

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL

**MODELAGEM APLICADA PARA A DETERMINAÇÃO DE
INDICADORES DA DINÂMICA DE BALANÇO DE MASSA:
ESTUDO DE CASO PARA A GELEIRA GREY, CHILE**

por

Victor Huggo Lessa Rosolem

Dissertação para obtenção do Título de
Mestre em Modelagem Computacional

Rio Grande, maio, 2025

Victor Huggo Lessa Rosolem

**“MODELAGEM APLICADA PARA A DETERMINAÇÃO DE INDICADORES DA
DINÂMICA DE BALANÇO DE MASSA: ESTUDO DE CASO PARA A GELEIRA GREY,
CHILE”**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional da Universidade Federal do Rio Grande - FURG, como requisito parcial para obtenção do Grau de Mestre. Área de concentração: Modelagem Computacional.

Aprovada em: 13/05/2025

BANCA EXAMINADORA

Documento assinado digitalmente
 **DINALVA AIRES DE SALES**
Data: 13/05/2025 09:40:25-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Dinalva Aires de Sales (Orientadora – FURG)

Documento assinado digitalmente
 **JEAN MARCEL DE ALMEIDA ESPINOZA**
Data: 13/05/2025 11:33:33-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Jean Marcel de Almeida Espinoza (Coorientador – IFRS)

Documento assinado digitalmente
 **MATHEUS JATKOSKE LAZO**
Data: 13/05/2025 11:23:36-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Matheus Jatkoske Lazo (FURG)

Documento assinado digitalmente
 **CLAUDIO WILSON MENDES JUNIOR**
Data: 13/05/2025 11:40:53-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Claudio Wilson Mendes Junior (UFRGS)

Documento assinado digitalmente
 **PAULO VICTOR DE ARAUJO BRITO LISBOA**
Data: 13/05/2025 11:26:59-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Paulo Victor de Araújo Brito Lisboa (IFRS)

Rio Grande - RS
2025

Ficha Catalográfica

R822m Rosolem, Victor Huggo Lessa.
Modelagem aplicada para a determinação de indicadores da
dinâmica de balanço de massa : estudo de caso para a geleira Grey,
Chile / Victor Huggo Lessa Rosolem. – 2025.
92 f.

Dissertação (mestrado) – Universidade Federal do Rio Grande –
FURG, Programa de Mestrado em Modelagem Computacional, Rio
Grande/RS, 2025.
Orientadora: Dra. Dinalva Aires de Sales.
Coorientador: Dr. Jean Marcel de Almeida Espinoza.

1. Modelagem computacional. 2. Sensoriamento remoto. 3.
Criosfera. 4. Geleira Grey (Chile). 5. Mudança climática. 6. Google
Earth Engine. I. Sales, Dinalva Aires de. II. Espinoza, Jean Marcel de
Almeida. III. Título.

CDU 551.32(83)

Catálogo na Fonte: Bibliotecária Sabrina Vaz da Silva CRB 10/2243

Dedico esta dissertação a minha Vó Creusa. Te levarei em meu coração para todo o sempre.

AGRADECIMENTOS

A conclusão desta dissertação representa o resultado de uma jornada marcada por desafios, aprendizados e conquistas, e não teria sido possível sem o apoio de muitas pessoas e instituições. Em primeiro lugar, agradeço à minha orientadora e ao meu coorientador, Prof.^a Dra. Dinalva Aires de Sales e Dr. Jean Marcel de Almeida Espinoza, pela orientação e colaboração ao longo de todo o processo. Suas contribuições foram fundamentais para meu crescimento acadêmico e pessoal.

Sou profundamente grato à FURG por ter me dado a oportunidade de fazer parte desta instituição e desenvolver-me como estudante e futuro profissional. A FURG me ofereceu um ambiente seguro e acolhedor, que me permitiu evoluir tanto pessoal quanto profissionalmente, e isso é algo que sempre levarei comigo. Também sou grato ao Programa de Pós-Graduação em Modelagem Computacional e aos professores, cujas aulas, sugestões e incentivos foram essenciais para ampliar meu conhecimento e aprimorar minha pesquisa. À agência de fomento CAPES, pelo apoio financeiro e pela confiança em minha pesquisa.

Agradeço aos amigos e colegas de curso, especialmente ao meu amigo Felipe, que compartilhou comigo momentos de troca intelectual, apoio mútuo e pelos momentos de descontração que me ajudaram a manter o equilíbrio ao longo dessa jornada, contribuindo para que essa trajetória fosse mais leve e enriquecedora.

Não poderia deixar de mencionar minha família, que foi meu alicerce em todos os momentos. Aos meus pais, Elisângela e Geraldo, agradeço pelo amor, pelo incentivo constante e por acreditarem em mim mesmo nos momentos mais difíceis. Além disso, quero agradecer às minhas irmãs Victória e Yasmim, que estiveram presentes nos momentos de alegria e conquistas, e que sempre foram minhas parceiras de riso e diversão. Expresso minha profunda gratidão à minha namorada e companheira, Laís, sua presença constante ao longo desta jornada acadêmica foi um verdadeiro alicerce.

Por fim, agradeço a Deus por me dar saúde, força e perseverança para superar os desafios enfrentados durante esta etapa da minha vida. A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, deixo aqui minha sincera gratidão.

RESUMO

Esta dissertação investiga a dinâmica do balanço de massa da geleira Grey, localizada no Campo de Gelo Patagônico Sul (CGPS)/Chile, utilizando técnicas de modelagem computacional e sensoriamento remoto. O estudo abrange o período de 2000 a 2024, empregando imagens dos sensores dos satélites da série LANDSAT e dados climáticos da reanálise ERA5-Land. A metodologia desenvolvida implementa uma abordagem automatizada no Google Earth Engine (GEE) para classificação da área glacial e determinação do deslocamento de sua frente. Esta abordagem utiliza índices espectrais como *Normalized Difference Snow Index* (NDSI) e *Normalized Difference Water Index* (NDWI), análise de textura e operações morfológicas para identificar e delimitar a área da geleira. A validação foi realizada comparando os resultados obtidos com dados vetoriais do projeto Global Land Ice Measurements from Space (GLIMS), demonstrando uma sobreposição superior a 94% nas áreas classificadas. Os resultados revelam uma perda significativa de 10,76 km² na área da porção frontal da geleira durante o período analisado, com uma taxa média de retração de aproximadamente 0,47 km² por ano ($R^2 = 0,98$, p-valor < 0,001). O deslocamento acumulado da frente da geleira foi estimado em 706 m, evidenciando um recuo contínuo, com períodos de retração mais intensa entre 2002-2009 (140 m) e 2011-2013 (133 m). A análise de Funções Ortogonais Empíricas (EOF) identificou que os dois primeiros modos explicam cerca de 75% da variância total observada. O primeiro modo (58,02%) está associado principalmente às variações na região frontal da geleira, enquanto o segundo modo (16,96%) representa padrões mais localizados e possivelmente relacionados a eventos climáticos específicos. A Decomposição em Valores Singulares (SVD) demonstrou correlações significativas entre os padrões espaciais da geleira e variáveis climáticas. A temperatura apresentou correlação negativa significativa ($\rho = -0,66$, p-valor = 0,008), indicando que o aumento da temperatura está diretamente associado ao recuo glacial. A precipitação de neve ($\rho = 0,55$, p-valor = 0,033) e o albedo ($\rho = 0,52$, p-valor = 0,046) mostraram correlações positivas moderadas, enquanto a evaporação ($\rho = 0,17$, p-valor = 0,551) e a velocidade do vento ($\rho = -0,12$, p-valor = 0,680) não apresentaram correlações significativas. O teste de Mann-Kendall aplicado às séries temporais climáticas confirmou uma tendência linear significativa de aumento na temperatura (p-valor = 0,038, $Z = 2,079$), fator determinante para o recuo glacial. As demais variáveis climáticas não apresentaram tendências significativas, embora a precipitação tenha mostrado uma tendência de diminuição próxima ao limiar de significância. A modelagem dinâmica da área superficial da geleira Grey revelou uma tendência negativa significativa ao longo do tempo, com uma redução total de -10,67 km² no período modelado. A comparação com os dados obtidos do GEE demonstrou uma convergência e uma correlação positiva significativa ($R^2 = 0,88$), validando o modelo para análises de tendências de longo prazo.

Palavras-chave: Criosfera, Geleiras, Mudanças Climáticas, Sensoriamento Remoto, Google Earth Engine.

ABSTRACT

This dissertation investigates the mass balance dynamics of the Grey Glacier, located in the Southern Patagonian Ice Field (SPI)/Chile, using computational modeling and remote sensing techniques. The study covers the period from 2000 to 2024, employing images from the LANDSAT series and climate data from the ERA5-Land reanalysis. The developed methodology implements an automated approach in Google Earth Engine (GEE) to classifying the glacial area and determining the displacement of its front. This approach uses spectral indices such as NDSI (Normalized Difference Snow Index) and NDWI (Normalized Difference Water Index), texture analysis, and morphological operations to identify and delimit the glacier area. The methodology was validated by comparing the results obtained with vector data from the Global Land Ice Measurements from Space (GLIMS) project, demonstrating an overlap of over 94% in the classified areas. The results reveal a significant loss of 10.76 km² in the area of the frontal portion of the glacier during the analyzed period, with an average retreat rate of approximately 0.47 km² per year ($R^2 = 0.98$, p-value < 0.001). The accumulated displacement of the glacier front was estimated at 706 m, showing a continuous retreat, with periods of more intense retreat between 2002-2009 (140 m) and 2011-2013 (133 m). Empirical Orthogonal Functions (EOF) analysis identified that the first two modes explain about 75% of the total observed variance. The first mode (58.02%) is mainly associated with variations in the frontal region of the glacier, while the second mode (16.96%) represents more localized patterns and possibly related to specific climatic events. Singular Value Decomposition (SVD) demonstrated significant correlations between the spatial patterns of the glacier and climatic variables. Temperature showed a significant negative correlation ($\rho = -0.66$, p-value = 0.008), indicating that the increase in temperature is directly associated with glacial retreat. Snow precipitation ($\rho = 0.55$, p-value = 0.033) and albedo ($\rho = 0.52$, p-value = 0.046) showed moderate positive correlations, while evaporation ($\rho = 0.17$, p-value = 0.551) and wind speed ($\rho = -0.12$, p-value = 0.680) did not show significant correlations. The Mann-Kendall test applied to the climatic time series confirmed a significant increasing linear trend in temperature (p-value = 0.038, $Z = 2.079$), a determining factor for the observed glacial retreat. The other climatic variables did not show significant trends, although precipitation showed a decreasing trend close to the significance threshold. Dynamic modeling of the Grey Glacier's surface area revealed a significant negative trend over time, with a total reduction of -10.67 km² in the modeled period. Comparison with data obtained from GEE demonstrated convergence and a significant positive correlation ($R^2 = 0.88$), validating the model for long-term trend analysis.

Keywords: Cryosphere, Glaciers, Climate Changes, Remote Sensing, Google Earth Engine.

ÍNDICE

1	INTRODUÇÃO	14
1.1	Área de Estudo	15
1.2	Objetivos	18
1.2.1	Objetivo geral	18
1.2.2	Objetivos específicos	18
2	EMBASAMENTO TEÓRICO	19
2.1	Fundamentos da Glaciologia	19
2.1.1	Geleiras e seus tipos	19
2.1.2	Transformação da Neve em <i>Firn</i> e Gelo	19
2.1.3	Dinâmica das Geleiras	20
2.1.4	Fluxo Glacial	21
2.1.5	Componentes principais do Fluxo Glacial	22
2.1.6	Balanço de massa de uma Geleira	24
2.2	Modelagem da dinâmica das Geleiras	25
2.3	Modelagem dinâmica com VENSIM	26
2.4	Sensoriamento remoto e propriedades eletromagnéticas das geleiras	28
2.4.1	Índices físicos da neve, gelo e da água	30
2.4.2	A série LANDSAT	30
2.4.3	Modelos Digitais de Elevação: Terminologia e Definições	33
2.5	A Plataforma Google Earth Engine (GEE)	34
2.5.1	Operações Morfológicas no GEE	35
2.5.2	Convolução no GEE	36
2.6	Classificação Supervisionada e Não Supervisionada	36
2.6.1	Classificação por limiarização	37
2.7	Análise de Funções Ortogonais Empíricas (EOF)	38
2.8	Análise de Decomposição em Valores Singulares (SVD)	39
2.9	Teste de Mann-Kendall	40
3	MATERIAIS E MÉTODOS	42
3.1	Dados	42
3.1.1	Imagens de sensores Satelitais Utilizadas	42
3.1.2	Dados Vetoriais GLIMS	42
3.1.3	Dados Climáticos	43
3.2	Métodos	43
3.2.1	Seleção e Pré-Processamento das imagens dos sensores da série LANDSAT	45
3.2.2	Determinação da Área e da Frente da Geleira com GEE	45
3.2.3	Análise EOF, SVD e Séries Temporais	46
3.2.4	Modelagem do Balanço da Área da Geleira	47
4	RESULTADOS E DISCUSSÃO	50

4.1	Classificação por GEE vs. GLIMS	50
4.2	Variação Espacial da geleira Grey 2000-2024	54
4.3	Análise EOF	59
4.4	Análise SVD	60
4.5	Modedo dinâmico para a variabilidade da área superficial da geleira Grey	65
4.6	Variação espacial da geleira Grey frente as mudanças climáticas	68
5	CONCLUSÃO	73
	REFERÊNCIAS	78
6	APÊNDICES	92
6.1	Imagens no espectro visível	92
6.2	Classificações binárias obtidas via GEE obtidas entre o período de 2000 a 2024 .	93

LISTA DE FIGURAS

Figura 1:	Localização da área de estudo. Fonte: Elaboração própria a partir de dados do Bing Maps (2025).	16
Figura 2:	Fluxo gravitacional impulsionado pelo acumulo de massa entre as áreas de acumulação e ablação. Fonte: (CUFFEY; PATERSON, 2010).	20
Figura 3:	Corte transversal da distribuição de velocidade vertical e velocidade de superfície (U) em uma geleira com os três componentes do movimento do gelo: deformação interna (U_c), deslizamento basal (U_s) e deformação do leito (U_d). U_s e U_d combinados também podem ser denotados como movimento basal (U_b). Fonte: (JISKOOT, 2011).	23
Figura 4:	Diagramas de dois perfis de velocidade transversais em geleiras (a) Fluxo parabólico aproximado e (b) "Plug flow". As linhas hachuradas representam margens de cisalhamento. Fonte: (JISKOOT, 2011).	23
Figura 5:	Exemplo simples de balanço parcial de uma geleira.	27
Figura 6:	Curvas de referência espectral da neve e gelo em diferentes estágios. Adaptado de ZENG et al. (1984).	29
Figura 7:	Diagrama metodológico.	44
Figura 8:	Modelo dinâmico construído no VENSIM.	49
Figura 9:	Classificação da área utilizando GEE e arquivo vetorial GLIMS para o ano de 2000 (a) Área classificada com GEE; (b) Área classificada pelo GLIMS.	51
Figura 10:	Classificação da área utilizando GEE e arquivo vetorial GLIMS para o ano de 2016 (a) Área classificada com GEE; (b) Área classificada pelo GLIMS.	51
Figura 11:	<i>Overlay</i> da área do GEE e arquivo vetorial GLIMS para os anos de 2000 e 2016 (a) Ano de 2000; (b) Ano de 2016.	52
Figura 12:	Comparação entre os vetores de movimentação gerados a partir das distâncias entre as centróides de 2000 e 2016 (a) Vetor gerado a partir da classificação via GEE; (b) Vetor gerado a partir da classificação via arquivo vetorial GLIMS.	53
Figura 13:	Classificações obtidas via GEE obtidas entre o período de 2000 a 2024.	54
Figura 14:	Áreas das geleiras obtidas a partir da classificação via GEE.	56
Figura 15:	Deslocamento acumulado obtido através das diferenças entre os centróides ano a ano.	57
Figura 16:	Vetor de movimentação gerado a partir das distâncias entre as centróides de 2000 e 2024 obtidos via GEE.	58
Figura 17:	Deslocamento acumulado gerado a partir das distâncias entre os centróides ano a ano referente ao período de 2000 a 2024.	59
Figura 18:	Análise dos padrões espaciais e temporais da geleira via EOF (a) Primeiro Modo (EOF1); (b) Segundo Modo (EOF2); (c) Componentes principais referentes a EOF1 e EOF2.	60

Figura 19: Análise dos padrões espaciais e temporais da geleira conjuntamente da temperatura via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da temperatura; (c) Componentes principais referentes aos modos.	61
Figura 20: Análise dos padrões espaciais e temporais da geleira conjuntamente da precipitação de neve via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da precipitação de neve; (c) Componentes principais referentes aos modos.	62
Figura 21: Análise dos padrões espaciais e temporais da geleira conjuntamente do albedo via SVD (a) Primeiro modo da geleira; (b) Primeiro modo do albedo; (c) Componentes principais referentes aos modos.	63
Figura 22: Análise dos padrões espaciais e temporais da geleira conjuntamente da evaporação via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da evaporação; (c) Componentes principais referentes aos modos.	63
Figura 23: Análise dos padrões espaciais e temporais da geleira conjuntamente da velocidade do vento via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da velocidade do vento; (c) Componentes principais referentes aos modos.	64
Figura 24: Variação da área frontal da geleira Grey modelada no VENSIM em 25 anos.	66
Figura 25: Acumulado da variação da área frontal da geleira Grey modelada no VENSIM.	66
Figura 26: Área acumulada para a geleira Grey. Em vermelho está a área acumulada obtida no VENSIM, enquanto em azul está a obtida no GEE.	67
Figura 27: Dispersão das áreas acumuladas do VENSIM e do GEE.	68
Figura 28: Médias anuais das anomalias do verão (DJF) para as forçantes climáticas (a) Temperatura; (b) Precipitação; (c) Albedo; (d) Evaporação; (e) Velocidade do vento.	69
Figura 29: Imagens no espectro visível.	92
Figura 30: Classificações binárias obtidas via GEE obtidas entre o período de 2000 a 2024.	93

LISTA DE TABELAS

Tabela 1:	Varição (ma^{-1}) da frente da geleira Grey entre os anos de 1937 a 2003. Fonte: RIVERA; CASASSA (2004).	17
Tabela 2:	Sensor TM/LANDSAT-5.	31
Tabela 3:	Sensor ETM+/LANDSAT-7.	31
Tabela 4:	Sensores OLI e TIRS/LANDSAT-8.	32
Tabela 5:	Sensores OLI-2 e TIRS-2/LANDSAT-9.	33
Tabela 6:	Informações técnicas das imagens selecionadas para o trabalho.	42
Tabela 7:	Classificações feitas pelo GEE e o GLIMS para 2000 e 2016.	50
Tabela 8:	Classificação da área da geleira e área acumulada.	55
Tabela 9:	Deslocamento ano por período e o acumulado.	56
Tabela 10:	Área modelada e Área modelada acumulada.	65

LISTA DE ABREVIATURAS

ALOS	Advanced Land Observing Satellite
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
CBERS	China-Brazil Earth Resources Satellite
CGPS	Campo de Gelo Patagônico Sul
CNES	Centre National d'Études Spatiales
DEM	Digital Elevation Model
DLR	Deutsches Zentrum für Luft- und Raumfahrt
EDEM	Edited DEM
EOF	Empirical Orthogonal Functions
ESA	European Space Agency
ETM+	Enhanced Thematic Mapper Plus
GDEM	Global Digital Elevation Model
GEE	Google Earth Engine
GIS	Geographic Information Systems
GLIMS	Global Land Ice Measurements from Space
GlacierMIP	Glacier Model Intercomparison Project
GloGEM	Global Glacier Evolution Model
IPCC	Intergovernmental Panel on Climate Change
JAXA	Japan Aerospace Exploration Agency
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
NASA	National Aeronautics and Space Administration
NDSI	Normalized Difference Snow Index
NDWI	Normalized Difference Water Index
NGA	National Geospatial-Intelligence Agency
NIR	Near Infrared
OLI/OLI-2	Operational Land Imager
PCA	Principal Component Analysis
PRISM	Panchromatic Remote-sensing Instrument for Stereo Mapping
PyGEM	Python Glacier Evolution Model
RGI	Randolph Glacier Inventory
SRTM	Shuttle Radar Topography Mission
SVD	Singular Value Decomposition
SWIR	Short Wavelength InfraRed
TIRS/TIRS-2	Thermal Infrared Sensor
TM	Thematic Mapper
USGS	United States Geological Survey
WGMS	World Glacier Monitoring Service

1 INTRODUÇÃO

A criosfera representa todos os elementos do sistema terrestre que contêm uma porção significativa de água em estado sólido. Essa região abrange diversos componentes, incluindo neve, gelo marinho, mantos de gelo, plataformas de gelo, geleiras, calotas de gelo e solo congelado (i.e., *permafrost*), que podem ser encontrados tanto na superfície terrestre como sob as águas oceânicas (MEREDITH et al., 2019).

Como aponta o Painel Intergovernamental sobre Mudanças Climáticas em seu relatório de 2023 (IPCC., 2023), as geleiras estão retraindo e perdendo massa em todo o mundo, em sincronia com o aquecimento atmosférico (ORLOVE, 2009). Sem a neve ou gelo, o sistema atmosfera-terra e os oceanos ganhariam energia através de um *feedback* positivo, e o nosso planeta se aqueceria até um novo ponto de equilíbrio (DERKSEN; BROWN, 2012; MUDRYK et al., 2017; CHANGE, 2014).

O monitoramento de geleiras é dificultoso e complexo devido à distância e inacessibilidade do terreno e aos desafios para a realização de trabalhos de campo extensos (TALOOR et al., 2021). A aplicação de sensoriamento remoto em geleiras começou na década de 1970, iniciando uma nova fase no monitoramento de geleiras, resolvendo em certa medida as limitações e as dificuldades do monitoramento dessas feições (VEETTIL; KAMP, 2019). Os dados obtidos por sensores remotos fornecem informações valiosas, constantemente atualizadas e quase em tempo real sobre geleiras e as feições associadas (VEETTIL; KAMP, 2019; RACOVITEANU et al., 2009; TALOOR et al., 2021).

Em escala global e regional, a extensão das geleiras pode ser derivada por meio de algoritmos de classificação automatizados aplicados a dados de imageamento orbital (RACOVITEANU et al., 2009), como os das missões LANDSAT com mais de cinco décadas de informações globais disponíveis gratuitamente (<https://earthexplorer.usgs.gov/>). Métodos automatizados para classificação de geleiras a partir de dados multiespectrais foram desenvolvidos e testados nas últimas décadas e provaram ser adequados para detectar o gelo de geleiras, limpo ou ligeiramente sujo, e neve fresca ou em metamorfismo (RACOVITEANU et al., 2009; ALBERT, 2002; PAUL; KÄÄB; HAEBERLI, 2007).

No entanto, os esforços de mapeamento da cobertura de geleiras não têm um registro único da área de uma geleiras, havendo muitas áreas não avaliadas em todo o globo, além de grandes incertezas sobre essas extensões, em virtude dos métodos empregados. Esses levantamentos ou inventários, contêm informações de diferentes épocas climáticas em cada geleira (MARTA et al., 2021), tornando sua comparação temporal difícil. Essas iniciativas também adotam metodologias baseadas em fotointerpretação e vetorização manual, como o *Global Land Ice Measurements from Space* (GLIMS) e *World Glacier Monitoring Service* (WGMS), que através da cooperação de grupos de pesquisa distribuídos no mundo, realiza a delimitação de geleiras, baseada nessa abordagem (VEETTIL; KAMP, 2019; RACOVITEANU et al., 2009). Portanto, é necessário ter um registro temporal climaticamente síncrono e comparável das áreas de geleiras

para observar sua resposta às mudanças e variabilidades climáticas, reduzindo as flutuações de interpretação humana dessas estimativas (TALOOR et al., 2021).

Uma geleira pode ser dividida em duas parcelas principais: (1) a região de acumulação; e, (2) a região de ablação. A ablação engloba todos os processos pelos quais uma geleira perde massa, incluindo derretimento, evaporação, desprendimento, erosão eólica e avalanches (FELL et al., 2018). A região de acumulação é aquela onde os processos de ganho de massa, como a acumulação de neve ou gelo, superam as perdas causadas pelos processos de ablação. Na região de ablação, ocorre o contrário, ou seja, as perdas são maiores que os ganhos de massa.

A diferença entre o ganho e a perda de massa é conhecida como balanço de massa da geleira, que é um indicativo do seu estado de equilíbrio. Quando esse balanço é negativo, há perda de massa de gelo, contribuindo para o aumento do nível médio dos oceanos, com exceção das geleiras de maré, e redução do albedo terrestre, por exemplo JOHNSON; RUPPER (2020), além de possíveis impactos na dinâmica oceânica tanto local quanto global. Esses dados sobre a dinâmicas das geleiras são fundamentais para permitir a modelagem do balanço de massa de uma geleira, principal indicador do nível de estabilidade dessa feição (PADMAN et al., 2012).

Nos últimos anos, a disponibilidade, acessibilidade e continuidade temporal e espacial de dados oriundos de sensores orbitais, presentes em satélites das séries como LANDSAT e SENTINEL, e o desenvolvimento de plataformas de computação em nuvem, como o Google Earth Engine (GEE), criaram uma oportunidade para mapear a evolução histórica da mudança na cobertura terrestre, como corpos d'água e geleiras com uma abordagem de *Big Data* (WOOD et al., 2021; TALOOR et al., 2021; VEETTIL, 2018; LI; XU, 2021; SOUZA JR et al., 2019; KAMP; PAN, 2015; PAUL et al., 2016; BURNS; NOLIN, 2014; KOZHIKKODAN VEETTIL; SOUZA, 2017).

Apesar do progresso feito nos últimos anos, na avaliação das áreas de geleiras, ainda existem muitos casos em que a delimitação automática das fronteiras das geleiras em imagens de sensores remotos é complexa, propensa a erros ou demorada (RACOVITEANU et al., 2009; CRAWFORD et al., 2013). Na maioria dos casos, as estimativas de mudança na cobertura de geleiras cobrem períodos de 5 ou 10 anos (VEETTIL, 2018; KOZHIKKODAN VEETTIL; SOUZA, 2017; FRANCOU et al., 2000).

Neste contexto, é fundamental desenvolver abordagens metodológicas rigorosas de modelagem computacional que apoiem a determinação de estimativas de balanço de massa em geleiras. Essas abordagens podem ser empregadas para o reconhecimento de padrões que identifiquem a presença e os processos de balanço de massa em geleiras, a partir da análise de dados de sensoriamento remoto e o desenvolvimento de modelos dinâmicos para simulação da evolução do balanço de massa dessas feições.

1.1 Área de Estudo

A geleira Grey (Coordenadas geográficas centrais: Lat. 50.9°S, Lon. 73.3°W, datum WGS84) está localizada na região do Campo de Gelo Patagônico Sul (CGPS), tem uma área

243 km² e deságua no Lago Grey, por meio de três terminais distintos (SUGIYAMA et al., 2021), visto na Figura 1. O CGPS estende-se de 48°20'S a 51°30'S ao longo de 73°30'W por cerca de 350 km com largura de até 60 km (ANIYA et al., 1993). Segundo ANIYA et al. (1993), as geleiras localizadas na região do CGPS são sensíveis e estão entre os mais suscetíveis as mudanças climáticas.




Figura 1: Localização da área de estudo. Fonte: Elaboração própria a partir de dados do Bing Maps (2025).

Em um estudo publicado por RIVERA; CASASSA (2004), foram realizadas estimativas abrangentes sobre diversas características das geleiras situadas no Parque Nacional Torres del Paine, Chile. Estes incluíram o comprimento, área total, extensão de gelo, orientação, posição das frentes das geleiras, bem como as elevações máxima e mínima.

Os resultados revelaram uma tendência preocupante de diminuição da área coberta por gelo no parque, totalizando aproximadamente -62,2 km² desde o ano de 1945, o que representa uma redução correspondente a -8% da área total de gelo registrada neste período. Os valores estimados das alterações resultaram na variação da frente da geleira Grey, demonstrado pela tabela 1.

É possível observar através da tabela 1, que entre os anos de 1937 até 1945, o recuo da geleira Grey ocorreu de forma moderada, mas com uma tendência negativa, ao longo dos anos. Os autores RIVERA; CASASSA (2004), destacam que, entre 1975 e 1995, uma notável taxa

Tabela 1: Variação (ma^{-1}) da frente da geleira Grey entre os anos de 1937 a 2003. Fonte: RIVERA; CASASSA (2004).

Período	Braço Ocidental	Braço Oriental
1937-1945	-14	-12
1945-1975	-31	-3
1975-1986	-23	-16
1986-1995	-50	-56
1995-1997	-768	-125
1997-2000	-60	-75
2000-2003	Estável	-67
Total	-946	-354

de degelo foi observada nessa geleira, possivelmente associada a um aumento na velocidade do fluxo de gelo e nas alterações positivas de temperatura para as estações, resultando na extensão longitudinal da porção inferior da geleira. Esse fenômeno pode ter desencadeado o processo de desprendimento (*calving*) na geleira, culminando em uma grande perda ocorrida em 1997.

Segundo DAVIES; GLASSER (2012), o intenso derretimento das geleiras da Patagônia é atribuído principalmente a um aumento nas temperaturas atmosféricas, como confirmam os sequentes levantamentos climáticos locais (IPCC., 2023). Essa tendência de aquecimento, observada durante o século XX e início do século XXI, levou ao afinamento e recuo generalizado das geleiras na região.

Fatores como a latitude, continentalidade e altitude também influenciam na taxa de derretimento. Além disso, mudanças na precipitação também podem ter desempenhado um papel no aumento do derretimento, particularmente nas primeiras décadas do período entre 1870 e 1986 (DAVIES; GLASSER, 2012).

As geleiras que encerram seu ciclo em lagos ou no oceano frequentemente retrocedem mais rapidamente do que aquelas localizadas em terra firme (VEEN, 2002; POST et al., 2011). Isso ocorre porque estão mais suscetíveis a perder quantidades significativas de gelo devido a eventos de *calving*, especialmente no atual cenário de mudanças climáticas (BENN; WARREN; MOTTRAM, 2007; TRUFFER; MOTYKA, 2016).

As geleiras são consideradas grandes reservatórios naturais de água doce, correspondendo a 77% de toda a água doce do planeta (REES, 2005). Em regiões como a Cordilheira dos Andes, que se estende por aproximadamente 7.000 km ao longo da costa oeste da América do Sul (DAVIES; GLASSER, 2012), essas massas de gelo possuem significativa importância econômica, atuando como fontes de nascentes que formam rios utilizados para o abastecimento de água, geração de energia elétrica e irrigação.

Dada a relevância econômica dessas geleiras, bem como os riscos de enchentes e deslizamentos decorrentes de seu derretimento acelerado, além de seu papel como indicador de mudanças climáticas, o monitoramento de geleiras temperadas, como a geleira Grey, tornou-se uma necessidade premente. Tal acompanhamento é fundamental para a compreensão da evolução dessas grandes massas de gelo frente às evidentes alterações climáticas.

1.2 Objetivos

1.2.1 Objetivo geral

O objetivo central deste estudo é desenvolver uma modelagem para a identificação de padrões que caracterizem a evolução de indicadores de balanço de massa de geleiras, como a posição da frente e sua extensão, utilizando dados de sensoriamento remoto referentes ao período de inventário de geleiras do projeto GLIMS.

1.2.2 Objetivos específicos

Para alcançar o objetivo principal, foram estabelecidos os seguintes objetivos específicos:

- Determinar uma abordagem automatizada para a determinação da frente da geleira Grey com o uso da ferramenta GEE;
- Estimar o deslocamento da frente da geleira Grey;
- Avaliar a acurácia dessas estimativas a partir dos dados de referência do GLIMS;
- Implementar um modelo dinâmico para avaliar indicadores do balanço de massa da geleira Grey.

2 EMBASAMENTO TEÓRICO

2.1 Fundamentos da Glaciologia

2.1.1 Geleiras e seus tipos

As geleiras são entendidas como uma massa de gelo e neve que se move continuamente, por fluência (i.e., deformação interna) ou por deslizamento basal, do ponto mais alto para o mais baixo (SIMÕES, 2004). Essas massas de gelo não são uniformes e homogêneas, podendo ser divididas em zonas ou fácies, de acordo com as suas características superficiais e internas (PATERSON, 1994). Elas são formadas por sucessivas camadas de neve compactada e recristalizada, de vários períodos, em regiões onde a acumulação de neve é superior a ablação (MENDONÇA, 2013).

As geleiras são classificadas de acordo com sua morfologia e características térmicas. As formas mais comuns de geleira são geleiras de anfiteatro, geleiras de montanha, geleiras de vale, geleiras nicho, geleiras de piemonte, geleiras de rocha e as geleiras que se desprendem do mar são chamadas de geleiras de maré (BARRY; GAN, 2022).

As geleiras podem ser classificadas morfológicamente em três tipos: (I) restritas, (II) irrestritas (III) e de maré (OLIVEIRA, 2013; BENN; EVANS, 2014). Geleiras restritas, comuns em altas montanhas, têm seu movimento condicionado pela topografia do terreno, enquanto as irrestritas, como mantos de gelo e calotas polares, fluem livremente, independentemente do relevo (HAGG, 2022). Geleiras de maré terminam no oceano e perdem gelo através de *calving*, onde blocos se desprendem, sendo influenciadas pela profundidade da água e pelas marés. Elas passam por ciclos de avanço e recuo, com exemplos no Alasca e Patagônia (BARRY; GAN, 2022).

A classificação térmica das geleiras é determinada pelo perfil de temperatura do gelo glacial. Geleiras temperadas estão no ponto de fusão sob pressão, exceto na superfície durante o inverno, e possuem água de degelo presente (É comum em montanhas de latitudes médias e regiões tropicais, com exceção de altitudes muito elevadas) BARRY; GAN, 2022. Por outro lado geleiras polares (Encontradas em regiões polares) geralmente estão congeladas até a sua base e não apresentam derretimento superficial (BARRY; GAN, 2022).

geleiras politermicas são mais complexas; elas podem estar abaixo do ponto de congelamento na zona de ablação e temperadas até certa profundidade na zona de acumulação; ou podem estar principalmente abaixo do ponto de congelamento, mas temperadas em sua base (HAGG, 2022). Além disto, elas podem conter canais de água supraglaciais durante a estação de degelo.

2.1.2 Transformação da Neve em *Firn* e Gelo

O processo inicial que culmina na formação das massas de gelo glacial tem origem na precipitação de neve sobre as geleiras (BENNETT; GLASSER, 2011). Contudo, a transição da neve recém-caída para o gelo compacto não é um evento simples e imediato, mas sim uma

jornada comumente longa e intrincada. A velocidade com que essa metamorfose ocorre está intimamente ligada às condições térmicas prevalentes.

Nas geleiras de regiões temperadas, a alternância entre períodos de degelo e de recongelamento da neve úmida propicia uma transformação relativamente acelerada. Contudo, na Antártica central, onde as temperaturas permanecem abaixo do ponto de congelamento o ano todo, esse processo é significativamente mais lento. Assim, não há um mecanismo único regendo essa transição, mas sim diferentes mecanismos operando em ambientes distintos (CUFFEY; PATERSON, 2010).

A partir da precipitação e o acúmulo da neve, a compactação produz eliminação das bolhas de ar e o posterior incremento das ligações entre os cristal de gelo, gerando estrutura policristalina (BENNETT; GLASSER, 2011; MENDONÇA, 2013). Essa fase é conhecida como *firn*, que segundo SIMÕES (2004) é identificado por características tais como cristais soldados uns aos outros, mas onde ainda persiste a conexão dos espaços intergranulares (ou seja, ainda é permeável).

O limite *firn*-gelo, por sua vez, é marcado pelo fechamento da conexão entres os poros, e ocorre quando a densidade atinge $0,83 \text{ g.cm}^{-3}$. No gelo glacial, o ar está presente na forma de bolhas. A compressão das bolhas é em grande parte responsável por novos aumentos de densidade (CUFFEY; PATERSON, 2010).

2.1.3 Dinâmica das Geleiras

As geleiras, exibem um fluxo gravitacional encosta abaixo, impulsionado pelo acúmulo de massa na zona de acumulação e pela subsequente ablação na zona de ablação, demonstrado na Figura 2. Este equilíbrio dinâmico, denominado fluxo de equilíbrio, visa manter um perfil glacial estável, conforme teorizado por CLARKE (1987). A velocidade do fluxo, conhecida como velocidade de equilíbrio, é modulada pelo balanço de massa e pela geometria da geleira. No entanto, devido à natureza retardada da resposta glacial ao acúmulo, flutuações no balanço de massa resultam em variações de velocidade assíncronas e defasadas, influenciando as taxas de avanço e recuo glacial, conforme demonstrado por JÓHANNESSON; RAYMOND; WADDINGTON (1989).




Figura 2: Fluxo gravitacional impulsionado pelo acúmulo de massa entre as áreas de acumulação e ablação. Fonte: (CUFFEY; PATERSON, 2010).

Desvios do fluxo de equilíbrio, onde os fluxos medidos divergem significativamente do fluxo de equilíbrio, podem levar à depleção glacial ou a comportamentos pulsantes, caracterizados por alternâncias entre fluxos lentos e rápidos. Geleiras de maré instáveis e correntes de gelo são exemplos notáveis de sistemas pulsantes (CLARKE, 1987).

A dinâmica do fluxo glacial é governada por um complexo conjunto de fatores, incluindo a geometria do gelo (espessura e inclinação), propriedades físicas (temperatura, impurezas e densidade), características do vale, condições do leito (congelado/descongelado, rigidez do substrato e tipo de drenagem subglacial), presença de gelo flutuante e taxas de acumulação/ablação (balanço de massa superficial).

A interação desses fatores resulta em velocidades de fluxo variáveis, geralmente inferiores a algumas centenas de metros por ano para geleiras de vale e até vários quilômetros por ano para geleiras de descarga (PATERSON, 1994). Além disso, flutuações sazonais de velocidade são observadas, com picos no início da estação de degelo devido à disponibilidade de água de degelo e ao desenvolvimento gradual dos sistemas de drenagem subglacial.

O movimento glacial desempenha um papel fundamental na escultura da paisagem, através da erosão da rocha subjacente e do transporte de sedimentos glaciais (*till*), resultando em feições geomorfológicas distintas, como as morainas. Além disso, processos glaciofluviais, glaciolacustres e o desprendimento de icebergs contribuem para a modificação da paisagem. Massas de gelo espessas induzem a subsidência isostática da astenosfera e litosfera, seguida por rebote isostático após o degelo, impactando o nível relativo do mar em regiões anteriormente glaciadas.

2.1.4 Fluxo Glacial

O movimento de uma geleira é governado por mecanismos de viscosidade plástica, os quais são influenciados pela temperatura do gelo e pelos processos de compressão e alongamento internos, gerados pela enorme massa de gelo que está atrelada à ação da força gravitacional ao longo do substrato rochoso (MENDONÇA, 2013).

O gelo está sujeito a tensão de cisalhamento, que depende da pressão do gelo sobrejacente e da inclinação da superfície da geleira. Essa tensão de cisalhamento atua tanto em cristais de gelo individuais quanto em um corpo de vários cristais (HAGG, 2022). A deformação de cristais individuais foi investigada em laboratório, onde descobriu-se que a deformação ocorre ao longo dos planos basais no cristal de gelo (PATERSON, 1994).

O gelo glacial, com sua estrutura policristalina, exibe um fluxo peculiar que não segue o comportamento nem de materiais Newtonianos, os quais possuem uma viscosidade única a uma dada temperatura, independentemente da tensão de cisalhamento aplicada, nem de materiais idealmente plásticos, apresentando, em vez disso, uma reologia complexa, onde sua capacidade de escoar depende de uma combinação de fatores, incluindo temperatura, pressão, taxa de deformação e a própria história de deformação do gelo (HAMBREY, 1994).

2.1.5 Componentes principais do Fluxo Glacial

Os processos de deformação interna, deslizamento basal e deformação do leito macio são os três mecanismos principais que contribuem para o fluxo de gelo, permitindo que as geleiras se desloquem em resposta ao estresse de deformação. Esses processos podem atuar de forma independente ou combinada, influenciando o movimento geral das geleiras.

O deslizamento ocorre principalmente em geleiras temperadas ou politermais, que não estão congeladas em seus leitos. Já a deformação do leito é observada em geleiras que possuem um substrato macio e flexível. Segundo BOULTON; HINDMARSH (1987), tanto o deslizamento quanto a deformação do leito podem ser significativamente mais rápidos do que a deformação interna, frequentemente representando mais de 50% da velocidade total da superfície da geleira quando ativados.

De acordo com JISKOOT (2011), a velocidade total do fluxo de gelo na superfície da geleira (U) pode ser descrita como a soma da velocidade de deformação interna (U_c), velocidade de deslizamento (U_s) e velocidade de deformação do leito (U_d), conforme ilustrado na equação:

$$U = U_c + U_s + U_d \quad (2.1)$$

Em alguns casos, U_s e U_d são combinados para representar o movimento basal (U_b):

$$U_b = U_s + U_d \quad (2.2)$$

Em regiões onde o movimento ocorre predominantemente por deformação interna, a velocidade diminui como um polinômio de quarta ordem com a profundidade, atingindo seu valor máximo na superfície e quase zero na base (figura 3: U_c), enquanto o perfil transversal da velocidade apresenta uma forma parabólica, com velocidades máximas no centro do vale e redução em direção às bordas, em contraste com as geleiras dominadas pelo movimento basal, que apresentam um perfil de velocidade mais uniforme (plano) (JISKOOT, 2011).

Nas transições entre áreas estacionárias (rocha/gelo) e gelo em movimento, pode ocorrer um fenômeno extremo conhecido como "*Plug flow*", caracterizado por limites distintos de cisalhamento em ambos os lados do gelo (SHARP, 1991) (figura 4).




Figura 3: Corte transversal da distribuição de velocidade vertical e velocidade de superfície (U) em uma geleira com os três componentes do movimento do gelo: deformação interna (U_c), deslizamento basal (U_s) e deformação do leito (U_d). U_s e U_d combinados também podem ser denotados como movimento basal (U_b). Fonte: (JISKOOT, 2011).




Figura 4: Diagramas de dois perfis de velocidade transversais em geleiras (a) Fluxo parabólico aproximado e (b) "Plug flow". As linhas hachuradas representam margens de cisalhamento. Fonte: (JISKOOT, 2011).

2.1.6 Balanço de massa de uma Geleira

Conforme descrito por CUFFEY; PATERSON (2010), o balanço de massa de uma geleira pode ser dividido com base na localização vertical onde ocorrem as trocas de massa. Essa divisão é representada pela equação:

$$\dot{b} = \dot{b}_s + \dot{b}_e + \dot{b}_b \quad (2.3)$$

Aqui, $\dot{b}_s$ refere-se ao balanço de massa superficial, $\dot{b}_b$ ao balanço basal, e $\dot{b}_e$ ao balanço englacial, que abrange os processos internos da geleira. Essa separação é importante devido aos diferentes fatores que influenciam cada componente.

Na maioria dos casos, o balanço de massa superficial é o principal responsável pelas variações no balanço total. Isso frequentemente permite a simplificação $\dot{b} \approx \dot{b}_s$. No entanto, em situações específicas, como em geleiras de maré ou em regiões montanhosas, o balanço basal pode ter um papel relevante.

Se considerarmos M como a massa total de gelo de uma geleira e A como sua área projetada no plano, a taxa de variação de M pode ser expressa pela seguinte equação:

$$\frac{dM}{dt} = \int_A [\dot{b}_s + \dot{b}_e + \dot{b}_b] dA - \dot{B}_c \quad (2.4)$$

Nessa fórmula, $\dot{B}_c$ representa a taxa de perda de massa por *calving*. Ao integrar essa equação ao longo do tempo, obtém-se o balanço de massa total da geleira (ΔM), frequentemente identificado como B na literatura.

O balanço superficial ($\dot{b}_s$) é determinado por processos que adicionam ou removem massa da superfície da geleira. Esses processos incluem acumulação de neve ($\dot{a}_s$), deposição por avalanches ($\dot{a}_a$), derretimento ($\dot{m}_s$), recongelamento de água ($\dot{a}_r$), sublimação ($\dot{s}$) e deposição pelo vento ($\dot{a}_w$). A taxa do balanço superficial pode ser descrita pela equação:

$$\dot{b}_s = \dot{a}_s + \dot{a}_a - \dot{m}_s + \dot{a}_r + \dot{s} + \dot{a}_w \quad (2.5)$$

O balanço englacial ($\dot{b}_e$) resulta da redistribuição interna de massa na geleira. Exemplos incluem o recongelamento da água derretida que se infiltra no *firn* ou neve, e o recongelamento da água fluindo para fraturas. A fusão interna ocorre quando o gelo está à temperatura de fusão e há uma fonte de energia disponível, como deformação do gelo ou fluxo de água. A taxa de aquecimento por deformação ($\dot{S}_E$) é dada por:

$$\dot{S}_E = \sigma \cdot \dot{\epsilon} \quad (2.6)$$

onde σ é a tensão no gelo e $\dot{\epsilon}$ é a taxa de deformação. A perda de massa devido à fusão interna em uma camada com espessura Z_t é representada por:

$$-\dot{b}_e = \frac{\dot{S}_E Z_t}{L_f} \quad (2.7)$$

Aqui, L_f é o calor latente de fusão do gelo.

O balanço basal ($\dot{b}_b$) depende das condições térmicas, da disponibilidade de água e do fluxo energético líquido na base da geleira. A energia basal (E_b) pode ser expressa como:

$$E_b = G + u_b \tau_b + k_T \frac{\partial T}{\partial z} \quad (2.8)$$

Onde G é o fluxo térmico do substrato, u_b a velocidade do deslizamento basal, τ_b a tensão cisalhante no leito, k_T a condutividade térmica do gelo e $\frac{\partial T}{\partial z}$ o gradiente vertical de temperatura. Quando $E_b < 0$, ocorre acumulação basal (*freeze-on*), cuja taxa é dada por:

$$\dot{b}_b = \frac{-E_b}{\rho_i L_f} \quad (2.9)$$

Onde ρ_i é a densidade do gelo. Caso $E_b > 0$, ocorre fusão basal, sendo usada a mesma equação com $E_b > 0$.

Compreender os processos relacionados ao balanço de massa das geleiras é essencial para avaliar as interações entre as geleiras e o clima. Alterações nesse balanço refletem mudanças climáticas e influenciam diretamente as dimensões das geleiras, afetando tanto o clima local quanto global em áreas com grandes massas glaciais.

2.2 Modelagem da dinâmica das Geleiras

A modelagem da evolução das geleiras em larga escala passou por um processo de aprimoramento e sofisticação nas últimas décadas, impulsionado pela disponibilidade crescente de dados e pelo avanço dos recursos computacionais. Os primeiros modelos, desenvolvidos antes de 2010, enfrentavam limitações significativas devido à escassez de dados sobre a espessura do gelo e a geometria das geleiras (ZEKOLLARI et al., 2022). Como resultado, estudos pioneiros como os de RAPER; BRAITHWAITE (2006), RADIĆ; HOCK (2011) e GIESEN; OERLEMANS (2013) utilizaram modelos simplificados de balanço de massa, muitas vezes baseados em graus-dia, e extrapolaram resultados de geleiras individuais para a escala global. Essas abordagens não conseguiam capturar a complexidade da dinâmica do gelo e a variabilidade espacial das características das geleiras.

O lançamento do *Randolph Glacier Inventory* (RGI) em 2012 (ARENDT et al., 2012) representou um marco importante, fornecendo um inventário globalmente completo dos contornos das geleiras. Isso permitiu a aplicação de modelos globais sem a necessidade de extrapolações, como demonstrado por MARZEION; JAROSCH; HOFER (2012) e HIRABAYASHI et al. (2013). No entanto, a falta de informações detalhadas sobre a espessura do gelo ainda impedia a representação precisa da evolução das geleiras, levando ao uso de relações de escala de volume-área que negligenciavam os processos dinâmicos do gelo (BAHR; MEIER; PECKHAM, 1997; BAHR; PFEFFER; KASER, 2015).

A estimativa da distribuição da espessura do gelo para todas as geleiras da Terra por HUSS; FARINOTTI (2012) pavimentou o caminho para a próxima geração de modelos de geleiras em

larga escala temporal e espacial. O *Global Glacier Evolution Model* (GloGEM), desenvolvido por HUSS; HOCK (2015), foi o primeiro a considerar explicitamente a geometria e o volume das geleiras, utilizando uma parametrização de conservação de massa para redistribuir as mudanças de volume na superfície glacial (HUSS et al., 2010).

Com o aumento da capacidade computacional, surgiram modelos que incorporaram a dinâmica do gelo por meio da *Shallow Ice Approximation* (SIA) (HUTTER; HUGHES, 1984). CLARKE et al. (2015) aplicaram a SIA em escala regional no oeste do Canadá, enquanto MAUSSION et al. (2019) e ZEKOLLARI; HUSS; FARINOTTI (2019) desenvolveram modelos que simulavam a evolução de geleiras individuais, considerando a dinâmica do gelo e a geometria de cada geleira.

Apesar dos avanços significativos, esses modelos ainda ignoravam características morfológicas importantes que influenciam a resposta das geleiras às mudanças climáticas. A cobertura de detritos supraglaciais, por exemplo, desempenha um papel crucial na moderação das taxas de derretimento e na evolução da geometria glacial (REID et al., 2012; ROWAN et al., 2015). Estudos específicos de geleiras, como os de JOUVET et al. (2011), ROWAN et al. (2015) e KIE-NHOLZ et al. (2017), começaram a incorporar a evolução da cobertura de detritos, destacando a necessidade de incluir esse processo em modelos de larga escala.

Atualmente, os modelos de evolução global de geleiras, como OGGM, GloGEM e Py-GEM, estão em constante desenvolvimento para incorporar novos processos e aprimorar a representação das geleiras (MAUSSION et al., 2019; HUSS; HOCK, 2015; ROUNCE; HOCK; SHEAN, 2020). Além da evolução da cobertura de detritos, outros aspectos como a ablação frontal de geleiras de maré e a evolução do albedo da superfície estão sendo investigados, impulsionados pela disponibilidade de dados de sensoriamento remoto cada vez mais precisos (RECINOS et al., 2019; HUGONNET et al., 2021; MCCARTHY et al., 2022; ROUNCE et al., 2021; GARDNER; FAHNSTOCK; SCAMBOS, 2019; MILLAN et al., 2022).

O *Glacier Model Intercomparison Project* (GlacierMIP) desempenha um papel importante na coordenação da intercomparação de modelos globais de geleiras, promovendo o aprimoramento dos modelos e a redução das incertezas nas projeções de mudanças glaciais (HOCK et al., 2019; MARZEION et al., 2020). Com a terceira fase do GlacierMIP (GlacierMIP3) em andamento, o foco se volta para o equilíbrio das geleiras sob diferentes condições climáticas, permitindo uma análise abrangente da resposta das geleiras às mudanças climáticas em escalas de tempo centenárias.

2.3 Modelagem dinâmica com VENSIM

O VENSIM é um *software* amplamente utilizado para o desenvolvimento e análise de modelos dinâmicos em diversas áreas, incluindo a modelagem de sistemas ambientais e geográficos (VENTANA, 2023). Desenvolvido pela Ventana Systems, o VENSIM oferece uma interface visual intuitiva para a criação, simulação e análise de modelos complexos, tornando-o uma ferramenta poderosa para a compreensão de sistemas dinâmicos, baseada em programação em

blocos e representação de diagramas de fluxos (STERMAN, 2000).

Um dos principais benefícios do VENSIM é sua capacidade de modelar relações causais entre diferentes variáveis, representadas por meio de diagramas de fluxo e de estoque (FORRESTER, 1997). Essa abordagem de modelagem por dinâmica de sistemas permite aos usuários visualizar e compreender melhor a estrutura e o comportamento do sistema modelado, facilitando a identificação de gargalos, pontos de alavancagem e cenários alternativos (MEADOWS, 2008).

Na representação dos modelos de Dinâmica de Sistemas, os estoques são simbolizados por retângulos ou diagramas de estoques. As taxas de entrada são ilustradas por flechas com duas linhas sólidas que confluem para o estoque, ao passo que as taxas de saída são representadas por flechas com duas linhas sólidas que divergem do estoque. As válvulas exercem o controle sobre as taxas de entrada e de saída. As nuvens simbolizam as disponibilidades externas que fornecem ou recebem as respectivas taxas. A Figura 5 ilustra esse processo.



Figura 5: Exemplo simples de balanço parcial de uma geleira.

Nesta figura, temos um estoque que representa o balanço de massa parcial de uma geleira. Quando há uma taxa de precipitação de neve maior que a taxa de sublimação, o estoque obtém um saldo positivo de massa, fazendo com que a geleira ganhe mais massa do que perde. Já no caso contrário, quando a taxa de sublimação é maior que a taxa de precipitação de neve, temos um saldo negativo, fazendo com que a geleira perca massa.

Além da modelagem visual, o VENSIM oferece uma ampla gama de recursos avançados, como a capacidade de realizar simulações dinâmicas, análises de sensibilidade e otimização de modelos. Essas funcionalidades permitem aos usuários testarem diferentes hipóteses, explorar a incerteza nos parâmetros e identificar estratégias ótimas para o sistema modelado (VENTANA, 2023). O *software* VENSIM tem sido amplamente adotado em diversas áreas, desde a gestão empresarial até a pesquisa em ciências ambientais e sociais.

Pesquisadores e profissionais utilizam o VENSIM para modelar fenômenos complexos, como a dinâmica de bacias hidrográficas, a difusão de inovações, a evolução de epidemias, a dinâmica de recursos naturais e a tomada de decisão em sistemas socioeconômicos (STERMAN, 2000; MEADOWS, 2008). Uma das características que torna o VENSIM tão versátil é sua capacidade de lidar com diferentes níveis de complexidade. Os modelos podem variar desde abordagens simplificadas, com apenas algumas variáveis-chave, até representações mais detalhadas e realistas, com centenas de variáveis e interações.

Essa flexibilidade permite que o VENSIM seja aplicado em diversos contextos, desde o planejamento estratégico de uma empresa até a compreensão de sistemas ambientais complexos (VENTANA, 2023). Além disso, o VENSIM oferece recursos de documentação, análise de cenários e visualização de resultados, facilitando a comunicação e a tomada de decisão com base nos modelos desenvolvidos. Essa abordagem holística torna o VENSIM uma ferramenta poderosa para profissionais e pesquisadores que buscam compreender e intervir em sistemas dinâmicos, independentemente da área de aplicação.

2.4 Sensoriamento remoto e propriedades eletromagnéticas das geleiras

O sensoriamento remoto consiste em um conjunto de metodologias para obtenção de informações de um objeto de estudo à distância, sem que ocorra contato físico com ele, através da coleta de um fluxo de energia (JENSEN; EPIPHANIO, 2009). Geralmente o sensoriamento remoto é empregado coletando fluxos de energia eletromagnética, refletida (no espectro óptico ou emitida no espectro termal) pelo alvo.

O grande impulso do sensoriamento remoto se deu como ferramenta de suporte para o monitoramento ambiental global, através da aplicação de sistemas sensores em plataformas espaciais, formando sistemas de sensoriamento remoto baseados em satélites, que se difundiram a partir da década de 1980 (JENSEN; EPIPHANIO, 2009). Como exemplo, podemos citar as missões LANDSAT (*National Aeronautics and Space Administration* (NASA) / *United States Geological Survey* (USGS)), SENTINEL (*European Space Agency* (ESA)), Spot (*Centre national d'études spatiales* (CNES)), TerraSAR (*Deutsches Zentrum für Luft- und Raumfahrt* (DLR)), CBERS (Instituto Nacional de Pesquisas Espaciais (INPE)), entre outros.

O índice de reflexão das ondas eletromagnéticas varia de acordo com os materiais presentes, bem como com a distribuição, o tamanho e o formato dos grãos de neve (PETSCH, 2014). A composição da geleira apresenta tipicamente uma tríade de elementos: a matriz de gelo sólido, porções de água em estado líquido e diversos materiais particulados (PETSCH, 2014).

Com o passar do tempo, o acúmulo progressivo de sedimentos e partículas atmosféricas sobre o manto nevado modifica suas propriedades ópticas, resultando em uma diminuição significativa de sua capacidade reflexiva e, conseqüentemente, alterando o albedo da superfície (HALL; MARTINEC, 1985; REES, 2005).

A reflectância é definida pela reflexão que um corpo sofre a partir da incidência de radiação sobre ele, que pode variar de 0 a 1 ou de 0 a 100% (CUFFEY; PATERSON, 2010; PETSCH, 2014), conhecida como albedo. A neve por sua vez, possui uma refletância relativamente alta, no visível do espectro eletromagnético, variando de 80% e podendo chegar em 97%. O *firn* (caracterizado por ser parecido com “neve molhada”) possui reflectância entre 25 a 30%, enquanto o gelo possui entre 40 a 70% (figura 6).

O autor DOZIER; SCHNEIDER; MCGINNIS (1981) destaca que, no espectro visível, a reflectância da neve não sofre influência significativa pela variação da granulometria da neve,




Figura 6: Curvas de referência espectral da neve e gelo em diferentes estágios. Adaptado de ZENG et al. (1984).

porém é suscetível a impurezas. Indo de encontro a região do infravermelho próximo e médio, a granulometria já começa a ser um fator mais importante do que as impurezas, devido a quanto maior o seu diâmetro, mais baixa será sua refletância (DOZIER; SCHNEIDER; MCGINNIS, 1981).

Sob essa perspectiva, o sensoriamento remoto é uma alternativa amplamente difundida para monitorar a dinâmica das geleiras (BHARDWAJ et al., 2016). Muito em consequência da localização e a grande extensão dos glaciais, os dados de sensoriamento remoto apoiam os trabalhos de campo, muitas vezes dispendiosos e com a oferta de risco físico aos pesquisadores. Soma-se a isso a oferta vasta de fontes de dados de sensoriamento remoto de forma gratuita, disponíveis atualmente. Assim, o sensoriamento remoto aplicado à glaciologia, permite extrair informações em qualquer local da Terra, cobrindo um geleiras, gelo marinho e mantos de gelo ao nível global (OLIVEIRA, 2013).

2.4.1 Índices físicos da neve, gelo e da água

A detecção e mapeamento dos corpos de água e neve nas imagens obtidas através de sensores remotos pode ser realizado por meio da aplicação de índices espectrais. Esses índices, Índice de Água de Diferença Normalizada (NDWI) e o Índice de Neve de Diferença Normalizada (NDSI), aproveitam as propriedades de reflectância distintas da água e da neve/gelo em diferentes faixas espectrais (MCFEETERS, 1996; HALL; RIGGS; SALOMONSON, 1995).

O NDWI, proposto por MCFEETERS (1996), utiliza as bandas verde e infravermelho próximo (NIR) para realçar as feições de água, enquanto o NDSI, desenvolvido por HALL; RIGGS; SALOMONSON (1995), emprega as bandas verde e infravermelho de ondas curtas (SWIR) para destacar a cobertura de neve/gelo.

A abordagem geral para a classificação de índices físicos envolve o cálculo dos índices NDWI e NDSI a partir das bandas espectrais correspondentes das imagens de sensores remotos. De acordo com GAO (1996), o NDWI é calculado através da equação 2.10, e o NDSI pela equação 2.11.

$$NDWI = \frac{(verde - NIR)}{(verde + NIR)} \quad (2.10)$$

$$NDSI = \frac{(verde - SWIR)}{(verde + SWIR)} \quad (2.11)$$

Esses índices normalizados realçam as diferenças espectrais entre água/neve e outros alvos terrestres, facilitando sua identificação e discriminação (XU, 2006). Após o cálculo dos índices, são aplicados limiares empíricos para segmentar as áreas de interesse, como corpos d'água e cobertura de neve/gelo (KULKARNI et al., 2006; HUGGEL et al., 2002).

A escolha dos limiares adequados para a classificação dos índices físicos é um passo crucial e pode variar de acordo com as características locais, condições atmosféricas e sensor utilizado. Estudos anteriores têm explorado diferentes abordagens para determinar limiares ótimos, incluindo análise de histogramas, técnicas de segmentação automática e validação de campo (HUANG et al., 2018; KULKARNI et al., 2006).

Por exemplo, HUGGEL et al. (2002) aplicaram um limiar de NDSI > 0,3 para mapear a cobertura de neve/gelo em regiões montanhosas, enquanto MCFEETERS (1996) sugeriu um limiar de NDWI > 0,2 para a detecção de corpos d'água abertos.

2.4.2 A série LANDSAT

Os satélites da missão LANDSAT, operados pela NASA e pelo USGS, fornecem uma das mais importantes séries históricas de dados de sensoriamento remoto da superfície terrestre (WULDER et al., 2019). Lançado em 1984, o LANDSAT 5 foi equipado com o sensor *Thematic Mapper* (TM), que revolucionou a aquisição de imagens multiespectrais com suas sete bandas cobrindo o espectro óptico refletido e emitido (CHANDER; MARKHAM; HELDER, 2009). O LANDSAT 5 operou por 29 anos, até ser descontinuado em 2013. Suas imagens seguem

disponíveis em acervo eletrônico de acesso gratuito, disponibilizado, por exemplo, pelo USGS. As especificações técnicas do sensor TM estão contidas na tabela 2

Tabela 2: Sensor TM/LANDSAT-5.

Bandas Espectrais	Faixa Espectral (μm)	Resolução Espacial	Resolução Radiométrica
1 - Azul	0,45 - 0,52	30m	8 bits
2 - Verde	0,52 - 0,60	30m	
3 - Vermelho	0,63 - 0,69	30m	
4 - Infravermelho Próximo	0,76 - 0,90	30m	
5 - Infravermelho Médio 1	1,55 - 1,75	30m	
6 - Infravermelho Termal	10,40 - 12,50	120m*	
7 - Infravermelho Médio 2	2,08 - 2,35	30m	
*Banda termal de 120m, reamostrada para 30m			

Em 1999, foi lançado o LANDSAT 7, carregando o sensor aprimorado *Enhanced Thematic Mapper Plus* (ETM+), que manteve as mesmas bandas espectrais do TM, com algumas pequenas modificações nas faixas espectrais (CHANDER; MARKHAM; HELDER, 2009). Uma novidade foi a adição de uma banda pancromática (somando a radiância total da faixa do visível) com resolução espacial de 15 metros (MARKHAM et al., 2004). Infelizmente, em 2003, ocorreu a falha do *Scan Line Corrector* (SLC), afetando a coleta das imagens coletadas após esse período, fazendo-as ter faixas de falha de imageamento (IRISH, 2000). As especificações técnicas do sensor ETM+ estão contidas na tabela 3

Tabela 3: Sensor ETM+/LANDSAT-7.

Bandas Espectrais	Faixa Espectral (μm)	Resolução Espacial	Resolução Radiométrica
1 - Azul	0,45 - 0,52	30m	8 bits
2 - Verde	0,53 - 0,61	30m	
3 - Vermelho	0,63 - 0,69	30m	
4 - Infravermelho Próximo	0,78 - 0,90	30m	
5 - Infravermelho Médio 1	1,55 - 1,75	30m	
6 - Infravermelho Termal	10,40 - 12,50	60m*	
7 - Infravermelho Médio 2	2,09 - 2,35	30m	
8 - Pancromática	0,52 - 0,90	15m	
*Banda termal de 60m, reamostrada para 30m			

Seguindo o programa LANDSAT, foi desenvolvido e lançado o LANDSAT 8, em operação desde 2013, que trouxe avanços significativos com os novos sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS) (ROY et al., 2014). O sensor OLI conta com nove bandas espectrais refinadas, incluindo uma banda 1, focada em monitorar o aerossol atmosférico e as feições costeiras, e a banda 9, focada em monitorar a cobertura de nuvens para fins de modelagem atmosférica e de balanço de energia (banda cirrus), todas com 30 metros de resolução espacial, exceto a pancromática com 15 metros (ZANTER, 2016). O sensor TIRS fornece duas

bandas termais com resolução espacial aprimorada de 100 metros (IRONS; DWYER; BARSI, 2012). As especificações técnicas dos sensores OLI e TIRS estão contidas na tabela 4

Tabela 4: Sensores OLI e TIRS/LANDSAT-8.

Bandas Espectrais	Faixa Espectral (μm)	Resolução Espacial	Resolução Radiométrica
1 - Aerossol Costeiro	0,43 - 0,45	30m	12 bits
2 - Azul	0,45 - 0,51	30m	
3 - Verde	0,53 - 0,59	30m	
4 - Vermelho	0,64 - 0,67	30m	
5 - Infravermelho Próximo	0,85 - 0,88	30m	
6 - Infravermelho Médio 1	1,57 - 1,65	30m	
7 - Infravermelho Médio 2	2,11 - 2,29	30m	
8 - Pancromática	0,50 - 0,68	15m	
9 - Cirrus	1,36 - 1,39	30m	
10 - Infravermelho Termal 1	10,60 - 11,19	100m*	
11 - Infravermelho Termal 2	11,50 - 12,51	100m*	
*Banda termal de 100m, reamostrada para 30m			

O LANDSAT 9 é o mais recente satélite da série LANDSAT, lançado em 27 de setembro de 2021 (SAYLER; GLYNN, 2022). Esta missão é uma continuação da parceria bem-sucedida entre a NASA e o USGS para monitorar e gerenciar os recursos da Terra.

O LANDSAT 9 substituiu o LANDSAT 7 e opera em conjunto com o LANDSAT 8, garantindo a continuidade da coleta de dados de observação da Terra de alta qualidade (SAYLER; GLYNN, 2022). O satélite LANDSAT 9 carrega dois instrumentos principais: o *Operational Land Imager 2* (OLI-2) e o *Thermal Infrared Sensor 2* (TIRS-2). Estes instrumentos são versões aprimoradas dos sensores a bordo do Landsat 8, oferecendo melhorias na qualidade dos dados e na confiabilidade do sistema (MASEK et al., 2020).

O LANDSAT 9 mantém a resolução espacial de 30 metros para a maioria das bandas multiespectrais, 15 metros para a banda pancromática e 100 metros para as bandas térmicas. Uma melhoria significativa em relação aos seus predecessores é a resolução radiométrica de 14 *bits* para todas as bandas, o que permite uma melhor discriminação de características sutis na superfície terrestre (SAYLER; GLYNN, 2022; MASEK et al., 2020). As especificações técnicas dos sensores OLI-2 e TIRS-2 estão contidas na tabela 5

Essa inestimável série de dados dos sensores dos satélites da série LANDSAT é amplamente utilizada em diversas aplicações de sensoriamento remoto, como estudos de mudanças na cobertura terrestre, monitoramento de ecossistemas, modelagem de superfície, gerenciamento de recursos naturais, entre outras (HANSEN; LOVELAND, 2012). A continuidade e consistência dessa missão de observação da Terra são fundamentais para a compreensão dos processos ambientais em escala global (WULDER et al., 2019).

Tabela 5: Sensores OLI-2 e TIRS-2/LANDSAT-9.

Bandas Espectrais	Faixa Espectral (μm)	Resolução Espacial	Resolução Radiométrica
1 - Aerossol Costeiro	0,43 - 0,45	30m	
2 - Azul	0,45 - 0,51	30m	
3 - Verde	0,53 - 0,59	30m	
4 - Vermelho	0,64 - 0,67	30m	
5 - Infravermelho Próximo	0,85 - 0,88	30m	
6 - Infravermelho Médio 1	1,57 - 1,65	30m	14 bits
7 - Infravermelho Médio 2	2,11 - 2,29	30m	
8 - Pancromática	0,50 - 0,68	15m	
9 - Cirrus	1,36 - 1,39	30m	
10 - Infravermelho Termal 1	10,60 - 11,19	100m*	
11 - Infravermelho Termal 2	11,50 - 12,51	100m*	

*Banda termal de 100m, reamostrada para 30m

2.4.3 Modelos Digitais de Elevação: Terminologia e Definições

Diversos campos, como geomorfometria, ciências criosféricas, agricultura de precisão, telecomunicações, planejamento territorial e sensoriamento remoto, têm adotado a topografia digital por meio de Modelos Digitais de Elevação (MDEs), entretanto, os produtores de dados, incluindo cientistas, fornecedores comerciais e organizações governamentais, junto aos usuários, utilizam diferentes definições para as representações digitais das superfícies topográficas e seus derivados, devido à falta de referências comuns (GUTH et al., 2021).

Um MDE é um dos conjuntos de dados espaciais importantes em muitos sistemas de informações geográficas (GIS) (ZHAN et al., 2005). A expressão MDE refere-se a um termo genérico para uma grade georretificada baseada em pontos ou áreas que representa as elevações de uma superfície topográfica da Terra ou de outros corpos celestes sólidos, e atualmente a maioria dos MDEs utiliza formatos de armazenamento de imagem raster e grades retangulares, ou "matrizes" (GUTH et al., 2021). Os MDEs são comumente obtidos por meio de técnicas de fotogrametria aérea, interferometria de radar e varredura a laser (LILLESAND; KIEFER; CHIPMAN, 2015).

Os Modelos Digitais de Terreno (MDTs), por sua vez, são funções bidimensionais de variáveis morfométricas derivadas dos MDEs, representando a "terra nua", ou seja, o limite entre a litosfera e a atmosfera, sem incluir a biosfera ou antroposfera (GUTH et al., 2021). Já os Modelos Digitais de Superfície (MDSs) registram a elevação do topo de objetos localizados no terreno (FLORINSKY, 2016), registrando o limite inferior da atmosfera (e a litosfera, hidrosfera, criosfera, biosfera ou antroposfera) (GUTH et al., 2021). Essa distinção é importante, pois influencia diretamente a aplicação e a interpretação dos dados de elevação (LIU, 2008).

A escolha do modelo mais adequado dependerá das necessidades específicas da aplicação, bem como da disponibilidade e qualidade dos dados. É importante notar que a qualidade e a resolução espacial dos MDEs variam significativamente, dependendo das técnicas e sensores

utilizados em sua obtenção. Alguns MDEs disponíveis, como os gerados pela missão *Shuttle Radar Topography Mission* (SRTM) e pelo *Panchromatic Remote-sensing Instrument for Stereo Mapping* (PRISM) no *Advanced Land Observing Satellite* (ALOS), fornecem MDEs com resoluções de 30 metros ou melhores (YAMAZAKI et al., 2017).

O SRTM é um projeto conjunto entre a NASA e a *National Geospatial-Intelligence Agency* (NGA), lançado em Fevereiro de 2000. O SRTM utilizou uma técnica de interferometria de radar para obter dados de elevação em uma resolução espacial de 30 metros, cobrindo aproximadamente 80% da superfície terrestre entre as latitudes 60°N e 56°S (FARR et al., 2007).

O ALOS PRISM, sensor de alta resolução a bordo do satélite japonês ALOS, lançado em 2006 pela *Japan Aerospace Exploration Agency* (JAXA), foi projetado para gerar Modelos Digitais de Elevação (MDEs). Ele oferece resolução espacial de 2,5 metros para imagens pancromáticas, possibilitando a criação de MDEs com resolução de 30 metros (TADONO et al., 2015).

Outra missão relevante é o *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) *Global Digital Elevation Model* (GDEM), desenvolvido pelo Japão e pela NASA/USGS. Lançado em 2009, o ASTER GDEM oferece dados globais com resolução de 30 metros, gerados a partir de imagens estereoscópicas obtidas pelo sensor ASTER no satélite TERRA (TACHIKAWA et al., 2011).

A missão TanDEM-X, uma parceria entre a DLR e a *Airbus Defence and Space*, produziu um modelo de elevação global de alta resolução a partir de interferometria de radar, com dados coletados entre 2010 e 2015. O TanDEM-X utiliza dois satélites em formação fechada para gerar um MDE com resolução de 12 metros (RIZZOLI et al., 2017).

Em novembro de 2023, foi lançada uma versão editada do TanDEM-X 30m DEM, denominada TanDEM-X 30m *Edited* DEM (EDEM), com preenchimento de lacunas e edição de corpos d'água, resultando em um MDE global de 1 arcsec sem vazios e com superfícies de água achatadas (BACHMANN et al., 2022).

2.5 A Plataforma Google Earth Engine (GEE)

O GEE é uma plataforma de computação em nuvem revolucionária desenvolvida pelo Google para análise de *Big Data* geoespacial (GORELICK et al., 2017). Lançada em 2010, essa ferramenta online fornece acesso a uma vasta coleção de conjuntos de dados de sensoriamento remoto e outras fontes geoespaciais, juntamente com enormes recursos computacionais para processá-los (SIDHU; PEBESMA; CÂMARA, 2018).

Uma das principais vantagens do GEE é sua arquitetura baseada em nuvem, que permite a execução de algoritmos diretamente nos servidores do Google, eliminando a necessidade de downloads ou instalações locais de *softwares* específicos (ERICKSON, 2014; HANCHER, 2013; MOORE; HANSEN, 2011). Essa abordagem reduz significativamente os requisitos de armazenamento e poder computacional dos usuários, democratizando o acesso a recursos de alto desempenho (MUTANGA; KUMAR, 2019).

O GEE oferece acesso a coleções completas de dados de sensores como LANDSAT, MODIS, bem como conjuntos de dados meteorológicos, demográficos, de cobertura terrestre e muitos outros, organizados como coleções de imagens (JOHANSEN; PHINN; TAYLOR, 2015). Essa integração de dados multifonte em uma única plataforma, juntamente com ferramentas para filtragem, composição, análise de séries temporais e processamento em larga escala, facilita consideravelmente estudos multidisciplinares (MUTANGA; KUMAR, 2019).

Graças à sua linguagem de programação baseada em JavaScript e interface de codificação online, o GEE permite o desenvolvimento e compartilhamento colaborativo de algoritmos de processamento de imagens e modelos ambientais (GORELICK et al., 2017). Essa abordagem aberta impulsiona o avanço científico, com equipes em todo o mundo utilizando a plataforma para monitorar mudanças ambientais, mapear desmatamento, avaliar riscos de desastres naturais, modelar variáveis biofísicas e muito mais (MUTANGA; KUMAR, 2019).

2.5.1 Operações Morfológicas no GEE

O GEE oferece um conjunto de operações morfológicas que podem ser aplicadas às imagens de sensoriamento remoto. Essas operações são derivadas da morfologia matemática, um ramo da teoria dos conjuntos e geometria integral que lida com a análise de estruturas geométricas em imagens (SOILLE et al., 1999). As principais operações morfológicas disponíveis no GEE são (GORELICK et al., 2017):

- Erosão: Remove *pixels* dos objetos de interesse, encolhendo-os. É útil para remover ruídos ou separar objetos conectados.
- Dilatação: Adiciona *pixels* aos objetos, expandindo-os. Pode ser usado para preencher buracos ou conectar objetos próximos.
- Abertura: Realiza uma erosão seguida de uma dilatação. Suaviza o contorno de objetos, removendo protuberâncias finas e eliminando ruídos.
- Fechamento: Realiza uma dilatação seguida de uma erosão. Tende a suavizar seções de contornos, mas além disso, une quebras estreitas e remove pequenos buracos.
- Gradiente Morfológico: Calcula a diferença entre a dilatação e a erosão de uma imagem, realçando os contornos dos objetos.
- Preenchimento de Buracos: Preenche os buracos dentro dos objetos, considerando todos os *pixels* conectados com o mesmo valor como parte de um único objeto.

Essas operações são frequentemente utilizadas em etapas de pós-processamento de imagens de sensoriamento remoto, como filtragem de ruídos, realce de bordas, separação de objetos e preenchimento de áreas faltantes (SOILLE; PESARESI, 2002). Além disso, são amplamente empregadas em tarefas de classificação de imagens, extração de feições e análise de padrões espaciais (HARALICK; STERNBERG; ZHUANG, 1987; ZHAN et al., 2005).

No GEE, as operações morfológicas são aplicadas utilizando *kernels* (núcleos) estruturantes, que definem a forma e o tamanho dos elementos estruturantes usados nas transformações. O GEE fornece *kernels* predefinidos, como círculos, quadrados e linhas, além da possibilidade de criar *kernels* personalizados (GORELICK et al., 2017).

2.5.2 Convolução no GEE

A convolução é uma técnica fundamental no processamento de imagens digitais e sistemas de informação geográfica, permitindo a aplicação de diversos filtros e operações para realçar, suavizar ou detectar características específicas nas imagens. No GEE, essa operação é amplamente utilizada em análises de séries temporais de imagens de sensoriamento remoto. Segundo com SCHOWENGERDT (2006), a fórmula geral para uma operação de convolução 2D em uma imagem $f(x, y)$ com um *kernel* $h(s, t)$ é:

$$g(x, y) = \sum \sum f(x + s, y + t) * h(s, t) \quad (2.12)$$

Onde $g(x, y)$ é o valor do novo *pixel* na imagem de saída.

No GEE, a função `ee.Kernel` é usada para criar *kernels* personalizados para convolução. Por exemplo, `ee.Kernel.square(1)` cria um *kernel* 3x3 com todos os pesos iguais a 1, útil para suavização por média. Um *kernel* específico de grande relevância é o `Laplacian8`, utilizado para detecção de bordas. Ele é um operador laplaciano baseado na segunda derivada, definido pela matriz 3x3 (GONZALEZ, 2009):

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Quando aplicado por convolução, o `Laplacian8` realça as regiões da imagem onde ocorrem mudanças abruptas de intensidade, destacando bordas e contornos. A. RAMEZAN; A. WARNER; E. MAXWELL (2019) utilizaram o operador `Laplacian8` como uma etapa de pré-processamento para realçar características texturais em imagens SENTINEL-2, antes de aplicar algoritmos de *machine learning* para classificação de uso do solo urbano, onde foi possível observar que a aplicação do `Laplacian8` melhorou a acurácia da classificação.

2.6 Classificação Supervisionada e Não Supervisionada

A classificação de imagens digitais, obtidas por sensoriamento remoto, pode ser realizada por meio de técnicas supervisionadas ou não supervisionadas, com abordagens *pixel-a-pixel* ou orientada a objeto, cada uma delas com suas vantagens e limitações (CÂMARA et al., 2001). A escolha do método depende dos objetivos do estudo, dos dados disponíveis e do conhecimento prévio da área de interesse.

A classificação supervisionada é um processo em que o analista fornece amostras de treinamento representativas de diferentes classes de cobertura terrestre ou feições de interesse (LILLESAND; KIEFER; CHIPMAN, 2008). Com base nessas amostras, um algoritmo de classificação é treinado para reconhecer padrões (e.g., espectrais, texturais, estatísticos, etc) e atribuir cada *pixel* da imagem a uma das classes pré-definidas. Os principais métodos de classificação empregados são:

- (1) Máxima Verossimilhança: Este método assume que a distribuição de probabilidade para cada classe em cada banda é normal e calcula a probabilidade de um determinado *pixel* pertencer a uma classe específica.
- (2) Mínima Distância Euclidiana: Neste algoritmo, a distância euclidiana é calculada entre o vetor de valores espectrais de cada *pixel* e os vetores médios de cada classe de treinamento. O *pixel* é então atribuído à classe com a menor distância.
- (3) Paralelepípedos: Este método define limites de decisão para cada classe no espaço de *features*, formando paralelepípedos multidimensionais. *Pixels* cujos valores espectrais caem dentro dos limites de uma classe são atribuídos a essa classe.

Em contraste com a abordagem supervisionada, a classificação não supervisionada não requer amostras de treinamento pré-definidas. Em vez disso, os algoritmos agrupam *pixels* com características similares em *clusters* ou classes distintas com base em medidas de distância ou similaridade estatística (RICHARDS; RICHARDS, 2013).

- (1) K-Means: Este algoritmo particiona os *pixels* em um número k de *clusters*, minimizando a soma das distâncias quadráticas entre cada *pixel* e o centroide do *cluster* mais próximo.
- (2) ISODATA: Similar ao K-Means, mas com a capacidade de fundir *clusters* próximos e dividir *clusters* heterogêneos durante o processo de agrupamento.
- (3) Agrupamento Hierárquico: Cria uma hierarquia de *clusters*, começando com cada *pixel* como um *cluster* separado e, em seguida, agrupando sucessivamente os *clusters* mais próximos.
- (4) Classificação por limiarização ou *threshold*: É um método não supervisionado baseado na definição de limites (limiares) para os valores de corte que indicam a classe de interesse. Esses limiares podem compor valores de reflectância de superfície, valores de textura, valores de elevação, entre outros.

2.6.1 Classificação por limiarização

A classificação por limiarização (*thresholding*) é uma técnica não supervisionada amplamente utilizada no processamento e análise de imagens de sensoriamento remoto. Embora

relativamente simples em seu conceito, desempenha um papel fundamental na extração de informações valiosas a partir de dados de sensoriamento remoto. Esta abordagem baseia-se na premissa de que determinadas classes de interesse em uma cena possuem valores espectrais distintos, permitindo sua separação por meio da definição de limiares apropriados (LILLESAND; KIEFER; CHIPMAN, 2015).

O processo de classificação por limiarização inicia-se com uma análise minuciosa do histograma da imagem, que representa a distribuição de frequências dos valores de brilho ou níveis digitais dos *pixels*. Conforme destacado por SCHOWENGERDT (2006), o histograma é uma ferramenta crucial neste contexto, pois permite a identificação de picos e vales que indicam a presença de diferentes classes espectrais. Os vales, regiões de baixa frequência entre os picos proeminentes, são os pontos ideais para o estabelecimento dos limiares que separam as classes de interesse.

Uma vez identificados os limiares adequados, a limiarização é aplicada à imagem original. Cada *pixel* é comparado com os limiares, e um novo valor é atribuído com base em regras pré-definidas. Essa atribuição de valores é frequentemente representada pela equação geral proposta por GONZALEZ; WOODS (2008):

$$g(x, y) = \begin{cases} 1, & \text{se } f(x, y) > T \\ 0, & \text{caso contrário} \end{cases} \quad (2.13)$$

Onde $g(x, y)$ é a imagem segmentada, $f(x, y)$ é a imagem original, e T é o valor do limiar. Essa equação essencialmente classifica os *pixels* como pertencentes a uma determinada classe (valor 1) ou não (valor 0), com base no limiar estabelecido.

Após a aplicação da limiarização, os *pixels* são rotulados com base nos limiares aplicados. Por exemplo, se houver dois limiares $T1$ e $T2$, os *pixels* podem ser classificados em três classes distintas: aqueles com valores menores que $T1$, aqueles com valores entre $T1$ e $T2$, e aqueles com valores maiores que $T2$ (MATHER; TSO, 2016). Essa atribuição de rótulos de classe é fundamental para a interpretação e análise subsequente dos dados de sensoriamento remoto.

É importante ressaltar que a classificação por limiarização é mais eficaz quando as classes de interesse apresentam valores espectrais distintos e não sobrepostos. Caso contrário, técnicas de classificação mais avançadas, como a classificação supervisionada ou não supervisionada, podem ser necessárias para lidar com a complexidade dos dados e obter resultados mais precisos (LU; WENG, 2007; RICHARDS, 2013).

2.7 Análise de Funções Ortogonais Empíricas (EOF)

A análise de Funções Ortogonais Empíricas (EOF) é uma técnica amplamente utilizada para investigar variações espaciais e temporais de parâmetros climáticos, conforme descrito por LORENZ (1956) e BJÖRNSSON; VENEGAS (1997). Essencialmente, a análise EOF decompõe dados espaço-temporais em vários modos de variação. Cada modo pode ser associado a um ou

mais mecanismos que explicam as variações observadas. A técnica é conceitualmente semelhante à Análise de Componentes Principais (PCA), frequentemente empregada para descorrelacionar conjuntos de variáveis.

Segundo LI et al. (2011), no contexto da análise EOF, o conjunto de dados do parâmetro observado pode ser tratado como uma função $s(x, y, t)$, onde x e y representam as coordenadas espaciais, e t o tempo. A técnica decompõe essa função em uma série de funções ortogonais $f_i(x, y)$, que dependem apenas das coordenadas espaciais, enquanto a variação temporal é capturada por uma série de funções temporais $g_i(t)$. Esse procedimento permite identificar padrões espaciais dominantes e suas respectivas flutuações temporais. Essa decomposição pode ser expressa matematicamente como:

$$s(x, y, t) = \sum_{i=1}^N f_i(x, y)g_i(t) \quad (2.14)$$

Onde N é o número total de observações realizadas no tempo. As EOFs $f_i(x, y)$ e seus respectivos coeficientes $g_i(t)$ são determinados resolvendo a equação de autovalores construída a partir da matriz de covariância da função $s(x, y, t)$. As funções ortogonais $f_i(x, y)$ são organizadas em ordem decrescente dos autovalores correspondentes da matriz de covariância. Dessa forma, as primeiras funções ortogonais geralmente explicam a maior parte da variância espacial presente no conjunto de dados.

2.8 Análise de Decomposição em Valores Singulares (SVD)

A decomposição em valores singulares (SVD) é uma técnica matemática que utiliza autovetores e autovalores para decompôr uma matriz retangular geral. Nesse contexto, "valor singular" é outro termo para autovalor. Embora a teoria matemática básica da SVD tenha sido desenvolvida há quase 200 anos (STEWART, 1993), o algoritmo moderno para o cálculo eficiente da SVD foi introduzido por GOLUB; REINSCH (1971) na década de 70. Atualmente, a SVD tornou-se uma ferramenta essencial de análise de dados em diversas áreas, incluindo as ciências climáticas.

Em estudos climáticos, os dados espaço-temporais frequentemente são representados por matrizes retangulares, pois o número de locais (n) geralmente não é igual ao número de observações temporais (m) nesses locais (SHEN; SHEN; NORTH, 2023). Assim, uma matriz de dados climáticos espaço-temporais pode ser representada como $X_{n \times m}$, onde n é o número de locais (ou caixas de grade em um modelo climático) e m é o número total de passos temporais (SHEN; SHEN; NORTH, 2023).

A técnica SVD é amplamente utilizada na análise climática devido à sua capacidade de decompor grandes conjuntos de dados em padrões significativos. Ela permite separar modos dominantes de variabilidade e reduzir o ruído nos dados. Por exemplo, a SVD tem sido aplicada para identificar padrões dominantes em precipitação e fluxos latentes de calor em oceanos globais, bem como para corrigir vieses em previsões climáticas sazonais e sub-sazonais (QIN

et al., 2011; LI et al., 2011; FU; HUANG; GUO, 2022).

A técnica funciona ao decompor a matriz $X_{n \times m}$ em três componentes principais:

$$X = U\Sigma V^T \quad (2.15)$$

Onde U contém os autovetores da matriz XX^T , representando padrões espaciais; Σ é uma matriz diagonal com os valores singulares (autovalores), que indicam a importância relativa dos padrões; V^T contém os autovetores da matriz X^TX , representando as variações temporais associadas (SHEN; SHEN; NORTH, 2023). Os valores singulares são ordenados em ordem decrescente, o que permite que os primeiros modos capturem a maior parte da variância nos dados. Essa característica torna a SVD particularmente útil para simplificar conjuntos de dados complexos enquanto preserva informações essenciais (HAN; KIM; JUNG, 2024; KURODA, 1998).

Além disso, a SVD pode ser aplicada para analisar duas variáveis climáticas simultaneamente, permitindo explorar correlações entre seus padrões espaço-temporais (CHERRY, 1997). Nesse caso, as matrizes das duas variáveis são comparadas para identificar padrões compartilhados e calcular coeficientes de correlação entre os componentes principais temporais (KURODA, 1998).

2.9 Teste de Mann-Kendall

O teste de Mann-Kendall (MK) é um método estatístico não paramétrico amplamente utilizado para detectar tendências monotônicas em séries temporais, especialmente em dados hidrológicos, meteorológicos e ambientais. Desenvolvido inicialmente por MANN (1945) e posteriormente aprimorado por KENDALL (1975), este teste se destaca por sua robustez e aplicabilidade em diversos contextos científicos.

O teste de Mann-Kendall baseia-se na análise dos ranks (posições) dos dados em uma série temporal, em vez de utilizar os valores brutos das observações. Esta característica torna o teste particularmente adequado para séries que não seguem uma distribuição normal, contêm valores extremos ou apresentam dados faltantes. A hipótese nula (H_0) do teste é que não existe tendência na série, enquanto a hipótese alternativa (H_1) indica a presença de uma tendência monotônica, seja crescente ou decrescente.

A aplicação do teste inicia com o cálculo da estatística S de Mann-Kendall que é obtida pela soma dos sinais das diferenças entre todos os pares possíveis de observações na série temporal. Matematicamente, a estatística S é definida pela equação:

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (2.16)$$

Onde x_i e x_j são os valores observados nos tempos i e j , respectivamente, com $j > i$ e a função sinal (sgn) é dada por:

$$\text{sgn}(x_j - x_i) = \begin{cases} +1, & \text{se } (x_j - x_i) > 0 \\ 0, & \text{se } (x_j - x_i) = 0 \\ -1, & \text{se } (x_j - x_i) < 0 \end{cases} \quad (2.17)$$

Quando o tamanho da amostra n é suficientemente grande (geralmente $n \geq 8$ a distribuição da estatística S aproxima-se da normalidade com média zero e variância dada por:

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^p t_i(t_i-1)(2t_i+5)}{18} \quad (2.18)$$

Nesta expressão, n representa o número total de dados na série temporal, p é o número de grupos com empates (valores idênticos), e t_i indica o número de observações empatadas no grupo i . A partir disso, obtém-se a estatística padronizada do teste (Z_{MK}), calculada como:

$$Z_{MK} = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}}, & S > 0 \\ 0, & S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}}, & S < 0 \end{cases} \quad (2.19)$$

Essa estatística segue uma distribuição normal padrão sob a hipótese nula (ausência de tendência monotônica). Assim, ao comparar o valor absoluto obtido para Z_{MK} com valores críticos tabelados para um dado nível de significância (geralmente 5%), pode-se decidir pela rejeição ou não da hipótese nula. Valores positivos significativos indicam tendência crescente, enquanto valores negativos significativos apontam para tendência decrescente.

3 MATERIAIS E MÉTODOS

3.1 Dados

3.1.1 Imagens de sensores Satelitais Utilizadas

Foram utilizadas imagens de satélite dos sensores, TM/LANDSAT-5, ETM+/LANDSAT-7, OLI-TIRS/LANDSAT-8 e OLI2-TIRS2/LANDSAT-9. As imagens foram obtidas através do USGS em nível de processamento *Level 1* (L1) e estão esparsadas entre o intervalo de tempo de 2000-2024. O *ID*, *data*, *path* e *row* das imagens utilizadas encontram-se na tabela 6.

Tabela 6: Informações técnicas das imagens selecionadas para o trabalho.

<i>ID</i>	<i>DATA</i>	<i>PATH</i>	<i>ROW</i>
LT05_L1TP_230096_20001113_20230212_02_T1	13/11/2000	230	096
LE07_L1TP_230096_20020111_20200917_02_T1	11/01/2002	230	096
LT05_L1TP_230096_20091208_20200825_02_T1	08/12/2009	230	096
LT05_L1TP_230096_20101109_20200823_02_T1	09/11/2010	230	096
LT05_L1TP_230096_20111011_20200820_02_T1	11/10/2011	230	096
LC08_L1TP_230096_20131219_20200912_02_T1	19/12/2013	230	096
LC08_L1TP_230096_20141019_20200910_02_T1	19/10/2014	230	096
LC08_L1TP_230096_20150123_20200910_02_T1	23/01/2015	230	096
LC08_L1TP_230096_20161125_20200905_02_T1	25/11/2016	230	096
LC08_L1TP_231095_20190109_20200830_02_T1	09/01/2019	231	095
LC08_L1TP_230096_20200206_20200823_02_T1	06/02/2020	230	096
LC08_L1TP_231095_20210303_20210312_02_T1	03/03/2021	231	095
LC08_L1TP_231095_20221016_20221021_02_T1	16/10/2022	231	095
LC09_L1TP_230096_20231207_20231207_02_T1	07/12/2023	230	096
LC09_L1TP_231095_20241216_20241216_02_T1	16/12/2024	231	095

3.1.2 Dados Vetoriais GLIMS

Os dados vetoriais no formato shapefile para a verificação da acurácia dos resultados foram adquiridos do projeto GLIMS. O projeto GLIMS (Global Land Ice Measurements from Space) foi estabelecido com o objetivo de adquirir imagens de satélite multiespectrais das geleiras do mundo, analisá-las quanto à extensão e mudanças, e entender esses dados de mudança em termos de forçantes climáticas e outros fatores. Originou-se como um esforço da Equipe de Ciência do instrumento ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) a bordo do satélite Terra.

Embora as imagens ASTER sejam a principal fonte de dados, o GLIMS também utiliza imagens de outros sensores como LANDSAT ETM+, LANDSAT antigos, imagens de radar de abertura sintética (SAR), bem como mapas e fotos aéreas históricas para preencher lacunas temporais e espaciais. O projeto submete solicitações anuais de aquisição de imagens ASTER com configurações otimizadas para o mapeamento de geleiras em todo o mundo.

3.1.3 Dados Climáticos

Os dados climáticos utilizados neste estudo foram obtidos a partir da reanálise ERA5-Land, disponibilizada pelo Programa de Observação da Terra da União Europeia (<https://cds.climate.copernicus.eu/>), coordenado pela Comissão Europeia. Este conjunto de dados fornece informações detalhadas sobre variáveis terrestres, como velocidade do vento, temperatura, albedo, precipitação de neve e evaporação. A ERA5-Land é uma reanálise climática de alta resolução que utiliza simulações do componente terrestre da reanálise ERA5, forçadas por campos meteorológicos. Essa abordagem permite maior precisão nos dados terrestres ao oferecer uma resolução espacial aprimorada de aproximadamente 9 km, em comparação com os 31 km da ERA5 convencional.

A reanálise combina modelos numéricos e observações globais para gerar estimativas consistentes e detalhadas do clima ao longo de várias décadas. Uma das principais vantagens do ERA5-Land é sua capacidade de fornecer dados horários e mascarar áreas oceânicas, facilitando análises específicas para superfícies terrestres. Além disso, o modelo incorpora melhorias no esquema H-TESEL, projetado para representar com precisão a hidrologia da superfície terrestre. O ERA5-Land não utiliza assimilação direta de dados, o que simplifica sua atualização e permite respostas rápidas às melhorias nos modelos ou novos conjuntos de dados auxiliares. Este conjunto de dados é amplamente utilizado em aplicações como previsão de secas e inundações, devido à sua alta resolução temporal e espacial.

3.2 Métodos

Neste capítulo, serão descritas todas as etapas relevantes do processamento das imagens da série LANDSAT e dos dados ERA5-Land, até a classificação da área da geleira, obtenção do vetor de movimentação para estimativa da variação da frente da geleira Grey, obtenção dos padrões espaciais e a correlação com as forçantes climatológicas. Além também da validação da classificação da área e deslocamento da frente utilizando os dados vetoriais do projeto GLIMS. O fluxograma metodológico apresentado na figura 7 ilustra as etapas descritas. Além disso, também será apresentada a construção do modelo dinâmico para a determinação da área da geleira.




Figura 7: Diagrama metodológico.

3.2.1 Seleção e Pré-Processamento das imagens dos sensores da série LANDSAT

Esta etapa foi conduzida utilizando dados das missões espaciais TM/LANDSAT 5, ETM+/LANDSAT 7, OLI-TIRS/LANDSAT 8, OLI2-TIRS2/LANDSAT 9. Nessa etapa, adotou-se um critério rigoroso de seleção, incluindo apenas as imagens com boa visibilidade e sem a presença de nuvens, a fim de minimizar possíveis interferências e garantir uma melhor qualidade dos dados.

As imagens selecionadas passaram pelo pré-processamento utilizando o software QGIS e o plugin SCP. Primeiramente, foi realizada a conversão de imagens de DN (ou seja, Números Digitais) para a medida física de reflectância do Topo da Atmosfera (TOA) e a aplicação de uma correção atmosférica simples usando o método DOS1 (Dark Object Subtraction 1).

A aplicação do DOS envolve, inicialmente, a identificação automática dos *pixels* negros em cada banda espectral, ou seja, os *pixels* com os menores valores de reflectância TOA. Esses *pixels* negros são considerados objetos escuros cuja reflectância é próxima de zero, conforme o pressuposto do método de CHAVEZ et al. (1996); SOBRINO et al. (2004).

Após a calibração das imagens, as bandas foram devidamente empilhadas e exportadas utilizando o sistema de coordenadas WGS 84 com projeção *Universal Transversal de Mercator* (UTM) 18°S no formato GeoTIFF. As imagens tratadas foram então carregadas na plataforma de computação em nuvem GEE onde foram recortadas para a região de interesse.

3.2.2 Determinação da Área e da Frente da Geleira com GEE

O estudo foi conduzido utilizando o Google Earth Engine (GEE) para analisar a dinâmica de uma geleira localizada em uma região delimitada por um polígono retangular, definido como a área de interesse (ROI). O objetivo principal foi determinar a área total da geleira ao longo do tempo, identificar deslocamentos e calcular o movimento de sua frente entre os anos de 2000 e 2024.

As imagens LANDSAT foram carregadas e associadas ao respectivo ano como uma propriedade, permitindo a organização temporal dos dados. Para o cálculo dos índices espectrais NDWI (Normalized Difference Water Index) e NDSI (Normalized Difference Snow Index), foram utilizadas equações específicas para cada sensor. No caso do LANDSAT-5 e LANDSAT-7, as bandas empregadas para o cálculo foram:

Para os sensores TM e ETM+:

$$NDWI = \frac{B2 - B4}{B2 + B4}, \quad NDSI = \frac{B2 - B5}{B2 + B5} \quad (3.1)$$

Para os sensores OLI, as equações foram ajustadas para as bandas correspondentes:

$$NDWI = \frac{B3 - B5}{B3 + B5}, \quad NDSI = \frac{B3 - B6}{B3 + B6} \quad (3.2)$$

Esses índices normalizados realçam as diferenças espectrais entre água/neve e outros alvos terrestres, facilitando sua identificação e discriminação (XU, 2006). Após o cálculo dos índices,

são aplicados limiares empíricos para segmentar as áreas de interesse, como corpos d'água e cobertura de neve/gelo (KULKARNI et al., 2006; HUGGEL et al., 2002). Além disso, foi realizada uma análise de textura na banda do infravermelho próximo (NIR), utilizando a matriz de coocorrência de níveis de cinza (GLCM), permitindo calcular a variância da textura.

Com base nos índices calculados e na análise de textura, as áreas glaciais foram classificadas aplicando condições específicas: valores de NDSI $> 0,4$ para detectar neve e gelo, valores de NDWI $< 0,5$ para excluir grandes corpos d'água, variância $> 0,2$ e reflectância NIR $> 0,11$ para auxiliar na separação dos pixels de gelo/neve e pixels de corpos d'água.

Após essa classificação inicial, foram realizadas operações morfológicas (dilatação e erosão) para refinar os resultados. As áreas classificadas foram vetorizadas em polígonos e filtradas para incluir apenas aquelas com área superior a 10 km^2 . Posteriormente, foi calculada a área total das regiões vetorizadas, somando-se os polígonos filtrados.

Para analisar o deslocamento da frente da geleira ao longo do tempo, os centróides das áreas classificadas foram calculados anualmente. O cálculo do centróide foi realizado determinando o ponto médio geométrico de cada polígono vetorizado correspondente à área classificada como geleira. Esse ponto representa o centro espacial da área analisada em cada ano.

A partir dos centróides anuais, foi possível medir as distâncias entre eles para quantificar o deslocamento da frente da geleira entre os anos. Para quantificar o deslocamento total da frente da geleira, foi calculado o vetor de movimentação, representado pela equação 3.3, entre o centróide inicial (2000) e final (2024). Uma linha conectando os centróides inicial e final foi criada para representar o deslocamento acumulado durante o período analisado.

$$D = \sqrt{(LAT1 - LAT2)^2 + (LON1 - LON2)^2} \quad (3.3)$$

Tanto a classificação da área, quanto o deslocamento da frente da geleira foram comparados com os dados vetoriais do projeto GLIMS, para a região da geleira analisada. Os resultados foram organizados em tabelas contendo as áreas totais das geleiras por ano e as distâncias entre os centróides anuais. Essas tabelas foram exportadas em formato CSV para análises adicionais fora do ambiente do GEE. Por fim, o deslocamento acumulado da frente da geleira entre 2000 e 2024 foi calculado como um indicador-chave das mudanças ocorridas ao longo do período estudado.

3.2.3 Análise EOF, SVD e Séries Temporais

A análise EOF e SVD foi realizada para identificar padrões espaciais e temporais associados às mudanças na extensão das geleiras e suas relações com variáveis climáticas. Esse processo envolveu uma série de etapas, desde o pré-processamento das imagens da série LANDSAT até a aplicação das técnicas de análise estatística. A metodologia seguiu o fluxo descrito no diagrama metodológico (figura 7), integrando dados de satélite e climáticos.

Os dados climáticos da reanálise ERA5-Land, incluindo temperatura do ar a 2m, precipitação de neve, evaporação, albedo e velocidade do vento a 10m, foram ajustados para uma

resolução espacial de 30 metros utilizando reamostragem com interpolação linear. Apenas os valores médios dos verões anuais foram considerados. Por se tratar de uma região com grande obliquidade, o verão acaba se sobressaindo quando se trata de coleta de dados com sensores ópticos; dessa forma, a estação do verão foi escolhida para garantir que as análises fossem mais próximas e compatíveis com as imagens selecionadas.

Com os dados devidamente ajustados, a análise EOF foi aplicada à matriz tridimensional das imagens binárias da geleira para decompor as variações espaciais em modos principais de variabilidade. Cada modo EOF representa um padrão espacial dominante associado a uma fração específica da variância total dos dados. As componentes principais (PCs) foram geradas para representar a evolução no tempo dos padrões espaciais identificados pelos modos EOF.

A análise SVD foi realizada entre os padrões extraídos das imagens binárias da geleira e as variáveis climáticas ajustadas do ERA5-Land. A matriz de covariância cruzada foi calculada entre as anomalias das geleiras e as variáveis climáticas. A SVD foi então utilizada para decompor essa matriz em três componentes principais: U (padrões espaciais das geleiras), V (padrões espaciais das variáveis climáticas) e S (valores singulares).

Um aspecto importante da análise SVD foi o cálculo da correlação de acoplamento entre os coeficientes temporais das geleiras ($sk1$) e das variáveis climáticas ($sk2$). Para o primeiro modo singular, a correlação de acoplamento foi calculada usando o coeficiente de Pearson (ρ), acompanhado pelo p-valor associado para avaliar sua significância estatística. Além disso, foi determinado o nível crítico de correlação ao nível de confiança de 95%, utilizando um teste t bilateral. Esse teste permitiu verificar se a correlação observada era estatisticamente significativa.

Também foi extraída a série temporal das médias anuais dos meses de verão (dezembro a fevereiro - DJF), período que mais se aproxima das imagens obtidas neste trabalho. Após a extração das séries temporais, foi obtida a anomalia extraíndo a média dos valores da própria série temporal e foi realizado o teste de Mann-Kendall para identificar se há a presença de tendência significativa ou não para as variáveis estudadas.

3.2.4 Modelagem do Balanço da Área da Geleira

Para a construção do modelo dinâmico, foi utilizada como base a bibliografia dos autores CUFFEY; PATERSON (2010) e o software VENSIM, onde foram selecionadas as variáveis que se relacionam diretamente com o balanço de massa da geleira, extraídas do ERA5-Land. As variáveis incluem precipitação de neve, temperatura a 2 metros, albedo, evaporação e velocidade do vento. No modelo, a taxa de entrada é representada pela precipitação de neve, enquanto as taxas de saída englobam os processos de ablação e evaporação.

Todo modelo dinâmico é construído a partir da observação de um fenômeno de interesse e das variáveis envolvidas. Inicialmente, identificam-se as variabilidades dessas variáveis em relação à dinâmica do fenômeno observado. Em seguida, realiza-se um processo de ajuste de curvas, que define as equações e os coeficientes capazes de representar a dinâmica do sistema

em estudo. Geralmente, busca-se um modelo mais simples, pois ele facilita a compreensão e a interpretação dos resultados.

A formulação da precipitação (eq. 3.4) foi baseada exclusivamente na função da própria variável de precipitação (eq. 3.7). Por outro lado, a taxa de ablação (eq. 3.5) foi definida como uma função dependente da temperatura (eq. 3.8), do albedo (eq. 3.9) e da velocidade do vento (eq. 3.11). Já a evaporação (eq. 3.6) foi modelada como uma função que considera tanto os dados de evaporação (eq. 3.10) quanto as influências do vento (eq. 3.11) e da temperatura (eq. 3.8).

$$\text{Precipitação} = | f_{precip} | \quad (3.4)$$

$$\text{Ablação} = 2 * | f_{temp} | + | f_{albedo} | + | f_{vento} | \quad (3.5)$$

$$\text{Evaporação} = | f_{evap} | + 0.75 * | f_{temp} | + 0.5 * | f_{vento} | \quad (3.6)$$

$$f_{precip} = 0.0002 * precipTAB(Time) * 10^6 \quad (3.7)$$

$$f_{temp} = 0.0743 * tempTAB(Time) \quad (3.8)$$

$$f_{albedo} = 0.0254 * albedoTAB(Time) \quad (3.9)$$

$$f_{evap} = 1.87 * 10^{-6} * evapTAB(Time) * 10^6 \quad (3.10)$$

$$f_{vento} = 0.0086 * ventoTAB(Time) \quad (3.11)$$

Após a definição das equações e coeficientes, o modelo é executado e os resultados obtidos são analisados em comparação com valores observados, estimados com o GEE. Durante essa etapa, pode ser necessário realizar ajustes de escala para adequar o comportamento das variáveis às equações propostas. Esse processo iterativo garante que o modelo represente de forma mais fiel o fenômeno estudado, permitindo análises confiáveis e previsões robustas. A estrutura geral do modelo dinâmico e suas interações podem ser visualizadas na figura 8.




Figura 8: Modelo dinâmico construído no VENSIM.

4 RESULTADOS E DISCUSSÃO

4.1 Classificação por GEE vs. GLIMS

Por se tratar de uma região extensa e montanhosa, a região selecionada para conduzir este estudo foi a porção frontal da geleira Grey que é a parte mais sensível a variações espaciais ao longo do tempo. Por se tratar da região mais baixa da geleira, essa porção acaba por ter taxas de derretimento e ablação mais elevadas, sendo sensível a variações espaciais ao longo do tempo (DAVIES; GLASSER, 2012).

Dessa forma, foi necessário aproximar os arquivos vetoriais do GLIMS para nossa região de estudo. Após a realização do processamento das imagens da série LANDSAT e dos arquivos vetorizados da geleira Grey, aplicação da metodologia proposta pelo diagrama metodológico descrito pela figura 7, os resultados são mostrados na tabela 7 que contém a quantificação da área classificada pelo GEE e pelo GLIMS, assim como a área de intersecção e sobreposição entre para comparação.

Tabela 7: Classificações feitas pelo GEE e o GLIMS para 2000 e 2016.

	Ano 2000		Ano 2016	
	GEE (km ²)	GLIMS (km ²)	GEE (km ²)	GLIMS (km ²)
Área Classificada	37,22	37,70	30,14	30,81
Área em Intersecção	36,51 km ²		29,69 km ²	
Índice de Sobreposição	95,04 %		94,94 %	

As figuras 9 e 10 representam a classificação obtida pela metodologia proposta do trabalho com a ferramenta GEE e a classificação obtida através dos arquivos vetoriais do inventário de geleiras GLIMS. Para o ano de 2000, o método proposto obteve uma área de aproximadamente 37,22 km², enquanto o arquivo vetorial nos deu uma área aproximada de 37,70 km², uma diferença de aproximadamente 0,48 km². Já para o ano de 2016, os valores foram de aproximadamente 30,14 km² e 30,81 km², respectivamente, representando uma diferença de 0,67 km².




Figura 9: Classificação da área utilizando GEE e arquivo vetorial GLIMS para o ano de 2000 (a) Área classificada com GEE; (b) Área classificada pelo GLIMS.




Figura 10: Classificação da área utilizando GEE e arquivo vetorial GLIMS para o ano de 2016 (a) Área classificada com GEE; (b) Área classificada pelo GLIMS.

Com a finalidade de visualizar as diferenças pontuais entre as duas classificações, foi aplicada a técnica de *Overlay* entre os arquivos vetoriais das classificações (figura 11). A área em intersecção para o ano de 2000 representa um valor aproximado de 36,51 km² e um índice de sobreposição de aproximadamente 95,04%. Já para o ano de 2016, obtivemos um valor de 29,69 km² e 94,94% respectivamente.

As figuras 11a) e 11b), trazem a área de intersecção em verde, a área classificada pelo GEE em rosê e a área classificada pelo GLIMS em azul marinho. É possível observar que a classificação do GLIMS extrapola a área da geleira no terminal esquerdo e não captura totalmente a região frontal dos terminais, enquanto o método proposto consegue capturar de maneira satisfatória as regiões que de fato a geleira está presente, assim como os contornos da geleira.




Figura 11: *Overlay* da área do GEE e arquivo vetorial GLIMS para os anos de 2000 e 2016 (a) Ano de 2000; (b) Ano de 2016.

Para entender melhor a variação espacial e temporal da frente da geleira entre os anos de 2000 e 2016, reduziu-se o polígono de classificação da área da geleira em um ponto central (centroide), pelo qual é possível estimar pontualmente o deslocamento da geleira (figura 12). Dessa forma, a distância entre os centróides de 2000 e 2016 para a classificação via GEE foi estimada em aproximadamente 428 m (figura 12a), enquanto para a classificação via GLIMS foi de 408 m (figura 12b). Dado os resultados, observa-se que a diferença entre a variação da frente da geleira classificada via GEE e via GLIMS é de aproximadamente 20 m, não representando uma diferença considerada significativa, tendo em conta a dimensão da área estudada.

Por se tratar de um inventário de geleiras, onde as geleiras são classificadas de forma manual




Figura 12: Comparação entre os vetores de movimentação gerados a partir da distâncias entre as centróides de 2000 e 2016 (a) Vetor gerado a partir da classificação via GEE; (b) Vetor gerado a partir da classificação via arquivo vetorial GLIMS.

através de uma imagem obtida através de um sensor orbital, o GLIMS conta com algumas limitações dependendo da região de estudo (RAUP et al., 2007; RAUP; KHALSA, 2010). Uma das dificuldades encontradas neste trabalho foi a obtenção de um período temporal mais extenso de classificações da geleira Grey, para a validação e comparação com os resultados obtidos com este trabalho; dessa forma, limitamos esta parte do trabalho a comparar apenas as classificações com o período correspondente ao que é disponibilizado pelo projeto GLIMS.

4.2 Variação Espacial da geleira Grey 2000-2024

Para mensurar de maneira mais eficiente as variações espaciais da área da geleira Grey e também da sua frente, optou-se por estender o período analisado para além do que há pelo projeto GLIMS. Dessa maneira, foi possível realizar a classificação da área da porção frontal da geleira para 14 anos, partindo de 2000 até 2024, conforme demonstrado pela figura 13, onde se tem a classificação para todo o período analisado.



Figura 13: Classificações obtidas via GEE obtidas entre o período de 2000 a 2024.

Ao analisar a figura 13, é possível observar que, na maioria das imagens escolhidas, a metodologia foi capaz de classificar de forma eficiente a área da porção frontal da geleira Grey,

com ressalva da imagem de 2002 (figura 13b), onde uma pequena parte do terminal frontal não foi capturada e na imagem de 2011 (figura 13e), onde a classificação na região frontal capturou uma pequena região de não geleira, além de não capturar uma pequena porção do terminal direito da geleira.

Esses contratempos na classificação podem ser atribuídos a alguns fatores, como a presença de nuvens, desprendimento de gelo e até mesmo sombra da montanha sobre a geleira. Todos esses fatores podem influenciar e confundir a tomada de decisão de acordo com os limiares escolhidos para a classificação de área, gerando *pixels* de gelo onde visivelmente não há gelo.

A tabela 8, traz de maneira quantitativa os valores de área referentes à classificação obtida no GEE (figura 13) e também a área acumulada. Ao analisar a tabela, é possível observar que o período analisado não é contínuo, devido ao fato de alguns anos não possuírem imagens com condições boas para a classificação. Além disso, a geleira Grey é uma geleira de montanha e está em uma região que sofre com a obliquidade, dificultando ainda mais a coleta de dados por sensores ópticos (e.g. Série LANDSAT), sendo que a maioria das imagens com boas condições de visibilidade são referentes ao período das estações da Primavera e do Verão.

Tabela 8: Classificação da área da geleira e área acumulada.

Anos	Área Classificada (km ²)	Área Acumulada (km ²)
2000	37,22	0
2002	36,95	-0,27
2009	33,94	-3,28
2010	33,74	-3,48
2011	33,27	-3,95
2013	31,16	-6,05
2014	30,97	-6,25
2015	30,40	-6,82
2016	30,14	-7,08
2019	29,50	-7,72
2020	28,58	-8,63
2021	27,79	-9,42
2022	27,47	-9,75
2023	26,95	-10,27
2024	26,46	-10,76

A porção frontal da geleira Grey na região de estudo teve seu máximo em 2000 e mínimo em 2024, com as áreas aproximadas de 37,22 km² e 26,46 km², respectivamente. Foi calculada a diferença entre os anos, onde os períodos com maiores perdas ocorreram entre os anos de 2002-2009 e 2011-2013, acumulando perdas de aproximadamente 3,01 km² e 2,11 km² respectivamente. Entre o ano 2000 e 2024, a porção frontal da geleira Grey experimentou uma perda acumulada de 10,76 km².

Essa perda substancial é representada na figura 14, onde temos um gráfico da área classificada em função do tempo, com sua respectiva tendência. Segundo os resultados, a porção frontal da geleira Grey experimentou apenas perdas ao longo dos anos, seguindo uma tendência

negativa de aproximadamente $0,47 \text{ km}^2$ ao ano com um R^2 de aproximadamente 0,987 e um p-valor de $1,495 \times 10^{-13}$, indicando significância ao nível de 95% e que a regressão do modelo linear se ajusta de maneira satisfatória ao nosso conjunto de dados.




Figura 14: Áreas da geleiras obtidas a partir da classificação via GEE.

Para entender melhor o deslocamento da frente da geleira, foi calculado para cada ano o centróide de cada polígono de área e foi feita a diferença entre os períodos, onde os períodos de 2002-2009 e 2011-2013 tiveram o maior recuo da geleira entre todos os outros, com um deslocamento de aproximadamente 140 m e 133 m. Além disso, foi calculado o deslocamento acumulado da geleira, revelando o recuo de 706 m de 2000 a 2024. Os resultados estão contidos na tabela 9.

Tabela 9: Deslocamento ano por período e o acumulado.

Período	Deslocamento (m)	Deslocamento Acumulado (m)
2000-2002	33	33
2002-2009	140	173
2009-2010	14	186
2010-2011	35	221
2011-2013	133	354
2013-2014	51	405
2014-2015	24	429
2015-2016	30	459
2016-2019	50	509
2019-2020	67	575
2020-2021	60	636
2021-2022	27	662
2022-2023	19	681
2023-2024	25	706

Esse deslocamento acumulado pode ser observado na figura 15, onde há o acúmulo do deslocamento da frente da geleira, os períodos analisados e a tendência. Os resultados revelam que a porção frontal da geleira está experimentando um constante recuo, com uma tendência positiva de aproximadamente 51 m por período, com um R^2 de aproximadamente 0,972 e um p-valor de $1,145 \times 10^{-10}$, indicando significância ao nível de 95% e que a regressão do modelo linear se ajusta de maneira satisfatória ao nosso conjunto de dados.




Figura 15: Deslocamento acumulado obtido através das diferenças entre os centróides ano a ano.

Para estimar o deslocamento da frente da geleira entre o ano de 2000 e 2024, foi realizado o cálculo da distância entre os centróides dos dois anos. Assim, gerou-se a figura 16, onde o centróide em azul representa o ano de 2000, enquanto o vermelho representa o ano de 2024. O vetor deslocamento é representado pela linha que liga ambos os centróides. A distância obtida entre ambos os centróides foi de aproximadamente 624 m.

Aqui é importante destacar que o valor do deslocamento acumulado e o deslocamento entre os anos de 2000 e 2024 difere-se devido à condição de não linearidade do recuo da frente. O deslocamento acumulado considera todos os movimentos intermediários, incluindo possíveis avanços temporários ou mudanças de direção. Já o deslocamento direto entre 2000 e 2024 representa apenas a mudança líquida na posição do centróide. A geleira pode recuar de forma irregular, com variações na direção e intensidade do recuo em diferentes períodos; à medida que a geleira recua, sua forma pode mudar significativamente. Isso afeta a posição do centróide, que pode se mover em direções diferentes ao longo do tempo, observado pela figura 17.




Figura 16: Vetor de movimentação gerado a partir da distâncias entre as centróides de 2000 e 2024 obtidos via GEE.




Figura 17: Deslocamento acumulado gerado a partir das distâncias entre os centróides ano a ano referente ao período de 2000 a 2024.

4.3 Análise EOF

A análise dos padrões espaciais e temporais da geleira foi realizada por meio das Funções Ortogonais Empíricas (EOFs), permitindo identificar as principais fontes de variabilidade espacial e temporal presentes nos dados. Os resultados indicam que os dois primeiros modos explicam conjuntamente cerca de 75% da variância total observada, sendo 58,02% atribuídos à EOF 1 e 16,96% à EOF 2. Esses modos representam os padrões dominantes que descrevem o

comportamento espacial e temporal da geleira ao longo do período analisado (2000–2024).

A figura 18 das EOFs mostra os padrões espaciais associados aos dois primeiros modos. A EOF 1 (figura 18a) apresenta um padrão espacial amplo, com valores próximos a zero na região central da geleira e valores negativos nas bordas e na região frontal. Por outro lado, a EOF 2 (figura 18b) exibe um padrão espacial mais localizado, com áreas alternando entre valores positivos e negativos em diferentes regiões da geleira.




Figura 18: Análise dos padrões espaciais e temporais da geleira via EOF (a) Primeiro Modo (EOF1); (b) Segundo Modo (EOF2); (c) Componentes principais referentes a EOF1 e EOF2.

As séries temporais associadas às EOFs (figura 18c, PC 1 e PC 2) estão apresentadas no gráfico à direita da figura 18. A PC 1 demonstra uma tendência de aumento contínuo até 2024. Já a PC 2 (linha laranja), responsável por 16,96% da variância, exibe um padrão distinto. Sua amplitude cresce rapidamente até aproximadamente 2010, indicando uma intensificação dos processos associados a essa componente durante esse período. Contudo, após atingir o pico, observa-se uma redução acentuada na sua amplitude até 2024.

4.4 Análise SVD

Para entender a relação entre os padrões espaciais das geleiras e as forçantes meteorológicas, foi realizada uma análise por Decomposição em Valores Singulares (SVD). Os resultados, apresentados nas figuras 19, 20, 21, 22 e 23, estão organizados em três subplots que ilustram os padrões espaciais das variáveis e suas séries temporais associadas.

Nas figuras, o item a) representa o primeiro modo espacial da geleira, refletindo sua variabilidade ao longo do período analisado. Áreas próximas às bordas apresentam maior contribuição negativa (azul), enquanto regiões internas possuem contribuição positiva (amarelo). A região central apresenta menor contribuição no padrão dominante de variabilidade. Esses resultados sugerem que as mudanças mais relevantes ocorrem nas extremidades da geleira, enquanto a parte central permanece relativamente estável.

Na figura 19b), observa-se o padrão espacial do Modo 1 da temperatura. Nota-se uma correspondência espacial clara entre temperatura e geleira: regiões com maior variabilidade positiva da temperatura coincidem com áreas de maior variabilidade negativa da geleira e vice-versa. Essa relação sugere uma interação significativa entre temperatura e dinâmica glacial. A figura 19c) apresenta as séries temporais dos coeficientes associados ao Modo 1 para ambas as variáveis. Observa-se uma correlação negativa significativa ($\rho = -0,66$, $p = 0,008$), indicando que aumentos na amplitude da temperatura estão associados a reduções na amplitude do padrão da geleira. Destaca-se também um pico significativo na temperatura em 2010, possivelmente relacionado a um evento climático extremo ou anomalia térmica.




Figura 19: Análise dos padrões espaciais e temporais da geleira conjuntamente da temperatura via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da temperatura; (c) Componentes principais referentes aos modos.

A análise da precipitação de neve (figura 20b) também revela correspondência espacial com o padrão das geleiras, especialmente nas bordas. Regiões de maior variabilidade positiva na precipitação coincidem com áreas de maior variabilidade negativa das geleiras, sugerindo que mudanças na precipitação afetam diretamente a dinâmica frontal glacial. As séries temporais dos coeficientes de expansão (figura 20c) mostram correlação positiva moderada ($\rho = 0,55$, $p = 0,033$), indicando que aumentos na precipitação estão relacionados a aumentos no padrão espacial das geleiras ao longo dos anos. Eventos extremos em 2010 e 2020 podem ter contribuído diretamente para essas variações.

Na figura 21b, observa-se uma correspondência geográfica entre albedo e geleira: áreas centrais com maior variabilidade positiva coincidem nas duas variáveis, enquanto as bordas




Figura 20: Análise dos padrões espaciais e temporais da geleira conjuntamente da precipitação de neve via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da precipitação de neve; (c) Componentes principais referentes aos modos.

apresentam contribuições negativas simultâneas. A correlação temporal (figura 20c) é positiva moderada ($\rho = 0,52$, $p = 0,046$), sugerindo que aumentos no albedo associam-se a aumentos no padrão espacial das geleiras ao longo do tempo. O albedo influencia diretamente o balanço energético superficial, afetando o derretimento glacial.

A figura 22b mostra que o padrão espacial da evaporação não possui correspondência direta clara com o padrão das geleiras; áreas de maior contribuição positiva na evaporação encontram-se principalmente fora da região glacial, enquanto áreas negativas coincidem parcialmente com as bordas glaciais. A correlação temporal (figura 22c) é fraca e não significativa ($\rho = 0,17$, $p = 0,551$), indicando a ausência de relação temporal consistente entre evaporação e dinâmica glacial.

Finalmente, a análise da velocidade do vento (figura 23b) revela correspondência geográfica limitada com o padrão glacial: áreas positivas concentram-se em regiões adjacentes às geleiras, enquanto áreas negativas coincidem parcialmente com algumas bordas glaciais. A correlação temporal (figura 23c) é muito fraca e não significativa ($\rho = -0,12$, $p = 0,680$), sugerindo que outros fatores climáticos ou ambientais desempenham papel mais relevante na dinâmica glacial do que a velocidade do vento.




Figura 21: Análise dos padrões espaciais e temporais da geleira conjuntamente do albedo via SVD (a) Primeiro modo da geleira; (b) Primeiro modo do albedo; (c) Componentes principais referentes aos modos.




Figura 22: Análise dos padrões espaciais e temporais da geleira conjuntamente da evaporação via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da evaporação; (c) Componentes principais referentes aos modos.




Figura 23: Análise dos padrões espaciais e temporais da geleira conjuntamente da velocidade do vento via SVD (a) Primeiro modo da geleira; (b) Primeiro modo da velocidade do vento; (c) Componentes principais referentes aos modos.

4.5 Modedo dinâmico para a variabilidade da área superficial da geleira Grey

Os valores para a área modelada e área acumulada obtidos através da execução do modelo dinâmico no VENSIM estão contidos na tabela 10.

Tabela 10: Área modelada e Área modelada acumulada.		
Tempo	Área Modelada (km ²)	Área Modelada Acumulada (km ²)
1	0	0
2	0,51	0,51
3	0,88	1,38
4	0,74	2,12
5	0,84	2,96
6	0,17	3,13
7	-0,19	2,94
8	-0,31	2,62
9	-0,27	2,36
10	-0,83	1,53
11	-0,87	0,67
12	-0,33	0,34
13	-0,76	-0,41
14	-0,92	-1,33
15	-0,87	-2,20
16	-0,32	-2,53
17	-0,35	-2,88
18	-0,495	-3,36
19	-0,36	-3,72
20	-0,72	-4,44
21	-0,43	-4,87
22	-0,50	-5,37
23	-1,28	-6,64
24	-1,72	-8,35
25	-2,31	-10,66

A análise temporal dos dados revela um padrão dinâmico na evolução da porção frontal da geleira Grey. No período inicial, entre os anos 1 e 5, observa-se valores positivos para a área modelada, fenômeno que pode ser atribuído ao equilíbrio proporcionado pela precipitação. Este estado de relativa estabilidade, foi interrompido subsequentemente, quando os processos que contribuem para a ablação glacial e evaporação começaram a predominar no sistema, resultando na tendência negativa evidenciada na Figura 24.

A aplicação do teste de Mann-Kendall para esta série temporal corrobora quantitativamente esta observação, indicando uma tendência negativa estatisticamente significativa (tendência: negativa; p-valor = $1,014 \times 10^{-5}$; estatística Z = -4,414; Tau de Kendall = -0,633; inclinação estimada = -0,077). Estes parâmetros estatísticos demonstram, com elevado nível de confiabilidade, que a redução da área modelada não representa uma flutuação aleatória, mas sim um

comportamento sistemático de retração glacial.




Figura 24: Variação da área frontal da geleira Grey modelada no VENSIM em 25 anos.

A tendência de perda de área na porção frontal torna-se mais evidente quando analisada cumulativamente, tendo uma redução total de $-10,66 \text{ km}^2$ no último ano do período modelado (tabela 10). A figura 25, associada ao teste de Mann-Kendall, confirma uma tendência negativa significativa (tendência: negativa; p-valor = $5,277 \times 10^8$; estatística $Z = -5,441$; Tau de Kendall = $-0,780$; inclinação estimada = $-0,532$). O p-valor, consideravelmente inferior ao limiar convencional de significância (0,05), e o elevado módulo do coeficiente Tau de Kendall indicam uma forte consistência na tendência de redução da área glacial acumulada.




Figura 25: Acumulado da variação da área frontal da geleira Grey modelada no VENSIM.

A validação do modelo foi realizada mediante comparação entre a área acumulada obtida pelo Google Earth Engine (GEE) e a área acumulada derivada do modelo dinâmico implementado (figura 26). Esta análise comparativa revela uma notável convergência entre os valores observados e modelados, ambos apresentando tendências decrescentes e atingindo magnitudes próximas ao final do período estudado: $-10,76 \text{ km}^2$ (GEE) e $-10,66 \text{ km}^2$ (Modelo). Esta proximidade numérica sugere que, apesar das simplificações inerentes ao modelo, o mesmo consegue capturar adequadamente a dinâmica principal de retração da geleira Grey no horizonte temporal considerado.




Figura 26: Área acumulada para a geleira Grey. Em vermelho está a área acumulada obtida no VENSIM, enquanto em azul está a obtida no GEE.

A análise de dispersão entre os valores de área acumulada obtidos via GEE e os resultados do modelo (figura 27) demonstra uma correlação positiva significativa, quantificada por um coeficiente de determinação (R^2) de 0,88. Este parâmetro estatístico indica que aproximadamente 88% da variabilidade observada nos dados do GEE é explicada pelo modelo proposto, o que confirma sua adequação satisfatória para representar a evolução da área acumulada da geleira Grey no contexto temporal analisado.

É importante ressaltar as limitações metodológicas presentes neste estudo. A resolução espacial relativamente grosseira (9 km) utilizada como dado de entrada constitui uma restrição significativa para a representação precisa do comportamento da geleira Grey em escala detalhada. Sistemas glaciais são caracterizados por dinâmicas complexas e multifatoriais que demandariam a incorporação de parâmetros adicionais para uma modelagem mais fidedigna, como o balanço englacial, os processos basais da geleira e as múltiplas variáveis termodinâmicas e mecânicas envolvidas nesses fenômenos. No entanto, no que concerne especificamente à modelagem da área acumulada em escala temporal ampla, o modelo proposto demonstrou desempenho satisfatório, evidenciando sua utilidade para análises de tendências de longo prazo na extensão

glacial, mesmo com as simplificações adotadas.




Figura 27: Dispersão das áreas acumuladas do VENSIM e do GEE.

4.6 Variação espacial da geleira Grey frente as mudanças climáticas

A geleira Grey, localizada no Campo de Gelo Patagônico Sul (CGPS), apresenta um padrão consistente de perda de área e volume nas últimas décadas, diretamente relacionado às mudanças climáticas e às características geográficas locais. Os resultados dessa dissertação reforçam essa tendência, indicando que a porção frontal da geleira perdeu $10,76 \text{ km}^2$ entre 2000 e 2024.

O modelo dinâmico implementado no VENSIM corrobora esses resultados, evidenciando um comportamento inicial de relativa estabilidade, atribuídos ao equilíbrio proporcionado pela precipitação nesse período. Posteriormente, os processos de ablação glacial e evaporação tornaram-se predominantes, resultando em uma perda acumulada significativa de $-10,66 \text{ km}^2$ ao final do período modelado, valor notavelmente convergente com as observações no GEE.

A análise de dispersão entre os valores observados via GEE e os resultados do modelo demonstra uma correlação positiva significativa ($R^2=0,88$), confirmando a adequação do modelo para representar a evolução da área da geleira. Essa perda é compatível com os dados de SÁEZ; STAUB; RÍO (2019), que estimaram uma redução total de $10,87 \text{ km}^2$ na área da geleira Grey entre 1998 e 2017, além de uma diminuição de volume de $2,6 \text{ km}^3$ no mesmo período.

Esses resultados complementam as análises anteriores de WHITE; COPLAND (2015), que identificaram uma perda cumulativa de $15,02 \text{ km}^2$ na área total da geleira Grey entre 1976/79 e 2008/10. Especificamente, no intervalo de 2000/2002 a 2008/10, a perda foi estimada em $3,97 \text{ km}^2$, o que corrobora os dados encontrados nesta pesquisa para o período de 2000 a 2010 ($3,48 \text{ km}^2$).

km²). Esses estudos evidenciam que as perdas são generalizadas e continuam ocorrendo, com taxas médias anuais de retração em torno de -0,60 km² por ano.

Os fatores climáticos desempenham um papel central nesse processo. A análise das anomalias de temperatura na região da geleira Grey entre 2000 e 2024 (figura 28a) revela uma tendência significativa de aumento, confirmada pelo teste de Mann-Kendall (tendência: positiva; p-valor: 0,038; estatística Z: 2,079; Tau de Kendall: 0,3; inclinação estimada: 0,038). Esta tendência de aquecimento corrobora os dados apresentados por ROSENBLÜTH; FUENZALIDA; ACEITUNO (1997) que identificou taxas de aquecimento de 0,013°C para 0,02°C de 1933 à 1992 e o dobro para 1960 à 1992 utilizando estações do norte e sul do Chile. O aquecimento contínuo observado nos dados atuais reforça a compreensão de que as temperaturas mais elevadas estão prolongando a estação de derretimento, contribuindo diretamente para a perda de área da geleira.




Figura 28: Médias anuais das anomalias do verão (DJF) para as forçantes climatológicas (a)Temperatura; (b)Precipitação; (c)Albedo; (d)Evaporação; (e)Velocidade do vento.

Esses resultados corroboram a análise EOF apresentada, que mostrou que o primeiro modo (figura 18a), responsável por 58,02% da variância total, apresenta valores negativos nas bordas e na região frontal da geleira, coincidindo com as áreas de maior recuo observadas. A série temporal associada à EOF 1 (PC 1) demonstra uma tendência de aumento contínuo, período que

coincide com as anomalias positivas de temperatura, reforçando a relação entre o aquecimento e o recuo glacial.

Esta tendência de aumento da temperatura é consistente com os resultados da análise SVD, que revelou uma correlação negativa significativa ($\rho = -0,66$, p-valor = 0,008) entre os padrões espaciais da temperatura e da geleira. Como demonstrado na figura 19, regiões com maior variabilidade positiva da temperatura coincidem com áreas de maior variabilidade negativa da geleira, confirmando a influência direta do aquecimento no recuo glacial.

Quanto às anomalias de precipitação (figura 28b), o teste de Mann-Kendall não identificou uma tendência estatisticamente significativa (tendência: sem tendência; p-valor = 0,065; estatística Z = -1,845; Tau de Kendall = -0,266; inclinação estimada = -0,0001). No entanto, a inclinação negativa observada e o coeficiente Tau de Kendall sugerem uma tendência de diminuição, próxima ao limiar de significância estatística. Esta observação é consistente com os estudos de RASMUSSEN; CONWAY; RAYMOND (2007), que indicaram uma redução de aproximadamente 5% na precipitação sólida entre 1960 e 1999 nos campos de gelo patagônicos. A redução na precipitação, especialmente na forma de neve, diminui o acúmulo anual de gelo, afetando negativamente o balanço de massa da geleira Grey.

A análise SVD da precipitação de neve (figura 20) complementa esses resultados, mostrando uma correlação positiva moderada ($\rho = 0,55$, p-valor = 0,033) entre os padrões espaciais da precipitação e da geleira. Regiões de maior variabilidade positiva na precipitação coincidem com áreas de maior variabilidade negativa das geleiras, confirmando que mudanças na precipitação afetam diretamente a dinâmica frontal glacial.

O balanço de massa das geleiras da Patagônia é caracterizado por uma quantidade extraordinária de neve na área de acumulação (SHIRAIWA et al., 2002; RIVERA et al., 2002; SCHWIKOWSKI et al., 2013). Embora dados de estações meteorológicas entre 51°S e 53°S indiquem pouca variação na precipitação total anual entre 1950 e 2000 (ARAVENA; LUCKMAN, 2009), os dados de reanálise e as tendências observadas neste estudo sugerem alterações nos padrões de precipitação que podem impactar o comportamento da geleira.

As anomalias do albedo (figura 28c) não apresentaram tendência significativa segundo o teste de Mann-Kendall (tendência: sem tendência; p-valor = 0,761; estatística Z = 0,304; Tau de Kendall = 0,047; inclinação estimada = 0,005), porém os gráficos mostram variações importantes, incluindo valores extremamente baixos em anos recentes (2020-2022). Estas flutuações no albedo podem estar relacionadas à exposição de superfícies menos reflexivas na geleira, como mencionado por RAYMOND et al. (2005), que identificou mecanismos de *feedback* positivo relacionados ao albedo como um dos fatores que contribuem para a aceleração do afinamento e recuo das geleiras patagônicas.

Esses resultados são corroborados pela análise SVD do albedo (figura 21), que mostrou uma correlação positiva moderada ($\rho = 0,52$, p-valor = 0,046) entre os padrões espaciais do albedo e da geleira. A correspondência geográfica entre as áreas centrais com maior variabilidade positiva em ambas as variáveis confirma a influência direta do albedo no balanço energético superficial e, conseqüentemente, no derretimento glacial. As variações extremas no albedo observadas nos

gráficos de anomalias climáticas para os anos 2020-2022 podem estar relacionadas às mudanças na série temporal da SVD para o mesmo período.

Para as anomalias de evaporação (figura 28d), o teste de Mann-Kendall também não identificou tendências significativas (tendência: sem tendência; p-valor = 0,870; estatística Z = 0,163; Tau de Kendall = 0,028; inclinação estimada = $5,523 \times 10^{-7}$), assim como para a velocidade do vento (tendência: sem tendência; p-valor = 0,657; estatística Z = 0,443; Tau de Kendall = 0,067; inclinação estimada = 0,002) (figura 28e). No entanto, essas variáveis integram o complexo sistema de interações que, conforme destacado por VILLALBA (2019), afetam o balanço de massa e energia das formações glaciais.

De forma consistente, a análise SVD da evaporação (figura 22) e da velocidade do vento (figura 23) mostrou correlações fracas e não significativas ($\rho = 0,17$, p-valor = 0,551 e $\rho = -0,12$, p-valor = 0,680, respectivamente) com o padrão espacial da geleira. Estes resultados confirmam que, embora estas variáveis façam parte do sistema climático que afeta a geleira, outros fatores como temperatura, precipitação e albedo desempenham papéis mais relevantes na dinâmica glacial, como evidenciado tanto pelos testes estatísticos quanto pela análise de EOF, que mostrou que os dois primeiros modos explicam conjuntamente cerca de 75% da variância total observada.

O impacto das mudanças climáticas nos campos de gelo da Patagônia foi documentado por vários autores. De acordo com MASIOKAS et al. (2009), os Andes da Patagônia têm visto aquecimento substancial e declínios de precipitação durante o período de 1912–2002, como evidenciado pelas tendências lineares em registros regionais de temperatura e precipitação anuais e sazonais. Com base em registros de temperaturas de verão e precipitação de inverno, este autor criou um índice climático que replica as correlações entre o balanço de massa da geleira. Comparações fotográficas revelam recessão glacial, que é apoiada pela tendência de queda do índice climático. Além disso, há fortes correlações positivas com a série regional de precipitação, uma tendência negativa no registro regional de escoamento e semelhanças marcantes com o índice climático.

A região Patagônia Andina tem visto uma tendência significativa de aquecimento ao longo do último século, de acordo com vários conjuntos de dados climáticos (VEBLEN et al., 2011). Tanto para os Andes do Norte quanto do Sul da Patagônia, registros climáticos em grade interpolados de muitas estações climáticas dispersas revelam pequenas quedas na precipitação durante a temporada de outubro a março e tendências significativas de aquecimento no final do século XX.

A combinação destas variáveis climáticas, especialmente o aumento significativo da temperatura identificado pelo teste de Mann-Kendall, cria condições favoráveis ao processo de *calving* mencionado por MINOWA et al. (2021) e SUGIYAMA; MINOWA; SCHAEFER (2019), intensificando o desprendimento de blocos de gelo na geleira Grey. Este mecanismo, somado às alterações no balanço de massa devido às mudanças nos padrões de temperatura e precipitação, explica a aceleração nas taxas de recuo observadas por DAVIES; GLASSER (2012), que identificou o dobro na velocidade de recuo das geleiras entre 2000-2011, atingindo uma taxa anual

média de 0,18%.

Esses padrões são consistentes com os observados por RIGNOT; RIVERA; CASASSA (2003), que identificaram um afinamento mais rápido dos glaciares na metade norte do CGPS em comparação com a metade sul durante o período entre 1968/1975 e 2000. De forma semelhante, ANIYA et al. (1997) relataram taxas mais altas de recuo no norte em comparação com o sul entre as décadas de 1940–1990, além de maiores taxas no leste em relação ao oeste — resultando nas menores taxas gerais no sudoeste e nas maiores no noroeste. Em estudos conduzidos por LOPEZ et al. (2010), flutuações no comprimento dos glaciares do CGPS entre 1945–2005 também apontaram recuos inferiores a 2 km na porção sul do campo de gelo, com exceção da parte mais austral onde os recuos ultrapassaram 2 km.

Os dados climáticos analisados neste estudo, portanto, fornecem evidências adicionais que sustentam as projeções de SÁEZ; STAUB; RÍO (2019), que sugerem perdas superiores a 48 km² em área e 17 km³ em volume até 2050, caso o cenário atual persista. A tendência significativa de aumento da temperatura, combinada com possíveis reduções na precipitação e alterações no albedo, indica que o processo de recuo da geleira Grey deve continuar nas próximas décadas, reforçando a necessidade de monitoramento contínuo e estudos complementares para compreender a dinâmica dessas mudanças.

5 CONCLUSÃO

A metodologia automatizada implementada no GEE para classificação da área glacial e determinação do deslocamento de sua frente mostrou-se eficiente, apresentando uma sobreposição superior a 94% quando comparada com os dados vetoriais do projeto GLIMS. Esta abordagem permitiu superar as limitações de disponibilidade temporal dos inventários existentes, possibilitando uma análise mais detalhada e contínua das mudanças ocorridas na geleira.

A utilização de índices espectrais como NDSI e NDWI, combinados com análise de textura e operações morfológicas, proporcionou uma classificação robusta da área glacial, mesmo em condições de imageamento desafiadoras. A metodologia desenvolvida mostrou-se particularmente eficaz para a região frontal da geleira, que é a mais sensível às variações climáticas e apresenta as maiores taxas de mudança.

A validação dos resultados, realizada por meio da comparação com os dados vetoriais do GLIMS para os anos de 2000 e 2016, demonstrou a confiabilidade da metodologia proposta. Para o ano de 2000, a área classificada pelo método proposto foi de aproximadamente 37,22 km², enquanto o arquivo vetorial do GLIMS indicou uma área de 37,70 km², resultando em uma diferença de 0,48 km². Para 2016, os valores foram de 30,14 km² e 30,81 km², respectivamente, com uma diferença de 0,67 km². Estas pequenas discrepâncias são aceitáveis, considerando as diferentes metodologias e fontes de dados utilizadas.

Os resultados revelaram uma perda significativa de 10,76 km² na área da porção frontal da geleira durante o período analisado, com uma taxa média de retração de aproximadamente 0,47 km² por ano ($R^2 = 0,987$, $p < 0,001$). Esta perda substancial é consistente com estudos anteriores que documentam o recuo acelerado das geleiras na região patagônica, como os trabalhos de SÁEZ; STAUB; RÍO (2019), que estimaram uma redução total de 10,87 km² na área da geleira Grey entre 1998 e 2017, e WHITE; COPLAND (2015), que identificaram uma perda cumulativa de 15,02 km² entre 1976/79 e 2008/10.

A análise temporal revelou que os períodos com maiores perdas ocorreram entre 2002-2009 e 2011-2013, acumulando reduções de aproximadamente 3,01 km² e 2,11 km², respectivamente. Estas perdas aceleradas coincidem com períodos de anomalias térmicas positivas e redução na precipitação de neve, conforme evidenciado pela análise das séries temporais climáticas.

O deslocamento acumulado da frente da geleira foi estimado em 706 m, evidenciando um recuo contínuo, com períodos de retração mais intensa entre 2002-2009 (140 m) e 2011-2013 (133 m). A análise do deslocamento direto entre os centróides de 2000 e 2024 resultou em uma distância de 624 m, valor inferior ao deslocamento acumulado devido à não linearidade do recuo da frente. Esta diferença reflete as variações na direção e intensidade do recuo em diferentes períodos, bem como as mudanças na forma da geleira ao longo do tempo.

A análise de Funções Ortogonais Empíricas (EOF) identificou que os dois primeiros modos explicam cerca de 75% da variância total observada. O primeiro modo (58,02%) está associado principalmente às variações na região frontal da geleira, com valores negativos nas bordas e na

região frontal, coincidindo com as áreas de maior recuo observadas. A série temporal associada à EOF 1 demonstra uma tendência de aumento contínuo até 2024, período que coincide com as anomalias positivas de temperatura.

O segundo modo (16,96%) representa padrões mais localizados, possivelmente relacionados a eventos climáticos específicos. Sua série temporal exibe um padrão distinto, com amplitude crescente até aproximadamente 2010, seguida de uma redução acentuada até 2024. Este comportamento pode estar relacionado a processos específicos, como variações sazonais ou eventos climáticos extremos que impactam partes distintas da geleira de forma desigual.

A Decomposição em Valores Singulares (SVD) demonstrou correlações significativas entre os padrões espaciais da geleira e variáveis climáticas. A temperatura apresentou correlação negativa significativa ($\rho = -0,66$, $p = 0,008$), indicando que o aumento da temperatura está diretamente associado ao recuo glacial. Regiões com maior variabilidade positiva da temperatura coincidem com áreas de maior variabilidade negativa da geleira, confirmando a influência direta do aquecimento no recuo glacial.

A análise temporal do modelo para a área da porção frontal da geleira Grey revela um padrão dinâmico na evolução da porção frontal da geleira Grey. No período inicial (anos 1 a 5), observam-se valores positivos para a área modelada, atribuíveis ao equilíbrio proporcionado pela precipitação. Este estado de relativa estabilidade foi interrompido quando os processos de ablação glacial e evaporação começaram a predominar, resultando em uma tendência negativa. O teste estatístico não paramétrico de Mann-Kendall corrobora essa observação, indicando uma tendência negativa estatisticamente significativa (tendência: negativa; p-valor = $1,014 \times 10^{-5}$; estatística $Z = -4,414$; Tau de Kendall = $-0,633$; inclinação estimada = $-0,077$). Estes parâmetros demonstram, com elevado nível de confiabilidade, que a redução da área modelada não representa uma flutuação aleatória, mas sim um comportamento sistemático de retração glacial.

A tendência de perda de área na porção frontal torna-se ainda mais evidente quando analisada cumulativamente ao longo dos anos, culminando em uma redução total de $-10,66 \text{ km}^2$ no último ano do período modelado. A representação gráfica desta evolução, associada aos resultados do teste de Mann-Kendall, confirma uma tendência negativa altamente significativa (tendência: negativa; p-valor = $5,277 \times 10^{-8}$; estatística $Z = -5,441$; Tau de Kendall = $-0,780$; inclinação estimada = $-0,532$). A magnitude do p-valor, consideravelmente inferior ao limiar convencional de significância (0,05), e o elevado módulo do coeficiente Tau de Kendall indicam uma forte consistência na tendência de redução da área glacial acumulada.

A validação do modelo foi realizada mediante comparação entre a área acumulada obtida pelo Google Earth Engine (GEE) e a área acumulada derivada do modelo dinâmico implementado. Esta análise comparativa revela uma notável convergência entre os valores observados e modelados, ambos apresentando tendências decrescentes e atingindo magnitudes próximas ao final do período estudado: $-10,76 \text{ km}^2$ (GEE) e $-10,66 \text{ km}^2$ (Modelo). Esta proximidade numérica sugere que, apesar das simplificações inerentes ao modelo, o mesmo consegue capturar de maneira satisfatória a dinâmica principal de retração da geleira Grey.

A análise de dispersão entre os valores de área acumulada obtidos via GEE e os resultados do modelo demonstra uma correlação positiva significativa, quantificada por um coeficiente de determinação (R^2) de 0,88. Este parâmetro estatístico indica que aproximadamente 88% da variabilidade observada nos dados do GEE é explicada pelo modelo proposto, o que confirma sua adequação satisfatória para representar a evolução da área acumulada da geleira Grey no contexto temporal analisado.

O teste de Mann-Kendall aplicado às séries temporais climáticas confirmou uma tendência significativa de aumento na temperatura (p-valor = 0,038, $Z = 2,079$), fator determinante para o recuo glacial observado. Esta tendência de aquecimento corrobora os dados apresentados por ROSENBLÜTH; FUENZALIDA; ACEITUNO (1997), identificaram taxas de aquecimento de 0,013°C para 0,02 °C de 1933 à 1992 e o dobro para 1960 à 1992 utilizando estações do norte e sul do Chile. O aquecimento contínuo observado nos dados atuais reforça a compreensão de que as temperaturas mais elevadas estão prolongando a estação de derretimento, contribuindo diretamente para a perda de área da geleira.

A precipitação de neve ($\rho = 0,55$, p-valor = 0,033) e o albedo ($\rho = 0,52$, p-valor = 0,046) mostraram correlações positivas moderadas com os padrões espaciais da geleira. Embora o teste de Mann-Kendall não tenha identificado tendências estatisticamente significativas para essas variáveis, a análise SVD revelou importantes relações espaciais. Regiões de maior variabilidade positiva na precipitação coincidem com áreas de maior variabilidade negativa das geleiras, confirmando que mudanças na precipitação afetam diretamente a dinâmica frontal glacial.

Quanto às anomalias de precipitação, o teste de Mann-Kendall não identificou uma tendência estatisticamente significativa (p-valor = 0,065), mas a inclinação negativa observada e o coeficiente Tau de Kendall sugerem uma tendência de diminuição, próxima ao limiar de significância estatística. Esta observação é consistente com os estudos de RASMUSSEN; CONWAY; RAYMOND (2007), que indicaram uma redução de aproximadamente 5% na precipitação sólida entre 1960 e 1999 nos campos de gelo patagônicos. A redução na precipitação, especialmente na forma de neve, diminui o acúmulo anual de gelo, afetando negativamente o balanço de massa da geleira Grey.

As anomalias do albedo não apresentaram tendência significativa segundo o teste de Mann-Kendall (p-valor = 0,761), porém os gráficos mostram variações importantes, incluindo valores extremamente baixos em anos recentes (2020-2022). Estas flutuações no albedo podem estar relacionadas à exposição de superfícies menos reflexivas na geleira, como mencionado por RAYMOND et al. (2005), que identificou mecanismos de feedback positivo relacionados ao albedo como um dos fatores que contribuem para a aceleração do afinamento e recuo das geleiras patagônicas.

A evaporação ($\rho = 0,17$, p-valor = 0,551) e a velocidade do vento ($\rho = -0,12$, p-valor = 0,680) não apresentaram correlações significativas com os padrões espaciais da geleira, nem tendências estatisticamente significativas segundo o teste de Mann-Kendall. Estes resultados sugerem que, embora estas variáveis façam parte do sistema climático que afeta a geleira, outros fatores como temperatura, precipitação e albedo desempenham papéis mais relevantes na dinâmica glacial.

Os resultados obtidos nesta dissertação se inserem em um contexto regional mais amplo de mudanças climáticas nos Andes da Patagônia. Conforme documentado por MASIOKAS et al. (2009), esta região tem experimentado aquecimento substancial e declínios de precipitação durante o período de 1912-2002, evidenciados pelas tendências lineares em registros regionais de temperatura e precipitação anuais e sazonais.

A região Patagônia Andina tem apresentado uma tendência significativa de aquecimento ao longo do último século, de acordo com vários conjuntos de dados climáticos (VEBLEN et al., 2011). Tanto para os Andes do Norte quanto do Sul da Patagônia, registros climáticos interpolados revelam pequenas quedas na precipitação durante a temporada de outubro a março e tendências significativas de aquecimento no final do século XX. Além disso, a tendência geral de temperatura na Patagônia indica que a temporada de outubro a março está se tornando mais longa devido ao aumento de anomalias positivas ao longo desse período.

A combinação destas variáveis climáticas, especialmente o aumento significativo da temperatura identificado pelo teste de Mann-Kendall, cria condições favoráveis ao processo de *calving* mencionado por MINOWA et al. (2021) e SUGIYAMA; MINOWA; SCHAEFER (2019), intensificando o desprendimento de blocos de gelo na geleira Grey. Este mecanismo, somado às alterações no balanço de massa devido às mudanças nos padrões de temperatura e precipitação, explica a aceleração nas taxas de recuo observadas por DAVIES; GLASSER (2012), que identificou o dobro na velocidade de recuo das geleiras entre 2000-2011, atingindo uma taxa anual média de 0,18%.

A abordagem automatizada desenvolvida para classificação da área glacial e determinação do deslocamento de sua frente utilizando o Google Earth Engine representa um avanço importante em relação aos métodos tradicionais de mapeamento de geleiras, que frequentemente dependem de fotointerpretação e vetorização manual.

A metodologia proposta permite o monitoramento contínuo e sistemático das geleiras, superando as limitações de disponibilidade temporal dos inventários existentes. Além disso, a integração de técnicas de análise estatística avançadas, como EOF e SVD, possibilita uma compreensão mais profunda dos padrões espaciais e temporais associados às mudanças nas geleiras e suas relações com variáveis climáticas.

Do ponto de vista científico, os resultados obtidos contribuem para o avanço do conhecimento sobre a dinâmica das geleiras patagônicas em resposta às mudanças climáticas. A quantificação precisa das taxas de retração da geleira Grey e a identificação dos principais fatores climáticos associados a essas alterações fornecem informações valiosas para a compreensão dos processos que governam o balanço de massa das geleiras na região.

Apesar dos avanços alcançados, esta pesquisa apresenta algumas limitações que devem ser consideradas na interpretação dos resultados. A disponibilidade de imagens de satélite com condições adequadas para a classificação da área glacial foi um fator limitante, especialmente devido à obliquidade da região e à frequente cobertura de nuvens. Isso resultou em uma série temporal não contínua, com lacunas em alguns anos.

Além disso, a resolução espacial das imagens LANDSAT (30 metros) e os dados do ERA5-

Land podem não ser suficientes para capturar detalhes finos da dinâmica glacial, especialmente em regiões com topografia complexa. A utilização de imagens de maior resolução espacial, como as fornecidas pelos satélites SENTINEL-2 ou por sensores comerciais de alta resolução, poderia proporcionar uma análise mais detalhada das mudanças na geleira, tanto para classificação da área da geleira, análise da retração e criação de modelos para entender a dinâmica superficial da geleira.

Como recomendações para trabalhos futuros, sugere-se a integração de dados de radar e altimetria para estimativas mais precisas do volume glacial e das taxas de retração. Sensores de radar, como os dos satélites SENTINEL-1 ou TerraSAR-X, têm a vantagem de não serem afetados pela cobertura de nuvens, permitindo um monitoramento mais contínuo da geleira.

REFERÊNCIAS

- A. RAMEZAN, C.; A. WARNER, T.; E. MAXWELL, A. Evaluation of sampling and cross-validation tuning strategies for regional-scale machine learning classification. **Remote Sensing**, [S.l.], v.11, n.2, p.185, 2019.
- ALBERT, T. H. Evaluation of remote sensing techniques for ice-area classification applied to the tropical Quelccaya Ice Cap, Peru. **Polar Geography**, [S.l.], v.26, n.3, p.210–226, 2002.
- ANIYA, M.; NARUSE, R.; SHIZUKUISHI, M.; SKVARCA, P.; CASASSA, G. Monitoring of recent glacier variations in the Southern Patagonia Icefield, utilizing remote sensing data. **International Archives of Photogrammetry and Remote Sensing**, [S.l.], v.29, p.87–87, 1993.
- ANIYA, M.; SATO, H.; NARUSE, R.; SKVARCA, P.; CASASSA, G. Recent glacier variations in the Southern Patagonia icefield, South America. **Arctic and Alpine Research**, [S.l.], v.29, n.1, p.1–12, 1997.
- ARAVENA, J.-C.; LUCKMAN, B. H. Spatio-temporal rainfall patterns in southern South America. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, [S.l.], v.29, n.14, p.2106–2120, 2009.
- ARENDT, A. et al. Randolph Glacier Inventory (RGI), Vers. 1.0: A dataset of global glacier outlines. **Global Land Ice Measurements from Space, Boulder, Colo., Digital media**. [Available at <http://www.glims.org/RGI/randolph.html>], [S.l.], 2012.
- BACHMANN, M.; GONZÁLEZ, C.; BUESO-BELLO, J.-L.; RIZZOLI, P.; ZINK, M. TanDEM-X Edited DEM: Automated Global Void Filling and Water Flattening. In: IGARSS 2022-2022 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2022. **Anais...** [S.l.: s.n.], 2022. p.5425–5428.
- BAHR, D. B.; MEIER, M. F.; PECKHAM, S. D. The physical basis of glacier volume-area scaling. **Journal of Geophysical Research: Solid Earth**, [S.l.], v.102, n.B9, p.20355–20362, 1997.
- BAHR, D. B.; PFEFFER, W. T.; KASER, G. A review of volume-area scaling of glaciers. **Reviews of Geophysics**, [S.l.], v.53, n.1, p.95–140, 2015.
- BARRY, R. G.; GAN, T. Y. **The global cryosphere: past, present, and future**. [S.l.]: Cambridge University Press, 2022.
- BENN, D.; EVANS, D. J. **Glaciers and glaciation**. [S.l.]: Routledge, 2014.
- BENN, D. I.; WARREN, C. R.; MOTTRAM, R. H. Calving processes and the dynamics of calving glaciers. **Earth-Science Reviews**, [S.l.], v.82, n.3-4, p.143–179, 2007.

- BENNETT, M. M.; GLASSER, N. F. **Glacial geology**: ice sheets and landforms. [S.l.]: John Wiley & Sons, 2011.
- BHARDWAJ, A.; SAM, L.; MARTÍN-TORRES, F. J.; KUMAR, R. et al. UAVs as remote sensing platform in glaciology: Present applications and future prospects. **Remote sensing of environment**, [S.l.], v.175, p.196–204, 2016.
- BJÖRNSSON, H.; VENEGAS, S. A manual for EOF and SVD analyses of climatic data. **CCGCR Report**, [S.l.], v.97, n.1, p.112–134, 1997.
- BOULTON, G. S.; HINDMARSH, R. Sediment deformation beneath glaciers: rheology and geological consequences. **Journal of Geophysical Research: Solid Earth**, [S.l.], v.92, n.B9, p.9059–9082, 1987.
- BURNS, P.; NOLIN, A. Using atmospherically-corrected Landsat imagery to measure glacier area change in the Cordillera Blanca, Peru from 1987 to 2010. **Remote Sensing of Environment**, [S.l.], v.140, p.165–178, 2014.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V.; D'ALGE, J. Introdução à ciência da geoinformação. **São José dos Campos: INPE**, [S.l.], v.345, 2001.
- CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote sensing of environment**, [S.l.], v.113, n.5, p.893–903, 2009.
- CHANGE, I. C. impact. **Adaptation and vulnerability, IPCC WGII AR5 summary for policymakers**, [S.l.], 2014.
- CHAVEZ, P. S. et al. Image-based atmospheric corrections-revisited and improved. **Photogrammetric engineering and remote sensing**, [S.l.], v.62, n.9, p.1025–1035, 1996.
- CHERRY, S. Some comments on singular value decomposition analysis. **Journal of Climate**, [S.l.], v.10, n.7, p.1759–1761, 1997.
- CLARKE, G. K. Fast glacier flow: Ice streams, surging, and tidewater glaciers. **Journal of Geophysical Research: Solid Earth**, [S.l.], v.92, n.B9, p.8835–8841, 1987.
- CLARKE, G. K.; JAROSCH, A. H.; ANSLOW, F. S.; RADIĆ, V.; MENOUNOS, B. Projected deglaciation of western Canada in the twenty-first century. **Nature Geoscience**, [S.l.], v.8, n.5, p.372–377, 2015.
- CRAWFORD, C. J.; MANSON, S. M.; BAUER, M. E.; HALL, D. K. Multitemporal snow cover mapping in mountainous terrain for Landsat climate data record development. **Remote Sensing of Environment**, [S.l.], v.135, p.224–233, 2013.

- CUFFEY, K. M.; PATERSON, W. S. B. **The physics of glaciers**. [S.l.]: Academic Press, 2010.
- DAVIES, B.; GLASSER, N. Accelerating shrinkage of Patagonian glaciers from the Little Ice Age (~ AD 1870) to 2011. **Journal of Glaciology**, [S.l.], v.58, n.212, p.1063–1084, 2012.
- DERKSEN, C.; BROWN, R. Spring snow cover extent reductions in the 2008–2012 period exceeding climate model projections. **Geophysical Research Letters**, [S.l.], v.39, n.19, 2012.
- DOZIER, J.; SCHNEIDER, S. R.; MCGINNIS, D. F. Effect of grain size and snowpack water equivalence on visible and near-infrared satellite observations of snow. **Water Resources Research**, [S.l.], v.17, n.4, p.1213–1221, 1981.
- ERICKSON, T. Multi-source geospatial data analysis with Google Earth Engine. In: AGU FALL MEETING ABSTRACTS, 2014. **Anais...** [S.l.: s.n.], 2014. v.2014, p.IN53E–05.
- FARR, T. G.; ROSEN, P. A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.; KOBICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L. et al. The shuttle radar topography mission. **Reviews of geophysics**, [S.l.], v.45, n.2, 2007.
- FELL, S. C.; CARRIVICK, J. L.; KELLY, M. G.; FÜREDER, L.; BROWN, L. E. Declining glacier cover threatens the biodiversity of alpine river diatom assemblages. **Global change biology**, [S.l.], v.24, n.12, p.5828–5840, 2018.
- FLORINSKY, I. **Digital terrain analysis in soil science and geology**. [S.l.]: Academic Press, 2016.
- FORRESTER, J. W. Industrial dynamics. **Journal of the Operational Research Society**, [S.l.], v.48, n.10, p.1037–1041, 1997.
- FRANCOU, B.; RAMIREZ, E.; CÁCERES, B.; MENDOZA, J. Glacier evolution in the tropical Andes during the last decades of the 20th century: Chacaltaya, Bolivia, and Antizana, Ecuador. **AMBIO: A Journal of the Human Environment**, [S.l.], v.29, n.7, p.416–422, 2000.
- FU, Z.; HUANG, A.; GUO, Q. Improvements of the Sub-Seasonal Precipitation Predicted by the BCC_S2S Forecast System Over Eastern China in Summer Using the Singular Value Decomposition Bias Correction Method. **Frontiers in Earth Science**, [S.l.], v.9, p.770167, 2022.
- GAO, B.-C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, [S.l.], v.58, n.3, p.257–266, 1996.
- GARDNER, A.; FAHNSTOCK, M.; SCAMBOS, T. **ITS_LIVE Regional Glacier and Ice Sheet Surface Velocities; Data archived at National Snow and Ice Data Center**.

- GIESEN, R. H.; OERLEMANS, J. Climate-model induced differences in the 21st century global and regional glacier contributions to sea-level rise. **Climate dynamics**, [S.l.], v.41, p.3283–3300, 2013.
- GOLUB, G. H.; REINSCH, C. Singular value decomposition and least squares solutions. In: **Handbook for Automatic Computation: Volume II: Linear Algebra**. [S.l.]: Springer, 1971. p.134–151.
- GONZALEZ, R. C. **Digital image processing**. [S.l.]: Pearson education india, 2009.
- GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. Upper Saddle River, N.J.: Prentice Hall, 2008.
- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, [S.l.], v.202, p.18–27, 2017.
- GUTH, P. L.; VAN NIEKERK, A.; GROHMANN, C. H.; MULLER, J.-P.; HAWKER, L.; FLORINSKY, I. V.; GESCH, D.; REUTER, H. I.; HERRERA-CRUZ, V.; RIAZANOFF, S. et al. Digital elevation models: Terminology and definitions. **Remote Sensing**, [S.l.], v.13, n.18, p.3581, 2021.
- HAGG, W. **Glaciology and Glacial Geomorphology**. [S.l.]: Springer Nature, 2022.
- HALL, D. K.; MARTINEC, J. An introduction to the optical, thermal and electrical properties of ice and snow. In: **Remote Sensing of Ice and Snow**. [S.l.]: Springer, 1985. p.1–9.
- HALL, D. K.; RIGGS, G. A.; SALOMONSON, V. V. Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data. **Remote sensing of Environment**, [S.l.], v.54, n.2, p.127–140, 1995.
- HAMBREY, M. J. **Glacial environments**. [S.l.]: UBC Press, 1994.
- HAN, S.; KIM, K.; JUNG, S. **Robust SVD Made Easy**: A fast and reliable algorithm for large-scale data analysis.
- HANCHER, M. Planetary-scale geospatial data Analysis techniques in Google’s Earth Engine platform. In: AGU FALL MEETING ABSTRACTS, 2013. **Anais. . .** [S.l.: s.n.], 2013. v.2013, p.IN52A–07.
- HANSEN, M. C.; LOVELAND, T. R. A review of large area monitoring of land cover change using Landsat data. **Remote sensing of Environment**, [S.l.], v.122, p.66–74, 2012.
- HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. Image analysis using mathematical morphology. **IEEE transactions on pattern analysis and machine intelligence**, [S.l.], n.4, p.532–550, 1987.

- HIRABAYASHI, Y.; ZANG, Y.; WATANABE, S.; KOIRALA, S.; KANAE, S. Projection of glacier mass changes under a high-emission climate scenario using the global glacier model HYOGA2. **Hydrological Research Letters**, [S.l.], v.7, n.1, p.6–11, 2013.
- HOCK, R.; BLISS, A.; MARZEION, B.; GIESEN, R. H.; HIRABAYASHI, Y.; HUSS, M.; RADIC, V.; SLANGEN, A. B. GlacierMIP—A model intercomparison of global-scale glacier mass-balance models and projections. **Journal of Glaciology**, [S.l.], v.65, n.251, p.453–467, 2019.
- HUANG, C.; CHEN, Y.; ZHANG, S.; WU, J. Detecting, extracting, and monitoring surface water from space using optical sensors: A review. **Reviews of Geophysics**, [S.l.], v.56, n.2, p.333–360, 2018.
- HUGGEL, C.; KÄÄB, A.; HAEBERLI, W.; TEYSSEIRE, P.; PAUL, F. Remote sensing based assessment of hazards from glacier lake outbursts: a case study in the Swiss Alps. **Canadian Geotechnical Journal**, [S.l.], v.39, n.2, p.316–330, 2002.
- HUGONNET, R.; MCNABB, R.; BERTHIER, E.; MENOUNOS, B.; NUTH, C.; GIROD, L.; FARINOTTI, D.; HUSS, M.; DUSSAILLANT, I.; BRUN, F. et al. Accelerated global glacier mass loss in the early twenty-first century. **Nature**, [S.l.], v.592, n.7856, p.726–731, 2021.
- HUSS, M.; FARINOTTI, D. Distributed ice thickness and volume of all glaciers around the globe. **Journal of Geophysical Research: Earth Surface**, [S.l.], v.117, n.F4, 2012.
- HUSS, M.; HOCK, R. A new model for global glacier change and sea-level rise. **Frontiers in Earth Science**, [S.l.], v.3, p.54, 2015.
- HUSS, M.; JOUVET, G.; FARINOTTI, D.; BAUDER, A. Future high-mountain hydrology: a new parameterization of glacier retreat. **Hydrology and Earth System Sciences**, [S.l.], v.14, n.5, p.815–829, 2010.
- HUTTER, K.; HUGHES, T. Theoretical glaciology. **Journal of Applied Mechanics**, [S.l.], v.51, n.4, p.948, 1984.
- IPCC., C. AR6 synthesis report: Climate change 2023. , [S.l.], 2023.
- IRISH, R. R. Landsat 7 science data users handbook. **National Aeronautics and Space Administration, Report**, [S.l.], v.2000, p.415–430, 2000.
- IRONS, J. R.; DWYER, J. L.; BARSİ, J. A. The next Landsat satellite: The Landsat data continuity mission. **Remote sensing of environment**, [S.l.], v.122, p.11–21, 2012.
- JENSEN, J. R.; EPIPHANIO, J. C. N. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. , [S.l.], 2009.
- JISKOOT, H. Dynamics of glaciers. **physical Research**, [S.l.], v.92, n.B9, p.9–083, 2011.

- JÓHANNESSON, T.; RAYMOND, C.; WADDINGTON, E. Time-scale for adjustment of glaciers to changes in mass balance. **Journal of Glaciology**, [S.l.], v.35, n.121, p.355–369, 1989.
- JOHANSEN, K.; PHINN, S.; TAYLOR, M. Mapping woody vegetation clearing in Queensland, Australia from Landsat imagery using the Google Earth Engine. **Remote Sensing Applications: Society and Environment**, [S.l.], v.1, p.36–49, 2015.
- JOHNSON, E.; RUPPER, S. An examination of physical processes that trigger the albedo-feedback on glacier surfaces and implications for regional glacier mass balance across high mountain Asia. **Frontiers in Earth Science**, [S.l.], v.8, p.129, 2020.
- JOUVET, G.; HUSS, M.; FUNK, M.; BLATTER, H. Modelling the retreat of Grosser Aletschgletscher, Switzerland, in a changing climate. **Journal of Glaciology**, [S.l.], v.57, n.206, p.1033–1045, 2011.
- KAMP, U.; PAN, C. G. Inventory of glaciers in Mongolia, derived from Landsat imagery from 1989 to 2011. **Geografiska Annaler: Series A, Physical Geography**, [S.l.], v.97, n.4, p.653–669, 2015.
- KENDALL, M. G. Rank correlation methods. , [S.l.], 1975.
- KIENHOLZ, C.; HOCK, R.; TRUFFER, M.; BIENIEK, P.; LADER, R. Mass balance evolution of black rapids glacier, Alaska, 1980–2100, and its implications for surge recurrence. **Frontiers in Earth Science**, [S.l.], v.5, p.56, 2017.
- KOZHIKKODAN VEETIL, B.; SOUZA, S. F. de. Study of 40-year glacier retreat in the northern region of the Cordillera Vilcanota, Peru, using satellite images: preliminary results. **Remote Sensing Letters**, [S.l.], v.8, n.1, p.78–85, 2017.
- KULKARNI, A.; SINGH, S.; MATHUR, P.; MISHRA, V. Algorithm to monitor snow cover using AWiFS data of RESOURCESAT-1 for the Himalayan region. **International Journal of Remote Sensing**, [S.l.], v.27, n.12, p.2449–2457, 2006.
- KURODA, Y. An effective SVD calculation method for climate analysis. **Journal of the Meteorological Society of Japan. Ser. II**, [S.l.], v.76, n.4, p.649–655, 1998.
- LI, G.; REN, B.; ZHENG, J.; YANG, C. Trend singular value decomposition analysis and its application to the global ocean surface latent heat flux and SST anomalies. **Journal of climate**, [S.l.], v.24, n.12, p.2931–2948, 2011.
- LI, K.; XU, E. High-accuracy continuous mapping of surface water dynamics using automatic update of training samples and temporal consistency modification based on Google Earth Engine: A case study from Huizhou, China. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v.179, p.66–80, 2021.

- LILLESAND, T.; KIEFER, R.; CHIPMAN, J. Digital image interpretation and analysis. **Remote sensing and image interpretation**, [S.l.], v.6, p.545–81, 2008.
- LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. [S.l.]: John Wiley & Sons, 2015.
- LIU, X. Airborne LiDAR for DEM generation: some critical issues. **Progress in physical geography**, [S.l.], v.32, n.1, p.31–49, 2008.
- LOPEZ, P.; CHEVALLIER, P.; FAVIER, V.; POUYAUD, B.; ORDENES, F.; OERLEMANS, J. A regional view of fluctuations in glacier length in southern South America. **Global and Planetary Change**, [S.l.], v.71, n.1-2, p.85–108, 2010.
- LORENZ, E. N. **Empirical orthogonal functions and statistical weather prediction**. [S.l.]: Massachusetts Institute of Technology, Department of Meteorology Cambridge, 1956. v.1.
- LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International journal of Remote sensing**, [S.l.], v.28, n.5, p.823–870, 2007.
- MANN, H. B. Nonparametric tests against trend. **Econometrica: Journal of the econometric society**, [S.l.], p.245–259, 1945.
- MARKHAM, B. L.; STOREY, J. C.; WILLIAMS, D. L.; IRONS, J. R. Landsat sensor performance: history and current status. **IEEE transactions on geoscience and remote sensing**, [S.l.], v.42, n.12, p.2691–2694, 2004.
- MARTA, S.; AZZONI, R. S.; FUGAZZA, D.; TIELIDZE, L.; CHAND, P.; SIERON, K.; ALMOND, P.; AMBROSINI, R.; ANTHELME, F.; ALVIZ GAZITÚA, P. et al. The retreat of mountain glaciers since the little ice age: A spatially explicit database. **Data**, [S.l.], v.6, n.10, p.107, 2021.
- MARZEION, B.; HOCK, R.; ANDERSON, B.; BLISS, A.; CHAMPOLLION, N.; FUJITA, K. et al. **Results of the second experiment of the Glacier Model Intercomparison Project.(data set)**.
- MARZEION, B.; JAROSCH, A.; HOFER, M. Past and future sea-level change from the surface mass balance of glaciers. **The Cryosphere**, [S.l.], v.6, n.6, p.1295–1322, 2012.
- MASEK, J. G.; WULDER, M. A.; MARKHAM, B.; MCCORKEL, J.; CRAWFORD, C. J.; STOREY, J.; JENSTROM, D. T. Landsat 9: Empowering open science and applications through continuity. **Remote Sensing of Environment**, [S.l.], v.248, p.111968, 2020.

- MASIOKAS, M. H.; RIVERA, A.; ESPIZUA, L. E.; VILLALBA, R.; DELGADO, S.; ARAVENA, J. C. Glacier fluctuations in extratropical South America during the past 1000 years. **Palaeogeography, Palaeoclimatology, Palaeoecology**, [S.l.], v.281, n.3-4, p.242–268, 2009.
- MATHER, P.; TSO, B. **Classification methods for remotely sensed data**. [S.l.]: CRC press, 2016.
- MAUSSION, F.; BUTENKO, A.; CHAMPOLLION, N.; DUSCH, M.; EIS, J.; FOURTEAU, K.; GREGOR, P.; JAROSCH, A. H.; LANDMANN, J.; OESTERLE, F. et al. The open global glacier model (OGGM) v1. 1. **Geoscientific Model Development**, [S.l.], v.12, n.3, p.909–931, 2019.
- MCCARTHY, M.; MILES, E.; KNEIB, M.; BURI, P.; FUGGER, S.; PELLICCIOTTI, F. Supraglacial debris thickness and supply rate in High-Mountain Asia. **Communications Earth & Environment**, [S.l.], v.3, n.1, p.269, 2022.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International journal of remote sensing**, [S.l.], v.17, n.7, p.1425–1432, 1996.
- MEADOWS, D. H. **Thinking in systems: A primer**. [S.l.]: chelsea green publishing, 2008.
- MENDONÇA, L. F. F. d. Estimativa das variações sazonais no fluxo da Geleira Grey, Patagônia, por imagens SAR. , [S.l.], 2013.
- MEREDITH, M.; SOMMERKORN, M.; CASSOTTA, S.; DERKSEN, C.; EKAYKIN, A.; HOLLOWED, A.; KOFINAS, G.; MACKINTOSH, A.; MELBOURNE-THOMAS, J.; MUELBERT, M. et al. Polar Regions. Chapter 3, IPCC Special Report on the Ocean and Cryosphere in a Changing Climate. , [S.l.], 2019.
- MILLAN, R.; MOUGINOT, J.; RABATEL, A.; MORLIGHEM, M. Ice velocity and thickness of the world's glaciers. **Nature Geoscience**, [S.l.], v.15, n.2, p.124–129, 2022.
- MINOWA, M.; SCHAEFER, M.; SUGIYAMA, S.; SAKAKIBARA, D.; SKVARCA, P. Frontal ablation and mass loss of the Patagonian icefields. **Earth and Planetary Science Letters**, [S.l.], v.561, p.116811, 2021.
- MOORE, R.; HANSEN, M. Google Earth Engine: a new cloud-computing platform for global-scale earth observation data and analysis. In: AGU FALL MEETING ABSTRACTS, 2011. **Anais...** [S.l.: s.n.], 2011. v.2011, p.IN43C–02.
- MUDRYK, L.; KUSHNER, P.; DERKSEN, C.; THACKERAY, C. Snow cover response to temperature in observational and climate model ensembles. **Geophysical Research Letters**, [S.l.], v.44, n.2, p.919–926, 2017.

- MUTANGA, O.; KUMAR, L. **Google earth engine applications**. [S.l.]: MDPI, 2019. 591p. v.11, n.5.
- OLIVEIRA, A. M. S. D. F. d. Variações na extensão da cobertura de gelo do Nevado Cololo, Bolívia. , [S.l.], 2013.
- ORLOVE, B. Glacier retreat: reviewing the limits of human adaptation to climate change. **Environment: Science and Policy for Sustainable Development**, [S.l.], v.51, n.3, p.22–34, 2009.
- PADMAN, L.; COSTA, D. P.; DINNIMAN, M. S.; FRICKER, H. A.; GOEBEL, M. E.; HUCKSTADT, L. A.; HUMBERT, A.; JOUGHIN, I.; LENAERTS, J. T.; LIGTENBERG, S. R. et al. Oceanic controls on the mass balance of Wilkins Ice Shelf, Antarctica. **Journal of Geophysical Research: Oceans**, [S.l.], v.117, n.C1, 2012.
- PATERSON, W. S. B. **Physics of glaciers**. [S.l.]: Butterworth-Heinemann, 1994.
- PAUL, F.; KÄÄB, A.; HAEBERLI, W. Recent glacier changes in the Alps observed by satellite: Consequences for future monitoring strategies. **Global and Planetary Change**, [S.l.], v.56, n.1-2, p.111–122, 2007.
- PAUL, F.; WINSVOLD, S. H.; KÄÄB, A.; NAGLER, T.; SCHWAIZER, G. Glacier remote sensing using Sentinel-2. Part II: Mapping glacier extents and surface facies, and comparison to Landsat 8. **Remote Sensing**, [S.l.], v.8, n.7, p.575, 2016.
- PETSCH, C. Sensoriamento remoto da calota de gelo da ilha Renaud–Antártica. , [S.l.], 2014.
- POST, A.; O'NEEL, S.; MOTYKA, R. J.; STREVELER, G. A complex relationship between calving glaciers and climate. **Eos, Transactions American Geophysical Union**, [S.l.], v.92, n.37, p.305–306, 2011.
- QIN, Z.; LIN, Z.; CHEN, H.; SUN, Z. The bias correction methods based on the EOF/SVD for short-term climate prediction and their applications. **Acta Meteorologica Sinica**, [S.l.], v.69, n.2, p.289–296, 2011.
- RACOVITEANU, A. E.; PAUL, F.; RAUP, B.; KHALSA, S. J. S.; ARMSTRONG, R. Challenges and recommendations in mapping of glacier parameters from space: results of the 2008 Global Land Ice Measurements from Space (GLIMS) workshop, Boulder, Colorado, USA. **Annals of Glaciology**, [S.l.], v.50, n.53, p.53–69, 2009.
- RADIĆ, V.; HOCK, R. Regionally differentiated contribution of mountain glaciers and ice caps to future sea-level rise. **Nature Geoscience**, [S.l.], v.4, n.2, p.91–94, 2011.
- RAPER, S. C.; BRAITHWAITE, R. J. Low sea level rise projections from mountain glaciers and icecaps under global warming. **Nature**, [S.l.], v.439, n.7074, p.311–313, 2006.

- RASMUSSEN, L.; CONWAY, H.; RAYMOND, C. Influence of upper air conditions on the Patagonia icefields. **Global and Planetary Change**, [S.l.], v.59, n.1-4, p.203–216, 2007.
- RAUP, B.; KHALSA, S. J. S. GLIMS analysis tutorial. **Boulder, CO: National Snow**, [S.l.], 2010.
- RAUP, B.; RACOVITEANU, A.; KHALSA, S. J. S.; HELM, C.; ARMSTRONG, R.; ARNAUD, Y. The GLIMS geospatial glacier database: A new tool for studying glacier change. **Global and Planetary Change**, [S.l.], v.56, n.1-2, p.101–110, 2007.
- RAYMOND, C.; NEUMANN, T. A.; RIGNOT, E.; ECHELMMEYER, K.; RIVERA, A.; CASASSA, G. Retreat of Glaciar Tyndall, Patagonia, over the last half-century. **Journal of Glaciology**, [S.l.], v.51, n.173, p.239–247, 2005.
- RECINOS, B.; MAUSSION, F.; ROTHENPIELER, T.; MARZEION, B. Impact of frontal ablation on the ice thickness estimation of marine-terminating glaciers in Alaska. **The Cryosphere**, [S.l.], v.13, n.10, p.2657–2672, 2019.
- REES, W. G. **Remote sensing of snow and ice**. [S.l.]: CRC press, 2005.
- REID, T.; CARENZO, M.; PELLICCIOTTI, F.; BROCK, B. Including debris cover effects in a distributed model of glacier ablation. **Journal of Geophysical Research: Atmospheres**, [S.l.], v.117, n.D18, 2012.
- RICHARDS, J. A. **Remote sensing digital image analysis: An introduction** (5th ed.). [S.l.]: Springer, 2013.
- RICHARDS, J. A.; RICHARDS, J. A. Clustering and unsupervised classification. **Remote Sensing Digital Image Analysis: An Introduction**, [S.l.], p.319–341, 2013.
- RIGNOT, E.; RIVERA, A.; CASASSA, G. Contribution of the Patagonia Icefields of South America to sea level rise. **Science**, [S.l.], v.302, n.5644, p.434–437, 2003.
- RIVERA, A.; ACUÑA, C.; CASASSA, G.; BOWN, F. Use of remotely sensed and field data to estimate the contribution of Chilean glaciers to eustatic sea-level rise. **Annals of Glaciology**, [S.l.], v.34, p.367–372, 2002.
- RIVERA, A.; CASASSA, G. Ice elevation, areal, and frontal changes of glaciers from National Park Torres del Paine, Southern Patagonia Icefield. **Arctic, Antarctic, and Alpine Research**, [S.l.], v.36, n.4, p.379–389, 2004.
- RIZZOLI, P.; MARTONE, M.; GONZALEZ, C.; WECKLICH, C.; TRIDON, D. B.; BRÄUTIGAM, B.; BACHMANN, M.; SCHULZE, D.; FRITZ, T.; HUBER, M. et al. Generation and performance assessment of the global TanDEM-X digital elevation model. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v.132, p.119–139, 2017.

- ROSENBLÜTH, B.; FUENZALIDA, H. A.; ACEITUNO, P. Recent temperature variations in southern South America. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, [S.l.], v.17, n.1, p.67–85, 1997.
- ROUNCE, D. R.; HOCK, R.; MCNABB, R.; MILLAN, R.; SOMMER, C.; BRAUN, M.; MALZ, P.; MAUSSION, F.; MOUGINOT, J.; SEEHAUS, T. et al. Distributed global debris thickness estimates reveal debris significantly impacts glacier mass balance. **Geophysical Research Letters**, [S.l.], v.48, n.8, p.e2020GL091311, 2021.
- ROUNCE, D. R.; HOCK, R.; SHEAN, D. E. Glacier mass change in High Mountain Asia through 2100 using the open-source python glacier evolution model (PyGEM). **Frontiers in Earth Science**, [S.l.], v.7, p.331, 2020.
- ROWAN, A. V.; EGHOLM, D. L.; QUINCEY, D. J.; GLASSER, N. F. Modelling the feedbacks between mass balance, ice flow and debris transport to predict the response to climate change of debris-covered glaciers in the Himalaya. **Earth and Planetary Science Letters**, [S.l.], v.430, p.427–438, 2015.
- ROY, D. P.; WULDER, M. A.; LOVELAND, T. R.; WOODCOCK, C. E.; ALLEN, R. G.; ANDERSON, M. C.; HELDER, D.; IRONS, J. R.; JOHNSON, D. M.; KENNEDY, R. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, [S.l.], v.145, p.154–172, 2014.
- SÁEZ, N.; STAUB, G.; RÍO, R. Abarca-del. Monitoring Glacier Retreat in the Chilean Southern Patagonian Ice Field. In: IGARSS 2019-2019 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2019. **Anais...** [S.l.: s.n.], 2019. p.4169–4171.
- SAYLER, K.; GLYNN, T. Landsat 9 data users handbook (Version 1.0). **National Aeronautics and Space Administration, Report**, [S.l.], p.107, 2022.
- SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. [S.l.]: elsevier, 2006.
- SCHWIKOWSKI, M.; SCHLÄPPI, M.; SANTIBAÑEZ, P.; RIVERA, A.; CASASSA, G. Net accumulation rates derived from ice core stable isotope records of Pío XI glacier, Southern Patagonia Icefield. **The Cryosphere**, [S.l.], v.7, n.5, p.1635–1644, 2013.
- SHARP, R. P. **Living ice: understanding glaciers and glaciation**. [S.l.]: Cambridge University Press, 1991.
- SHEN, S. S.; SHEN, S. S.; NORTH, G. R. **Statistics and Data Visualization in Climate Science with R and Python**. [S.l.]: Cambridge University Press, 2023.
- SHIRAIWA, T.; KOHSHIMA, S.; UEMURA, R.; YOSHIDA, N.; MATOBA, S.; UETAKE, J.; GODOI, M. A. High net accumulation rates at Campo deHielo Patagónico Sur, South

- America, revealed by analysis of a 45.97 m long ice core. **Annals of Glaciology**, [S.l.], v.35, p.84–90, 2002.
- SIDHU, N.; PEBESMA, E.; CÂMARA, G. Using Google Earth Engine to detect land cover change: Singapore as a use case. **European Journal of Remote Sensing**, [S.l.], v.51, n.1, p.486–500, 2018.
- SIMÕES, J. C. Glossário da língua portuguesa da neve, do gelo e termos correlatos. **Pesquisa Antártica Brasileira**, [S.l.], v.4, n.119-154, 2004.
- SOBRINO, J. A. et al. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of environment**, [S.l.], v.90, n.4, p.434–440, 2004.
- SOILLE, P. et al. **Morphological image analysis: principles and applications**. [S.l.]: Springer, 1999. v.2, n.3.
- SOILLE, P.; PESARESI, M. Advances in mathematical morphology applied to geoscience and remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v.40, n.9, p.2042–2055, 2002.
- SOUZA JR, C. M.; KIRCHHOFF, F. T.; OLIVEIRA, B. C.; RIBEIRO, J. G.; SALES, M. H. Long-term annual surface water change in the Brazilian Amazon Biome: potential links with deforestation, infrastructure development and climate change. **Water**, [S.l.], v.11, n.3, p.566, 2019.
- STERMAN, J. **Business Dynamics: Systems Thinking and Modeling for a Complex World** Irwin McGraw-Hill Boston MA.
- STEWART, G. W. On the early history of the singular value decomposition. **SIAM review**, [S.l.], v.35, n.4, p.551–566, 1993.
- SUGIYAMA, S.; MINOWA, M.; FUKAMACHI, Y.; HATA, S.; YAMAMOTO, Y.; SAUTER, T.; SCHNEIDER, C.; SCHAEFER, M. Subglacial discharge controls seasonal variations in the thermal structure of a glacial lake in Patagonia. **Nature communications**, [S.l.], v.12, n.1, p.6301, 2021.
- SUGIYAMA, S.; MINOWA, M.; SCHAEFER, M. Underwater ice terrace observed at the front of Glaciar Grey, a freshwater calving glacier in Patagonia. **Geophysical research letters**, [S.l.], v.46, n.5, p.2602–2609, 2019.
- TACHIKAWA, T.; KAKU, M.; IWASAKI, A.; GESCH, D. B.; OIMOEN, M. J.; ZHANG, Z.; DANIELSON, J. J.; KRIEGER, T.; CURTIS, B.; HAASE, J. et al. **ASTER global digital elevation model version 2-summary of validation results**. [S.l.]: NASA, 2011.

- TADONO, T.; TAKAKU, J.; TSUTSUI, K.; ODA, F.; NAGAI, H. Status of “ALOS World 3D (AW3D)” global DSM generation. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2015., 2015. **Anais. . .** [S.l.: s.n.], 2015. p.3822–3825.
- TALOOR, A. K.; KOTHYARI, G. C.; MANHAS, D. S.; BISHT, H.; MEHTA, P.; SHARMA, M.; MAHAJAN, S.; ROY, S.; SINGH, A. K.; ALI, S. Spatio-temporal changes in the Machoi glacier Zaskar Himalaya India using geospatial technology. **Quaternary Science Advances**, [S.l.], v.4, p.100031, 2021.
- TRUFFER, M.; MOTYKA, R. J. Where glaciers meet water: Subaqueous melt and its relevance to glaciers in various settings. **Reviews of Geophysics**, [S.l.], v.54, n.1, p.220–239, 2016.
- VEBLEN, T. T.; HOLZ, A.; PARITSIS, J.; RAFFAELE, E.; KITZBERGER, T.; BLACKHALL, M. Adapting to global environmental change in Patagonia: what role for disturbance ecology? **Austral Ecology**, [S.l.], v.36, n.8, p.891–903, 2011.
- VEEN, C. Van der. Calving glaciers. **Progress in Physical Geography**, [S.l.], v.26, n.1, p.96–122, 2002.
- VEETTIL, B. K. Glacier mapping in the Cordillera Blanca, Peru, tropical Andes, using Sentinel-2 and Landsat data. **Singapore Journal of Tropical Geography**, [S.l.], v.39, n.3, p.351–363, 2018.
- VEETTIL, B. K.; KAMP, U. Global disappearance of tropical mountain glaciers: observations, causes, and challenges. **Geosciences**, [S.l.], v.9, n.5, p.196, 2019.
- VENTANA, S. **Vensim Software**. <https://vensim.com/software/Versions>.
- VILLALBA, R. Glaciares y cambio climático. , [S.l.], 2019.
- WHITE, A.; COPLAND, L. Decadal-scale variations in glacier area changes across the Southern Patagonian Icefield since the 1970s. **Arctic, Antarctic, and Alpine Research**, [S.l.], v.47, n.1, p.147–167, 2015.
- WOOD, J.; HARRISON, S.; WILSON, R.; EMMER, A.; YARLEQUE, C.; GLASSER, N.; TORRES, J.; CABALLERO, A.; ARAUJO, J.; BENNETT, G. et al. Contemporary glacial lakes in the Peruvian Andes. **Global and Planetary Change**, [S.l.], v.204, p.103574, 2021.
- WULDER, M. A.; LOVELAND, T. R.; ROY, D. P.; CRAWFORD, C. J.; MASEK, J. G.; WOODCOCK, C. E.; ALLEN, R. G.; ANDERSON, M. C.; BELWARD, A. S.; COHEN, W. B. et al. Current status of Landsat program, science, and applications. **Remote sensing of environment**, [S.l.], v.225, p.127–147, 2019.

- XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International journal of remote sensing**, [S.l.], v.27, n.14, p.3025–3033, 2006.
- YAMAZAKI, D.; IKESHIMA, D.; TAWATARI, R.; YAMAGUCHI, T.; O’LOUGHLIN, F.; NEAL, J. C.; SAMPSON, C. C.; KANAE, S.; BATES, P. D. A high-accuracy map of global terrain elevations. **Geophysical Research Letters**, [S.l.], v.44, n.11, p.5844–5853, 2017.
- ZANTER, K. Landsat 8 (L8) data users handbook. **Landsat Science Official Website**, [S.l.], v.33, 2016.
- ZEKOLLARI, H.; HUSS, M.; FARINOTTI, D. Modelling the future evolution of glaciers in the European Alps under the EURO-CORDEX RCM ensemble. **The Cryosphere**, [S.l.], v.13, n.4, p.1125–1146, 2019.
- ZEKOLLARI, H.; HUSS, M.; FARINOTTI, D.; LHERMITTE, S. Ice-Dynamical Glacier Evolution Modeling—A Review. **Reviews of Geophysics**, [S.l.], v.60, n.2, p.e2021RG000754, 2022.
- ZENG, Q.; CAO, M.; FENG, X.; LIANG, F.; CHEN, X.; SHENG, W. A study of spectral reflection characteristics for snow, ice and water in the north of China. **Hydrological applications of remote sensing and remote data transmission**, [S.l.], v.145, p.451–462, 1984.
- ZHAN, Q.; MOLENAAR, M.; TEMPFLI, K.; SHI, W. Quality assessment for geo-spatial objects derived from remotely sensed data. **International Journal of Remote Sensing**, [S.l.], v.26, n.14, p.2953–2974, 2005.

6 APÊNDICES

6.1 Imagens no espectro visível




Figura 29: Imagens no espectro visível.

6.2 Classificações binárias obtidas via GEE obtidas entre o período de 2000 a 2024




Figura 30: Classificações binárias obtidas via GEE obtidas entre o período de 2000 a 2024.