

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, CONTÁBEIS E ATUARIAIS
CIÊNCIAS ATUARIAIS**

RENATA VILLAS BOAS DIAS

**EVENTOS CLIMÁTICOS EXTREMOS: OS DESAFIOS PARA O
MERCADO SEGURADOR E ABORDAGENS PARA A
MODELAGEM E PREDIÇÃO DE EVENTOS FUTUROS**

SÃO PAULO

2024

RENATA VILLAS BOAS DIAS

**EVENTOS CLIMÁTICOS EXTREMOS: OS DESAFIOS PARA O
MERCADO SEGURADOR E ABORDAGENS PARA A
MODELAGEM E PREDIÇÃO DE EVENTOS FUTUROS**

Trabalho de Conclusão de Curso apresentado ao curso de Ciências Atuariais, da Pontifícia Universidade Católica de São Paulo, como requisito parcial para a obtenção do Grau de Bacharel em Ciências Atuariais.

Orientador: Profa. Dra. Fabiana Lopes Da Silva

SÃO PAULO

2024

RENATA VILLAS BOAS DIAS

EVENTOS CLIMÁTICOS EXTREMOS: OS DESAFIOS PARA O
MERCADO SEGURADOR E ABORDAGENS PARA A MODELAGEM E
PREDIÇÃO DE EVENTOS FUTUROS

Trabalho de Conclusão de Curso apresentado
ao curso de Ciências Atuariais, da Pontifícia
Universidade Católica de São Paulo, como
requisito parcial para a obtenção do Grau de
Bacharel em Ciências Atuariais.

São Paulo, 17 de junho de 2024.

BANCA EXAMINADORA

Orientadora Profa. Dra. Fabiana Lopes da Silva

Examinador Prof. Dr. Antônio Cordeiro Filho

Examinadora Profa. Dra. Elizabeth Borelli

Resumo

Em um contexto de mudanças climáticas e ocorrência cada vez mais frequente e severa de eventos climáticos extremos, surge a necessidade de o mercado segurador adotar metodologias estatísticas mais robustas para a previsão de eventos extremos futuros e, sob a ótica da IFRS 17, incorporá-las à melhor estimativa de seu passivo para cobertura de sinistros futuros. Neste trabalho, é feita a discussão dos desafios que as mudanças climáticas e a crescente frequência de eventos climáticos extremos impõem ao mercado segurador. Em particular, são introduzidas duas abordagens metodológicas para a modelagem de eventos extremos que, se incorporadas às mensurações dos riscos de um grupo de contratos, podem ser de grande valia: a análise de séries temporais e os modelos bayesianos. Para cada abordagem, são apresentados exemplos de pesquisas que aplicam as respectivas metodologias na modelagem e previsão de eventos climáticos extremos. Diante da limitação de dados históricos, intrínseca quando tratando-se de eventos extremos, os trabalhos propõem alternativas e mostram, por meio da aplicação a dados reais, a eficácia das suas abordagens.

Palavras-chave: Eventos Climáticos Extremos, Mudanças Climáticas, Mercado Segurador, IFRS 17.

Abstract

Climate change is increasing the frequency and severity of extreme weather events, which creates the need for insurance markets to adopt more robust statistical methodologies for predicting these events and, under the perspective of the IFRS 17, to incorporate these predictions into the best estimate of its liabilities for the coverage of future claims. This work discusses the challenges that climate change and the growing frequency of extreme weather events pose to the insurance market. It also presents two methodological approaches for modeling extreme events, which, if incorporated into risk measurements for a group of contracts, could be highly valuable: time series analysis and Bayesian models. For each approach, examples of research applying these methodologies to the modeling and prediction of extreme weather events are presented. Given the inherent limitation of historical data when dealing with extreme events, the studies propose alternatives and demonstrate, through application to real data sets, the effectiveness of their approaches.

Keywords: Extreme Climate Events, Climate Change, Insurance Market, IFRS 17.

Lista de ilustrações

Figura 1 – Diferenças entre a temperatura da superfície da terra no século XXI em comparação com a média do século XX	11
Figura 2 – Número de catástrofes naturais ao redor do mundo, 1980 - 2018	12
Figura 3 – Evolução da quantidade de desastres nos últimos 40 anos no Brasil	13
Figura 4 – Prejuízo por extremos climáticos no Brasil	14
Figura 5 – Montante de sinistros causados por desastres naturais - Estados Unidos	15
Figura 6 – Exemplos de exposição a riscos climáticos por cobertura - seguros de danos	17
Figura 7 – Previsão de um modelo ARIMA	26
Figura 8 – Previsão de um modelo SARIMA	27

Sumário

	1 INTRODUÇÃO	7
1.1	Contextualização	7
1.2	Objetivo	8
1.3	Metodologia	8
1.4	Justificativa	9
	2 AS MUDANÇAS CLIMÁTICAS E OS DESAFIOS PARA O MERCADO SEGURADOR	10
2.1	As mudanças climáticas e seus efeitos no Brasil e no mundo . .	10
2.2	O mercado segurador	16
2.3	Desafios das mudanças climáticas para o mercado segurador . .	20
	3 ABORDAGENS PARA A MODELAGEM DE EVENTOS CLI- MÁTICOS EXTREMOS	25
3.1	Modelagem de eventos climáticos extremos por meio da análise de séries temporais	26
3.2	Modelos de regressão bayesianos para a modelagem de eventos climáticos extremos	29
	4 CONSIDERAÇÕES FINAIS	37
	REFERÊNCIAS	39

1. Introdução

1.1. Contextualização

Apenas em 2023, o Brasil registrou 12 eventos climáticos extremos, segundo relatório publicado em maio de 2024 pela Organização Meteorológica Mundial (OMM), agência especializada da ONU ([World Meteorological Organization, 2024](#)). Desses eventos, nove foram classificados como incomuns e dois sem precedentes: cinco ondas de calor, três chuvas intensas, uma onda de frio, uma inundação, uma seca e um ciclone extratropical. Além disso, em maio deste ano (2024) o Rio Grande do Sul foi severamente afetado pelas enchentes causadas pelo excesso de chuva no estado, deixando 172 mortos e centenas de milhares de desabrigados, conforme informações divulgadas no dia 3 de junho de 2024 ([Agência Brasil, 2024](#)).

Desde o aumento na frequência e severidade de sinistros a perdas de ativos se tornando mais volátil e possuindo maiores impactos, as mudanças climáticas trazem a necessidade do trabalho conjunto dos cientistas climáticos e atuários. No cálculo dos fluxos de caixa futuros, os atuários precisam considerar a crescente incerteza nos valores das indenizações, sem deixar de levar em consideração as características específicas das diferentes linhas de negócios. Ainda, as estimativas precisam considerar as limitações dos dados históricos, e as modelagens de catástrofe se tornam essenciais para quantificar os possíveis impactos das mudanças climáticas. Esses e outros aspectos devem ser incorporados pelo mercado segurador para garantir que os efeitos causados pelas mudanças climáticas sejam integrados de maneira precisa ao conceito da melhor estimativa.

A IFRS 17 ([IASB, 2017](#)) traz consigo o conceito de fluxos de caixa futuros para a mensuração do passivo de um grupo de contratos de seguro. Assim, a necessidade de previsões cada vez mais precisas, tanto do montante de sinistros futuros quanto do momento de pagamento das indenizações, torna-se ainda mais crítica para obter estimativas que não se distanciem significativamente da realidade. Historicamente, o mercado segurador brasileiro tende a construir suas premissas de sinistralidade e curvas de ocorrência e pagamento de sinistros com base em estatísticas históricas, utilizando a média de um período de observações dos dados e realizando possíveis ajustes para desconsiderar períodos ou observações atípicas. No entanto, em um cenário de mudanças climáticas e consequente limitação dos dados históricos, surge a necessidade de o mercado segurador expandir seu horizonte para a ado-

ção de metodologias estatísticas mais robustas para a previsão de eventos extremos, a fim de incorporá-las à melhor estimativa de seu passivo para cobertura de sinistros futuros.

1.2. Objetivo

O objetivo deste trabalho é discutir os desafios que as mudanças climáticas e a crescente frequência de eventos climáticos extremos impõem ao mercado segurador. Dessa forma, sob a ótica da IFRS 17 (IASB, 2017), explorar possibilidades na mensuração dos riscos de um grupo de contratos de seguro e estimação do passivo para cobertura de sinistros futuros.

Os objetivos específicos incluem a introdução de duas abordagens metodológicas para a modelagem de eventos climáticos extremos, que podem ser valiosas se incorporadas às mensurações dos riscos de um grupo de contratos: a análise de séries temporais e os modelos bayesianos. Para cada abordagem, são apresentados exemplos de trabalhos distintos que aplicam as respectivas metodologias na modelagem e previsão de eventos climáticos extremos.

1.3. Metodologia

Este trabalho consiste em uma pesquisa quali-quantitativa, que busca destacar a crescente relevância das mudanças climáticas e a ocorrência cada vez mais frequente de eventos climáticos extremos no contexto do mercado segurador. Com a intensificação desses eventos, torna-se crucial entender como esses fatores afetam a avaliação de riscos e a gestão de sinistros. Dessa forma, sob a ótica da IFRS 17 (IASB, 2017), este estudo busca explorar possibilidades de abordagens que podem ser incorporadas ao processo de mensuração do passivo para cobertura de sinistros futuros de um grupo de contratos impactados por eventos climáticos extremos.

A IFRS 17, que estabelece princípios para o reconhecimento, a mensuração, a apresentação e a divulgação dos contratos de seguro, oferece um quadro robusto para a análise dessas questões. A pesquisa visa identificar metodologias que permitam uma avaliação mais precisa e robusta dos passivos, considerando a maior imprevisibilidade e o aumento da frequência dos eventos climáticos extremos.

Além disso, o estudo pretende analisar como as seguradoras podem adaptar suas práticas atuais para mitigar os riscos associados a esses eventos, incluindo a possível revisão de premissas atuariais e a implementação de novos modelos de risco. Essas mudanças não só visam a conformidade regulatória, mas também a resiliência financeira das empresas de seguros frente aos desafios impostos pelas mudanças climáticas.

1.4. Justificativa

Apesar de pesquisas sobre mudanças climáticas e predição de eventos climáticos extremos desenvolvidas por cientistas climáticos não serem algo novo, já tendo sido exploradas por, por exemplo, (BERLINER; KIM, 2008), (BRIGGS, 2008), (CHAND; WALSH, 2011), (ELSNER; BOSSAK, 2001), (CHU; ZHAO, 2011) e (HO; CHU, 2009), no âmbito das ciências atuariais este ainda é um tópico pouco explorado. No entanto, com o desafio trazido pela IFRS 17 de projeção de fluxos de caixa futuros relacionados aos contratos de seguro, e diante de um cenário de mudanças climáticas e eventos extremos, surge a necessidade de cientistas climáticos e atuários trabalharem em conjunto. Assim, a incorporação de metodologias de predição destes eventos, como as abordadas por (LU; CHU; LIN, 2010), (JAGGER; ELSNER, 2010) (CHU; ZHAO, 2007) e (DING et al., 2019) podem ser de grande valia para as estimativas atuariais e adequada mensuração do passivo das seguradoras.

2. As mudanças climáticas e os desafios para o mercado segurador

2.1. As mudanças climáticas e seus efeitos no Brasil e no mundo

Mudanças climáticas, segundo a Organização das Nações Unidas (ONU), referem-se a mudanças a longo prazo nas temperaturas e padrões climáticos, sendo causadas pela atividade humana ou não (ONU, 2022). Estas são causadas pelo aquecimento global, que surge devido às emissões de gases de efeito estufa. E quais as consequências das mudanças climáticas? Ondas de calor e de frio, inundações e enchentes, incêndios florestais, estiagem e seca, deslizamento de terra, ciclones, tornados e vendavais são apenas alguns dos exemplos. Estes eventos são o que denominamos como eventos climáticos extremos e que, segundo a OMM, são raros em um local particular e período do ano, com características incomuns em termos de magnitude, localidade, tempo ou extensão, e suas características podem variar de lugar para lugar.

Os eventos climáticos extremos têm se tornado uma preocupação crescente nas últimas décadas devido à sua frequência e intensidade aumentarem continuamente. Fenômenos como ondas de calor, tempestades intensas, furacões, secas e inundações estão ocorrendo com maior frequência e severidade, causando impactos profundos na sociedade, economia e meio ambiente. Economicamente, os desastres climáticos causam danos significativos à infraestrutura, agricultura e setores industriais, levando a enormes custos de recuperação e afetando o crescimento econômico. Por exemplo, tempestades e furacões podem destruir casas, estradas e redes elétricas, exigindo investimentos maciços para reconstrução. Na agricultura, secas prolongadas podem devastar colheitas, reduzir a produção de alimentos e aumentar os preços, colocando em risco a segurança alimentar.

Ambientalmente, esses eventos provocam a degradação dos ecossistemas, perda de biodiversidade e alteração dos ciclos naturais. Por exemplo, inundações podem levar à erosão do solo e à destruição de habitats naturais, enquanto ondas de calor extremo podem estressar plantas e animais, resultando em mortalidade significativa e perda de espécies. A mudança nos padrões climáticos também altera os ciclos de reprodução e migração de muitas espécies, perturbando o equilíbrio ecológico.

Além disso, os impactos sociais são profundos, especialmente para comunidades vulneráveis. Deslocamentos forçados devido a desastres naturais, perda de habitação e acesso reduzido a recursos essenciais, como água potável, aumentam as dificuldades enfrentadas por populações já marginalizadas. Esses eventos exacerbam as desigualdades sociais e podem levar a crises humanitárias. Assim, compreender as causas, os efeitos e as estratégias de mitigação desses eventos é crucial para enfrentar os desafios impostos por um clima em constante mudança.

O aumento das temperaturas médias globais é um dos principais motores das mudanças climáticas. A temperatura média global já subiu cerca de 1,1°C desde a era pré-industrial (1850 - 1900), segundo informações da agência regulatória norte-americana NOAA (*National Oceanic and Atmospheric Administration*), responsável pelo monitoramento das condições oceânicas e atmosféricas, além de previsões climáticas ([National Oceanic and Atmospheric Administration, 2024](#)). Embora esse número possa parecer pequeno, suas consequências são profundas, uma vez que pequenas variações na temperatura média global podem levar a grandes mudanças nos padrões climáticos.




Figura 1 – Diferenças entre a temperatura da superfície da terra no século XXI em comparação com a média do século XX

Fonte: Página do NOAA National Centers for Environmental Information, Climate at a Glance: Global Time Serie ([National Oceanic and Atmospheric Administration, 2024](#))

Ondas de calor mais intensas e frequentes são uma consequência direta do aumento das temperaturas globais, exacerbadas pelas mudanças climáticas. Estas ondas de calor não só representam um risco significativo à saúde humana, causando condições como desidratação, insolação e agravando condições crônicas, como também afetam a agricultura, reduzindo a produtividade das colheitas, aumentando os custos de produção e, conseqüentemente, elevando os preços dos alimentos, aumentando a vulnerabilidade alimentar e a insegurança nutricional em regiões afetadas.

As tempestades intensas, incluindo furacões e tufões, têm se tornado mais poderosas

e destrutivas. A elevação da temperatura do oceano fornece mais energia para esses sistemas de tempestades, resultando em precipitações mais intensas e ventos mais fortes. O impacto desses eventos é sentido de forma aguda em regiões costeiras, onde as inundações e os danos estruturais podem desabrigar milhares de pessoas e destruir infraestrutura vital.

As secas prolongadas, por outro lado, têm aumentado em frequência e severidade, afetando a disponibilidade de água potável, a produção agrícola e a biodiversidade. Regiões que tradicionalmente já enfrentam escassez de água, como partes da África e do Oriente Médio, estão especialmente vulneráveis, exacerbando problemas socioeconômicos e conflitos pela água.

Inundações mais frequentes e severas também estão associadas às mudanças climáticas. A elevação do nível do mar, causada pelo derretimento das calotas polares e das geleiras, combinada com tempestades mais intensas, tem levado a inundações costeiras devastadoras. Além disso, chuvas torrenciais podem provocar enchentes em áreas que antes não eram afetadas, causando perda de vidas, destruição de propriedades e grandes deslocamentos populacionais.

Dessa forma, com o aumento das temperaturas globais, os riscos climáticos, incluindo eventos climáticos extremos (como os exemplificados acima) também aumentam, se tornando cada vez mais frequentes e intensos ao longo dos últimos anos: desde 1980, conforme dados divulgados pela Munich Re, o número de desastres naturais ao redor do mundo mais que triplicou (Munich Re, *Geo Risks Research*, 2019).




Figura 2 – Número de catástrofes naturais ao redor do mundo, 1980 - 2018

Fonte: Informações fornecidas pela Munich Re (Munich Re, *Geo Risks Research*, 2019)

Na imagem acima, eventos como terremotos, tsunamis e atividade vulcânica estão classificados como *Geophysical events*. Eventos meteorológicos, como tempestades, estão classificados como *Meteorological events*, inundações como *Hydrological events* e tempera-

turas extremas, seca e queimadas florestais como *Climatological events*.

Refletindo as tendências globais climáticas, no Brasil, nos últimos 40 anos, a quantidade total desses eventos aumentou seis vezes. A evolução da quantidade de eventos climáticos extremos nas últimas duas décadas no Brasil pode ser observada por meio do gráfico abaixo. Nesta imagem, eventos climáticos referem-se àqueles ligados à escassez de água e incêndios florestais; eventos hidrológicos referem-se a enchentes, inundações e enxurradas; eventos meteorológicos referem-se a tempestades e ventos intensos.




Figura 3 – Evolução da quantidade de desastres nos últimos 40 anos no Brasil

Fonte: Reportagem da Revista Galileu ([Revista Galileu, 2020](#))

No período apresentado, observa-se que os eventos classificados como climáticos foram os que apresentaram aumento mais expressivo. Além disso, é interessante notar que, por mais que tenha havido aumento no número de cidades afetadas, este não acompanhou a evolução da quantidade total de eventos, indicando que muitas destas foram afetadas por mais de um desastre.

Os impactos dos eventos climáticos extremos são amplamente sentidos nas áreas econômicas, sociais e ambientais. O aumento dos custos de reconstrução e recuperação após desastres, a perda de vidas humanas, o deslocamento de comunidades e a degradação ambiental são algumas das consequências graves que estão se tornando cada vez mais comuns. Ainda, eventos decorrentes dos riscos climáticos possuem impacto direto na atividade econômica por meio de danos físicos a propriedades e *commodities*, por exemplo, e também por meio de interrupções ao comércio.

Conforme reportagem publicada pela revista Exame em seu site eletrônico em 11 de maio de 2024 ([Revista Exame, 2024](#)), o Brasil registrou um prejuízo de R\$ 502,438 bilhões

nos últimos 30 anos por eventos climáticos extremos. Entre 1993 e 2002 foram R\$ 19,573 bilhões em prejuízos. Já entre os anos de 2003 e 2012, este montante passou para R\$ 165,964 bilhões, chegando R\$ 316,902 bilhões entre 2013 e 2022. Nestes montantes, considera-se como prejuízo destruição de casas e prédios, além dos impactos financeiros em setores da economia (agronegócio, indústria e infraestrutura pública, por exemplo).

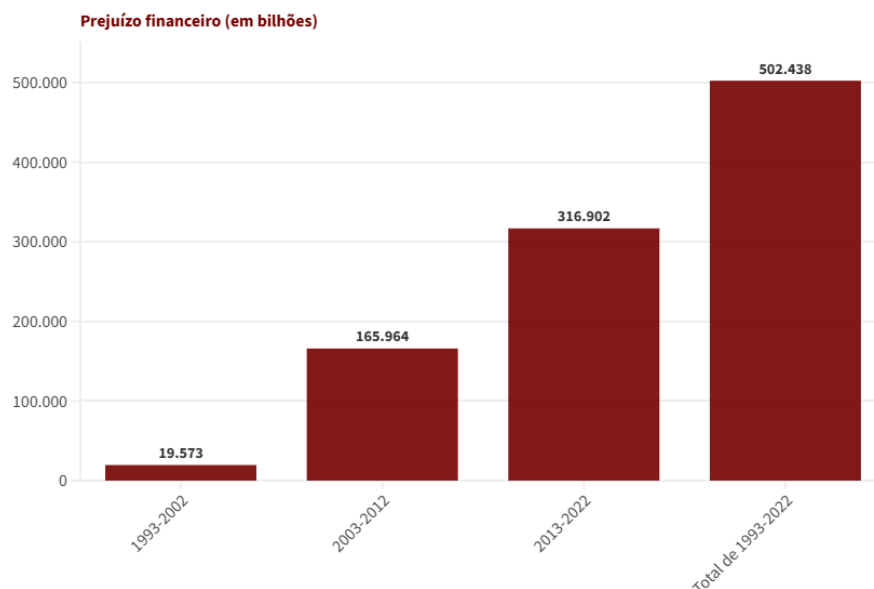


Figura 4 – Prejuízo por extremos climáticos no Brasil

Fonte: Reportagem da Revista Exame ([Revista Exame, 2024](#))

Com o crescente aumento na quantidade de eventos climáticos extremos e nos prejuízos causados por eles, surge a necessidade do mercado segurador focar nos riscos associados às mudanças climáticas e eventos climáticos extremos. A materialização dos riscos devido a eventos climáticos extremos pode ocorrer em variados tipos de seguros e coberturas: seguros de automóvel podem ter seus custos aumentados devido ao clima extremo; sinistros de seguros patrimoniais e habitacionais podem sofrer aumento em sua frequência e severidade devido a danos a edifícios, casas e lojas; o seguro rural pode ter aumento de sinistralidade devido ao clima mais extremo.

Um relatório publicado pela Swiss Re ([Swiss RE Institute, 2024](#)) destaca que sinistros decorrentes de catástrofes climáticas superaram a marca dos 100 bilhões de dólares apenas em 2023. Com isso, os riscos climáticos têm ameaçado uma subida nos preços dos seguros e a saída de algumas seguradoras dos setores em que os riscos associados a eventos climáticos extremos são mais elevados.

Uma reportagem publicada pelo Washington Post em 3 de setembro de 2023 ([The Washington Post, 2023](#)) mostra que algumas das maiores seguradoras norte-americanas (Allstate, American Family, Nationwide, Erie Insurance Group e Berkshire Hathaway) afirmam que eventos climáticos extremos, causados pelas mudanças climáticas, os levaram a parar de

oferecer determinadas coberturas em seus seguros, excluïrem a proteçãõ contra desastres naturais, além de elevarem o valor dos prêmios. Como a maior parte dos seguros patrimoniais são anuais, as seguradoras não estão presas a estas apólices por mais de 12 meses e, com isso, muitas delas têm mostrado desinteresse em renovar suas apólices em determinados locais à medida que essas regiões se tornam mais vulneráveis a desastres naturais.

Nos Estados Unidos, de 2020 a 2022, desastres naturais causaram um montante de sinistros associados a eventos climáticos extremos de 295,8 bilhões de dólares. Este número representa recorde histórico para um período de análise de três anos seguidos. A evolução deste número, desde 2013 a 2022, pode ser observada na figura abaixo.




Figura 5 – Montante de sinistros causados por desastres naturais - Estados Unidos

Fonte: Reportagem do *The Washington Post* ([The Washington Post, 2023](#))

No Brasil, a discussão em torno dos eventos climáticos extremos no mercado segurador ganhou ênfase apenas nos últimos anos, principalmente devido aos recentes recordes de ocorrência de eventos climáticos extremos. O aumento da frequência destes eventos tem produzido efeitos sobre o setor, no mínimo, nos últimos dez anos. Em fevereiro de 2023, por exemplo, fortes chuvas afetaram o litoral de São Paulo, como São Sebastião, Gurujá e Betioga. Apenas na semana seguinte à tragédia, a Porto Seguro, uma das maiores seguradoras no ramo de automóveis no Brasil, registrou 2.600 assistências a veículos e 750 a passageiros nessas regiões, o que representa um aumento de oito vezes em relação à média usual do período ([Capital Reset, 2023](#)).

Em 2022, o setor agrícola, que desempenha papel fundamental no PIB do Brasil, foi afetado pelas chuvas em excesso e estiagem prolongada, gerando fortes perdas e impactando de forma direta o mercado segurador. Apenas no primeiro semestre deste mesmo ano, as resseguradoras tiveram prejuízo de 4,6 bilhões de reais com o seguro rural, o que representa

18 vezes o prejuízo do mesmo período do ano anterior.

Em maio de 2024, o Rio Grande do Sul foi severamente afetado pelas fortes chuvas, causando um dos maiores desastres climáticos de sua história. Segundo reportagem publicada pela CNN no dia 29 de maio de 2024 (CNN, 2024), até esta data, segundo a última atualização da Defesa Civil, 169 mortes foram confirmadas no estado e mais de 2,3 milhões de pessoas foram afetadas. Cientistas não descartam que as chuvas sejam reflexos do El Niño e, de forma indireta, das mudanças climáticas. Isso porque a atmosfera e os oceanos estão mais quentes, o que contribui para a formação das chuvas.

No dia 26 de maio de 2024, a CNSeg (Confederação Nacional das Seguradoras) afirmou que 23,4 mil sinistros referentes às perdas causadas pelas enchentes no Rio Grande do Sul já haviam sido avisados às seguradoras (CNSEG, 2024). Apenas os casos já avisados, resultariam em um montante de indenizações de R\$ 1,67 bilhão. Os seguros de automóvel lideram em montante de sinistros avisados, seguido dos seguros patrimonial, grandes riscos e agrícola. Outros segmentos também estão na lista, mas sua representatividade é baixa frente ao montante total de sinistros já avisados. Adicionalmente, sabe-se que ainda haverá aumento considerável nesses montantes, tendo em vista os sinistros que ainda não foram avisados às seguradoras.

Diante deste histórico e, principalmente, ao crescente número de eventos climáticos extremos no Brasil e no mundo, é possível afirmar que as mudanças climáticas se tornaram críticas para o setor de seguros, já que os prejuízos crescentes com perdas humanas e patrimoniais impõem um desafio sem precedentes para o cálculo de riscos, ameaçando a saúde financeira das seguradoras.

2.2. O mercado segurador

Segundo dados da (CNSeg, 2024), de janeiro a outubro de 2023 o mercado segurador brasileiro pagou quase R\$ 190 bilhões aos segurados, sendo que um dos maiores índices de arrecadação ficou por conta de dois ramos do grupo de seguros Patrimonial. Neste período, um dos produtos que teve o maior avanço percentual no retorno aos segurados foi o Pecuário, com 51,6% e pagando R\$ 703,6 milhões em indenizações. Neste sentido, diante da constante evolução do mercado segurador no Brasil, tanto em relação ao montante de indenizações pagas quanto no aumento dos montantes arrecadados em prêmios, e com o avanço das mudanças climáticas, surge a preocupação em torno de seus efeitos e consequências sobre os diferentes grupos/ramos de seguros.

Conforme discutido na seção anterior, a materialização dos riscos devido a eventos climáticos extremos pode ocorrer em variados tipos de seguros e coberturas, como no grupo Automóvel, Patrimonial e Rural, por exemplo. Ainda, pode haver grupos de seguros para os

quais a materialização do risco pode ocorrer por meio de efeitos ainda não experienciados ou identificados e, por isso, nunca mensurados. Abaixo, alguns exemplos de riscos por cobertura, nos seguros de danos, são trazidos (Pricewaterhouse&Coopers, 2021), segregados pela classificação do risco: de transição ou físico.

① Coverage Type	Workers' Compensation	Commercial Property / Homeowners	D&O	General / Products Liability	Auto liability	Others
② Transition Risk	Medium Workers transition from jobs with credible loss history to newer technology where claims development trends are not yet known	Low Technologies required to meet new environmental building regulations may fail, leading to increased business interruptions	High Climate-related litigation being brought against insureds requiring unexpected levels of claim and defense costs	Medium Increasing litigation against heavy polluters for their contributions to climate change creates latent claim risks	Low Greater adoption of electric vehicles could lead to underpricing/higher claims ratios due to limited historical data on repair costs	Unknown Transition risks may continue to emerge from unexpected sources as changes are made to move towards a low carbon economy
③ Physical Risk	Medium Heatwaves leading to heat stress of more workers, particularly in the agricultural, construction, and manufacturing fields	High Increased frequency and severity of claims related to damage to buildings, storefronts, etc from severe weather events	Low N/A	Medium Coverages such as contractors' liability could see rise in weather-related damages claims	Medium Increased personal auto comprehensive coverage claim costs due to severe weather	Unknown Physical risks may result in downstream effects not currently felt or identified

Figura 6 – Exemplos de exposição a riscos climáticos por cobertura - seguros de danos

Fonte: Apresentação feita pela empresa PwC (Pricewaterhouse&Coopers, 2021)

Ainda que o foco deste trabalho seja abordar os riscos físicos no âmbito dos riscos climáticos, é fundamental diferenciar entre riscos de transição e riscos físicos, pois cada um possui implicações distintas para empresas, governos e sociedades:

1. Riscos de Transição: Referem-se às incertezas e impactos econômicos, legais, tecnológicos e de mercado associados à transição para uma economia de baixo carbono. Esses riscos surgem das mudanças nas políticas, regulamentações e preferências de mercado que buscam mitigar as mudanças climáticas. Por exemplo, a implementação de novas regulamentações ambientais pode impactar a viabilidade econômica de certas atividades seguradas, exigindo ajustes nas apólices de seguro.
2. Riscos Físicos: Referem-se aos impactos diretos e indiretos das mudanças climáticas nos sistemas naturais e humanos. Isso inclui eventos climáticos extremos, como tempestades, inundações, secas e ondas de calor, que podem causar danos substanciais a propriedades e infraestruturas. A gestão desses riscos requer uma análise detalhada das tendências climáticas e a adaptação das práticas de seguro para garantir a resiliência financeira das seguradoras.

Seguro Rural

Conforme sitio eletrônico da SUSEP, “o seguro rural é um dos mais importantes instrumentos de política agrícola, por permitir ao produtor proteger-se contra perdas decorrentes

principalmente de fenômenos climáticos adversos” (SUSEP, 2024). Com isso, o seguro rural tem como objetivo principal oferecer coberturas que não atendam somente ao produtor e à sua produção, mas também, que atendam à geração de garantias a seus financiadores, investidores e todos interessados na maior diluição dos riscos. As coberturas não se limitam apenas à atividade agrícola: a atividade pecuária, o patrimônio do produtor rural, os produtos, o crédito para a sua comercialização e o seguro de vida dos produtores também são coberturas oferecidas por esse tipo de seguro.

Conforme informações divulgadas pela CNSeg (CNSEG, 2023), o seguro agrícola, uma das modalidades do seguro rural, teve crescimento de, aproximadamente, 26.463% de 2005 a 2022, saindo de uma arrecadação de R\$ 23,8 milhões para R\$ 6,3 bilhões. Esse crescimento foi potencializado pelo Programa de Subvenção ao Prêmio do Seguro Rural (PSR), que tem como objetivo principal facilitar o acesso do produtor rural ao seguro. Neste sentido, o governo assume parte do prêmio, reduzindo o custo para o produtor rural.

O avanço do seguro rural nos últimos 20 anos foi acompanhado pelo avanço, também, no montante de indenizações pagas. Em 2021 e 2022, segundo dados da CNSeg e da FenSeg (Federação Nacional de Seguros Gerais), foram R\$ 11,1 bilhões em prêmios ganhos acompanhados de R\$ 14,2 bilhões em sinistros pagos (Valor Econômico, 2023). As secas, mas também o excesso de chuva no país, impactaram negativamente as safras desses anos, levando a altos índices de sinistralidade das principais seguradoras e resseguradoras do país.

Seguro Patrimonial

Outra modalidade de seguro que se mostra frágil quando se fala de mudanças climáticas é o compreensivo residencial, do grupo patrimonial. Este é destinado a residências individuais, casas e apartamentos, garantindo cobertura para a edificação e, de forma facultativa, para o seu conteúdo. Conforme informações da SUSEP (SUSEP, 2022), a cobertura mais comum é contra incêndio, queda de raios e explosão, podendo, ainda, serem oferecidas coberturas que indenizam os danos causados por alagamento, queimadas em zona rural, vendaval, impacto de veículos, queda de aeronave, danos elétricos, dentre outras. Quando se fala desta modalidade de seguro, as mudanças climáticas podem significar um aumento na frequência e severidade de sinistros relacionados a perdas causadas por eventos climáticos extremos.

Seguro Automóvel

Na modalidade de seguro compreensivo, do grupo automóvel, garante-se a cobertura para submersão parcial ou total do veículo em água doce proveniente de enchentes ou inundações, garantindo que os seguros de automóvel não fujam dos impactos das mudanças climáticas. Exemplo disso são as fortes chuvas que atingiram o litoral de São Paulo em feve-

reiro de 2023 e que levaram a 6.500 veículos encalhados na lama que se formou nas cidades afetadas. Conforme informações publicadas pela CNN no dia 23 de fevereiro de 2023 (CNN, 2023), a FenSeg informou que, no período da tragédia, a demanda nas seguradoras aumentou oito vezes em relação à média do período.

No entanto, não são apenas os seguros de danos afetados pela materialização dos riscos decorrentes das mudanças climáticas: os de vida também. Eventos climáticos extremos, como furacões, inundações, ondas de calor e incêndios florestais, podem causar um aumento imediato na mortalidade. Essas catástrofes resultam em um número elevado de fatalidades em um curto período de tempo, o que pode levar a um aumento substancial nas reivindicações de seguros de vida. As seguradoras precisam estar preparadas para lidar com picos repentinos na quantidade de sinistros, o que pode desafiar suas reservas financeiras e a capacidade de resposta.

As mudanças climáticas também têm efeitos de longo prazo na saúde pública, que podem influenciar os seguros de vida. Alguns desses efeitos incluem:

- **Doenças Respiratórias e Cardiovasculares:** O aumento da poluição do ar e a maior frequência de ondas de calor podem exacerbar condições respiratórias e cardiovasculares, levando a um aumento na mortalidade relacionada a essas doenças.
- **Doenças Infecciosas:** Mudanças nos padrões climáticos podem alterar a distribuição de vetores de doenças, como mosquitos, aumentando a incidência de doenças como malária, dengue e Zika. Isso pode resultar em um aumento nas taxas de mortalidade em áreas afetadas.
- **Segurança Alimentar e Nutricional:** Mudanças no clima podem impactar a produção agrícola, levando a crises de segurança alimentar e nutricional. A desnutrição e a insegurança alimentar têm consequências graves para a saúde, especialmente entre populações vulneráveis, como crianças e idosos, aumentando o risco de morte prematura.

Populações vulneráveis, como idosos, crianças e pessoas com condições médicas pre-existent, são desproporcionalmente afetadas pelas mudanças climáticas. As seguradoras de vida precisam considerar esses fatores ao avaliar riscos e precificar apólices. Em áreas propensas a desastres naturais, pode ser necessário ajustar as coberturas e os prêmios para refletir o risco aumentado.

Além disso, os eventos climáticos extremos podem forçar populações a migrar, resultando em mudanças demográficas que afetam o mercado de seguros de vida. As migrações podem levar a uma reconfiguração das bases de clientes das seguradoras, com populações deslocadas enfrentando diferentes riscos de saúde e mortalidade. As seguradoras precisam

adaptar suas estratégias para atender a essas populações em movimento e as novas condições de risco associadas.

Efeitos Ainda Não Experienciados ou Identificados

Além dos riscos já conhecidos, existem grupos de seguros para os quais a materialização do risco pode ocorrer por meio de efeitos ainda não experienciados ou identificados. Isso se deve ao fato de que as mudanças climáticas estão introduzindo novos padrões climáticos e fenômenos que ainda não foram totalmente compreendidos ou documentados. Por exemplo, o aumento da temperatura global pode levar a novas doenças de plantas e animais, mudanças na distribuição de pragas e até mesmo novas configurações de eventos climáticos que não têm precedentes históricos. Essas incertezas representam um desafio adicional para as seguradoras, que precisam se preparar para riscos emergentes e potencialmente catastróficos.

Com isso, em um cenário de mudanças climáticas e aumento na frequência e severidade dos eventos climáticos extremos, evidencia-se o desafio e a importância de análises preditivas cada vez mais assertivas como uma ferramenta essencial de gerenciamento de riscos das entidades seguradoras. Elas não apenas ajudam as seguradoras a avaliar riscos com maior precisão, mas também melhoram a gestão de riscos, a precificação, incentivam a inovação, garantem conformidade regulatória e promovem benefícios socioeconômicos mais amplos. Em última análise, a adoção e integração de análises preditivas robustas permitem que as seguradoras se adaptem de maneira eficaz às novas realidades climáticas, protegendo seus negócios e contribuindo para a resiliência das comunidades que servem.

2.3. Desafios das mudanças climáticas para o mercado segurador

A teoria básica do seguro de danos está fundamentada na teoria do risco coletivo. Esta baseia-se essencialmente na ideia de um grupo de pessoas contribuindo monetariamente para um único cofre comum. A cada ano, perdas ocorrerão a um grupo seletivo de indivíduos. Ao longo dos anos, esses indivíduos, por sua vez, têm o direito de reivindicar uma parte do dinheiro do cofre, enquanto continuam a contribuir regularmente. Este processo é contínuo e cíclico: o cofre representa a seguradora, as contribuições financeiras dos membros são os prêmios e o sinistro é o evento que causa a perda, resultando na necessidade de retirada do dinheiro do cofre para pagamento da indenização.

Este tipo de seguro funciona quando os riscos são aleatórios. Assim, o valor total das indenizações é calculado a partir de uma soma aleatória de variáveis aleatórias. Sendo X_i o

montante relativo ao i -ésimo sinistro ocorrido, N o número de sinistros para o mesmo período de análise e $N = n$, então $X_1, X_2, X_3, \dots, X_n$ são independentes e identicamente distribuídos. Com isso, tem-se que:

$$E(S_{col}) = E\left(\sum_{i=1}^N X_i\right), \quad (2.1)$$

em que S_{col} consiste no montante agregado relativo aos sinistros ocorridos no ano.

Dessa forma, o modelo de risco coletivo pressupõe que, embora cada indivíduo possa enfrentar riscos imprevisíveis e potencialmente catastróficos, a agregação dos riscos em um grupo permite uma distribuição mais gerenciável e previsível das perdas. O equilíbrio é crucial para garantir que todos os membros do grupo estejam protegidos contra perdas financeiras significativas, enquanto a seguradora mantém a solvência necessária para cumprir suas obrigações contratuais.

Assim, a teoria do risco coletivo implica na necessidade de manter a solvência da seguradora, ou seja, sua capacidade de pagar todas as reivindicações válidas. Isso é feito por meio da diversificação de seus portfólios de risco, por exemplo, mas também de adequadas reservas de capital, garantindo que possa absorver os choques financeiros decorrentes de grandes sinistros. Esses montantes representam o cofre mencionado anteriormente e funcionam como a espinha dorsal que assegura às seguradoras a capacidade de honrar com as suas obrigações com os segurados. Assim, reservas adequadas são essenciais para preservar a estabilidade financeira e solvência das entidades, permitindo-lhes absorver perdas inesperadas ou variações no padrão de ocorrência dos sinistros. Em última análise, um passivo bem dimensionado contribui para a manutenção da solvência das seguradoras e para o cumprimento de seus compromissos perante os segurados, assegurando a sua viabilidade a longo prazo.

Sob a ótica da IFRS 4 - Contratos de Seguro (IASB, 2004), emitido pelo IASB (*International Accounting Standards Board*), essas quantias de capital são representadas pelas provisões técnicas atuariais, como PPNG (Provisão de Prêmios Não Ganhos), IBNR (Provisão de Sinistros Ocorridos Mas Não Avisados), PSL (Provisão de Sinistros a Liquidar), PDR (Provisão de Despesas Relacionadas), dentre outras, cada uma destinada a um fim. Por exemplo, a Provisão de Sinistros Ocorridos Mas Não Avisados é destinada à cobertura de sinistros já ocorridos, mas que a entidade seguradora ainda não tem conhecimento. Com a divulgação da IFRS 17 - Contratos de Seguros (IASB, 2017), substituindo a IFRS 4, deixa de existir a figura das provisões técnicas atuariais trazidas pela IFRS 4 e as Companhias já sujeitas a esta nova norma tiveram que se adaptar para adotar os novos princípios de reconhecimento, mensuração, apresentação e divulgação dos contratos de seguro que estão em seu escopo.

Vale ressaltar que, ainda que a Superintendência de Seguros Privados (SUSEP), órgão regulador do mercado segurador no Brasil, ainda não tenha se pronunciado sobre a adoção

da IFRS 17 e continue seguindo a IFRS 4, a Comissão de Valores Mobiliários (CVM) já adotou a nova norma. Isso implica que as seguradoras de capital aberto estão obrigadas a se adequar a ela. Além disso, as empresas cuja matriz está situada na Europa, em que a IFRS 17 já está em vigor, também precisam se adequar para consolidar seus balanços. Portanto, embora algumas seguradoras ainda publiquem suas demonstrações financeiras em IFRS 4, sabe-se que é uma questão de tempo até que a SUSEP adote a IFRS 17. Assim, mais cedo ou mais tarde, a implementação dessa nova norma se tornará um desafio não apenas para um grupo restrito de empresas, mas para todo o mercado segurador brasileiro.

Os contratos de seguro, em geral, acarretam em fluxos de caixa que variam substancialmente durante um longo período. Assim, a fim de fornecer informações úteis a respeito destes contratos, a IFRS 17 traz a ideia de fluxo de caixa para a mensuração dos contratos de seguro, em que, o valor contábil de um grupo de contratos de seguro no fim de cada período contábil é a soma do (i) passivo para cobertura remanescente (*LRC - Liability for Remaining Coverage*); e (ii) passivo para sinistros ocorridos (*LIC - Liability for Incurred Claims*). A LRC deve compreender os fluxos de caixa de cumprimento relativos a cobertura de seguro futuras alocados ao grupo nessa data, aplicando-se os itens 33 a 37 e B36 a B92 da norma. Ainda, deve compreender a margem contratual de seguro do grupo nessa data, mensurada aplicando-se os itens 43 a 46. A LIC, em contrapartida, deve compreender os fluxos de caixa de cumprimento relativos a coberturas de seguro passadas, mensurados aplicando-se os itens 33 a 37 e B36 a B92 da norma.

De acordo com os parágrafos B37 a B40, referenciados acima, sobre a estimativa dos fluxos de caixa futuros:

- B37. "O objetivo de estimar os fluxos de caixa futuros é determinar o valor esperado, ou média ponderada por probabilidade, do conjunto completo de resultados possíveis, considerando todas as informações razoáveis e sustentáveis disponíveis na data do relatório sem custo ou esforço excessivo. Informações razoáveis e sustentáveis disponíveis na data do relatório sem custo ou esforço excessivo incluem informações sobre eventos passados e condições atuais, e previsões de condições futuras (ver item B41). Informações disponíveis de sistemas de informações próprios da entidade são consideradas disponíveis sem custo ou esforço excessivo."
- B38. "O ponto de partida para a estimativa dos fluxos de caixa é a variedade de cenários que reflete o conjunto completo de resultados possíveis. Cada cenário especifica o valor e a época dos fluxos de caixa para um determinado resultado, e a probabilidade estimada desse resultado. Os fluxos de caixa de cada cenário são descontados e ponderados pela probabilidade estimada desse resultado para obter o valor presente esperado. Consequentemente, o objetivo não é desenvolver o resultado mais provável, ou o resultado mais provável que improvável, de fluxos de caixa futuros."

- B39. "Ao considerar o conjunto completo de resultados possíveis, o objetivo é incorporar todas as informações razoáveis e sustentáveis disponíveis sem custo ou esforço excessivo de forma imparcial, em vez de identificar cada cenário possível. Na prática, desenvolver cenários explícitos é desnecessário se a estimativa resultante for consistente com o objetivo de mensuração de considerar todas as informações razoáveis e sustentáveis disponíveis sem custo ou esforço excessivo ao determinar a média. Por exemplo, se a entidade estima que a distribuição de probabilidade de resultados seja amplamente consistente com a distribuição de probabilidade que pode ser descrita completamente com pequeno número de parâmetros, será suficiente estimar o menor número de parâmetros. Similarmente, em alguns casos, uma modelagem relativamente simples pode dar uma resposta dentro de faixa aceitável de precisão, sem a necessidade de muitas simulações detalhadas. Contudo, em alguns casos, os fluxos de caixa podem ser orientados por fatores subjacentes complexos e podem responder de forma não linear a mudanças nas condições econômicas. Isso pode acontecer se, por exemplo, os fluxos de caixa refletirem uma série de opções inter-relacionadas que são implícitas ou explícitas. Nesses casos, é provável que uma modelagem estocástica mais sofisticada seja necessária para satisfazer o objetivo da mensuração."
- B40. "Os cenários desenvolvidos devem incluir estimativas imparciais da probabilidade de perdas catastróficas de acordo com contratos existentes. Esses cenários excluem possíveis sinistros de acordo com possíveis contratos futuros."

Dessa forma, as entidades devem estimar as probabilidades e valores de pagamentos futuros de acordo com seus contratos existentes, o que pode ser feito com base em dados históricos da experiência da própria entidade, por exemplo, quando acredita-se que os padrões históricos observados se manterão no futuro. No entanto, quando há indicações de que tendências históricas não continuarão, que novas tendências surgirão, ou que mudanças podem afetar os fluxos de caixa dos contratos de seguro existentes, devem ser feitos ajustes para refletir as condições atuais.

Tem-se a necessidade, portanto, de não somente analisar a sinistralidade e padrões de ocorrência e pagamento dos sinistros e despesas com sinistros históricos, por exemplo, mas também analisar as condições atuais e expectativas/previsões futuras. Assim, em um cenário no qual as mudanças climáticas são protagonistas e que existe uma limitação de dados históricos que reflitam a nova realidade, como mensurar os fluxos de caixa de cumprimento de um grupo de contratos de seguro exposto aos efeitos das mudanças climáticas?

A imprevisibilidade e a alta variabilidade dos eventos climáticos extremos tornam mais desafiador para as seguradoras preverem e modelarem riscos adequadamente. Com a intensificação dos eventos climáticos extremos, as seguradoras precisam ajustar seus modelos atuariais para refletir a nova realidade, incorporando dados mais recentes e modelos de

previsão climática avançados. Assim, surge a necessidade do mercado segurador se aprofundar em abordagens de modelagem de eventos climáticos extremos, já bastante explorado por cientistas climáticos, com o objetivo de incorporá-las às mensurações dos riscos dos grupos de contratos de seguro.

As regulamentações financeiras internacionais, como a IFRS 17, exigem que as seguradoras tenham uma visão clara e precisa de seus riscos futuros. Neste sentido, as análises preditivas fornecem a transparência necessária para cumprir os requisitos de relatórios financeiros e de solvência, mostrando como os riscos climáticos são gerenciados. Além disso, ajudam a alinhar melhor a gestão de ativos e passivos, garantindo que as seguradoras mantenham uma posição financeira sólida para enfrentar os desafios impostos pelos eventos climáticos extremos.

3. Abordagens para a modelagem de eventos climáticos extremos

A predição de eventos climáticos extremos é uma área crítica da ciência climática, que busca entender e antecipar a ocorrência de fenômenos como ondas de calor, tempestades intensas, furacões, secas e inundações. O seu trabalho é fundamental para fornecer informações precisas e oportunas, que são essenciais para a preparação e mitigação dos impactos desses eventos.

O estudo de dados históricos ajuda os cientistas a identificar tendências e variações climáticas ao longo do tempo, fornecendo uma base para prever eventos extremos. Assim, modelos estatísticos, como abordados por (BERLINER; KIM, 2008), (BRIGGS, 2008), (CHAND; WALSH, 2011), (ELSNER; BOSSAK, 2001), (CHU; ZHAO, 2011) e (HO; CHU, 2009), são utilizados para identificar padrões nos dados históricos e prever eventos futuros.

Com o desafio trazido pela IFRS 17 de projeção de fluxos de caixa futuros relacionados aos contratos de seguro, e diante de um cenário de eventos climáticos extremos mais frequentes e severos, surge a necessidade das seguradoras ajustarem seus modelos e premissas atuariais para refletir a nova realidade, incorporando dados mais recentes e modelos de previsão climática avançados. A IFRS 17 exige que as seguradoras avaliem com precisão os passivos de seguros, o que inclui a consideração de riscos emergentes como os eventos climáticos extremos.

Técnicas estatísticas, como a análise de séries temporais e de regressão linear, são amplamente utilizadas para a modelagem e predição de eventos climáticos extremos. As séries temporais analisam dados sequenciais ao longo do tempo para identificar tendências e padrões, enquanto a regressão linear pode ser usada para modelar a relação entre variáveis climáticas e a ocorrência de eventos extremos. Ainda, quando combinadas com os modelos bayesianos, essas técnicas oferecem uma abordagem poderosa e flexível para a inferência estatística.

Por exemplo, (DING et al., 2019) utilizam os conceitos de séries temporais para a predição de eventos climáticos extremos, propondo uma nova função de perda para a detecção da ocorrência de eventos extremos no futuro, utilizando modelos bayesianos. Além disso, (LU; CHU; LIN, 2010), (JAGGER; ELSNER, 2010) e (CHU; ZHAO, 2007) aplicam modelos de regressão linear de Poisson utilizando métodos bayesianos para a previsão de ciclones

tropicais e furacões sazonais.

3.1. Modelagem de eventos climáticos extremos por meio da análise de séries temporais

Uma série temporal pode ser resumida a um conjunto de observações sobre a mesma variável de interesse ordenadas no tempo. Assim, esta tem como objetivo identificar padrões não aleatórios na série temporal de forma a possibilitar previsões futuras. A análise de séries temporais envolve métodos para analisar esses dados e extrair informações significativas sobre as tendências, padrões sazonais e relações temporais entre os dados. Essa técnica é amplamente utilizada em diversas áreas, como finanças, meteorologia, economia, controle de inventário, ciência de dados, entre outras.

Os modelos ARIMA(p,d,q), abreviação para *Autoregressive Integrated Moving Average* são exemplos de modelos estatísticos lineares para a análise de séries temporais. Estes têm como premissa que a série temporal é gerada por um processo estocástico, sendo que p consiste no número de parâmetros auto-regressivos, d no número de diferenciações para que a série se torne estacionária e q no número de parâmetros de médias móveis. Um exemplo de previsão utilizando um modelo ARIMA(1,1,2) pode ser observado abaixo:

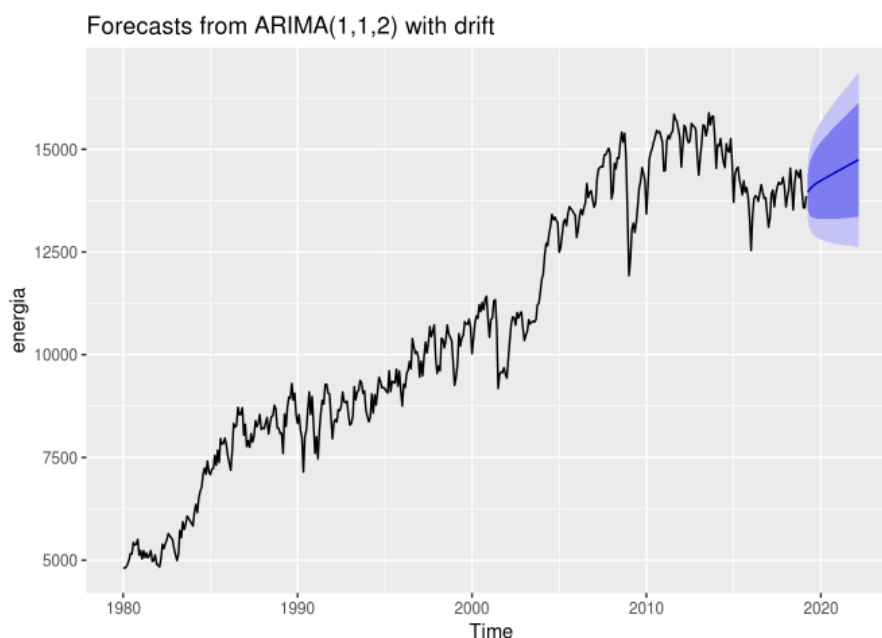


Figura 7 – Previsão de um modelo ARIMA

Fonte: Retirado do curso de Séries Temporais de Sillas Gonzaga ([Sillas Teixeira Gonzaga, 2019](#))

Casos particulares deste modelo são aqueles para séries temporais estacionárias, por

exemplo, ou seja, $d = 0$: ARMA(p, q), AR(p) e MA(q). Estes três possuem a limitação de assumirem a existência de uma relação linear entre os elementos da sequência e baseiam-se na hipótese de estacionariedade da série, ou seja, de que as suas propriedades estatísticas, como média e o desvio padrão das observações medidas, não variam ao longo do tempo.

Outra extensão dos modelos ARIMA são os SARIMA $(p, d, q)(P, D, Q)_s$ (*Seasonal Autoregressive Integrated Moving Average*), incorporando componentes sazonais. Os parâmetros p , d e q são os mesmos definidos para os modelos ARIMA. Além disso, P consiste no número de parâmetros auto-regressivos sazonais (SAR), D no número de diferenciações para que a série se torne sazonal, Q no número de parâmetros de médias móveis sazonais (SMA) e s no período da sazonalidade. Esses modelos são amplamente utilizados para prever séries temporais que exibem padrões sazonais, ou seja, padrões que se repetem em intervalos regulares, como meses, trimestres ou anos.




Figura 8 – Previsão de um modelo SARIMA

Fonte: Retirado do curso de Séries Temporais de Sillas Gonzaga ([Sillas Teixeira Gonzaga, 2019](#))

Existem várias metodologias para a previsão de séries temporais (Modelos Autoregressivos - AR, Modelos de Média Móvel - MA, Modelos ARIMA, Modelos SARIMA, Modelos de Suavização Exponencial, Modelos de Redes Neurais e *Deep Learning*), cada uma com suas características e aplicabilidades. A escolha da metodologia de análise depende da natureza dos dados e do objetivo específico da previsão. Assim, previsões por meio de séries temporais são uma ferramenta poderosa para analisar dados cronológicos e fazer previsões informadas sobre o futuro. A escolha da metodologia adequada depende da natureza dos dados e do contexto da aplicação.

Apesar da análise de séries temporais com o objetivo de predição de eventos futuros não ser um assunto novo na estatística, quando aplicada a séries temporais reais com a existência de eventos extremos, que tem por característica principal a sua raridade e aleatoriedade, observa-se uma performance relativamente baixa dos métodos usuais de *deep learning*. Isso porque, um de seus desafios é requerer grandes quantidades de dados para treinamento eficaz, e os eventos extremos, em contrapartida, possuem como característica a sua baixa frequência.

Deep learning é um subcampo do aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas para modelar e interpretar dados complexos. Na análise de séries temporais, este é utilizado para prever valores futuros, identificar padrões e anomalias, e extrair características importantes dos dados temporais. As suas técnicas são aplicadas na análise de séries temporais para capturar relações complexas e dinâmicas nos dados. Alguns exemplos das arquiteturas mais comuns utilizadas são: Redes Neurais Recorrentes (RNNs), Redes Convolucionais (CNNs) e Redes de Memória de Longo Prazo e Memória Curta (LSTM).

(DING et al., 2019) explicam o porquê de métodos tradicionais de *deep learning*, como as Redes Neurais Profundas, não performarem tão bem quando aplicados a questões envolvendo eventos extremos: como o bom desempenho do estimador de densidade não paramétrico de Kernel depende de um mínimo suficiente de amostras, a sua performance tende a cair à medida que caminhamos para a cauda dos dados, em que o número de observações pode ser consideravelmente limitado. Isso acontece a partir do momento que a faixa de valores extremos geralmente é extensa, o que faz com que poucas amostras contenham esses valores. Com isso, neste contexto, métodos como as Redes Neurais Profundas tendem a modelos com baixo ajuste.

Eventos extremos em uma série temporal são comumente observáveis por meio de valores muito baixos ou muito altos, raros e irregulares. Historicamente, apesar de algumas vezes se observar um baixo ajuste de modelos no momento na fase de teste, na média, a performance destes se mostra tolerável e, por isso, ainda assim são utilizados. No entanto, quando se fala em eventos climáticos extremos e crises financeiras, por exemplo, modelos que possam capturar eventos extremos e fazer predições razoáveis se tornam essenciais.

Neste contexto, (DING et al., 2019), propuseram a imposição de uma distribuição aproximada na cauda das observações e desenvolveram uma nova função de perda denominada *Extreme Value Loss* (EVL), dada pela equação abaixo. Os autores demonstraram que a EVL possui papel fundamental no processo de predição e validaram a efetividade da EVL nas predições de eventos futuros.

$$EVL(u_t) = -\beta_0 \left[1 - \frac{u_t}{\gamma} \right]^\gamma (1 - v_t) \log(1 - u_t), \quad (3.1)$$

em que $\beta_0 = P(v_t = 0)$ consiste na proporção de eventos normais no conjunto de dados e $P(v_t = 1)$ é a proporção de eventos à direita no conjunto de dados. Além disso, γ consiste no hiper-parâmetro, que é a aproximação do indexador de valor extremo (*extreme value index*).

Além disso, (DING et al., 2019) propuseram o uso de uma rede de memória para armazenar e recordar características dos eventos extremos de dados históricos aprimorando ainda mais a capacidade preditiva do modelo. Quando combinadas, essas duas proposições são capazes de impor informações prévias sobre a parte extrema das observações para Redes Neurais Profundas e, conseqüentemente, melhorar significativamente o desempenho das previsões de séries temporais envolvendo valores extremos.

O método proposto é validado por meio de extensos experimentos em dados sintéticos e conjuntos de dados real, como dados do mercado de ações e registros climáticos. Os resultados demonstram a eficácia do *framework* em capturar eventos extremos, proporcionando uma solução robusta para tarefas de previsão de séries temporais em que esses eventos são relevantes.

Assim, o trabalho faz contribuições significativas ao abordar as limitações dos modelos de *deep learning* existentes em lidar com eventos extremos e ao propor um *framework* especializado que aprimora a precisão das previsões em cenários em que esses eventos são críticos.

3.2. Modelos de regressão bayesianos para a modelagem de eventos climáticos extremos

Modelos de regressão são amplamente utilizados no âmbito das ciências sociais, biológicas e econômicas, além de engenharia e administração. A análise de regressão consiste, basicamente, em um método estatístico que utiliza a relação entre uma ou mais variáveis com o objetivo de predição da variável resposta. Por exemplo, o tempo que um paciente de uma cirurgia permanece no hospital pode ser estimado utilizando a relação entre o tempo de permanência no hospital e a severidade da cirurgia. Ou ainda, o nível de pico de hormônio de crescimento no plasma de crianças pode ser estimado por meio da relação dessa variável resposta e as variáveis explicativas idade, gênero, altura, peso, dentre outras.

Os modelos de regressão, sejam eles lineares ou não lineares, pertencem à família de modelos conhecida como Modelos Lineares Generalizados (*Generalized Linear Models* - GLM). Esta foi introduzida inicialmente por Nelder e Wedderburn (NELDER; R. W. M. Wedderburn, 1972), e abrange modelos de regressão lineares cujos erros são normalmente distribuídos, além de modelos de regressão não lineares, como o exponencial, logístico e

Poisson.

Dada a variável resposta Y , o modelo linear generalizado é dado por:

$$f(y) = c(y, \phi) \exp\left(\frac{y\theta - a(\theta)}{\phi}\right), \quad g(\mu) = x' \beta. \quad (3.2)$$

A equação para $f(y)$ em 3.2 determina que a distribuição da variável resposta pertence à família exponencial. Já a segunda equação determina que a transformação da média $g(\mu)$ é linearmente relacionada à variável explicativa x .

Dessa forma, os modelos lineares generalizados são descritos conforme mostrado abaixo.

- Y_1, Y_2, \dots, Y_n consistem em n variáveis resposta que seguem uma distribuição de probabilidade pertencente à família exponencial com esperança $E\{Y_i\} = \mu_i$.
- Um preditor linear baseado nas variáveis preditoras $X_{i1}, X_{i2}, \dots, X_{i,p-1}$ é utilizado e dado por $X_i' \beta$:

$$X_i' \beta = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{p-1} X_{i,p-1}$$

- A função de ligação g transforma a esperança da variável resposta $E\{Y_i\} = \mu_i$ no preditor linear:

$$X_i' \beta = g(\mu_i)$$

Dessa forma, a escolha de $g(\mu)$ determina como a média se relaciona com as variáveis explicativas x .

Ainda que os modelos lineares generalizados possam ter variâncias σ_i^2 não constantes para a variável resposta Y_i , a variância σ_i^2 deve ser uma função das variáveis preditoras por meio da esperança da variável resposta μ_i .

A regressão linear utilizando inferência bayesiana oferece uma abordagem robusta e flexível para modelar relações entre variáveis. Ao combinar a modelagem estatística com a atualização de crenças por meio do Teorema de Bayes, essa técnica fornece uma forma poderosa de realizar inferências e previsões, especialmente em situações onde a incorporação de conhecimento prévio e a quantificação da incerteza são cruciais.

Modelos bayesianos consistem em uma abordagem estatística baseada no teorema de Bayes, que permite a atualização das probabilidades à medida que novas evidências ou dados são observados. Os componentes desses modelos são: (i) distribuição *a priori*; (ii) verossimilhança; e (iii) distribuição *a posteriori*. A primeira representa o conhecimento inicial sobre

os parâmetros antes da observação dos dados, podendo ser com base em dados históricos ou suposições teóricas, por exemplo. A segunda descreve como os dados são gerados, dado um conjunto de parâmetros e, assim, captura a relação entre os parâmetros do modelo e os dados observados. Já a terceira, resulta da combinação da primeira e da segunda, representando o conhecimento atualizado sobre os parâmetros após a observação dos dados. Esta é calculada utilizando o Teorema de Bayes.

O Teorema de Bayes é expresso por meio da equação abaixo:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}, \quad (3.3)$$

em que A e B são eventos e $P(B) \neq 0$. Adicionalmente, $P(A)$ e $P(B)$ são probabilidades *a priori* de A e B , respectivamente, e $P(A|B)$ é a probabilidade *a posteriori* de A condicionada a B .

Os modelos bayesianos fornecem uma abordagem poderosa e flexível para a inferência estatística, permitindo a incorporação de conhecimento prévio e a atualização contínua das estimativas à medida que novos dados são observados. Assim, facilita a modelagem precisa em contextos onde a incerteza é alta e os dados são escassos, proporcionando *insights* valiosos e adaptáveis em tempo real.

No contexto da regressão linear, isso significa atualizar nossas crenças sobre os coeficientes de regressão à medida que novos dados são observados. Ou seja, após observar os dados, atualizamos essa distribuição *a priori* para obter a distribuição *a posteriori*.

Vantagens da Inferência Bayesiana:

- **Incorporar Conhecimento Prévio:** A abordagem bayesiana permite a incorporação de conhecimento prévio através da distribuição *a priori*. Isso é especialmente útil em situações onde temos informações anteriores ou expertise sobre o problema.
- **Estimativas Probabilísticas:** Em vez de fornecer um único ponto estimado para os coeficientes, a inferência bayesiana fornece distribuições de probabilidade, permitindo uma compreensão mais rica da incerteza associada às estimativas.
- **Flexibilidade:** A abordagem bayesiana pode ser estendida de forma natural para modelos mais complexos e não lineares, o que pode ser mais difícil de alcançar com métodos frequentistas tradicionais.
- **Predições:** A inferência bayesiana facilita a geração de predições probabilísticas, fornecendo intervalos de confiança diretamente a partir da distribuição *a posteriori*.

Usualmente na estatística, quando se fala em modelagem, alguns artifícios estatísticos são utilizados na escolha de um único modelo dentre uma gama de opções. Inicialmente, de k variáveis, é natural que algumas destas não contribuam para o modelo e, com isso, já se reduza a quantidade de modelos. Posteriormente, dentre algumas opções de modelos, é feita a seleção daquele que mais se ajusta aos dados e os parâmetros do modelo são determinados para, posteriormente, este ser utilizado para predição e inferência sobre os dados. A cada $p - 1$ possíveis variáveis explicativas de um modelo, existem 2^{p-1} modelos que podem ser construídos. Isso porque cada variável pode ser incluída ou não no modelo, partindo de um modelo com nenhuma variável explicativa X , ou seja, $Y_i = \beta_0 + \epsilon_i$.

A fim de otimizar o tempo gasto na seleção das variáveis a serem consideradas em um modelo, algoritmos de seleção automática foram desenvolvidos, em que algumas possibilidades são identificadas de acordo com determinados critérios, sem a necessidade de ajuste de todos os possíveis modelos de regressão (NELDER; R. W. M. Wedderburn, 1972).

- Método *Forward*

O método *forward* de seleção de variáveis, basicamente, consiste em partir de um modelo sem nenhuma variável X explicativa e a cada passo adicionar ou excluir uma variável X no modelo.

- Método *Backward*

Ao contrário do método *forward* de seleção de variáveis, o método *backward* parte de um modelo com todas as p possíveis variáveis explicativas X . Com isso, esse método identifica a variável que apresenta o maior p -valor e, caso seja maior que um limite pré definido, a variável X é retirada do modelo. Em seguida, o modelo com as $p - 2$ possíveis variáveis é ajustado e a próxima variável X a ser excluída do modelo é identificada. Esse processo é seguido até que não haja mais nenhuma variável X a ser retirada do modelo.

- Método *Stepwise*

O método *stepwise* de seleção de variáveis se assemelha ao método *forward*, mas ao contrário deste, permite que uma variável já incluída no modelo seja posteriormente excluída. O critério para a inclusão ou exclusão de uma variável é baseada na redução da soma de quadrados do erro, coeficiente de correlação parcial, estatística t ou estatística F .

Neste sentido, (LU; CHU; LIN, 2010) aplicaram um modelo linear generalizado de Poisson para predição do número de ciclones tropicais sazonais em Taiwan, utilizando o método *stepwise* na seleção das variáveis explicativas. O ciclone tropical consiste em um dos eventos climáticos mais devastadores uma vez que envolve diversos riscos: fortes chuvas,

ventos e inundações são alguns exemplos de eventos associados a um ciclone tropical. Com isso, tem-se a necessidade de modelos de predição o mais preciso possível.

Um processo de Poisson descreve a distribuição de probabilidade do número de ciclones tropicais. Assim, a probabilidade de ocorrência de c ciclones tropicais em uma unidade de tempo é dada por:

$$P(c|\lambda) = \exp(-\lambda) \frac{(\lambda)^c}{c!}, \quad (3.4)$$

em que $c = 0, 1, 2, \dots$ e $\lambda > 0$.

Dessa forma, a relação entre a variável resposta número de ciclones tropicais e as variáveis explicativas pode ser dada por meio de um modelo de regressão de Poisson, em que a taxa λ é tratada como uma variável aleatória que é condicionada às variáveis preditoras. Uma vez que λ é um número contínuo e o número de ciclones tropicais (c) é um número inteiro, entende-se que λ contém mais informação sobre c . Ainda, c é condicional a λ . Com isso, λ deve ser usado para prever o número de ciclones tropicais no lugar de c .

O modelo selecionado por (LU; CHU; LIN, 2010) possui três variáveis climáticas de grande escala como explicativas: vorticidade relativa a 850 hPa (Vor850), cisalhamento do vento vertical e pressão ao nível do mar sobre o Pacífico Norte ocidental e central do mês de maio antecedente. Além disso, a temporada de ciclones tropicais considerada é de junho a novembro e o período de dados utilizado para o desenvolvimento do modelo é de 1979 a 2007.

Os resultados do estudo demonstram que o modelo de regressão multivariada bayesiana proporciona previsões mais precisas e confiáveis da atividade de ciclones tropicais em comparação com métodos tradicionais. As previsões incluem a frequência esperada de ciclones e a intensidade potencial, oferecendo informações detalhadas que são vitais para a gestão de riscos e a tomada de decisões. Por outro lado, o modelo mostra viés negativo durante os anos com ciclones tropicais sucessivos e, neste sentido, os autores trazem a discussão a respeito da predição em tempo real e como o modelo é influenciado positivamente por esta prática.

Os métodos de seleção automática de modelos muitas vezes ignoram a incerteza inerente do processo de seleção de modelos. Dessa forma, o procedimento de BMA - *Bayesian Model Averaging* surge como uma alternativa na seleção do melhor modelo. Assim, em vez de se utilizar um único modelo para fazer previsões, utiliza-se todos os modelos, mas para cada um é atribuído um “peso”, sendo este com base na probabilidade dos dados terem vindo do respectivo modelo. Um modelo final, definido com base na média ponderada de todos os modelos é então utilizado para fazer previsões.

Neste contexto, (JAGGER; ELSNER, 2010) propuseram a aplicação deste método

na modelagem da quantidade de furacões sazonais nos Estados Unidos. Tendo em vista a base de dados e a variável de interesse, traduzida em número de eventos, é assumido que as observações seguem uma distribuição de Poisson com o parâmetro de taxa desconhecido. É assumido, também, que o logaritmo do parâmetro de taxa é uma combinação linear entre uma lista de variáveis fixas, mas desconhecidas. Como a variável preditora consiste no número de furacões em um ano, tem-se um modelo linear generalizado (GLM - *Generalized Linear Model*) e utiliza-se o método da máxima verossimilhança para a estimação dos parâmetros.

O modelo inicial, antes de qualquer seleção de variáveis, possui 24 variáveis explicativas - 6 meses e 4 variáveis climáticas por mês. Com isso, há 2^{24} possibilidades de modelos - mais de 16 milhões. Primeiramente, reduziu-se a quantidade de modelos para 3.600 (150 x 24) considerando apenas os 150 melhores modelos de cada tamanho, ou seja, com a mesma quantidade de variáveis. Posteriormente, reduziu-se ainda mais, para 432, fazendo a comparação dos valores de BIC de cada modelo com o menor BIC identificado entre os modelos, mantendo os modelos cuja diferença era menor que 20.

Os critérios de informação de Akaike (AIC) e Bayesiano de Schwarz (BIC) fornecem uma base para a seleção de um modelo dentre uma lista de vários. Esta seleção utilizando os critérios de informação foi desenvolvido com o objetivo de resumir as evidências fornecidas pelos dados a favor de um modelo. O critério BIC difere do Akaike apenas no fato do segundo termo depender do tamanho da amostra, sendo dado por:

$$BIC = -2\log(L) + p\log(n), \quad (3.5)$$

em que L é a verossimilhança, p é o número de parâmetros no modelo e n o tamanho amostral.

Ambos critérios penalizam a adição de parâmetros no modelo, sendo que o critério Bayesiano de Schwarz penaliza mais modelos mais complexos se comparado ao critério de Akaike. Cabe destacar que deve-se selecionar o modelo que apresenta o menor valor para esses critérios e, por isso, os autores fizeram a comparação do BIC de cada modelo com o menor BIC identificado entre os modelos.

Após a redução do número de modelos para 432, o método BMA foi aplicado por (JAGGER; ELSNER, 2010), atribuindo-se, primeiramente, um peso para cada modelo (por meio de sua probabilidade a posteriori) e, posteriormente, calculada a média dos modelos. Ou seja, cada modelo foi utilizado para prever a quantidade de furacões em um ano e a média das predições foi calculada, dando um peso maior às predições dos modelos com maior probabilidade a posteriori. Dessa forma, dentre os 432 modelos, não se escolheu o “melhor” modelo e, sim, a média ponderada de todos os modelos.

Os resultados apresentados no artigo mostram que o modelo consensual oferece pre-

visões mais precisas e confiáveis em comparação com qualquer modelo individual. Ao combinar as previsões de múltiplos modelos, o método reduz a incerteza e melhora a capacidade de prever a frequência e intensidade dos furacões durante a temporada. Dessa forma, os autores mostraram que o procedimento BMA é uma forma natural de incorporar no processo de predição modelos concorrentes, ao mesmo tempo que oferece uma abordagem mais racional para se obter um consenso para o processo de gerenciamento de riscos.

Com o objetivo de prever atividades de ciclones tropicais no Pacífico Norte durante a temporada de furacões (julho a setembro), (CHU; ZHAO, 2007) aplicaram um modelo de regressão linear generalizada de Poisson, configurado no *framework* bayesiano. A capacidade de prever com precisão a atividade de ciclones tropicais é crucial para minimizar os danos causados por esses eventos, permitindo a implementação de medidas preventivas e de resposta mais eficazes. A abordagem bayesiana proposta pelos autores representa um avanço significativo nessa área, destacando a importância de métodos estatísticos avançados na previsão climática.

Conforme discutido anteriormente, a fórmula básica bayesiana, assumindo um dado modelo, um vetor de parâmetros do modelo θ e dados de treino h , é dada por:

$$P(\theta|h) = \frac{P(h|\theta)P(\theta)}{\int P(h|\theta)P(\theta)d\theta} \propto P(h|\theta)P(\theta), \quad (3.6)$$

em que \propto significa “proporcional”. Assim, a fim de se fazer previsões, é necessária a distribuição a *posteriori*, sendo condicional aos dados observados h e fornece uma previsão para o observável desconhecido.

A derivação da distribuição a *posteriori* é complexa e, portanto, não será trazida em detalhes. No entanto, vale ressaltar que (CHU; ZHAO, 2007) utilizam o amostrador de Gibbs a fim de solucionar essa questão. Este é um método de amostragem estocástica utilizado em estatística e aprendizado de máquina, particularmente em inferência Bayesiana e modelos de mistura. É uma técnica de Monte Carlo via Cadeias de Markov (MCMC) que permite amostrar de distribuições de probabilidade complexas, especialmente quando estas distribuições não podem ser amostradas diretamente de maneira eficiente.

Assim, os autores utilizam um modelo de regressão por meio de uma abordagem bayesiana para integrar dados históricos e variáveis climáticas preditivas. Variáveis ambientais em larga escala disponíveis até maio e junho precedentes foram utilizadas. Especificamente, cinco variáveis preditoras foram consideradas: temperaturas da superfície do mar, pressões ao nível do mar, cisalhamento vertical do vento, vortacidade relativa e água precipitável.

Tendo em vista que a variação dos ciclones tropicais é aproximadamente independente de um ano para o outro, os autores aplicam um método de validação cruzada denominada LOOCV (“*Leave-One-Out Cross Validation*”). Assim, com dados de 38 anos de conta-

gem de ciclones tropicais, um ano-alvo é escolhido e um modelo é desenvolvido usando os dados dos 37 anos restantes como conjunto de treinamento. As observações dos preditores selecionados para o ano-alvo são então usadas como entradas para prever o ano ausente. Este processo é repetido sucessivamente até que todas as 38 previsões sejam feitas.

Os resultados do estudo indicam que o modelo de regressão bayesiana proporciona melhorias significativas na precisão das previsões de ciclones tropicais em comparação com métodos tradicionais. O modelo conseguiu capturar as variações sazonais e as tendências de longo prazo na atividade de ciclones, fornecendo informações valiosas para a gestão de riscos e a tomada de decisões.

4. Considerações Finais

Diante do cenário das mudanças climáticas, este trabalho aborda os desafios impostos pela crescente frequência e severidade de eventos climáticos extremos para o mercado segurador. Em específico, são apresentadas duas abordagens metodológicas para a predição desses eventos, com o objetivo de explorar as possibilidades que as entidades seguradoras possuem para a mensuração dos riscos futuros de um grupo de contratos de seguros sob a ótica da IFRS 17: a análise de séries temporais e os modelos bayesianos.

A análise de séries temporais, no contexto de eventos extremos, enfrenta a limitação de dados históricos, o que pode resultar na baixa performance dos modelos desenvolvidos. No entanto, (DING et al., 2019) propuseram a imposição de uma distribuição aproximada na cauda dos dados e de uma nova função de perda denominada EVL (*Extreme Value Loss*), combinada ao uso de uma rede de memória, para a predição de valores extremos. Por meio da aplicação dessas metodologias de forma combinada a dois conjuntos de dados, os autores conseguiram demonstrar a eficácia das suas proposições.

Os modelos de regressão de Poisson, aplicando os conceitos da inferência bayesiana, como os desenvolvidos por (LU; CHU; LIN, 2010), (JAGGER; ELSNER, 2010) e (CHU; ZHAO, 2007), oferecem uma abordagem valiosa, permitindo a incorporação de conhecimento prévio e a atualização contínua das informações à medida que novos dados são observados. Também por meio da aplicação a dados reais, os autores demonstraram a eficácia de suas proposições.

Sendo responsáveis pelo pagamento das indenizações quando seus segurados sofrem perdas causadas por condições meteorológicas extremas e, portanto, estando expostas a riscos financeiros elevados, as entidades seguradoras desempenham um papel crucial na luta global contra as mudanças climáticas. A incorporação de modelos mais robustos para a predição de eventos climáticos extremos possui a motivação de maior acurácia das estimativas atuariais e de solvência. Além disso, elas ajudam as seguradoras a avaliar e precificar riscos com maior precisão, melhoram a gestão de riscos, incentivam a inovação, garantem conformidade regulatória e promovem benefícios socioeconômicos mais amplos. Em última análise, a adoção e integração de análises preditivas robustas permitem que as seguradoras se adaptem de maneira eficaz às novas realidades climáticas, protegendo seus negócios e contribuindo para a resiliência das comunidades que servem.

A imprevisibilidade e a alta variabilidade dos eventos climáticos extremos tornam a previsão e modelagem adequada dos riscos mais desafiadora para as seguradoras. Assim, na mensuração dos riscos de um grupo de contratos de seguro e estimação do passivo para cobertura de sinistros futuros, surge a necessidade de não somente analisar padrões históricos, mas também analisar as condições atuais e expectativas/previsões futuras. Neste sentido, surge a necessidade de metodologias mais robustas e assertivas para a predição de eventos extremos futuros. Assim, as abordagens introduzidas neste trabalho podem ser de grande valia se incorporadas pelo mercado segurador na mensuração de riscos futuros. A aplicação dessas metodologias pode melhorar significativamente a capacidade das seguradoras de prever eventos climáticos extremos, contribuindo para uma maior assertividade das estimativas de seus passivos para cobertura de sinistros futuros.

Referências

Agência Brasil. *Rio Grande do Sul tem 616 mil pessoas fora de casa pela calamidade*. 2024. Disponível em: <<https://agenciabrasil.etc.com.br/geral/noticia/2024-06/rio-grande-do-sul-tem-616-mil-pessoas-fora-de-casa-pela-calami-dade>>. Citado na página 7.

BERLINER, L. M.; KIM, Y. Bayesian design and analysis for superensemble-based climate forecasting. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 21, n. 9, p. 1891 – 1910, 2008. Disponível em: <<https://journals.ametsoc.org/view/journals/clim/21/9/2007jcli1619.1.xml>>. Citado 2 vezes nas páginas 9 e 25.

BRIGGS, W. M. On the changes in the number and intensity of north atlantic tropical cyclones. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 21, n. 6, p. 1387 – 1402, 2008. Disponível em: <<https://journals.ametsoc.org/view/journals/clim/21/6/2007jcli1871.1.xml>>. Citado 2 vezes nas páginas 9 e 25.

Capital Reset. *Mercado de seguros no Brasil já sente efeitos da mudança climática*. 2023. Disponível em: <<https://capitalreset.uol.com.br/clima/ciencia/mercado-de-seguros-no-brasil-ja-sente-efeitos-da-mudanca-climatica/>>. Citado na página 15.

CHAND, S. S.; WALSH, K. J. E. Forecasting tropical cyclone formation in the fiji region: A probit regression approach using bayesian fitting. *Weather and Forecasting*, American Meteorological Society, Boston MA, USA, v. 26, n. 2, p. 150 – 165, 2011. Disponível em: <https://journals.ametsoc.org/view/journals/wefo/26/2/2010waf222452_1.xml>. Citado 2 vezes nas páginas 9 e 25.

CHU, P.-S.; ZHAO, X. A bayesian regression approach for predicting seasonal tropical cyclone activity over the central north pacific. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 20, n. 15, p. 4002 – 4013, 2007. Disponível em: <<https://journals.ametsoc.org/view/journals/clim/20/15/jcli4214.1.xml>>. Citado 4 vezes nas páginas 9, 25, 35 e 37.

CHU, P.-S.; ZHAO, X. Bayesian analysis for extreme climatic events: A review. *Atmospheric Research*, v. 102, n. 3, p. 243–262, 2011. ISSN 0169-8095. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169809511002158>>. Citado 2 vezes nas páginas 9 e 25.

CNN. *Demanda de seguradoras cresce oito vezes no litoral paulista após fortes chuvas*. 2023. Disponível em: <<https://www.cnnbrasil.com.br/economia/demanda-para-seguradoras-cresce-oito-vezes-apos-fortes-chuvas-no-litoral-paulista/>>. Citado na página 19.

- CNN. *Um mês de enchentes no Rio Grande do Sul: veja situação do estado*. 2024. Disponível em: <<https://www.cnnbrasil.com.br/nacional/um-mes-de-enchentes-no-rio-grande-do-sul-veja-situacao-do-estado/>>. Citado na página 16.
- CNSEG. *Seguro Agrícola cresce mais de 265 vezes em 18 anos*. 2023. Disponível em: <<https://cnseg.org.br/noticias/seguro-agricola-cresce-mais-de-265-vezes-em-18-anos>>. Citado na página 18.
- CNSEg. *Mercado segurador paga quase R\$ 190 bilhões aos segurados em 2023*. 2024. Disponível em: <<https://cnseg.org.br/noticias/mercado-segurador-paga-quase-r-190-bilhoes-aos-segurados-em-2023>>. Citado na página 16.
- CNSEG. *Seguradoras já registraram R\$1,7 bilhão em indenizações previstas no Rio Grande do Sul*. 2024. Disponível em: <<https://www.cnseg.org.br/noticias/seguradoras-ja-registraram-r-1-7-bilhao-em-indenizacoes-no-rio-grande-do-sul>>. Citado na página 16.
- DING, D. et al. Modeling extreme events in time series prediction. Association for Computing Machinery, New York, NY, USA, p. 1114–1122, 2019. Disponível em: <<https://doi.org/10.1145/3292500.3330896>>. Citado 5 vezes nas páginas 9, 25, 28, 29 e 37.
- ELSNER, J. B.; BOSSAK, B. H. Bayesian analysis of u.s. hurricane climate. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 14, n. 23, p. 4341 – 4350, 2001. Disponível em: <https://journals.ametsoc.org/view/journals/clim/14/23/1520-0442_2001_014_4341_baoush_2.0.co_2.xml>. Citado 2 vezes nas páginas 9 e 25.
- HO, H.-S. K. C.-H.; CHU, P.-S. Seasonal prediction of tropical cyclone frequency over the east china sea through a bayesian poisson-regression method. *Asia-Pacific Journal of Atmospheric Sciences*, American Meteorological Society, Boston MA, USA, v. 1, n. 45, p. 45 – 54, 2009. Citado 2 vezes nas páginas 9 e 25.
- IASB. *IFRS 4 Insurance Contracts*. [S.l.], 2004. Citado na página 21.
- IASB. *IFRS 17 Insurance Contracts*. [S.l.], 2017. Citado 3 vezes nas páginas 7, 8 e 21.
- JAGGER, T. H.; ELSNER, J. B. A consensus model for seasonal hurricane prediction. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 23, n. 22, p. 6090 – 6099, 2010. Disponível em: <<https://journals.ametsoc.org/view/journals/clim/23/22/2010jcli3686.1.xml>>. Citado 5 vezes nas páginas 9, 25, 33, 34 e 37.
- LU, M.-M.; CHU, P.-S.; LIN, Y.-C. Seasonal prediction of tropical cyclone activity near taiwan using the bayesian multivariate regression method. *Weather and Forecasting*, American Meteorological Society, Boston MA, USA, v. 25, n. 6, p. 1780 – 1795, 2010. Disponível em: <https://journals.ametsoc.org/view/journals/wefo/25/6/2010waf2222408_1.xml>. Citado 5 vezes nas páginas 9, 25, 32, 33 e 37.
- MORETTIN, P. A.; BUSSAB, W. d. O. *Estatística básica*. [S.l.]: Saraiva, 2004. Nenhuma citação no texto.
- Munich Re, Geo Risks Research. *NatCatSERVICE*. 2019. Disponível em: <<https://www.iii.org/graph-archive/96424>>. Citado na página 12.

National Oceanic and Atmospheric Administration. *Global Time Series*. 2024. Disponível em: <<https://www.ncei.noaa.gov/access/monitoring/climate-at-a-glance/global/time-series>>. Citado na página 11.

NELDER, J. A.; R. W. M. Wedderburn. Generalized linear models. *Journal of the Royal Statistical Society. Series A (General)*, [Royal Statistical Society, Wiley], v. 135, n. 3, p. 370–84, 1972. Citado 2 vezes nas páginas 29 e 32.

ONU. *O que são as mudanças climáticas?* 2022. Disponível em: <<https://brasil.un.org/pt-br/175180-o-que-s%C3%A3o-mudan%C3%A7as-clim%C3%A1ticas>>. Citado na página 10.

Pricewaterhouse&Coopers. *Climate Change: Actuarial Roles and Strategies*. 2021. Disponível em: <https://www.casact.org/sites/default/files/2022-02/CS7-Climate_Change_Actuarial_Roles_and_Strategies_0.pdf>. Citado na página 17.

Revista Exame. *Prejuízos com extremos climáticos no Brasil somam R\$ 502,4 bilhões em 30 anos*. 2024. Disponível em: <<https://exame.com/brasil/prejuizo-com-extremos-climaticos-no-brasil-somam-r-5024-bilhoes-em-30-anos/>>. Citado 2 vezes nas páginas 13 e 14.

Revista Galileu. *Por que eventos climáticos extremos são cada vez mais parte da realidade*. 2020. Disponível em: <<https://revistagalileu.globo.com/Ciencia/Meio-Ambiente/noticia/2020/07/por-que-eventos-climaticos-extremos-sao-cada-vez-mais-parte-da-realidade.html>>. Citado na página 13.

Sillas Teixeira Gonzaga. *Curso de Séries Temporais*. 2019. Disponível em: <http://sillasgonzaga.com/material/curso_series_temporais/arima>. Citado 2 vezes nas páginas 26 e 27.

SUSEP. *Seguro Compreensivo*. 2022. Disponível em: <<https://www.gov.br/susep/pt-br/planos-e-produtos/seguros/seguro-compreensivo>>. Citado na página 18.

SUSEP. *Seguro Rural*. 2024. Disponível em: <https://homolog2.susep.gov.br/menuatendimento/Seguro_Rural.asp>. Citado na página 18.

Swiss RE Institute. *Natural catastrophes in 2023: gearing up for today's and tomorrow's weather risks*. [S.l.], 2024. No 1. Citado na página 14.

The Washington Post. *Home insurers cut natural disasters from policies as climate risks grow*. 2023. Disponível em: <<https://www.washingtonpost.com/business/2023/09/03/natural-disaster-climate-insurance/>>. Citado 2 vezes nas páginas 14 e 15.

Valor Econômico. *Seguradoras amargam perdas no campo*. 2023. Disponível em: <<https://valor.globo.com/publicacoes/especiais/seguros/noticia/2023/10/31/seguradoras-amargam-perdas-no-campo.ghtml>>. Citado na página 18.

World Meteorological Organization. *State of the Climate in Latin America and the Caribbean*. [S.l.], 2024. WMO - No 1351. Citado na página 7.