wiley Online Library, v. 81, n. 348, p. 158–171, 1955.

KACZMARSKA, J.; JEWSON, S.; BELLONE, E. Quantifying the sources of simulation uncertainty in natural catastrophe models. **Stochastic environmental research and risk assessment**, Springer, v. 32, n. 3, p. 591–605, 2018.

KUHN, M. Building predictive models in r using the caret package. **Journal of statistical software**, Foundation for Open Access Statistic, v. 28, n. 5, p. 1–26, 2008.

LEITE, M. L.; FILHO, J. S. das V. Avaliação da velocidade média e direção predominante do vento em ponta grossa pr. **Rev. Bras. Agrometeorologia**, v. 14, n. 2, p. 157–167, 2006.

LI, J. et al. Spatial interpolation methods comparison for climate variables: Temperature and precipitation in china. **International Journal of Climatology**, Wiley Online Library, v. 38, n. 2, p. 722–737, 2018.

LI, M.; HAN, X.; SUN, B. The effectiveness of weather derivatives as a hedge against the risks of renewable energy projects: Evidence from china. **Energy Policy**, Elsevier, v. 149, 2021.

LIGUORI, G. et al. Oceanic control of the sea surface winds over the tropical atlantic. **Nature Climate Change**, Nature Publishing Group, v. 8, n. 9, p. 707–712, 2018.

LIMA, F.; SANTOS, T. Impacto do aquecimento global na velocidade do vento em são paulo. **Boletim da Sociedade Brasileira de Meteorologia**, v. 44, n. 3, p. 321–328, 2019.

LIU, Y.; WANG, Q.; HE, Z. Regional extreme wind analysis using the generalized extreme value distribution. **Journal of Wind Engineering and Industrial Aerodynamics**, Elsevier, v. 192, p. 129–137, 2019.

LIU, Y.; WANG, Q.; HE, Z. Estimation of extreme wind events in offshore wind farms using the generalized extreme value distribution. **Renewable Energy**, Elsevier, v. 145, p. 520–530, 2020.

LIU, Y.; ZHANG, X. A comprehensive study on cross-validation for time-series prediction. **IEEE Access**, IEEE, v. 7, p. 113740–113749, 2019.

MA, L. et al. A comparison of spatial interpolation methods for hourly solar radiation. **Energy Reports**, Elsevier, v. 7, p. 834–841, 2021.

MACEDO, L. P. D. d. S. et al. **Justo valor, previsões, requisitos de capital e solvência II: aplicação a uma companhia de seguros do ramo não-vida**. Tese (Doutorado), 2015.

MADYCH, W. R.; NELSON, S. A. Multiquadrics—a scattered data approximation scheme with applications to computational fluid-dynamics—ii solutions to parabolic, hyperbolic and elliptic partial differential equations. **Computers & mathematics with applications**, Elsevier, v. 19, n. 8-9, p. 147–161, 1990.

MAPBOX. 2023. <<https://www.mapbox.com/>>. Software de mapeamento.

MARSHALL, J.; THOMPSON, D. W.; WAUGH, D. W. Stronger southern hemisphere winds due to global warming. **Nature Climate Change**, Nature Publishing Group, v. 9, n. 9, p. 697–703, 2019.

MATHERON, G. The intrinsic random functions and their applications. **Advances in Applied Probability**, v. 5, p. 439–468, 1973.

MATTOS, R. S. **Tendências e Raízes Unitárias**. Tese (Doutorado) — Universidade Federal de Juiz de Fora Departamento de Economia, 2018.

MILLARD, S. P. Spatial cross-validation for the assessment of predictive models in environmental epidemiology. **Geospatial health**, PAGEPress Publications, v. 7, n. 2, p. 399–403, 2013.

MOREIRA, G. L.; SILVEIRA, V. C. da. Estudo de caso de um possível evento de tornado em santa barbara do sul-rs. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto**, 2013.

NAGHETTINI, M.; PINTO, E. Hidrologia estatística, 484 pp. **Belo Horizonte, CPRM-Serviço Geológico do Brasil, Brasil**, 2007.

NASCIMENTO, E. S. M. L. et al. A micrometeorological analysis of the vento norte phenomenon in southern brazil. **Boundary-Layer Meteorology**, Springer, v. 176, n. 3, p. 415–439, 2020.

OLIVEIRA, L. M. de et al. Avaliação do comportamento hidrológico de uma microbacia através de dados de estações meteorológicas automáticas. **Revista Brasileira de Recursos Hídricos**, 2019.

PERRUCI, V. P. **Análise da complementariedade entre diferentes técnicas estatísticas para aumento na resolução espacial do comportamento do vento local**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2018.

POHLERT, T. **ppcc: Probability Plot Correlation Coefficient Test**. [S.l.], 2020. R package version 1.2. Disponível em: <<https://CRAN.R-project.org/package=ppcc>>.

POULSON, M.; EPPLER, J. Spatial validation for predictive modelling. **Journal of Spatial Information Science**, v. 16, p. 1–28, 2018.

R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2020. Disponível em: <<https://www.R-project.org/>>.

RAIS, S.; LIM, J.-S.; YIM, A. Pricing rainfall futures using the hidden markov model. **Journal of Climate**, American Meteorological Society, v. 35, n. 5, p. 1847–1863, 2022.

RAMOS, F. G.; SEIDLER, N. Estudo da energia eólica para aproveitamento em pequenos empreendimentos. **Revista Vivências**, v. 7, n. 13, p. 108–127, 2011.

REIS, L. M. et al. Mudanças de regime no processo de geração de ventos no brasil. Universidade Federal do Rio de Janeiro, 2011.

REUTERS. London metal exchange launches futures contracts based on european average temperature. Reuters, 2021.

ROESCH, A.; SCHMIDBAUER, H. **WaveletComp: Computational Wavelet Analysis**. [S.l.], 2018. R package version 1.1. Disponível em: <<https://CRAN.R-project.org/package=WaveletComp>>.

ROOTZÉN, H.; TAJVIDI, N. Extreme value statistics and wind storm losses: a case study. **Scandinavian Actuarial Journal**, Taylor & Francis, v. 1997, n. 1, p. 70–94, 1997.

S2ID. 2023. <<https://s2id.mi.gov.br/>>. Integrated Disaster Information System (S2iD).

SAEB, A. **gnFit: Goodness of Fit Test for Continuous Distribution Functions**. [S.l.], 2018. R package version 0.2.0. Disponível em: <<https://CRAN.R-project.org/package=gnFit>>.

SANDSTRÖM, A., 2011. Handbook of Solvency for Actuaries and Risk Managers. [S.l.]: chapman& Hall, 2011. 985–20 p.

SANTOS, C. A. G.; FREIRE, P.; TORRENCE, C. A transformada wavelet e sua aplicação na análise de séries hidrológicas. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 271–280, 2013.

SARHADI, A.; SAJJADI, S. M.; AHMADI, G. Assessment of extreme wind speeds using generalized extreme value distribution: A case study. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 74, p. 647–653, 2017.

SASTRY, N.; SHAIKH, A. Analyzing spatial patterns of urban sprawl using density maps: A case study of ahmedabad, india. **Landscape and Urban Planning**, Elsevier, v. 183, p. 1–13, 2019.

SHRESTHA, P.; KAUR, S.; IMRAN, M. Weather derivatives: A literature review on climate derivatives and climate insurance. **Sustainability**, Multidisciplinary Digital Publishing Institute, v. 13, n. 2, 2021.

SILVA, A. B. da et al. Análise da distribuição espacial e temporal da precipitação em bacias hidrográficas do semiárido brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2017.

SILVA, R. G. da; SOUZA, F. R. de; MACHADO, R. S. Análise da variabilidade climática em santa catarina utilizando dados de estações meteorológicas automáticas. **Revista Brasileira de Climatologia**, 2018.

SMITH, R. L. Maximum likelihood estimation in a class of nonregular cases. **Biometrika**, Oxford University Press, v. 72, n. 1, p. 67–90, 1985.

SOARES, A. d. S. **Predição de séries temporais econômicas por meio de redes neurais artificiais e transformada Wavelet: combinando modelo técnico e fundamentalista**. Tese (Doutorado), 2008.

SOUSA, A. d. B. Mecanismos financeiros para a redução de risco associado ao clima: contrato de opções, seguro baseado em índice e fundo financeiro. 2014.

STAUT, F. O processo de implantação de parques eólicos no nordeste brasileiro. Universidade Federal da Bahia. Escola Politécnica, 2011.

STEPHENSON, A. G. evd: Extreme value distributions. **R News**, v. 2, n. 2, June 2002. Disponível em: <<https://CRAN.R-project.org/doc/Rnews/>>.

SUPERVISORS, I. A. of I. Issues paper on climate change risks to the insurance sector. 2019. Disponível em: <<https://www.iaisweb.org/page/supervisory-material/insurance-core-principles-and-guidance-notes/iais-issues-paper-on-climate-change-risks-to-the-insurance-sector>>.

SUSEP. 2023. <<http://www.susep.gov.br/>>. Superintendence of Private Insurance (SUSEP).

TAKIGUCHI, A. T. Aplicação da teoria dos valores extremos no cálculo do risco atuarial para o mercado de seguros de automóveis no Brasil. Universidade Federal de São Paulo, 2019.

TOMASINI, J. **Padrão de variabilidade do vento à superfície, em Lajeado, Rio Grande do Sul, Brasil: implicações ambientais**. Dissertação (B.S. thesis), 2012.

TSE, Y.; CHAN, W.; WONG, W. Pricing and hedging rainfall index derivatives in Australia. **Journal of Futures Markets**, Wiley Online Library, v. 40, n. 1, p. 45–66, 2020.

VENTURA, E. Pricing weather derivatives by marginal value. **Energy Risk**, Inclusive Financial Publishing, v. 10, n. 4, p. 67–71, 1997.

VILLALOBOS, J. C.; MARTINEZ, J. A.; SANZ, J. A. Machine learning for weather derivatives pricing: A systematic review. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 11, n. 22, p. 10685, 2021.

WEN, X. et al. Radial basis function methods for interpolation of spatial data: A review. **International Journal of Geographical Information Science**, Taylor Francis, v. 32, n. 4, p. 607–628, 2018.

WINDY. 2023. <<https://www.windy.com/>>. Plataforma de visualização de dados meteorológicos.

WREGE, M. S. et al. **Atlas climático da região sul do Brasil: estados do Paraná, Santa Catarina e Rio Grande do Sul**. [S.l.]: Pelotas: Embrapa Clima Temperado; Colombo: Embrapa Florestas, 2012., 2012.

WU, X. et al. Radial basis function networks for classification of medical images: a review. **Medical image analysis**, Elsevier, v. 14, n. 5, p. 643–663, 2010.

YIN, J. et al. Comparative analysis of interpolation methods for gridded precipitation data in china. **International Journal of Climatology**, Wiley Online Library, v. 40, n. 6, p. 3267–3281, 2020.

ZHANG, J.; LI, J. Weather derivatives pricing via principal component analysis and monte carlo simulation. **Applied Mathematical Modelling**, Elsevier, v. 87, p. 409–422, 2021.

ZHOU, C.; HUANG, B.; LI, Y. Comparison of cross-validation strategies for model evaluation of soil organic carbon. **Scientific Reports**, v. 7, p. 12467, 2017.

ZHU, S.; FUKUSHIMA, M. Pricing weather derivatives under the cox-ingersoll-ross model. **Journal of Risk Finance**, Emerald Group Publishing Limited, v. 6, n. 4, p. 339–352, 2005.

6.1

Anexos

Tabela 6.1: Anexo 1 - Informações das estações Meteorológicas e Análises descritivas básicas da variável rajada máxima horária de vento (m/s)

Código	latitude	longitude	Ano de fundação	Estado	Maximo (m/s)	Mínimo (m/s)	Média (m/s)	Variância	kurtosis	Skewness	Dados faltantes
A1E1	-33.74	-53.37	2008	RS	34,2	0	11,2453	25,8684	0,8337	-0,1701	5610
A1E2	-32.53	-53.38	2007	RS	32	3,3	10,219	12,3446	2,6593	1,1474	4478
A1E3	-32.08	-52.17	2001	RS	30,6	3,5	10,6359	11,0358	1,6931	0,9389	4388
A2E1	-27.89	-54.48	2006	RS	36,6	0	8,4253	10,9996	5,3627	1,5928	10772
A2E2	-28.65	-56.02	2007	RS	32	0	9,0112	13,1951	3,0027	0,8586	9521
A2E3	-29.19	-54.89	2009	RS	42,6	3,6	9,4273	10,5731	6,9631	1,6552	10172
A3E1	-28.65	-53.11	2012	RS	24,7	3,5	9,0964	8,2926	1,7806	1,0942	2784
A3E2	-30.34	-54.31	2007	RS	30,5	0	9,3037	10,6384	2,7698	1,0691	3283
A3E3	-30.55	-53.47	2006	RS	34,8	3,8	10,9741	11,7446	3,9789	1,4502	6071
A4E1	-27.66	-52.31	2006	RS	26,1	0	8,1124	12,2762	1,4666	-0,1632	3733
A4E2	-27.92	-53.32	2008	RS	28,7	2,1	9,7834	10,0449	2,2901	1,1813	4651
A4E3	-28.51	-50.88	2008	RS	44,8	4,1	10,623	17,986	19,6414	3,3973	4487
A5E1	-29.37	-50.83	2008	RS	39,8	3,5	10,0497	9,8228	6,2589	1,5222	2866
A5E2	-28.93	-49.5	2008	SC	29,5	2,1	8,8239	11,772	1,6765	0,9588	8960
A5E3	-28.75	-50.06	2006	RS	44,4	4	12,2248	13,0732	3,9595	1,5948	33987
A6E1	-28.6	-48.81	2008	SC	36,7	0	12,9518	34,6073	-0,0053	0,2729	18142
A6E2	-28.53	-49.32	2008	SC	33,1	0	6,8097	8,059	4,9761	1,177	11513
A6E3	-26.91	-49.27	2006	SC	35,1	0	6,9843	11,5353	4,9511	1,5126	5147
A7E1	-26.25	-49.58	2008	SC	27	0	8,0024	10,1943	2,383	0,7591	5262
A7E2	-26.08	-48.64	2007	SC	22,5	0	6,8239	6,6879	1,6982	0,6788	9980
A7E3	-27.6	-48.62	2003	SC	28,2	0	9,5156	6,8107	1,9393	0,5068	496
A8E1	-27.42	-49.65	2008	SC	31,1	0	7,0912	11,092	3,4848	1,1533	2120
A8E2	-26.39	-50.36	2009	SC	30,9	0	9,1348	12,1005	2,89	1,3267	1995
A8E3	-27.17	-51.56	2007	SC	28,2	0	10,018	14,3158	1,7197	0,9797	4010
A9E1	-26.42	-52.35	2008	PR	25,9	4,1	9,9223	11,0164	0,9662	1,0327	25012
A9E2	-26.94	-52.4	2008	SC	32,8	0	10,4914	14,1553	0,6433	0,7927	4965
A9E3	-26.29	-53.63	2008	SC	32	0	10,4532	12,5003	1,6431	0,6108	11165
A10E1	-26.4	-51.35	2008	PR	23,7	1,8	7,9622	7,6433	1,9532	1,0218	6859
A10E2	-25.72	-53.75	2007	PR	35,2	0,5	9,6582	12,105	4,0078	1,4406	6497
A10E3	-24.53	-54.02	2006	PR	34,6	0	10,634	12,6148	3,7755	1,2771	5654
A11E1	-25.57	-51.08	2006	PR	34,2	0	7,0043	11,5646	3,6488	1,0271	15867
A11E2	-23.98	-48.89	2006	SP	24,7	0	9,4445	9,937	1,3939	0,6665	5898
A11E3	-24.67	-47.55	2006	SP	24,7	0,2	7,9277	8,0376	1,8309	0,8266	7343
A12E1	-22.64	-52.89	2008	PR	33,4	0	9,3679	11,1945	2,638	1,0397	12603
A12E2	-23.36	-52.93	2008	PR	27,8	0	8,621	10,7104	1,865	0,9334	12400
A12E3	-23.77	-50.18	2008	PR	32,2	0	9,1284	8,4759	3,2671	1,0526	2704
A13E1	-22.66	-52.13	2008	PR	31	3,8	10,7874	13,7537	1,0414	0,8231	7155
A13E2	-22.37	-50.97	2006	SP	24	0	8,8735	10,6588	1,3559	0,8172	12048
A13E3	-21.32	-50.93	2007	SP	24,5	4	8,854	10,7682	1,5013	1,0009	19000
A14E1	-22.36	-49.03	2001	SP	23,8	0	8,1579	6,1724	2,5152	1,1641	4546
A14E2	-23.43	-47.59	2006	SP	25	0	9,4426	8,8179	2,2899	1,1146	3360
A14E3	-23.85	-48.16	2006	SP	24,7	0	9,3927	9,2739	2,0735	0,9996	10976

Tabela 6.2: Anexo 2 - Resumo dos ajuste dos parâmetros de escala, forma e posição.

Estação	Estimate Loc	Estimate Scale	Estimate Shape	Std.err Loc	Std.err Scale	Std.err Shape	Deviance	Distrib.
A1E1	5.9384	3.7591	-0.1325	0.0123	0.0046	0.000002	539188.7	Fréchet
A1E2	4.6219	2.7501	-0.0626	0.0099	0.0071	0.002117	488571.0	Fréchet
A1E3	5.6053	2.8128	-0.1066	0.0097	0.0069	0.001109	486987.4	Fréchet
A2E1	3.4775	2.0317	-0.0385	0.0072	0.0051	0.001812	432407.4	Fréchet
A2E2	3.3060	2.9842	-0.1014	0.0102	0.0071	0.000523	498031.0	Fréchet
A2E3	4.9762	2.1644	-0.0557	0.0073	0.0049	0.000002	440243.8	Fréchet
A3E1	4.5864	1.9150	-0.0390	0.0081	0.0058	0.002483	307749.0	Fréchet
A3E2	3.9147	2.7747	-0.1026	0.0093	0.0059	0.000002	484037.6	Fréchet
A3E3	6.0711	2.3982	-0.0769	0.0083	0.0058	0.001229	458706.9	Fréchet
A4E1	3.3422	2.6291	-0.1063	0.0087	0.0042	0.000002	471530.5	Fréchet
A4E2	4.7107	2.6512	-0.1026	0.0086	0.0032	0.000002	473104.9	Fréchet
A4E3	5.3271	2.1966	-0.0042	0.0078	0.0056	0.001737	450555.9	Gumbel
A5E1	5.2631	2.3952	-0.0651	0.0083	0.0059	0.000987	460683.8	Fréchet
A5E2	3.2440	2.1310	0.0621	0.0079	0.0059	0.002660	454076.3	Weibull
A5E3	8.0706	2.6467	-0.0720	0.0088	0.0049	0.000002	471357.4	Fréchet
A6E1	5.6267	4.8194	-0.0983	0.0172	0.0122	0.001950	591680.1	Fréchet
A6E2	1.8787	1.7799	0.0272	0.0066	0.0049	0.002722	415584.1	Weibull
A6E3	2.1734	1.6109	0.0573	0.0058	0.0043	0.002270	399117.2	Weibull
A7E1	2.2123	2.3491	-0.0266	0.0089	0.0067	0.002950	463253.8	Fréchet
A7E2	1.8816	1.8812	0.0375	0.0072	0.0055	0.003259	427884.7	Weibull
A7E3	3.6733	2.8328	-0.0906	0.0095	0.0059	0.000002	489870.6	Fréchet
A8E1	1.5098	1.5806	0.2176	0.0063	0.0052	0.003942	413451.3	Weibull
A8E2	3.2782	2.2691	-0.0406	0.0081	0.0057	0.001862	453184.9	Fréchet
A8E3	3.2340	2.9846	-0.0838	0.0107	0.0077	0.002048	501690.2	Fréchet
A9E1	5.6534	2.4493	-0.0876	0.0081	0.0040	0.000002	458675.4	Fréchet
A9E2	4.9902	2.9044	-0.1038	0.0096	0.0045	0.000002	493421.4	Fréchet
A9E3	5.3002	3.1229	-0.1161	0.0103	0.0053	0.000002	501344.2	Fréchet
A10E1	2.4035	2.0550	0.0017	0.0077	0.0057	0.002786	440567.3	Gumbel
A10E2	3.8668	2.6539	-0.0838	0.0088	0.0049	0.000002	474821.0	Fréchet
A10E3	4.7167	2.8259	-0.0936	0.0094	0.0052	0.000002	485602.2	Fréchet
A11E1	3.6108	2.2991	-0.0744	0.0076	0.0041	0.000002	449474.8	Fréchet
A11E2	3.9320	2.9409	-0.1388	0.0101	0.0070	0.000791	491506.2	Fréchet
A11E3	2.8060	2.1900	-0.0101	0.0083	0.0062	0.002983	451887.6	Gumbel
A12E1	3.7951	2.8423	-0.0951	0.0094	0.0046	0.000002	486858.2	Fréchet
A12E2	3.1946	2.5246	-0.0980	0.0088	0.0062	0.001149	466727.7	Fréchet
A12E3	3.6826	2.7592	-0.0964	0.0090	0.0029	0.000002	482097.6	Fréchet
A13E1	4.4620	2.6691	-0.0375	0.0097	0.0070	0.002276	485856.9	Fréchet
A13E2	2.7598	2.2912	-0.0027	0.0085	0.0063	0.002755	460932.8	Gumbel
A13E3	4.0068	2.2023	-0.0891	0.0077	0.0054	0.001461	441215.0	Fréchet
A14E1	3.8519	2.0499	-0.1015	0.0068	0.0041	0.000002	425027.6	Fréchet
A14E2	3.5768	2.3971	-0.0776	0.0086	0.0061	0.001945	460296.9	Fréchet
A14E3	4.2201	2.7724	-0.1346	0.0091	0.0044	0.000002	478650.1	Fréchet

Tabela 6.3: Anexo 3 - Intervalos de confiança ao nível de 99,5% dos parâmetros de escala, forma e posição.

Estação	Low loc	Up loc	Low scale	Up scale	Low shape	Up shape	P(X>20m/s)
A1E1	5.9067	5.9701	3.7472	3.7709	-0.1325	-0.1325	8.83E-05
A1E2	4.5964	4.6474	2.7319	2.7683	-0.0681	-0.0571	5.86E-05
A1E3	5.5802	5.6303	2.7950	2.8305	-0.1095	-0.1038	1.41E-06
A2E1	3.4589	3.4961	2.0185	2.0448	-0.0432	-0.0338	4.10E-06
A2E2	3.2798	3.3323	2.9658	3.0025	-0.1028	-0.1001	1.20E-05
A2E3	4.9574	4.9950	2.1517	2.1770	-0.0557	-0.0557	2.18E-06
A3E1	4.5656	4.6072	1.9001	1.9298	-0.0454	-0.0326	1.45E-06
A3E2	3.8908	3.9386	2.7595	2.7899	-0.1027	-0.1026	1.74E-06
A3E3	6.0496	6.0926	2.3832	2.4132	-0.0801	-0.0737	1.48E-06
A4E1	3.3198	3.3646	2.6182	2.6399	-0.1064	-0.1063	1.40E-07
A4E2	4.6885	4.7330	2.6430	2.6594	-0.1026	-0.1026	4.27E-07
A4E3	5.3071	5.3472	2.1822	2.2110	-0.0087	0.0003	9.28E-05
A5E1	5.2419	5.2844	2.3800	2.4104	-0.0676	-0.0625	5.54E-06
A5E2	3.2238	3.2643	2.1159	2.1462	0.0552	0.0689	6.25E-04
A5E3	8.0479	8.0933	2.6342	2.6592	-0.0720	-0.0720	1.73E-05
A6E1	5.5823	5.6710	4.7879	4.8508	-0.1033	-0.0933	4.66E-03
A6E2	1.8617	1.8958	1.7671	1.7926	0.0202	0.0342	5.59E-05
A6E3	2.1583	2.1884	1.5998	1.6219	0.0514	0.0631	8.63E-05
A7E1	2.1894	2.2351	2.3319	2.3663	-0.0342	-0.0190	6.34E-05
A7E2	1.8630	1.9002	1.8670	1.8955	0.0291	0.0459	1.32E-04
A7E3	3.6489	3.6977	2.8175	2.8481	-0.0906	-0.0906	1.17E-05
A8E1	1.4935	1.5261	1.5672	1.5940	0.2075	0.2278	2.38E-03
A8E2	3.2574	3.2990	2.2544	2.2838	-0.0454	-0.0359	1.77E-05
A8E3	3.2064	3.2616	2.9648	3.0045	-0.0891	-0.0786	4.99E-05
A9E1	5.6326	5.6743	2.4390	2.4596	-0.0876	-0.0876	5.20E-07
A9E2	4.9656	5.0148	2.8927	2.9160	-0.1038	-0.1038	4.98E-06
A9E3	5.2736	5.3267	3.1093	3.1364	-0.1161	-0.1161	7.00E-06
A10E1	2.3837	2.4232	2.0403	2.0698	-0.0055	0.0088	6.42E-05
A10E2	3.8440	3.8895	2.6413	2.6665	-0.0838	-0.0838	6.13E-06
A10E3	4.6925	4.7409	2.8123	2.8394	-0.0936	-0.0936	8.28E-06
A11E1	3.5912	3.6304	2.2886	2.3096	-0.0744	-0.0744	7.54E-07
A11E2	3.9060	3.9579	2.9228	2.9591	-0.1408	-0.1368	3.98E-10
A11E3	2.7848	2.8273	2.1741	2.2060	-0.0177	-0.0024	6.88E-05
A12E1	3.7709	3.8193	2.8305	2.8541	-0.0951	-0.0950	8.06E-06
A12E2	3.1720	3.2171	2.5087	2.5405	-0.1009	-0.0950	1.95E-07
A12E3	3.6595	3.7058	2.7518	2.7666	-0.0964	-0.0964	3.49E-06
A13E1	4.4371	4.4869	2.6512	2.6870	-0.0434	-0.0317	1.48E-04
A13E2	2.7378	2.7817	2.2748	2.3075	-0.0098	0.0044	1.46E-04
A13E3	3.9869	4.0267	2.1885	2.2161	-0.0929	-0.0854	6.72E-09
A14E1	3.8343	3.8695	2.0393	2.0606	-0.1015	-0.1015	0.00E+00
A14E2	3.5548	3.5988	2.3815	2.4127	-0.0826	-0.0726	1.34E-06
A14E3	4.1966	4.2436	2.7611	2.7837	-0.1346	-0.1346	5.84E-13

Tabela 6.4: Anexo 4 - Testes de aderência.

Estação	KS	P-valor	RES	Fi	P-valor	RES	AD	P-valor	RES
A1E1	0.0551	0	NAJ	0.9490	0	NAJ	0.2731	0.6674	AJ
A1E2	0.0202	0	AJ	0.9887	0	NAJ	0.2242	0.8238	AJ
A1E3	0.0345	0	AJ	0.9681	0	NAJ	0.2044	0.8744	AJ
A2E1	0.0483	0	NAJ	0.9963	0	NAJ	0.1951	0.8914	AJ
A2E2	0.1369	0	NAJ	0.9513	0	NAJ	0.9594	0.0155	NAJ
A2E3	0.0662	0	NAJ	0.9893	0	NAJ	0.3820	0.3992	AJ
A3E1	0.0267	0	AJ	0.9963	0	NAJ	0.7618	0.0476	AJ
A3E2	0.0483	0	NAJ	0.9640	0	NAJ	0.3774	0.4091	AJ
A3E3	0.0393	0	NAJ	0.9874	0	NAJ	0.2320	0.8012	AJ
A4E1	0.1103	0	NAJ	0.9416	0	NAJ	0.3750	0.4144	AJ
A4E2	0.0544	0	NAJ	0.9658	0	NAJ	0.3335	0.5093	AJ
A4E3	0.0381	0	NAJ	0.9888	0	NAJ	0.2604	0.7101	AJ
A5E1	0.0310	0	AJ	0.9873	0	NAJ	0.2457	0.7586	AJ
A5E2	0.0315	0	AJ	0.9958	0	NAJ	0.1967	0.8890	AJ
A5E3	0.1419	0	NAJ	0.9675	0	NAJ	0.3194	0.5340	AJ
A6E1	0.1102	0	NAJ	0.9665	0	NAJ	0.1830	0.9111	AJ
A6E2	0.1085	0	NAJ	0.9936	0	NAJ	0.2007	0.8827	AJ
A6E3	0.0403	0	NAJ	0.9858	0	NAJ	0.1786	0.9186	AJ
A7E1	0.1536	0	NAJ	0.9816	0	NAJ	0.2170	0.8433	AJ
A7E2	0.1113	0	NAJ	0.9915	0	NAJ	0.3922	0.3780	AJ
A7E3	0.0626	0	NAJ	0.9578	0	NAJ	0.4907	0.2200	AJ
A8E1	0.0751	0	NAJ	0.9580	0	NAJ	0.5743	0.1360	AJ
A8E2	0.0462	0	NAJ	0.9957	0	NAJ	0.3673	0.4316	AJ
A8E3	0.1290	0	NAJ	0.9725	0	NAJ	0.2684	0.6832	AJ
A9E1	0.1111	0	NAJ	0.9734	0	NAJ	0.1508	0.9621	AJ
A9E2	0.0314	0	AJ	0.9746	0	NAJ	0.2835	0.6331	AJ
A9E3	0.0775	0	NAJ	0.9439	0	NAJ	0.2541	0.7311	AJ
A10E1	0.0520	0	NAJ	0.9956	0	NAJ	0.3005	0.5811	AJ
A10E2	0.0726	0	NAJ	0.9740	0	NAJ	0.1518	0.9608	AJ
A10E3	0.0586	0	NAJ	0.9717	0	NAJ	0.2496	0.7460	AJ
A11E1	0.0956	0	NAJ	0.9745	0	NAJ	0.1581	0.9521	AJ
A11E2	0.0708	0	NAJ	0.9404	0	NAJ	0.3374	0.5044	AJ
A11E3	0.0567	0	NAJ	0.9905	0	NAJ	0.1361	0.9780	AJ
A12E1	0.1006	0	NAJ	0.9535	0	NAJ	0.4561	0.2669	AJ
A12E2	0.0907	0	NAJ	0.9705	0	NAJ	0.2280	0.8129	AJ
A12E3	0.0866	0	NAJ	0.9517	0	NAJ	0.3704	0.4246	AJ
A13E1	0.0302	0	AJ	0.9943	0	NAJ	0.1712	0.9313	AJ
A13E2	0.0426	0	NAJ	0.9955	0	NAJ	0.3012	0.5792	AJ
A13E3	0.0688	0	NAJ	0.9824	0	NAJ	0.3831	0.3969	AJ
A14E1	0.0335	0	AJ	0.9717	0	NAJ	0.5632	0.1452	AJ
A14E2	0.0350	0	AJ	0.9835	0	NAJ	0.1630	0.9447	AJ
A14E3	0.0737	0	NAJ	0.9382	0	NAJ	0.8817	0.0241	NAJ

Tabela 6.5: Anexo 5 - Classificação de risco das estações meteorológicas- Parte I.

Estação	Tendência		Box plot			Wavelets		Rosa dos ventos			GEV
	Intercepto	Coefficiente	EEFS	MCVF	MCVFr	Variabilidade	PAPM	CVFE	CVEQ	CDQ	P(X>=20m/s)
A1E1	-5.18	0.00077	forte	m10,m11	m5,m6	2A,A,T,M	2A	2T,4T	Q3	Q4,Q1	8.83E-05
A1E2	7.37	-0.00008	forte	m9,m10,m11	m5,m6	A,B,M,Sem	A	4T	Q1	Q4,Q1	5.86E-05
A1E3	7.85	-0.00005	forte	m9,m10,m11	m5,m6	A,B,M,Sem	A	4T	Q3	Q1	1.41E-06
A2E1	3.50	0.00006	forte	m10,m12	m5,m6,m7	2A,A,B	A	4T	Q4	Q4	4.10E-06
A2E2	16.21	-0.00069	forte	m10,m11	m4	2A,A,B	A	4T	Q4	Q4	NAJ
A2E3	12.19	-0.00037	forte	m8	m4	A,B,M,Sem	A	3T,4T	Q4	Q4	2.18E-06
A3E1	-23.38	0.00166	forte	m10,m11	m5	A,B,M,Sem	A	3T,4T	Q4	Q4,Q1	1.45E-06
A3E2	2.76	0.00015	forte	m10,m11,m12	m5,m6	2A,A,B,T,M	A	4T	Q1	Q1,Q4	1.74E-06
A3E3	7.14	0.00001	forte	m8	m4	2A,A,T,M	A	3T,4T	Q1	Q1,Q4	1.48E-06
A4E1	16.94	-0.00074	forte	m9,m10	m5	2A,A,T	A	3T,4T	Q4	Q1,Q4	1.40E-07
A4E2	9.96	-0.00024	forte	m8	m4	2A,A,B,T,M	A	3T,4T	Q4	Q1,Q4	4.27E-07
A4E3	8.66	-0.00013	fraco	m8,m5	m6	2A,A,B,T,M	A	3T,2T	Q1	Q1,Q2	9.28E-05
A5E1	6.15	0.00002	fraco	m8	m4,m5	A,B,T,M	A	3T,2T	Q2	Q1,Q2	5.54E-06
A5E2	4.11	0.00003	forte	m10,m11	m6	2A,A,T	A	3T,4T	Q3	Q3,Q4	6.25E-04
A5E3	9.74	-0.00003	fraco	m8,m9	m4	2A,A,T	2A	3T,4T	Q2	Q2,Q3	1.73E-05
A6E1	27.75	-0.00119	forte	m3,m4	m11,m12	2A,A,T,M	A	1T,2T,3T	Q1,Q3	Q3	4.66E-03
A6E2	2.40	0.00003	forte	m10	m5	2A,A,M	A	3T,4T	Q3	Q3	5.59E-05
A6E3	3.76	-0.00003	fraco	m1	m6	2A,A,T,B,M	A	3T,4T	Q3	Q3,Q1	8.63E-05
A7E1	19.75	-0.00098	forte	m6,m7	m10,m11	2A,A,T,M	A	4T	Q4	Q4	6.34E-05
A7E2	5.77	-0.00016	forte	m11,m12	m6	2A,A,T,M	A	3T	Q3	Q3	1.32E-04
A7E3	3.40	0.00010	fraco	m10	m6	A,B,M,Sem	A	3T,4T	Q2,Q4	Q2	1.17E-05

Tabela 6.6: Anexo 6 - Classificação de risco das estações meteorológicas- Parte II.

Estação	Tendência		Box plot			Wavelets		Rosa dos ventos			GEV
	Intercepto	Coeficiente	EEFS	MCVF	MCVFr	Variabilidade	PAPM	CVFE	CVEQ	CDQ	P(X>=20m/s)
A8E1	-1.79	0.00028	forte	m6,m7	m10	2A,A,T,M	A	2T,3T	Q3,Q2	Q3	2.38E-03
A8E2	5.26	-0.00005	forte	m6,m7	m11	2A,A,M,Sem	A	3T,4T	Q3,Q4	Q3	1.77E-05
A8E3	17.62	-0.00078	forte	m9,m10	m2,m3	A,T,M	A	3T,4T	Q1	Q1	4.99E-05
A9E1	6.26	0.00003	fraco	m8,m9,m10	m4	2A,A,T	A	3T,4T	Q1,Q2	Q2	5.20E-07
A9E2	12.15	-0.00035	fraco	m7,m8	m3,m4	2A,A,M,Sem	A	3T,4T	Q1,Q2	Q2	4.98E-06
A9E3	10.59	-0.00023	forte	m8	m3,m4	2A,A,M,Sem	A	3T,4T	Q4	Q4	7.00E-06
A10E1	5.25	-0.00010	forte	m10,m11	m5	2A,A,M,Sem	A	3T,4T	Q1,Q2	Q2	6.42E-05
A10E2	11.72	-0.00040	fraco	m6,m7	m9,m10	2A,A,T	A	3T	Q1,Q4	Q1,Q4	6.13E-06
A10E3	8.12	-0.00012	forte	m9,m10	m4	2A,A,M,Sem	A	3T,4T	Q3,Q4	Q3	8.28E-06
A11E1	6.92	-0.00013	fraco	m8,m1	m4,m5	2A,A,T	2A	4T	Q4	Q4	7.54E-07
A11E2	8.86	-0.00022	forte	m10,m11	m6	2A,A,M,Sem	A	3T,4T	Q4	Q4	3.98E-10
A11E3	2.57	0.00009	forte	m10,m11	m6	2A,A,T,M	A	3T,4T	Q4	Q4	6.88E-05
A12E1	2.52	0.00016	fraco	m9,m10	m5,m6	2A,A,T	A	3T,4T	Q4	Q4	8.06E-06
A12E2	2.11	0.00014	forte	m9,m10,m11	m3,m4	2A,A,T,M	A	3T,4T	Q4	Q4	1.95E-07
A12E3	2.83	0.00013	fraco	m10,m11	m6	2A,A,T,M	A	3T,4T	Q3	Q3,Q1	3.49E-06
A13E1	5.90	0.00000	fraco	m10,m11	m6	2A,A,T	A	3T,4T	Q2	Q2,Q1	1.48E-04
A13E2	2.90	0.00007	forte	m10,m11	m5,m6	2A,A,T,M	A	3T,4T	Q4	Q4	1.46E-04
A13E3	7.00	-0.00012	forte	m9	m5	2A,A,T	A	3T,4T	Q4	Q4,Q1	6.72E-09
A14E1	4.35	0.00003	forte	m10	m5,m6	2A,A,T	A	3T,4T	Q4	Q4,Q2	0.00E+00
A14E2	4.55	0.00001	forte	m10	m6	A,M,Sem	A	3T,4T	Q4	Q4	1.34E-06
A14E3	5.26	0.00001	forte	m10,m11	m5	2A,A,T,B	A	3T,4T	Q1,Q4	Q1,Q4	NAJ

Tabela 6.7: Anexo 7 - Siglas das Tabelas do anexo 6 e 7.

Sigla	Descrição	Classificadores
EEFS	Estimativa de Efeito Sazonal	forte,fraco,inesistente
MCVF	Meses de Concentração de Ventos Fortes	m1 até m12
MCVFr	Meses de Concentração de Ventos Fracos	m1 até m12
Variabilidade	Periodos que apresentam efeitos sazonais com significância ao nível de 5% pelo método de Wavelet	2A(2 anos), A(1 ano), T(trimestre), B(bimestre), M(mensal), Sem(Semanal)
PAPM	Periodo de alta potência média de wavelet	2A(2 anos), A(1 ano), T(trimestre), B(bimestre), M(mensal), Sem(Semanal)
CVFE	Concentração de Ventos Fortes Época do ano	1T,2T,3T,4T(Trimestres)
CVFQ	Concentração de Ventos Fortes Quadrante	Q1,Q2,Q3,Q4(Quadrantes)
CDQ	Concentração de dados Quadrante	Q1,Q2,Q3,Q4(Quadrantes)

Tabela 6.8: Anexo 8 - Escala de classificação de Riscos das Tabelas do anexo 6 e 7.

Risco	Classificação $P(X \geq 20\text{m/s})$
RISCO ALTO	$P(X \geq 20\text{m/s}) > 1\text{E-}04$
RISCO MÉDIO ALTO	$1\text{E-}04 \geq P(X \geq 20\text{m/s}) > 1\text{E-}05$
RISCO MÉDIO	$1\text{E-}05 \geq P(X \geq 20\text{m/s}) > 1\text{E-}06$
RISCO MÉDIO BAIXO	$1\text{E-}06 \geq P(X \geq 20\text{m/s}) > 1\text{E-}07$
RISCO BAIXO	$1\text{E-}07 \geq P(X \geq 20\text{m/s})$

Figura 6.1: Anexo 9- Matriz de correlação de Pearson




Tabela 6.9: Anexo 12- Área de classificação de risco correspondendo aos 6 modelos de interpolação espacial e considerando probabilidade de ventos extremos acima de 20m/s

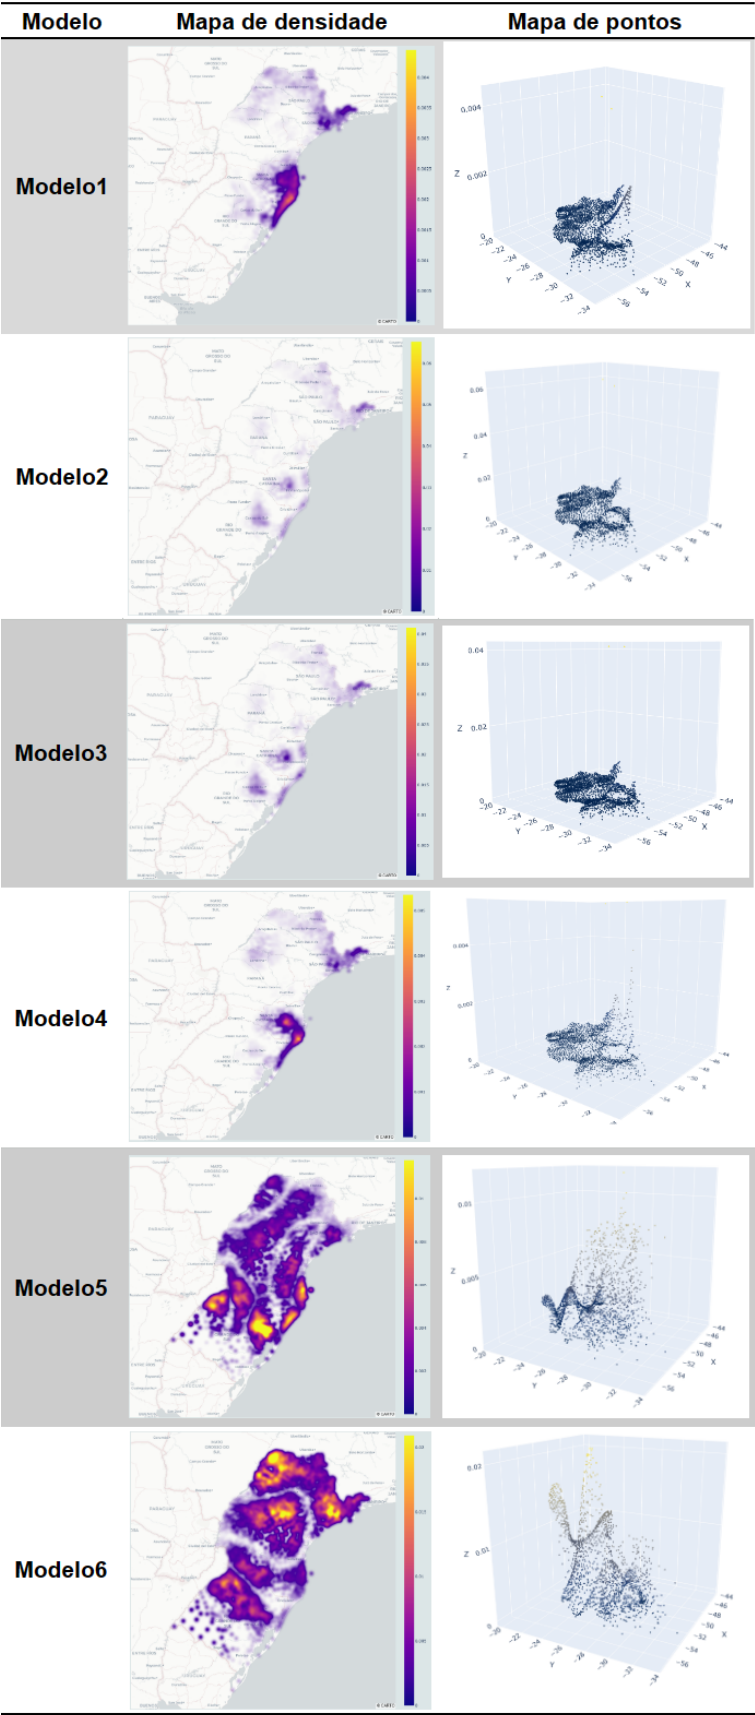


Tabela 6.10: Anexo 13- Gráficos de densidade e pontos com a Variação das taxas de sinistralidade de 10%,20% e 30%

