



Universidade de Brasília (UnB)  
Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas  
(FACE)  
Programa de Pós-Graduação em Ciências Contábeis (PPGCont/UnB)

**A UTILIZAÇÃO DE DERIVATIVOS CLIMÁTICOS E SUA  
APLICABILIDADE COMO FERRAMENTA DE GERENCIAMENTO DE  
RISCO NO AGRONEGÓCIO BRASILEIRO**

**STÉPHANIE CRISTINA GARCIA TRAPP PASSOS**

BRASÍLIA – DF  
2023

**STÉPHANIE CRISTINA GARCIA TRAPP PASSOS**

A Utilização de Derivativos Climáticos e sua Aplicabilidade como Ferramenta de Gerenciamento de Risco no Agronegócio Brasileiro

Dissertação apresentada como requisito para obtenção do Título de Mestre em Ciências Contábeis do Programa de Pós-graduação em Ciências Contábeis da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília.

Orientador:

Prof. Dr. Bruno Vinícius Ramos  
Fernandes

BRASÍLIA – DF  
2023

**STÉPHANIE CRISTINA GARCIA TRAPP PASSOS**

**A UTILIZAÇÃO DE DERIVATIVOS CLIMÁTICOS E SUA APLICABILIDADE  
COMO FERRAMENTA DE GERENCIAMENTO DE RISCO NO  
AGRONEGÓCIO BRASILEIRO**

Dissertação apresentada no Programa de Pós-graduação em Ciências Contábeis da  
Universidade de Brasília para obtenção do título de Mestre em Ciências Contábeis.

Banca Examinadora:

**Prof. Dr. Bruno Vinicius Ramos Fernandes**  
PPGCont/UnB - Orientador

**Prof. Dr. Herbert Kimura**  
PPGCont/UnB – Membro Interno

**Prof. Dr. Diogo Henrique Silva de Lima**  
UFRN – Membro externo

**Prof. Dr. Paulo Augusto Pettenuzzo de Britto**  
PPGCont/UnB - Suplente

**UNIVERSIDADE DE BRASÍLIA (UnB)**

Profa. Dra. Márcia Abrahão Moura  
Reitora

Prof. Dr. Enrique Huelva Unternbäumen  
Vice-Reitor

Prof. Dr. Lúcio Remuzat Rennó Junior  
Decano de Pós-Graduação

Prof. Dr. José Márcio Carvalho  
Diretor da Faculdade de Economia, Administração, Contabilidade e Gestão de  
Políticas Públicas

Prof. Dr. Sérgio Ricardo Miranda Nazaré  
Chefe do Departamento de Ciências Contábeis e Atuarias

Prof. Dr. Jomar Miranda Rodrigues  
Coordenador do Programa de Pós Graduação em Ciências Contábeis

## AGRADECIMENTOS

Primeiramente, gostaria de agradecer aos meus pais, por todo suporte que sempre deram e por nunca duvidarem da minha capacidade. À minha mãe, meu exemplo de pessoa que quero sempre seguir os passos, e ao meu pai que me moldou a ser essa pessoa que sou e que me orgulho muito. E a minha maravilhosa irmã Stella, que espero ser sempre motivo de admiração.

Agradeço também, imensamente, ao meu marido Antonio que me ajudou muito nessa jornada do mestrado com a maternidade. Foi a pessoa que mais me incentivou ao longo da jornada, nunca me deixando esquecer da minha capacidade e força. Enfrentei meus desafios com o melhor companheiro de todos. Obrigada por me acompanhar por toda essa caminhada árdua. Você também foi minha inspiração a seguir essa vida acadêmica.

Agradeço ao meu lindo filho Arthur, pela paciência em dividir a mãe com a universidade de uma forma tranquila. Todo esse crescimento de sua mãe é dedicado a você. Amo você.

Meus sinceros agradecimentos aos professores e servidores do Programa de Pós-Graduação em Contabilidade (PPGCont) da Universidade de Brasília, por todos os ensinamentos que me fizeram crescer como pesquisadora. Em especial, ao meu orientador prof. Bruno por toda a compreensão e apoio nesses anos de mestrado.

Ao CNPq/CAPES pelo apoio ao longo do programa de mestrado, e em especial pela concessão da bolsa que foi fundamental para o avanço da pesquisa.

## RESUMO

O clima é uma variável de difícil previsibilidade e que pode acarretar grandes perdas operacionais em diversos setores da economia. Normalmente, o risco climático é tratado como sendo de difícil mitigação, tendo como ferramenta apenas o monitoramento por meio de estações meteorológicas. Entretanto, na década de 90, nos Estados Unidos, surge um instrumento derivativo com foco em fatores climáticos como: temperatura, pluviosidade, vento ou vegetação. Assim, os derivativos climáticos surgem como uma possível solução financeira para essas eventuais perdas. Diferentemente do seguro que só é acionado em grandes eventos catastróficos que geram sinistros, o derivativo climático funciona por meio de alterações climáticas mais leves, porém que geram prejuízos. Como no caso do agronegócio, o qual um produtor pode não ter um desastre natural para acionar o seguro, mas sua colheita foi impactada por constantes períodos de temperaturas baixas o que diminuiu a capacidade produtiva. No mercado internacional ocorre a negociação desse tipo de produto. Além disso, no meio acadêmico internacional há discussões sobre essa temática, entretanto no Brasil, a pesquisa acadêmica com foco em derivativos climáticos é muito incipiente mesmo sendo um país, cujas principais atividades econômicas são fortemente vulneráveis as variabilidades climáticas. Assim, o presente trabalho buscou avaliar a utilização de derivativos climáticos no Brasil e a aplicabilidade do instrumento financeiro no segmento do agronegócio. Por meio de uma pesquisa buscou-se investigar se haveria a negociação desse instrumento no país por meio de uma análise qualitativa das notas explicativas das principais empresas do “Novo Mercado” na B3, em busca de responder os seguintes questionamentos: (i) se as empresas utilizam derivativos para *hedge* e quais os instrumentos; (ii) se utilizam derivativos climáticos; (iii) se há uma percepção dessas sobre o impacto dos riscos climáticos sobre suas atividades. Conclui-se que as empresas utilizam diversos instrumentos derivativos para proteção, porém não possuem derivativos climáticos. Por outro lado, alguns segmentos, em especial a agricultura e energia, reconheceram que há impactos relevantes dos riscos climáticos. Assim, a segunda parte do estudo realizou uma análise sobre a aplicabilidade dos derivativos climáticos no agronegócio brasileiro. Para isso, foram escolhidos os cinco maiores estados produtores de cada região do Brasil, de cada uma das três principais culturas do país: soja, milho e cana-de-açúcar. Definiu-se a utilização de derivativos climáticos com indexadores de temperatura (*heating degree day* - HDD e *cooling degree day* - CDD) por serem os mais discutidos na academia. E para efeitos comparativos realizou-se uma simulação da receita de um produtor que não utiliza o contrato contra a receita de um produtor aplicando o contrato. O resultado demonstrou que há de fato um ganho com a utilização dos instrumentos derivativos a depender da região e da *commodity*. Conclui-se que as regiões norte e nordeste tiveram menores alterações climáticas em comparação com as regiões centro oeste, sudeste e sul, em especial as duas últimas que tiveram maiores HDD. Assim, o estudo define que para a aplicação dos contratos de derivativos climáticos torna-se mais eficiente em locais nos quais os índices HDD/CDD são maiores e a depender do volume produtivo e das características biológicas da cultura, como exemplo o intervalo ideal de temperatura da *commodity*.

**Palavras-chave:** Agronegócio. Derivativos Climáticos. Riscos Climáticos. Temperatura.

## ABSTRACT

The weather is a variable that is difficult to predict and can result in significant operational losses in various sectors of the economy. Typically, climate risk is seen as hard to mitigate, with weather stations being the main tool for monitoring. However, in 1990s, a derivative instrument focusing on climate factors such as temperature, precipitation, wind, or vegetation emerged in the United States. Thus, climate derivatives emerged as a potential financial solution for these eventual losses. Unlike insurance, which is triggered in major catastrophic events that result in losses, climate derivatives triggers through milder climate change that may impact the production. For example, in the case of agriculture, a producer may not have a natural disaster to trigger insurance coverage, but their Harvest may be affected by prolonged periods of low temperatures, resulting in reduced productivity. Many discussions about this type of products occurs in the international academic community. However, in Brazil, academic research focused on climate derivatives is still in its early stages, despite the country's main economic activities being highly vulnerable to climate variability. Thus, this study aimed to evaluate the possible applicability of climate derivatives in the Brazilian agriculture segment. Through a research, its conclusion was that no trading occurs in the country. This confirmation was based on a qualitative analysis of the explanatory notes of the main companies in the "Novo Mercado" on B3, in order to answer the following questions: (i) whether companies use derivatives for hedging and which instruments; (ii) whether they use climate derivatives; (iii) if they a perception about the impact of climate risks on their activities. It was concluded that companies use a great variety of derivative instruments for protection but do not employ weather derivatives. However, some sectors, particularly agriculture and energy, acknowledged the significant impacts of climate risks. Therefore, the second part of the study aimed to analyze the potential applicability of climate derivatives in Brazillian agriculture. For this purpose, the five largest producers of each region of Brazil were selected for the country's three main crops: soybean, corn and sugarcane. Climate derivatives with temperature índices were chosen, such as heating degree day – HDD and cooling degree day – DD, since they are the most discussed academically. For comparative purposes, a simulation was conducted comparing the revenue of a producer who does not use the contract Against the revenue of a producer applying the contract. The results showed that there is indeed a gain from using derivative instruments depending on the region and commodity. It was concluded that the Northern and northeastern regions had fewer climate changes compared to the central west, southeast and Southern regions, with the last two of them experiencing higher HDD. Therefore, the study suggests that the application of climate derivative contracts is more efficient in locations with higher HDD/CDD índices and depending on the production volume and biological characteristics of the crop, such as the ideal temperature range for the commodity.

**Key Words: Agriculture. Weather Derivatives. Climate Risks. Temperature.**

## LISTA DE QUADROS

Quadro 1: Definições acerca do que é risco .....	25
Quadro 2: Definições sobre risco no agronegócio .....	26
Quadro 3: Resumo dos principais estudos do mercado norte-americano .....	36
Quadro 4: Resumo dos principais estudos do mercado europeu .....	39
Quadro 5: Resumo dos principais estudos do mercado asiático .....	41
Quadro 6: Resumo dos principais estudos do mercado africano .....	42
Quadro 7: Intervalo da temperatura ideal de plantio (em Celsius) .....	55
Quadro 8: Número de empresas com derivativos para <i>hedge</i> .....	59
Quadro 9: Instrumentos derivativos utilizados por cada empresa .....	61
Quadro 10: Principais motivos divulgados pelas empresas para utilização de derivativos .....	62
Quadro 11: Quantidade de empresas que citaram riscos climáticos sobre suas atividades operacionais .....	63
Quadro 12: Notas explicativas do setor agropecuário/agrícola .....	65
Quadro 13: Notas explicativas do setor alimentício .....	66
Quadro 14: Notas explicativas do setor de aluguel de veículos .....	67
Quadro 15: Notas explicativas do setor de bens industriais .....	67
Quadro 16: Notas explicativas do setor de comércio e distribuição .....	68
Quadro 17: Notas explicativas do setor de consumo não cíclico .....	68
Quadro 18: Notas explicativas do setor de energia .....	69
Quadro 19: Notas explicativas do setor de mineração.....	69
Quadro 20: Notas explicativas do setor de papel celulose .....	70
Quadro 21: Resumo dos estados produtores (em toneladas) de cada produto – (média de 2006 a 2022) .....	72
Quadro 22: Resumo das variáveis climáticas de cada estado definido como maior produtor regional de cana-de-açúcar (média 2006 a 2022) .....	74
Quadro 23: Calendário agrícola – Cana-de-açúcar por região.....	75
Quadro 24: Resumo das variações climáticas de cada estado definido como maior produtor regional de soja (média 2006 a 2022) .....	76
Quadro 25: Calendário agrícola – Soja por região.....	77
Quadro 26: Resumo das variações climáticas de cada estado definido como maior produtor regional de milho (1ª safra) .....	79



Quadro 27: Calendário agrícola – milho (1ª safra) por região .....	80
Quadro 28: Resumo das variações climáticas de cada estado definido como maior produtor regional de milho (2ª safra) .....	81
Quadro 29: Calendário agrícola – milho (2ª safra) por região .....	82
Quadro 30: Estatística descritiva dos dados meteorológicos .....	83
Quadro 31: Resultados dos indexadores totais de temperatura .....	85
Quadro 32: Resultado da precificação da cultura de cana-de-açúcar .....	88
Quadro 33: Resultado da precificação da cultura de soja .....	88
Quadro 34: Resultado da precificação da cultura de milho (1ª safra) .....	89
Quadro 35: Resultado da precificação da cultura de milho (2ª safra) .....	89
Quadro 36: Simulação da receita do produtor pelo índice temperatura HDD .....	91
Quadro 37: Simulação da receita do produtor pelo índice temperatura CDD .....	93

**LISTA DE FIGURAS**

Figura 1: Chicago Mercantile Exchange (CME) volume de futuro e de opções climáticos negociados entre o ano de 2019 a 2020 pelo CME Group.....	33
Figura 2: Quadro resumo dos modelos de precificação de derivativos climáticos .....	46
Figura 3: Processo Metodológico do Trabalho.....	53
Figura 4: Riscos Encontrados e seus Instrumentos Financeiros.....	71
Figura 5: Mapa do Brasil com os cinco principais produtores regionais de cana-de-açúcar em destaque .....	73
Figura 6: Mapa do Brasil com os cinco principais produtores regionais de soja em destaque .....	76
Figura 7: Mapa do Brasil com os cinco principais produtores regionais de milho (1ª safra) em destaque .....	78
Figura 8: Mapa do Brasil com os cinco principais produtores regionais de milho (2ª safra) em destaque .....	81

**LISTA DE ABREVIATURA E SIGLAS**

CME	Chicago Mercantile Exchange
CONAB	Companhia Nacional de Abastecimento
COSO	Committee of Sponsoring Organizations of the Treadway Commission
ISO	International Organization for Standardization
LIFEE	London International Financial Futures and Options Exchange
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
NCEP	National Centers for Environmental Prediction
PROAGRO	Programa de Garantia da Atividade Agropecuária
SASB	Sustainability Accounting Standards Board
USDA	United States Department of Agriculture
ZARC	Zoneamento Agrícola de Risco Climático

## SUMÁRIO

1	INTRODUÇÃO .....	16
	1.1 Contextualização.....	16
	1.2 Justificativa.....	18
	1.3 Problema.....	19
	1.4 Objetivos.....	20
	1.5 Delimitação de Pesquisa.....	21
	1.6 Estrutura da pesquisa .....	21
2	REFERENCIAL TEÓRICO .....	23
	2.1 Agronegócio .....	23
	2.2 Risco climático .....	23
	2.3 Gerenciamento de risco .....	24
	2.3.1 Gerenciamento de risco no agronegócio .....	26
	2.3.2 Gerenciamento de risco climático .....	27
	2.4 Derivativos climáticos .....	28
	2.5 Seguros agrícolas <i>versus</i> derivativos climáticos .....	32
	2.6 Mercado global de derivativos climáticos .....	33
	2.7 Estudos internacionais sobre derivativos climáticos .....	34
	2.7.1 Continente americano .....	34
	2.7.2 Continente europeu .....	36
	2.7.3 Continente asiático .....	39
	2.7.4 Continente africano .....	41
	2.8 Mercado brasileiro e os riscos climáticos .....	42
	2.9 Estudos nacionais sobre derivativos climáticos .....	43
	2.10 Limitações no uso de derivativos climáticos .....	44
	2.10.1 Precificação do instrumento .....	44
	2.10.1.1 Método atuarial .....	46
	2.10.1.2 <i>Historical burn analysis</i> .....	47
	2.10.1.3 Modelagem indexada .....	47
	2.10.1.4 Modelagem diária .....	47
	2.10.1.5 Métodos alternativos .....	48
	2.10.2 Risco de base (basis risk) .....	48

3	PROCEDIMENTOS METODOLÓGICOS .....	50
	3.1 Análise de Resultado sobre o uso de derivativos climáticos no Brasil .....	50
	3.2 Coleta de dados .....	51
	3.3 Preparação dos dados meteorológicos .....	53
	3.4 Definindo o <i>Heating Degree Days</i> (HDD) e o <i>Cooling Degree Days</i> (CDD)..	55
	3.5 Fórmula de precificação .....	56
	3.6 Definição da indenização .....	57
	3.7 Cálculo da eficiência do instrumento financeiro .....	57
4	RESULTADOS ESTUDO QUALITATIVO .....	59
	4.1 Estudo sobre o uso de derivativos climáticos no Brasil.....	59
	4.1.1 Amostra de empresas que utilizam derivativos .....	59
	4.1.2 Instrumentos derivativos utilizados.....	60
	4.1.3 Principais motivos apresentados para o uso de derivativos.....	62
	4.1.4 Empresas que divulgaram em notas explicativas sobre riscos climáticos .....	63
	4.2 Fatos relevantes encontrados em notas explicativas .....	65
5	ESTUDO SOBRE A APLICABILIDADE DE UM MODELO DE DERIVATIVO CLIMÁTICO .....	72
	5.1 Determinação do maior produtor de cada região .....	72
	5.1.1 Cana-de-açúcar .....	73
	5.1.2 Soja .....	75
	5.1.3 Milho (1ª safra) .....	78
	5.1.4 Milho (2ª safra) .....	80
	5.2 Apresentação estatística descritiva dos dados meteorológicos .....	82
	5.3 Precificação do instrumento derivativo .....	87
	5.4 Eficiência do derivativo climático considerando a receita do produtor .....	90
6	CONSIDERAÇÕES FINAIS E REFLEXÕES ACERCA DO TEMA .....	95
	REFERÊNCIAS .....	98

APÊNDICE A – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Tocantins (Pedro Afonso) .....	106
APÊNDICE B – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Alagoas (Coruripe).....	111
APÊNDICE C – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – São Paulo (Barretos).....	116
APÊNDICE D – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Paraná (Maringá).....	121
APÊNDICE E – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Goiás (Mineiros).....	126
APÊNDICE F – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Bahia (Correntina).....	131
APÊNDICE G – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Mato Grosso (Sapezal).....	136
APÊNDICE H – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Paraná (Clevelândia).....	141
APÊNDICE I – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Tocantins (Campos Lindos).....	146
APÊNDICE J – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Minas Gerais (Unai).....	151
APÊNDICE K – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Bahia (Luiz Eduardo Magalhães).157	
APÊNDICE L – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático –Goiás (Jataí).....	162
APÊNDICE M – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Pará (Paragominas).....	168
APÊNDICE N – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Minas Gerais (Uberaba).....	173
APÊNDICE O – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Paraná (São Mateus do Sul).....	178
APÊNDICE P – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Mato Grosso (Primavera do Leste).....	184

APÊNDICE Q – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Rondônia (Vilhena).....	189
APÊNDICE R – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – São Paulo (Itapeva) .....	194
APÊNDICE S – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Sergipe (Carira).....	198
APÊNDICE T – Código texto utilizado no Matlab R2023b para modelagem da temperatura e precipitação do derivativo climático – Paraná (Clevelândia).....	204

## 1. INTRODUÇÃO

### 1.1 Contextualização

A agricultura tem grande importância no desenvolvimento da sociedade. Desde as plantações para a própria sobrevivência do ser humano até a atividade para comercialização do excedente produzido. Assim, como em outros setores, dentro deste grande segmento econômico há fatores de risco que comprometem essa atividade. Desde as questões operacionais, as financeiras e até mesmo as ambientais. Muitas vezes, esses fatores de riscos ambientais tendem a serem considerados inerentes e de difícil minimização. Em vista disso, o clima é considerado um desses possíveis vetores de impacto sobre a produtividade do agronegócio, impactando além da produção a rentabilidade do produtor.

O agronegócio surge como um sistema mais complexo envolvendo diversas atividades. Na década de 60, Davis e Goldberg propuseram uma definição para o agronegócio como sendo a soma de todas as operações que envolvessem a manufatura e distribuição de suprimentos, as operações de produção, as estocagens, os processamentos e as distribuições de produtos. Assim, a agricultura não passa a ser considerada um setor isolado, mas torna-se parte de um sistema especializado de agentes interconectados (ZYLBERSZTAJN, 2017).

Os produtores rurais são expostos a diversos riscos, sendo os principais: (i) risco de produção; (ii) risco de preços; (iii) risco de financiamento; (iv) risco institucional; e (v) risco de capital humano. Dentro do risco de produção, encontra-se o fator da incerteza do processo natural relacionado ao cultivo e às variáveis que podem impactar essa incerteza, entre elas pode-se citar desastres naturais, pestes, clima entre outros possíveis fatores (USDA, 2019).

Desta maneira, pode-se perceber que diferentemente das outras atividades empresariais, o agronegócio envolve certas peculiaridades que a tornam mais arriscada em comparação as outras. Isso ocorre devido a eventuais interferências de caráter biológico sobre a produção, aos impactos diretos/indiretos de variações climáticas e à consequente alta volatilidade de preços referentes a essas incertezas de negócios. O que torna relevante a criação de mecanismos de gerenciamento de risco para essa atividade econômica (MAPA, 2021).



A variável ambiental do clima afeta diretamente a atividade produtiva das empresas, porém a depender do setor econômico esse nível de impacto é diferente. Empresas que dependem do clima para seus produtos ou serviços sofrem maior impacto pela volatilidade dessa variável. Entretanto, diferentemente das outras variáveis ambientais, o clima é um fator que não pode ser controlado (CAO, WEI, 2004).

Assim, diversos componentes do clima, como geadas, aumento ou diminuição de temperaturas fora do normal, umidade, chuvas ou nevascas podem alterar a economia por representarem fatores anormais nas atividades. Esses impactos econômicos podem ser observados em diversos setores, como: hotelaria, turismo, setor de energia, indústria e agropecuária.

Dessa forma, surgem os riscos climáticos que impactam diretamente ou indiretamente as atividades operacionais dos negócios. O Chicago Mercantile Exchange – CME (2021) reportou que os riscos climáticos e suas consequências no sistema financeiro são considerados de choque “sub-sistêmico”. Isso indica que os riscos climáticos por si só não conseguiriam prejudicar a economia inteira de um país, entretanto esse risco acaba por afetar cada um dos agentes em proporções diferentes. E, conseqüentemente, o estresse constante sobre os agentes pode impactar o sistema financeiro como um todo.

Variações climáticas afetam a oferta e a demanda de produtos no mercado econômico. Isso pode ocorrer, desde o uso maior de eletricidade devido a variação de temperatura, a impactos naturais diretos como um aumento anormal de pluviosidade em uma plantação. Lemos (2014) considera que um sinônimo em relação ao risco climático é o risco volumétrico. Uma vez que esse risco afeta diretamente o volume de produção e não os preços. A variação monetária pode ocorrer devido às flutuações relacionadas à oferta e à demanda do produto/serviço nem sempre serem lineares e que podem ser afetadas por outros fatores como guerras ou nível de armazenamento.

Como as variáveis ambientais são de difícil controle, surge a necessidade de criação de ferramentas que consigam minimizar os impactos financeiros. Dessa forma, na década de 90, os derivativos climáticos surgiram pela primeira vez por uma transação entre as empresas de energia Enron Corporation e Koch Industries. Entretanto, mesmo com a falência da Enron, esse instrumento financeiro continuou sendo negociado no mercado norte-americano pela Chicago Mercantile Exchange (CME). No ano de 2020, o

valor total nominal dos contratos de derivativos climáticos passou do valor de US\$ 1.230 milhões.<sup>1</sup> (CME, 2021)

Tanto no continente europeu quanto no norte americano, o derivativo climático é um instrumento financeiro em comercialização no mercado. No âmbito acadêmico, os estudos sobre a temática demonstraram ser uma ferramenta de gestão de risco eficiente em diversos setores e com possibilidade de uso de diferentes indexadores climáticos, podendo assim ser utilizado em diferentes localidades geográficas. Por consequência, está se tornando cada vez mais importante e popular entre os instrumentos de hedge sobre riscos climáticos ao redor do mundo. (HULL, 2015)

Entretanto, no Brasil a temática ainda não é muito explorada. São poucos os trabalhos que avaliam a possibilidade de utilização da ferramenta no país como forma viável de mitigar os riscos climáticos. No agronegócio, trabalhos como Lemos (2014), Lucas (2015), Raucci, Lanna, Silveira e Capitani (2019) e Alves Neto (2021) buscaram aplicar modelos de precificação e analisar a possível viabilidade de uso desses em regiões específicas do território nacional. Todos conseguiram corroborar que o instrumento é eficiente na sua funcionalidade de *hedge* contra eventos adversos climáticos.

## **1.2 Justificativa**

Por meio dos crescentes estudos sobre a temática dos derivativos climáticos no agronegócio (CYR, KUSY e SHAW, 2010; ENDER e ZHANG, 2015; ZHOU, LI e PAI, 2016; LOPES, 2018; KUSNIYEVA, 2019; MÖLLMANN, BUCHHOLZ e MUSSHOFF, 2019; RAUCCI, CAPITANI e SILVEIRA, 2020; ALVES NETO, 2021), percebe-se que os resultados corroboram a eficiência desse instrumento financeiro na mitigação dos riscos de produção, independentemente da localização e do fator climático a ser considerado. Entretanto, estudos brasileiros sobre os derivativos climáticos são escassos, diferentemente da pesquisa internacional.

De acordo com o Ministério da Agricultura, Pecuária e Abastecimento - MAPA (2021), as constantes mudanças climáticas impactam os principais segmentos da economia brasileira, o agronegócio, o energético e o turístico de modo que se torna relevante incentivos sobre ferramentas de gestão de riscos climáticos nesses setores. De

---

<sup>1</sup> Valor composto por US\$ 750 milhões em contratos futuros e US\$ 480 milhões em contratos de opções.

modo que a implementação de derivativos climáticos como uma ferramenta de gestão de risco apresenta uma oportunidade ao mercado do agronegócio brasileiro, que é de extrema relevância ao PIB do país. O setor, no ano de 2021, alcançou uma participação de 27,4% no PIB brasileiro, indicando o maior valor desde 2004 (quando atingiu o percentual de 27,53%).

A demanda externa por produtos agropecuários está alavancada. Tendo registrado o setor, em julho de 2021 no acumulado de 12 meses, um superávit comercial recorde de US\$ 98,2 bilhões. Além disso, internamente, o setor do agronegócio apresentou um crescimento real de 21,6% nos últimos 7 anos, contra uma queda de 3,1% da economia como um todo. Indicando que nos próximos meses há uma estimativa de crescimento no setor devido à demanda aquecida no mundo. (CONAB, 2021)

Eventos climáticos relacionados a temperatura, ou até mesmo hídrico, acabam por prejudicar a economia do país. Desde eventos extremos como inundações, tempestades ou mesmo estiagem aumentaram suas incidências e intensidades ao longo dos anos. De modo que esses impactos estão sendo observados no segmento econômico de diversas economias emergentes. (UNDP, 2019)

### **1.3 Problema**

Dessa forma, o Brasil tem relevância mundial em setores que sofrem grandes impactos relacionados a riscos climáticos, como o agronegócio, o setor energético e o de turismo. Todos esses segmentos de mercado necessitam de um gerenciamento de risco que também priorize buscar medidas para mitigar possíveis perdas ocasionadas por essas variações climáticas em suas operações. O agronegócio está entre os segmentos mais sensíveis as variações climáticas, já que o clima em si é um importante fator que impacta crescimento, desenvolvimento e qualidade da colheita. (KHAN, RENNIE e CHARLEBOIS, 2013).

Nos continentes Europeu, Norte Americano e Asiático, os derivativos climáticos já são comercializados e estudados. Em comparação com o Brasil, não se encontram muitos trabalhos com essa temática, o que corrobora com a premissa de que não há comercialização desse instrumento no mercado brasileiro. Pereira Junior e Malaquias (2019) analisaram dentro de uma amostra de 44 empresas na B3 a possível utilização de

derivativos climáticos no ano de 2017. Os autores concluíram que não havia indícios do uso desse produto financeiro pelas empresas analisadas.

Diante do exposto, busca-se determinar qual a viabilidade do uso do derivativo climático sobre os principais produtos do agronegócio brasileiro como gerenciamento de risco climático?

#### **1.4 Objetivos**

Desse modo, considerando a relevância do Brasil no agronegócio, buscou-se analisar qual o nível de utilização de derivativos climáticos no Brasil, por meio de uma análise qualitativa sobre as demonstrações financeiras como um todo de empresas acionárias. Para posteriormente, determinar a viabilidade de uso desse instrumento financeiro sobre os principais produtos do agronegócio brasileiro como instrumento no gerenciamento de risco climático.

Para alcançar o objetivo geral da pesquisa foram considerados os objetivos específicos citados a seguir:

- a) Identificar e quantificar as empresas que demonstram ter riscos climáticos em suas operações;
- b) Analisar a percepção das empresas sobre a possibilidade de riscos climáticos impactarem suas operações;
- c) Determinar se há comercialização de contratos de derivativos climáticos no mercado brasileiro por empresas de capital aberto que compõem o segmento do “Novo Mercado” na B3, haja vista que a última pesquisa com esse intuito foi realizada em 2019 (PEREIRA JÚNIOR e MALAQUIAS, 2019);
- d) Precificar derivativos climáticos, com foco no indexador de temperatura, dos três principais produtos agropecuários brasileiros (Soja, Milho e Cana-de-açúcar) considerando sobre cada um desses produtos os maiores produtores de cada região brasileira;
- e) Avaliar a eficiência sobre o uso do derivativo climático no agronegócio a partir da comparação sobre possíveis ganhos de um produtor representativo que faz uso do instrumento com aquele que o faz.

### **1.5 Delimitação da Pesquisa**

A possível utilização de derivativos climáticos engloba uma grande diversidade de indexadores climáticos a serem considerados. Para determinar qual o mais adequado é necessário que o produtor do negócio identifique qual o fator climático que mais impacta sua operação dentre os possíveis fatores, como: temperatura, pluviosidade, geadas etc. Com esse conhecimento prévio, o derivativo climático consegue ser mais eficiente em sua função de hedge.

Devido ao relatório emitido pela Companhia de Abastecimento Nacional – Conab (2022), as variáveis climáticas temperatura e precipitação são constantemente fatores que impactam a produção agrícola mês a mês. Entretanto, este trabalho foca apenas na variável temperatura para fins de analisar esse indexador no território brasileiro como um todo.

O derivativo climático pode ser utilizado em qualquer segmento de mercado, mas seu uso é mais comum em setores com maior impacto ocasionados por variações climáticas. Esse estudo analisa possíveis formas de mitigação desse risco no setor do agronegócio brasileiro. Esse segmento é vasto com grande diversificação de produtos e com participação de todas as regiões geográficas do território nacional. Assim, buscou-se analisar o segmento da agricultura e seus principais produtos de exportação com relevante participação no mercado mundial. Desse modo, ainda há outras possíveis análises sobre os outros produtos e serviços no segmento que podem utilizar derivativos climáticos.

### **1.6 Estrutura da Pesquisa**

A partir da contextualização, do problema de pesquisa, dos objetivos, da delimitação identificada e da justificativa apresentados nesta Introdução, este estudo é estruturado da seguinte maneira:

- Capítulo 1 trata da contextualização e apresentação do problema de pesquisa. Explicitando os objetivos a serem alcançados por meio do estudo e a delimitação da pesquisa. Além de demonstrar a relevância do tema por meio da justificativa.
- Capítulo 2 apresenta o referencial teórico que aborda conceitos relacionados ao agronegócio, gerenciamento de risco e aspectos dos derivativos. Além disso, é constituído de estudos anteriores sobre a temática no contexto internacional e com a apresentação dos recentes trabalhos nacionais.

- Capítulo 3 introduz os procedimentos metodológicos a serem utilizados para a realização da pesquisa que será feita por método quali-quantitativo.
- Capítulo 4 apresenta um estudo qualitativo sobre o mercado brasileiro de derivativos climáticos na atualidade, buscando analisar por meio de notas explicativas a perspectiva das empresas sobre risco climático e se essas divulgam a utilização desse instrumento financeiro para mitigar tais riscos. Esse capítulo apresenta a parte do estudo qualitativo do trabalho.
- Capítulo 5 apresenta o estudo de viabilidade, propriamente dito, com a determinação das principais cidades regionais produtoras das *commodities* avaliadas; manipulação e observação de dados temporais (temperatura e precipitação); determinação das opções de venda de cada *commodity* e suas respectivas cidades; e a análise de eficiência sobre o uso do derivativo climático como ferramenta de mitigação de risco climático.
- Capítulo 6 trata sobre as considerações finais e as reflexões acerca do tema.

## 2. REFERENCIAL TEÓRICO

### 2.1 Agronegócio

O agronegócio surgiu como um conceito muito maior que apenas a junção entre agricultura e pecuária. Davis e Goldberg (1957 apud Luz e Fochezatto, 2022) definem que é necessário considerar dentro deste grupo tudo que seria gerado em razão da agropecuária, desde o segmento de fertilizantes, químicos, fármacos, máquinas agrícolas, biotecnologia, energia elétrica, combustíveis etc. Deve-se considerar tudo que é gerado a partir da produção agrícola ou da pecuária, além de considerar o segmento de serviços que transportam, armazenam, financiam, comercializam internamente ou por meio de exportação a produção primária.

Portanto, para fins de aplicação na literatura pertinente, pode-se identificar quatro componentes dentro das atividades relacionadas ao agronegócio: Núcleo do Agronegócio, contemplando as atividades agrícolas e pecuárias; Montante do Agronegócio, com o fornecimento de insumos e capital ao Núcleo; Jusante do Agronegócio, com os segmentos que recebem a produção do Núcleo como matéria prima para sua própria produção; e Distribuição do Agronegócio, com o segmento de serviços (LUZ e FOCHEZATTO, 2022).

Como envolve um processo de grande proporção, esse sistema divide-se em três partes: antes da porteira, dentro da porteira e depois da porteira. A primeira fase conhecida como “antes da porteira” representa as atividades econômicas relacionadas aos insumos utilizados na produção agropecuária. A segunda fase, “dentro da porteira”, indica a produção propriamente dita de plantio ou manejo de animais. E, por último, “depois da porteira” está relacionado com o processamento e distribuição do produto ao consumidor final (Buranello, 2013 apud Alcantara, 2020).

### 2.2 Risco Climático

O risco climático, especialmente com as recorrentes mudanças climáticas, impacta diretamente ou indiretamente a sociedade e as organizações. Fraser, Quail e Simkins (2021) exemplificam que de acordo com o *Sustainability Accounting Standards Board* (SASB), 93% das indústrias no mercado de capitais Norte Americano são significativamente impactadas por riscos climáticos.

Consequências advindas do aquecimento global podem ser observadas, como: derretimento de geleiras, aumento no nível do mar, maior número de incêndios naturais etc. Fraser et al. (2021) preveem que com o aumento da temperatura global e da taxa de evaporação da água podem impactar na precipitação pluviométrica de regiões de florestas tropicais. O que pode resultar em novas áreas com pouca chuva e, conseqüentemente, mais seca; e chuvas além do normal em outras áreas destruindo habitats e ocasionando erosões, impactando atividades humanas como a agricultura.

Além disso, uma alteração no ciclo da água, redução de chuvas, geleiras e nevascas impactam de alguma forma no abastecimento de água. Como consequência, negócios que dependam do uso de água para funcionar serão prejudicados devido à baixa oferta de água impactando severamente suas operações, como: agricultura; energia nuclear; papel e celulose; produtos químicos e manufatura (FRASER *ET AL.*, 2021).

Uma das principais recomendações oferecidas pelo SASB foi a de que empresas deveriam reportar sobre os seus riscos financeiros relacionados a fatores climáticos dentro de suas respectivas estruturas de gerenciamento de riscos. Incluindo a incorporação de monitoramento e gerenciamento de riscos climáticos nas estruturas de governança das empresas, inclusive por meio de responsabilidades de supervisão claramente definidas pelo conselho de administração da empresa.

Devido ao fato de impactar as atividades econômicas, como a agricultura, Fraser, Quail e Simkins (2021) relatam que o segmento de seguros e resseguros pode apresentar, conseqüentemente, efeitos agudos sobre seu mercado. Dimitrova (2019) explica que os custos e disponibilidade dos contratos de seguros podem ser impactados já que os modelos atuariais dependem de projeções com variáveis, que em períodos de extremas mudanças como no caso do aquecimento global, passam a serem inadequadas para lidarem com essas incertezas.

### **2.3 Gerenciamento de Risco**

O risco está intrinsecamente ligado as atividades do cotidiano. Sua origem pode surgir de diversas fontes: ações humanas, crises econômicas, fenômenos naturais etc. No ambiente organizacional, o gerenciamento de risco torna-se um processo essencial para a existência da empresa. Kimura e Perera (2005) relatam que à medida em que o mercado



evolui, as empresas tendem a ficar mais expostas a riscos. Assim, torna-se mandat3rio para a sobreviv3ncia dessas empresas o gerenciamento desses riscos.

H3 uma gama de defini33es sobre o conceito de risco como pode-se observar pelo quadro 1, a seguir. Por3m, de modo geral o risco expressa uma caracter3stica de imprevisibilidade sobre uma atividade. O COSO ERM (2017) define que o risco 3 a possibilidade de que um evento ocorra de modo a afetar a realiza33o da estrat3gia e dos objetivos de neg3cio. Corroborando com essa defini33o, o ISO 31000 (2009) tamb3m define o risco como o efeito de uma incerteza em rela33o aos objetivos organizacionais.

**Quadro 1: Defini33es acerca do que 3 risco**

Autor	Conceito
Bastias (1977)	Risco 3 uma ou mais condi33es de uma vari3vel que possuem o potencial suficiente para danificar um sistema, em termos de fatores humanos, organizacionais, financeiros, entre outros. Resultando, assim, em poss3veis realoca33es de metas.
Giddens (2003)	A din3mica que mobiliza uma sociedade predisposta 3s mudan3as 3 o risco, na qual estipula seu pr3prio futuro em vez de confi3-lo aos fatores externos.
Lalonde e Boiral (2012)	A probabilidade e o tamanho do impacto do evento s3o medidos pelo risco. Matematicamente, risco 3 a probabilidade dos danos frente a sua propaga33o.
Verbano e Venturini (2013)	A combina33o de duas vari3veis 3 considerada como risco. Sendo a frequ3ncia o primeiro epis3dio no qual o risco ocorreu, ou seja, sua probabilidade. A segunda vari3vel 3 a extens3o das consequ3ncias geradas por um evento, isto 3, a magnitude.
Strelnik (2016)	A probabilidade de um evento ocorre e suas consequ3ncias s3o consideradas os riscos, no qual seu desempenho modifica os indicadores de uma organiza33o, para melhor ou pior, at3 mesmo na varia33o do ambiente interno e externo independente das decis3es gerenciais.
Carlsson-Wall et al. (2019)	O risco inclui todos os fatores pol3ticos, estrat3gicos, financeiros, operacionais e de dados.

Fonte: Souza e Souza (2019)

Mesmo tendo essa caracter3stica de incerteza, o gerenciamento sobre os riscos 3 fator relevante para a sobreviv3ncia de uma organiza33o. O gerenciamento de riscos definir3 quais os processos dentro da organiza33o que ir3o estabelecer estrat3gias que ser3o formuladas para identificar em toda a organiza33o esses eventos em potencial que podem impactar as atividades organizacionais. Os riscos n3o ser3o eliminados, mas sim minimizados de modo que garantam o cumprimento razo3vel dos objetivos da entidade (COSO ERM, 2017).

Sendo assim, pode-se afirmar que o gerenciamento de risco 3 uma ferramenta relevante para a organiza33o obter vantagem competitiva no mercado. Desde a

determinação das estratégias de atuação com as evidenciações sobre as exposições da entidade, as fragilidades e as possíveis perdas nas quais deve-se imunizar o capital até o monitoramento. (FERNANDES, 2012).

### 2.3.1 Gerenciamento de Risco no Agronegócio

O agronegócio representa um segmento de mercado que além dos riscos presentes nos outros setores, como o risco de mercado ou institucional, apresenta riscos específicos relacionados a atividade, como riscos climáticos, pragas etc. (MOREIRA, BARREIRO e PROTIL, 2009).

**Quadro 2: Definições sobre risco no agronegócio**

Riscos	Principais definições sobre risco no agronegócio
Risco de Produção	Impactos sobre a produtividade que por consequência afeta o resultado. As principais fontes desse tipo de risco são: clima, mudanças climáticas, pragas, doenças, tecnologia, genética, eficiência do maquinário e a qualidade dos insumos.
Risco de Mercado	Impactos sobre o resultado financeiro, devido a variações dos preços de venda da produção, preço dos insumos e para o acesso aos mercados
Risco Financeiro	Todos os riscos que podem ameaçar a saúde financeira, sendo seus componentes básicos: o custo e a disponibilidade de capital; capacidade de atender às necessidades de fluxo de caixa em tempo hábil; capacidade de manter e aumentar a equidade; e a capacidade de absorver choques financeiros de curto prazo.
Risco Legal	A atividade agrícola possui compromissos com implicações legais, sendo essas: arranjos contratuais; organização empresarial; leis e regulamentos; responsabilidade por delitos; e políticas públicas e atitudes.
Risco na Gestão de Pessoas	Pessoas são fontes de risco, mas também são importantes no processo de mitigação desses. Assim, o gerenciamento de risco na gestão de pessoas busca lidar com segurança, satisfação e produtividade dos colaboradores, com foco em alguns aspectos: saúde e bem-estar dos colaboradores; relações familiares e comerciais; gestão de funcionários; e planejamento de transição

Fonte: Crane et al. (2013)

Devido a importância da atividade do setor e dos riscos que podem surgir e impactar não só a perpetuidade da operação, mas também a estabilidade financeira do produtor, é importante a busca por ferramentas de gestão de risco no agronegócio (VIGANI e KATHAGE, 2019).

Assim, um gerenciamento dos riscos inerentes à atividade agrícola é fator determinante sobre o sucesso ou fracasso do produtor. Esses riscos são preocupações perceptíveis sobre o agronegócio, desde as variações climáticas (risco ambiental), as variações do preço de venda (risco de mercado), produtividade abaixo do esperado (risco operacional) e variação dos custos de produção (risco de mercado). Todos os riscos

tendem a ter alguma ferramenta disponível para mitigá-los. No risco de mercado, pode se utilizar soluções como travamento de preço dos insumos por meio de cooperativas; travamento das taxas de juros de financiamentos ou diversificação da produção, como exemplo. Outras formas de mitigar riscos específicos do setor, como os biológicos, podem ocorrer por meio de medidas como o controle contra de doenças na produção ou o controle epidêmico (ALCANTARA, 2020; ZHU *ET AL.*, 2019).

### **2.3.2 Gerenciamento de Risco Climático**

Assumindo que há um processo de gerenciamento de risco corporativo, Fraser et al. (2021) apontam que ao considerar riscos climáticos algumas técnicas e critérios precisam ser adaptados.

O primeiro ponto a ser destacado é com relação ao horizonte de tempo. De acordo com Fraser et al. (2021), os perfis de riscos e os procedimentos são alterados num espaço curto de tempo, usualmente dentro de um período de três a cinco anos. Mudanças climáticas envolvem períodos de tempos maiores que impactam no planejamento estratégico de uma empresa. Dessa forma, quando há avaliação sobre os riscos associados a fatores climáticos, a relação entre o risco e a estratégia adotada pelo negócio é efetivamente revertida, isto é, os objetivos passam a ser analisados de acordo com o contexto de risco.

As mudanças climáticas impactam de forma imprevisível e constantemente, introduzindo novas variáveis a serem identificadas pelos agentes, necessitando ajustes no planejamento estratégico de modo a mitigar os riscos. Pois os impactos ocasionados por mudanças climáticas podem ser observáveis desde mudanças no habitat até nas consequentes atividades econômicas. Assim, Fraser et al. (2021) indicam que uma organização deve monitorar os aspectos chaves relacionados aos riscos climáticos, os seus impactos e o contexto das atividades de tratamento. Assim, é relevante manter uma combinação entre planejamento de longo-prazo, investimento planejado, monitoramento constante e agilidade na tomada de decisão.

Na agricultura, Raucci, Capitani e Silveira (2020) apresentam que as decisões dos gestores são essenciais no processo de alcançar os resultados financeiros, de modo que essas decisões são alteradas ao longo do processo agrícola, desde o ciclo produtivo até o comercial. Envolvendo escolhas, desde o período do plantio, a forma de financiamento, o

pacote tecnológico adotado e a forma de comercialização do produto. Assim, cada etapa desse processo traz riscos diferentes a serem geridos pelos produtores.

Ainda que esses riscos climáticos não possam ser eliminados, podem ser mitigados por meio de instrumentos financeiros com o intuito de proteção ao patrimônio do *hedger*. Sousa, Souza Filho e Silva (2015) citam que na gestão de risco climáticos, tem-se três instrumentos de transferência de risco: (i) os seguros tradicionais; (ii) seguros indexados; e (iii) os derivativos climáticos. Os seguros tradicionais são elaborados para proteger o agente social e econômico contra as perdas. O indexado é projetado por meio de um índice, como a precipitação, que irá servir como proxy para perdas, eliminando a necessidade de avaliar as perdas individuais.

Um estudo conduzido por Dosi e Moretto (2003) buscou investigar a relação entre a variabilidade do clima e o lançamento de derivativos climáticos. Em especial, a principal pergunta feita pelos autores foi: Podemos supor que pelo surgimento do instrumento financeiro derivativo climático que o setor econômico considera relevante o aquecimento global e suas consequências? Para isso, consideraram um agente adverso ao risco com um ativo sob sua gestão que depende de padrões climáticos. Para conseguir adquirir proteção contra riscos climáticos, o agente pode ou adquirir um contrato de seguro padrão ou comprar uma opção de derivativo climático precificado pelo modelo clássico de Black-Scholes (1973). Assim, o resultado do estudo foi obtido por meio de uma comparação entre o custo dessas duas alternativas de *hedge*. Chegando à conclusão de que o aquecimento global poderá aumentar cada vez mais a demanda por derivativos climáticos para *hedge* sobre risco climático.

## **2.4 Derivativos Climáticos**

Os instrumentos derivativos surgiram com o objetivo de proteção para os agricultores. Lima et al. (2009) exemplificam que devido à problemas de sazonalidade decorrentes do cultivo de arroz que surgiram os primeiros instrumentos. Assim, os derivativos, ao longo do tempo, tornaram-se mais robustos e diversificados passando, dessa forma, a exigir sua negociação em ambientes mais normatizados.

O surgimento do derivativo climático ocorreu com a Enron Corporation e a Koch Industries. Na ocasião, o foco principal era o mercado de energia elétrica, em especial pela desregulamentação desse mercado. Isso permitiu que novos tipos de produtos

financeiros fossem desenvolvidos com o propósito de hedge sobre os riscos climáticos desse setor, em específico.

Sloan et al. (2002) explicam que os diferentes participantes deste mercado negociam suas próprias linhas de produtos e seguem modelos de precificação distintos. Isso ocorre, em especial, devido à natureza incerta dos fenômenos naturais, que permitem essa liberdade de criar contratos e precificar de modo que se adapte as necessidades das empresas. De um modo geral, esses modelos tendem a seguir uma aproximação atuarial, utilizada constantemente no mercado de seguros. Porém, essa aproximação desconsidera o mercado financeiro na sua formulação, sendo que eventos climáticos afetam diretamente os ativos e, portanto, esses podem sofrer um hedge que serão estocasticamente relacionados aos derivativos climáticos.

Assim, pode-se perceber algumas diferenças entre os instrumentos derivativos convencionais e os climáticos. Brockett et al. (2005) citam que o primeiro se baseia em algum índice subjacente para determinar seus contratos, como taxas de juros, títulos, moedas ou preços. No caso dos derivativos climáticos, não há um valor original ou negociável já existente, pois o fator a ser medido são as condições climáticas.

Brockett et al. (2005) definem que um risco climático consiste em incertezas de fluxos de caixa ou de lucros que seriam causados por eventos climáticos não catastróficos. Alguns possíveis eventos seriam: temperatura, umidade, tempestades, nevascas, alagamentos entre outros. Em especial, esses derivativos têm como característica principal de focar em eventos adversos naturais, mas que não indiquem catástrofes, que seriam eventos mais associados à área de seguros.

O principal papel desse instrumento financeiro, como Brockett et al. (2005) explicam, é o de permitir que negócios que seriam afetados negativamente por mudanças temporais imprevisíveis consigam balancear os seus riscos. Da mesma forma que *hedgers* usariam outros instrumentos financeiros derivativos para esse mesmo propósito, mas com outras variáveis como, taxas de juros ou variação de moeda.

Assim, o objeto de negociação de derivativos climáticos é o clima, sendo esse fator de difícil mensuração. Assim, para conseguir precificar e, posteriormente, negociar esse tipo de produto é necessário cumprir com algumas premissas. Uma delas relaciona-se a base de dados que será utilizada para determinar o histórico climático. Como

exemplo, cita-se o caso em que se deseja determinar o uso de um derivativo climático de uma determinada região com base na temperatura, utilizando o índice calor graus/dias. Para isso, seria necessária uma base consistente, completa, e com elevada acurácia sobre os dados passados daquela região, para assim conseguir precificar o derivativo (VEDENOV e BARNETT, 2004).

Além disso, é necessário a existência de uma contraparte que possa negociar esse instrumento. Muitas vezes não precisa ser uma empresa que esteja na mesma região da contraparte. Única obrigatoriedade desse derivativo é utilizar uma métrica que seja de possível mensuração e controle, por meio de algum centro meteorológico. (RAUCCI, CAPITANI e SILVEIRA, 2020).

Um contrato de derivativo climático padrão é definido, como apresentam Raucci, Capitani e Silveira (2020) com os seguintes atributos: (i) periodicidade (data de início e final da operação); (ii) a estação de medida; (iii) a variável climática que será utilizada; (iv) índice (proxy da variável climática que o contrato busca acompanhar); (v) função de payoff; e em alguns casos, a depender da estrutura contratual, o prêmio. Assim, percebe-se que um derivativo climático não possui um ativo-objeto transacionável no mercado, como ações, moedas ou commodities.

Devido ao surgimento dos derivativos climáticos no setor energético, um dos principais índices utilizados são os de aquecimento e resfriamento. Assim, existem três possíveis tipos: o *Cooling Degree Days* (CDD), o *Heating Degree Days* (HDD) e o *Cumulative Amount of Temperature* (CAT). Para Jewson e Brix (2015) os índices de CDD e HDD representam a demanda de temperatura. O HDD representa a quantidade de energia demandada para alcançar o aquecimento necessário em dias mais frios. Já o CDD indica a quantidade de energia demandada para alcançar o resfriamento necessário em dias mais quentes. O terceiro índice é mais utilizado na Europa como um substituto ao CDD para regiões nas quais a temperatura dificilmente é abaixo de 18 graus célsius (°C).

Dessa forma, pode-se perceber que a temperatura base poderá não ser a mesma a depender do setor ou mesmo do produto a ser avaliado. É importante saber qual a variável climática com impacto direto no negócio e em que intervalo de medida essa variável impacta negativamente na operação. Alves Neto (2021) exemplifica que na cultura de soja, a temperatura base é diferente do que na cultura de milho e que, portanto, não se pode aplicar a mesma temperatura para dois produtos ou em regiões diferentes.

Alaton, Djehiche e Stillberger (2002) definem que a partir de uma estação meteorológica,  $T_i^{max}$  e  $T_i^{min}$  são consideradas as temperaturas máximas e mínimas (em graus Celsius) respectivamente, medidas no dia  $i$ . Sendo assim, a definição da temperatura do dia  $i$  é:

$$T_i = \frac{T_i^{max} + T_i^{min}}{2} \quad (1)$$

Assim, por meio da denotação de  $T_i$  pode-se definir a função de *heating degree-days* ( $HDD_i$ ) e *cooling degree-days* ( $CDD_i$ ) geradas no dia em questão como:

$$HDD_i = \sum_{i=1}^i \max(T_{base} - T_i, 0) \quad (2)$$

$$CDD_i = \sum_{i=1}^i \max(T_i - T_{base}, 0) \quad (3)$$

Em que:

$T_i$  = Temperatura observada no dia  $i$ ;

$T_{base}$  = Temperatura utilizada como referência.

Outros indicadores podem ser usados além dos citados anteriormente. É o caso de Just e Ortiz-Bobea (2012) que utilizaram o *Growing Degree Days* (GDD) e *Damaging Degree Days* (DDD). Ambos os indicadores estão relacionados ao impacto da temperatura sobre o crescimento das plantas. O primeiro é o intervalo de temperatura que afeta positivamente no desenvolvimento da planta, e o segundo o intervalo que afeta negativamente.

A pluviosidade também é considerada um possível indexador, com grande impacto nos principais setores econômicos, como agronegócio, hidrelétricas, construção e o empresas do setor de turismo. Entretanto, diferentemente da temperatura, é um modelo mais difícil de ser obtido. Isso ocorre devido ao fato de que a pluviosidade não é considerada uma variável contínua, isto é, é uma variável de evento binário. Em cada dia, pode ser observado ou não a presença de precipitação. Tal evento faz com que a precipitação seja considerada mais irregular do que as alterações de temperatura. (ZAPRANIS e ALEXANDRIDIS, 2013)

Segundo Cabrera, Odening e Ritter (2013) o índice de pluviosidade é constituído a partir da soma da pluviosidade diária  $R_t$  de uma determinada localização no período entre  $[\tau_1, \tau_2]$ , sendo:

$$I(\tau_1, \tau_2) = \sum_{t=\tau_1}^{\tau_2} R_t \quad (4)$$

## 2.5 Seguros Agrícolas versus Derivativos Climáticos

Lemos (2014) cita que a escolha entre o produto financeiro mais apropriado depende da intensidade da severidade e da frequência que ocorre. Variações climáticas de pequena escala, mas que podem gerar algum impacto econômico, não representam a alta severidade e baixa frequência necessária para a indenização por meio de seguros. Sendo assim, para o produtor uma oportunidade de utilizar derivativos climáticos para cobrir eventuais prejuízos decorrentes de fatores climáticos nas atividades operacionais.

Raucci, Capitani e Silveira (2020) indicam que a contratação de um seguro eficiente por parte do produtor permite a manutenção da competitividade no mercado, mesmo ocorrendo a perda patrimonial ou uma redução na produtividade da lavoura na ocorrência de eventos climáticos adversos. A alta diversidade de produtos ofertados pelas seguradoras auxiliam na escolha do produtor sobre a melhor opção a depender da sua necessidade, desde seguros de custeio, receita ou faturamento, produtividade, penhor rural e pecuniário. Entretanto os seguros diferem dos derivativos climáticos em especial devido a sua estrutura contratual.

Os seguros agrícolas tradicionais são diferentes dos derivativos climáticos. Os primeiros realizam sua estrutura de pagamento a depender, exclusivamente, de um evento meteorológico específico que ocasione o sinistro, sendo esse mensurado por um indicador predeterminado. Já o derivativo climático independe da ocorrência de um sinistro, alterações discretas de fatores climáticos já estariam sob cobertura do instrumento derivativo (RAUCCI, CAPITANI e SILVEIRA, 2020)

Dentro do mercado de seguros, a assimetria de informação pode comprometer a eficiência dos seguros, sendo os dois problemas mais usuais a seleção adversa e o risco moral. Silva, Bastos e Féres (2017) definem que a seleção adversa ocorre, pois, riscos individuais são heterogêneos. Isso indica que os indivíduos têm mais informações sobre



seus próprios graus de risco, quando comparados às companhias seguradoras. Para as seguradoras descobrirem o perfil de risco de cada usuário é necessário um alto custo o que pode acarretar uma alta despesa para o usuário. Já o risco moral advém do fato de que a heterogeneidade dos riscos pode decorrer não apenas dos distintos perfis de risco intrínseco, mas devido ao fato de que os agentes não investem de forma eficiente na prevenção de riscos.

Além disso, os principais problemas de risco moral e seleção adversa, inerentes aos seguros de produção agrícola, são eliminados. Devido ao fato de não ser atrelado o valor de indenização paga ao produto à produtividade da lavoura, o incentivo a usos de estratégias de gestão de produção abaixo do esperado deixa de existir. Os produtores passam a investir em melhores práticas de gestão o que reduz o risco agregado da seguradora, e conseqüentemente, o custo do seguro. Incentivando novos agentes a operar nesse mercado (SILVA, BASTOS e FÉRES, 2017).

Assim, como o mercado de seguros agrícolas apresenta algumas limitações referentes ao seu uso, outras ferramentas de gestão de risco podem ser utilizadas com o objetivo de proteger o patrimônio do produtor.

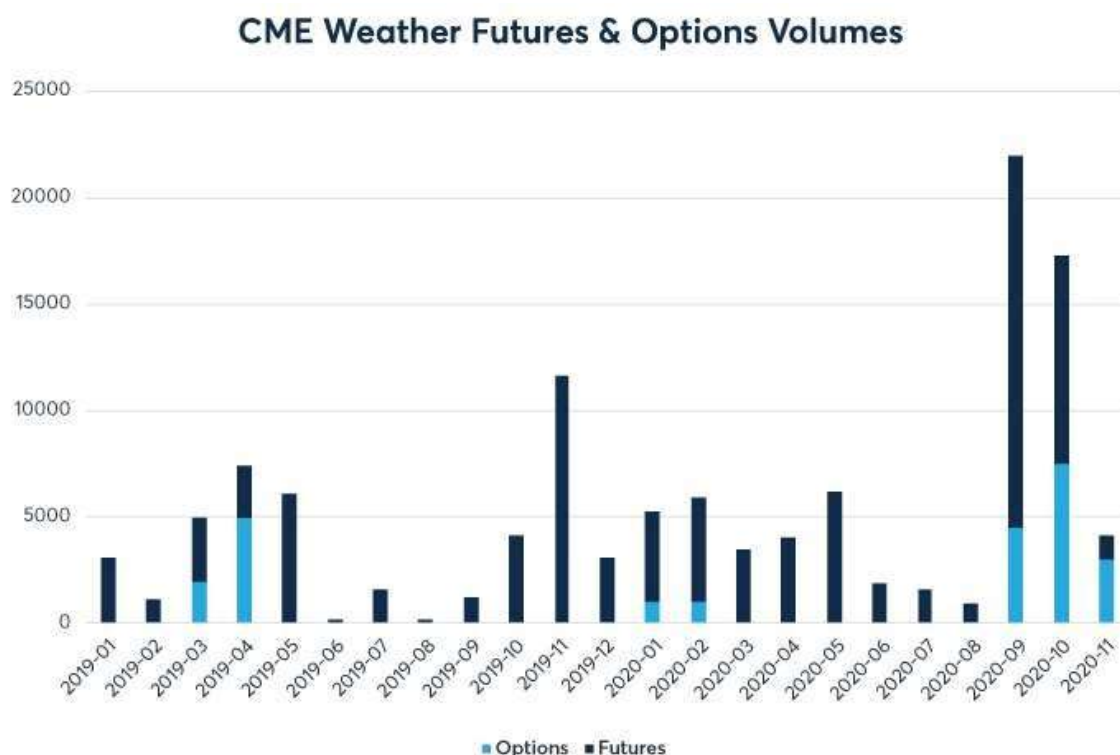
## **2.6 Mercado Global de Derivativos Climático**

Atualmente, percebe-se que o volume de negociações em bolsa de derivativos climáticos vem aumentando nos últimos anos como reportado *pelo Climate Related Market Risk Subcommittee* (2020), conforme pode-se observar na figura 1. Em grande parte, devido às alterações climáticas provenientes do aquecimento global, percebe-se cada vez mais os impactos do clima nas atividades econômicas (DOSI e MORETTO, 2003).

O CME negocia contratos futuros e de opções com indexadores de temperatura desde o surgimento desses instrumentos em solo norte-americano. Na Europa, até o ano de 2004 a *London International Financial Futures and Options Exchange* (LIFEE) negociava os contratos futuros em épocas sazonais. A LIFEE foi incorporada pela NYSE Euronext.

Na CME as negociações são baseadas no indexador de temperatura de cidades americanas e outras três grandes capitais fora dos Estados Unidos (Tóquio, Amsterdã e Londres).

**Figura 1 – Chicago Mercantile Exchange (CME) volume de futuro e de opções climáticos negociados entre o ano de 2019 a 2020 pelo CME Group**



Fonte: CME (2021)

A figura 1 apresenta o aumento no número de contratos de derivativos climáticos, especialmente sobre futuro e opções. Este dado foi apresentado pela CME com o objetivo de demonstrar que em 2020 ocorreu um aumento sobre o volume de contrato futuro climático de 60% no acumulado do ano, com um valor nominal de \$750 milhões. O volume de contratos de opções climáticas aumentou em 143% no acumulado do ano, com um valor nominal de \$480 milhões.

## 2.7 Estudos Internacionais sobre Derivativos Climáticos

### 2.7.1 Continente Americano

Nos Estados Unidos, Vedenov e Barnett (2004) analisaram a eficiência dos derivativos climáticos em plantações de milho, de algodão e de soja entre localizações diferentes. Os autores consideraram que o derivativo climático cumpre sua função de hedge. Entretanto, os autores constataram que os instrumentos apresentaram mudanças tanto em sua estrutura quanto na performance de redução de risco, fato que corrobora o impacto do risco de base geográfica.

Já Woodard e Garcia (2008) focaram sua análise nas plantações de milho em Illinois, Estados Unidos, para determinar os impactos do risco de base sobre a eficiência do instrumento. Os autores também buscaram comparar a utilização de instrumentos focados em temperatura com os de precipitação pluviométrica. Os derivativos focados em indexadores de temperatura conseguiram uma melhor *performance* de eficiência em comparação aos derivativos de precipitação. E uma justificativa para tal fenômeno é atribuída a diferença entre no grau de correlação espacial dos indexadores. Isto é, por exemplo, a correlação da precipitação declina rapidamente espacialmente do que a temperatura. Pode-se perceber a delimitação da precipitação, o que não ocorre com a temperatura.

Zhou, Li e Pai (2016), também em Illinois, buscaram determinar um modelo de simulação apropriado para uso futuro de derivativos climáticos em plantações de milho em um ano futuro. Os autores conseguiram alcançar com a estrutura proposta a eficiência do *hedge* e a distribuição e quantidade necessária de instrumento a ser transacionado. O método utilizado pelos autores foi com um alto número de simulações, o que diminuiu a possibilidade de erros no modelo, dessa forma os autores concluem que foram eficientes com relação à proposta de determinar a eficiência dos instrumentos derivativos climáticos com a função de *hedge*.

Cyr, Kusy e Shaw (2010) analisaram, na região do Niagara, no Canadá, o possível uso de derivativos climáticos com o objetivo de hedge de um dos problemas de variação climática da região: a chuva durante o período de colheita. Os autores chegaram à conclusão de que mesmo com o risco de base geográfica os derivativos climáticos são determinísticos para a mitigação dos riscos na vinicultura. Além disso, o prêmio estimado para os produtores foi considerado financeiramente viável.

Na província de Saskatchewan, também no Canadá, Khan, Rennie e Charlebois (2013) conduziram uma pesquisa por meio de questionário direcionado a agricultores de grãos da região, conhecida por ser impactada de modo não catastrófico, porém com demasiada frequência. O estudo buscou determinar quais as práticas de gerenciamento de risco climático praticada pelos agricultores, e se, em especial, há o uso de derivativos climáticos como forma de complemento de seguro agrícola. Os autores concluem que menos de 10% dos entrevistados usam de fato derivativos climáticos. Isso ocorre, em

especial, devido à falta de conhecimento sobre a existência do produto financeiro, fato que corrobora a literatura previa acerca da temática.

O quadro 3 apresenta o resumo para fins comparativos entre os estudos norte-americanos.

**Quadro 3: Resumo dos principais estudos do mercado norte-americano**

<b>Autores</b>	<b>Ano</b>	<b>Continentes</b>	<b>Indexador</b>	<b>Objetivos</b>	<b>Principais Achados</b>
Vedenov e Barnett	2004	Americano	Agricultura - temperatura	Autores analisaram três <i>commodities</i> diferentes (milho, algodão e soja) no mercado norte-americano, em locais diferentes para determinar o impacto do risco geográfico e a eficiência do derivativo.	Os autores conseguiram provar a eficiência do instrumento derivativo. Entretanto, também confirmaram os impactos negativos do risco de base geográfica sobre o derivativo.
Woodard e Garcia	2008	Americano	Agricultura - temperatura/ pluviosidade	Comparação entre os indexadores de temperatura e pluviosidade. Estudo de caso realizado em uma plantação de milho nos Estados Unidos.	Os derivativos de temperatura foram mais eficientes que os de precipitação.
Cyr, Kusy e Shaw	2010	Americano	Agricultura - pluviosidade	Autores buscam avaliar o <i>hedge</i> sobre o uso de derivativos climáticos com indexadores pluviométricos na região do Niagara, no Canadá.	Há o reconhecimento do impacto do risco de base geográfico sobre o resultado. Entretanto, o uso do derivativo gerou retorno financeiro viável sendo seu uso defendido.
Khan, Rennie e Charlebois	2013	Americano	Agricultura	Pesquisa qualitativa, feita no Canadá, com intuito de determinar por meio de questionários com agricultores sobre o uso desse instrumento como ferramenta de risco climático	O resultado demonstrou que menos de 10% dos entrevistados usam derivativos climáticos, e que tal fato ocorre devido à falta de conhecimento sobre a existência do produto
Zhou, Li e Pai	2016	Americano	Agricultura - temperatura	Autores buscaram determinar um modelo apropriado de simulação futura de derivativos climáticos em uma plantação de milho.	Autores definem que o instrumento é eficiente em sua função de <i>hedge</i>

Fonte: Elaboração própria

### 2.7.2 Continente Europeu

Musshoff, Odening e Xu (2008) assumiram que devido às constantes mudanças climáticas e, conseqüentemente, às incertezas sobre a produção de trigo, produtores buscam outras formas de proteção além dos seguros agrícolas. Assim, os autores buscaram analisar a eficiência dos derivativos climáticos no gerenciamento de risco sobre uma plantação de trigo no nordeste da Alemanha. Como conclusão, a eficiência do hedge

é comprovada, entretanto o risco de base geográfica impacta na quantificação do hedge. Quanto menor for o risco de base geográfica maior a eficiência do hedge. Demonstrando assim, a importância de melhorar as bases meteorológicas a disposição dos modelos de precificação dos derivativos.

Ghiulnara e Viegas (2010) defendem o uso de derivativos climáticos em Portugal como uma forma de contribuir aos fatores de gerenciamento de riscos climáticos, que compõem a sensibilidade climática, a previsão climática e o crescimento econômico das empresas. Entretanto, as autoras determinam que alguns fatores precisam ser aprimorados: (a) criação de novos produtos climáticos; (b) treinamento de profissionais qualificados para esses instrumentos e; (c) a existência de empresas interessadas na utilização desses instrumentos com o objetivo de hedge.

Štulec (2017) realiza um estudo no segmento de varejo, em especial o de bebidas, na Croácia. O objetivo da autora era o de analisar a eficiência de derivativos climáticos sobre o gerenciamento de riscos climático não catastróficos. Dentro da amostra de 60 empresas, os resultados mostraram que o clima tem um efeito significativo sobre as vendas de bebidas no país. Assim os derivativos climáticos conseguem ser eficientes na redução incerta de vendas de bebidas.

Möllmann, Buchholz e Musshoff, (2019) ao invés de utilizarem os indexadores mais comuns nesse tipo de instrumento derivativo relacionados a temperatura e a precipitação, os autores fizeram um estudo de caso em plantações alemãs de trigo com o uso do *vegetation health index* (VHI). Esse indexador é utilizado como um possível substituto das estações meteorológicas, em especial para regiões distantes do centro de controle meteorológico. O estudo de caso revelou que o VHI, no período do inverno analisado, tinha alta correlação com a plantação de trigo, e que assim, derivativos climáticos baseados em indexadores de VHI apresentaram maior eficiência no hedge.

Analisando o uso de derivativos climáticos no turismo na Comunidade Valenciana, na Espanha. Martinez-Salgueiro e Tarrazon-Rodon (2019) questionam sobre a possível utilização desse instrumento financeiro como alternativa aos seguros em eventos culturais na província. Para isso são consideradas opções baseadas em temperatura e precipitação dentro de três condados diferentes. Concluindo que mesmo com o risco de base geográfico, a impactar cada uma das regiões, que há potencial capacidade de hedge desse instrumento no objeto analisado.

Ballotta, Fusai, Kyriakou, Papapostolou e Poulialis (2020) buscaram analisar também no segmento do turismo, em especial na região dos Alpes austríacos, a performance das estratégias de *hedging* em estações de ski da região baseados em indexadores de neve e temperatura. Os autores examinaram a habilidade do modelo proposto pelos autores em providenciar uma representação realística dos dados, junto com a variabilidade das variáveis lucro e prejuízo para, posteriormente, determinar o *tradeoff* entre o orçamento destinado a *hedge*. Os autores defendem que os derivativos climáticos foram eficientes em sua função de *hedge*. Entretanto, consideram como desvantagem de as negociações serem, normalmente, de balcão o fato de que há um aumento do risco da contraparte. Como solução, argumentam que a utilização de um bom modelo robusto pode ser uma alternativa válida para o desenvolvimento de um mercado de derivativo climático no futuro.

Wieczorek-Kosmala (2020) afirma que o setor energético é o mais impactado por mudanças climáticas e que essa exposição é de alta frequência e de baixa severidade, ideal para o uso de derivativos climáticos. O autor analisa as empresas de energia da Polônia com o objetivo de entender qual o nível de percepção dessas sobre os riscos climáticos e qual o gerenciamento de risco aplicado. O autor considera que grande parte das empresas analisadas apresentaram todos os fatores relevantes de riscos climáticos e as principais estratégias de mitigação desse tipo de risco. Entretanto, não foram encontradas informações sobre o uso de derivativos climáticos por empresas de energia polonesas. Os autores consideraram como possível trabalho futuro determinar quais os fatores da não utilização de derivativos climáticos por essas empresas.

O quadro 4 apresenta o resumo contendo os principais estudos apresentados sobre o mercado europeu, para fins comparativos.

**Quadro 4: Resumo dos principais estudos do mercado europeu**

<b>Autores</b>	<b>Ano</b>	<b>Continentes</b>	<b>Indexador</b>	<b>Objetivos</b>	<b>Principais Achados</b>
Musshoff, Odening e Xu	2008	Europeu	Agricultura	Analisar a eficiência dos derivativos climáticos no gerenciamento de risco de uma plantação de trigo na Alemanha.	Eficiência do instrumento é comprovada, entretanto o risco de base geográfico impacta o resultado.
Ghiulnara e Viegas	2010	Europeu	-	Autores buscam formas de defender a utilização dos derivativos climáticos em Portugal	Conclusão é a de que para o uso desse instrumento ocorrer deve-se aumentar a visibilidade sobre ele entre as pessoas.
Štulec	2017	Europeu	-	Determinar a eficiência dos derivativos climáticos sob empresas de venda de bebidas na Croácia	A eficiência do produto é confirmada.
Möllmann, Buchholz e Musshoff	2019	Europeu	Agricultura - Vegetação	Autores avaliam o uso de derivativos climáticos em uma plantação de trigo com indexador de vegetação	Os derivativos climáticos com VHI foram mais eficientes no estudo em questão.
Martinez-Salgueiro e Tarrazon-Rodon	2019	Europeu	Turismo - Temperatura e Pluviosidade	Análise da utilização de derivativos climáticos em três condados diferentes na Espanha para determinar o potencial de <i>hedge</i> do instrumento	Como conclusão, os autores relatam que o risco de base geográfica existe, porém não prejudica o uso do instrumento.
Ballotta, Fusai, Kyriakou, Papapostolou e Poulialis	2020	Europeu	Turismo - Neve	Realizam uma análise sobre a viabilidade do uso de derivativos climáticos em estações de ski nos alpes Austríacos	O instrumento é considerado eficiente.
Wieczorek-Kosmala	2020	Europeu	-	Avaliação da percepção de risco climático e eventuais ferramentas de risco associadas as empresas de energia na Polónia	Autor afirma que não foram encontradas informações sobre o uso desse instrumento por empresas energéticas polonesas.

Fonte: Elaboração própria

### 2.7.3 Continente Asiático

Sharma e Vashishtha (2007) realizaram um estudo na Índia com o objetivo de examinar o gerenciamento de risco nos setores de agricultura e energia elétrica. O método consistiu em avaliar o índice de eficiência de derivativos climáticos como uma ferramenta alternativa de gerenciamento de risco e as formas de implementação desses instrumentos. Os autores concluem que em uma economia predominantemente agrícola e de setores de

energia, contratos de derivativos climáticos são mais apropriados por serem flexíveis e terem uma forma gerencial de controlar os riscos climáticos em uma economia.

Outro estudo similar na Índia foi o de Seth, Ansari e Datta (2009) que buscou, por meio de um questionário em seis vilarejos no estado de Rajasthan, determinar qual seria o nível de aceitação de pequenos agricultores que correspondem a um grande percentual da agricultura do país. O estudo foi estruturado em apresentar o conceito de derivativos climáticos e realizar por meio de um esquema de leilão qual o valor que os agricultores aceitariam pagar de prêmio. Como resultado, o estudo determinou que apenas 8,8% dos entrevistados (de um total de 500 questionários) aceitariam utilizar derivativos para *hedge*. Entretanto, os autores salientam que esse percentual indica o mínimo necessário para introduzir derivativos climáticos no mercado sem a necessidade de subsídios do governo.

Já Choi, Shin e Kim (2012) mensuraram os riscos climáticos presentes em empresas do setor de gás natural na Coreia, que sofrem frequentemente altos impactos em suas operações devido a alterações climáticas. Além de demonstrar como o gerenciamento de riscos climáticos por meio de derivativos climáticos afeta a volatilidade do fluxo de caixa das empresas, por meio de testes computacionais. Para alcançar os objetivos desejados, a precificação dos derivativos climáticos foi feita e, posteriormente, analisada. Como resultado, os testes indicaram que o uso desses instrumentos financeiros não apenas reduz a volatilidade do fluxo de caixa das empresas analisadas, mas também aumentaria o lucro.

Ender e Zhang (2015) analisaram a eficiência de derivativos climáticos com indexadores baseados na temperatura como forma de reduzir os riscos de exposição da indústria agrícola chinesa. A análise foi feita sobre plantações de arroz e trigo por meio de opções de venda. E os resultados indicaram que esses contratos foram eficientes ao compensarem os déficits de baixo rendimento devido a variações de temperatura nas plantações.

Kusniyeva (2019) apresentou em seu estudo que o Cazaquistão tem sobre a economia agrícola seguros compulsórios para proteger o mercado. Entretanto, o autor considera que o possível uso de derivativos climáticos neste segmento seria mais vantajoso. Fato que é corroborado ao longo do trabalho que consistiu em analisar a possibilidade de uso do instrumento por meio de entrevistas com produtores locais. O



autor conclui que a utilização dos derivativos climáticos em conjunto com os seguros agrícolas pode trazer vantagens competitivas.

O quadro 5 apresenta o resumo com os principais estudos apresentados sobre o continente asiático.

**Quadro 5: Resumo dos principais estudos do mercado asiático**

<b>Autores</b>	<b>Ano</b>	<b>Continente</b>	<b>Indexador</b>	<b>Objetivos</b>	<b>Principais Achados</b>
Sharma e Vashishtha	2007	Asiático	-	Autores buscam determinar, nos setores da agricultura e energia, se os derivativos climáticos seriam eficientes na Índia	Devido à grande relevância desses dois segmentos na economia da Índia, o uso de derivativos climáticos era apropriado
Seth, Ansari e Datta	2009	Asiático	-	Estudo qualitativo com agricultores em uma região na Índia com o objetivo de determinar o nível de aceitação desses com relação aos derivativos climáticos	Os resultados determinaram que menos de 10% dos entrevistados aceitariam o uso do instrumento. Entretanto os autores ressaltam que o resultado é sem o auxílio de subsídios do governo
Choi, Shin e Kim	2012	Asiático	Gás Natural - Temperatura	Autores buscaram analisar quais os impactos dos derivativos climáticos sobre o fluxo de caixa das empresas	Os testes indicaram que os derivativos conseguiram reduzir a volatilidade do fluxo de caixa
Ender e Zhang	2015	Asiático	Agricultura - Temperatura	Buscaram a eficiência dos instrumentos derivativos indexados pela temperatura em plantações de arroz e trigo na China	Os resultados indicaram que os contratos eram eficientes
Kusniyeva	2019	Asiático	-	Pesquisa qualitativa sobre o uso de derivativos climáticos em contrapartida a seguros compulsórios no Cazaquistão.	Conclusão de que a maior vantagem seria utilizar os dois produtos financeiros em conjunto.

Fonte: Elaboração própria

#### **2.7.4 Continente Africano**

Já no continente africano, em especial na Etiópia, Berhane, Shibabaw, Awgichew e Walelgn (2020) realizaram estudo, englobando 16 cidades, calculando o fator de risco de mercado para derivativos climáticos com indexadores de temperatura a partir dos dados históricos. Os autores relatam que estudos passados calculavam esse fator por meio de uma estimativa a partir de preços de contratos ativos no mercado, que para o caso dos

derivativos climáticos não se torna viável. Como conclusão, os autores relatam que os preços obtidos por meio do método dos dados históricos foram mais precisos do que o gerado com base num fator de risco zero de mercado.

Kermiche e Vuillermet (2015) realizaram a proposta de calcular o preço de derivativos climáticos com indexadores em temperatura 18 países africanos ao longo do continente. O planejamento dos autores foi o de buscar entender o uso de derivativos climáticos para *hedge* das três principais culturas de 18 países africanos diferentes. Os contratos feitos pelos autores foram calculados com base nos dias-graus na considerada temperatura ótima. Entre os resultados encontrados, vale destacar a correlação observada entre os *payoffs* e decréscimo da produção da colheita, demonstrando que há possibilidade de uso desse tipo de instrumento na agricultura.

O quadro 6 apresenta um resumo dos principais estudos apresentados sobre o continente africano.

**Quadro 6: Resumo dos principais estudos do mercado africano**

<b>Autores</b>	<b>Ano</b>	<b>Continente</b>	<b>Indexador</b>	<b>Objetivos</b>	<b>Principais Achados</b>
Berhane, Shibabaw, Awgichew e Walelgn	2020	Africano	Agricultura - Temperatura	Determinar, em 16 cidades da Etiópia e em três culturas diferentes, o preço dos derivativos climáticos por meio de dados históricos	Autores defendem que esse é o melhor método a ser utilizado para precificar derivativos climáticos com mais precisão
Kermiche e Vuillermet	2015	Africano	Agricultura - Temperatura	Determinar os preços dos derivativos das principais culturas de 18 países do continente africano.	Dentre os resultados dos autores, vale destacar a correlação encontrada entre os <i>payoffs</i> e o decréscimo das colheitas

Fonte: Elaboração própria

## 2.8 Mercado Brasileiro e os Riscos Climáticos

O Brasil, por meio do Ministério da Agricultura, Pecuária e Abastecimento (MAPA) oferece um portal com estudos e pesquisas sobre Zoneamento Agrícola de Risco Climático (Zarc). Esse portal foi criado como um estudo técnico- científico em parceria da Embrapa com outros órgãos com o objetivo de auxiliar a contratação de políticas públicas como o seguro rural e a concessão de crédito de custeio oficial.

Ao seguirem as orientações contidas no portal Zarc, os agricultores melhoram seu gerenciamento de risco climático e facilitam seu acesso aos programas oferecidos pelo governo brasileiro, como o Programa de Garantia da Atividade Agropecuária (Proagro) e pelo Programa de Subvenção ao prêmio do Seguro Rural (PSR).

No relatório sobre seguro rural oferecido pelo MAPA, a ocorrência de eventos climáticos adversos e com cada vez maior frequência tem ocasionado prejuízos significativos aos produtores nas regiões agrícolas pelo País, mesmo com a utilização de produtos de alta tecnologia para minimizar os impactos. Assim, o MAPA tende a impulsionar a oferta de seguro rural para os produtores como uma forma de gerenciar o risco climático e auxiliar na permanência do produtor de forma competitiva no agronegócio, mesmo sob condições de perdas patrimoniais ou de frustração de safra (MAPA, 2021).

## **2.9 Estudos Nacionais sobre Derivativos Climáticos**

No Brasil, um estudo feito por Pereira Junior e Malaquias (2019) realizou uma pesquisa exploratória sobre a utilização dos derivativos climáticos no Brasil. Com a análise das notas explicativas de 44 empresas listadas no índice do Ibovespa no ano de 2017, os autores concluíram que não há menção sobre o uso de derivativos climáticos na gestão de riscos.

Raucci, Capitani e Silveira (2017) realizaram um estudo analisando a viabilidade do uso de contratos de derivativos climáticos como instrumento de hedge com foco na cultura de soja na região do Rio Grande do Sul. Os autores desenharam contratos, calcularam os prêmios e a efetividade da operação com base na precipitação da região. Como conclusão os autores defenderam que o hedge obtido com o derivativo climático se mostrou capaz de mitigar os riscos climáticos, diminuindo a variabilidade da receita por hectare além de proporcionar recuperação de parte da perda por estiagem.

Lemos (2014) implementou uma metodologia de precificação por meio de 265 estações meteorológicas no Brasil, com o intuito de analisar de forma não regional, mas nacional sobre a utilização dos derivativos climáticos. O autor percebeu que o principal desafio para a implementação desses instrumentos financeiros é a distribuição de estações meteorológicas de forma igualitária entre as regiões do país. Esse resultado demonstrando o impacto do risco de base geográfica para a precificação, e conseqüentemente,

implementação dos derivativos no país. Entretanto, ele utilizou métodos para aprimorar os dados faltantes no modelo, no caso, por meio do projeto NCEP/NCAR, uma base de dados com o estado da atmosfera terrestre, incorporando observações e modelos de previsão climática.

Alves Neto (2021) realizou um estudo analisando o uso de derivativos climáticos como uma ferramenta de gestão de risco na cultura de soja no estado do Mato Grosso, Brasil. O objetivo do estudo é determinar se o uso desse instrumento financeiro seria aplicável e eficaz para a região, garantindo a estabilidade de renda do produtor. O autor utiliza o modelo de precificação apresentado por Cao e Wei (2004). Após a precificação, o autor analisa por meio de métricas de efetividade (*Value at Risk*, *Certainty Equivalence* e *Mean Root Square Loss*) a possível aplicação desse instrumento no Brasil. Como conclusão o autor determina que dentre todas as métricas utilizadas, o derivativo climático foi considerado como efetivo para o uso no cultivo de soja na região do Mato Grosso.

Outro estudo brasileiro sobre a temática foi conduzido por Silveira e Camilo (2021), que analisaram dentro do mercado energético a possibilidade de uso de derivativos climáticos. Pelo uso de tecnologia de *Blockchain*, os autores optaram por estimar por meio do modelo de reversão à média e pelo uso da simulação de Monte Carlo para precificar uma opção de compra para *hedge* sobre oscilações de temperatura de seis cidades brasileiras para posterior elaboração dos contratos. Como conclusão, os autores afirmam que a tecnologia foi satisfatória em sua função de definir os contratos de derivativos climáticos, sendo uma alternativa para mercados de países de terceiro mundo.

## **2.10 Limitações no Uso de Derivativo Climático**

### **2.10.1 Precificação do Instrumento**

O método mais utilizado para precificação de derivativos corresponde ao modelo de Black Scholes (1973). Esse modelo baseia-se na estratégia de criar um portfólio que replicará o payoff do derivativo, de modo que o risco associado ao derivativo financeiro é eliminado ou mitigado. O modelo é muito utilizado no chamado mercado completo. Young e Zariphopoulou (2002) definem que o mercado financeiro é exemplo de mercado completo quando todas as reivindicações conseguem ser replicadas por meio de estratégias de autofinanciamento. Caso contrário, o mercado é incompleto.

Os derivativos climáticos são um modelo de mercado incompleto, pois o ativo subjacente utilizado é um indexador climático negociável como: o *Heating degree day* (HDD) ou o *cooling degree day* (CDD), precipitação, entre outros. Isto é, para determinar a taxa de juros, os contratos de derivativos usam o preço de mercado de instrumentos líquidos, enquanto os contratos de derivativos climáticos utilizam dados passados, e, portanto, é relevante conseguir dados climáticos com alta acurácia (YOUNG e ZARIPHOPULOU, 2002).

Assim, o modelo de Black Scholes (1973) não consegue ser aplicado de forma eficiente para derivativos climáticos, sendo necessário utilizar algum modelo de mercado incompleto. Trabalhos como o de Botos and Ciomas (2012) tentaram analisar se o modelo de Black Scholes (1973) de fato não poderia ser utilizado. Os autores basearam-se nas premissas de que o modelo deveria seguir uma tendência de reversão da média, mas na prática descobriram que com os dados históricos não era possível alcançar tal resultado.

Já Meissner e Burke (2011) afirmam que mesmo o modelo Black Scholes (1973) exigindo a premissa de um mercado completo, pode-se utilizá-lo em contratos de derivativos climáticos se existir um mercado futuro com valores líquidos de temperatura.

Outros autores tentaram encontrar métodos de precificação que fossem mais flexíveis as características dos derivativos climáticos. Davis (2001) que defendeu como um possível modelo de precificação a utilidade marginal, baseando-se na suposição que os agentes do mercado de derivativos climáticos não seriam representativos, mas que teriam riscos climáticos específicos. Isso foi provado pelo autor por meio do HDD acumulado e dos preços das commodities modelados por movimentos geométricos brownianos, resultando assim nos aos valores dos swaps e das opções.

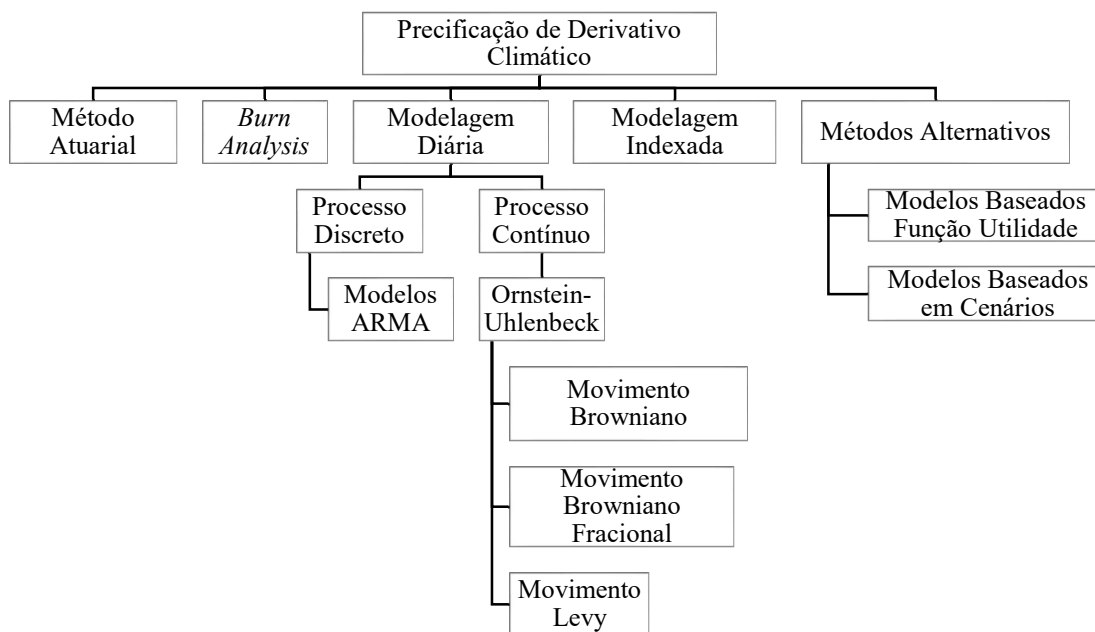
De um modo geral, para que o derivativo climático seja eficiente, é necessário um índice climático formulado de maneira clara, de acordo com o segmento a ser protegido, devendo ainda contar com um método de precificação robusto e transparente. Por meio dessas considerações é factível a diminuição de um possível risco moral e de seleção adversa sobre esses contratos (CONSIDINE, 2000; SPAULDING et al., 2003).

Devido a essas características, em especial que o banco de dados sobre o fenômeno climático em questão seja acurado e de fácil obtenção, os modelos de precificação tendem a serem considerados fatores limitadores sobre a utilização dos derivativos climáticos.

Entretanto, diversos estudos buscam formas de facilitar o cálculo da precificação e tornar o modelo mais eficiente possível ao usuário, por meio de aprimorações matemáticas (LI, 2021; RASULOV e RAIMOVA, 2021; HUSSAIN e ALI, 2021; SILVEIRA e CAMILO, 2021)

Desse modo, não há um método específico para precificação desse tipo de instrumento derivativo. Diversos estudos (ALATON, DJEHICHE e STILLBERGER, 2002; CAO e WEI, 2004; CABRERA, ODENING e RITTER, 2013; SALGUEIRO e TARRAZON-RODON, 2019; BOBRIKOVÁ, 2022) buscam discutir, aprimorar ou apresentar novas técnicas de precificação, como demonstrado na figura 2.

**Figura 2 – Quadro-Resumo dos modelos de precificação de derivativos climáticos**



Fonte: Adaptado de Zapranis e Alexandridis (2013)

### 2.10.1.1. Método Atuarial

Essa abordagem é frequentemente utilizada pelo setor de seguros. Por meio de uma de um banco de dados meteorológico e de previsão que são usados de modo a obter a distribuição de todos os possíveis resultados do indexador. Enquanto os dados históricos

são utilizados para calcular o *payoff* esperado. Sendo esse descontado a taxa livre de risco para assim obter o preço. (JEWSON, 2004)

#### **2.10.1.2. Historical Burn Analysis**

A *historical Burn Analysis* (HBA) é uma clássica abordagem na temática de precificação de derivativos climáticos, sendo essa baseada em simulações de dados históricos. Nesse modelo, o *payoff* médio do derivativo climático é computado sob os últimos  $n$  anos, sendo assim considerada uma abordagem de *benchmark*. A principal premissa do modelo é a de que os registros históricos dos *payoffs* representa uma ilustração precisa da distribuição potencial dos *payoffs*. (ZAPRANIS e ALEXANDRIDIS, 2013).

Por ser o modelo mais simples, apresenta algumas poucas premissas. A primeira é a de que a série temporal de temperatura é assumida como sendo estacionária. Em segundo, os dados para diferentes anos são assumidos como sendo independentes e distribuídos uniformemente. Entretanto, mesmo sendo um método simples de precificação e de fácil implementação ainda é um método com grande chance de erros relevantes. (JEWSON *et al.*, 2015).

#### **2.10.1.3 Modelagem Indexada**

Estudos mais recentes (GEMAN e LEONARDI, 2005; DAVIS, 2001;), buscam modelar diretamente os indexadores de temperatura, como os HDDs, CDDs ou o CAT.

#### **2.10.1.4 Modelagem Diária**

Outra abordagem utilizada é baseada em modelos dinâmicos que simulam diretamente o comportamento futuro da temperatura. Diferentemente da modelagem por indexadores que demanda que a cada indexador (temperatura, pluviosidade, vento etc.) um modelo diferente seja estimado, a modelagem diária utiliza apenas um modelo que é adaptável a contratos distintos sobre uma mesma localização. Entretanto, mesmo sendo um modelo robusto, pequenos erros de especificação podem levar a grandes erros de precificação. (ZAPRANIS e ALEXANDRIDIS, 2013).

### 2.10.1.5 Métodos Alternativos

Como já visto anteriormente, por ser considerado parte de um mercado incompleto, métodos padrões de precificação não podem ser aplicados em derivativos climáticos. Dessa forma, surge na literatura discussões sobre possíveis meios alternativos de cálculos.

Buscando soluções sob a perspectiva de modelos baseados em cenários, Zeng (2000) propõe a utilização de um modelo alternativo da simulação de Monte Carlo. O autor define  $P_A$ ,  $P_N$  e  $P_B$ , como sendo respectivamente, a probabilidade de a variável climática estar acima, perto e abaixo da norma climática. Assume-se que para aproximar a probabilidade o indexador correspondente (HDD ou CDD) está acima, perto ou abaixo da norma climática, respectivamente.

Uma outra abordagem baseada em funções de utilidades, foi proposta por Brockett *et al.* (2006). Devido à ausência de um mercado secundário líquido de derivativos climáticos, os autores avaliam os efeitos nos portfólios. Nesse modelo, o preço limite do derivativo é considerado aquele o qual o comprador é indiferente., em termos de utilidade esperada, a decisão de comprar ou não o contrato.

### 2.10.2 Risco de Base

Tanto o mercado de derivativos climáticos quanto os estudos acadêmicos internacionais estão em constante crescimento. Entretanto, como citam Raucci, Capitani e Silveira (2020) os estudos sobre o uso desse instrumento financeiro como ferramenta na gestão de risco na atividade agrícola brasileira são escassos. Uma das possíveis limitações deve-se ao basis risk (risco de base), não sendo esse risco exclusividade única dos derivativos climáticos. Assaf Neto (2003) exemplifica que um risco de base ocorre como resultado da correlação imperfeita entre o *payoff* pago pelo derivativo e o *payoff* ideal para o *hedge* do comprador, o que gera um *hedge* imperfeito que impede o derivativo de realizar sua função.

Pensando no agronegócio, o risco de base é definido como sendo a correlação imperfeita entre o indexador climático escolhido e o rendimento da colheita em questão. Assim, percebe-se dois componentes no risco de base desse segmento. O primeiro refere-se à diferença geográfica entre o local da plantação/manejo de animais e a estação meteorológica, já que alguns eventos climáticos podem impactar o primeiro, mas não ser



perceptível ao segundo, representando um risco de base geográfica. O segundo componente refere-se ao fato de que o rendimento da colheita não é impactado apenas por indexadores climáticos, mas por outras características climáticas e variáveis biológicas, que podem ser definidos como risco de base de concepção (MÖLLMANN, BUCHHOLZ e MUSSHOF, 2019).

Lopes (2018) apresenta três possíveis riscos de base para os derivativos climáticos: o temporal, o de produto e o geográfico. O risco de base temporal é definido como a diferença entre o período do tempo da exposição do comprador ao evento climático e o período no tempo de referência do contrato. O risco de base do produto ocorre quando a diferença entre o *payoff* do derivativo e o *payoff* ideal necessário para a compensação do prejuízo resultado da exposição ao evento climático é um resultado de precificação errônea do próprio derivativo ou de alguma correlação imperfeita entre o índice utilizado e a atividade a ser protegida. O risco de base geográfica indica a diferença entre o *payoff* do derivativo recebido pelo comprador e o prejuízo resultado da exposição justificada pela diferença de localização entre o local a ser protegido e o local que está a base meteorológica de aferição do índice de indexação do derivativo.

Diversos estudos buscaram formas de minimizar os impactos que poderiam ser gerados por meio de risco de base geográfica. Möllmann, Buchholz e Musshoff (2019) defendem que ao invés de utilizar a coleta de dados meteorológicos que ocasionalmente podem aumentar o risco de base geográfica pode-se utilizar dados adquiridos à distância que independem da distribuição de estações meteorológicas. O exemplo de fonte de dados utilizado pelos autores refere-se a *normalized difference vegetation index* (NDVI).

O NDVI determina a densidade e o vigor da biomassa verde da plantação, indicando qual o nível de saúde da vegetação. Esse indicador consegue explicar o impacto das variações climáticas sobre o local geográfico sem depender do viés que pode surgir ao utilizar derivativos climáticos com indexadores de temperatura e precipitação (MÖLLMANN, BUCHHOLZ e MUSSHOF, 2019).

Por último, Woodard e Garcia (2008) citam o risco de base do produto que ocorre devido a diferença de eficiência entre diferentes instrumentos financeiros. No caso da agricultura, por exemplo, colheitas são impactadas por diferentes níveis de precipitação e temperatura. Assim, o risco de base do produto irá refletir a diferença da eficiência de *hedge* de indexadores de temperatura e de precipitação.

### 3. PROCEDIMENTOS METODOLÓGICOS

O presente trabalho tem duas etapas de procedimento metodológicos. Primeiramente, foi realizado um estudo sobre a existência de derivativos climáticos no Brasil em empresas de capital aberto. Posteriormente, buscou-se determinar a viabilidade desse instrumento como ferramenta de gerenciamento de risco no agronegócio, um dos principais setores impactados por variações climáticas.

Com base no trabalho feito por Vedenov e Barnett (2004) e Raucci, Lanna, Silveira e Capitani (2019) foram realizadas quatro etapas: a coleta dos dados meteorológicos com suas respectivas adaptações e modelagem; a precificação com base no índice climático escolhido para cada respectivo produto; a formulação de duas variáveis baseadas na renda adquirida pelo produtor (renda produtor que não utiliza o contrato e a renda de um produtor que possui o contrato derivativo) para posterior comparação.

Dessa forma, o trabalho utilizou uma metodologia mista (quali-quantitativa) para a coleta e análise dos dados. Logo, para atingir os objetivos específicos a), b) e c) (citados na seção introdução) utilizou-se como fonte de dados os documentos publicados pelas empresas (notas explicativas) e a análise se deu por meio da técnica Análise de Conteúdo.

#### 3.1 Análise de Resultado sobre o Uso de Derivativos Climáticos no Brasil

Para iniciar a análise sobre a viabilidade de uso dos derivativos climáticos no mercado brasileiro, buscou-se investigar se há o uso desse tipo de instrumento no Brasil como ferramenta de hedge para riscos climáticos. Isso foi realizado por meio de um estudo de análise de conteúdo por meio de notas explicativas das empresas analisadas. Bardin (2011) reporta que este tipo de análise visa atingir o armazenamento das informações de forma conveniente e de fácil acesso ao observador, de modo que se obtenha o máximo de informação (aspecto quantitativo), com o máximo de pertinência possível (aspecto qualitativo). Sendo essa, portanto, considerada uma fase preliminar de importância.

A análise de conteúdo seguiu os três principais polos cronológicos essenciais ao processo: (i) a pré análise; (ii) a exploração do material, e (iii) o tratamento dos resultados, a inferência e a interpretação. A primeira etapa de pré análise é composta por algumas atividades e regras, dentre elas a escolha dos documentos a serem submetidos à análise, a

formulação das hipóteses e dos objetivos e, por fim, a elaboração dos indicadores que fundamentem a interpretação final (BARDIN, 2011).

Para cumprir tal objetivo foi feita uma análise sobre as empresas de capital aberto listadas na B3 (antiga Bolsa de Valores, Mercadorias e Futuros de São Paulo – BM&FBovespa) no segmento de “Novo Mercado”. Esse é composto por 204 empresas de grande porte em diversos setores econômicos, o que indica uma boa amostra para determinar se há o uso do instrumento no país. Vale destacar, porém, que muitos contratos de derivativos climáticos são negociados em balcão e não necessariamente podem ser divulgados em demonstrações financeiras. Entretanto, a possibilidade de declaração do instrumento financeiro existir não pode ser precipitadamente negada.

Dentro da amostra selecionada foram analisadas as respectivas demonstrações financeiras padronizadas do ano de 2020 das empresas junto com suas notas explicativas. O intuito era determinar quantas dessas empresas possuíam algum instrumento derivativos para hedge de suas operações e quais seriam esses produtos. Assim, a frequência sobre a incidência de cada instrumento derivativo era quantificada. Dentre as empresas que declararam o uso de derivativos para hedge buscou-se determinar se utilizavam derivativos climáticos.

Em paralelo, por meio das notas explicativas, buscou-se determinar a percepção das empresas sobre potenciais riscos climáticos sobre suas operações. A depender do setor, em especial os mais impactados por variações climáticas (agronegócio, turismo e energético), espera-se que as empresas tenham maior percepção sobre esses riscos e seus impactos. Por meio de uma análise setorial, pode-se inferir quais as percepções das empresas sobre seus riscos climáticos e eventuais ferramentas de mitigação desse tipo de risco.

### **3.2 Coleta de Dados**

Segundo Jewson e Brix (2015) para uma precificação eficiente de derivativos climáticos é importante determinar alguns fatores: o período do contrato (em dias corridos); (ii) a estação meteorológica que será utilizada para medir a variável climática (estação base); (iii) a variável climática a ser analisada e seu índice de agregação (temperatura, pluviosidade etc.); e (iv) a estrutura de precificação dos prêmios do contrato.

Para conseguir realizar a precificação, alguns dados precisam ser obtidos como o período do contrato a depender do produto (período do mês do plantio a colheita) e os dados meteorológicos disponíveis sobre a região. Esses dados foram coletados de bases disponibilizadas pelo Instituto Nacional de Meteorologia (INMET), que mede as variáveis de temperatura e de pluviosidade.

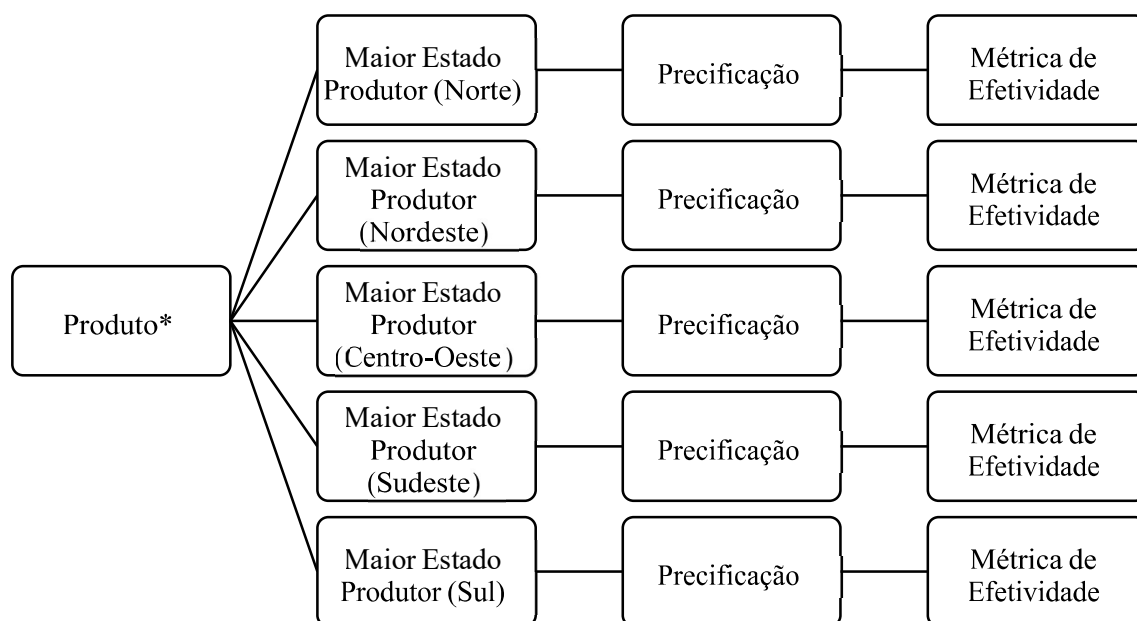
Como os modelos precisam ser compostos por dados mais precisos possíveis, alguns ajustes podem ser feitos para aprimorar o modelo. Em caso de dados faltantes pode-se utilizar outras fontes de informação para complementar. Como no caso de Alves Neto (2021) que utilizou para os dados ausentes, as informações contidas na base do *National Centers for Environmental Prediction* (NCEP) e da NASA POWER para a interpolação. Essa medida utiliza de uma regressão linear simples com a temperatura média da estação meteorológica (INMET) como variável dependente e a temperatura média obtida na NASA POWER<sup>1</sup>, para este estudo, como variável independente. Vale destacar que tal interpolação é relevante mesmo sendo os dados provenientes dos satélites não tão precisos devido as limitações de análise de superfície de solo, mas o uso dessas informações torna-se relevante quando há dados faltantes nas estações meteorológicas.

Baseando-se no estudo de Alves Neto (2021) e Raucci, Capitani e Silveira (2017) nos quais os autores fizeram uma análise sobre a viabilidade de derivativos climáticos sobre a cultura de soja no Brasil, com foco nos estados do Mato Grosso e Rio Grande do Sul, respectivamente. Nesse estudo, buscou-se analisar três dos maiores produtos exportados do Brasil, sendo eles a soja, o milho e a cana-de-açúcar. Dentro de cada produto será escolhido o maior estado produtor da commodity por região (Norte, Nordeste, Centro-Oeste, Sudeste e Sul). No total foram 15 observações analisadas sobre a precificação e a respectiva métrica de efetividade obtida para determinar a aplicabilidade do instrumento no território nacional como um todo. A figura 2, a seguir, demonstra o processo realizado para cada produto agrícola.

---

<sup>1</sup> Acesso a base de dados [POWER | Data Access Viewer \(nasa.gov\)](https://power.larc.nasa.gov/)

Figura 3 – Processo Metodológico do Trabalho



\*Modelo considerado para cada uma das commodities a serem analisadas: soja, milho e cana-de-açúcar.

Fonte: Elaboração própria

Para os respectivos cálculos, foram utilizados os programas Python para a interpolação dos dados meteorológicos e Matlab R2023b para o tratamento desses dados, a determinação do indexador de temperatura e, posteriormente, a precificação do derivativo climático.

### 3.3 Preparação dos dados meteorológicos

Após a obtenção e limpeza dos dados meteorológicos é importante proceder com a modelação da dinâmica das variáveis climáticas. Para isso, é importante analisar a tendência e sazonalidade presentes na série temporal (ALEXANDRIDIS e ZAPRANIS, 2013).

O principal indexador analisado neste trabalho foi a temperatura. Dessa forma serão apresentados os processos utilizados para a modelagem da temperatura. Etapa essa essencial para a definição do preço do derivativo climático. Alaton, Djehiche e Stillberger (2002) apresentam um modelo determinístico, com os parâmetros  $A$ ,  $B$ ,  $C$  e  $\varphi$  a serem estimados, para a temperatura média no tempo  $t$ ,  $T_t^m$  que seria:

$$T_t^m = A + Bt + C \sin(\omega t + \varphi) \quad (5)$$

Em que:

$A, B, C$  e  $\varphi$  = parâmetros a serem estimados;

$t$  = tempo observado.

Entretanto, como a variável temperatura não pode ser considerada determinística, mas sim estocástica, tal modelo citado deve ser alterado com base em alguns processos matemáticos. O primeiro deles é o processo de *driving noise* que tem como função adicionar ruído ao modelo determinístico, o que pode ser feito pelo processo de *Wiener* ( $W_t, t \geq 0$ ). O segundo procedimento a ser realizado é com relação à reversão à média, pois é sabido que mesmo com o aumento da temperatura global, há dias com temperatura mais baixas, isto é, a temperatura não só aumenta dia após dia. Dessa forma, o modelo de temperatura não pode permitir que a temperatura desvie da sua média por períodos longos no tempo. Assim, o processo estocástico que estiver descrevendo a temperatura deve possuir a propriedade de reversão à média. (ALATON, DJEHICHE e STILLBERGER, 2002).

Logo, o novo modelo considerado será:

$$T_t^m = A + Bt + C \sin(2\pi t) + D \cos(2\pi t) + E(4\pi t) \quad (6)$$

Em que:

$A, B, C, D$  e  $E$  = parâmetros a serem estimados;

$t$  = tempo observado.

Com esse modelo, pode-se determinar os parâmetros e analisar a série temporal definindo também a regressão linear da temperatura. Dessa forma, pode-se estipular quantos graus aumentam/diminuem a cada ano.

O próximo procedimento necessário é a criação de um modelo *Autoregressive Integrated Moving Average* (ARIMA) para os resíduos. Além disso, o uso da modelo GARCH para determinar a variância dos resíduos com intuito de modelar a autocorrelação nos resíduos quadrados. Após a calibração do modelo de temperatura, a simulação das temperaturas futuras pode ser realizada de forma mais eficiente.

Para cumprir com todas as etapas de modelagem citadas, utilizou-se do programa Matlab R2023b<sup>1</sup>. O código-texto utilizado, para cada uma das cidades, está disponível no apêndice deste trabalho.

### 3.4. Definindo o *Heating Degree Days* (HDD) e o *Cooling Degree Days* (CDD)

Os indexadores HDD e CDD podem ser obtidos por meio das equações a seguir, onde  $T_i$  representa as temperaturas simuladas.

$$HDD_i = \sum_{i=1}^i \max(T_{base} - T_i, 0) \quad (2)$$

$$CDD_i = \sum_{i=1}^i \max(T_i - T_{base}, 0) \quad (3)$$

Vale destacar que a temperatura base deve ser utilizada a partir do contexto que se encontra. Sendo assim, este estudo usou como temperatura base os valores considerados pelos órgãos competentes da agricultura brasileira como sendo ideal para o plantio e colhimento de cada cultura. O quadro 7 apresenta os valores que foram considerados no estudo.

**Quadro 7: Intervalo da temperatura ideal de plantio (em °Celsius)**

Cultura	Intervalo Ideal de Cultivo		
	Mínimo	Ideal	Máxima
Cana-de-açúcar	20	26	30
Soja	20	25	30
Milho (1ª Safra)	22	24	30
Milho (2ª Safra)			

Fonte: Elaboração própria por meio de dados divulgados pela EMBRAPA

A temperatura base considerada em cada modelo foi a variável “ideal”. Dessa forma, também já se estabeleceu os *strikes* a serem atingidos por essa variável. As temperaturas, que ao longo do ano analisado, forem abaixo do considerado “mínimo” ativam o *strike* e

<sup>1</sup> O Matlab oferece acesso ao MathWorks, que auxilia o usuário sobre diversos tópicos. Há uma página com descrição sobre método de modelagem de temperatura e precificação de derivativos climáticos, baseados nos métodos de Alaton, Djehiche e Stillberger (2002). Disponível em: [Price Weather Derivatives - MATLAB & Simulink Example \(mathworks.com\)](https://www.mathworks.com/help/price_toolbox/price_weather_derivatives_matlab_simulink_example.html)

incrementam o indexador HDD. Enquanto, temperaturas que ultrapassarem do limite máximo da cultura ativam a *strike*, sendo a diferença aplicada no indexador CDD.

Para obter a distribuição do *payoff* da opção utilizou-se fórmula de Alaton, Djehiche e Stillberger (2002), definida como:

$$\chi = \alpha \max\{H_n - K, 0\} \quad (7)$$

Sendo,

$\alpha = Tick\ size;$

$H_n =$  Somatório de HDD no período;

$K = Strike.$

### 3.5 Fórmula de Precificação

O objetivo do trabalho foi analisar a utilização de derivativos climáticos em diferentes produtos advindos do agronegócio. Dessa forma, foco de discussão não foi com relação aos modelos de precificação e seus prós e seus contras, mas sim demonstrar na prática qual o impacto do uso desses instrumentos financeiros.

Dessa forma, utilizou-se a fórmula de precificação apresentada por Alaton, Djehiche e Stillberger (2002), apresentada a seguir, e aplicada por meio de código texto no Matlab R2023b, esse pode ser encontrado no apêndice desse trabalho. A equação do preço da opção,  $p(t)$ , é representada pelo termo exponencial descontando o *payoff* da opção no valor presente ( $e^{-r(t_n-t)}$ ),  $\mu_n$  é o valor esperado do retorno do ativo,  $\sigma_n$  o desvio padrão do retorno do ativo, e  $\Phi(\alpha_n)$  indica a função de distribuição cumulativa (CDF) da distribuição normal avaliada em  $\alpha_n$ .

$$p(t) = e^{-r(t_n-t)} \left[ (K - \mu_n) \left( \Phi(\alpha_n) - \Phi\left(-\frac{\mu_n}{\sigma_n}\right) \right) + \frac{\sigma_n}{\sqrt{2\pi}} \left( e^{-\frac{\alpha_n^2}{2}} - e^{-\frac{1}{2}\left(\frac{\mu_n}{\sigma_n}\right)^2} \right) \right] \quad (8)$$

Em que:

$e$  = número de Euler, valor aproximado de 2,7182;

$\mu_n$  = o valor esperado do retorno do ativo;

$K$  = *Strike*;



$\Phi(\alpha_n)$  = função de distribuição cumulativa;

$\sigma_n$  = desvio padrão do retorno do ativo.

### 3.6 Definição da Indenização

Vedenov e Barnett (2004) apresentam que os contratos de indexadores podem ser estruturados de diferentes maneiras, com estruturas de cobertura e provisões distintas. O foco neste trabalho foi dado ao chamado contrato elementar, o qual ocorre o pagamento de uma indenização condicionada na realização de um determinado indexador, como pode-se observar, a seguir:

$$I_t = \begin{cases} 0 & \text{se } F_t \geq K \\ \frac{K - F_t}{K} & \text{se } F_t < K \end{cases} \theta \quad (9)$$

Em que:

$F_t$  = temperatura observada;

$K$  = *strike* estabelecido para o contrato;

$\theta$  = valor máximo de indenização definido por contrato.

Pela função, percebe-se que a indenização é acionada quando o índice for menor que o *strike* definido para cada cultura. O pagamento será proporcional a máxima indenização ( $\theta$ ), logo, quanto maior for a diferença entre o *strike* e o indexador de temperatura, maior será o *payoff* (RAUCCI, LANNA, SILVEIRA e CAPITANI, 2019).

### 3.7 Cálculo da Eficiência do Instrumento Financeiro

Para determinar a eficiência no quesito de *hedge* do derivativo climático, diversos modelos são discutidos e apresentados pelo meio acadêmico. Neste estudo, foi considerada como ferramenta de eficiência do instrumento, o método aplicado por Raucci, Lanna, Silveira e Capitani (2019).

Para definir a eficiência é necessário calcular a relativa redução da exposição ao risco do produtor (desvio padrão da receita do produto em questão) quando utilizando derivativos climáticos. Para fins de comparação, também é necessário definir a receita no ano  $t$  do produtor sem a utilização do instrumento financeiro ( $R_t$ ), na qual multiplica-se a produção ( $\varphi_{\varphi t}$ ) pelo preço da cultura ( $P_t$ ). Sendo essa definida como:

$$R_t = \varphi_{\varphi t} \times P_t \quad (10)$$

Em que:

$\varphi_{\varphi t}$  = produção obtida em toneladas;

$P_t$  = preço da *commodity*.

A receita do produtor considerando o instrumento derivativo ( $R_t^*$ ) é dada como sendo o acréscimo da indenização ( $I_t$ ) recebida no ano  $t$  e a subtração do prêmio pago pelo derivativo ( $pr$ ), sendo esse último atualizado pela data de expiração do contrato e a taxa de juros livre de risco. Considerando Euler como aproximadamente 2,71828. Sendo assim, a equação é definida como sendo:

$$R_t^* = \varphi_{\varphi t} \times P_t + I_t - pr \times e^{r \times \Delta t} \quad (11)$$

Em que:

$\varphi_{\varphi t}$  = produção obtida em toneladas;

$P_t$  = preço da *commodity*;

$I_t$  = indenização estabelecida pela fórmula (9);

$pr$  = prêmio pago pelo derivativo;

$e$  = número de Euler, aproximadamente 2,71828;

$r$  = taxa de juros livre de risco;

$\Delta t$  = tempo estabelecido de contrato.

## 4. RESULTADOS ESTUDO QUALITATIVO

### 4.1 Estudo sobre o Uso de Derivativos Climáticos no Brasil

Como forma de determinar se há o uso de derivativos climáticos por empresas brasileiras de capital aberto, buscou-se analisar as demonstrações financeiras padronizadas de 204 empresas de diversos setores que compõem o chamado “Novo Mercado” da B3. A escolha desse segmento foi devido ao fato de que as empresas deste grupo são consideradas de alta transparência e governança corporativa, de modo que tornam-se empresas válidas para a análise sobre o gerenciamento de risco, em especial o climático.

#### 4.1.1 Amostra de Empresas que Utilizam Derivativos

A análise de conteúdo focou nas notas explicativas das empresas, por meio da busca pelo termo “derivativos”. Em caso afirmativo de presença do instrumento financeiro nas demonstrações financeiras, a empresa foi incluída no banco de dados. O quadro 8 apresenta um resumo, por grupos setoriais, de quantas empresas divulgaram terem operações com derivativos com o objetivo de *hedge* sobre as suas operações.

**Quadro 8: Número de empresas com derivativos para hedge dentro da amostra analisada**

Setor	Quantidade de Empresas no Setor	Empresas que usam Derivativos para hedge	% Empresas que usam Derivativos para hedge
Agropecuária/Agricultura	14	12	86%
Alimentício	7	7	100%
Aluguel de Carros	6	5	83%
Aviação	1	1	100%
Bens Industriais	17	11	65%
Comércio e Distribuição	14	6	43%
Construção Civil	10	4	40%
Consumo não cíclico	13	13	100%
Energia Elétrica	14	11	79%
Entretenimento	1	1	100%
Exploração de Imóveis	23	10	43%
Financeiro	5	4	80%
Mineração	2	2	100%
Papel e Celulose	3	2	67%
Petróleo, Gás e Biocombustível	11	9	82%
Serv. Médico Hospitalar	19	12	63%

Serviços	14	9	64%
Siderurgia	1	1	100%
Tecnologia da Informação	13	6	46%
Telecomunicações	9	6	67%
Utilidade Pública - Água	7	3	43%
Total	204	135	66%

Fonte: Elaboração Própria

Inicialmente, pode-se perceber que, por meio da amostra analisada o número de empresas no Novo Mercado que divulgaram em notas explicativas a utilização de derivativos de uma forma geral, como instrumento de *hedge* representou um total de 66% da amostra totalizando 135 empresas. Assim, para continuar a análise, uma nova amostra foi criada composta por essas empresas com derivativos.

#### **4.1.2 Instrumentos Derivativos Utilizados**

A gama de instrumentos específicos dentro do universo denominado derivativos é extensa, desde instrumentos mais comuns como swap, opções, a termo e futuro, existem também instrumentos considerados exóticos, como é o caso dos derivativos climáticos. Logo, buscou-se determinar quais os específicos instrumentos derivativos que as empresas operam. Para isso, buscou-se nas notas explicativas os detalhes dos instrumentos financeiros das respectivas empresas. Os resultados encontrados foram resumidos no quadro 9.

**Quadro 9: Instrumentos derivativos utilizados por cada uma das empresas**

Setor	Empresas com Derivativos	Instrumentos						
		SWAP	Termo	Futuro	Opções	<i>Non Deliverable Forward</i>	Outros	Não Descreve
Agropecuária/Agricultura	12	8	3	7	6	7	0	1
Alimentício	7	5	1	4	1	4	0	1
Aluguel de Carros	5	4	0	0	1	3	0	0
Aviação	1	1	0	0	1	1	0	0
Bens Industriais	11	8	0	0	2	3	0	1
Comércio e Distribuição	6	5	2	0	0	3	0	0
Construção Civil	4	2	0	0	0	0	0	2
Consumo não cíclico	13	10	0	2	2	6	0	1
Energia Elétrica	11	9	3	0	2	4	1	1
Entretenimento	1	0	0	0	0	1	0	0
Exploração de Imóveis	10	10	1	0	0	1	0	0
Financeiro	4	2	0	0	1	0	0	2
Mineração	2	2	2	0	1	0	0	0
Papel e Celulose	2	2	0	0	1	2	0	0
petróleo, Gás e Biocombustível	9	5	2	0	4	3	0	1
Serv. Médico Hospitalar	12	8	0	0	0	1	0	3
Serviços	9	8	0	1	1	1	0	0
Siderurgia	1	0	0	0	0	1	0	0
Tecnologia da Informação	6	3	0	0	0	1	0	2
Telecomunicações	6	3	2	0	1	0	0	3
Utilidade Pública - Água	3	3	0	0	0	0	0	0
Total	135	98	16	14	24	42	1	19

Fonte: Elaboração Própria

Dentre as 135 empresas, 19 optaram por não detalharem quais os instrumentos derivativos são utilizados para mitigação de riscos. Assim, 116 empresas utilizam ao menos um instrumento para hedge de suas operações. Dessa forma, buscou-se entender as possíveis motivações para a utilização destes produtos financeiros. Para isso, leu-se as justificativas disponibilizadas em notas explicativas de cada empresa e o resultado obtido encontra-se no quadro 10 em forma resumida.

#### 4.1.3 Principais Motivos Apresentados para o Uso de Derivativos

**Quadro 10: Principais motivos divulgados pelas empresas para a utilização de derivativos**

Setor	Empresas com Derivativos	Principais Razões de Uso			Não citam
		Variação Cambial	Variação Taxa de Juros	Variação Preço Commodities	
Agropecuária/Agricultura	12	11	7	9	0
Alimentício	7	6	2	3	1
Aluguel de Carros	5	5	2	0	0
Aviação	1	1	1	0	0
Bens Industriais	11	10	5	1	0
Comércio e Distribuição	6	6	2	0	0
Construção Civil	4	4	2	0	0
Consumo não cíclico	13	12	3	1	1
Energia Elétrica	11	11	6	2	0
Entretenimento	1	1	0	0	0
Exploração de Imóveis	10	5	4	0	3
Financeiro	4	2	0	0	2
Mineração	2	2	2	2	0
Papel e Celulose	2	3	3	3	0
petróleo, Gás e Biocombustível	9	6	4	4	0
Serv. Médico Hospitalar	12	12	5	0	0
Serviços	9	8	1	0	0
Siderurgia	1	1	1	1	0
Tecnologia da Informação	6	6	1	0	0
Telecomunicações	6	5	3	0	1
Utilidade Pública - Água	3	1	3	0	0
Total	135	118	57	26	8

Fonte: Elaboração Própria

De um modo geral, nota-se que as empresas citaram três principais motivos para a aquisição de derivativos, todos relacionados a possíveis variações de fatores financeiros, como: câmbio, taxa de juros e preço de commodities. O motivo mais citado

(87,40%) foi com relação à variação cambial, em especial relacionados ao dólar, e a segunda justificativa mais citada (42,22%) foi a taxa de juros nacional. Por último, a motivação de *hedge* contra eventuais variações no preço de *commodities* foi a menos citada (19,25%) pelo fato de que não são todos os setores que se monitoram essa variável. Apenas 8 empresas, das 135 analisadas, optaram por não justificarem aos usuários sobre possíveis motivos para aquisição do instrumento.

De um modo geral, percebe-se que não foram divulgados possíveis instrumentos derivativos como forma de minimizar impactos relacionados a riscos climáticos. Assim, surge um novo questionamento sobre se há divulgação por parte dessas empresas sobre esses riscos em suas operações. Para isso, buscou-se procurar nas notas explicativas os termos “climáticos” ou “climáticas” para definir a posição da respectiva empresa sobre o assunto. O resultado de tal etapa encontra-se no quadro 11, o qual demonstra um resumo sobre a quantidade de empresas que se encaixaram no perfil procurado.

#### 4.1.4 Empresas que Divulgam em Notas Explicativas sobre Riscos Climáticos

**Quadro 11: Quantidade de Empresas que Citaram Riscos Climáticos sobre suas Atividades**

Setor	Riscos Climáticos divulgados em Nota Explicativa	Total de Empresas com Derivativos	% Percepção sobre Risco Climático
Agronegócio	6	12	50%
Alimentício	2	7	29%
Aluguel de Carros	1	5	20%
Aviação	0	1	0%
Bens Industriais	1	11	9%
Comércio e Distribuição	2	6	33%
Concessão	0	2	0%
Construção Civil	0	2	0%
Consumo não cíclico	1	13	8%
Energia Elétrica	5	11	45%
Entretenimento	0	1	0%
Exploração de Imóveis	0	10	0%
Financeiro	0	4	0%
Mineração	1	2	50%

<b>Papel e Celulose</b>	2	2	100%
<b>petróleo, Gás e Biocombustível</b>	0	9	0%
<b>Serv. Médico Hospitalar</b>	0	12	0%
<b>Serviços</b>	0	6	0%
<b>Serviços Educacionais</b>	0	3	0%
<b>Siderurgia</b>	0	1	0%
<b>Tecnologia da Informação</b>	0	6	0%
<b>Telecomunicações</b>	0	6	0%
<b>Utilidade Pública - Água</b>	1	3	33%
<b>Total</b>	22	135	
<b>Total de Empresas com Riscos Climáticos (T)</b>		<b>22</b>	
<b>Total de Empresas no Novo Mercado (NM)</b>		<b>204</b>	
<b>Total de Empresas com Derivativos (D)</b>		<b>135</b>	
<b>% Empresas com Riscos Climáticos nas Operações (T/NM)</b>		<b>11%</b>	
<b>% Empresas com Derivativos e Riscos Climáticos nas Operações (T/D)</b>		<b>16%</b>	

Fonte: Elaboração Própria

Analisando os resultados apresentados no quadro 11, percebe-se que as empresas que citaram os riscos climáticos em suas operações foram 22 empresas de diversos setores. Assim, um percentual de 16% das empresas com derivativos relatara sobre algum impacto de fatores climáticos em suas operações. E um percentual de 11% das empresas do Novo Mercado relatara sobre esse mesmo aspecto.

O segmento de papel e celulose foi o único que reconheceu em sua totalidade esse tipo de risco sobre suas operações. Seguido do setor agropecuário/agricultura e energético, respectivamente.

Como já citado anteriormente, alguns setores tendem a serem mais impactados por fenômenos climáticos devido as suas atividades, como o agronegócio, o turismo e o setor energético. Assim, esperava-se que esses segmentos apresentassem uma maior divulgação ou percepção sobre esses possíveis riscos climáticos em suas operações ou a existência de alguma ferramenta para mitigá-los.



## 4.2 Fatos relevantes encontrados em Notas Explicativas

Como já citado anteriormente, no segmento do agronegócio espera-se que a percepção e ações acerca da temática de fatores climáticos seja mais assídua. Assim, ao observar as notas explicativas das empresas que compõem esse segmento percebe-se alguns pontos relevantes a serem destacados, estes foram resumidos no quadro 12.

**Quadro 12 – Notas Explicativas setor Agropecuária/Agricultura**

Empresa	Principal Foco Sobre o Clima	Trecho da Nota Explicativa
<b>Agrogalaxy Participações S.A.</b>	Percepção do Risco	"Os preços da soja e do milho estão sujeitos à volatilidade resultante das <b>condições climáticas(...)</b> "
<b>Boa Safra Sementes S.A.</b>	Auditoria de Provisão	"Relatório da Auditoria (KPMG) pede a determinação de níveis adequados de provisão pois há a necessidade de julgamentos mais significativos com relação aos riscos climáticos assumidos pela empresa. "
<b>Boa Safra Sementes S.A.</b>	Mitigação do Risco	"A empresa com o objetivo de mitigar os riscos das <b>condições climáticas</b> , determina que seus produtores fiquem a 150 km das UBS."
<b>Jalles Machado S.A.</b>	Mitigação do Risco	"A empresa tem processos extensivos com recursos alocados para acompanhar e mitigar os riscos, incluindo inspeções regulares de situação da lavoura. "
<b>Jalles Machado S.A.</b>	Percepção do Risco	"O cultivo de cana-de-açúcar é exposto a riscos de danos de <b>mudanças climáticas</b> . As condições climáticas podem causar volatilidade no setor sucroenergético e, conseqüentemente, no resultado operacional da companhia, por influenciarem as safras aumentando ou reduzindo colheitas."
<b>Minerva S.A.</b>	Percepção do Risco	"A companhia está exposta à volatilidade dos preços do gado, cuja variação resulta de fatores fora do controle da Administração, como <b>fatores climáticos</b> , volume da oferta, custos de transporte, políticas agropecuárias e outros."
<b>SLC Agrícola S.A.</b>	Percepção do Risco	"Regiões produtoras de milho ao Sul enfrentaram <b>condições climáticas</b> adversas para desenvolvimento das lavouras de milho primeira safra, onde dados de produção ainda deverão confirmar os volumes produzidos."
<b>Vittia Fertilizantes e Biológicos S.A.</b>	Auditoria de Provisão	"A determinação dos níveis adequados da provisão para perdas de crédito esperadas exige que a Companhia exerça julgamentos significativos relacionados às incertezas no ambiente macroeconômico, aos <b>fatores climáticos(...)</b> "

Fonte: Elaboração Própria

Pelo quadro 12, nota-se que as empresas do segmento retratam os fatores climáticos por meio de três vertentes: (i) demonstrando sua percepção sobre a temática; (ii) buscando apresentar soluções para mitigar esses riscos; e (iii) indagação advinda de auditoria externa sobre as provisões de riscos climáticos serem mais acuradas possível.

Por meio do quadro 13, observa-se qual é o principal foco atribuído ao risco climático para as empresas em questão.

**Quadro 13 – Notas Explicativas setor Alimentício**

Empresa	Principal Foco Sobre o Clima	Trecho da Nota Explicativa
Camil Alimentos	Mitigação do Risco	"Os principais insumos utilizados no processo produtivo da Companhia e suas controladas são commodities agrícolas, cujos preços sofrem flutuações em função das políticas públicas de fomento agrícola, sazonalidade de safras e <b>efeitos climáticos</b> , podendo acarretar perda em decorrência da flutuação de preços no mercado. Para minimizar esse risco, a Companhia monitora permanentemente as oscilações de preço nos mercados nacional e internacional. A Companhia historicamente tem obtido resultados satisfatórios em relação as suas metas de mitigação deste risco."
M Dias Branco S.A	Mitigação do Risco	"A Companhia acompanha o mercado mundial de commodities, monitorando os fatores que impactam a formação dos preços, tais como períodos de safra, <b>eventos climáticos</b> e decisões de política econômica."

Fonte: Elaboração Própria

Observando o segmento de alimentação, as duas empresas que citaram o clima nas suas notas explicativas foram: a Camil Alimentos e M Dias Branco S.A. A primeira reconhece os efeitos climáticos sobre seu principal insumo que é uma *commodity* agrícola, além de demonstrar que tem um gerenciamento de risco voltado para minimizar os efeitos sobre suas operações. A M Dias Branco também afirma monitorar os efeitos de eventos climáticos sobre as *commodities*. Percebe-se, assim, uma percepção sobre os riscos climáticos na operação deste segmento, com a apresentação de um gerenciamento de risco mais amplo focado no monitoramento das mudanças.

Já no setor de locação de automóveis, os impactos climáticos são citados como consequência do funcionamento do segmento. Isso ocorre, devido a poluição ocasionada pelo uso de veículos à base de combustíveis fósseis. O que pode ser observado pelo quadro 14.

**Quadro 14 – Notas Explicativas setor Aluguel veículos**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>Movida Participações S.A.</b>	Efeito de Causa	"Ainda na frente climática, a Companhia realizou em 2020 o mapeamento de todos os <b>riscos climáticos</b> que possam impactar nossos negócios, com base na metodologia Força-Tarefa sobre Divulgações Financeiras Relacionadas ao Clima (Task Force on Climate-related Financial Disclosures – TCFD)."

Fonte: Elaboração Própria

No setor relacionado a bens industriais, apresentado pelo quadro 15, a empresa Metalfrio Solutions S.A. relata nas notas explicativas que a depender da região, o clima impacta a demanda por seus produtos. Em locais com climas quentes frequentes ao longo do ano, demandam maior necessidade por produtos refrigerados. Já nas regiões subtropicais, que há uma distinção mais nítida entre inverno e verão, pode-se perceber quais períodos seriam os mais quentes e que demandam maior necessidade sobre os produtos da empresa. Logo, a empresa tem uma percepção sobre os impactos da variação climática sobre as suas operações.

**Quadro 15 – Notas Explicativas setor Bens Industriais**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>Metalfrio Solutions S A</b>	Percepção do Risco	"A empresa monitora outros riscos sobre Sazonalidade. As regiões tropicais e equatoriais apresentam <b>clima</b> quente durante o ano todo, propiciando a venda de bebidas, sorvetes e congelados em todas as estações do ano. Portanto, se torna difícil notar uma sazonalidade clara nessas regiões. Já nas regiões subtropicais, por terem um contraste maior entre verão e inverno, com consumo de bebidas geladas e sorvetes mais acentuado no verão, é possível notar as vendas de freezers e refrigeradores um pouco mais fortes nos períodos de pré-estação verão e verão".

Fonte: Elaboração Própria

O setor de comércio e distribuição é composto por duas empresas, a São Martinho S.A. e a Americanas S.A.. De acordo com as respectivas notas explicativas, ambas têm percepção clara sobre os impactos das variáveis climáticas sobre suas operações. Em especial, as Americanas S.A. apresentam relatório completo sobre a mitigação e percepção dos riscos climáticos da empresa, consideram desde eventos extremos de precipitação que podem ocasionar perdas diversas até eventos com

mudanças de temperaturas que podem gerar custos maiores. O quadro 16 apresenta o os detalhes expostos em notas explicativas.

**Quadro 16 – Notas Explicativas setor de Comércio e Distribuição**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>São Martinho S.A.</b>	Percepção do Risco	"Conforme já divulgado anteriormente, ao longo da safra 19/20 a Companhia processou 22,6 milhões de toneladas de cana-de-açúcar, apresentando um aumento de 10,7% em relação ao volume de cana processado na safra anterior, refletindo o crescimento de 11,7% na produtividade média dos canaviais (TCH) no período, resultado de melhores <b>condições climáticas</b> observadas durante a safra."
<b>Americanas S.A.</b>	Percepção do Risco/Mitigação do Risco	"Há um relatório completo sobre identificação de riscos e oportunidade. Nesse são citadas as interferências das <b>mudanças climáticas</b> nas operações da entidade. Dentro as <b>ameaças climáticas</b> mais relevantes: (a) Eventos extremos de precipitação que podem ocasionar risco agudo de inundações de lojas físicas e <i>FullFillment Centers</i> ; e (b) Mudanças de temperatura que podem ocasionar riscos de ondas de calor que afetará o bem-estar dos associados e demandará mais gasto energético para a armazenagem de produtos."

Fonte: Elaboração Própria

No ramo de consumo não cíclico, a empresa Natura Holding S.A. demonstra de forma sucinta pelo quadro 17, que fatores climáticos podem impactar suas operações. Entretanto não há maiores detalhes sobre quais os riscos e possíveis ferramentas de gerenciamento de risco climático.

**Quadro 17 – Notas Explicativas setor consumo não cíclico**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>Natura Holding S.A.</b>	Percepção do Risco	" <b>Mudanças climáticas</b> como um todo que afetariam os resultados operacionais."

Fonte: Elaboração Própria

Outro setor com alto impacto sobre as variações climáticas é o de energia. O quadro 18 apresenta o resumo do que foi encontrado nas notas explicativas das respectivas empresas do setor. De um modo geral, nota-se que as companhias relatam sobre os impactos dos fatores climáticos sobre suas operações, algumas detalhando um pouco mais que outras. Entretanto, pode-se perceber que nenhuma empresa detalhou algum tipo de ferramenta de gerenciamento de risco climático como foi o caso das

organizações do setor agrícola que citaram atividades de monitoramento sobre as variáveis climáticas.

**Quadro 18 – Notas Explicativas setor de energia**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>AES Tiete Energia S.A.</b>	Percepção do Risco	"As <b>variações climáticas</b> podem ocasionar excedentes ou escassez de produção hidrelétrica em determinadas regiões e em determinados períodos do ano, uma vez que o volume de energia gerado pelas usinas hidrelétricas depende do índice pluviométrico e do volume acumulado de água em seus reservatórios, que determinam o despacho otimizado do ONS."
<b>Alcoeste Bioenergia Fernandópolis S.A.</b>	Percepção do Risco/Mitigação de Risco	"As atividades operacionais de cultivo de cana de açúcar estão expostas ao risco de danos decorrentes das <b>mudanças climáticas</b> , pragas e doenças, incêndios florestais e outras forças naturais. A companhia tem processos extensivos com recursos alocados para acompanhar e mitigar esses riscos, incluindo inspeções regulares de situação da lavoura de cana de açúcar."
<b>Ampla Energia e Serviços S.A.</b>	Percepção do Risco	"Empresa relata sobre os possíveis <b>impactos climáticos</b> sobre suas operações. No relatório de 2020 citam os impactos do el nino diminuindo as receitas em torno de 20%"
<b>Light S.A.</b>	Percepção do Risco/Mitigação de Risco	"A Light é comprometida em analisar as <b>mudanças climáticas</b> de forma a mitigar os riscos assumidos pela atividade fim da empresa."
<b>Neoenergia S.A.</b>	Percepção do Risco	"O Grupo está atento à gestão do <b>risco climático</b> em seus negócios e às oportunidades rumo à transição energética e descarbonização da economia"

Fonte: Elaboração Própria

No setor da mineração, a empresa que relatou acompanhar fatos relacionados a risco climáticos foi a Vale S.A., como pode ser observado no quadro 19. A empresa cita ter conhecimento das mudanças climáticas e seus possíveis impactos nas atividades.

**Quadro 19 – Notas Explicativas setor de mineração**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>Vale S.A.</b>	Percepção do Risco	"Além disso, em linha com as recomendações do TCFD, a Vale realizou a resiliência de seu portfólio frente aos cenários de <b>mudanças climáticas</b> , bem como avaliação para <b>riscos climáticos</b> , passos importantes para a gestão de sua agenda climática. Os estudos estão disponíveis no Portal ESG, na seção de Mudanças Climáticas."

Fonte: Elaboração Própria

O setor de papel e celulose também é impactado de forma direta por variáveis de natureza climática. Como pode ser observado pelo quadro 20, as duas empresas reportam a percepção do risco climático em suas atividades. Entretanto, a empresa Suzano S.A. relata que para mitigar tais riscos a empresa busca monitorar as alterações climáticas por meio das estações meteorológicas.

**Quadro 20 – Notas Explicativas setor de papel e celulose**

<b>Empresa</b>	<b>Principal Foco Sobre o Clima</b>	<b>Trecho da Nota Explicativa</b>
<b>Dexco S.A.</b>	Percepção do Risco	"A produtividade média poderá variar em função de idade, rotação, <b>condições climáticas</b> , qualidade das mudas, incêndios e outros riscos naturais. "
<b>Suzano S.A.</b>	Percepção do Risco/Mitigação de Risco	"A Companhia administra os riscos financeiros relacionados com a atividade agrícola de forma preventiva. Para redução dos riscos decorrentes de <b>fatores edafoclimáticos</b> , é realizado monitoramento através de estações meteorológicas (...)"

Fonte: Elaboração Própria

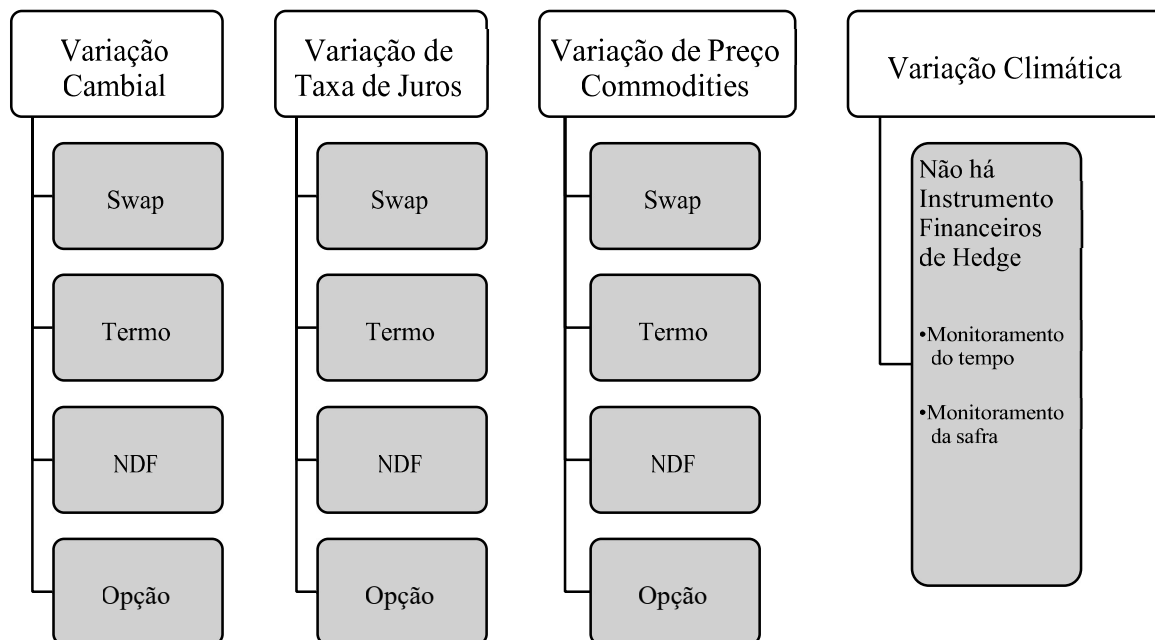
Logo, percebe-se que as empresas citam de forma breve e genérica sobre os impactos operacionais que podem ocorrer devido às alterações climáticas que são de difícil previsibilidade. Em alguns casos, como solução são utilizadas estratégias amplas como o caso do monitoramento climático que, por si só, não isenta a empresa de sofrer impactos operacionais ou financeiros.

Como conclusão do estudo, observa-se que as empresas não são aversão ao uso de derivativos com o objetivo de *hedge*, utilizando para proteção contra variação cambial, taxa de juros ou sobre as oscilações dos preços das *commodities*. Assim, a possível existência de uma ferramenta financeira com foco nas variações climáticas pode ser uma vantagem competitiva e que proteja o patrimônio do produtor contra eventuais perdas operacionais.

Além disso, pode-se determinar que há a percepção de que o risco climático impacta as atividades operacionais, mas por ser um evento de difícil previsibilidade e inerente ao negócio, não haveria ferramentas de gerenciamento deste tipo de risco para minimizar seus impactos patrimoniais. No gerenciamento de risco, de modo geral, existem diversas ferramentas de mitigação de riscos financeiros com ampla divulgação, diferentemente do risco de variação climática. A figura 4 ilustra a utilização ampla de

instrumentos financeiros como forma de mitigar riscos financeiros, e o questionamento sobre o uso de instrumentos financeiros para riscos climáticos.

**Figura 4 – Riscos Encontrados e seus Instrumentos Financeiros**



Fonte: Elaboração própria

Stulec, Petljak e Bakovic (2016) citaram que as organizações tendem a ignorarem os riscos climáticos ou apenas cooperam com as consequências das adversidades climáticas com os recursos a disposição. Entretanto, o gerenciamento sobre os riscos climáticos estão se tornando cada vez mais necessários em uma economia com possibilidade de crise e devido à alta volatilidade das variáveis climáticas.

Os derivativos climáticos seriam uma solução para aumentar a oferta as empresas de ferramentas de gerenciamento de risco, em especial nos setores mais impactados por esses fatores ambientais. De modo que os principais produtos do agronegócio brasileiro serão precificados e analisados por métricas de efetividade para determinar a aplicabilidade efetiva desse produto financeiro no Brasil.

## 5. ESTUDO SOBRE APLICABILIDADE DE UM MODELO DE DERIVATIVO CLIMÁTICO

### 5.1 Determinação do Maior Produtor de cada região

Para determinar qual o maior produtor, no período de 2006 a 2022, buscou-se por meio do Instituto Brasileiro de Geografia e Estatística (IBGE) os dados relacionados a produtividade de cada uma das culturas (cana-de-açúcar, soja, milho 1ª e 2ª safra). Assim, calculou-se a produtividade média de cada estado para elencar os maiores produtores de cada região. O quadro a seguir apresenta o resumo das informações obtidas.

**Quadro 21 – Resumo dos estados produtores (em toneladas) de cada produto – média de 2006 a 2022**

Região/Unidades Federativas	Maiores produtores (em toneladas)			
	Cana-de-açúcar	Milho (1ª safra)	Milho (2ª safra)	Soja
<b>Norte</b>				
Acre	66.070,16	78.662,73	11.293,90	7.448,10
Rondônia	89.930,62	237.048,40	<b>836.206,60</b>	740.804,70
Amazonas	296.718,20	26.360,07	172,14	0,00
Roraima	3.962,66	14.433,91	29.974,80	51.769,51
Pará	864.014,20	<b>539.928,10</b>	266.933,90	998.312,30
Amapá	4.053,43	1.989,28	0,00	43.063,51
Tocantins	<b>1.921.523,00</b>	280.526,80	563.874,00	<b>1.832.616,00</b>
<b>Nordeste</b>				
Maranhão	2.822.302,00	840.587,30	637.946,70	2.027.096,00
Piauí	891.927,90	1.067.646,00	201.362,80	1.604.525,00
Ceará	1.422.200,00	525.424,90	905,80	4.168,93
Rio Grande do Norte	3.829.562,00	28.958,62	0,00	0,00
Paraíba	6.166.286,00	89.651,21	0,00	23,00
Pernambuco	16.064.176,00	84.797,05	43.469,86	0,00
Alagoas	<b>23.272.519,00</b>	34.047,70	43.934,47	5.913,89
Sergipe	2.687.872,00	471.769,10	<b>683.855,60</b>	0,00
Bahia	5.735.190,00	<b>1.731.865,00</b>	474.648,70	<b>4.155.449,00</b>
<b>Sudeste</b>				
Espírito Santos	3.710.429,00	57.309,23	6.451,10	0,00
Minas Gerais	65.648.106,00	<b>5.681.671,00</b>	1.215.442,00	<b>4.146.638,00</b>
Rio de Janeiro	4.383.231,00	11.315,67	2.611,80	0,00
São Paulo	<b>363.462.141,30</b>	2.812.336,00	<b>1.484.308,00</b>	2.388.004,00
<b>Sul</b>				
Paraná	<b>47.402.734,00</b>	<b>5.339.841,00</b>	<b>9.516.777,00</b>	<b>15.274.949,00</b>
Santa Catarina	407.736,30	3.097.485,00	0,00	1.749.384,00
Rio Grande do Sul	984.979,70	4.943.765,00	0,00	12.886.094,00
<b>Centro Oeste</b>				
Mato Grosso	18.440.382,00	425.819,10	<b>18.500.382,00</b>	<b>25.959.578,00</b>
Mato Grosso do Sul	41.674.993,00	298.564,70	6.361.006,00	7.064.647,00
Goiás	<b>58.972.462,00</b>	<b>2.297.585,00</b>	5.441.544,00	9.470.072,00
Distrito Federal	24.611,67	228.140,20	167.806,50	205.174,20

Fonte: Elaboração Própria - Dados obtidos pela base de dados SIDRA do IBGE



Importante destacar, que de acordo com a tabela anterior, o milho foi dividido em duas categorias: 1ª safra e 2ª safra (conhecido popularmente como safrinha). Isso ocorre, pois, a produção de milho no Brasil ocorre na primeira safra (semeio concentrado na primavera/verão) e na segunda safra (verão/outono). Sendo a última uma safra de contexto de sucessão de culturas, cultivadas geralmente depois do semeio e colheita de soja (SANCHES, ALVES e BARROS, 2018).

Com as informações obtidas pelo IBGE, determinou-se os maiores produtores das respectivas regiões do país, considerando a produtividade média em toneladas, no período de setembro de 2006 a dezembro de 2022. Tal análise foi realizada com cada uma das *commodities*.

Além disso, vale destacar que foi determinada uma principal cidade produtora de cada estado considerando dois critérios: a necessidade de haver uma estação meteorológica na cidade em questão e, conjuntamente, ser uma cidade produtora.

### 5.1.1 Cana-de-açúcar

De acordo com o quadro, conclui-se que serão consideradas no modelo de derivativos climáticos os seguintes estados: Tocantins – 1.921.523 toneladas (Norte), Alagoas – 23.272.519 toneladas (Nordeste), São Paulo – 363.462.141 toneladas (Sudeste), Paraná - 47.402.734 toneladas (Sul) e Goiás – 58.972.462 toneladas (Centro Oeste). A figura 4 apresenta o mapa do Brasil com os cinco maiores produtores de cana-de-açúcar de cada região em destaque.

**Figura 5 – Mapa do Brasil com os cinco principais produtores regionais de cana de açúcar**



Fonte: Elaboração Própria

De acordo com relatório emitido pelo CONAB (2023), mais de 50% da produção nacional vem da região sudeste do país. Em grande parte devido as condições favoráveis da região. Variáveis climáticas como temperatura e precipitação são de grande impacto nesse tipo de commodities, sendo assim, constantemente monitoradas por órgãos responsáveis e produtores. O quadro 8 resume as variações climáticas que impactaram as plantações como um todo, indicando que os riscos climáticos são relevantes ao setor.

**Quadro 22 – Resumo das variações climáticas de cada estado definido como maior produtor regional de cana-de-açúcar (média 2006 a 2022)**






Ano	Região	Estado	Meses											
			Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2021	Sudeste	São Paulo												
2022														
2021	Centro-Oeste	Goiás												
2022														
2021	Nordeste	Alagoas												
2022														
2021	Norte	Tocantins												
2022														
2021	Sul	Paraná												
2022														

Fonte: Elaboração Própria

\*Altas temperaturas

\*\*Também excesso de precipitações

**Legenda:**

	Clima Favorável
	Falta de Chuva
	Baixa Temperatura
	Sem Previsão
	Excesso de Chuva

A cana-de-açúcar apresenta diversos subprodutos de extrema relevância à economia brasileira, desde a produção de açúcar até etanol total (milho e cana-de-açúcar). Sendo o subproduto açúcar abastecido, em grande parte, pelas regiões norte e nordeste, com maior destaque para a segunda. A produção de etanol também é feita com grande participação das regiões norte e nordeste. Sendo relevante citar que o estado de Tocantins é o grande produtor de cana-de-açúcar com foco em produção de etanol, sendo umas das maiores fábricas do subproduto na região.




Devido ao elevado nível de sacarose, a planta necessita de condições térmicas e hídricas adequadas. Desse modo, a temperatura mínima ideal para o desenvolvimento vegetativo adequado da cana-de-açúcar é de 20° Celsius. Com relação à precipitação, a quantidade de água necessária para a cultura atingir o máximo potencial é em torno de 1200 a 1300 milímetros.<sup>1</sup>

Para o uso do contrato de derivativo, buscou-se o calendário agrícola da cultura de cana-de-açúcar para determinar o tempo de plantio e colheita. Desse modo, consegue-se definir o tempo ideal do contrato de derivativo. O quadro 23 apresenta o resumo da época de plantio e colheita da cultura.

**Quadro 23 – Calendário Agrícola – Cana-de-açúcar por região**

Estado	Cidade	CANA DE AÇÚCAR											
		Primavera			Verão			Outono			Inverno		
		Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set
Tocantins	Pedro Afonso												
Alagoas	Coruripe												
Goiás	Mineiros												
São Paulo	Barretos												
Paraná	Maringá												

Fonte: Elaboração própria com base em dados da Sifreca- Esalq/USP

	Plantio
	Colheita
	Plantio/Colheita

Pelo quadro 23, pode-se perceber que o plantio da cana ocorre em um período de no mínimo 3 meses, em locais mais quentes (norte, nordeste e centro-oeste), e um período maior de 6 meses em regiões mais frias (sudeste e sul). Já a colheita é realizada em um mesmo intervalo de tempo para todos os estados, um período de 6 meses.

### 5.1.2 Soja

De acordo com o quadro de maiores produtores, conclui-se que serão consideradas no modelo de derivativos climáticos sobre milho (1ª safra) os seguintes estados: Tocantins – 1.832.616 toneladas (Norte), Bahia – 4.155.449 toneladas (Nordeste), Minas Gerais – 4.146.638 toneladas (Sudeste), Paraná – 15.274.949 toneladas

<sup>1</sup> Informações obtidas na página da Embrapa sobre relação entre cultura e clima da cana-de-açúcar. [Clima - Portal Embrapa](#)

(Sul) e Mato Grosso – 25.959.578 toneladas (Centro Oeste). A figura 6 apresenta o mapa do Brasil com os cinco maiores produtores de milho (1ª safra) de cada região destacada.

**Figura 6 – Mapa do Brasil com os cinco principais produtores regionais de soja**



Fonte: Elaboração Própria

A produção de soja brasileira é de alta relevância no país, sendo essa concentrada nas regiões sul e centro-oeste com 78,2% da área. E, recentemente, a região conhecida como MATOPIBA (composta pelos estados: Maranhão, Tocantins, Piauí e Bahia) está ganhando mais espaço na agricultura da região (EMBRAPA, 2020)

**Quadro 24 – Resumo das variações climáticas de cada estado definido como maior produtor regional de soja (média 2006 a 2022)**






Ano	Região	Estado	Meses											
			Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2021	Sudeste	Minas Gerais	Verde	Verde	Verde	Verde						Verde	Verde	Verde
2022			Verde	Verde	Amarelo	Verde						Verde	Verde	Verde
2021	Centro-Oeste	Mato Grosso	Verde	Verde	Verde	Verde						Verde	Verde	Verde
2022			Verde	Verde	Verde	Verde	Verde				Verde	*	Verde	Verde
2021	Nordeste	Bahia	Verde	Verde	Verde	Verde						Verde	Verde	Verde
2022			Verde	Verde	Verde	Verde	Verde					Verde	Verde	Verde
2021	Norte	Tocantins	Verde	Verde	Verde	Verde						Verde	Verde	Verde
2022			Verde	Verde	Verde	Verde	Verde					Verde	Verde	Verde
2021	Sul	Paraná	Verde	Verde	Verde	Verde						Verde	Verde	Verde
2022			Verde	Verde	Verde	Verde	Verde				Verde	**	Verde	Verde

Fonte: Elaboração Própria

\*Alta temperatura

\*\*Também excesso de precipitação

**Legenda:**

	Clima Favorável
	Falta de Chuva
	Baixa Temperatura
	Sem Previsão
	Excesso de Chuva

De acordo com um relatório emitido pelo EMBRAPA (2020) a produção de soja é dependente das chuvas, de modo que a ocorrência de secas acaba por aumentar os custos dos produtores para irrigação. Tal fato, em adição ao demonstrado pelo quadro 24, com as variações climáticas registradas no plantio de soja, corroboram com a necessidade de se precaver contra riscos climáticos que impactam o operacional dos agricultores.




Também pode-se observar pelo quadro 24 que em algumas localizações foram possíveis observar mais de uma adversidade. Como exemplo, o Mato Grosso que apresentou em outubro de 2022 problemas advindos da falta de chuva com altas temperaturas, impactando o nível de produção da região. Nesse mesmo período, na região do estado do Paraná, ocorreram eventos relacionados a temperaturas baixas ao extremo e, ainda grande volume de pluviosidade.

Para o uso do contrato de derivativo, buscou-se o calendário agrícola da cultura de soja para determinar o tempo de plantio e colheita. Desse modo, consegue-se definir o tempo ideal do contrato de derivativo. O quadro 25 apresenta o resumo da época de plantio e colheita da cultura.

**Quadro 25 – Calendário Agrícola – Soja por região**

Estado	Cidade	SOJA											
		Primavera			Verão			Outono			Inverno		
		Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set
Tocantins	Campos Lindos												
Bahia	Correntina												
Mato Grosso	Sapezal												
Minas Gerais	Unai												
Paraná	Clevelândia												

Fonte: Elaboração própria com base em dados relatório de safra da Conab

	Plantio
	Colheita
	Plantio/Colheita

Pelo quadro 25, pode-se perceber que o plantio da soja ocorre em um período de 3 meses e na mesma época (outubro a dezembro). Pode-se observar que a colheita também ocorre por um intervalo de tempo semelhante entre todos os produtores de soja escolhidos nesta amostra, indicando a necessidade de um período de 4 meses de colheita. Dois estados apresentam um período intermediário que ocorre a fase conjunta de plantio e colheita, são esses: Bahia e Paraná.

### 5.1.3 Milho (1ª Safra)

De acordo com a tabela, conclui-se que serão consideradas no modelo de derivativos climáticos sobre milho (1ª safra) os seguintes estados: Pará – 539.928 toneladas (Norte), Bahia – 1.731.865 toneladas (Nordeste), Minas Gerais – 5.681.671 toneladas (Sudeste), Paraná – 5.339.841 toneladas (Sul) e Goiás – 2.297.585 toneladas (Centro Oeste). A figura 7 apresenta o mapa do Brasil com os cinco maiores produtores de milho (1ª safra) de cada região destacada.

**Figura 7 – Mapa do Brasil com os cinco principais produtores regionais de milho (1ª safra)**



Fonte: Elaboração Própria

Sanches, Alves e Barros (2018) reafirmam a importância do milho para o Brasil, ao citarem que todas as unidades da federação participam do cultivo do cereal de modo que esse cultivo exibe elevada importância em termos de segurança alimentar. Já que com a grande quantidade produzida de milho ele é destinado tanto para a subsistência (em pequenas áreas) quanto para comercialização. Para essa commodity os riscos climáticos

são também baseados em variações de temperatura e precipitação. O quadro 26 resume as variações climáticas que impactaram as plantações como um todo, indicando que os riscos climáticos são relevantes ao setor.

**Quadro 26 – Resumo das variações climáticas de cada estado definido como maior produtor regional de milho (1ªsafra) - (média 2006 a 2022)**

Ano	Região	Estado	Meses											
			Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2021	Sudeste	Minas Gerais	■	■	■	■	■	■	■	■	■	■	■	■
2022			■	■	■	■	■	■	■	■	■	■	■	■
2021	Centro-Oeste	Goiás	■	■	■	■	■	■	■	■	■	■	■	
2022			■	■	■	■	■	■	■	■	■	■	■	
2021	Nordeste	Bahia	■	■	■	■	■	■	■	■	■	■	■	
2022			■	■	■	■	■	■	■	■	■	■	■	
2021	Norte	Pará	■	■	■	■	■	■	■	■	■	■	■	
2022			■	■	■	■	■	■	■	■	■	■	■	
2021	Sul	Paraná	■	■	■	■	■	■	■	■	■	■	■	
2022			**	**	**	■	■	■	■	■	■	■	■	

Fonte: Elaboração Própria

\*Presença de geadas/granizo

\*\*Altas temperaturas

**Legenda:**

■	Clima Favorável
■	Falta de Chuva
■	Baixa Temperatura
■	Sem Previsão
■	Excesso de Chuva

Para conseguir atingir seu máximo potencial de produção, o milho necessita de índices climáticos nos níveis considerados ótimos. A temperatura apresenta uma relação direta com o processo metabólico da planta, em temperaturas mais altas o processo é acelerado e em períodos mais frios o metabolismo tende a diminuir. Essa oscilação metabólica deve ocorrer dentro do limite tolerado que é compreendido entre 10° Celsius e 30°Celsius. Dentro do intervalo, a temperatura ideal para o desenvolvimento do milho na casa dos 24° Celsius. Já com relação à precipitação, a cultura de milho é muito dependente da variável água. A ocorrência de déficit hídrico nesse tipo de cultura pode ocasionar danos em todas as fases de cultivo. Assim, durante o seu ciclo produtivo a quantidade de água ideal de consumo da planta está em torno de 600 milímetros. (EMBRAPA, 2010)

Para o uso do contrato de derivativo, buscou-se o calendário agrícola da cultura de milho (1ª safra) para determinar o tempo de plantio e colheita. Desse modo, consegue-se definir o tempo ideal do contrato de derivativo. O quadro 27 apresenta o resumo da época de plantio e colheita da cultura.

**Quadro 27 – Calendário Agrícola – Milho (1ª safra) por região**

Estado	Cidade	MILHO 1º SAFRA											
		Primavera			Verão			Outono			Inverno		
		Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set
Tocantins	Pedro Afonso												
Alagoas	Coruripe												
Goiás	Mineiros												
São Paulo	Barretos												
Paraná	Maringá												

Fonte: Elaboração própria com base em dados relatório de safra da Conab

	Plantio
	Colheita
	Plantio/Colheita

Pelo quadro 27, pode-se perceber que o plantio do milho (1ª safra) ocorre em um período de 3 meses para os estados nas regiões norte e nordeste. E para o restante, ocorre num período de 4 meses. Já com relação a colheita, em todos os estados ocorre num período de 4 meses, com exceção do Paraná que utiliza um período de cinco meses para o processo de colheita.






#### 5.1.4 Milho (2ª Safra)

De acordo com a tabela, conclui-se que serão consideradas no modelo de derivativos climáticos sobre milho (2ª safra) os seguintes estados: Rondônia – 836.206 toneladas (Norte), Sergipe – 683.855 toneladas (Nordeste), São Paulo – 1.484.308 toneladas (Sudeste), Paraná – 9.516.777 toneladas (Sul) e Mato Grosso – 18.500.382 toneladas (Centro Oeste). A figura 8 apresenta o mapa do Brasil com os cinco maiores produtores de milho (2ª safra) de cada região.





**Legenda:**

	Clima Favorável
	Falta de Chuva
	Baixa Temperatura
	Sem Previsão
	Excesso de Chuva




Pode-se perceber com o quadro 10, elaborado como resumo dos relatórios mensais emitidos pela Conab sobre as safras de grãos do Brasil, que as variações climáticas são recorrentes e que impactam de alguma forma o processo de cultivo do grão.

Para o uso do contrato de derivativo, buscou-se o calendário agrícola da cultura de milho (2ª safra) para determinar o tempo de plantio e colheita. Desse modo, consegue-se definir o tempo ideal do contrato de derivativo. O quadro 27 apresenta o resumo da época de plantio e colheita da cultura.

**Quadro 29 – Calendário Agrícola – Milho (2ª safra) por região**

		MILHO 2º SAFRA											
Estado	Cidade	Primavera			Verão			Outono			Inverno		
		Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set
Rondônia	Vilhena				Plantio	Plantio	Plantio			Colheita	Colheita	Colheita	
Sergipe	Carira						Plantio				Colheita	Colheita	
Mato Grosso	Primavera do Leste				Plantio	Plantio	Plantio		Colheita	Colheita	Colheita	Colheita	
São Paulo	Itapeva					Plantio	Plantio	Plantio		Colheita	Colheita	Colheita	Colheita
Paraná	Clevelândia				Plantio	Plantio	Plantio	Plantio	Colheita	Colheita	Colheita	Colheita	Colheita

Fonte: Elaboração própria com base em dados relatório de safra da Conab

	Plantio
	Colheita
	Plantio/Colheita

## 5.2. Apresentação Estatística Descritiva dos dados meteorológicos

Para conseguir alcançar os objetivos propostos é válido realizar uma análise generalizada dos dados meteorológicos obtidos na amostra em questão. No quadro 16, apresenta-se um resumo com alguns aspectos relevantes sobre os dados, como média, mínimo, máximo, desvio padrão, variância e mediana. Além disso, o número de observações consideradas foram de 11.323, representando dados obtidos desde 1º de janeiro de 1992 até a data de 31 de dezembro de 2022.

Quadro 30: Estatística Descritiva dos dados meteorológicos

<b>Cultura</b>	<b>Região</b>	<b>Estado</b>	<b>Cidade</b>	<b>Observações</b>	<b>Média</b>	<b>Mediana</b>	<b>Desvio Padrão</b>	<b>Min</b>	<b>Máx</b>	<b>Variância</b>
<b>Cana-de-açúcar</b>	<b>Norte</b>	<b>Tocantins</b>	<b>Pedro Afonso</b>	11323	26.81	26.54	1.63	21.99	38.10	2.65
	<b>Nordeste</b>	<b>Alagoas</b>	<b>Coruripe</b>	11323	25.94	26.00	1.90	21.63	34.63	3.61
	<b>Centro Oeste</b>	<b>Goiás</b>	<b>Mineiros</b>	11323	22.68	23.01	2.51	7.58	34.04	6.32
	<b>Sudeste</b>	<b>São Paulo</b>	<b>Barretos</b>	11323	23.45	23.86	2.97	9.25	32.92	8.80
	<b>Sul</b>	<b>Paraná</b>	<b>Maringá</b>	11323	22.42	23.12	3.79	5.30	33.14	14.35
<b>Soja</b>	<b>Norte</b>	<b>Tocantins</b>	<b>Campos Lindos</b>	11323	26.50	26.00	2.14	18.47	35.43	4.57
	<b>Nordeste</b>	<b>Bahia</b>	<b>Correntina</b>	11323	24.81	24.61	2.20	14.60	37.50	4.85
	<b>Centro Oeste</b>	<b>Mato Grosso</b>	<b>Sapezal</b>	11323	23.98	24.11	2.24	10.33	33.15	5.03
	<b>Sudeste</b>	<b>Minas Gerais</b>	<b>Unaí</b>	11323	23.41	23.39	2.48	12.74	32.87	6.13
	<b>Sul</b>	<b>Paraná</b>	<b>Clevelândia</b>	11323	17.93	18.68	4.19	0.51	29.87	17.64
<b>Milho (1ªsafra)</b>	<b>Norte</b>	<b>Pará</b>	<b>Paragominas</b>	11323	26.42	26.05	1.59	22.09	34.61	2.53
	<b>Nordeste</b>	<b>Bahia</b>	<b>Luiz Eduardo Magalhães</b>	11323	23.74	23.55	1.89	15.73	30.90	3.56
	<b>Centro Oeste</b>	<b>Goiás</b>	<b>Jataí</b>	11323	22.74	23.18	2.66	3.01	37.40	7.05
	<b>Sudeste</b>	<b>Minas Gerais</b>	<b>Uberaba</b>	11323	22.08	22.45	2.66	7.41	32.30	7.08
	<b>Sul</b>	<b>Paraná</b>	<b>São Mateus do Sul</b>	11323	17.96	18.53	4.26	1.44	27.37	18.12
<b>Milho (2ªsafra)</b>	<b>Norte</b>	<b>Rondônia</b>	<b>Vilhena</b>	11323	24.06	24.05	2.03	10.05	34.50	4.11
	<b>Nordeste</b>	<b>Sergipe</b>	<b>Carira</b>	11323	24.85	25.19	2.22	18.69	31.14	4.93
	<b>Centro Oeste</b>	<b>Mato Grosso</b>	<b>Primavera do Leste</b>	11323	21.98	22.01	2.03	11.13	32.35	4.11
	<b>Sudeste</b>	<b>São Paulo</b>	<b>Itapeva</b>	11323	19.56	19.89	3.73	4.33	36.59	13.88
	<b>Sul</b>	<b>Paraná</b>	<b>Clevelândia</b>	11323	17.93	18.68	4.19	0.51	29.87	17.64

Fonte: Elaboração Própria

Acerca dos resultados obtidos por meio do quadro anterior, pode-se perceber algumas características relevantes de serem discutidas em cada uma das culturas apresentadas. Primeiramente, analisando a cultura de cana-de-açúcar, entende-se que no Paraná, em especial na cidade de Maringá, a variância da temperatura foi a mais alta (14,35). Tal fato indica que o município enfrentou uma maior volatilidade climática na amostra em questão, com temperaturas mínimas na faixa dos 5° Celsius e máximas de 33° Celsius.

De acordo com o Embrapa (2022) a cultura da cana -de-açúcar é diretamente relacionada a alterações climáticas. De modo que há restrições de locais que poderiam plantar tal cultura. A temperatura média ideal de crescimento da cultura, com alta garantia de produção e rendimento, varia entre 22° e 30° C. Entretanto, temperaturas abaixo de 20°C podem começar a prejudicar a produção da cultura. No caso deste estudo, as cidades das regiões Centro Oeste, Sudeste e Sul sofreram alguns dias com temperaturas abaixo de 10°Celsius, de modo que a plantação da cultura pode ter sofrido impactos. Além disso, todas as cinco maiores produtoras regionais tiveram máximas acima dos 30°Celsius, podendo impactar de forma negativa a produção.

A cultura de soja melhor se adapta a temperaturas do ar entre 20°C e 30°C, assim é considerado como temperatura média ideal para o crescimento da leguminosa 25°Celsius. Assim, crescimentos abaixo desta faixa podem ocasionar impactos negativos na produção da cultura. Em especial, pode-se citar que o crescimento da soja é pequeno ou quase nulo em temperaturas menores ou iguais a 10° Celsius, e que temperaturas acima de 40°C também impactam negativamente na produção, na medida que provocam distúrbios na floração e diminuem a capacidade de retenção das vagens, problema esse que ainda pode ser agravado caso ocorra, simultaneamente, com um déficit hídrico. (ABRASS, 2020)

Pelo quadro 28, percebe-se que todas as cinco cidades analisadas na cultura de soja apresentaram mínimas menores que 20°Celsius. Dentre essas, a cidade de Clevelândia no Paraná, apresentou uma média de 17,93°Celsius indicando que as temperaturas da cidade saíram bastante do intervalo ideal de crescimento da soja. Com

relação a extrapolação da temperatura máxima de produção da soja, percebe-se que nenhuma cidade conseguiu ultrapassar tal limite da soja (40°Celsius).

A cultura do milho, incluindo a 1ªsafra e 2ªsafra, tem como temperatura média ideal para seu crescimento em 24°C. O milho apresenta rendimentos de produção diferentes a depender da temperatura, assim, abaixo dos 10°C, o crescimento das plantas é quase nulo. Já acima dos 30°C, o rendimento dos grãos decresce quando exposto por uma noite inteira a tal temperatura, devido ao consumo dos produtos metabólicos elaborados durante o dia. (EMBRAPA, 2010)

De acordo com o quadro 28, a temperatura média de todas as dez cidades que plantam milho está dentro do intervalo de temperatura ideal de plantio. Observando detalhadamente, algumas cidades registraram alguns dias com valores máximos maiores de 30°C, entretanto, para representar um impacto negativo na cultura é essencial o contato prolongado da cultura com tal temperatura. Tal fato não pode ser validado com apenas a observação do alcance da temperatura máxima. Já com relação à temperatura mínima atingida, de acordo com relatório sobre cultivo do milho elaborado pela EMBRAPA (2010), o metabolismo do milho diminui instantaneamente o que já impacta seu rendimento. Assim, pode-se observar que grande parte das cidades localizadas nas regiões Centro-Oeste, Sudeste e Sul as temperaturas mínimas foram abaixo de 10° Celsius. Indicando que, em alguns períodos a temperatura foi um fator negativo na produtividade da cultura.

**Quadro 31: Resultados dos indexadores totais de temperatura**

Cultura	Estado	Cidade	Total indexadores no período (2006-2022)	
			HDD	CDD
Cana-de-açúcar	Tocantins	Pedro Afonso	1.312,79	7.688,10
	Alagoas	Coruripe	4.212,88	5.259,31
	Goiás	Mineiros	19.942,22	641,50
	São Paulo	Barretos	18.576,33	1.149,93
	Paraná	Maringá	21.293,94	1.614,38
Soja	Tocantins	Campos Lindos	331,74	15.253,97
	Bahia	Correntina	3.337,74	6.903,42
	Mato Grosso	Sapezal	3.849,51	32.306,63
	Minas Gerais	Unai	6.655,31	4.636,26
	Paraná	Clevelândia	37.176,68	171,76
Milho (1ªsafra)	Pará	Paragominas	13,64	15.068,50

	Bahia	Luiz Eduardo Magalhães	5.365,51	3.720,16
	Goiás	Jataí	9.716,88	3.172,01
	Minas Gerais	Uberaba	12.492,97	2.144,00
	Paraná	São Mateus do Sul	37.000,45	245,43
Milho (2ªsafra)	Rondônia	Vilhena	3.363,15	6.157,84
	Sergipe	Carira	4.325,08	8.126,12
	Mato Grosso	Primavera do Leste	11.919,06	1.733,58
	São Paulo	Itapeva	26.531,89	1.432,36
	Paraná	Clevelândia	37.176,68	171,76
TOTAL			264.594,45	117.597,02

Fonte: Elaboração própria

Complementarmente, o quadro mostra o HDD e CDD acumulado ao longo do período histórico de 2006 a 2022. Pode-se observar que na cultura de cana-de-açúcar, no HDD, as regiões centro oeste, sudeste e sul apresentaram um maior acúmulo do índice HDD, indicando que essas regiões sofreram mais com impactos negativos sobre a produção da cultura. Já no índice de CDD, o acumulado não foi tão grande quanto no HDD. Entretanto, os estados das regiões norte e nordeste foram os que tiveram maior índice acumulado de CDD, demonstrando que em alguns períodos a temperatura foi maior que a máxima de 30° Celsius.

Já na cultura de soja, o estado com maior número de HDD foi o Paraná, com um indicador acumulado de 37.176,68, no período. Tal fato demonstra que as baixas temperaturas que ocorreram no Paraná, também afetaram a produção da soja. Outro estado com valor de indexador relevante na análise foi o Mato Grosso com um indexador CDD acumulado de 32.306,63. Tal resultado demonstra que o estado teve dias com temperaturas altas acima do esperado para a cultura de soja.

Na cultura do milho, com foco na 1ª safra, percebe-se que novamente o estado do Paraná apresentou um indexador HDD alto, especialmente quando comparado aos outros componentes da amostra. O segundo estado com o maior indexador HDD acumulado é Minas Gerais com 12.492,97. Para o CDD, o estado do Pará apresentou o maior indexador acumulado, com aproximadamente 15.069, indicando que em alguns dias a temperatura foi acima da considerada ideal para a cultura.

Na safrinha, cultura do milho 2ª safra, percebe-se o mesmo padrão citado anteriormente, o qual os estados das regiões centro oeste, sudeste e sul apresentam maior variação com base no indexador HDD. Enquanto os estados do norte e nordeste

apresentam o maior CDD. Relevante salientar que de um modo geral percebe-se que o indexador HDD está mais presente sobre os principais estados produtores das *commodities* estudadas.

Outro fato relevante a se destacar é com relação ao estado do Paraná, que esteve presente como o maior acumulador de HDD de todas as culturas analisadas. Isso demonstra que o estado está com constantes eventos climáticos adversos as temperaturas, e como já visto anteriormente, a depender do quão baixa foi a temperatura há o maior risco de danificação das culturas. Podemos citar também os impactos climáticos no estado de São Paulo que apresentou, do mesmo modo anterior, altos índices de HDD indicando a probabilidade de impactos na produtividade das culturas da região.

Logo, pode-se perceber que o índice de temperatura HDD é maior que o CDD nas cidades que fazem parte da amostra. Isso indica que, para as culturas analisadas, os dias mais frios tendem a ocorrerem mais ou terem uma amplitude de temperatura maior, em comparação com a temperatura considerada ideal para cada uma das culturas.

### **5.3 Precificação do Instrumento Derivativo**

Para precificar o instrumento foi utilizado o código disponibilizado no Apêndice para Matlab R2023b para cada uma das cidades e as respectivas *commodities*. O quadro apresenta um resumo dos contratos elaborados para cada uma das cidades. As durações dos contratos variaram entre 90 ou 120 dias, a depender da localização e do produto.

Com relação ao strike, cada cultura assumiu um valor baseado na temperatura considerada como inadequada para cultivo, e que conseqüentemente prejudicaria o desenvolvimento da cultura.

Para um efeito comparativo, foram determinados dois indexadores: o *heating degree day* e *cooling degree day*, as cidades que têm os dois indexadores apresentavam condições para isso. Isto é, cidades nas quais as temperaturas não alcançavam o *strike* requerido em momento algum não tiveram esse indexador calculado

**Quadro 32: Resultado da Precificação da cultura da cana-de-açúcar**

CULTURA DE CANA DE AÇÚCAR						
	Estado	Cidade	Graus-Dias	Dias	Call	Put
Norte	Tocantins	Pedro Afonso	HDD	90	9,1341	3,2496
			CDD	90	85,7345	0,0419
Nordeste	Alagoas	Coruripe	HDD	90	11,246	1,6495
			CDD	90	203,5313	0,835
Centro Oeste	Goiás	Mineiros	HDD	90	280,5708	3,7238
			CDD	90	1,3354	9,4211
Sudeste	São Paulo	Barretos	HDD	120	277,4488	6,7088
			CDD	120	3,9125	7,5652
Sul	Paraná	Maringá	HDD	120	107,2539	0,1662
			CDD	120	59,5708	0,9885

Fonte: Elaboração própria

Com relação a cultura de cana-de-açúcar, os dias considerados para o cálculo do contrato estavam de acordo com o prazo estipulado pela Conab como sendo o período de plantio da cultura. Nas regiões norte, nordeste e sudeste o calendário de plantio é de 90 dias, já na região sudeste e sul o tempo de plantio é maior, sendo assim de 120 dias. Os preços obtidos para as *calls* foram mais discrepantes entre si, diferentemente dos preços estabelecidos para as *puts* que apresentaram valores mais próximos entre si.

**Quadro 33: Resultado da Precificação da cultura de soja**

CULTURA DE SOJA						
	Estado	Cidade	Graus-Dias	Dias	Call	Put
Norte	Tocantins	Campos Lindos	HDD	90	9,8171	2,7941
			CDD	90	97,7536	6,0451
Nordeste	Bahia	Correntina	HDD	120	27,0083	1,1764
			CDD	120	70,8554	0,4627
Centro Oeste	Mato Grosso	Sapezal	HDD	90	36,1615	0,822
			CDD	90	58,1223	0,5702
Sudeste	Minas Gerais	Unai	HDD	90	33,8062	0,8573
			CDD	90	48,5061	0,8828
Sul	Paraná	Clevelândia	HDD	120	65,0371	0,6817
			CDD	120	69,251	0,688

Fonte: Elaboração própria

No caso da cultura de soja, os preços foram estabelecidos considerando, em grande parte dos casos, 90 dias de contrato. O mesmo só não foi considerado nos estados da Bahia e Paraná que precisaram de um número maior de dias para plantio, sendo considerados 120 dias para fins de precificação. Com relação aos preços, observa-se que



as *puts* foram valores próximos entre as diferentes localidades, menos no caso do Tocantins que apresentou valores maiores da *put*.

**Quadro 34: Resultado da Precificação da cultura de milho (1ª safra)**

CULTURA DE MILHO (1ª SAFRA)						
	Estado	Cidade	Graus-Dias	Dias	Call	Put
Norte	Pará	Paragominas	HDD	90	52,7521	3,2496
			CDD	90	208,1475	0,0321
Nordeste	Bahia	Luiz Eduardo Magalhães	HDD	90	235,9508	5,0394
			CDD	90	44,2186	0,8339
Centro Oeste	Goiás	Jataí	HDD	90	246,3815	1,9803
			CDD	90	49,8858	0,8509
Sudeste	Minas Gerais	Uberaba	HDD	90	293,2408	4,5858
			CDD	90	28,7382	1,8155
Sul	Paraná	São Mateus do Sul	HDD	120	575,6628	3,9261
			CDD	120	12,683	4,4677

Fonte: Elaboração própria

Para a cultura do milho, em especial a 1ª safra, para fins de definição do prazo dos contratos foram considerados 90 dias de plantio, com exceção do estado do Paraná que realiza o processo de plantio num prazo maior de 120 dias. Tempo esse o necessário para manter a temperatura da cultura de milho no intervalo ideal de temperatura. Com relação as *calls*, percebe-se que os valores tendem a serem maiores em contratos de HDD, com exceção do estado do Pará. Para os contratos de *put*, todos os valores obtidos foram próximos uns aos outros. Além disso, todas as localidades tiveram uma *put* de HDD maior que a de CDD, com exceção do estado do Paraná.

**Quadro 35: Resultado da Precificação da cultura de milho (2ª safra)**

CULTURA DE MILHO (2ª SAFRA)						
	Estado	Cidade	Graus-Dias	Dias	Call	Put
Norte	Rondônia	Vilhena	HDD	90	28,3808	1,355
			CDD	90	8,1841	0,0985
Nordeste	Sergipe	Carira	HDD	30	261,2145	1,9244
			CDD	30	257,3047	1,8424
Centro Oeste	Mato Grosso	Primavera do Leste	HDD	90	113,8211	0,0535
			CDD	90	16,2739	6,0451
Sudeste	São Paulo	Itapeva	HDD	90	224,6857	6,0493
			CDD	90	31,201	6,049
Sul	Paraná	Clevelândia	HDD	120	471,7044	5,0306
			CDD	120	26,421	5,031

Fonte: Elaboração Própria

E, por último, a cultura do milho (2ª safra) conhecida como safrinha, por ser uma cultura praticada no contexto de entre safras, essa tende a ocorrer muitas vezes em ambientes que favorecem o crescimento do milho em detrimento de outra cultura. Percebe-se que muitas fazendas da cultura de soja realizam, após a colheita dela, o plantio da safrinha de milho.

Observando no quadro 33, novamente o número de dias de contrato, normalmente são considerados 90 dias, com exceção do estado do Paraná que exige um plantio dentro do prazo de 120 dias. Ademais, percebe-se que as *calls* apresentam valores muito maiores e que divergem consideravelmente ao se considerar o indexador. Já no caso das *puts*, do mesmo modo que ocorreu em outras culturas, os valores são mais próximos entre si,

#### **5.4 Eficiência do derivativo climático considerando a receita do produtor**

Para determinar a eficiência do instrumento derivativo em questão, buscou-se simular a receita obtida por um produtor de cada uma das cidades para posterior comparação com a receita obtida com a utilização de contrato de derivativos climáticos. Assim, como o propósito é a utilização do instrumento como forma de proteção contra eventuais perdas operacionais e, conseqüentemente, impactos sobre a receita do produtor. Deste modo, utilizou-se para simulação as *put options* com os dois indexadores de temperatura com o intuito de definir possíveis impactos.

Quadro 36: Simulação da Receita do Produtor pelo índice de Temperatura HDD

Cultura	Estado	Cidade	Put	HDD		Percentual Alteração (B x A)
				Receita sem contrato (A)	Receita com contrato (B)	
Cana-de-açúcar	Tocantins	Pedro Afonso	3,2496	R\$ 17.379.869,92	R\$ 17.384.731,24	0,028%
	Alagoas	Coruripe	1,6495	R\$ 39.535.153,47	R\$ 39.563.207,48	0,071%
	Goiás	Mineiros	3,7238	R\$ 225.594.379,92	R\$ 226.992.132,23	0,620%
	São Paulo	Barretos	6,7088	R\$ 829.374.669,95	R\$ 831.007.954,50	0,197%
	Paraná	Maringá	0,1662	R\$ 143.299.873,17	R\$ 144.926.173,82	1.135%
Soja	Tocantins	Campos Lindos	2,7941	R\$ 10.141.197,35	R\$ 10.142.236,02	0,010%
	Bahia	Correntina	1,1764	R\$ 21.980.848,80	R\$ 22.000.102,07	0,088%
	Mato Grosso	Sapezal	0,822	R\$ 116.018.723,13	R\$ 116.176.600,58	0,136%
	Minas Gerais	Unai	0,8573	R\$ 23.050.614,41	R\$ 23.131.659,79	0,352%
	Paraná	Clevelândia	0,6817	R\$ 37.421.128,72	R\$ 38.996.252,31	4,209%
Milho (1ªsafra)	Pará	Paragominas	3,2496	R\$ 10.141.197,35	R\$ 10.141.689,17	0,005%
	Bahia	Luiz Eduardo Magalhães	5,0394	R\$ 3.174.183,56	R\$ 3.175.021,56	0,026%
	Goiás	Jataí	1,9803	R\$ 2.091.133,60	R\$ 2.093.535,67	0,115%
	Minas Gerais	Uberaba	4,5858	R\$ 7.965.670,10	R\$ 8.129.285,49	2,054%
	Paraná	São Mateus do Sul	3,9261	R\$ 4.291.735,67	R\$ 4.495.608,77	4,750%
Milho (2ªsafra)	Rondônia	Vilhena	1,355	R\$ 2.062.374,05	R\$ 2.077.783,75	0,747%
	Sergipe	Carira	1,8424	R\$ 1.134.230,46	R\$ 1.134.507,39	0,024%
	Mato Grosso	Primavera do Leste	0,0535	R\$ 55.750.916,09	R\$ 55.787.700,07	0,066%
	São Paulo	Itapeva	6,0493	R\$ 3.148.902,26	R\$ 3.293.881,79	4,604%
	Paraná	Clevelândia	5,0306	R\$ 21.498.892,36	R\$ 21.991.033,38	2,289%

Fonte: Elaboração própria

A receita do produtor sem contrato de derivativo climático (A) foi comparada com a receita de um produtor com contrato de derivativo climático (B) com indexador baseado no HDD. A receita do produtor com derivativo considera além da receita de produção padrão, a indenização que será concedida a partir do *strike* definido no contrato e pelo preço do derivativo atualizado a tempo presente.

No exemplo do quadro anterior, a receita com contrato foi baseada numa indenização na qual o valor compensatório utilizado foi o preço da cotação, no ano em questão, da *commodity*. Isso faz com que a receita presente no quadro 36, considerada a receita com contrato, indique o valor mínimo possível de indenização.

De um modo geral, nota-se que ocorreu um aumento da receita em todos os casos analisados. Entretanto, alguns estados apresentaram um baixo percentual de crescimento de receita, isso ocorreu em especial nos estados que já tinham um indexador de temperatura acumulada baixo. Já em estados que tinham um alto indexador HDD apresentaram um aumento de receita maior, o que aconteceu com maior frequência nas cidades localizadas nas regiões centro oeste, sudeste e sul.

Assim, o uso desse instrumento derivativo pode não ser ideal para cidades com poucas alterações climáticas sobre a atividade agrícola, como no exemplo deste trabalho, as cidades localizadas nas regiões norte e nordeste que apresentaram um nível de crescimento de receita pequeno.

O quadro 37 apresenta os valores obtidos nessa simulação sobre a receita do produtor utilizando derivativo climático com indexador CDD.

Quadro 37: Simulação da Receita do Produtor pelo índice de Temperatura CDD

Cultura	Estado	Cidade	CDD			Percentual Alteração (B x A)	
			Put	Receita sem contrato (A)	Receita com contrato (B)		
Cana-de-açúcar	Tocantins	Pedro Afonso	0,042	R\$ 17.379.869,92	R\$ 17.439.310,90	0,342%	
		Alagoas	Coruripe	0,835	R\$ 39.535.153,47	R\$ 39.563.706,04	0,072%
		Goiás	Mineiros	1,142	R\$ 225.594.379,92	R\$ 225.772.138,58	0,079%
		São Paulo	Barretos	7,565	R\$ 829.374.669,95	R\$ 829.380.964,11	0,001%
		Paraná	Maringá	0,989	R\$ 143.299.873,17	R\$ 143.306.183,51	0,004%
Soja	Tocantins	Campos Lindos	6,045	R\$ 10.141.197,35	R\$ 10.274.037,15	1,310%	
		Bahia	Correntina	0,463	R\$ 21.980.848,80	R\$ 22.017.816,17	0,168%
		Mato Grosso	Sapezal	0,570	R\$ 116.018.723,13	R\$ 117.299.222,26	1,104%
		Minas Gerais	Unaí	0,883	R\$ 23.050.614,41	R\$ 23.090.947,90	0,175%
		Paraná	Clevelândia	0,688	R\$ 37.421.128,72	R\$ 37.422.734,84	0,004%
Milho (1ªsafra)	Pará	Paragominas	0,032	R\$ 10.141.197,35	R\$ 10.206.596,64	0,645%	
		Bahia	Luiz Eduardo Magalhães	0,834	R\$ 3.174.183,56	R\$ 3.192.023,95	0,562%
		Goiás	Jataí	0,851	R\$ 2.091.133,60	R\$ 2.110.238,90	0,914%
		Minas Gerais	Uberaba	1,816	R\$ 7.965.670,10	R\$ 7.973.753,39	0,101%
		Paraná	São Mateus do Sul	4,468	R\$ 4.291.735,67	R\$ 4.294.731,47	0,070%
Milho (2ªsafra)	Rondônia	Vilhena	0,099	R\$ 2.062.374,05	R\$ 2.114.523,35	2,529%	
		Sergipe	Carira	1,842	R\$ 1.134.230,46	R\$ 1.163.741,19	2,602%
		Mato Grosso	Primavera do Leste	6,045	R\$ 55.750.916,09	R\$ 55.774.231,88	0,042%
		São Paulo	Itapeva	6,049	R\$ 3.148.902,26	R\$ 3.159.332,27	0,331%
		Paraná	Clevelândia	5,031	R\$ 21.498.892,36	R\$ 21.499.647,77	0,004%

Fonte: Elaboração própria

Do mesmo modo anterior, a receita do produtor sem contrato de derivativo climático (A) foi comparada com a receita de um produtor com contrato de derivativo climático (B) com indexador baseado no CDD. A receita do produtor com derivativo considera a receita de produção padrão, a indenização que será concedida a partir do *strike* definido no contrato e pelo preço do derivativo atualizado a tempo presente.

De um modo geral, observa-se no quadro X que o impacto sobre a receita foi um pouco menor comparado com a receita obtida por meio do indexador HDD. Pode-se notar o aumento da receita do produtor, entretanto o qual não é relativamente alto podendo não representar algo a ser implementado quando não há eventos recorrentes de aumento de temperatura, acima do limite da cultura.

Entretanto, vale citar que algumas cidades atingiram um percentual maior de crescimento de receita com o uso do instrumento derivativo. Como exemplo, podemos citar as cidades de Campos Lindos, Sapezal, Vilhena e Carira. Todas essas localizadas nas regiões norte e nordeste do país, em contraste com o resultado obtido sobre o HDD.

Assim, novamente, a depender da localização e da cultura a ser analisada, o uso do contrato de derivativo pode não ser tão vantajoso do que em cidades com alta volatilidade de temperatura e impactos operacionais na colheita.

## 6. Considerações Finais e Reflexões Acerca do Tema

A presente pesquisa buscou definir a aplicabilidade dos derivativos climáticos no Brasil. Para isso, ocorreu uma extensa análise sobre o referencial teórico sobre o assunto e mercado existente. Para posteriormente, realizar uma pesquisa para definir a existência ou não de derivativos climáticos no mercado brasileiro e as percepções sobre risco climático nas empresas. E por último, a modelagem dos dados climáticos de temperatura para precificação dos instrumentos nos principais estados produtores e nas respectivas cidades com estações meteorológicas para tentar diminuir o risco de base geográfica.

No estudo qualitativo sobre a utilização do derivativo climático, nas demonstrações financeiras das empresas que compõem o grupo de percebeu-se que as empresas não são aversas ao uso de derivativos para *hedge* sobre diversas justificativas. Entretanto, o uso de derivativos climáticos não é apresentado nas notas explicativas como sendo utilizados pelas empresas brasileiras. Todavia, um percentual das empresas analisadas relatara, em notas explicativas, que o uso dos derivativos climáticos impactava suas operações. Dentre as empresas que citaram tais riscos, podemos destacar as empresas de agropecuária/agricultura e as empresas de energia, sendo essas correspondentes dos segmentos os quais pode-se perceber mais nitidamente os impactos de eventos climáticos sobre suas operações. Dessa forma, há um potencial grupo de empresas que poderiam utilizar esse instrumento financeiro para *hedge* de suas operações.

Posteriormente, buscou-se aplicar o derivativo climático em uma situação hipotética para eventuais produtores agrícolas das três principais culturas brasileiras: cana-de-açúcar, soja, milho (1ª e 2ª safras) em cada cidade composta pelo estado maior produtor da respectiva *commodity* em cada uma das regiões brasileiras, compondo no total 20 cidades analisadas (4 culturas \* 5 regiões brasileiras). Para isso, por meio de modelagens chegou-se a um resultado de precificação para cada uma das culturas e cidades.

De um modo geral, os índices de temperatura utilizados, HDD e o CDD, demonstraram que as temperaturas impactaram mais as regiões sul e sudeste, em especial o indicador HDD. Tal fato demonstra que a temperatura dessa região tendeu a ficar mais tempo abaixo do mínimo permitido por cada uma das culturas das *commodities*. Já no caso do indicador CDD, o valor não foi tão expressivo quanto no HDD. O indexador CDD

foi considerado maior nos países do norte, nordeste e em especial, sobre o estado do Mato Grosso no centro oeste. Porém, mesmo assim o indexador CDD foi muito menor do que o HDD. Logo, isso indica que entre todas as culturas e cidades, o indexador HDD faz mais sentido em ser utilizado, em especial nas regiões sul e sudeste.

Após isso, ocorreu a simulação das receitas de um produtor fictício de cada uma das culturas e cidades analisadas. O objetivo foi o de comparar a receita de um produtor que não utiliza contratos de derivativos climáticos com o intuito de *hedge* contra um produtor que tem derivativo. De modo que, como resultado o produtor com o contrato derivativo apresentou um resultado maior em todas as culturas e cidades. Todavia, o crescimento da receita só foi um pouco mais expressivo nas cidades que tiveram maior indexador HDD, que seriam Paraná e São Paulo (localizadas nas regiões sul e sudeste). Além disso, ao analisar o indexador CDD os resultados também não foram tão expressivos como com o HDD. Indicando assim, que o derivativo tem maior resultados em cidades que tenham maior variação de temperatura frente a temperatura base.

Como conclusão, percebe-se que o Brasil, por ter grande participação econômica com as principais culturas deve proteger os produtores dessas *commodities* de eventuais riscos climáticos que podem ocorrer ocasionalmente por meio de variações de temperatura. Como apresentado, os derivativos climáticos são uma opção recente que podem auxiliar no gerenciamento dos riscos climáticos pelos agricultores. Entretanto, o presente estudo ao realizar uma simulação entre receitas que utilizam o instrumento e outra que não utilizam chega-se à conclusão de que esse tipo de instrumento não consegue ser utilizado para todas as regiões do país. As regiões que de fato geram maior retorno com a utilização do instrumento são as regiões sul e sudeste com a utilização do indexador HDD, isso ocorreu devido a grandes alterações climáticas que ocasionaram essas regiões a terem temperaturas bem baixas, impactando, podendo impactar assim a produtividade das principais culturas dessas regiões: como é o caso do Paraná (grande produtor de diversas *commodities*) e São Paulo (principal produtor de cana-de-açúcar).

Como sugestão de pesquisa futura, devido a incipiente quantidade de trabalhos acadêmicos brasileiros sobre o assunto há uma gama de possíveis propostas de estudos futuros. Como exemplo, pode-se citar uma pesquisa qualitativa em busca dos principais fatores de impedimento para a aplicação de derivativos climáticos no Brasil.



Outra pesquisa poderia ser focada nos impactos da volatilidade climática sobre o agronegócio. Sendo um dos principais objetivos determinar qual o nível de perda de produção dos produtores a depender das variações climáticas.

Já com foco na área de auditoria, fator encontrado no estudo sobre a utilização do instrumento derivativo no mercado acionário, pode-se pensar em pesquisar sobre qual o nível de provisão mais adequado possível para empresas que sofrem impactos climáticos sobre suas operações.

E por último, a temperatura não é o único indexador possível para contrato de derivativos climáticos. Outras variáveis climáticas podem ser consideradas e analisadas no contexto brasileiro, como a pluviosidade ou mesmo a vegetação.

## REFERÊNCIAS

- Alaton P., Djehiche B. & Stillberger D. (2002) On modelling and pricing weather derivatives, *Applied Mathematical Finance*, 9:1, 1-20, DOI: 10.1080/13504860210132897
- Alcantara, L. T. D. (2020). Gerenciamento de riscos no agronegócio: um estudo empírico sobre a percepção dos produtores rurais do Distrito Federal, Goiás e Entorno. Dissertação de Mestrado, Universidade de Brasília,
- Alves Neto, A. (2021) Estudo sobre a viabilidade do uso de derivativos climáticos como ferramenta de gestão de risco na cultura de soja no estado do Mato Grosso. Dissertação de Mestrado em Economia Aplicada. Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.
- Assaf Neto, A. (2003) *Finanças corporativas e valor*. Atlas, São Paulo.
- Associação Brasileira de Normas Técnicas NBR ISO 31000 (2009) *Gestão de Riscos*, Brasil.
- Associação Brasileira dos Produtores de Sementes de Soja - BRASS, (2020) Princípios agronômicos – Efeitos da disponibilidade de água e altas temperaturas no ciclo da soja. Recuperado de: [Princípios agronômicos - Efeitos da disponibilidade de água e altas temperaturas no ciclo da soja \(abrass.org.br\)](http://www.abrass.org.br)
- Ballotta, L., Fusai, G., Kyriakou, I., Papapostolou, N. C., & Pouliasis, P. K. (2020). Risk management of climate impact for tourism operators: An empirical analysis on ski resorts. *Tourism Management*, 77, 104011.
- Berhane, T., Shibabaw, A., Awgichew, G. *et al.* (2020) Pricing of weather derivatives based on temperature by obtaining market risk factor from historical data. *Model. Earth Syst. Environ*, 7, 871-884. <https://doi.org/10.1007/s40808-020-00925-4>
- Black, F., & Scholes, M. (1973) The Pricing of Options and Corporate Liabilities, *Journal of Political Economy*, 81: 637-55.
- Botos, H. M.; Ciumas, C. (2012) The use of the black-scholes model in the field of weather derivatives. *Procedia Economics and Finance*, Cluj-Napoca, v. 3, p. 611-616.

Brobriková, M. (2022) Weather Risk Management in Agriculture using weather derivatives. *Italian review of agricultural economics* 77(2), 15-26. DOI: 10.36253/rea-13416.

Brockett, P.L., Wang, M., & Yang, C. (2005) Weather derivatives and Weather risk management. In: *Risk management and insurance review* 8, N 1, S. 127-140.

Brockett, P.L., Wang, M., Yang, C., & Zou, H. (2006) Portfolios effects and valuation of weather derivatives. *Financial Rev*, 41:55-76.

Cabrera, B. L., Odening, M., & Ritter, M. (2013) Pricing rainfall futures at the CME. *Journal of Banking & Finance*, 37, 4286-4298.

Cao, M.; & Wei, J. (2004). Weather derivatives valuation and market price of Weather risk. *The journal of futures markets*, v. 24, n.1m p.1065-1089. Disponível em: <https://doi.org/10.1002/fut.20122>.

Climate Related Market Risk Subcommittee (2020). Managing Climate Risk in the U.S. Financial System. Disponível em: [Managing Climate Risk in the U.S. Financial System \(cftc.gov\)](https://www.cftc.gov/Press-Release/2020/07/20200714).

Chicago Mercantile Exchange – CME (2021). Managing Climate Risk with CME Group Weather Futures and Options. Disponível em: [Managing Climate Risk with CME Group Weather Futures and Options - CME Group](https://www.cmegroup.com/trading/weather/files/WEA_intro_to_weather_der.pdf)

Choi, C., Shin, D.-H., & Kim, C. (2012) Managing Weather-Risks in Korean City-Gas Industry using Weather Derivatives. *Journal of Derivatives and Quantitative Studies*, Vol. 20, No. 4, pp. 451-481. <https://doi.org/10.1108/JDQS-04-2012-B0004>.

Committee of Sponsoring Organizations of the Treadway Commission – COSO (2017) Gerenciamento de riscos corporativos – Estrutura Integrada. Disponível em: <https://www.coso.org/Documents/COSO-ERM-Executive-Summary-portuguese.pdf>

CONAB – Companhia Nacional de Abastecimento (2021) Perspectivas para a agropecuária. Vol. 9. Safra 2021/2022 – Edição Grãos. Disponível em: [Perspectivas para a Agropecuaria - V.9 2021-2022 - Edicao Graos.pdf](https://www.conab.gov.br/images/stories/publicacoes/perspectivas_para_a_agropecuaria_-_v.9_2021-2022_-_edicao_graos.pdf)

Considine, G. (2000). Introduction to Weather derivatives. CME Group. Disponível em: [https://www.cmegroup.com/trading/weather/files/WEA\\_intro\\_to\\_weather\\_der.pdf](https://www.cmegroup.com/trading/weather/files/WEA_intro_to_weather_der.pdf).

Crane, L, Gene, G., Issacs, S., Jose, D., & Sharp, R. (2013). Introduction ro Risk

Management: Understanding Agricultural Risk. Disponível em: [Intro-Risk-Mgmt.pdf \(wsu.edu\)](#)

Cyr, D., Kusy, M., & Shaw, A. B. (2010). Climate change and the potential use of weather derivatives to hedge vineyard harvest rainfall risk in the Niagara region. *Journal of Wine Research*, 21(2-3), 207-227.

Davis, M., (2001) Pricing Weather Derivatives by Marginal Value, *Quantitative Finance*, 1: 1-4.

Dimitrova, S. (2019) Climate Change Risk – Emerging themes from regulators. Society of actuaries in Ireland. <https://web.actuaries.ie/press-publications/erm-library/ermblog/climate-change-risk-emerging-themes-regulators>

Dosi, C., & Moretto, M. (2003) Global warming and Financial Umbrellas, *Journal of Risk Finance*, vol. 4, No. 4, pp. 18-25. <https://doi.org/10.1108/eb022970>.

Ender, M. and Zhang, R. (2015), "Efficiency of weather derivatives for Chinese agriculture industry", *China Agricultural Economic Review*, Vol. 7 No. 1, pp. 102-121. <https://doi.org/10.1108/CAER-06-2013-0089>

Empresa Brasileira de Pesquisa Agropecuária, EMBRAPA (2010) *Sistemas de produção 2: Cultivo do Milho*, 5ª edição, Set/2010.

Empresa Brasileira de Pesquisa Agropecuária, EMBRAPA (2020) *Sistemas de produção 17: Tecnologias de produção de soja*, Londrina: Embrapa Soja.

Fernandes, B.V.R. (2012) Modelos de valores extremos e convencionais de VaR: nível de acurácia na previsão de risco de mercado nos países do G7 e BRICS. Tese de doutorado, Faculdade de Economia, Administração e Ciências Contábeis e Atuariais (FACE). Universidade de Brasília, Brasília.

Fraser, J. R., Quail, R., & Simkins, B. (Eds.). (2021). *Enterprise risk management: Today's leading research and best practices for tomorrow's executives*. John Wiley & Sons.

Geman, H., & Leonardi, M.P. (2005) Alternative approaches to weather derivatives pricing. *Managing Finance*, 31 (6): 46-72.

Ghiulnara, A., & Viegas, C. (2010). Introduction of weather-derivative concepts: perspectives for Portugal. *The Journal of Risk Finance*, 11(1):9-19.

- Groll, A.; López-Cabrera, B.; Meyer-Brandis, T. A. (2016) Consistent two-factor model for pricing temperature derivatives. *Energy Economics*, Munich, v. 55, p. 112-126.
- Hull, J. C. (2015). *Options, futures and Other derivatives* (vol. 9). London: Pearson Education, Inc.
- Hussain, J., & Ali, P. (2021). On Modelling and Pricing Weather Derivatives Driven by Nonlinear Brownian Motion. *International Journal of Analysis and Applications*, 19(1), 29-46.
- Jewson, S. (2004) Introduction to weather derivatives pricing. *Risk management solutions*.
- Jewson, S.; Brix, A. (2015). *Weather derivatives valuation: the meteorological, statistical, financial and mathematics foundations*. 1. Ed. Cambridge University Press.
- Just, R. E.; Ortiz-Bobea, A. (2012) Modelling the structure of adaption in climate change impact assessment. *American Journal of Agriculture Economics*, v. 95, n.2, p.244-251.
- Kermiche, L., & Vuillemet, N. (2016) Weather derivatives structuring and pricing: a sustainable agricultural approach in Africa, *Applied Economics*, 48:2, 165-177, DOI:10.1080/00036846.2015.1076147.
- Khan, S., Rennie, M., & Charlebois, S. (2013) Weather risk management by Saskatchewan agriculture producers. *Agricultural Finance Review*, Vol. 73 No.1, pp. 161-178. <https://doi.org/10.1108/00021461311321375>.
- Kimura, H., Perera, L. C. J. (2005) Modelo de otimização da gestão de risco em empresas não financeiras. *Revista Contabilidade & Finanças*, v. 16, n.37.
- Kusniyeva AT. (2019) The possibility of application of weather derivatives by agricultural market in Kazakhstan on the expert opinion. *Bulletin of Karaganda University, Series Economy*. 2019;93(1):241-8.
- Leblois, A. & Quirion, P. (2013) Agricultural insurances based on meteorological indices: realizations, methods and research challenges. *Meteorological Applications*, v. 20, p.1-9. DOI:<https://doi.org/10.1002/met.303>.
- Lemos, G. B. D. (2014). *Precificação de derivativos climáticos no Brasil: uma abordagem estatística alternativa e construção de um algoritmo em R*. Dissertação de Mestrado em

Estatística e Experimentação Agronômica. Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.

Li, P. (2021). The Valuation of Weather Derivatives Using One Sided Crank–Nicolson Schemes. *Computational Economics*, 58(3), 825-847.

Lima, I.S, Lima, G.; & Pimentel, R.C. (2009) Curso de mercado financeiro: tópicos especiais. In: São Paulo: Atlas 1.

Lopes, L. L. (2018) Minimização de risco de base geográfico de derivativos climáticos no Brasil. Dissertação de Mestrado em Desenvolvimento Econômico. Universidade Federal do Paraná, Curitiba.

Lucas, R.E. (1978). Assets prices in na Exchange economy. *Econometrica*, v.46, n.6, p.1429-1445.

Lucas, E.C. (2015) Impactos de eventos climáticos extremos sobre o preço de ações de indústrias de interesse nacional. Dissertação de Mestrado.

Luz, A. D., & Fochezatto, A. (2022). O transbordamento do PIB do Agronegócio do Brasil: uma análise da importância setorial via Matrizes de Insumo-Produto. *Revista de Economia e Sociologia Rural*, 61.

MAPA – Ministério da Agricultura, Pecuária e Abastecimento (2021). Projeções do Agronegócio 2020-2021 a 2030-2031. Disponível em: [Projeções do Agronegócio 2020-2021 a 2030-2031 \(1\).pdf](#)

Martinez Salgueiro, A., & Tarrazon-Rodon, M. A. (2021). Weather derivatives to mitigate meteorological risks in tourism management: An empirical application to celebrations of Comunidad Valenciana (Spain). *Tourism Economics*, 27(4), 591-613.

Meissner, G., Burke, J. (2011) Can we use the Black-Scholes-merton model to value temperature options? *Int. J. Financial Markets and Derivatives*, Vol. 2, No. 4, pp.298–313.

Möllmann, J., Buchholz, M., & Musshoff, O. (2019). Comparing the hedging effectiveness of weather derivatives based on remotely sensed vegetation health indices and meteorological indices. *Weather, Climate, and Society*, 11(1), 33-48.

- Moreira, V. R., Barreiros, R. F., & Protil, R. M. (2011). Portfolio de produção agropecuária e gestão de riscos de mercado nas cooperativas do agronegócio paranaense. *Revista de Administração (São Paulo)*, 46(4), 325-341.
- Musshoff, O., Odening, M., & Xu, W. (2009). Management of Climate Risks in Agriculture - Will Weather Derivatives Permeate? *Applied Economics*, 1067-1077. <https://doi.org/10.1080/00036840802600210>
- Pereira Júnior, A., & Malaquias, R. F. (2019). Derivativos de Clima: Oportunidades para Pesquisa e a Gestão de Risco no Cenário Brasileiro. *Pensar Contábil*, 22(77).
- Rasulov, A., & Raimova, G. (2021, July). Monte Carlo methods for pricing weather derivatives. In *AIP Conference Proceedings* (Vol. 2365, No. 1, p. 020017). AIP Publishing LLC.
- Raucci, G. L., Capitani, D. H. D., & Silveira, R. L. F. D. (2017). Viabilidade de implantação de derivativos climáticos: Uma análise para gestão de risco na produção de soja. 7ª conferência em gestão de risco e comercialização de commodities (CGRCC). São Paulo, SP, Brasil.
- Raucci, G. L., Capitani, D. H. D., & Silveira, R. L. F. D. (2020). Derivativos climáticos na agricultura: uma revisão de literatura. *Revista de Política Agrícola*, 29(3), 83.
- Richards, T.J., Manfredo, M. R., Sanders, D. R. (2004). Pricing Weather derivatives. *American Journal of Agricultural Economics*, v. 74, n.2, p.17-28.
- Sanches, A., Alves, L. R. A., & Barros, G. S. A. D. C. (2019). Oferta e demanda mensal de milho no Brasil: impactos da segunda safra. *Revista de Política Agrícola*, 27(4), 73.
- Seth, R. Ansari, V.A., & Datta, M. (2009) Weather risk hedging by farmers. An empirical study of willingness to pay in Rajasthan, India. *The journal of risk finance*, vol. 10, No 1, pp. 54-66. <https://doi.org/10.1108/15265940910924490>.
- Sharma, A. K., & Vashishtha, A. (2007). Weather derivatives: risk-hedging prospects for agriculture and power sectors in India. *The journal of risk finance*, v. 8, n.2, pp 112-132.
- Silva, A. G. M., Bastos, E. K. X., & Féres, J. G. (2017). Meio Ambiente e seguros. Escola Nacional de Seguros. Centro de Pesquisa e Economia do Seguro. Rio de Janeiro. Disponível em: MEIO-AMBIENTE-E-SEGUROS.pdf (researchgate.net)

Silveira, F. A., & Camilo, S. P. O. (2021) Brazilian Electricity Market and Weather Derivatives: Hedging Temperature Using Blockchain. XXI Encontro Brasileiro de Finanças.

Sloan, D., Palmer, L., & Burrow, H. (2002) A broker's view. In: Global Reinsurance, S. 22-25.

Sousa, A. D. B., Souza Filho, F. D. A. D., & Silva, S. M. O. D. (2015). Contrato de opção e fundo financeiro como instrumentos de gestão de risco climático na alocação de água. Revista de Gestão de água da América Latina, V. 12, n2. P. 5-15, jul/dez.

Souza, J.C., & Souza, P.A.R (2019). Produção acadêmica com enfoque nos termos de gestão e gerenciamento de riscos e a ABNT ISSO 31000 no período entre 2000 e 2019: um estudo bibliométrico. Revista de Gestão, Finanças e Contabilidade, 9(2), 18-36.

Spaulding, A, Kanakasabai, M., Hao, J., & Skess J. (2010). Can Weather derivative contracts help mitigating agricultural risk? Microeconomic policy implications for Romania. In: International Conference on Policy Modeling, Istanbul.

Štulec, I. (2017) Effectiveness of weather derivatives as a risk management tool in food retail: The case of Croatia. International Journal of Financial Studies, 5, 2; doi:10.3390/ijfs5010002.

Štulec, I., Petljak, K., & Bakovic, T. (2016). Effectiveness of weather derivatives as a hedge against the weather risk in agriculture. Agricultural Economics, 62(8), 356-362.

UNDP - United Nations Development Programme (2019). UNDP and Climate Change Zero Carbon, Sustainable Development. UNDP

USDA – United States Department of Agriculture Economic Research Service. (2019) Risk in agriculture. Disponível em: <http://www.ers.usda.gov/topics/farm-practicesmanagement/risk-management/risk-in-agriculture/>.

Vedenov, D. V., & Barnett, B. J. (2004). Efficiency of weather derivatives as primary crop insurance instruments. Journal of Agricultural and Resource Economics, 387-403.

Wieczorek-Kosmala, M. (2020). Weather risk management in energy sector: The Polish case. Energies, 13(4), 945.



Woodard, J.D., & Garcia, P. (2008) Basis risk and Weather hedging effectiveness. *Agricultural Finance Review*, V. 68, n.1, p. 99-117.

Vigani, M., & Kathage, J. (2019) To risk or not to risk? Risk Management and farm productivity. *American Journal of Agriculture Economics*, v. 101, n.5

Young V., & T. Zariphopoulou, (2002) Pricing Dynamic Insurance Risks Using the Principle of Equivalent Utility, *Scandinavian Actuarial Journal*, 4: 246-79.

Zapranis, A., & Alezandridis, A. (2013) *Weather Derivatives: Modelling and Pricing Weather Related Risk*. Springer: New York.

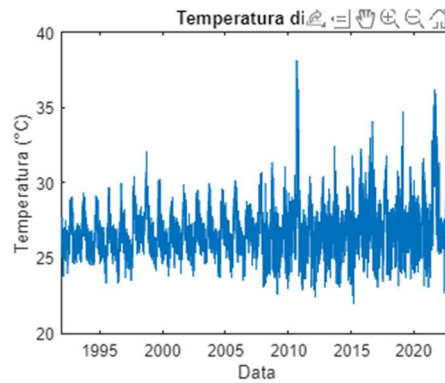
Zeng, L. (2000) Pricing weather derivatives. *J Risk Finance*, 1 (3): 72-78.

Zhou, R., Li, J.S.-H, & Pai, J. (2016) Hedging crop yield with Exchange traded weather derivatives. *Agricultural Finance Review*, Vol. 76 No 1, pp. 172-186. <https://doi.org/10.1108/AFR-11-2015-0045>.

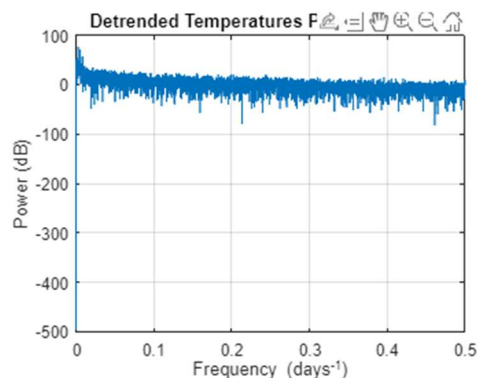
Zylbersztajn, D. (2017). Agribusiness systems analysis: origin, evolution and research perspectives. *Revista de Administração (São Paulo)*, 52, 114-117.

## APÊNDICE A – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Tocantins (Pedro Afonso)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```



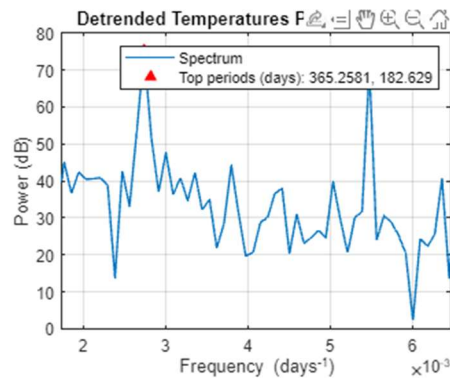
```
detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on
```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
```

```
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ), ", "
))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 * pi *
t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao, "VarNames",
[trendPreds, "Temperature"])
```


```
trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	26.269	0.024708	1063.2	0
<b>t</b>	0.035085	0.0013806	25.413	1.3476e-138
<b>cos(2*pi*t)</b>	-0.03103	0.017468	-1.7764	0.07569
<b>sin(2*pi*t)</b>	-1.013	0.017474	-57.973	0
<b>cos(4*pi*t)</b>	-0.77308	0.017468	-44.258	0

```
Number of observations: 11323, Error degrees of freedom: 11318
Root Mean Squared Error: 1.31
R-squared: 0.348, Adjusted R-Squared: 0.348
F-statistic vs. constant model: 1.51e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY, 25.402+0.034693...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.80276	0.0072893	110.13	0
<b>MA{1}</b>	-0.070997	0.011969	-5.932	2.9934e-09
<b>DoF</b>	8.5167	0.53736	15.849	1.4238e-56

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.0045867	0.0007354	6.2371	4.4585e-10
<b>GARCH{1}</b>	0.92951	0.0044678	208.05	0
<b>ARCH{1}</b>	0.063808	0.0043329	14.727	4.3547e-49
<b>DoF</b>	8.5167	0.53736	15.849	1.4238e-56

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
```

```

ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

```

```

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC / sqrt(2*pi))
* exp(-0.5*a^2))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC / sigmaC))
+ sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

```

```

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH / sqrt(2*pi))
* exp(-0.5*a^2))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH / sigmaH))
+ sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-0.5*(muH/sigmaH)^2)))


```

## APÊNDICE B – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Alagoas (Coruripe)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")


```



```

detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```



```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...

```

```

    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
", " ))

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```

trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)

```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	25.402	0.023538	1079.2	0
<b>t</b>	0.034693	0.0013152	26.378	7.3608e-149
<b>cos(2*pi*t)</b>	1.5718	0.01664	94.46	0
<b>sin(2*pi*t)</b>	1.1588	0.016646	69.613	0
<b>cos(4*pi*t)</b>	-0.33045	0.01664	-19.859	2.7161e-86

Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.25

R-squared: 0.566, Adjusted R-Squared: 0.566


F-statistic vs. constant model: 3.69e+03, p-value = 0

```

figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,25.402+0.034693...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])

```





```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.90461	0.0043449	208.2	0
<b>MA{1}</b>	-0.065854	0.0099284	-6.6329	3.2921e-11
<b>DoF</b>	7.1121	0.42261	16.829	1.4913e-63

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.00074442	0.00016583	4.4889	7.1581e60
<b>GARCH{1}</b>	0.96745	0.0028071	344.64	
0				
<b>ARCH{1}</b>	0.02926	0.0025594	11.433	2.869e30
<b>DoF</b>	7.1121	0.42261	16.829	1.4913e63

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
```

```

plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;


call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

```


```
put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))
```

### APÊNDICE C – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – São Paulo (Barretos)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```



```
detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on
```




```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
```

```

topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```

trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)

```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	23.877	0.037984	628.6	0
<b>t</b>	-0.02756	0.0021225	-12.985	2.7961e-38
<b>cos(2*pi*t)</b>	2.5864	0.026854	96.313	0
<b>sin(2*pi*t)</b>	-0.93978	0.026863	-34.984	1.0744e-254
<b>cos(4*pi*t)</b>	-1.3237	0.026854	-49.291	0

Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 2.02


R-squared: 0.536, Adjusted R-Squared: 0.536

F-statistic vs. constant model: 3.27e+03, p-value = 0

```

figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,23.877-0.02756 ...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])

```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.73924	0.0076911	96.116	0
<b>MA{1}</b>	0.23381	0.011453	20.415	1.2306e-92
<b>DoF</b>	5.3177	0.23668	22.467	8.6506e-112

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.24819	0.024167	10.27	9.6561e-25
<b>GARCH{1}</b>	0.66742	0.023232	28.728	1.6957e-181
<b>ARCH{1}</b>	0.17525	0.014426	12.148	5.9011e-34
<b>DoF</b>	5.3177	0.23668	22.467	8.6506e-112


```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
```


```
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on
```



```
C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on
```



```
K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

```



```

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

## APÊNDICE D – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Paraná (Maringá)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```




```

detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);


powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```


```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	21.715	0.051624	420.64	0
<b>t</b>	0.046116	0.0028846	15.987	6.6046e-57
<b>cos(2*pi*t)</b>	3.5134	0.036496	96.268	0
<b>sin(2*pi*t)</b>	0.16087	0.036509	4.4062	1.0616e-05
<b>cos(4*pi*t)</b>	-0.96375	0.036496	-26.407	3.5746e-149

```
Number of observations: 11323, Error degrees of freedom: 11318
```

Root Mean Squared Error: 2.75  
 R-squared: 0.475, Adjusted R-Squared: 0.475  
 F-statistic vs. constant model: 2.56e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,21.715+0.046116 ...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.7071	0.0077901	90.769	0
<b>MA{1}</b>	0.33193	0.0098897	33.563	5.7756e-247
<b>DoF</b>	5.0993	0.24832	20.535	1.0519e-93

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.027913	0.0051481	5.4221	5.8914e-08
<b>GARCH{1}</b>	0.9446	0.004698	201.06	0
<b>ARCH{1}</b>	0.046903	0.0040294	11.64	2.5777e-31
<b>DoF</b>	5.0993	0.24832	20.535	1.0519e-93

```
nDays = 90;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));
```


```

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);


r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

```



```

muC = mean(C);
sigmaC = std(C);


r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

```




## APÊNDICE E – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Goiás (Mineiros)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```



```


detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);


```

```
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on
```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

```
Estimated Coefficients:
```

Estimate	SE	tStat	pValue
----------	----	-------	--------

<b>(Intercept)</b>	22.232	0.035195	631.68	0
<b>t</b>	0.028831	0.0019666	14.66	3.2083e-48
<b>cos(2*pi*t)</b>	1.8148	0.024882	72.938	0
<b>sin(2*pi*t)</b>	-0.80026	0.024891	-32.151	4.1326e-217
<b>cos(4*pi*t)</b>	-1.2441	0.024882	-50.002	0


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.87

R-squared: 0.445, Adjusted R-Squared: 0.445

F-statistic vs. constant model: 2.27e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,22.232+0.028831 ...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.72027	0.0081772	88.083	0
<b>MA{1}</b>	0.14224	0.012124	11.732	8.754e-32
<b>DoF</b>	4.7855	0.19302	24.793	1.0746e-135

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
--	--------------	----------------------	-------------------	---------------



<b>Constant</b>	0.10283	0.0093846	10.957	6.1444e-28
<b>GARCH{1}</b>	0.76072	0.013476	56.451	0
<b>ARCH{1}</b>	0.16587	0.011732	14.139	2.1807e-45
<b>DoF</b>	4.7855	0.19302	24.793	1.0746e-135

```

nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));


trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "Linewidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

## APÊNDICE F – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Bahia (Correntina)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```




```

detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	25.093	0.034981	717.34	0
<b>t</b>	-0.018007	0.0019547	-9.2123	3.7519e-20
<b>cos(2*pi*t)</b>	0.81799	0.02473	33.076	4.2165e-229
<b>sin(2*pi*t)</b>	-0.72036	0.024739	-29.118	8.1795e-180
<b>cos(4*pi*t)</b>	-1.2395	0.02473	-50.122	0


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.86

R-squared: 0.286, Adjusted R-Squared: 0.285

F-statistic vs. constant model: 1.13e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,25.093-0,18007 ...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.83709	0.0060699	137.91	0
<b>MA{1}</b>	0.061459	0.010891	5.6432	1.6688e-08
<b>DoF</b>	7.6437	0.4729	16.163	9.1564e-59

GARCH(1,1) Conditional Variance Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0.049495	0.0063929	7.7421	9.7755e-15
<b>GARCH{1}</b>	0.88782	0.0097471	91.085	0
<b>ARCH{1}</b>	0.066081	0.0058876	11.224	3.1172e-29
<b>DoF</b>	7.6437	0.4729	16.163	9.1564e-59

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
```

```

xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on

```



```

C = sum(max(simTemp - 26, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```

```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

## APÊNDICE G – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Mato Grosso (Sapezal)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```




```

detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")

```




```
title("Detrended Temperatures Power Spectrum")
grid on
```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```


Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	23.506	0.032393	725.67	0
<b>t</b>	0.030559	0.0018101	16.883	3.5451e-63
<b>cos(2*pi*t)</b>	1.1491	0.022901	50.176	0
<b>sin(2*pi*t)</b>	-1.0159	0.022909	-44.344	0

```
cos(4*pi*t)    -1.2622    0.022901    -55.115    0
```

Number of observations: 11323, Error degrees of freedom: 11318  
 Root Mean Squared Error: 1.72  
 R-squared: 0.409, Adjusted R-Squared: 0.409  
 F-statistic vs. constant model: 1.96e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,23.506+0.030559 ...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.73896	0.0073714	100.25	0
<b>MA{1}</b>	0.16503	0.011842	13.937	3.7843e-44
<b>DoF</b>	3.9321	0.13288	29.59	1.9855e-192

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.22073	0.01771	12.463	1.1854e-35
<b>GARCH{1}</b>	0.55961	0.023372	23.944	1.0638e-126

<b>ARCH{1}</b>	0.28455	0.020784	13.691	1.1556e-42
<b>DoF</b>	3.9321	0.13288	29.59	1.9855e-192

```

nDays = 90;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));


simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);

simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```




```

K = 20
figure

```

```
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 20; % Strike value
TTM = 0.25; % Expiry time


a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH / sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH / sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-0.5*(muH/sigmaH)^2)))
```

## APÊNDICE H – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Paraná (Clevelândia)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```
detrendedTemps = detrend(INMET_regressao);
```

```

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```
trendModel =
Linear regression model:
  Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	18.153	0.053669	338.23	0
<b>t</b>	-0.014536	0.0029989	-4.847	1.27e-06
<b>cos(2*pi*t)</b>	4.2332	0.037943	111.57	0
<b>sin(2*pi*t)</b>	0.78494	0.037956	20.68	2.7407e-93
<b>cos(4*pi*t)</b>	-0.63513	0.037943	-16.739	3.7822e-62


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 2.85

R-squared: 0.538, Adjusted R-Squared: 0.538

F-statistic vs. constant model: 3.3e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,18.153-0.014536 ...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.69002	0.0079496	86.799	0

<b>MA{1}</b>	0.3421	0.0098949	34.573	6.4218e-262
<b>DoF</b>	4.1493	0.17499	23.712	2.6957e-124

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.042099	0.006252	6.7337	1.654e11
<b>GARCH{1}</b>	0.92506	0.0052437	176.41	0
<b>ARCH{1}</b>	0.06694	0.0051944	12.887	5.3224e38
<b>DoF</b>	4.1493	0.17499	23.712	2.6957e-124


```
nDays = 90;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

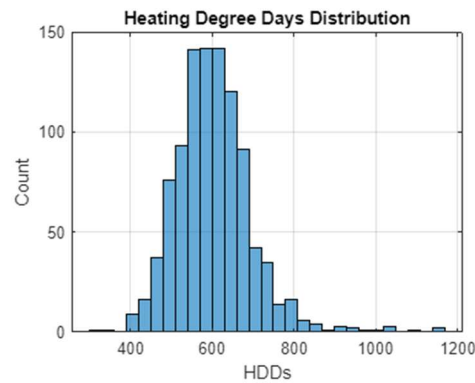
figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char(176) + "C)")
title("Temperature Simulation")
grid on
```



```
H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on
```






```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

K = 20
figure

```

```

alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 20; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

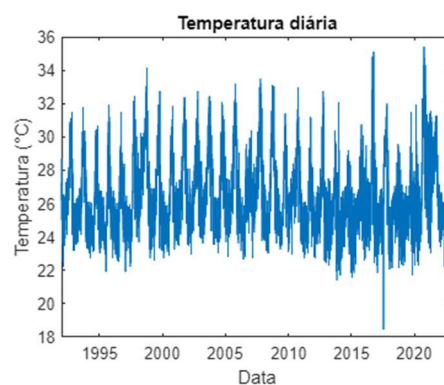
```

## APÊNDICE I – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Tocantins (Campos Lindos)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```



```


detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")


```

```
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on
```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	26.523	0.029466	900.12	0
<b>t</b>	-0.0018929	0.0016465	-1.1496	0.25033

```

cos(2*pi*t)      -0.22542      0.020832      -10.821      3.7088e-27
sin(2*pi*t)      -1.7922       0.020839      -86.001      0
cos(4*pi*t)      -0.98812       0.020832      -47.434      0

```

Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.57


R-squared: 0.463, Adjusted R-Squared: 0.463

F-statistic vs. constant model: 2.44e+03, p-value = 0

```

figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,26.523-0.0018929 ...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])

```



```

trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);

```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.84777	0.0059153	143.32	0
<b>MA{1}</b>	-0.031263	0.011194	-2.7929	0.0052237
<b>DoF</b>	9.5118	0.63675	14.938	1.8617e-50

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.01219	0.0018937	6.4374	1.2154e-10

<b>GARCH{1}</b>	0.92678	0.0058062	159.62	0
<b>ARCH{1}</b>	0.057353	0.0045742	12.538	4.6104e-36
<b>DoF</b>	9.5118	0.63675	14.938	1.8617e-50

```

nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));


simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);

simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 20
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 20; % Strike value
TTM = 0.25; % Expiry time


a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

```




```

K = 30
figure

```

```
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))
```

## APÊNDICE J – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Minas Gerais (Unai)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```

detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```





```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	22.97	0.032412	708.69	0
<b>t</b>	0.028429	0.0018111	15.697	6.0329e-55
<b>cos(2*pi*t)</b>	1.7459	0.022914	76.194	0
<b>sin(2*pi*t)</b>	-1.056	0.022923	-46.068	0
<b>cos(4*pi*t)</b>	-1.4186	0.022914	-61.908	0


```
Number of observations: 11323, Error degrees of freedom: 11318
```

```
Root Mean Squared Error: 1.72
```

```
R-squared: 0.516, Adjusted R-Squared: 0.515
```

```
F-statistic vs. constant model: 3.01e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY, 22.97+0.028429 ...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.79169	0.0068594	115.42	0
<b>MA{1}</b>	0.14706	0.01086	13.542	8.8646e-42
<b>DoF</b>	7.6383	0.453	16.861	8.6481e-64

GARCH(1,1) Conditional Variance Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0.023491	0.0035794	6.563	5.2748e-11
<b>GARCH{1}</b>	0.91892	0.0070417	130.5	0
<b>ARCH{1}</b>	0.057805	0.0050419	11.465	1.9762e-30
<b>DoF</b>	7.6383	0.453	16.861	8.6481e-64

```
nDays = 90;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "Linewidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
```

```

xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```


H = sum(max(24 - simTemp, 0));

```

```

figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 20
figure
alpha = 1;
chi = alpha * max(H - K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 20; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

muC = mean(C);
sigmaC = std(C);

```

```

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))


```

## APÊNDICE K – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Bahia (Luiz Eduardo Magalhães)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")


```



```


detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```


```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	23.604	0.028507	828.03	0
<b>t</b>	0.0087014	0.0015929	5.4626	4.7912e-08
<b>cos(2*pi*t)</b>	0.78398	0.020153	38.901	8.4049e-311
<b>sin(2*pi*t)</b>	-0.7912	0.020161	-39.245	5.9586e-316
<b>cos(4*pi*t)</b>	-1.1268	0.020153	-55.913	0

```
Number of observations: 11323, Error degrees of freedom: 11318
```

Root Mean Squared Error: 1.52  
 R-squared: 0.355, Adjusted R-Squared: 0.354  
 F-statistic vs. constant model: 1.56e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,23.604+0.0087014...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.81105	0.0068561	118.3	0
<b>MA{1}</b>	0.02537	0.011622	2.1829	0.029043
<b>DoF</b>	7.219	0.40627	17.769	1.2232e-70

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.051679	0.006596	7.835	4.6884e-15
<b>GARCH{1}</b>	0.86174	0.011741	73.393	0
<b>ARCH{1}</b>	0.080795	0.0069992	11.543	7.9649e-31
<b>DoF</b>	7.219	0.40627	17.769	1.2232e-70

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
```


```

simTime = years(simDates - DOY(1));
trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);


```



```

histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;


call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);


r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

```




## APÊNDICE L – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Goiás (Jataí)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```




```

detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	22.201	0.034552	642.54	0
<b>t</b>	0.034477	0.0019307	17.857	2.3344e-70
<b>cos(2*pi*t)</b>	2.1444	0.024427	87.789	0
<b>sin(2*pi*t)</b>	-0.84149	0.024436	-34.437	3.1019e-247
<b>cos(4*pi*t)</b>	-1.3564	0.024427	-55.53	0


```
Number of observations: 11323, Error degrees of freedom: 11318
```

```
Root Mean Squared Error: 1.84
```

```
R-squared: 0.521, Adjusted R-Squared: 0.521
```

```
F-statistic vs. constant model: 3.08e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY, 21.414+0.043079...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.68584	0.0087346	78.52	0
<b>MA{1}</b>	0.19287	0.011785	16.366	3.3405e-60
<b>DoF</b>	5.0205	0.20923	23.995	3.1497e-127

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.054721	0.0058746	9.3148	1.2221e-20
<b>GARCH{1}</b>	0.85462	0.0089276	95.728	0
<b>ARCH{1}</b>	0.1092	0.0079249	13.779	3.3978e-43
<b>DoF</b>	5.0205	0.20923	23.995	3.1497e-127

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
```

```

xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on

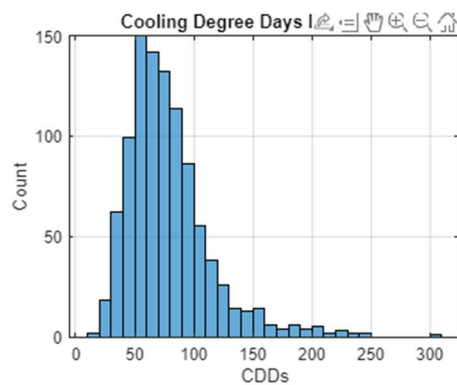
```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);

```

```

sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

```

```

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

### APÊNDICE M – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Pará (Paragominas)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```




```

detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on


```





```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```


```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	26.243	0.022444	1169.3	0
<b>t</b>	0.011574	0.0012541	9.2287	3.2245e-20
<b>cos(2*pi*t)</b>	0.66153	0.015867	41.692	0
<b>sin(2*pi*t)</b>	-1.2666	0.015873	-79.795	0
<b>cos(4*pi*t)</b>	-0.36575	0.015867	-23.051	6.1947e-115

```
Number of observations: 11323, Error degrees of freedom: 11318
```

Root Mean Squared Error: 1.19  
 R-squared: 0.436, Adjusted R-Squared: 0.436  
 F-statistic vs. constant model: 2.19e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,26.243+0.011574...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes)
```

ARIMA(1,0,1) Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.9489	0.0034715	273.34	0
<b>MA{1}</b>	-0.37019	0.0097261	-38.062	5.5525e-317
<b>DoF</b>	6.6748	0.34353	19.43	4.3172e-84

GARCH(1,1) Conditional Variance Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0.0067945	0.0010363	6.5567	5.5015e-11
<b>GARCH{1}</b>	0.91144	0.0063952	142.52	0
<b>ARCH{1}</b>	0.075839	0.005731	13.233	5.6465e-40
<b>DoF</b>	6.6748	0.34353	19.43	4.3172e-84

```


nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature ( " + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

```




```

K = 30
figure

```

```
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muC = mean(C);
sigmaC = std(C);


r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time

a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on
```




```
K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
```

```

histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

## APÊNDICE N – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Minas Gerais (Uberaba)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```



```

detrendedTemps = detrend(INMET_regressao);


```

```

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

trendModel =

```

Linear regression model:

$$\text{Temperature} \sim 1 + t + \cos(2\pi t) + \sin(2\pi t) + \cos(4\pi t)$$

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	21.414	0.032586	657.17	0
<b>t</b>	0.043079	0.0018208	23.659	7.921e-121
<b>cos(2*pi*t)</b>	2.3586	0.023037	102.38	0
<b>sin(2*pi*t)</b>	-0.74211	0.023045	-32.202	9.1638e-218
<b>cos(4*pi*t)</b>	-1.314	0.023037	-57.04	0


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.73

R-squared: 0.576, Adjusted R-Squared: 0.576

F-statistic vs. constant model: 3.84e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,21.414+0.043079...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.72725	0.0078034	93.197	0
<b>MA{1}</b>	0.23806	0.011422	20.842	1.8002e-96

**DoF**                    5.2941                    0.22685                    23.337                    1.86e-120

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.12459	0.012833	9.7087	2.7672e-22
<b>GARCH{1}</b>	0.75028	0.017924	41.86	0
<b>ARCH{1}</b>	0.13859	0.011249	12.32	7.0409e-35
<b>DoF</b>	5.2941	0.22685	23.337	1.86e-120


```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on
```



```
C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on
```






```

K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))


put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```



```
K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time


a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))
```

## APÊNDICE O – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Paraná (São Mateus do Sul)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```

detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days-1)")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	17.638	0.048973	360.16	0
<b>t</b>	0.020461	0.0027365	7.4769	8.1722e-14
<b>cos(2*pi*t)</b>	4.6041	0.034622	132.98	0
<b>sin(2*pi*t)</b>	0.96708	0.034635	27.922	5.5496e-166
<b>cos(4*pi*t)</b>	-0.70033	0.034622	-20.228	2.1038e-89


```
Number of observations: 11323, Error degrees of freedom: 11318
```

```
Root Mean Squared Error: 2.61
```

```
R-squared: 0.626, Adjusted R-Squared: 0.626
```

```
F-statistic vs. constant model: 4.73e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,18.916+0.078779...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.67473	0.0081549	82.739	0
<b>MA{1}</b>	0.36679	0.0096017	38.2	2.801e-319
<b>DoF</b>	4.8679	0.23573	20.651	9.5778e-95

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.033447	0.0069988	4.779	1.7614e-06
<b>GARCH{1}</b>	0.95777	0.005058	189.36	0
<b>ARCH{1}</b>	0.030088	0.0033521	8.976	2.8075e-19
<b>DoF</b>	4.8679	0.23573	20.651	9.5778e-95


```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
```

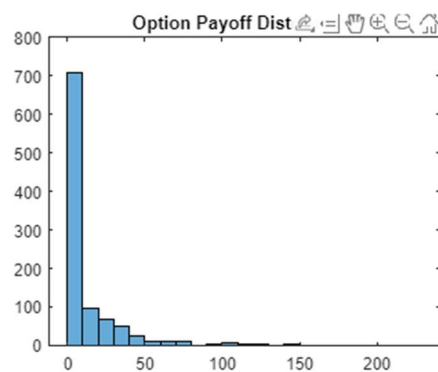
```
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on
```



```
C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on
```



```
K = 30
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 30; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(26 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on


```



```

K = 22
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

```

```

r = 0.01; % Risk-free interest rate
K = 22; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


```

### APÊNDICE P – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Mato Grosso (Primavera do Leste)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```



```


detrendedTemps = detrend(INMET_regressao);

numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on


```





```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```


```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	20.923	0.027303	766.32	0
<b>t</b>	0.068477	0.0015256	44.884	0
<b>cos(2*pi*t)</b>	1.1253	0.019302	58.299	0
<b>sin(2*pi*t)</b>	-0.88935	0.019309	-46.058	0

```
cos(4*pi*t)    -1.0763    0.019302    -55.758    0
```

```
Number of observations: 11323, Error degrees of freedom: 11318
Root Mean Squared Error: 1.45
R-squared: 0.487, Adjusted R-Squared: 0.487
F-statistic vs. constant model: 2.69e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY, 20.923+0.068477 ...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel, trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.81088	0.0062577	129.58	0
<b>MA{1}</b>	0.13673	0.010892	12.553	3.8126e-36
<b>DoF</b>	4.0214	0.14182	28.355	7.2999e-177

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.052223	0.0047542	10.985	4.5294e-28
<b>GARCH{1}</b>	0.75989	0.013118	57.926	0

<b>ARCH{1}</b>	0.18256	0.013312	13.714	8.3318e-43
<b>DoF</b>	4.0214	0.14182	28.355	7.2999e-177

```

nDays = 30;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));


simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);

simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on


```



```

K = 21
figure
alpha = 1;
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```




```

K = 21

```

```
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time


a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))
```

## APÊNDICE Q – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Rondônia (Vilhena)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```

detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```
trendModel =
```

```
Linear regression model:
```

```
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

```
Estimated Coefficients:
```

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	23.198	0.032606	711.47	0
<b>t</b>	0.055418	0.001822	30.416	2.129e-195
<b>cos(2*pi*t)</b>	0.43687	0.023052	18.952	7.0799e-79


```

sin(2*pi*t)    -0.87152    0.02306    -37.794    1.7812e-294
cos(4*pi*t)    -0.8567     0.023052   -37.164    2.3399e-285
    
```

Number of observations: 11323, Error degrees of freedom: 11318  
 Root Mean Squared Error: 1.73  
 R-squared: 0.268, Adjusted R-Squared: 0.268  
 F-statistic vs. constant model: 1.04e+03, p-value = 0

```

figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,23.198+0.055418 ...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
    
```



```

trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
    
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.73581	0.0076956	95.614	0
<b>MA{1}</b>	0.12326	0.010963	11.243	2.4985e-29
<b>DoF</b>	4.517	0.16141	27.984	2.5402e-172

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.02062	0.0026321	7.834	4.7268e-15
<b>GARCH{1}</b>	0.91458	0.0058524	156.27	0
<b>ARCH{1}</b>	0.069239	0.0054381	12.732	3.9109e-37

```

DoF          4.517          0.16141          27.984          2.5402e-172


nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));
simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```




K = 21



```

figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);


r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

```




```

C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

K = 21
figure
alpha = 1;

```

```
chi = alpha*max(C-K, 0);
histogram(chi)
title("Option Payoff Distribution")
```



```
muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))
```

## APÊNDICE R – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – São Paulo (Itapeva)

```
plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```
detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
```

```

Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

```




```

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```

trendModel =
Linear regression model:
    Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)

```

Estimated Coefficients:

	<u>Estimate</u>	<u>SE</u>	<u>tStat</u>	<u>pValue</u>
<b>(Intercept)</b>	18.798	0.049606	378.96	0
<b>t</b>	0.049351	0.0027719	17.804	5.8723e-70
<b>cos(2*pi*t)</b>	3.5024	0.03507	99.87	0
<b>sin(2*pi*t)</b>	0.93971	0.035082	26.786	2.6747e-153
<b>cos(4*pi*t)</b>	-0.57277	0.03507	-16.332	2.7657e-59


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 2.64

R-squared: 0.499, Adjusted R-Squared: 0.498

F-statistic vs. constant model: 2.81e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature ( " + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,18.798+0.049351 ...
    *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<u>Value</u>	<u>StandardError</u>	<u>TStatistic</u>	<u>PValue</u>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.65014	0.0088598	73.381	0
<b>MA{1}</b>	0.33521	0.010435	32.125	1.9446e-226
<b>DoF</b>	5.6109	0.30145	18.613	2.5113e-77

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.031708	0.0059566	5.3232	1.0195e-07
<b>GARCH{1}</b>	0.94353	0.0049714	189.79	0
<b>ARCH{1}</b>	0.046965	0.0040982	11.46	2.0937e-30
<b>DoF</b>	5.6109	0.30145	18.613	2.5113e-77


```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime))

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on
```



```
H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")

grid on
```



```

K = 21
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);


r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))

```




## APÊNDICE S – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Sergipe (Carira)

```

plot(DOY, INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")

```



```

detrendedTemps = detrend(INMET_regressao);


numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);

powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on

[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
    ", " ))

```



```

elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])

```

```
trendModel =
Linear regression model:
  Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	25.215	0.02131	1183.2	0
<b>t</b>	-0.023391	0.0011908	-19.643	1.671e-84
<b>cos(2*pi*t)</b>	2.3944	0.015066	158.93	0
<b>sin(2*pi*t)</b>	1.1048	0.015071	73.304	0
<b>cos(4*pi*t)</b>	-0.48754	0.015066	-32.361	8.3895e-220


Number of observations: 11323, Error degrees of freedom: 11318

Root Mean Squared Error: 1.13

R-squared: 0.74, Adjusted R-Squared: 0.739

F-statistic vs. constant model: 8.04e+03, p-value = 0

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,25.215-0.023391 ...
      *years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
  "MALags", 1, ...
  "Constant", 0, ...
  "Distribution", "t", ...
  "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.85214	0.0059218	143.9	0



<b>MA{1}</b>	0.0051076	0.010915	0.46794	0.63983
<b>DoF</b>	6.704	0.40183	16.684	1.7183e-62

GARCH(1,1) Conditional Variance Model (t Distribution):

	<b>Value</b>	<b>StandardError</b>	<b>TStatistic</b>	<b>PValue</b>
<b>Constant</b>	0.013203	0.0018259	7.2309	4.7969e-13
<b>GARCH{1}</b>	0.89234	0.0083587	106.76	0
<b>ARCH{1}</b>	0.078276	0.0062802	12.464	1.1744e-35
<b>DoF</b>	6.704	0.40183	16.684	1.7183e-62


```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));


simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;

figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "LineWidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
ylabel("Temperature (" + char(176) + "C)")
title("Temperature Simulation")
grid on
```




```
H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on
```



```

K = 21
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

```



```

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time


a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muH/sigmaH)^2)))


C = sum(max(simTemp - 24, 0));
figure
histogram(C)
xlabel("CDDs")
ylabel("Count")
title("Cooling Degree Days Distribution")
grid on

```



```
K = 21
figure
alpha = 1;
chi = alpha*max(C-K, 0);
```

```
histogram(chi)
title("Option Payoff Distribution")
```



```
muC = mean(C);
sigmaC = std(C);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time


a = (K - muC) / sigmaC;

call_option = exp(-r*TTM) * ((muC - K) * normcdf(-a) + (sigmaC /
sqrt(2*pi) * exp(-0.5*a^2)))


put_option = exp(-r*TTM) * ((K - muC) * (normcdf(a) - normcdf(-muC /
sigmaC)) + sigmaC / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-
0.5*(muC/sigmaC)^2)))
```

## APÊNDICE T – Código Texto utilizado no MatlabR2023b para Modelagem da Temperatura e Precificação do Derivativo Climático – Paraná (Clevelândia)

```
plot(DOY,INMET_regressao)
xlabel("Data")
ylabel("Temperatura (" + char(176) + "C)")
title("Temperatura diária")
```




```
detrendedTemps = detrend(INMET_regressao);
numObs = length(detrendedTemps);
Fs = 1;
[pow, freq] = periodogram(detrendedTemps, [], numObs, Fs);
powdB = db(pow);
figure
plot(freq, powdB)
xlabel("Frequency (days^{-1})")
ylabel("Power (dB)")
title("Detrended Temperatures Power Spectrum")
grid on
```



```
[topPow, idx] = findpeaks(powdB, "NPeaks", 2, ...
    "SortStr", "descend", ...
    "MinPeakProminence", 20);
topFreq = freq(idx);
topPeriods = 1 ./ topFreq;

hold on
plot(topFreq, topPow, "r^", "MarkerFaceColor", "r")
xlim([min( topFreq ) - 1e-3, max( topFreq ) + 1e-3])
```

```
legend("Spectrum", "Top periods (days): " + join( string( topPeriods ),
", " ))
```



```
elapsedTime = years(DOY - DOY(1));
designMatrix = @(t) [t, cos( 2 * pi * t ), sin( 2 * pi * t ), cos( 4 *
pi * t )];
trendPreds = ["t", "cos(2*pi*t)", "sin(2*pi*t)", "cos(4*pi*t)"];
trendModel = fitlm(designMatrix(elapsedTime), INMET_regressao,
"VarNames", [trendPreds, "Temperature"])
```


```
trendModel =
Linear regression model:
Temperature ~ 1 + t + cos(2*pi*t) + sin(2*pi*t) + cos(4*pi*t)
```

Estimated Coefficients:

	<b>Estimate</b>	<b>SE</b>	<b>tStat</b>	<b>pValue</b>
<b>(Intercept)</b>	18.153	0.053669	338.23	0
<b>t</b>	-0.014536	0.0029989	-4.847	1.27e-06
<b>cos(2*pi*t)</b>	4.2332	0.037943	111.57	0
<b>sin(2*pi*t)</b>	0.78494	0.037956	20.68	2.7407e-93
<b>cos(4*pi*t)</b>	-0.63513	0.037943	-16.739	3.7822e-62

```
Number of observations: 11323, Error degrees of freedom: 11318
Root Mean Squared Error: 2.85
R-squared: 0.538, Adjusted R-Squared: 0.538
F-statistic vs. constant model: 3.3e+03, p-value = 0
```

```
figure;
plot(DOY, INMET_regressao)
xlabel("Date")
ylabel("Temperature (" + char( 176 ) + "C)")
title("Daily Temperatures")
grid on
hold on
plot(DOY, trendModel.Fitted, "LineWidth", 2)
plot(DOY,18.153-0.014536 ...
*years(DOY - DOY(1)), 'k--', 'LineWidth', 2)
xlim([datetime(1992,1,1), datetime(2022,12,31)])
```



```
trendRes = trendModel.Residuals.Raw;
resModel = arima( "ARLags", 1, ...
    "MALags", 1, ...
    "Constant", 0, ...
    "Distribution", "t", ...
    "Variance", garch( 1, 1 ) );
resModel = estimate(resModel,trendRes);
```

ARIMA(1,0,1) Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0	0	NaN	NaN
<b>AR{1}</b>	0.69002	0.0079496	86.799	0
<b>MA{1}</b>	0.3421	0.0098949	34.573	6.4218e-262
<b>DoF</b>	4.1493	0.17499	23.712	2.6957e-124

GARCH(1,1) Conditional Variance Model (t Distribution):

	Value	StandardError	TStatistic	PValue
<b>Constant</b>	0.042099	0.006252	6.7337	1.654e-11
<b>GARCH{1}</b>	0.92506	0.0052437	176.41	0
<b>ARCH{1}</b>	0.06694	0.0051944	12.887	5.3224e-38
<b>DoF</b>	4.1493	0.17499	23.712	2.6957e-124

```
nDays = 120;
simDates = DOY(end) + caldays(1:nDays).';
simTime = years(simDates - DOY(1));

trendPred = predict(trendModel, designMatrix(simTime));

simRes = simulate(resModel, nDays, "NumPaths", 1000, "Y0", trendRes);
simTemp = simRes + trendPred;


figure
plot(DOY, INMET_regressao)
hold on
plot(simDates, simTemp),

simPrc = prctile(simTemp, [2.5, 50, 97.5], 2);
plot(simDates, simPrc, "y", "Linewidth", 1.5)
xlim([DOY(end) - calyears(1), simDates(end)])
xlabel("Date")
```

```

ylabel("Temperature (" + char( 176 ) + "C)")
title("Temperature Simulation")
grid on


```



```

H = sum(max(24 - simTemp, 0));
figure
histogram(H)
xlabel("HDDs")
ylabel("Count")
title("Heating Degree Days Distribution")
grid on

```



```

K = 21
figure
alpha = 1;
chi = alpha*max(H-K, 0);
histogram(chi)
title("Option Payoff Distribution")

muH = mean(H);
sigmaH = std(H);

r = 0.01; % Risk-free interest rate
K = 21; % Strike value
TTM = 0.25; % Expiry time

a = (K - muH) / sigmaH;

call_option = exp(-r*TTM) * ((muH - K) * normcdf(-a) + (sigmaH /
sqrt(2*pi) * exp(-0.5*a^2)))

```

```
put_option = exp(-r*TTM) * ((K - muH) * (normcdf(a) - normcdf(-muH /  
sigmaH)) + sigmaH / sqrt(2*pi) * (exp(-0.5*a^2) - exp(-  
0.5*(muH/sigmaH)^2))
```

