

Universidade Federal do Rio Grande – FURG
Instituto de Oceanografia

Programa de Pós-Graduação em Oceanologia

**DISTRIBUIÇÃO DE ICEBERGS NO OCEANO
AUSTRAL ATRAVÉS DE INTELIGÊNCIA
ARTIFICIAL: UMA CONTRIBUIÇÃO PARA O
ENTENDIMENTO DA SUA INFLUÊNCIA NA
CIRCULAÇÃO E NO CLIMA**

MAURO MEDEIROS BARBAT

Orientador: *Prof. Dr. Mauricio Magalhães Mata*
Universidade Federal do Rio Grande (FURG), Brasil

Coorientador: *Prof. Dr. Adriano Velasque Werhli*
Universidade Federal do Rio Grande (FURG), Brasil

Rio Grande, RS, Brasil

Março 2020

Universidade Federal do Rio Grande – FURG

Instituto de Oceanografia

Programa de Pós-Graduação em Oceanologia

**DISTRIBUIÇÃO DE ICEBERGS NO OCEANO
AUSTRAL ATRAVÉS DE INTELIGÊNCIA
ARTIFICIAL: UMA CONTRIBUIÇÃO PARA O
ENTENDIMENTO DA SUA INFLUÊNCIA NA
CIRCULAÇÃO E NO CLIMA**

MAURO MEDEIROS BARBAT

Tese apresentada ao Programa de Pós-
Graduação em Oceanologia, como
parte dos requisitos para a obtenção do
Título de Doutor.

Orientador: *Prof. Dr. Mauricio Magalhães Mata*
Universidade Federal do Rio Grande (FURG), Brasil.

Coorientador: *Prof. Dr. Adriano Velasque Werhli*
Universidade Federal do Rio Grande (FURG), Brasil

Rio Grande, RS, Brasil

Março 2020

DISTRIBUIÇÃO DE ICEBERGS NO OCEANO AUSTRAL ATRAVÉS DE INTELIGÊNCIA ARTIFICIAL: UMA CONTRIBUIÇÃO PARA O ENTENDIMENTO DA SUA INFLUÊNCIA NA CIRCULAÇÃO E NO CLIMA

Tese apresentada ao Programa de Pós-Graduação em Oceanologia, como parte dos requisitos para a obtenção do Título de Doutor

MAURO MEDEIROS BARBAT

Rio Grande, RS, Brasil

Março 2020

© A cópia parcial e a citação de trechos desta tese são permitidas sobre a condição de que qualquer pessoa que a consulte reconheça os direitos autorais do autor. Nenhuma informação derivada direta ou indiretamente desta obra deve ser publicada sem o consentimento prévio e por escrito do autor.

BARBAT, MAURO MEDEIROS

Distribuição de icebergs no oceano austral através de inteligência artificial:
uma contribuição para o entendimento da sua influência na circulação e no
clima/ Mauro M. Barbat – Rio Grande: FURG, 2020.

Número de páginas 230.

Tese (Doutorado) – Universidade Federal do Rio Grande. Doutorado em
Oceanografia Física, Química e Geológica.

1. Icebergs. 2. Inteligência artificial. 3. Diluição. 4. Detecção.
5. monitoramento.

[ATA DE DEFESA]



UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
IO – INSTITUTO DE OCEANOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM OCEANOLOGIA
E-mail: ccpolgg@furg.br – home-page: www.ppolgg.furg.br



ATA ESPECIAL DE DEFESA DE TESE DE DOUTORADO – 03/2020

Às nove horas do dia cinco de março do ano de dois mil e vinte , no Auditório SEAD - FURG/Carreiros, reuniu-se a Comissão Examinadora da Tese de **DOUTORADO** intitulada "**DISTRIBUIÇÃO DE ICEBERGS NO OCEANO AUSTRAL ATRAVÉS DE INTELIGÊNCIA ARTIFICIAL: UMA CONTRIBUIÇÃO PARA O ENTENDIMENTO DA SUA INFLUÊNCIA NA CIRCULAÇÃO E NO CLIMA**", do Acad. Mauro Medeiros Barbat. A Comissão Examinadora foi composta pelos seguintes membros: Prof. Dr. Mauricio Magalhães Mata - Orientador/Presidente – (IO/FURG), Prof. Dr. Adriano Velasque Werhli - (Co-orientador - C3/FURG), Prof. Dr. Rodrigo Kerr – (IO/FURG), Prof. Dr. Glauber A. Gonçalves – (C3/FURG) e Prof. Dr. Luciano P. Pezzi (INPE) . Dando início à reunião, o Orientador e Presidente da sessão, Prof. Dr. Mauricio M. Mata, agradeceu a presença de todos e fez a apresentação da Comissão Examinadora. Logo após esclareceu que o Candidato teria um tempo de 45 a 60 min para explanação do tema, e cada membro da Comissão Examinadora, um tempo máximo de 30 min para perguntas. A seguir, passou à palavra ao Candidato que apresentou o tema e respondeu às perguntas formuladas. Após ampla explanação, a Comissão Examinadora reuniu-se em reservado para discussão do conceito a ser atribuído ao Candidato. Foi estabelecido que as sugestões de todos os membros da Comissão Examinadora, que seguem em pareceres em anexo, foram aceitas pelo Orientador/Candidato para incorporação na versão final da Tese. Finalmente, a Comissão Examinadora considerou o candidato APROVADO, por unanimidade. Nada mais havendo a tratar, foi lavrada a presente ATA que após lida e aprovada, será assinada pela Comissão Examinadora, pelo Candidato e pelo Coordenador do Programa de Pós-Graduação em Oceanologia.

Prof. Dr. Mauricio Magalhães Mata

Presidente

Adriano V. Werhli

Prof. Dr. Adriano Velasque Werhli

Prof. Dr. Glauber A. Gonçalves

Prof. Dr. Rodrigo Kerr

Prof. Dr. Luciano P. Pezzi

Acad. Mauro Medeiros Barbat

Prof. Dr. Rodrigo Kerr
Coordenador do PPGO

“Grandes realizações não são feitas por impulso, mas por uma soma de pequenas realizações.”

Vincent Van Gogh (1853-1890)

À minha mãe e meu avô que, embora com todas as dificuldades, não mediram esforços para que eu tivesse o que mais importa: amor, saúde e força.

Índice

Agradecimentos	xi
Lista de Figuras	xiii
Lista de Tabelas	xviii
Lista de Acrônimos e Abreviações	xix
Abstract	1
Resumo.....	2
Prefácio.....	3
Capítulo I: Introdução.....	5
1.1. Das geleiras e plataformas de gelo para o oceano, os icebergs	5
1.2. Interações entre icebergs e o ambiente adjacente	8
1.3. icebergs, circulação oceânica e o clima	11
1.4. Icebergs, o passado e suas marcas: Eventos Heinrich	15
1.5. Icebergs, um desafio para o sensoriamento remoto e a ciência	16
1.6. Estrutura da tese.....	18
Capítulo II: Hipótese	19
Capítulo III: Objetivos	20
3.1. Objetivo geral.....	20
3.2. Objetivos específicos	20
Capítulo IV: Dados e Métodos	21
4.1. Radar de Abertura Sintética (SAR).....	21
4.1.1. Dataset 1 – ESA Envisat ASAR	24
4.1.2. Dataset 2 – Canadian Radarsat SAR.....	25

4.2. Área de estudo	27
4.2.1. Manto de gelo Antártico e o Oceano Austral: Características gerais	27
4.2.2. Mar de Weddell: Características gerais	31
4.2.3. Mar de Ross: Características gerais	33
4.3. Framework inteligente para detecção, monitoramento e análise de icebergs a partir de imagens SAR	35
4.3.1. Pré-processamento	37
4.3.2. Segmentação	43
4.3.3. Classificação	52
4.3.4. Pós classificação, metadados e estatísticas	72
4.3.5. Rastreamento de icebergs a partir de imagens SAR	74
Capítulo V: Resultados científicos.....	79
5.1. Artigo1: <i>An adaptive machine learning approach to improve automatic iceberg detection from SAR images</i>	79
5.1.1. Síntese do artigo 1	80
5.1.2. Abstract	81
5.1.3. Introduction.....	82
5.1.4. Data.....	86
5.1.5. Method	87
5.1.6. Performance analysis.....	97
5.1.7. Results and performance evaluation.....	99
5.1.8. Discussion.....	109
5.1.9. Conclusion.....	111
5.1.10. Appendix A: Features description	113
5.1.11. Acknowledgments	115
5.2. Artigo 2: <i>Three years of near-coastal Antarctic iceberg distribution from a machine learning approach applied to SAR imagery.....</i>	116
5.2.1. Síntese do artigo 2	116
5.2.2. Key Points:	118
5.2.3. Abstract	119
5.2.4. Plain Language Summary	120
5.2.5. Introduction.....	120
5.2.6. Data and Methods	124
5.2.7. Results	129
5.2.8. Discussion and Conclusions	142

5.2.9. Appendix A: Improving Generalization of the Detection Method.....	147
5.2.10. Appendix B: Detection Method Performance	148
5.2.11. Acknowledgments	151
5.3. Artigo 3: <i>Automated iceberg tracking with a machine learning approach applied to SAR imagery: A Weddell Sea case study</i>.....	152
5.3.1. Síntese do artigo 3	152
5.3.2. Key points.....	153
5.3.3. Abstract	154
5.3.4. Introduction.....	155
5.3.5. Data and Methods	158
5.3.6. Weddell Sea features	165
5.3.7. Results	166
5.3.8. Discussion and conclusion.....	177
5.3.9. Acknowledgments	182
Capítulo VI: Síntese da Discussão e Conclusões	183
6.1. Sugestões para trabalhos futuros	188
Capítulo VII: Referências.....	190
Apêndice I: Produtos e trabalhos derivados	210
A. 1. Artigos científicos	210
A. 2. Programa de Computador Registrado	211
A. 3. Orientações e trabalhos derivados	211

Agradecimentos

Com a conclusão deste trabalho mais um ciclo se concretiza, um ciclo repleto de buscas, expectativas e desafios, mas acima de tudo, alegrias. Alegrias estas impressas nos sentimentos de superação, de tarefa cumprida e de crescimento profissional e pessoal, conquistados dia após dia, desafio após desafio.

Ao longo desta trajetória pude conhecer e estar ao lado de diversas pessoas, que dentro da sua individualidade ímpar, marcaram-me de diferentes modos e estiveram presentes de uma forma ou de outra no caminho que convergiu para este momento. Desta forma, não poderia deixar de expressar meus agradecimentos a estas pessoas e tantas outras que embora possam não estar mencionadas neste texto, estarão para sempre fixadas no meu sentimento de gratidão.

A minha mãe e meu avô, Ana Paula e Clodomiro que sempre me mostraram que as únicas barreiras capazes de nos parar são aquelas impostas por nós mesmos.

Ao meu orientador, Prof. Dr. Mauricio M. Mata, pela confiança depositada a mim neste desafio multidisciplinar, acreditando no meu potencial científico/acadêmico/técnico sempre me motivando e apoiando nos momentos de adversidade.

Ao meu coorientador, Prof. Dr. Adriano Werlhi, que me acompanha desde o mestrado, apoiando e acreditando no meu potencial.

Ao meu orientador e colaboradores no exterior, Dr. Hartmut Hellmer, Dr. Thomas Rackow e Dr^a Christine Weche, os quais me receberam de braços abertos na Alemanha contribuindo em grande parte para o amadurecimento não apenas deste trabalho, mas pessoal.

Ao professor, Dr. José Luiz Azevedo pelo apoio, confiança, aulas espetaculares e diversas conversas descontraídas ao longo dessa trajetória.

Ao amigo, Dr. Marcelo Pinho, que me acompanhou desde a graduação, sempre acreditando e apoiando, ajudando em muito a amenizar os momentos mais pesados com uma boa conversa e um cafezinho.

Ao Laboratório de estudos dos Oceanos e Clima (LEOC), Grupo de Oceanografia de Altas Latitudes (GOAL), INCT-Criosfera e Instituto Alfred Wegener para Pesquisa Polar e Marinha (AWI), que proporcionaram os recursos técnicos e operacionais que possibilitaram o desenvolvimento deste trabalho.

Aos colegas e amigos do CEOCEAN e LEOC que me acompanharam ao longo do percurso, colaborando e apoiando no decorrer dos anos. Tornando esse período inesquecível e enriquecedor de inúmeras formas.

Ao secretário do Programa de Pós-Graduação, Clabisnei, pela prestatividade em diferentes momentos.

Aos membros da banca de avaliação, Prof. Dr. Glauber A. Gonçalves, Prof. Dr. Rodrigo Kerr, Prof. Dr. Luciano P. Pezzi, pela disposição em ler, corrigir, avaliar e somar conhecimento a esta tese.

E finalmente, ao CNPQ (140910/2016-6) e CAPES (88881.177236/2018-01), pelas bolsas de estudos fornecidas que possibilitaram a dedicação exclusiva ao desenvolvimento desta tese de doutorado assim como, o privilégio de desenvolver parte deste trabalho no exterior.

Lista de Figuras

- Figura 1.** Exemplo de iceberg tabular fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019, próximo a Península Antártica.....6
- Figura 2.** Exemplo de iceberg dry-dock fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019, estreito de Bransfield.....9
- Figura 3.** Exemplo de iceberg em deriva livre com pluma de água doce evidente sobre a superfície oceânica. Iceberg fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019.11
- Figura 4.** Circulação oceânica global como descrita por Broecker (1991). Correntes oceânicas quentes e salinas próximas a superfície (vermelho) dirigidas majoritariamente pelo atrito com o vento, seguem o padrão global da circulação atmosférica. Correntes frias e profundas (azul), de comportamento vertical e horizontal são movidas majoritariamente devido ao gradiente de densidade entre distintas massas de água. Massas de água frias e densas formadas em regiões polares capazes de afundar impulsionando demais massas de água. Adaptado de grida.no/resources/5228.....12
- Figura 5.** Esquemático da integração zonal e vertical da Atlantic Meridional Overturning Circulation – AMOC, evidenciando células profundas Antarctic Bottom Water (AABW) e North Atlantic Deep Water (NADW). Mapa evidenciando corte zonal (verde) é inserido no canto inferior direito. Adaptado de Wang et al., (2014).....14
- Figura 6.** Exemplificação de emissão (A) e retroespalhamento (B) do sinal emitido por sistemas SAR. A intensidade, amplitude do sinal refletido de volta a

antena será resultante das propriedades físicas e químicas do alvo, como características elétricas, geométricas ou de composição geral. Figura adaptada de Envisat/ESA handbook, (2007).....22

Figura 7. Variabilidade de padrões retroespalhamento conforme o tipo de superfície. Adaptada de Envisat/ESA handbook, (2007).....23

Figura 8. Exemplificação de sobreposição de diferentes passagens do satélite sobre a mesma área. Quadros “A, B e C” representam diferentes áreas de amostragem decorrentes de distintas passagens do satélite. Polígonos ilustram icebergs capturados nas cenas, sobreposições configuram recorrências do mesmo objeto em distintas cenas.25

Figura 9. Mapa do continente antártico, destacando principais setores e plataformas de gelo flutuantes (azul). Cordilheiras Transantárticas separando porções leste e oeste do continente são representadas em linha tracejada vermelha.28

Figura 10. Continente Antártico e esquema dos principais elementos da circulação do oceano Austral. (i) Plataformas de gelo flutuante são ilustradas em azul; (ii) ACC (setas em vermelho) limitada pela Frente Subantártica (SAF) e pelo limite sul (SB) da Upper Circumpolar Deep Water (UCDW); (iii) Giros de Weddell, Ross e “sem nome” e (iv) principais pontos de saída da Deep Western Boundary Current (DWBC). Adaptado de Carter et al., (2008).....29

Figura 11. Setor do Mar de Weddell e estruturas básicas. Esquema do Giro de Weddell é apresentado em tracejado. Principais plataformas de gelo flutuantes presentes no setor são destacadas e rotuladas. A batimetria é mostrada em escala de cor (Fonte: Etopo).32

Figura 12. Setor do Mar de Ross e estruturas básicas. Esquema do Giro de Ross é apresentado em tracejado. Principais plataformas de gelo flutuantes presentes no setor são destacadas e rotuladas. A batimetria é mostrada em escala de cor (Fonte: Etopo).34

Figura 13. Exemplo de uma cena SAR (Radarsat-1) com grande variabilidade espectral, textural e morfológica. [Retângulos A, B, C] dão exemplos de

aglomerados de pequenos icebergs cercados por ice-melange (mistura de iceberg, neve e gelo marinho) e gelo marinho, apresentando contraste de baixa intensidade e falta de definição de bordas entre objetos. Retângulos [D, E] dão exemplos da heterogeneidade de intensidade, textura, tamanho e formas apresentados por icebergs, e [F] exemplo de deriva de gelo marinho livre com assinatura de radar semelhante a icebergs escuros.....36

Figura 14. Visão geral do framework de classificação desenvolvido. Painel (A) mostra o fluxograma geral desenvolvido. Retângulos vermelhos destacam as etapas de segmentação por superpixel, comitê de máquinas e de aprendizagem incremental. Painel (B) expõe a arquitetura de aprendizado de máquina proposta.....37

Figura 15. Estágio de pré-processamento. Painel superior (A) pré-processamento básico para imagens brutas e painel inferior (B) pré-processamento avançado mandatório de forma a suavizar e padronizar as imagens de entrada.....39

Figura 16. Comparação entre cena SAR com (A) área continental visível e (B) cena após remoção da região de terra visível através de aplicação de máscara de terra.....41

Figura 17. Exemplo de imagem com presença de ruído do tipo Speckle. Área ampliada em conjunto com a distribuição dos níveis de cinza é disponilizada. 42

Figura 18. Aplicação do filtro Lee Sigma para redução de ruído do tipo Speckle. O ganho resultante desta etapa proporciona uma primitiva suave para computar parâmetros de textura com mínima perda nas transições de bordas. Em adição, respectivos histogramas são apresentados.43

Figura 19. Fluxograma completo do estágio de segmentação. Incluindo (i) reamostragem de cena (Image sectoring), (ii) limiarização de histograma (Histogram Thresholding), (iii) realce de contraste (Contrast Enhancement) e por fim, (iv) segmentação por Superpixel.44

Figura 20. Demonstração da aplicação do limiar de histograma (A) cena com forte assinatura de gelo marinho, águas abertas e presença de icebergs com

assinaturas radiométricas variadas e (C) cena com baixo contraste. (B) e (D) representação binária obtida com filtro percentil (99, 1).....	46
Figura 21. Demonstração de realce de contraste com filtro local de contraste linear “min-max” aplicado em uma cena de baixo contraste com a presença de icebergs escuros. (A) Cena original com redução de ruído “Speckle”, (B) cena com realce de contraste. Painéis inferiores apresentam respectivos histogramas.	49
Figura 22. Exemplo de segmentação aplicando o método Felzenszwalb and Huttenlocher [2004]. Painel A mostra imagem SAR em estado bruto sem etapas de ajuste. Painel B demonstra resultado de segmentação aplicado após etapas de pré-processamento e pré-segmentação. Linhas vermelhas demarcam o perímetro individual de cada segmento.....	51
Figura 23. Exemplos de icebergs com assinaturas de radar amplamente distintas. (A) Iceberg saturado (Bright iceberg), (B) iceberg de média intensidade e (C) iceberg “escuro” (Dark iceberg).....	53
Figura 24. Exemplos de segmentos utilizados para extração de descritores. Pixels externos a superfície do objeto é completamente removida.....	54
Figura 25. Exemplificação de descritores de histograma, comparação entre (A) iceberg e (B) não-iceberg. Respectivos painéis laterais apresentam distribuições de níveis de cinza para ambos objetos, assim como principais medidas estatísticas computadas.	56
Figura 26. Demonstração de cena SAR com a presença de icebergs com diferentes padrões de textura.	57
Figura 27. Demonstração da aplicação do filtro Gabor para extração de descritores de textura no domínio da frequência. Painéis (B) e (D) correspondem a resposta no domínio da frequência referente a (A) iceberg e (B) gelo marinho, respectivamente.....	58
Figura 28. Arquitetura padrão de sistemas baseados em comitê de máquinas. “X” representa dados de entrada e “Y” dados de saída.	63

Figura 29. Exemplo de espaço de hipóteses com presença de hipóteses ambíguas (adaptados de Zhou, 2012). Painel (A) mostra aplicação de modelo preditivo linear, apresentando erros de classificação de ambos os alvos. Painel (B) mostra aplicação de método ensemble Random Forest (RF). Diferentemente das abordagens lineares, o RF é definido através de uma fusão de modelos preditivos distintos calculados a partir de um conjunto de árvores de decisão heterogêneas com base em diferentes arranjos de descritores de imagem. Isso resulta em limites preditivos que são mais flexíveis, levando assim a uma melhor habilidade de generalização.....	64
Figura 30. Modelo meta-ensemble proposto, no qual um Comitê de RF (Random Forest Committee) é construído a partir da fusão de distintos classificadores RF heterogêneos, cada um especializado em um domínio de descritores: intensidade, textura ou morfo-espacial.....	66
Figura 31. Representação do processo de aprendizado proposto utilizando comitê de máquinas e aprendizado incremental.....	70
Figura 32. Fluxograma referente a abordagem de aprendizado incremental proposta.....	71
Figura 33. Ilustração dos descritores utilizados para rastreamento. (A) eixo principal, (B) eixo secundário, (C) representa a distância entre o centro do iceberg e seu limite externo (parâmetro computado em 360º sentido anti-horário).	75

Lista de Tabelas

Tabela 1. Classificação de icebergs conforme tamanho. Definido de acordo com a extensão em metros do maior eixo horizontal.	7
Tabela 2. Classes de icebergs por forma. Figuras adaptadas de © 2008 Encyclopedia Britanica, Inc (britanica.com/Science/iceberg/erosion-and-melting)	
.....	7
Tabela 3. Doze descritores mais representativos ranqueados pelo ganho de informação. Computado por Correlation-based Feature Selection (CFS). 0 significa sem relevância e 1.0 relevância máxima.....	62

Lista de Acrônimos e Abreviações

A

AABW - Antarctic Bottom Water
AAIW - Antarctic Intermediate Water
ACoC - Antarctic Coastal Current
ALBW - Adélie Land Bottom Water
AMOC - Atlantic Meridional Overturning Circulation
ASAR - Advanced Synthetic Aperture Radar
AZ - Antarctic Zone
ACC - Antarctic Circumpolar Current
AI - Artificial Intelligence

B

B&A - Mares de Bellingshausen e Amundsen BW
--

C

CDW – Circumpolar Deep Water

D

DWBC – Deep Western Boundary Current

M

ML – Machine Learning
MOC - Meridional Overturning Circulation

R

RF – Random Forest
RFC – Random Forest Committee
RFIS – Ronne-Filchner Ice Shelves
RIS – Ross Ice Shelf
RSBW – Ross Sea Bottom Water

S

SAF - Subantarctic Front
SAR - Synthetic Aperture Radar
SB - Southern Boundary

U

UCDW - Upper Circumpolar Deep Water
--

W

WSBW – Weddell Sea Bottom Water
--

Abstract

Icebergs are complex and important features of the polar environment. Bodies of continental ice they are able to interact with their surroundings in numerous ways. This includes interactions with the seabed and continental margins, transport of nutrients and terrigenous material, as well as interactions by impacting the thermohaline structure through cooling and freshwater input from melting icebergs. Being of similar magnitude to ice shelf basal melting, icebergs play an important and not yet fully understood role in the heat and freshwater balance of the Antarctic environment, this knowledge gap does not close due to the operational and technological complexity associated with a reliable monitoring of icebergs in the polar environment. In this sense, this thesis presents (i) a new autonomous method for large-scale monitoring and analysis of icebergs from Synthetic Aperture Radar (SAR) based on artificial intelligence; next steps are the scientific application of the developed method in order to (ii) investigate and document the pan-Antarctic near-coastal iceberg distribution and its variability between years and to relate it with the main Antarctic calving fronts and bottom water formation sites; the final goal is (iii) to present an extension of the detection method that allows to automatically track icebergs over time and to observe their potential freshwater input via satellites. As results, the method proved to be highly adaptable and capable of distinguishing icebergs with a high average accuracy of $97.5 \pm 0.6\%$. As a first scientific application, it was possible to document and investigate the spatial evolution of the size distribution (and mass) of pan-Antarctic icebergs on the continental shelf and in the near-coastal region for the years of 1997, 2000 and 2008. Finally, this thesis presents and discusses the tracking capabilities of the method proposed for a case study of the Weddell Sea, Antarctica. The extended method allows not only to monitor drifting icebergs but also their potential freshwater input over time automatically. Altogether, this work sheds light on the applicability of novel artificial intelligence methods to the complex iceberg classification problem. It bridges the gap between observational and numerical modeling efforts, which could be an essential step for future studies of the spatio-temporally changing freshwater input from Antarctic icebergs and thus climate change.

Resumo

Icebergs são complexos e importantes elementos do ambiente polar. Corpos de gelo de origem continental, estes são aptos a interagir com o ambiente no seu entorno de distintas formas incluindo interações com o leito oceânico e margens continentais, transporte de nutrientes e em decorrência da adição de água fria e doce proveniente do derretimento, impactar a estrutura termohalina local. Embora de similar magnitude com o derretimento basal das plataformas de gelo flutuantes, os icebergs desempenham um papel ainda não inteiramente compreendido no balanço de calor e água doce no ambiente Antártico. Em parte, devido à complexidade operacional e tecnológica para monitoramento em grande escala no ambiente polar. Neste sentido, esta tese apresenta (i) um novo método autônomo para monitoramento e análise de icebergs em grande escala a partir de imagens de Radar de Abertura Sintética (SAR) baseada em inteligência artificial; na sequência a aplicação científica do método para (ii) investigar e documentar integralmente a distribuição de icebergs na região costeira do continente Antártico, assim como, a variabilidade interanual, relacionando com as principais regiões de ruptura de icebergs e formação de água densa de fundo; por fim, (iii) apresenta e discute a extensão método para o rastreamento automático de icebergs ao longo do tempo assim como, sua aplicabilidade para monitorar potencial injeção de água doce através de imagens SAR. Como resultados, o método provou-se altamente adaptável sendo capaz de distinguir icebergs dos demais elementos presentes nas cenas polares com acurácia média de $97,5 \pm 0,6\%$. Como primeira aplicação científica, documenta e investiga a evolução espacial da distribuição de tamanho (e massa) de icebergs integralmente sobre a plataforma continental e região costeira Antártica para os anos de 1997, 2000 e 2008. Por fim, apresenta e discute a capacidade e aplicabilidade do método para rastreamento de icebergs em um estudo de caso no mar de Weddell, Antártica. Ao todo, esta tese destaca a aplicabilidade de métodos de inteligência artificial para o complexo problema de classificação de icebergs. Desta forma, preenchendo uma lacuna entre esforços observacionais e de modelagem numérica, que pode ser um passo essencial para futuros estudos acerca da variabilidade espaço-temporal do aporte de água doce a partir do derretimento de icebergs e seu possível impacto nas mudanças climáticas.

Prefácio

Embora amplamente presentes no imaginário coletivo como colossais montanhas de gelo flutuantes capazes de derivar pelos oceanos polares oferecendo riscos aos desavisados, a realidade é que pouco se sabe sobre estas estruturas ricas e amplas em termos de variabilidade morfológica e interações ambientais. Únicos na sua individualidade, icebergs são o resultado complexo de interações recíprocas com o ambiente, desde o surgimento (*calving*) até a desintegração total no oceano.

Da complexidade, o desafio. Icebergs e suas interações com o ambiente, não apenas no seu entorno, mas com o sistema global como um todo, caracterizam um conjunto de desafios multidisciplinares, neste caso, unindo a ciência polar, oceanografia, ciência da computação e minha própria jornada.

No decorrer da jornada que culminou nesta tese, muito se passou e um sentimento de desafio sempre me acompanhou, sentimento que desde o início da minha trajetória acadêmica (em engenharia de computação) levou-me a conhecer e apaixonar pela oceanografia e seus desafios. E, por consequência, me levou a construir um percurso engrandecedor e individual. Motivado por desafios e soluções, o engenheiro aos poucos tornou-se um cientista, observando e transitando plenamente através das ciências exatas e da Terra.

Fascinado pela ciência da computação e oceanografia, encontrei no oceano o elo e o estímulo que sempre busquei. E, como resultado, a motivação para este trabalho que em síntese aborda o papel dos icebergs na circulação oceânica e a complexidade envolvida para detecção, quantificação e monitoramento destes em grande escala no ambiente polar. E, por fim, observando o cenário de alterações ambientais globais, no futuro poder contribuir para o entendimento do papel destes no clima.

Capítulo I: Introdução

"Icebergs are a prime example of an environmental phenomenon that brings together multiple disciplines in the polar sciences, from the physics of calving and melting to the geology of their solid deposits and sea-floor interactions. Icebergs are also increasingly seen to play key roles in past and present climate change in causing the addition of freshwater to the ocean, in providing invaluable information through their debris, in fertilizing the polar oceans and in increasing hazards to Arctic travel and development."

Icebergs: Their Science and Links to Global Change [Bigg 2015]

1.1. Das geleiras e plataformas de gelo para o oceano, os icebergs

A partir do gelo glacial, formado através do acúmulo de neve compactada e recristalizada ao longo dos séculos, surgem os glaciares (ou geleiras) e, quando estes encontram o oceano, as plataformas de gelo flutuantes [Diemand 2001]. Através de interações físicas (e.g. elevação da temperatura oceano/atmosfera)

e mecânicas (e.g. tensão dos ventos, marés e ação de ondas) com a atmosfera e o oceano adjacentes surgem fendas nas plataformas de gelo e glaciares que ocasionam rupturas (*calving*) e, consequentemente, o surgimento de estruturas de gelo independentes, os icebergs (**Figura 1**).



Figura 1. Exemplo de iceberg tabular fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019, próximo a Península Antártica.

Amplos em tamanho (**Tabela 1**) e forma (**Tabela 2**), abrigando aproximadamente 90% da sua massa abaixo do nível do mar, após a ruptura, estes fragmentos livres de gelo continental com comprimentos de poucos metros a quilômetros [Wesche & Dierking 2015, Williams et al. 1999] estão aptos a derivar através dos oceanos polares para longe da sua região de origem, influenciados pela ação das correntes oceânicas, gelo marinho e batimetria local [Jacka & Giles 2007, Tournadre et al. 2016, Rackow et al. 2017]. Ao longo da sua trajetória de deriva, os icebergs estão sujeitos a eventuais fraturas (liberando icebergs de proporções menores) e gradual derretimento associados com a temperatura da água, ação das ondas, correntes oceânicas e regimes de vento [Bigg et al. 1997, Schodlok et al.

2006], representando um importante componente da interação entre as plataformas de gelo e o oceano adjacente. Desta forma, únicos tanto em sua natureza vasta e imponente quanto em suas implicações locais e globais, os icebergs desempenham papel singular no sistema terrestre com o potencial para impactar a circulação oceânica e o clima.

Tabela 1. Classificação de icebergs conforme tamanho. Definido de acordo com a extensão em metros do maior eixo horizontal.

Classe de Tamanho	Eixo Vertical (m)	Eixo horizontal (m)
<i>Growler</i>	< 1	0 – 5
<i>Bergy Bit</i>	1 – 4	6 – 15
<i>Small Berg</i>	5 – 15	16 – 60
<i>Medium Berg</i>	16 – 45	61 – 122
<i>Large Berg</i>	46 – 75	123 – 213
<i>Very Large Berg</i>	> 75	213 – 1850
<i>Giant Berg</i>	~250	> 1850

Tabela 2. Classes de icebergs por forma. Figuras adaptadas de © 2008 Encyclopedia Britanica, Inc (britanica.com/Science/iceberg/erosion-and-melting)

Classe	Descrição usual
<i>Tabular</i>	 Iceberg plano, comprimento/ altura < 5:1
<i>Dome</i>	 Iceberg com topo arredondado
<i>Pinnacle</i>	 Iceberg com um ou mais Pináculos
<i>Wedge</i>	 Iceberg com superfície inclinada
<i>Dry-Dock</i>	 Iceberg corroído em forma de doca ou canal
<i>Blocky</i>	 Iceberg de topo plano e laterais íngremes

1.2. Interações entre icebergs e o ambiente adjacente

Operacionalmente ao longo dos séculos, icebergs derivando livremente nos oceanos polares têm sido relatados como sérios riscos à navegação e atividades *offshore* [Bigg et al. 1997, 2018]. No entanto, a relevância destas estruturas amplamente variáveis em formas e tamanhos transcende os riscos operacionais.

A partir da ruptura, icebergs são capazes de impactar a costa e gerar *tsunamis* em decorrência da onda de choque resultante do impacto com a superfície oceânica [Gaull et al. 1992], assim como colidir com o leito oceânico marcando o substrato e promovendo trocas abruptas de sedimentos [Bigg 2015]. Próximo da costa, icebergs com eixo vertical suficientemente profundo são passíveis de permanecerem encalhados ou aprisionados por longos períodos de tempo, sendo capazes de afetar seu entorno em toda coluna de água assim como no substrato oceânico, como uma fonte persistente de água doce [Gwiazda et al. 1996, Freiwald et al. 1999, Gladstone et al. 2001, Schodlok et al. 2006].

Icebergs estacionários (encalhados ou aprisionados por gelo marinho), também podem atuar como obstáculos físicos e, quando grandes o suficiente, são capazes de impactar a estrutura oceanográfica local sendo passíveis de alterar o fluxo padrão de correntes oceânicas superficiais e influenciar a formação e o desenvolvimento de gelo marinho, contribuindo para a elevação do ponto de fusão e redução da densidade local da água do mar [Silva et al. 2006, Luckman et al. 2010, Marino et al. 2016].

Quando livres, são capazes de transportar e liberar sedimentos e nutrientes terrígenos, fertilizando regiões distantes da área costeira, sendo considerados verdadeiros *hotspots* para atividade biológica estimulando a produtividade primária

em regiões como por exemplo, Fe-limitadas [Schwarz & Schodlok 2009, Raiswell 2011, Shaw et al. 2011, Wu & Hou 2017], além de servirem como estações de descanso para aves e mamíferos marinhos [Smith 2011]. Um exemplo de iceberg do tipo *Dry-dock* em deriva livre é apresentado na **Figura 2**.



Figura 2. Exemplo de iceberg *dry-dock* fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019, estreito de Bransfield.

Embora as interações entre icebergs e seu entorno sejam vastas, a principal interação entre os icebergs e o oceano dá-se através da adição (ou injeção) de água doce proveniente do derretimento e a consequente diluição (“freshening”) das massas de água adjacentes. Os efeitos relacionados a esta adição diferem do derretimento basal das plataformas de gelo (de impacto local, uma vez que as plataformas de gelo são estruturas fixadas a linha de costa), do gelo marinho (formado e desintegrado sobre o oceano) e da precipitação (chuva e neve “*Meteoric Water*”, de impacto local e de menor magnitude quando comparado ao derretimento basal e diluição de icebergs) [Silva et al. 2006, Schodlok et al. 2006, Schwarz & Schodlok 2009, Lin et al. 2011, Tournadre et al. 2012, Depoorter et al. 2013, Merino et al. 2016], seja pela variabilidade isotópica ou pelo padrão de aporte e

redistribuição, uma vez que icebergs são fenômenos mais dinâmicos, capazes de injetar expressiva massa de água doce (e.g. Giga toneladas) longe da sua região de origem e em ritmo variável durante a deriva.

Diferentes processos termodinâmicos e mecânicos conduzem o derretimento e a desintegração, podendo ocorrer por toda extensão do iceberg, alterando sua forma e tamanho. Transferência turbulenta de calor na base do iceberg, erosão de ondas nas laterais, absorção de radiação solar e ação de ventos na superfície são exemplos de forçantes associadas a este processo [Bigg et al. 1997]. Entretanto, a maior parte do derretimento acontece na interface iceberg-superfície, produzindo uma pluma de água fria e doce (de baixa densidade) capaz de propagar-se horizontalmente sobre a superfície do oceano [Huppert & Turner 1978] e verticalmente até aproximadamente metade do eixo vertical submerso (quilha) do iceberg [Stephenson et al. 2011].

Individualmente, a pluma de baixa densidade produzida no entorno do iceberg tende a minimizar a estratificação local e estabilizar a coluna d'água, geralmente adicionando uma capa na camada de mistura, aumentando a flutuabilidade e dificultando a convecção e a mistura vertical de águas mais densas [Bigg 2015]. Este processo é capaz de influenciar o gradiente termohalino e, por consequência, os padrões locais de convecção vertical [Silva et al. 2006]. Exemplo de iceberg cercado pela pluma de água doce proveniente do derretimento é exibido na **Figura 3**.



Figura 3. Exemplo de iceberg em deriva livre com pluma de água doce evidente sobre a superfície oceânica. Iceberg fotografado pelo Grupo de Oceanografia de Altas Latitudes (GOAL) da Universidade Federal do Rio Grande (FURG) durante expedição científica OPERANTAR XXXVII no ano de 2019.

Em grande escala, a descarga de icebergs e a adição total de água doce sobre a superfície oceânica tende a alterar o campo superficial de densidade e, por consequência, o gradiente de pressão. Desta forma, sendo capaz de impactar os padrões usuais de correntes oceânicas [Grosfeld et al. 2001, Schodlok et al. 2006, Stern et al. 2016], a formação de massas de água e, por consequência influenciar o clima [Jacobs & Hellmer 1992, Silva et al. 2006, Diemand 2001, Gladstone et al. 2001, Bigg 2015, Merino et al. 2016, Rackow et al. 2017].

1.3. Icebergs, circulação oceânica e o clima

A estabilidade do clima global é uma função complexa de múltiplas variáveis. Dentre estas, a circulação oceânica ocupa papel de destaque, sendo responsável em grande parte pela regulação do clima. A circulação oceânica, atua como principal agente no armazenamento e transporte de calor no entorno do globo, desta forma, redistribuindo calor do equador aos polos [Rintoul 1998, Marshall & Speer 2012].

A circulação oceânica movimenta águas mais quentes próximas a superfície regidas majoritariamente pelo atrito com o vento e águas mais frias e densas próximas ao fundo impulsionadas principalmente devido ao gradiente de densidade. Esse mecanismo é conhecido como célula de revolvimento meridional (*Meridional Overturning Circulation - MOC*) [Broecker 1991, Ohshima et al. 2013] (**Figura 4**) a qual é responsável pela conexão entre todas as bacias oceânicas do planeta em escalas temporais maiores que séculos. Embora a estrutura da MOC não seja tão direta e simples como descrito anteriormente, alterações no fluxo padrão da circulação oceânica e redistribuição de calor potencialmente implicam em grandes alterações para o clima [Broecker 1991]. Existem distintos processos capazes de influenciar a dinâmica da circulação oceânica, uma das teorias mais aceitas se dá através das interações entre fluxos de água doce e a intensidade da célula de revolvimento meridional.

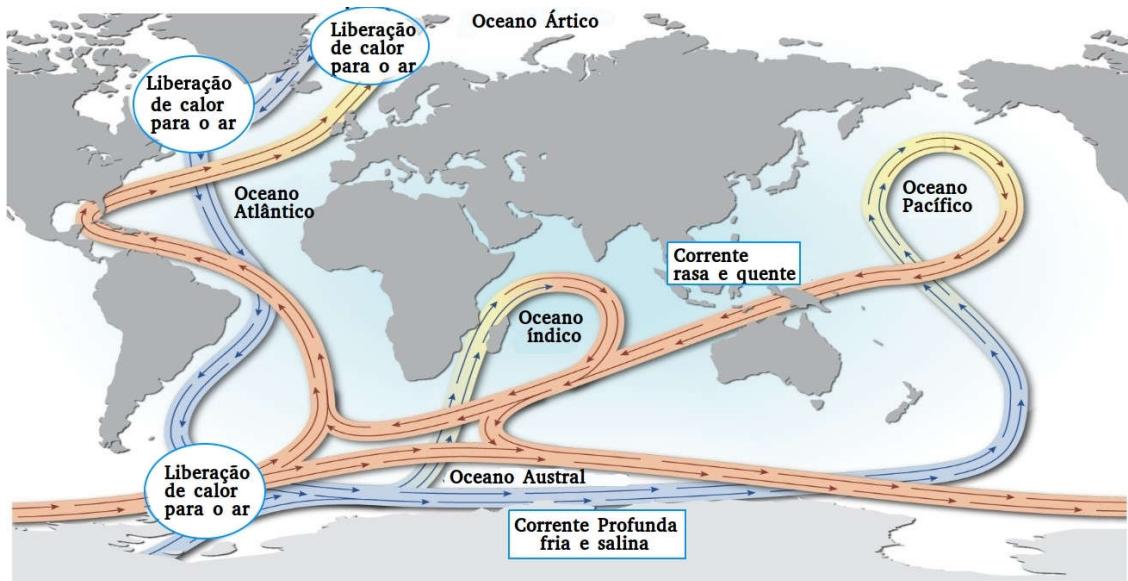


Figura 4. Circulação oceânica global como descrita por Broecker (1991). Correntes oceânicas quentes e salinas próximas a superfície (vermelho) dirigidas majoritariamente pelo atrito com o vento, seguem o padrão global da circulação atmosférica. Correntes frias e profundas (azul), de comportamento vertical e horizontal são movidas majoritariamente devido ao gradiente de densidade entre distintas massas de água. Massas de água frias e densas formadas em regiões polares capazes de afundar impulsionando demais massas de água. Adaptado de grida.no/resources/5228.

Anualmente, milhares de icebergs são liberados do entorno do continente Antártico para o oceano Austral [Bügelmayer et al. 2015, Wesche & Dierking 2015, Merino et al. 2016, Tournadre et al. 2016, Bouhier et al. 2018, Barbat et al. 2019b], contribuindoativamente para o fluxo de água doce inserido no oceano, com magnitude superior ao excesso de precipitação sobre evaporação (P-E) na região costeira [Jenkins 1991] e equivalente ao montante proveniente do derretimento basal das plataformas flutuantes [Depoorter et al. 2013, Merino et al. 2016]. Desta forma, estes icebergs são capazes de influenciarativamente o fluxo superficial médio de água doce e de impactar a estrutura termohalina usual e, por consequência, os padrões superficiais de densidade e gradiente pressão, tornando difícil a mistura vertical e enfraquecendo a convecção profunda de massas de água densas.

No contexto de mudanças climáticas, os potenciais impactos e implicações do aporte e, consequente derretimento de icebergs, dependerão fortemente da localização e da quantidade total de massa diluída [Schodlok et al. 2006, Romanov et al. 2008]. Em particular, devido sua influência nas principais regiões de formação da fria e densa Água de Fundo Antártica (*Antarctic Bottom Water* - AABW), componente essencial na célula de revolvimento meridional [Gordon 2001, Purkey & Johnson 2013].

Formada durante o inverno na quebra da plataforma continental, a fria e densa AABW é derivada de restritas regiões no entorno do continente Antártico cujas condições atmosféricas e oceanográficas permitem que massas de água superficiais atinjam densidade suficientemente alta para afundar e atingir o fundo oceânico [e.g. Gordon 2001], espalhando-se e impulsionando a camada profunda da MOC até aproximadamente 45°N [Ferreira & Kerr 2017]. As águas densas de fundo, adquirem suas propriedades em função de trocas de calor com a atmosfera e devido a injeção

de sal proveniente da formação/desintegração de gelo marinho. A desintegração do gelo marinho expõe a superfície do oceano, formando polynias que favorecem as trocas de calor e oxigênio entre o oceano e a atmosfera. A **Figura 5**, ilustra corte zonal e vertical da componente Atlântica da MOC (*Atlantic Meridional Overturning Circulation - AMOC*), destacando massas de água profundas.

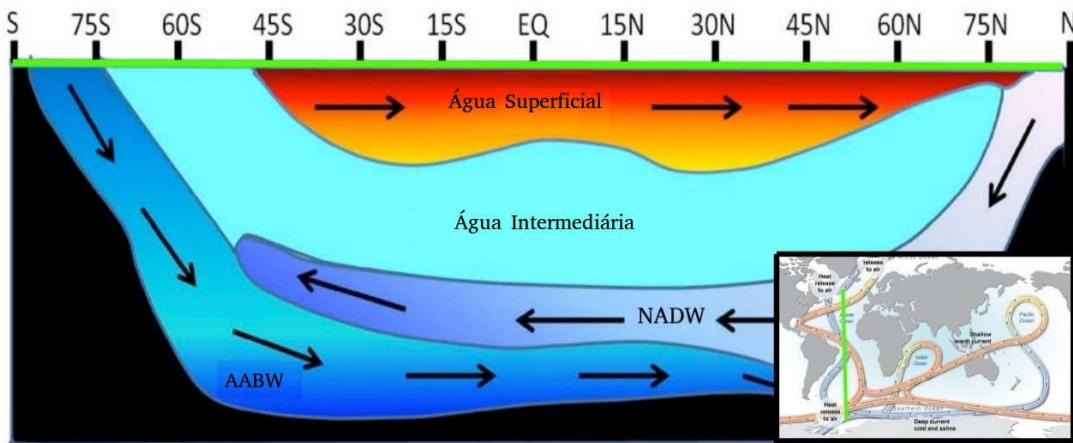


Figura 5. Esquemático da integração zonal e vertical da *Atlantic Meridional Overturning Circulation – AMOC*, evidenciando células profundas Antarctic Bottom Water (AABW) e North Atlantic Deep Water (NADW). Mapa evidenciando corte zonal (verde) é inserido no canto inferior direito. Adaptado de Wang et al., (2014).

Por consequência, alterações no campo de densidade superficial representam potencial enfraquecimento na formação das águas densas de fundo, impactando diretamente a força da MOC, com amplas implicações para o clima global. Embora as implicações referentes as relações entre o derretimento de icebergs e o enfraquecimento/interrupção da MOC não sejam diretamente observados nas condições atuais, liberações massivas de icebergs e mudanças climáticas abruptas desde o último máximo glacial deixaram pistas sobre a relação acima mencionada em momentos conhecidos como eventos Heinrich [Heinrich 1988].

1.4. Icebergs, o passado e suas marcas: Eventos Heinrich

Embora as causas ainda permaneçam foco de discussão [Hemming 2004, Hulbe et al. 2004, Jongma et al. 2013], mudanças climáticas abruptas associadas com o massivo aporte de icebergs durante o último máximo glacial foram observadas em um número de ocasiões. Estas ocasiões são conhecidas como Eventos Heinrich [Heinrich 1988].

Impresso nos sedimentos do oceano Atlântico Norte, registros do massivo e rápido aumento de *Ice-Rafted Detritus* (IRD) associados ao aporte e derretimento de amplas armadas de icebergs foram observados em diferentes ocasiões. Pelo menos seis principais eventos (H1-H6) com intervalos de aproximadamente $6 - 9 \times 10^3$ anos foram identificados durante a última glaciação (entre 14×10^3 e 70×10^3 anos atrás) e um evento isolado (H0) durante o *Younger Dryas Stadial* ($\sim 13 \times 10^3$ anos atrás) [Broecker 1991, Hulbe et al. 2004].

Principalmente descarregados na região do mar do Labrador, as “armadas de icebergs”, termo cunhado por Heinrich [1988], derivaram e derreteram rumo leste por volta de $40^\circ - 55^\circ\text{N}$, onde camadas mais espessas de IRD foram encontradas [Hemming 2004]. A intensa diluição resultante do derretimento massivo de icebergs é suposta como peça fundamental no enfraquecimento da circulação oceânica durante o período glacial [Broecker 1991, Jongma et al. 2013]. Esta suposição é corroborada por distintos estudos baseados em modelagem numérica com módulos oceano-atmosfera acoplados, mostrando que a injeção massiva de água doce proveniente dos icebergs pode disparar uma série de eventos resultante no enfraquecimento nas taxas de convecção profunda de massas e consequente

desaceleração ou mesmo “desligamento” da célula de revolvimento meridional [Hewitt et al. 2006, Jongma et al. 2013].

1.5. Icebergs, um desafio para o sensoriamento remoto e a ciência

No hemisfério sul, em conjunto com o derretimento basal das plataformas de gelo flutuantes, a ruptura de icebergs constitui uma das causas dominantes na perda de massa do continente Antártico [Depoorter et al. 2013, Merino et al. 2016, Tournadre et al. 2016, Bouhier et al. 2018]. Entretanto, embora de similar magnitude, o impacto resultante do aporte de água doce proveniente dos icebergs sobre a circulação oceânica e formação de água de fundo, assim como, seu papel no clima ainda é “insuficientemente” quantificado [Silva et al. 2006, Mazur et al. 2017].

Em parte, essa deficiência pode ser atribuída à complexidade para detecção e monitoramento em larga escala de icebergs no ambiente polar. Apesar dos esforços observacionais, de modelagem numérica e de sensoriamento remoto, os estudos sobre a dispersão e desintegração de icebergs ficam limitados, frequentemente, a cobertura de regiões geograficamente pequenas, áreas em mar aberto e/ou ao monitoramento restrito de icebergs gigantes.

Estudos embasados em esforços observacionais são frequentemente limitados espacial e/ou temporalmente, geralmente resultante do baixo número de observações e/ou restrições operacionais intrínsecas à navegação no ambiente polar [Jacka & Giles 2007, Romanov et al. 2012]. Representações obtidas a partir de módulos de icebergs acoplados a modelos numéricos ainda enfrentam dificuldades para representar a alta variabilidade de formas e tamanhos de icebergs, assim como sua dinâmica de desintegração [Jongma et al. 2013, Wagner et al. 2016, Rackow et

al. 2017]. O sensoriamento remoto, embora seja o método mais aplicado para detecção e monitoramento de icebergs [Gladstone & Bigg 2002, Silva & Bigg 2005, Silva et al. 2006, Tournadre et al. 2008, 2012, Wesche & Dierking 2012, 2015, Wesche et al. 2013, Merino et al. 2016, Bouhier et al. 2018, Collares et al. 2018, Barbat et al. 2019a,b, Tournadre & Tarasenko 2019], enfrenta problemas devido a densa atmosfera polar inviabilizando a utilização de sensores passivos (i.e. aqueles que não emitem energia própria) demandando a utilização de sensores ativos, como os radares aerotransportados ou instalados em plataformas orbitais.

Dados de satélite a partir de sensores ativos, como imagens de Radar de Abertura Sintética (*Synthetic Aperture Radar* - SAR), são derivados de um princípio ativo de emissão de micro-ondas e têm vantagens de minimizar a contaminação por nuvens densas que são recorrentes nos mares polares. A técnica de SAR é capaz de penetrar na densa atmosfera polar sob condições climáticas adversas, mesmo à noite [Wesche & Dierking 2012, Marino et al. 2016]. Além disso, os dados de SAR fornecem alta cobertura espacial e temporal na Antártica desde 1991 e se tornaram um conjunto de dados padrão para pesquisa de iceberg, geleiras e gelo marinho.

Neste sentido, este estudo aborda o desenvolvimento e aplicação de métodos mais robustos capazes de identificar, monitorar e inferir sobre a variabilidade de icebergs em grande escala no ambiente polar a partir de imagens SAR assim como, o estudo amplo dos resultados obtidos a partir desta. Com isso, tem-se o potencial para contribuir para a pesquisa oceanográfica e climática, contribuindo para o entendimento sobre os padrões de dispersão de água doce provenientes de icebergs e suas relações com a circulação oceânica e o clima.

1.6. Estrutura da tese

Em continuidade a este capítulo introdutório, nos capítulos 2 e 3 são apresentados a hipótese e objetivos desta tese de doutoramento. No capítulo 4 são apresentados os dados utilizados e o método inteligente desenvolvido para detecção, análise e rastreamento automático de icebergs, explorando todas as etapas do processo; o capítulo 5 apresenta os resultados científicos que compõem o corpo desta tese, ao todo três artigos científicos são apresentados explorando o método (i), a aplicação do método para detecção e análise em grande escala, discutindo a ampla variabilidade de icebergs e a potencial distribuição de massa de água doce em todo entorno Antártico (ii) e (iii) aplicação do método para rastreamento e análise da dispersão de água doce proveniente de icebergs em deriva livre. Por fim, capítulos 6 e 7 concluem este documento apresentando a síntese das discussões e conclusões e as referências bibliográficas.

Capítulo II: Hipótese

Considerando o cenário de alterações ambientais observadas no oceano Austral, assim como os desafios tecnológicos para detecção e monitoramento de icebergs no ambiente polar, a seguinte hipótese será testada:

“As distribuições de icebergs seguem padrões definidos, sendo importantes agentes nos sinais de diluição percebidos no entorno da Antártica e passíveis de serem observados em grande escala, através da união entre técnicas de inteligência artificial e sensoriamento remoto.”

Capítulo III: Objetivos

3.1. Objetivo geral

Investigar os padrões de distribuição, dispersão e desintegração de icebergs no oceano Austral a partir de imagens de sensoriamento remoto.

3.2. Objetivos específicos

- Desenvolver uma metodologia autônoma baseada em inteligência artificial para monitoramento e análise de icebergs em larga escala.
- Determinar os padrões de distribuição de icebergs comparando as principais semelhanças/diferenças entre as principais áreas fonte.
- Determinar os padrões de dispersão (deriva) e desintegração no mar de Weddell, assim como, a potencial injeção de água doce provenientes destes.

Capítulo IV: Dados e Métodos

4.1. Radar de Abertura Sintética (SAR)

Radares de Abertura Sintética (*Synthetic Aperture Radar - SAR*) são sistemas coerentes de imageamento por micro-ondas capazes de aumentar a resolução natural de sistemas de Radar (*Radio Detection and Ranging*) convencionais (abertura real). Este ganho se dá através do aumento sintético do tamanho da antena emissão, desta forma ampliando a resolução azimutal de imageamento mesmo que, fisicamente, uma antena menor seja usada para transmitir/receber o sinal de radar [Envisat/ESA handbook 2007].

Sistemas SAR a bordo de satélites orbitais oferecem um importante avanço para observação polar. Através do princípio ativo de emissão de radiação eletromagnética (na faixa das micro-ondas), sistemas SAR operam no intervalo entre

1 mm a 1m em comprimento de onda (λ). Devido sua independência em relação a necessidade de fonte solar, sua autossuficiência na emissão de radiação tornaram a utilização de sistemas SAR amplamente aplicados para pesquisas polares, principalmente, devido sua versatilidade e penetrabilidade sendo capaz de penetrar a densa atmosfera polar mesmo à noite. Além disso, são capazes de prover medidas quantitativas únicas acerca dos alvos, baseando-se em suas propriedades elétricas e geométricas [Toan 2007, Paradella et al. 2015].

O sensor opera através de visada lateral com feixe de iluminação irradiado de forma ortogonal à trajetória do satélite, sendo que parte do sinal emitido é refletido de volta à antena após ser retroespelhado (*Backscattered*) em contato com a superfície iluminada (**Figura 6**). A intensidade ou amplitude do sinal refletido pode ser influenciado primariamente pelas características elétricas, geométricas e/ou de composição geral do alvo como solo, vegetação, água ou gelo.

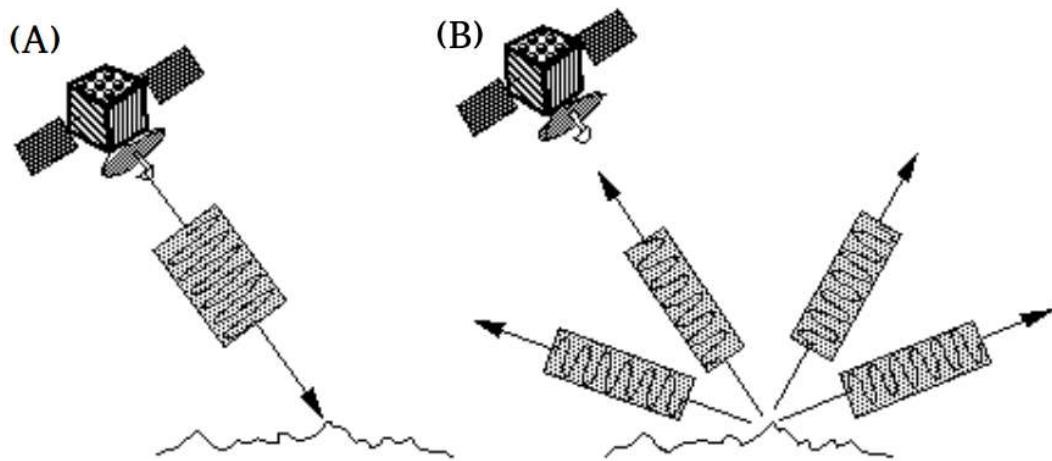


Figura 6. Exemplificação de emissão (A) e retroespalhamento (B) do sinal emitido por sistemas SAR. A intensidade, amplitude do sinal refletido de volta a antena será resultante das propriedades físicas e químicas do alvo, como características elétricas, geométricas ou de composição geral. Figura adaptada de Envisat/ESA handbook, (2007).

Por consequência, as imagens resultantes de radares de abertura sintética são o resultado das variações de energia retroespalhada pela superfície do alvo que retorna ao sensor, conforme ilustrado na **Figura 7**. Cada pixel contido na imagem resultante representa uma estimativa da força de retroespalhamento (σ_0), podendo variar de pixels com intensidade de cor (escala de cinza) elevada para alvos com alta refletividade e pixels opacos para alvos de alto índice absorção.

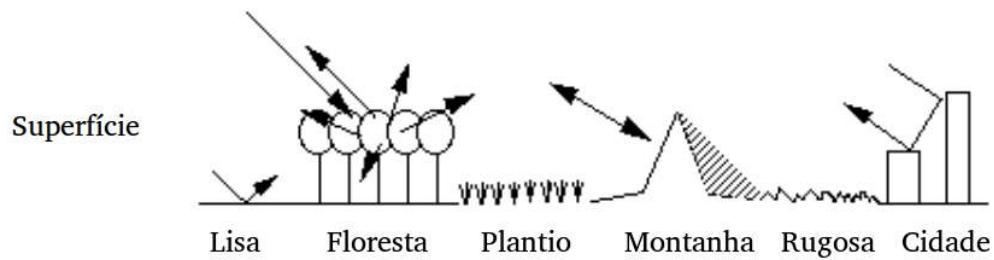


Figura 7. Variabilidade de padrões retroespalhamento conforme o tipo de superfície. Adaptada de Envisat/ESA handbook, (2007)

Em relação a icebergs e demais estruturas congeladas, a interpretação dos padrões de retroespalhamento adquirem complexidade adicional. Complexidade adquirida em função não apenas da variabilidade imposta pelas características do sensor como banda, polarização e geometria de aquisição, mas também pela variabilidade na composição geral de estruturas formadas por corpos de água, que quando somados a oscilações externas resultantes da dinâmica oceanográfica e meteorológica, confeccionam um cenário amplo e ambíguo de padrões de retroespalhamento. Particularidades sobre a variabilidade radiométrica apresentada por icebergs e demais estruturas congeladas serão exploradas nas seções subsequentes. Para este trabalho, dois conjuntos distintos de imagens SAR foram utilizados conforme descritos a seguir.

4.1.1.Dataset 1 – ESA Envisat ASAR

O sensor ASAR (*Advanced SAR*) é uma versão aprimorada dos sensores SAR convencionais que operavam a bordo dos satélites ESA ERS-1 e ERS-2. O sensor ASAR operou na banda C (5.3GHz) com comprimento de onda de ~5.6cm e polarização HH (transmissão e recepção horizontal) e esteve em operação entre 2002 e 2012 a bordo do satélite ESA Envisat da Agência Espacial Europeia. Os parâmetros orbitais possibilitaram o imageamento global com resolução temporal de 35 dias em cinco modos de aquisição com resoluções espaciais entre 25m e 1km [Envisat/ESA handbook 2007].

Para este trabalho, foram utilizadas imagens ASAR (ASA_WSM_1P) adquiridas no modo Wide Swath Mode (WSM) através da técnica de ScanSAR com faixa de aquisição (Swath) de 400 km de largura, obtidas através do alargamento de cinco sub-faixas de imageamento com o uso pares de antenas com da abertura sintética. Como resultado final, as imagens resultantes do modo WSM apresentam resolução espacial média com tamanho de pixel de 150 m. No entanto, devido a utilização da técnica de *multilooks*, os pixels são super-amostrados produzindo uma matriz final com resolução espacial apresentando tamanho de pixel de 75 × 75m, utilizada para este trabalho.

Para fins de rastreamento, a ampla faixa de cobertura (400 × 400km) resultante do WSM e a periodicidade do satélite em distintas órbitas de aquisição oferecem uma oportunidade única para ampliar a resolução temporal de 35 dias. Isto é possível em decorrência da sobreposição de diferentes passagens do satélite sobre a mesma área que, em conjunto com a dinâmica de deriva dos icebergs, permite observar objetos recorrentes em cenas distintas, desta forma aumentando a

resolução temporal original do dado. A **Figura 8** exemplifica a sobreposição de faixas de cobertura e a presença de recorrências de icebergs em distintas cenas.

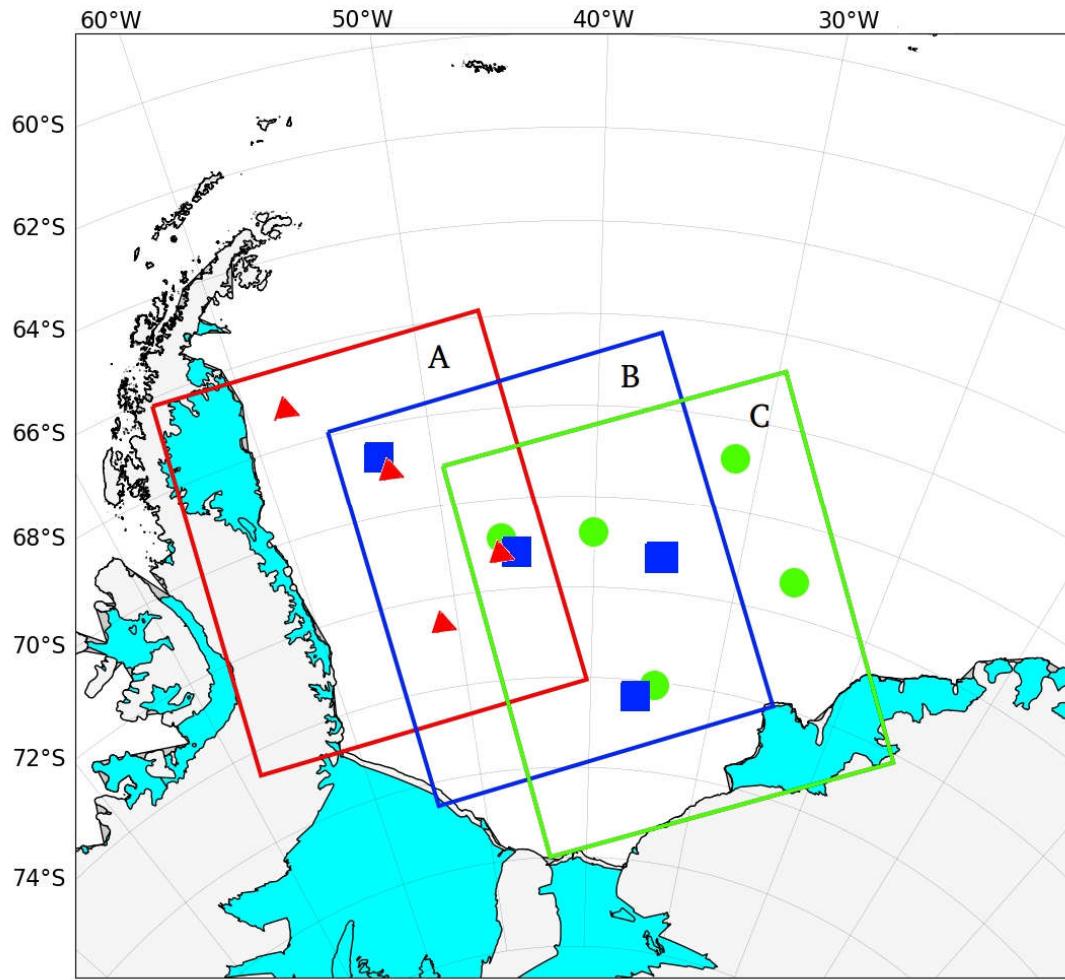


Figura 8. Exemplificação de sobreposição de diferentes passagens do satélite sobre a mesma área. Quadros “A, B e C” representam diferentes áreas de amostragem decorrentes de distintas passagens do satélite. Polígonos ilustram icebergs capturados nas cenas, sobreposições configuram recorrências do mesmo objeto em distintas cenas.

4.1.2. Dataset 2 – Canadian Radarsat SAR

O segundo conjunto de dados contempla três mosaicos de amplitude de retroespalhamento, cada um construído a partir de coleções de mais de 3000 imagens SAR individuais adquiridas pelos satélites canadenses RADARSAT-1 e

RADARSAT-2 na banda C (5.3GHz, com comprimento de onda de ~5.6cm), com resolução espacial nominal de 25 m e tamanho de pixel reamostrado para 100 m. Cada mosaico é construído a partir de coleções de quadros SAR adquiridos entre Setembro-Dezembro de 1997, 2000 e 2008 respectivamente, incluindo integralmente a zona costeira da Antártica [Canadian Space Agency 2010].

O primeiro mosaico, RAMP AMM-1 (*RADARSAT-1 Antarctic Mapping Project – Antarctic Mapping Mission-1*) 8 bits, é o resultado de uma iniciativa entre diferentes agências espaciais para mapear o continente antártico através de imageamento SAR de alta resolução, composto por mais de 3000 quadros individuais adquiridos abordo do satélite canadense RADARSAT-1 durante setembro e outubro de 1997 em órbita ascendente [Jezek et al. 2002].

O segundo mosaico, RAMP MAMM (*RADARSAT-1 Antarctic Mapping Project – Modified Antarctic Mapping Mission-1*) 8 bits, foi uma segunda missão RAMP SAR com o objetivo de observar possíveis mudanças na cobertura de gelo no continente Antártico em comparação com o mosaico de 1997, construído a partir de imagens adquiridas entre setembro e novembro de 2000 em órbitas ascendentes e descendente [Jezek et al. 2003].

Por fim, o terceiro mosaico de 8 bits resultante da missão *Radarsat-2 Antarctic Mapping Initiative* teve como objetivo produzir um mosaico continental atualizado, consistente com ambas missões RAMP de 1997 e 2000. Formado a partir de 3.150 quadros individuais adquiridos entre outubro e dezembro de 2008 com dupla polarização [MacDonald & Ltd. 2008].

4.2. Área de estudo

4.2.1. Manto de gelo Antártico e o oceano Austral: Características gerais

Representando o maior manto de gelo no planeta, o manto antártico situado sobre o continente Antártico (**Figura 9**) abrange uma extensão territorial de aproximadamente $14 \times 10^6 \text{ km}^2$ em área congelada, superior a oito vezes a área coberta pelo manto da Groelândia ($1.71 \times 10^6 \text{ km}^2$), caracterizando um equivalente aproximado a 70 m de elevação do nível do mar em termos de água doce [Bamber et al. 2013, Bigg 2015].

Em contraste com o manto de gelo da Groelândia, o manto Antártico se difere primariamente devido à geografia, sendo subdividido em duas porções (Ocidental e Oriental) pelas cordilheiras Transantárticas. Embora menor em extensão, a porção oeste apresenta maior variabilidade geográfica e geomorfológica quando comparada com a relativamente uniforme porção leste, com grande parte da linha de costa coberta por vastas plataformas de gelo flutuantes que se estendem sentido ao oceano. Dentre estas estão as expressivas plataformas de Ronne-Filchner e Ross cobrindo mais de $400 \times 10^3 \text{ km}^2$ cada, situadas nos mares de Weddell e Ross, respectivamente.

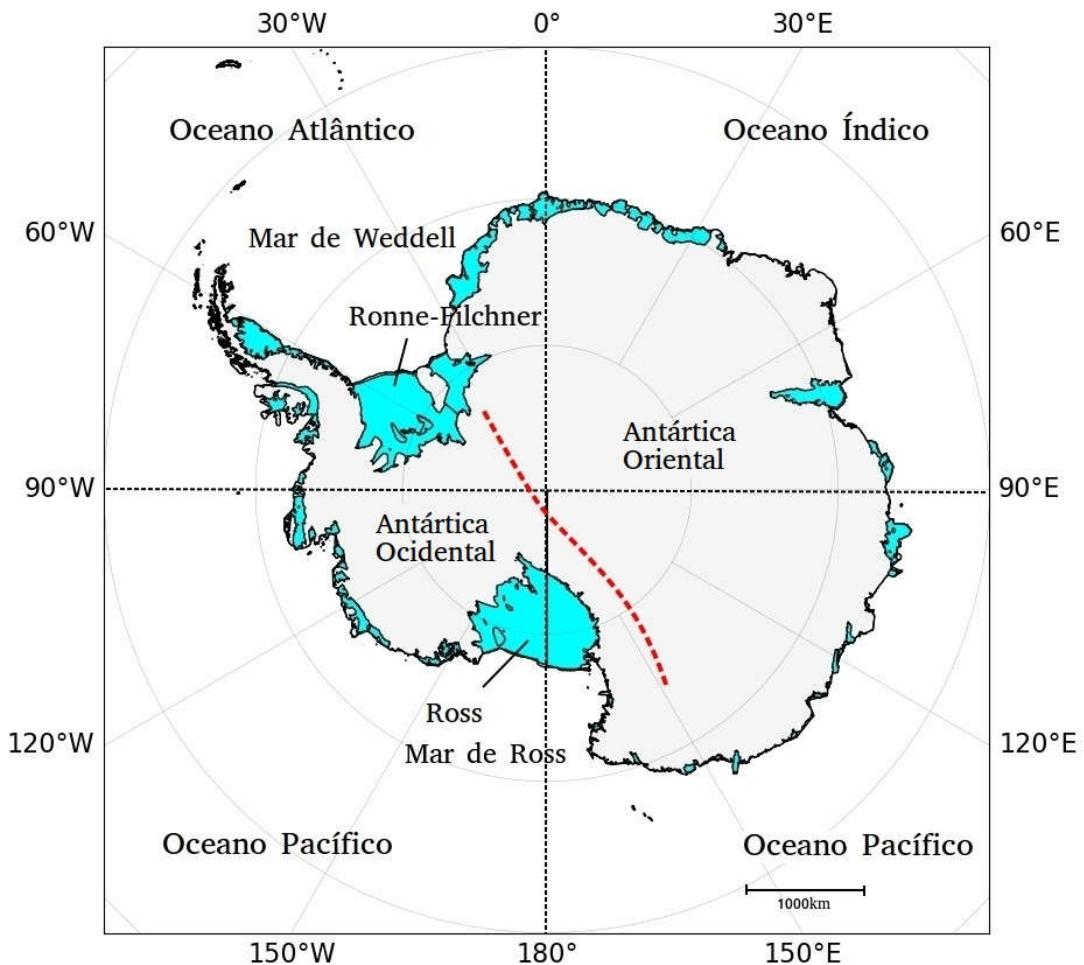


Figura 9. Mapa do continente antártico, destacando principais setores e plataformas de gelo flutuantes (azul). Cordilheiras Transantárticas separando porções leste e oeste do continente são representadas em linha tracejada vermelha.

No entorno do continente Antártico e ao sul da Frente Subtropical, o oceano Austral conecta distintas bacias oceânicas e liga os ramos rasos e profundos da célula de revolvimento meridional. Fortemente dominada pela Corrente Circumpolar Antártica (ACC), a circulação no oceano Austral flui de oeste para leste sendo capaz de percorrer o entorno do continente Antártico sem barreiras físicas conectando os oceanos Atlântico, Pacífico e Índico, assim desempenhando papel proeminente na distribuição global de calor, sal e gases [e.g. Carter et al. 2008]. Próximo à costa, o

sistema de correntes é mais complexo. Células ciclônicas de recirculação se desenvolvem ao sul da ACC, influenciadas pela ACC, batimetria e pela corrente costeira Antártica. Dentre estas, as mais conhecidas são os giros de Weddell e Ross, fluindo em sentido horário ao longo do talude continental [Orsi et al. 1995]. A **Figura 10** apresenta o esquema dos principais elementos da circulação do oceano Austral.

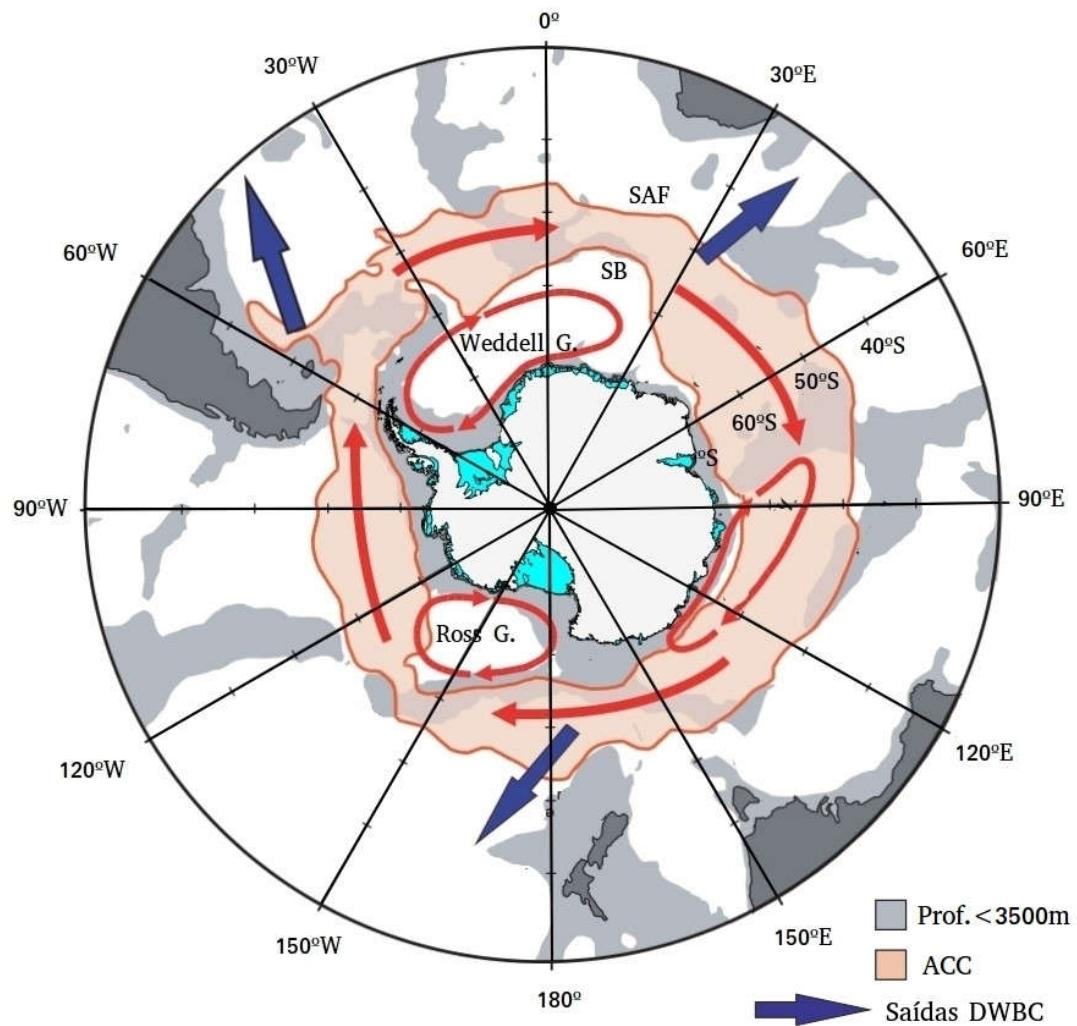


Figura 10. Continente Antártico e esquema dos principais elementos da circulação do oceano Austral. (i) Plataformas de gelo flutuante são ilustradas em azul; (ii) ACC (setas em vermelho) limitada pela Frente Subantártica (SAF) e pelo limite sul (SB) da *Upper Circumpolar Deep Water* (UCDW); (iii) Giros de Weddell, Ross e “sem nome” e (iv) principais pontos de saída da *Deep Western Boundary Current* (DWBC). Adaptado de Carter et al., (2008).

Tangencialmente à linha de costa, a Corrente Costeira Antártica (ACoC) determina o regime oceanográfico, onde massas de águas oceânicas interagem com as plataformas de gelo [Fahrbach et al. 1992, 1994]. Massas de água densas formadas nas margens do continente Antártico convergem até próximo ao leito oceânico onde se espalham e migram sentido norte, impulsionando massas de águas menos densas.

Dentre estas, a maior e mais representativa, a densa Água de Fundo Antártica (AABW) é formada em regiões específicas sobre a quebra da plataforma continental no entorno do continente Antártico. Estas regiões possuem características oceanográficas e atmosféricas que proporcionam condições específicas para que massas de água superficiais atinjam densidade suficiente para afundar até profundidades abissais, ocupando grande parte da camada de fundo da célula de revolvimento meridional [Jacobs et al. 1970, Orsi et al. 1999, Gordon 2001, Pardo et al. 2012, Shimada et al. 2012, Kerr et al. 2018].

A AABW é uma composição (mistura) entre distintas variantes regionais resultantes de um conjunto complexo de processos físico-químicos entre oceano, atmosfera e a criossfera, incluindo formação de gelo marinho, abertura de polynias costeiras e derretimento basal de plataformas de gelo flutuantes [e.g. Foster & Carmack 1976, Foster & Middleton 1980, Gordon 2001, Nicholls et al. 2009].

A produção da AABW é componente integral da célula de revolvimento meridional e tem importante papel no transporte e armazenamento de calor, gases e outras propriedades capazes de influenciar o clima, sendo referida como responsável por ventilar o oceano profundo [e.g. Broecker 1991, Rintoul 2011, Kerr et al. 2012].

4.2.2. Mar de Weddell: Características gerais

No oceano Austral, o mar de Weddell (**Figura 11**) compreendido entre a Península Antártica e aproximadamente o meridiano de Greenwich, ocupa papel de destaque entre os poucos locais onde as águas densas de fundo são capazes de serem formadas ao longo da margem continental Antártica [Foster & Carmack 1976, Beckmann et al. 1999, Gordon 2001]. Acredita-se que o mar de Weddell seja um dos principais contribuintes para a formação da AABW e agente majoritário no processo de ventilação das regiões abissais dos oceanos globais, através da formação da fria e rica em oxigênio, mas também relativamente fresca *Weddell Sea Bottom Water* (WSBW) [Orsi et al. 1999, Gladstone et al. 2001, Nicholls et al. 2009, Kerr et al. 2012, Ferreira & Kerr 2017].

Delimitado por características topográficas e hidrográficas marcantes, o mar de Weddell apresenta regime de circulação dominado por uma forte circulação ciclônica (sentido horário no hemisfério sul) conhecido como Giro de Weddell, resultante de um centro de baixa pressão atmosférica sobre o oceano [Deacon 1979]. O regime costeiro é determinado pela Corrente Costeira Antártica, onde as massas de água do oceano aberto interagem com as plataformas de gelo, sendo encontradas com temperaturas próximas ao ponto de congelamento da água [Fahrbach et al. 1992, Carter et al. 2008, Nicholls et al. 2009].

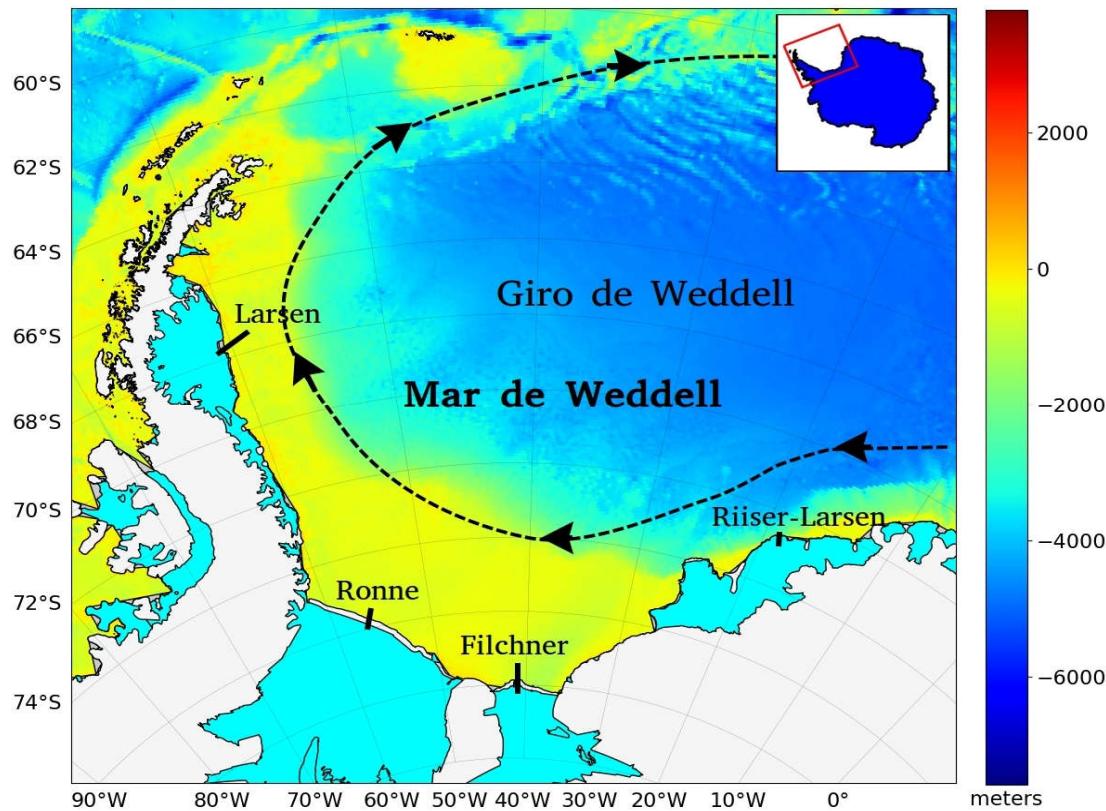


Figura 11. Setor do Mar de Weddell e estruturas básicas. Esquema do Giro de Weddell é apresentado em tracejado. Principais plataformas de gelo flutuantes presentes no setor são destacadas e rotuladas. A batimetria é mostrada em escala de cor (Fonte: Etopo).

Como características glaciais dominantes, o setor do Mar de Weddell abriga as massivas plataformas de gelo Ronne-Filchner e Larsen localizadas a sudoeste e oeste da região, respectivamente. De suas enormes plataformas de gelo, o Mar de Weddell é o caminho para a deriva de icebergs para longe da região origem, sentido noroeste/nordeste até serem capturados pela ACC. O transporte é influenciado pela ACoC, Giro de Weddell e pelo regime de gelo marinho no setor [Collares et al. 2018]. O gelo marinho em sí é dominado pelo ciclo sazonal com mínima extensão em fevereiro e máxima em setembro, com espessura média de 1m, podendo se estender até aproximadamente 60°S [Parkinson & Cavalieri 2012].

4.2.3. Mar de Ross: Características gerais

Delimitado entre os Cabos de Colbeck (158°W) e Adare (170°E), o mar de Ross (**Figura 12**) é caracterizado por um regime de circulação ciclônico marcado pela presença do Giro Ross, no sentido horário. No limite Sul, a plataforma de gelo de Ross é dominante entre as principais feições glaciais presentes na região, cobrindo uma extensão territorial de $520 \times 10^3 \text{ km}^2$ e espessura média de 370m , representando a maior plataforma de gelo flutuante do planeta [Smith et al. 2012].

No regime costeiro, a circulação superficial também é influenciada pela extensa plataforma de gelo de Ross que se estende sobre mais da metade da plataforma continental, enquanto águas densas e profundas circulam livremente sob esta plataforma de gelo. Parte do fluxo costeiro superficial incorpora a entrada de Água Antártica de Superfície (AASW) pelo cabo de Colbeck (De oeste para leste), que carrega não apenas água doce proveniente do derretimento continental, mas também gelo marinho e icebergs. Este padrão atua inserindo águas superficiais de baixa salinidade que, no inverno, favorecem o desenvolvimento da massiva polynia de Ross, conhecida como a mais ativa “fábrica de gelo marinho” no entorno da Antártida. Nesta área, em conjunto com o resfriamento atmosférico e o constante derretimento basal da plataforma de gelo de Ross, há importante produção de águas densas de fundo [Orsi et al. 1999, Smith et al. 2012].

O mar de Ross é responsável pela formação da componente mais salina da AABW [Orsi & Wiederwohl 2009]. Conhecida como *Ross Sea Bottom Water* (RSBW), esta componente tem sido historicamente dividida em duas variantes de acordo com a salinidade sendo à mais salina ($S > 34,7$) proveniente da região oeste do mar de Ross [Jacobs et al. 1970]. Embora ocupe papel de destaque junto a WSBW, estudos

recentes apontam um decaimento na produção de RSWB de aproximadamente $21 \pm 23\%$ entre 1970-2000s [Shimada et al. 2012], associado a alterações na salinidade média e temperatura potencial (θ) observadas nas águas densas de plataforma formadas nos setores de Ross e Adélie Land/George V (Oceano Pacífico Oeste) [Rintoul 1998, Orsi et al. 1999]. Ambas RSWB e *Adélie Land Bottom water* (ALBW) são produzidas quando as águas densas de plataforma, formadas pela perda de calor e adição de sal durante a formação de gelo marinho próxima as polynias costeiras, afundam sobre o talude continental e entram em contato com a relativamente quente *Circumpolar Deep Water* (CDW) [Gordon 2001, Shimada et al. 2012, Smith et al. 2012]. Desta forma, compõe e influenciando a mistura que resulta na formação integral que após a exportação recebe a denominação de AABW.

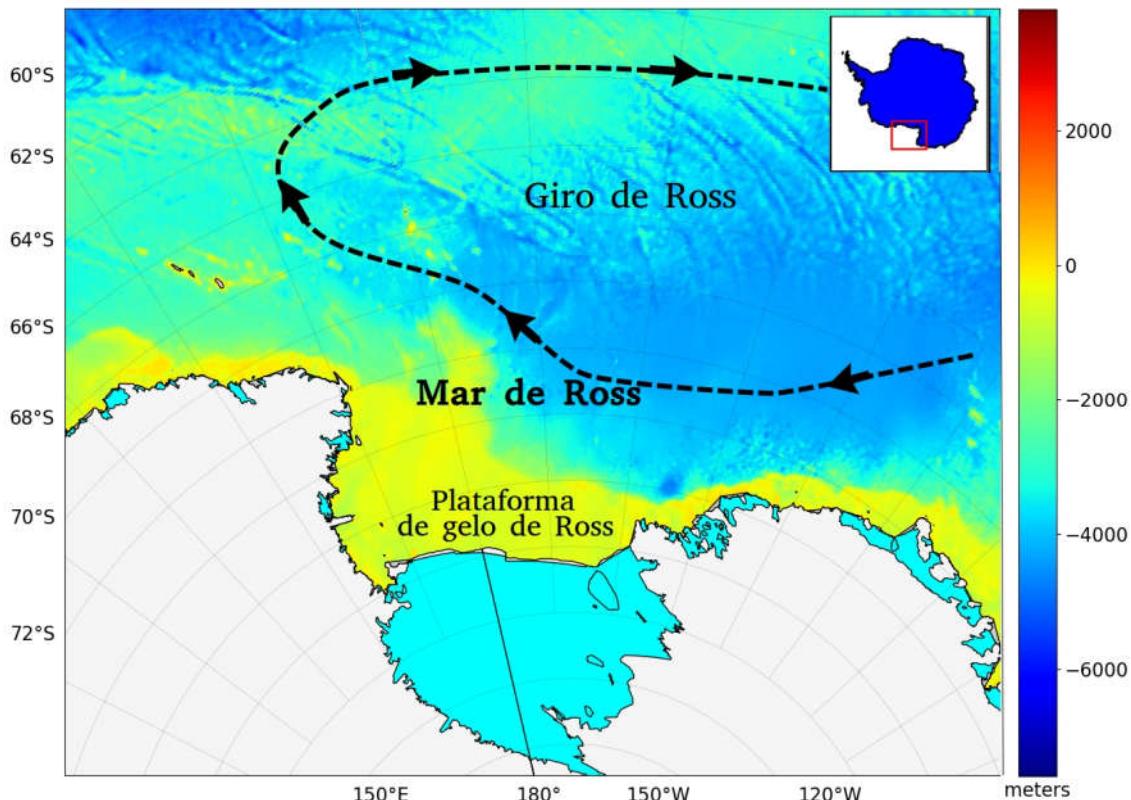


Figura 12. Setor do Mar de Ross e estruturas básicas. Esquema do Giro de Ross é apresentado em tracejado. Principais plataformas de gelo flutuantes presentes no setor são destacadas e rotuladas. A batimetria é mostrada em escala de cor (Fonte: Etopo).

4.3. Framework inteligente para detecção, monitoramento e análise de icebergs a partir de imagens SAR

A detecção automática de icebergs a partir de imagens de SAR é uma tarefa desafiadora. Devido a ampla variabilidade radiométrica, icebergs presentes em imagens SAR constituem objetos com assinatura digital amplamente ambígua inseridos em um cenário igualmente dúbio em decorrência de oscilações no sinal de aquisição resultantes da dinâmica atmosférica e oceanográfica comuns do ambiente polar. Como resultado, a ambiguidade entre os distintos elementos que compõem as cenas polares ocasiona um ambiente dúbio para classificação (e.g. **Figura 13**), o qual por consequência dificulta o estabelecimento de modelos preditivo precisos. Exige-se, portanto, extensa inspeção visual/manual, tarefa frequentemente inviável quando utilizado bancos de dados massivos, tornando visível a necessidade de abordagens adaptativas capazes de operar sob circunstâncias ambíguas.

O método introduzido nesta seção apresenta uma abordagem de inteligência artificial, o qual implementa uma arquitetura alternativa de aprendizado de máquina que emprega uma solução adaptativa para identificação automática de icebergs em larga escala a partir de imagens SAR. Desta forma, mostrando que a ambiguidade entre icebergs e demais objetos comuns em cenas polares pode ser amenizada através de um fluxo gradual de aprendizagem e da sobreposição de modelos preditivos heterogêneos capazes de inferir sobre os objetos sob distintas perspectivas, utilizando como núcleo (i) super-segmentação por superpixel, (ii) comitê de máquinas (*Ensemble Learning*) e (iii) aprendizagem incremental (*Incremental Learning*).

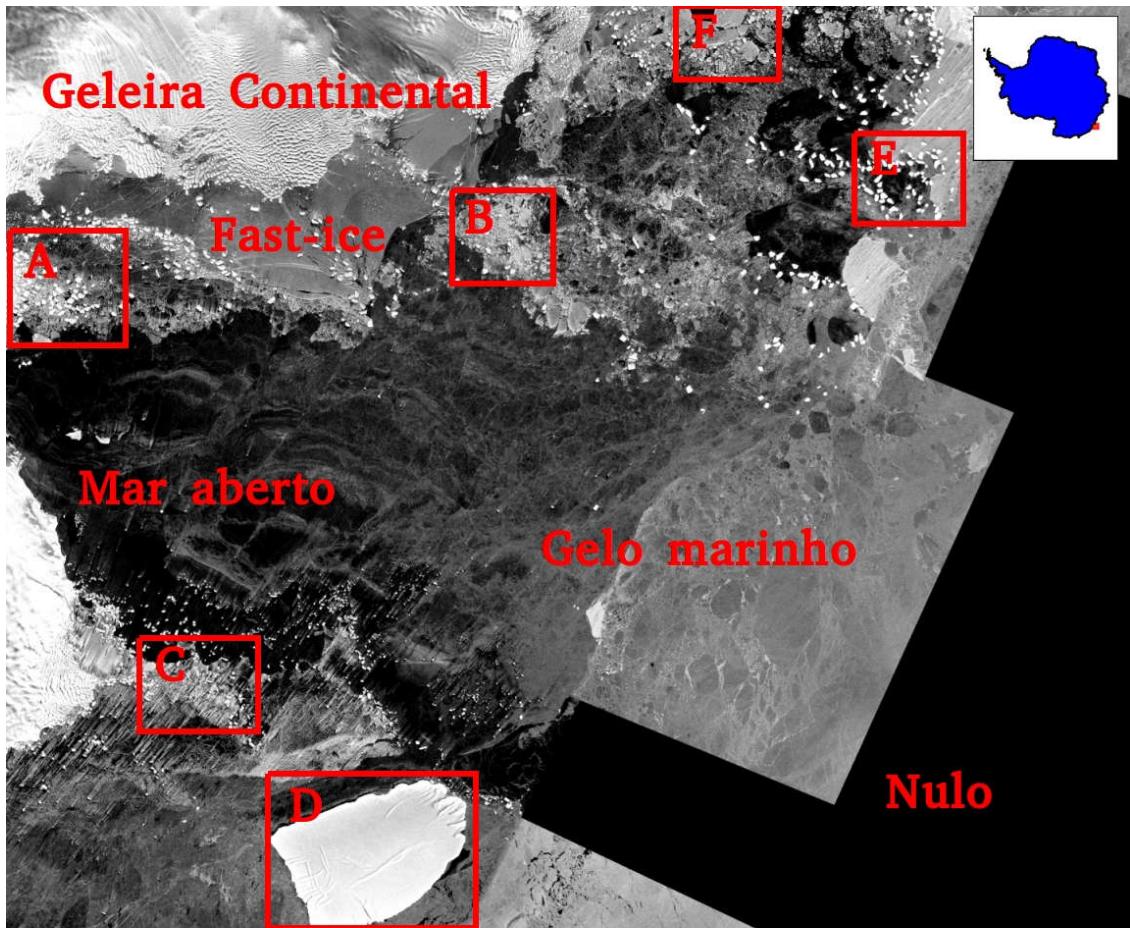


Figura 13. Exemplo de uma cena SAR (Radarsat-1) com grande variabilidade espectral, textural e morfológica. [Retângulos A, B, C] dão exemplos de aglomerados de pequenos icebergs cercados por ice-melange (mistura de iceberg, neve e gelo marinho) e gelo marinho, apresentando contraste de baixa intensidade e falta de definição de bordas entre objetos. Retângulos [D, E] dão exemplos da heterogeneidade de intensidade, textura, tamanho e formas apresentados por icebergs, e [F] exemplo de deriva de gelo marinho livre com assinatura de radar semelhante a icebergs escuros.

A metodologia desenvolvida é subdividida em 3 etapas principais: pré-processamento, segmentação, identificação/reconhecimento, projetadas para melhorar a precisão e o desempenho computacional para identificação e análise de icebergs a partir de imagens SAR sujeitas a diferentes fontes de variabilidade. A metodologia é resumida na **Figura 14** e descrita na sequência.

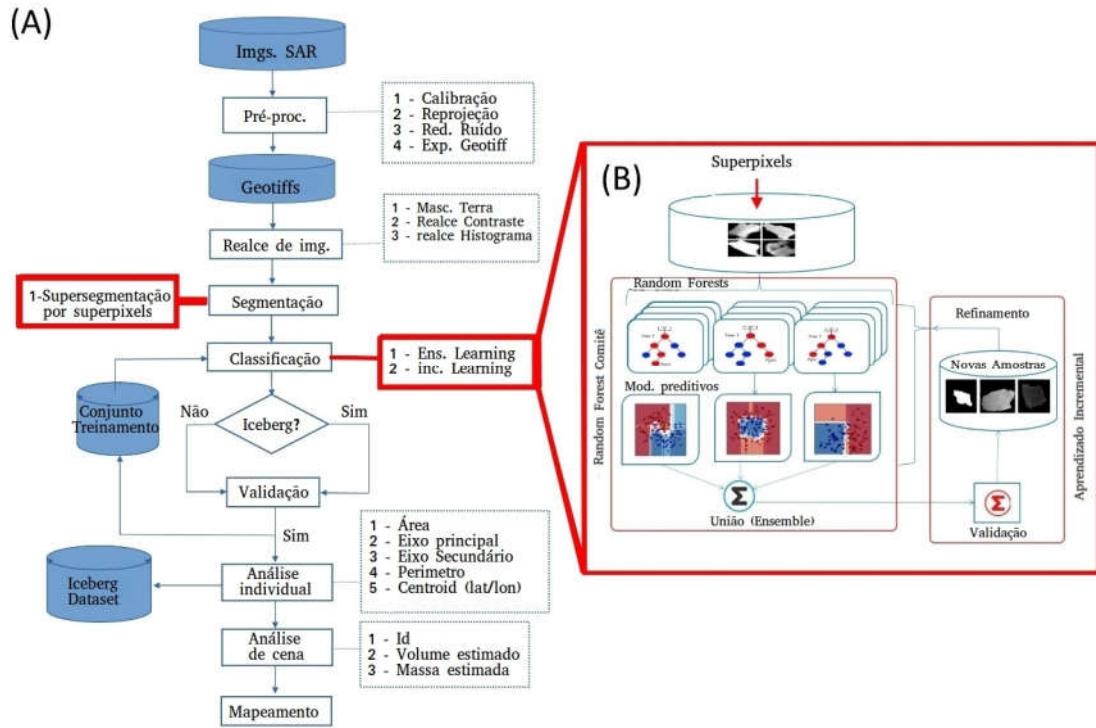


Figura 14. Visão geral do framework de classificação desenvolvido. Painel (A) mostra o fluxograma geral desenvolvido. Retângulos vermelhos destacam as etapas de segmentação por superpixel, comitê de máquinas e de aprendizagem incremental. Painel (B) expõe a arquitetura de aprendizado de máquina proposta.

4.3.1. Pré-processamento

Para este trabalho, foram utilizadas imagens SAR de diferentes sensores apresentando níveis iniciais de processamento diferenciados (e.g. calibração e reprojeção). De forma a padronizar o dado de entrada, o método de classificação demanda a utilização de imagens SAR em formato GeoTiff, devidamente pré-processadas atendendo dois estágios de iniciais de processamento (básico e avançado) conforme descrito a seguir e ilustrado na **Figura 15**.

1. Pré-processamento básico, aplicando:
 - a. Calibração radiométrica: De forma a estabelecer a relação direta entre intensidade de pixel (em escala de cinza) e força do coeficiente de retro espalhamento que retorna ao sensor [Rosich & Meadows 2004].
 - b. Reprojeção: De forma a estabelecer uma projeção cartográfica padronizada.
 - c. Exportação para o formato de imagem digital georreferenciada.

Esta etapa é aplicada para imagens em formato bruto através do software ESA-SNAP (*ESA-Sentinel Application Platform*), plataforma desenvolvida pela ESA para visualização e processamento de uma variedade de dados de sensoriamento remoto, disponível on-line em <https://step.esa.int/main/toolboxes/snap/>.

2. Pré-processamento avançado:
 - a. Redução do ruído tipo “*Speckle*”, característico em sinais provenientes de métodos ativos como radares e sonares [Kupidura 2016].
 - b. Remoção de pixels referentes a dados de terra (*Land Masking*).
 - c. Equalização e realce de contraste.
 - d. Redução do espaço de pesquisa.

Etapa de pré-processamento avançado é aplicada mandatoriamente e é inserido na base do *framework*.

A seguir os principais pontos acerca da etapa de pré-processamento são explorados.

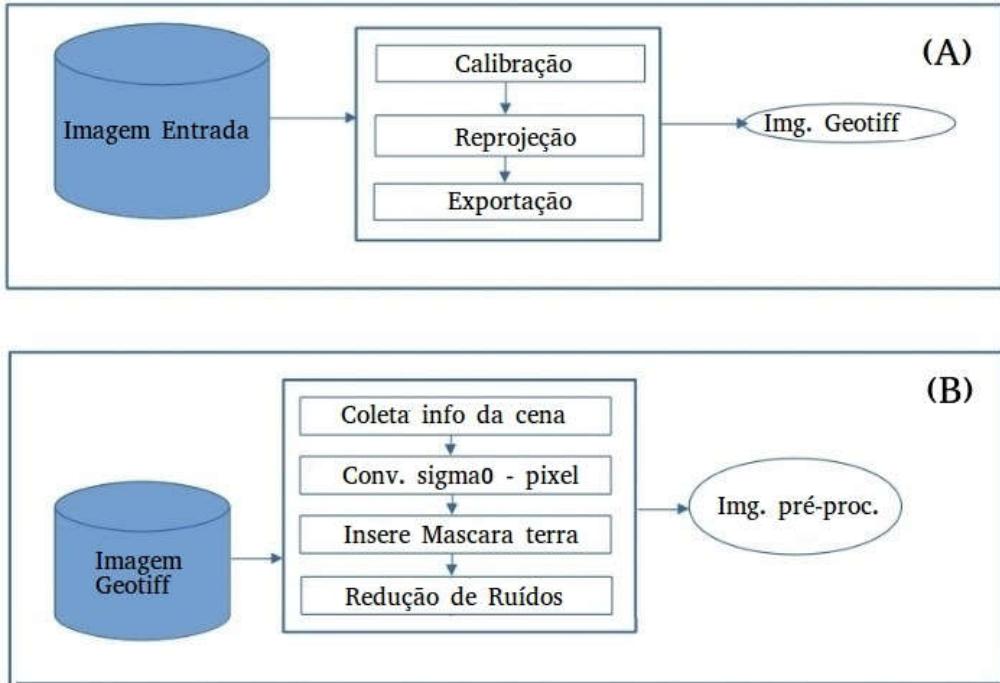


Figura 15. Estágio de pré-processamento. Painel superior (A) pré-processamento básico para imagens brutas e painel inferior (B) pré-processamento avançado mandatório de forma a suavizar e padronizar as imagens de entrada.

4.3.1.1. Calibração radiométrica, reprojeção e exportação

Recorrentemente, produtos em estágio inicial de processamento como por exemplo imagens Envisat ASAR WSM 1P, são entregues contendo distorções em seus valores de retroespalhamento. Em decorrência destas distorções, torna-se necessária a calibração de distintos parâmetros radiométricos (i.e. ângulo de incidência do radar, ganho padrão da antena, perda por espalhamento e/ou constante de calibração absoluta) para obtenção de imagens resultantes cujo coeficiente de retroespalhamento (σ) seja capaz de refletir coerentemente as propriedades físicas dos objetos iluminados pelo radar [Rosich & Meadows 2004, Collares et al. 2015].

Embora não seja obrigatório para metodologias baseadas em pixels, a calibração radiométrica permite que a intensidade dos pixels em tons de cinza das imagens resultantes seja diretamente relacionada com a força do coeficiente de

retroespalhamento em decibéis (*dB*) além de, também, permitir a comparação direta (através da intensidade de pixel) entre imagens SAR adquiridas por diferentes sensores SAR. Nesse sentido, a calibração é realizada conforme proposto por [Rosich & Meadows 2004], **Equação (1)**:

$$\sigma_0 = \frac{DN^2}{K} \sin(\alpha) \quad (1),$$

onde o *DN* é a intensidade (*Digital Number*) do pixel bruto, α corresponde ao ângulo de incidência e K é constante de calibração absoluta.

Os produtos descritos embora incluem correção de faixa de visada inclinada (*slant range*) para faixa terrestre (*ground range*) não são georreferenciados. Neste sentido, os dados são padronizados e reprojetados para EPSG: 3031 WGS 84/*Antarctic Polar Stereographic projection*, com latitude de origem em 90º S, meridiano central em 0º e paralelo padrão em 71º S.

Por fim, as imagens SAR calibradas e reprojetadas são exportadas para o formato GeoTiff (uma extensão do formato TIFF 6.0, com georreferencia e metadados espaciais) em 8 bits de intensidade de cor (tons de cinza) com valores de alcance 0-255.

4.3.1.2. Removendo áreas de terra e plataformas de gelo

Usualmente, as imagens costeiras podem apresentar áreas continentais e/ou amplas plataformas de gelo flutuantes que podem ser erroneamente identificadas como icebergs [Silva & Bigg 2005] (**Figura 16**). Neste sentido, essas áreas não pertinentes ao estudo são detectadas e removidas das imagens SAR através da

utilização de polígonos como marcadores de linha costa disponibilizados pelas agências espaciais responsáveis pela aquisição e distribuição das imagens SAR.

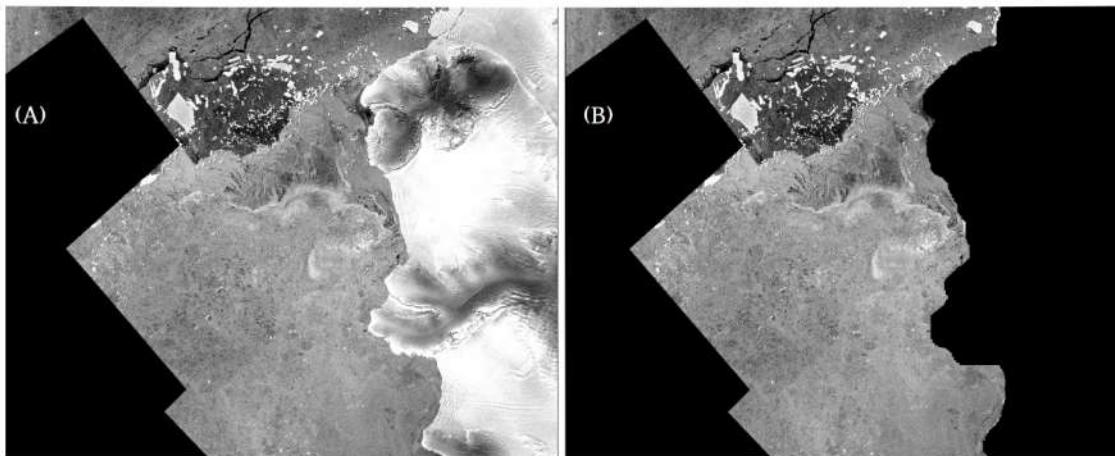


Figura 16. Comparação entre cena SAR com (A) área continental visível e (B) cena após remoção da região de terra visível através de aplicação de máscara de terra.

4.3.1.3. Redução de ruído

Imagens digitais são suscetíveis a distorções aleatórias introduzidas pelos processos de formação, gravação e/ou transmissão [Rudin et al. 1992]. Essas distorções, ou ruídos, são inevitáveis e frequentemente comprometem a cena, não refletindo a distribuição real de intensidade dos conjuntos de pixels.

O ruído multiplicativo conhecido como *Speckle* (também conhecido como Ruído Sal e Pimenta ou Impulso) é um fenômeno estocástico comum em sistemas ativos como sonares, lazeres e radares resultantes de interferências construtivas e destrutivas aleatórias nos sinais de retroespalhamento [Wesche & Dierking 2012] de forma geral assumindo a forma de ruído granular, reduzindo a qualidade da imagem (**Figura 17**).

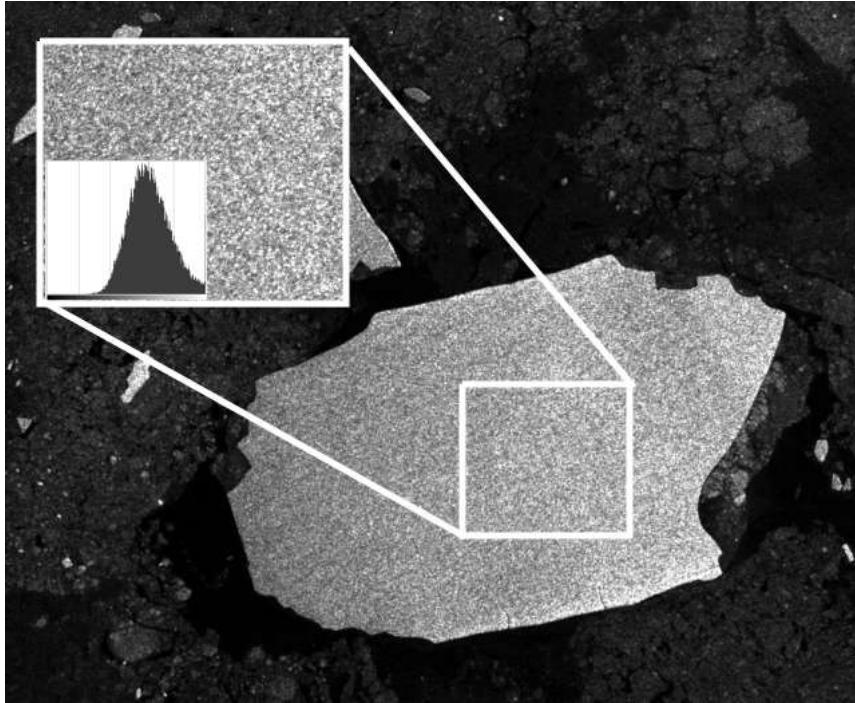


Figura 17. Exemplo de imagem com presença de ruído do tipo *Speckle*. Área ampliada em conjunto com a distribuição dos níveis de cinza é disponilizada.

Devido a sua natureza randômica o ruído *Speckle* tem sido estudado nos últimos 20 anos com vários algoritmos e métodos estatísticos propostos. Dentre estes, o filtro Lee Sigma [Lee 1981] (**Equação 2**), tem sido amplamente aplicado devido sua simplicidade, eficácia e eficiência computacional [Kupidura 2016].

Este filtro percorre uma janela móvel $N \times N$ sobre a imagem assumindo uma distribuição gaussiana para o ruído com base no conceito de que ~95% dos pixels são distribuídos dentro de dois intervalos de probabilidade sigma, definidos como a probabilidade de uma variável aleatória estar dentro de dois desvios padrão de sua média [Lee 1981, Kupidura 2016]. Geralmente, como a maioria dos pixels inseridos na amostragem pertencem à mesma distribuição, na maioria dos casos a suavização de imagem é sucinta o suficiente para preservar detalhes e transições de bordas. Um exemplo de aplicação do filtro Lee Sigma é apresentado na **Figura 18**.

A aplicação proposta utiliza janela móvel de tamanho 5×5 e sigma 0.5.

Conforme Equação (2):

$$Y = X + K(X - \bar{X}) \quad (2),$$

onde X representa o conjunto de pixels inseridos na janela móvel e \bar{X} é a média destes,

$$K = \frac{Var(X)}{\bar{X}^2 \sigma^2 + Var(X)} \quad (3),$$

e

$$Var(x) = \frac{std(X) + \bar{X}^2}{\sigma^2 + 1} - \bar{X}^2 \quad (4),$$

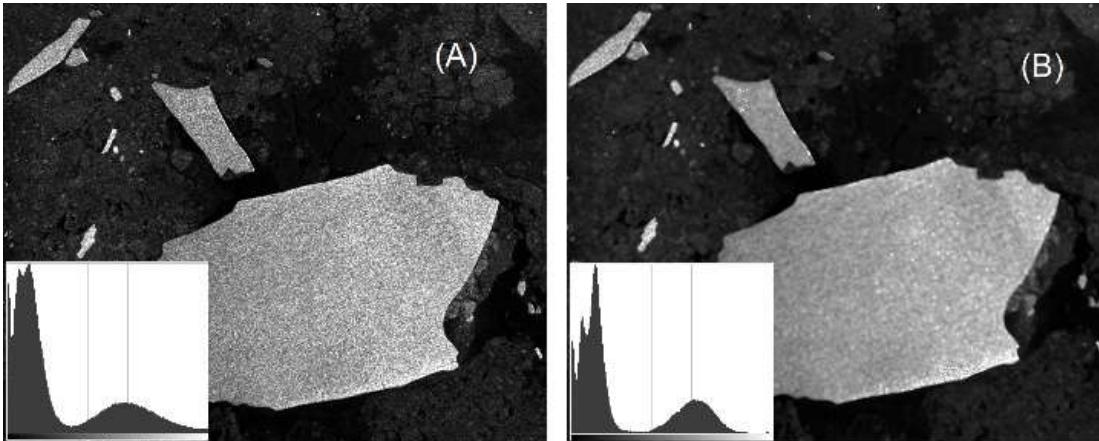


Figura 18. Aplicação do filtro Lee Sigma para redução de ruído do tipo *Speckle*. O ganho resultante desta etapa proporciona uma primitiva suave para computar parâmetros de textura com mínima perda nas transições de bordas. Em adição, respectivos histogramas são apresentados.

4.3.2. Segmentação

A segmentação é um estágio fundamental para problemas complexos de processamento de imagem como classificação. O principal objetivo é reduzir e/ou simplificar o complexo grid de pixels para um conjunto de regiões homogêneas correspondentes aos distintos objetos de interesse na cena [Sang et al. 2016]. No entanto, o processo de segmentação tende a ser computacionalmente oneroso e

altamente suscetível a falhas, principalmente em cenas de baixo contraste e limites de bordas fracos, uma vez que os segmentos (ou clusters) são resultantes do agrupamento de pixels por similaridade (geralmente intensidade (cor)). Neste sentido, o processo de segmentação proposto nessa abordagem (**Figura 19**) é subdividido em 4 estágios: (i) setorização de cena (*Image sectoring*), (ii) limiar de histograma (*Histogram Thresholding*), (iii) realce de contraste (*Contrast Enhancement*) e por fim, (iv) super-segmentação por Superpixels.

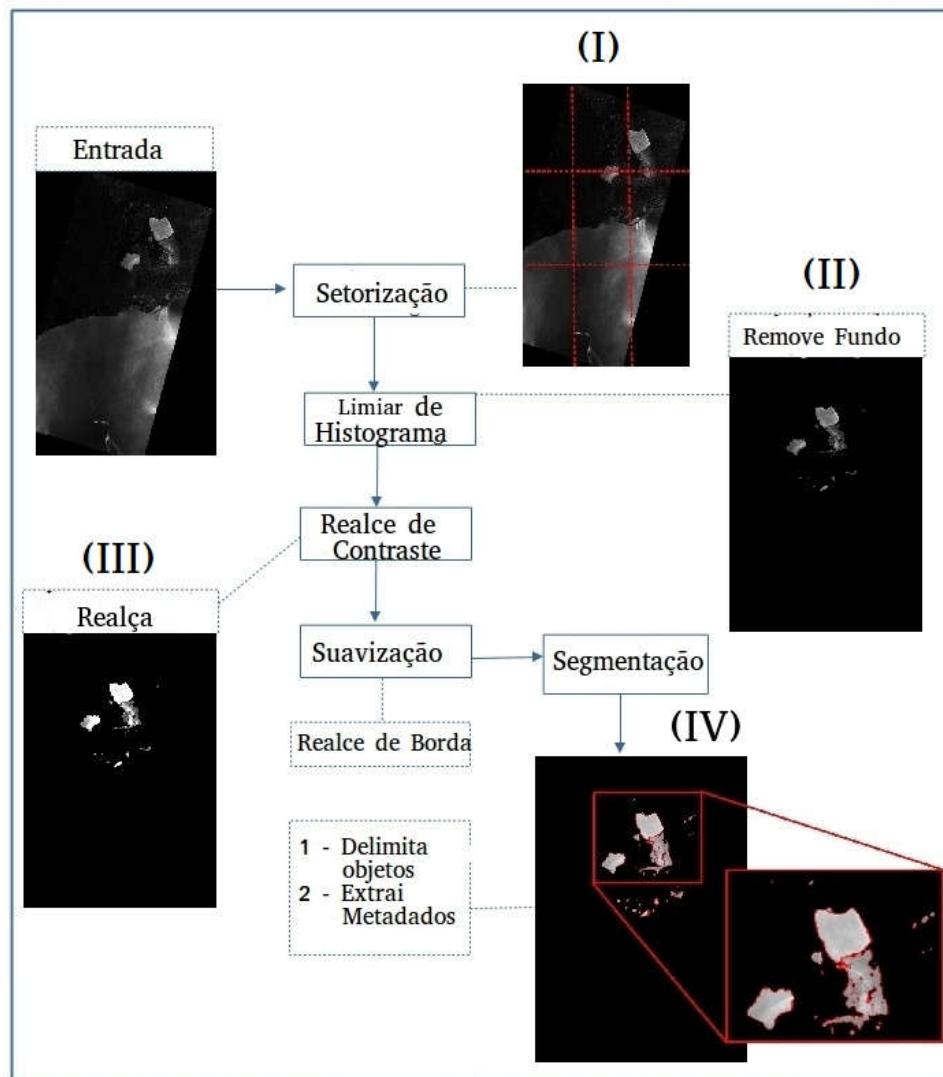


Figura 19. Fluxograma completo do estágio de segmentação. Incluindo (i) reamostragem de cena (*Image sectoring*), (ii) limiarização de histograma (*Histogram Thresholding*), (iii) realce de contraste (*Contrast Enhancement*) e por fim, (iv) segmentação por Superpixel.

4.3.2.1. Setorização de cena (*Image Sectoring*)

Usualmente, as imagens SAR constituem matrizes de alta resolução capazes de cobrir uma grande extensão de área, no entanto, icebergs representam uma parcela muito pequena das cenas. Nesse sentido, definir áreas particulares de interesse tende a reduzir consideravelmente o tempo de busca e melhorar os resultados finais evitando estruturas desnecessárias em etapas posteriores [Williams et al. 1999].

Em contextos de grande volume de dados, inspecionar visualmente a cena para definir áreas de interesse para a análise é impraticável e redimensionar a cena de forma a reduzir o espaço de busca pode resultar em perda de resolução, excluindo objetos pequenos. Além disso, para técnicas de processamento de imagem que operaram através de janelas móveis, imagens de alta resolução representam um problema complexo para o desempenho computacional. A complexidade computacional para mover uma janela $n \times n$ sobre uma imagem $N \times N$, é tomada em termos assintóticos como:

$$O(N^2 \times n^2) \quad (5),$$

Logo, devido à alta resolução espacial característica das imagens SAR utilizadas, todos os procedimentos de pré-processamento são aplicados em setores menores reamostrados da imagem origem. Desta forma, reduzindo a área de inspeção e permitindo o processamento paralelo. As cenas são setorizadas conforme:

$$I_{setor} = \left\lfloor \frac{M}{D} \right\rfloor \times \left\lfloor \frac{N}{D} \right\rfloor \quad (6),$$

onde $M \times N$ são as dimensões da imagem base e D é o número de partições.

Partições altamente homogêneas são removidas, isso evita que partições nulas (sem dados) e/ou mascaradas sejam consideradas.

4.3.2.2. Limiar de histograma (*Histogram Thresholding*)

O limiar de histograma é um método simples e eficaz para segmentação de imagem, capaz de separar objetos e fundo em dois conjuntos não sobrepostos criando uma representação binária da cena [Arifin & Asano 2006, Raju & Neelima 2012]. Esta representação binária é útil e pode ser utilizada para remover áreas nulas e/ou ressaltar possíveis áreas de interesse, conforme demonstrado na **Figura 20**.

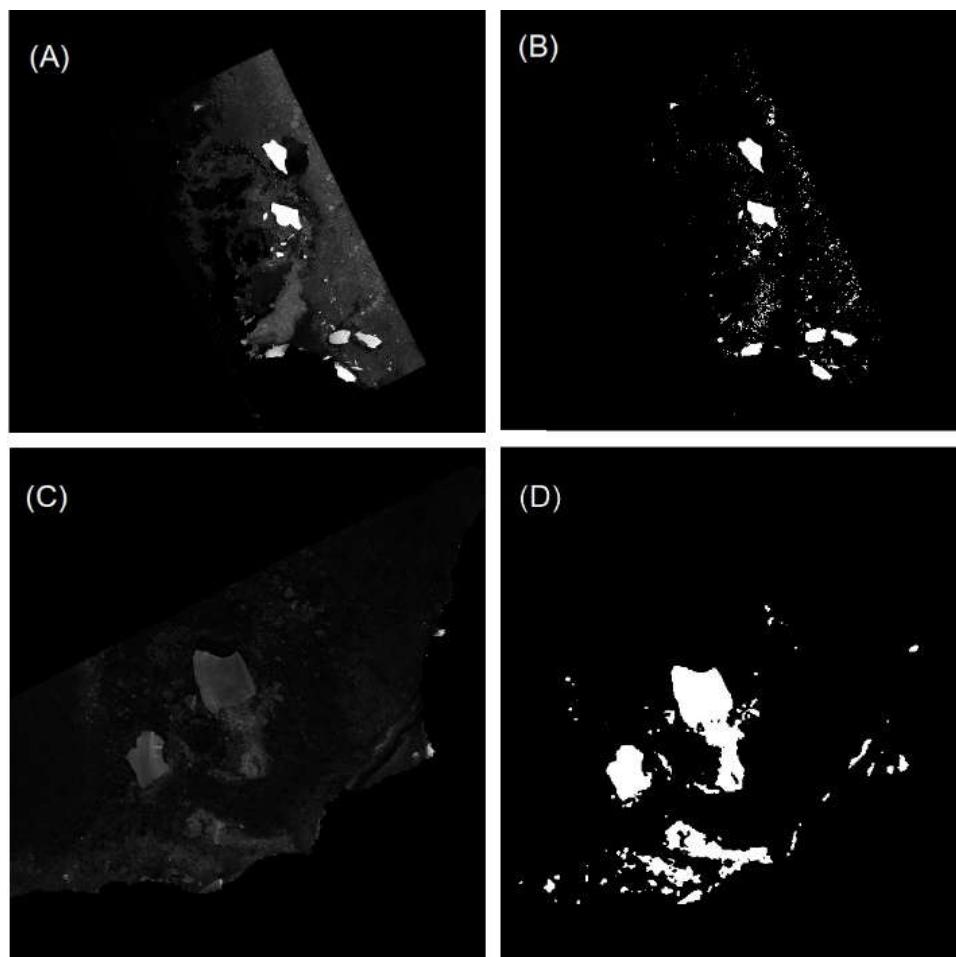


Figura 20. Demonstração da aplicação do limiar de histograma (A) cena com forte assinatura de gelo marinho, águas abertas e presença de icebergs com assinaturas radiométricas variadas e (C) cena com baixo contraste. (B) e (D) representação binária obtida com filtro percentil (99, 1).

O método aplicado é uma adaptação do método de busca binária em histograma [Danielsson 1981]. O método emprega uma estratégia adaptativa do filtro Percentil (*Rank Filter*) com percentis $[p1, p2]$ sendo definidos dinamicamente para as diferentes regiões da imagem. Na prática, cada pixel é substituído por um mínimo ou máximo local definido a partir da distribuição de intensidade contida na janela móvel [Duin et al. 1986]. Apenas valores entre percentis $[p1, p2]$ alocados para cada janela são considerados.

4.3.2.3. Realce de contraste (*Contrast Enhancement*)

Uma vez removida a maior parte das regiões nulas e de baixo interesse, os objetos restantes são passíveis de serem considerados para as etapas seguintes, reduzindo o custo computacional e diminuindo o volume de possíveis entradas nulas ou obviamente falsas. No entanto, ainda é necessário ressaltar o contraste entre os distintos objetos remanescentes nas cenas.

Definido como a amplitude entre níveis baixos e altos de intensidade de pixels, o contraste de uma imagem é resultante de variações de iluminação entre duas superfícies [Teoh & Ibrahim 2012] e em imagens de radar, o contraste é criado pela variação do coeficiente de retroespalhamento sobre os distintos alvos iluminados. Uma imagem de baixo contraste exibe uma pequena amplitude entre níveis baixos e altos, fazendo com que detalhes ou estruturas com menor amplitude de intensidade tornem-se imperceptíveis [Maini & Aggarwal 2010, Hassanpour & Samadiani 2015].

Melhorar o contraste entre icebergs e demais objetos (não-icebergs) a partir de imagens SAR é desafiador uma vez que os pixels podem estar confinados a valores mais elevados em imagens de alta intensidade, baixos para imagens escuras

ou ambos na mesma cena. Assim, a capacidade de ajustar o contraste da imagem com base na situação local é necessária.

Nesse sentido, o filtro local de contraste linear “Min-Max” [Al-amri et al. 2010] (**Equação (7)**) foi selecionado por apresentar satisfatório grau de performance em diferentes configurações de cenas. Nesta abordagem, os valores originais mínimos e máximos (Min-Max) de intensidade dentro da janela móvel (tamanho 5×5) são substituídos por novos valores dentro da faixa completa de intensidades (0-255). Esta abordagem é capaz de melhorar o contraste e as definições de bordas em ambas as porções escuras e claras da imagem, simultaneamente. Em adição, após o aprimoramento do contraste, o histograma resultante inclui picos proeminentes que podem ser separados em uma série de modos onde cada modo é esperado corresponder a uma região [Arifin & Asano 2006].

$$g(x,y) = \frac{f(x,y)-\min}{\max-\min} \times 255 \quad (7),$$

onde $g(x,y)$ representa a imagem de saída, $f(x,y)$ a imagem de entrada e \min e \max correspondem a intensidade mínima e máxima contidos na janela móvel, respectivamente. Um exemplo de aplicação do filtro Min-Max é apresentado na

Figura 21.

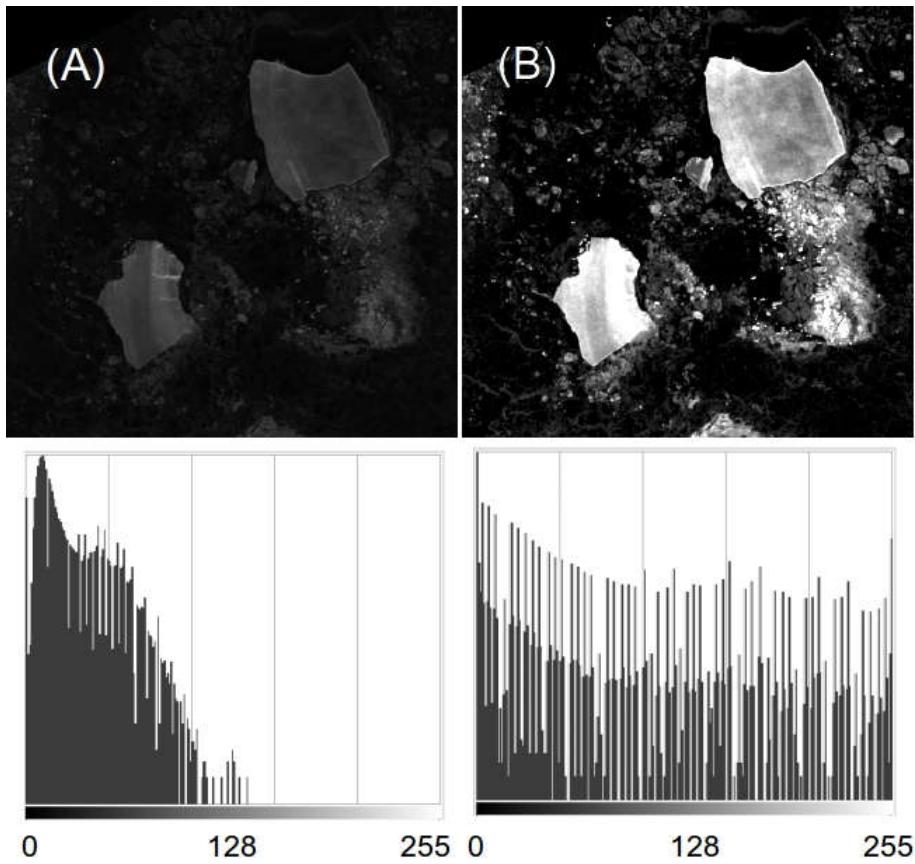


Figura 21. Demonstração de realce de contraste com filtro local de contraste linear “min-max” aplicado em uma cena de baixo contraste com a presença de icebergs escuros. (A) Cena original com redução de ruído “Speckle”, (B) cena com realce de contraste. Painéis inferiores apresentam respectivos histogramas.

4.3.2.4. Super-segmentação por Superpixel

As etapas descritas anteriormente resultam em cenas realçadas, limitando o espaço de busca a um grupo reduzido de objetos contrastados, os quais podem ou não ser icebergs. No entanto, para identificação precisa é necessário individualizar e atribuir um rótulo exclusivo a cada objeto para então, extrair informações capazes de descrever cada indivíduo. Algoritmos de segmentação por Superpixel são capazes de capturar redundâncias em imagens agrupando conjuntos de pixels individuais em regiões atômicas perceptivelmente significativas [Achanta et al. 2012]. Desta forma, fornecendo uma base conveniente para computar descritores de imagem e

propriedades espaciais, além de reduzir o custo computacional para tarefas de classificação, transformando a estrutura rígida de grade de pixels em um conjunto reduzido de regiões homogêneas [Achanta et al. 2010, Achanta et al. 2012, Zhang et al. 2017].

Operacionalmente, o objetivo deste método é individualizar possíveis icebergs presentes em imagens SAR os quais podem surgir sob tais condições: (i) icebergs podem aparecer parcialmente conectados a um ou mais objetos, (ii) icebergs plausíveis de apresentar baixo contraste em relação ao fundo, (iii) icebergs podem aparecer em uma ampla gama de tamanhos/formas e (iv) a aderência aos limites externos (perímetro) do iceberg é de suma importância para permitir a computação de metadados espaciais. Nesse sentido, o método de super-segmentação baseado na teoria dos grafos (ramo da matemática que estuda as relações entre os objetos de um determinado conjunto) [Thulasiraman & Swamy 2011] proposto por Felzenszwalb and Huttenlocher [2004] apresentou o melhor desempenho para a esta tarefa. Na prática, o método de segmentação agrupa pixels semelhantes (intensidade) através de buscas “gulosas” (*greedy search*) com base em três parâmetros (configurações utilizadas nesta abordagem estão dentro dos parênteses): (i) escala - define o nível de observação, maior significa segmentos cada vez menores (50); (ii) sigma - executa um filtro mediano sobre a imagem (0); e (iii) tamanho mínimo - número mínimo de pixels para criar um único segmento (10).

Na prática, o objetivo do método é produzir um conjunto de superpixels como vértices em um grafo. Cada vértice é recursivamente ajustado considerando uma distância mínima definida como a distância Euclidiana entre intensidades de pixel. Desta forma, o número de segmentos detectados está diretamente associado ao contraste da cena.

Após a segmentação inicial, geralmente grandes icebergs com uma ampla área horizontal podem apresentar extenso gradiente de textura, resultando em excesso de segmentação (segmentos menores dentro de segmentos maiores). Para reduzir essas inconsistências, gradualmente segmentos semelhantes são fundidos hierarquicamente usando a técnica de Regiões de adjacência em grafos (*Region Adjacency Graph* - RAG) [Tremeau 1995], aplicando um limite de distância de intensidade de 15% definido por testes. Isso produz superpixels que aderem bem aos limites dos icebergs, mesmo que tenham geometria irregular e/ou grande gradiente de textura na superfície do objeto. E por fim, na prática a utilização da abordagem de superpixel permite estimar a área do iceberg com base nas suas propriedades espaciais, conforme demonstrado na seção 4.3.4. A **Figura 22** mostra um exemplo de segmentação aplicando o método Felzenszwalb e Huttenlocher [2004] em imagem SAR resultante das etapas anteriores de processamento. Linhas vermelhas definem o perímetro individual de cada objeto segmentado.



Figura 22. Exemplo de segmentação aplicando o método Felzenszwalb and Huttenlocher [2004]. Painel A mostra imagem SAR em estado bruto sem etapas de ajuste. Painel B demonstra resultado

de segmentação aplicado após etapas de pré-processamento e pré-segmentação. Linhas vermelhas demarcam o perímetro individual de cada segmento.

4.3.3. Classificação

Nesta etapa, embora a grade total de pixels tenha sido convertida em um conjunto reduzido e realçado de segmentos homogêneos (Superpixels). Devido à grande variabilidade recorrente dos objetos contidos em imagens SAR obtidas em ambientes polares, nem todos os segmentos com características semelhantes podem ser rotulados como pertencentes a mesma classe. Por consequência, é necessário extrair um conjunto de características capazes de descrever os distintos objetos de forma coerente sob diferentes perspectivas e na sequência estabelecer modelos preditivos capazes de, finalmente, diferenciar e rotular os objetos como pertencentes a uma classe final: iceberg ou não-iceberg.

4.3.3.1. Descritores de imagens (*Image features*)

A escolha ou desenvolvimento de descritores de imagem capazes para descrever coerentemente algum objeto ou conjunto de objetos é variável e depende da tarefa em mãos [Machajdik & Hanbury 2010]. E quando o objeto a ser descrito apresenta comportamento ambíguo sujeito a diferentes tipos de variação na cena (ex. cor, textura, brilho, contraste, saturação, ruído e/ou rotação) esta tarefa é agravada, sendo necessário estabelecer um conjunto geral de descritores capazes de representar diferentes aspectos do mesmo objeto.

No caso dos icebergs e demais estruturas comumente presentes em imagens SAR adquiridas em ambientes polares, principalmente próximo a região costeira, variações nas assinaturas de retroespalhamento causadas por condições

atmosféricas e oceanográficas adversas, frequentemente resultam em um ambiente desafiador para classificação com ampla variabilidade, como demonstrado na **Figura 23**.

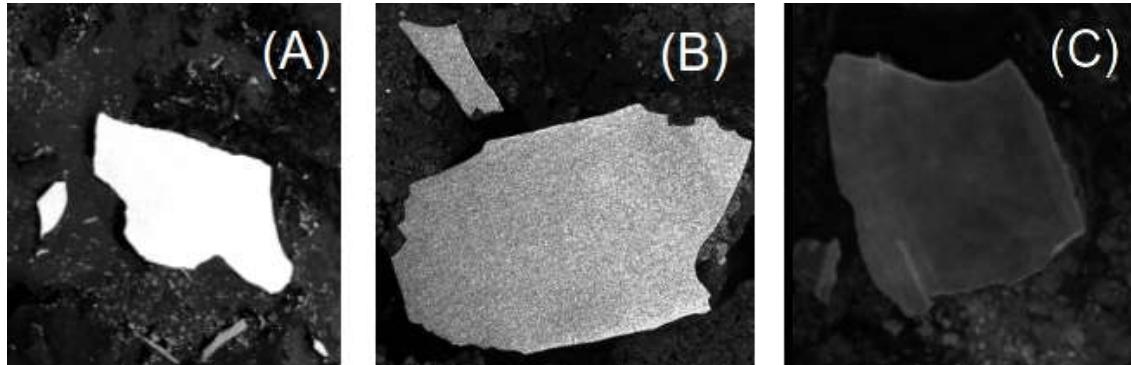


Figura 23. Exemplos de冰bergs com assinaturas de radar amplamente distintas. (A) Iceberg saturado (*Bright iceberg*), (B) iceberg de média intensidade e (C) iceberg “escuro” (*Dark iceberg*)

A assinatura de radar de um iceberg é dada pelo coeficiente de retroespalhamento (σ_0) resultante do somatório das contribuições de sua superfície e volume [Wesche & Dierking 2012]. A superfície dos icebergs pode ser coberta por neve em diferentes estágios, poças de derretimento e/ou áreas de gelo exposto. Não o bastante, icebergs podem rolar neste caso, expondo a região submersa formada por gelo glacial puro que frequentemente não exibe contraste positivo em comparação com elementos de baixo contraste como mar aberto. Em regiões onde as temperaturas do ar estão acima do ponto de fusão, a água líquida e/ou a neve molhada na superfície do iceberg reduzem a dispersão e o volume de retroespalhamento, resultando em icebergs "escuros" [Silva & Bigg 2005, Wesche & Dierking 2012]. A ação de vento intenso sobre a superfície oceânica em águas abertas pode saturar a cena apresentando intensidade de retroespalhamento elevada. Por fim, a assinatura do gelo do marinho aumenta quando este fragmenta

ou envelhece perdendo salinidade tendendo a assemelhar-se mais com icebergs [Williams et al. 1999, Gladstone & Bigg 2002].

Neste sentido, analisando as principais variações observadas em icebergs e demais objetos frequentes em cenas SAR obtidas em regiões polares, trinta e dois descritores de imagem foram determinados para detecção de icebergs. O objetivo é computar um conjunto amplo o suficiente capaz de descrever icebergs e demais objetos sob perspectivas distintas. Todos descritores são computados a partir dos Superpixels individuais obtidos na fase de segmentação, como ilustrado na **Figura 24**.

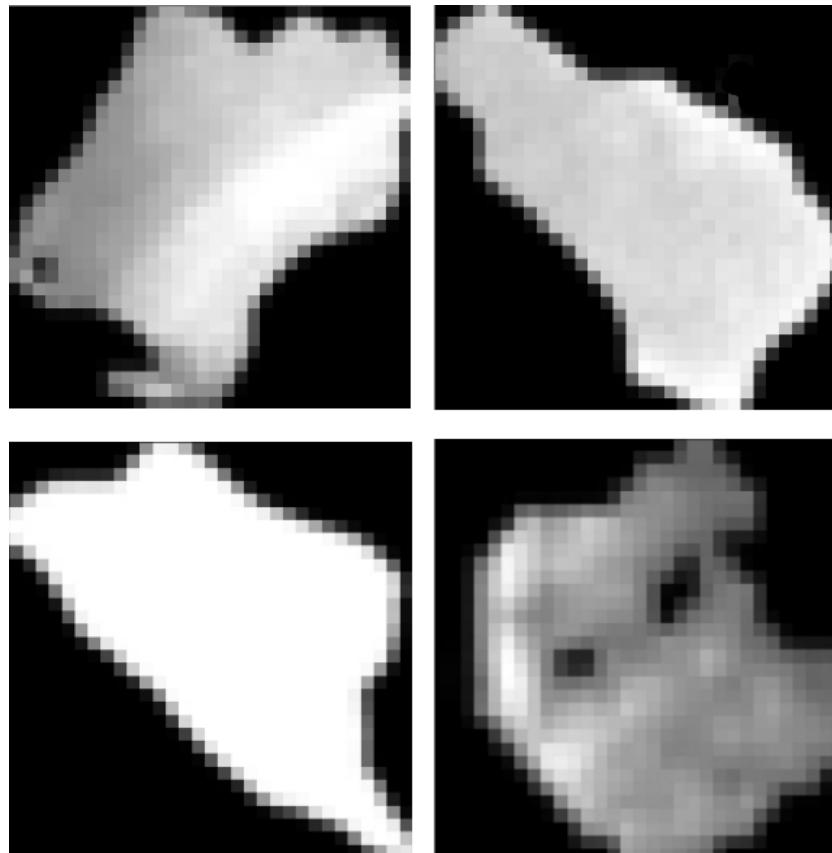


Figura 24. Exemplos de segmentos utilizados para extração de descritores. Pixels externos a superfície do objeto é completamente removida.

Estatísticas baseadas em intensidade de cor: Descritores estatísticos baseados na intensidade do pixel (cor em nível de cinza) derivada do coeficiente de retroespalhamento (σ_0) são amplamente os mais utilizados para classificar icebergs [Williams et al. 1999, Gladstone & Bigg 2002, Silva et al. 2006, Wesche & Dierking 2012, 2015, Frost et al. 2016, Mazur et al. 2017]. No entanto, variações na superfície do iceberg assim como no ângulo de incidência do radar em relação a orientação do iceberg [Wesche & Dierking 2012] tornam estes sensíveis e voláteis quando aplicados isoladamente. Nesta abordagem, cinco descritores estatísticos baseados na intensidade do pixel são empregues: (i) média, (ii) desvio padrão, (iii) mediana e (iv) moda e (v) energia.

Estatísticas baseadas em histograma: Um dos métodos mais úteis para tarefas de classificação de imagem. O histograma de uma imagem pode ser especificado independentemente de qualquer conteúdo real da imagem por uma distribuição de probabilidade discreta [Blachnik & Laaksonen 2008] e pode ser usado para analisar características de textura espacial [Singh & Singh 2002, Chen et al. 2003]. Nesse sentido, seis descritores estatísticos baseados em histograma foram considerados (i) média, (ii) variância, (iii) assimetria, (iv) curtose e (v) entropia e (vi) moda e um baseado na análise de tendência da distribuição de níveis de cinza (Declive (*slope*)).

Exemplo é apresentado na **Figura 25**.

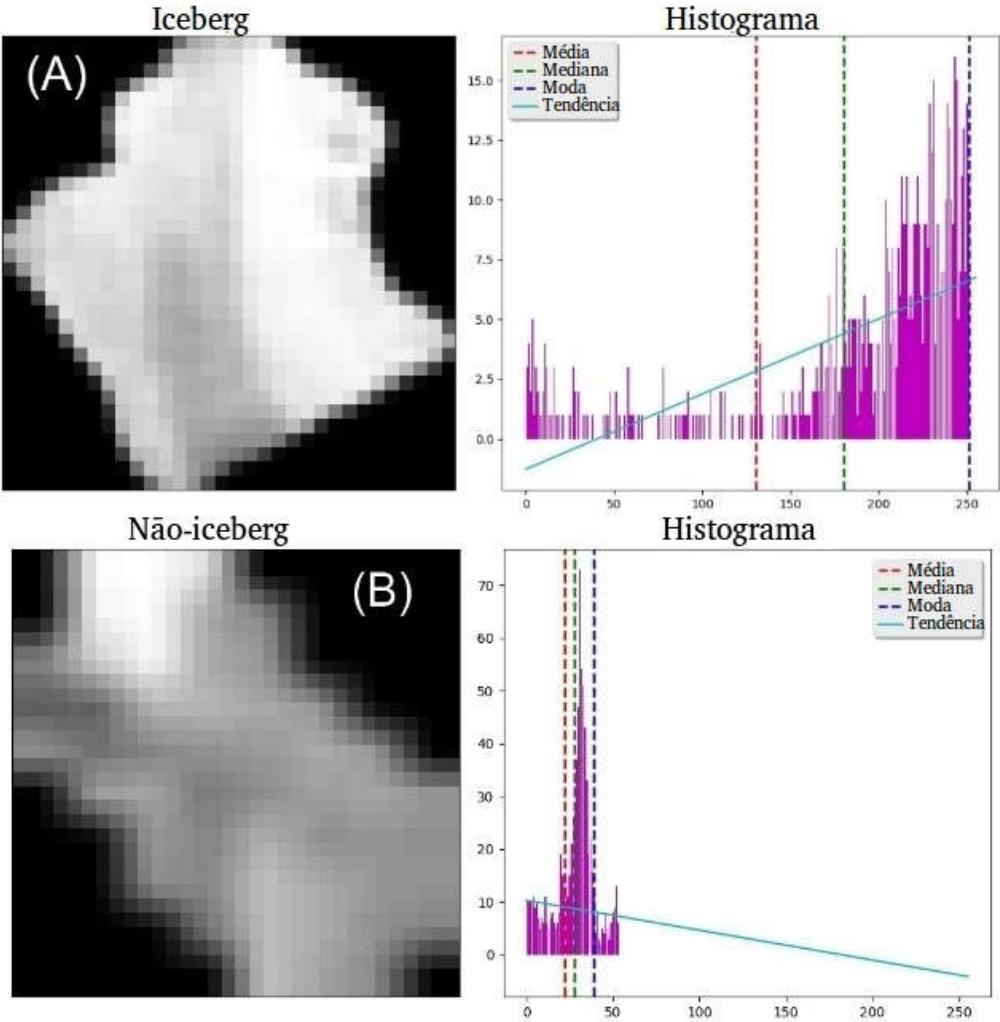


Figura 25. Exemplificação de descritores de histograma, comparação entre (A) iceberg e (B) não-iceberg. Respetivos painéis laterais apresentam distribuições de níveis de cinza para ambos objetos, assim como principais medidas estatísticas computadas.

Descritores de textura no domínio da frequência: Baseado na perspectiva de processamento do sinal, a diferença principal entre a cor e a textura é que o último exige uma vizinhança finita para ser definido [Chen et al. 2003]. Em um cenário ideal, icebergs seriam claramente identificados como objetos de assinatura contrastante dentro de um fundo homogêneo, no entanto, oscilações durante o processo de aquisição resultam em um cenário variável, apresentando icebergs com diferentes padrões de textura na mesma cena, como demonstrado na **Figura 26**.

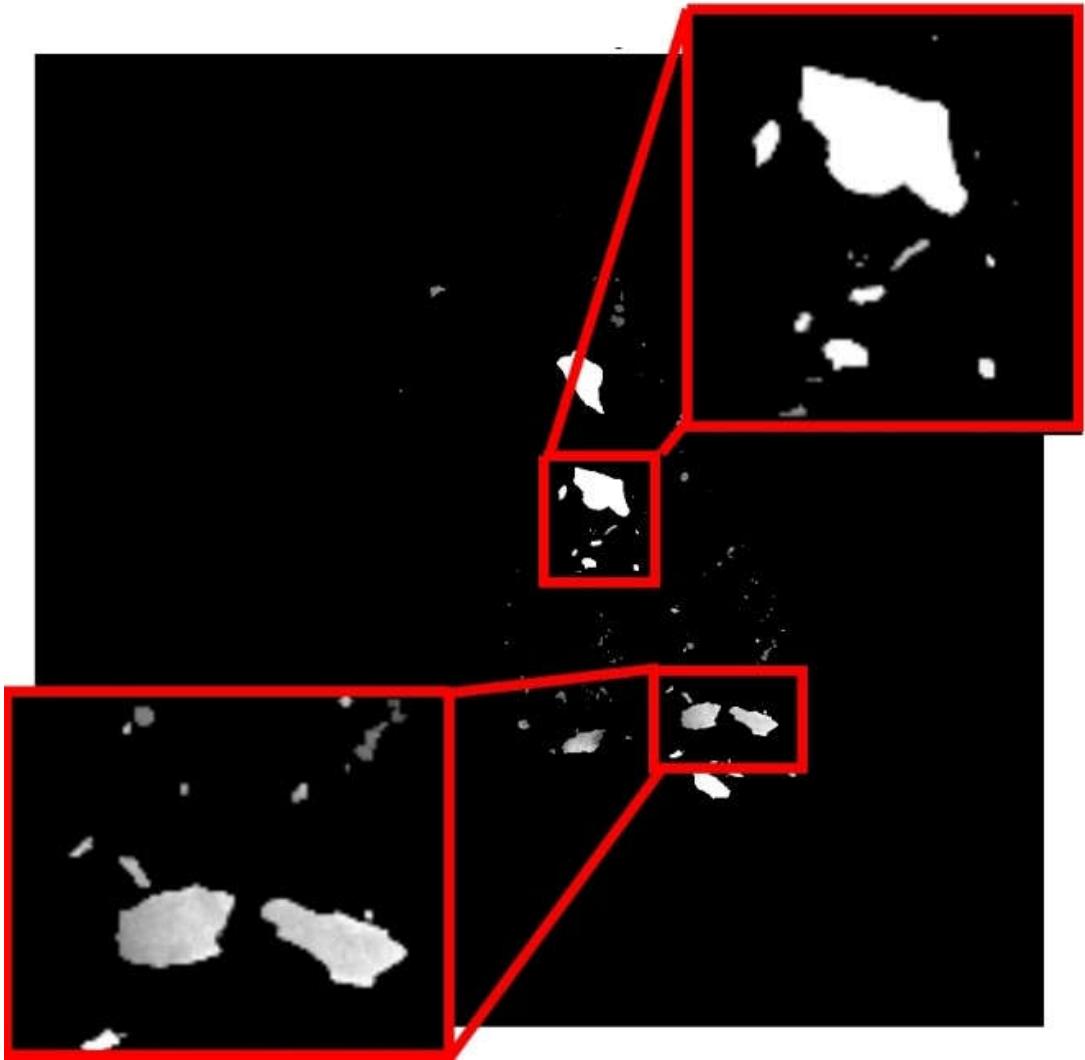


Figura 26. Demonstração de cena SAR com a presença de icebergs com diferentes padrões de textura.

O filtro Gabor (*wavelet-based Gabor Filter*) pode ser aplicado localmente para extrair descritores estatísticos com base na energia da textura [Mishra et al. 2010]. O uso do filtro Gabor apresenta características úteis para descrever objetos dinâmicos sendo invariante a rotação, iluminação e escala. Para obter uma representação das características de textura, o filtro Gabor percorre o conteúdo da imagem com diferentes escalas e orientações resultando em uma resposta única de domínio de frequência [Ismail et al. 2014] (**Figura 27**). Então, parâmetros estatísticos como a

média e a variância dos padrões de energia podem ser efetivamente usadas para reconhecimento [Masotti & Campanini 2008, Shihavuddin 2014].

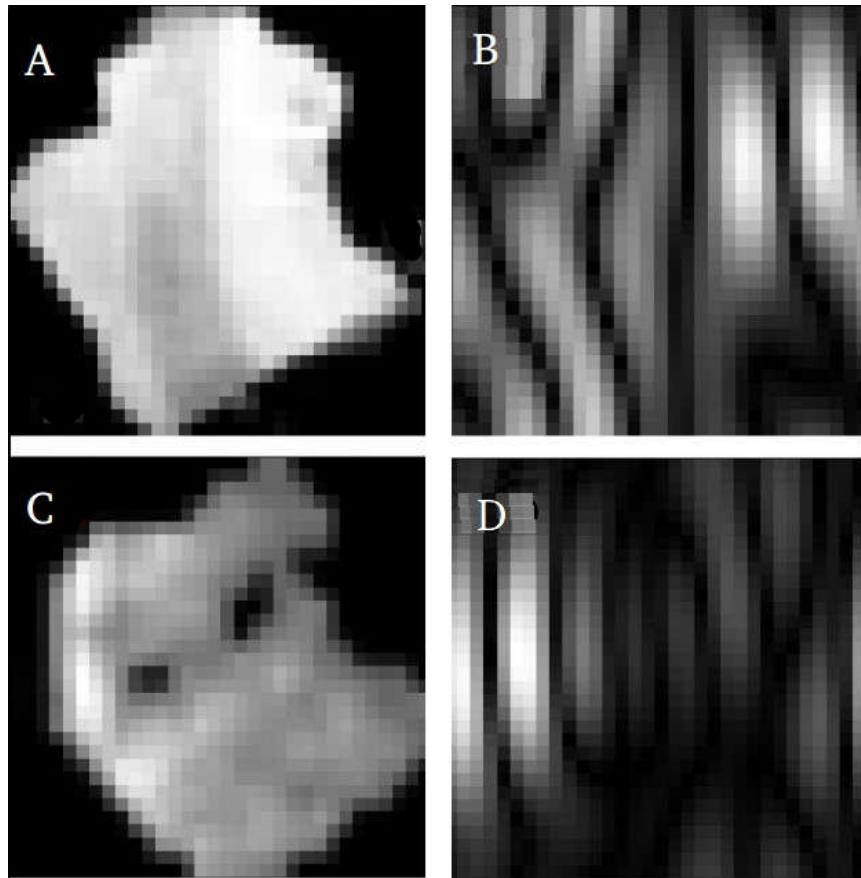


Figura 27. Demonstração da aplicação do filtro Gabor para extração de descritores de textura no domínio da frequência. Painéis (B) e (D) correspondem a resposta no domínio da frequência referente a (A) iceberg e (B) gelo marinho, respectivamente.

A definição formal do filtro Gabor é dada da seguinte forma:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(j\omega x) \quad (8),$$

onde x, y representam as coordenadas de pixel, $j = \sqrt{-1}$ e ω a frequência. Por fim, média e a variância são computados a partir da imagem filtrada.

Descritores de variabilidade textura: Descritores de textura baseados em matrizes de co-ocorrência de níveis de cinza (*Grey Level Co-occurrence Matrix - GLCM*) [Haralick & Shanmugan 1973, Haralick 1979] são amplamente utilizados para computar estatísticas baseadas nos padrões de regularidade de textura. Estes descritores, fornecem estatísticas úteis sobre a variabilidade da rugosidade da textura em diferentes ângulos. A partir da GLCM foram extraídas doze medidas de estatísticas de textura, três por ângulo (0° , 45° , 90° e 135°), contraste, homogeneidade e dissimilaridade, computados como segue:

O elemento $p(i,j)$ em uma GLCM representa a frequência de ocorrência de uma determinada intensidade pixel em uma direção θ e d é a distância adjacente entre os pixels nesta direção. Normalmente, d assume 1 ou 2, θ quatro direções 0° , 45° , 90° e 135° . Cada elemento valores de GLCM são então computados da seguinte forma:

$$p(i,j) = \frac{p(i,j,d,\theta)}{\sum_{i=1}^N \sum_{j=1}^N p(i,j,d,\theta)} \quad (9),$$

na sequência, os descritores de textura de Haralick usadas em nosso método são computadas para cada direção da seguinte forma:

$$\text{Contraste: } \sum_{i=1}^N \sum_{j=1}^N (i-j)^2 p(i,j) \quad (10),$$

$$\text{Homogeneidade: } \sum_{i=1}^N \sum_{j=1}^N \frac{p(i,j)}{1+(i-j)^2} \quad (11),$$

$$\text{Dissimilaridade: } \sum_{i=1}^N \sum_{j=1}^N |i-j| \cdot p(i,j) \quad (12),$$

Descritores baseados na variabilidade morfo-espacial: Considerando que uma das propriedades mais persistentes observadas em icebergs a partir de imagens SAR é a forma, sendo esta não afetada por oscilações no sinal de aquisição. Descritores baseados nas propriedades espaciais dos icebergs se tornam úteis. Embora estas

sejam sujeitas a alterações resultantes processos como fragmentação ou rolamento, icebergs comumente apresentam características espaciais e morfológicas mais simétricas e conservativas quando comparado com demais elementos presentes no fundo da cena. Neste sentido seis descritores computados a partir das propriedades morfo-espaciais dos Superpixels foram considerados: (i) excentricidade referente a proporção da distância entre os dois pontos focais de uma elipse que tem os mesmos segundos momentos que a região do superpixel, (ii) diâmetro equivalente a um círculo que tem a área proporcional a área do superpixel (*roundness*), (iii) solidez referente a densidade de pixels inseridos no menor polígono regular capaz de limitar o superpixel (*convex hull*), (iv) grau de compacidade (teste Polsby-Popper [Polsby & Popper 1991]), (v) índice de perímetro normalizado, e (vi) dimensão fractal [De Keersmaecker et al. 2003], computados como segue e:

$$\text{Excentricidade: } \sqrt{1 - \frac{b^2}{a^2}} \quad (13),$$

onde a é o comprimento do eixo principal e b o comprimento do eixo menor.

Definindo o “*convex hull*” como o polígono convexo mínimo que pode encerrar uma geometria de determinado objeto de imagem:

$$\text{Diâmetro equivalente: } \frac{4\pi \times \text{area}}{(\text{perímetro do convex hull})^2} \quad (14),$$

onde *convex hull perimeter* representa o perímetro do “*convex hull*” que encerra o objeto.

$$\text{Sólitez: } \frac{\text{area}}{\text{convex hull area}} \quad (15),$$

onde *convex area* é a área do menor “*convex hull*” capaz de encapsular o objeto.

$$\text{Polsby-Popper test: } \frac{4\pi A_o}{P_o^2} \quad (16),$$

onde A_o representa a área do objeto e P_o o perímetro do objeto. Uma pontuação de 1 indica a compacidade máxima.

$$\text{Índice de perímetro normalizado: } \frac{2\sqrt{\pi area}}{perimeter} \quad (17),$$

$$\text{Dimensão fractal: } \frac{\log r}{\log s} \quad (18),$$

onde r representa o número de dimensões auto semelhantes, cada uma reduzida por um fator s .

4.3.3.2. Seleção de descritores (*Feature Selection*)

Computado o conjunto de descritores, um problema central no aprendizado de máquinas é identificar e selecionar qual subconjunto é mais representativo e capaz de descrever cada objeto a ser classificado com o menor nível de ambiguidade possível. Esta etapa atua na redução da dimensionalidade dos dados e pode permitir que os algoritmos de aprendizagem operem de forma mais rápida e eficaz removendo descritores redundantes e/ou irrelevantes do conjunto de dados [Hall 1999, Aggarwal 2013].

Neste intuito, é computado o grau de correlação do conjunto de descritores através do método de *Correlation-based Feature Selection* (CFS) [Hall 1999] assumindo por base que os descritores de entrada representam o alvo de classificação. Desta forma, é possível avaliar e ranquear a capacidade preditiva individual de cada descritor [Selvakuberan et al. 2008]. Para computar o grau de ganho de informação de cada descritor, foi utilizado a função de mérito descrita por Hall [1999] como segue:

$$r_{zc} = \frac{k\bar{r}_{zi}}{\sqrt{k+k(k-1)\bar{r}_{ii}}} \quad (19),$$

onde r_{zc} é a correlação entre os componentes de entrada e a variável externa, k é o número de componentes, \bar{r}_{zi} é a média das correlações entre os componentes e a variável externa e \bar{r}_{ii} é a inter-correlação média entre componentes. *Na prática, a Equação (19) reflete o coeficiente de correlação de Pearson, no qual todas as variáveis foram padronizadas [Hall 1999].*

$$\rho = \frac{cov(x,y)}{\sqrt{var(x)var(y)}} \quad (20),$$

onde x, y representam as componentes de entrada e variável externa, respectivamente, cov é a covariância e var a variância. Na **Tabela 3** são apresentados os doze descritores mais significativos ranqueados pelo ganho de informação através de CFS.

Tabela 3. Doze descritores mais representativos ranqueados pelo ganho de informação. Computado por *Correlation-based Feature Selection* (CFS). 0 significa sem relevância e 1.0 relevância máxima.

Descriptor	Tipo	CFS
Contraste GLCM 0º	Textura	0.563
Contraste GLCM 180º	Textura	0.539
Diâmetro equivalente	Morfo-espacial	0.530
Dimensão fractal	Morfo-espacial	0.509
Polsby-Popper	Morfo-espacial	0.498
Contraste GLCM 270º	Textura	0.471
Intensidade de cor STD	Intensidade	0.437
Contraste GLCM 90º	Textura	0.424
Média do histograma	Textura	0.417
Assimetria do histograma	Textura	0.417
Curtose do histograma	Textura	0.414
Declive (<i>slope</i>) histograma	Textura	0.396

4.3.3.3. Comitê de máquinas (*Ensemble Learning*)

Embora sistemas autônomos de classificação baseados em aprendizado de máquinas sejam comumente aplicados a uma ampla gama de problemas, um desafio recorrente persiste. Como lidar com classes distintas que frequentemente se sobrepõem e/ou apresentam ampla diversidade de assinaturas entre objetos pertencentes a mesma classe.

Isso ocorre porque modelos preditivos individuais geralmente tendem a falhar ao tentar separar objetos com características semelhantes ou sobrepostas. Em abordagens baseadas em aprendizado em conjunto (*Ensemble Learning*) (**Figura 28**), diferentes modelos preditivos são combinados no intuito de aumentar a adaptabilidade em tarefas de classificação de objetos ambíguos, reduzindo a instabilidade dos classificadores individuais [Dietterich, 2000].

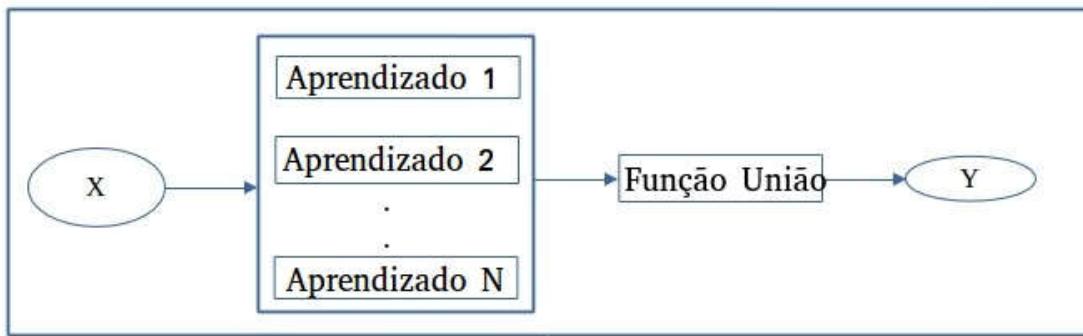


Figura 28. Arquitetura padrão de sistemas baseados em comitê de máquinas. “X” representa dados de entrada e “Y” dados de saída.

Em contraste com as abordagens tradicionais de aprendizagem de máquinas, a diversidade é uma propriedade fundamental para aplicação métodos de comitê máquinas (doravante chamados métodos ensemble), de fato essencial para promover a adaptabilidade em cenários complexos de predição [Breiman 2001, Eibl

& Pfeiffer 2005, Zhou 2012]. Intuitivamente, é compreensível que modelos preditivos individuais lineares ou polinomiais tendam a ser limitados quando aplicados a espaços de hipóteses amplos demais para explorar. Nestes casos, a união de modelos distintos, embora individuais, tende a reduzir o risco sobre estes espaços. A **Figura 29** mostra um exemplo de espaço de hipóteses com presença de hipóteses ambíguas e compara a aplicação de modelos preditivos individuais (lineares) e em conjunto (adaptados de Zhou [2012]).

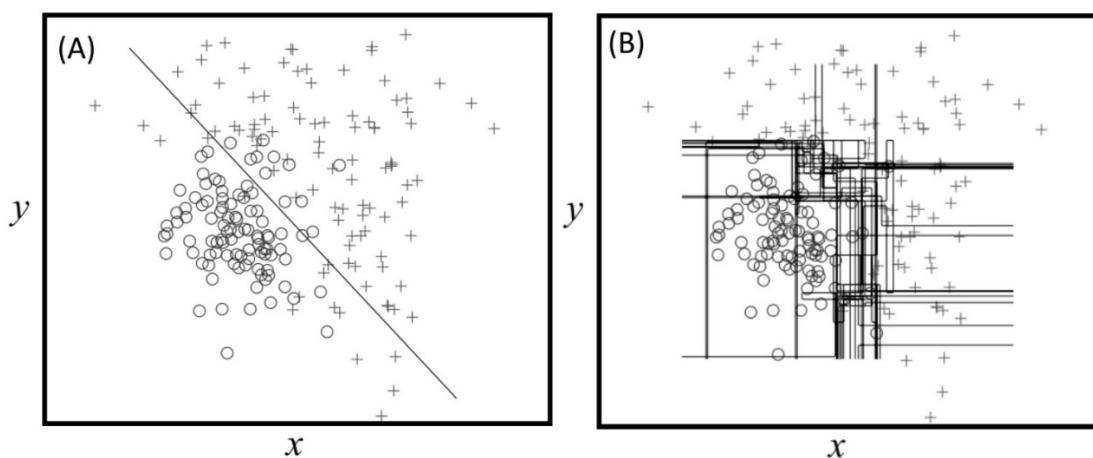


Figura 29. Exemplo de espaço de hipóteses com presença de hipóteses ambíguas (adaptados de Zhou, 2012). Painel (A) mostra aplicação de modelo preditivo linear, apresentando erros de classificação de ambos os alvos. Painel (B) mostra aplicação de método ensemble *Random Forest* (RF). Diferentemente das abordagens lineares, o RF é definido através de uma fusão de modelos preditivos distintos calculados a partir de um conjunto de árvores de decisão heterogêneas com base em diferentes arranjos de descritores de imagem. Isso resulta em limites preditivos que são mais flexíveis, levando assim a uma melhor habilidade de generalização.

Em métodos de aprendizado em conjunto, a diversidade no conjunto de modelos de predição pode ser alcançada com abordagens distintas. Dentre as mais utilizadas:

Bagging/bootstrap: Consiste na manipulação das amostras de treinamento de forma a construir múltiplas hipóteses, treinar cada classificador com um subconjunto aleatório do conjunto de treinamento [Breiman, 2001].

União de classificadores fracos: Através da manipulação do conjunto de descriptores para que cada classificador seja treinado com um subconjunto específico do espaço de descriptores desta forma, tornando cada modelo preditivo parcialmente especialista no espaço de hipóteses [Eibl & Pfeiffer 2005].

Entre os classificadores do tipo ensemble mais utilizados, o algoritmo não linear e não paramétrico *Random Forest* (RF) proposto por Breiman [2001] vem ganhando atenção e tem sido amplamente investigado e aplicado a problemas distintos [Beard 2007, Cutler et al. 2007, Özçift 2011, Hayes et al. 2014, Puissant et al. 2014, Belgiu & Drăgu 2016, Snapir et al. 2019]. Principalmente por apresentar vantagens como: (i) versatilidade e eficiência que permite ser aplicado sobre entradas de diferentes naturezas [Ghosh et al. 2014], (ii) apresenta alto desempenho computacional [Du et al. 2015, Gislason et al. 2006], (iii) permite avaliar a representatividade dos descriptores utilizados, (iv) é menos sensível à qualidade das amostras de treinamento e ruído [Puissant et al. 2014], (v) é robusto a *outliers* (entradas com assinaturas abruptas) e *overfitting* (quando o modelo aprende em demasia se tornando rígido a variabilidade de novas entradas), mesmo que o número de árvores de decisão que o compõe aumente [Özçift 2011], e (vi) é adequado para problemas onde a dimensionalidade do espaço de hipóteses é muito amplo ou correlacionados [Belgiu & Drăgu 2016].

Embora o algoritmo RF por base seja robusto para classificação em ambientes ambíguos, icebergs observados em imagens SAR apresentam sobreposições em todas as classes de descriptores utilizadas em decorrência de oscilações externas que resultam em um comportamento pseudoaleatório. Neste sentido, construímos uma abordagem meta-ensemble (ensemble de ensemble – **Figura 30**), na qual um Comitê de RF (*Random Forest Committee*) é construído a partir da fusão de distintos

classificadores RF heterogêneos, onde cada classificador RF base contido no comitê é especializado em um domínio específico de descritores, intensidade, textura ou morfo-espacial.

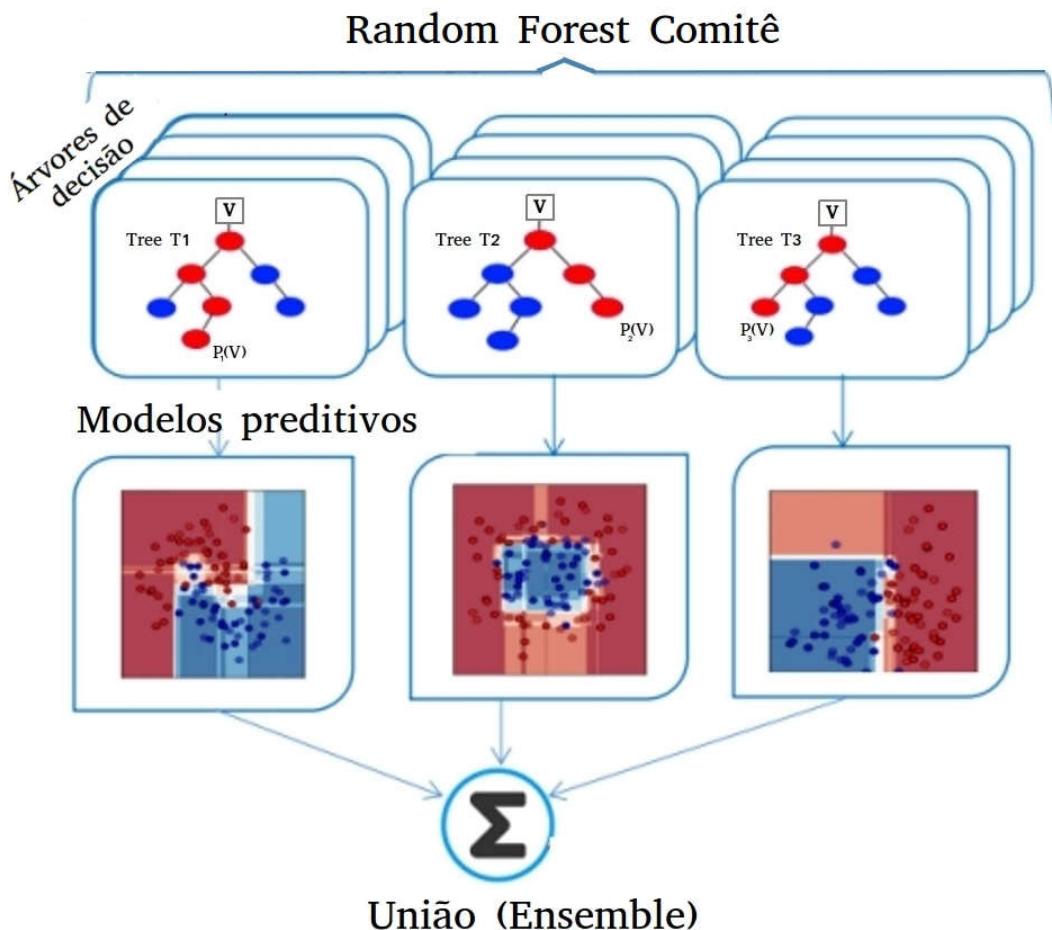


Figura 30. Modelo meta-ensemble proposto, no qual um Comitê de RF (*Random Forest Committee*) é construído a partir da fusão de distintos classificadores RF heterogêneos, cada um especializado em um domínio de descritores: intensidade, textura ou morfo-espacial.

O comitê é definido por cinco classificadores de base:

CFS-RF: Formado utilizando um arranjo com os doze descritores mais representativos definidos na etapa de seleção de descritores, computados utilizando

Correlation-Based Feature Selection (CFS) apresentados na **Tabela 3**. Neste classificador é permitido a união de descritores provenientes de domínios diferentes.

Morpho-RF: Especializado em variabilidades morfológicas e espaciais.

GLCM-RF: Especializado em variabilidade angular de textura no domínio espacial, utilizando descritores estatísticos obtidos através de matrizes co-ocorrência de níveis de cinza.

HistoGabor-RF: Especialista propriedades de textura no domínio espacial e de frequência, usando estatísticas de histograma e de filtro Gabor, respectivamente.

Spectral-RF: Especialista em padrões de variabilidade de cor (escala de cinza) derivado da intensidade do sinal de retroespalhamento (σ_0).

O resultado preditivo ($RF(x)$) do Comitê de RF proposto é construído combinando-se os votos individuais dos cinco classificadores RF usados como membros do comitê. Cada membro base fornece um único voto e um nível de confiança associado a este, indicando assim a probabilidade com que o voto é verdadeiro. O método de união aplicado é definido pela média ponderada dos votos (ponderada pelo nível de confiança) entre os diferentes classificadores base. O comitê de RF fornece uma saída combinada única e também um nível de confiança final associado, computado como:

$$RF(x) = \sum_{i=1}^T w_i h_i(x) \quad (21),$$

onde w_i é o peso associado a uma predição h_i . Os pesos w_i 's são geralmente assumidos e limitados conforme:

$$w_i \geq 0 \text{ e } \sum_{i=1}^T w_i = 1 \quad (22),$$

Supondo que a função verdade capaz de separar todos os objetos é dada por $f(x)$, e x é amostrado de acordo com uma distribuição $p(x)$, e a saída de cada membro do comitê pode ser escrita como o valor verdade adicionado a um erro (ϵ) associado:

$$h_i(x) = f(x) + \epsilon(x), \quad i = 1, \dots, T \quad (23),$$

o erro associado para combinação utilizando voto ponderado pode ser escrito como [Perrone & Cooper 1993]:

$$err(RF) = \int \left(\sum_{i=1}^T w_i h_i(x) - f(x) \right)^2 p(x) dx \quad (24),$$

4.3.3.4. Aprendizado incremental (*Incremental Learning*)

Em abordagens de aprendizado de máquinas do tipo supervisionado, um modelo preditivo $y = F(x)$ é derivado a partir de um conjunto de treinamento T previamente conhecido de rotulado $x \rightarrow y$. No entanto, estabelecer um conjunto de treinamento robusto capaz de representar a variabilidade em um ambiente de múltiplas hipóteses é uma tarefa complicada. Basicamente, o conjunto de treinamento $T(I \times F)$ onde I representa as instâncias de treinamento e F os descritores, deve prover instâncias suficientemente diversificadas e descritores representativos capazes de derivar um modelo apto a predizer sobre novas instâncias, estas não observadas durante o processo de treinamento.

Embora a estratégia supervisionada seja amplamente aplicada a diferentes problemas de aprendizado de máquina devido ao seu desempenho e flexibilidade

derivados um conjunto de treinamento pré-condicionado e rotulado. Construir, manualmente, um conjunto de treinamento constitui uma tarefa onerosa, exigindo horas para um especialista fornecer instâncias diversificadas capazes de derivar um modelo preditivo robusto. Não o bastante, dois problemas intrínsecos ao processo de treinamento devem ser constantemente monitorados e evitados: sobre-ajuste (*Overfitting*) e sub-ajuste (*Underfitting*). Sobre-ajuste acontece quando o modelo preditivo se torna específico em excesso, aprendendo detalhes e/ou ruído do conjunto de treinamento. Em contrapartida, o sub-ajuste resulta quando o conjunto de treinamento não proporciona instâncias suficientemente descritivas para induzir um modelo preditivo capaz de inferir coerentemente. Ambos sobre e sub ajustes geralmente são resultantes de inconsistências no conjunto de treinamento como número escasso e/ou pouco diversificado de instâncias ou descritores não representativos [Alpaydın 2012, Zhou 2012].

Neste sentido, observando que icebergs e demais elementos de fundo presentes em imagens SAR contêm um índice elevado de escalas de variabilidade em suas assinaturas de imagem. O que resulta em um amplo espectro de padrões de imagem que, geralmente, não são contemplados por conjuntos de treinamento definidos manualmente, além de inviabilizar a utilização de métodos não-supervisionados. Adotou-se uma abordagem incremental de aprendizagem conhecida como aprendizado em lote [Impoco & Tuminello 2015], principalmente, devido à sua versatilidade e desempenho para se adaptar às novas amostras (instâncias) introduzidas dinamicamente ao conjunto de treinamento, sem interferência manual. Desta forma, novas instâncias validadas com alto nível de confiança de todos os membros do comitê (conjunto de classificadores) são gradualmente incorporadas ao conjunto de treinamento automaticamente, adaptando

os modelos preditivos a novas amostras posteriormente. Este procedimento é ilustrado na **Figura 31**.

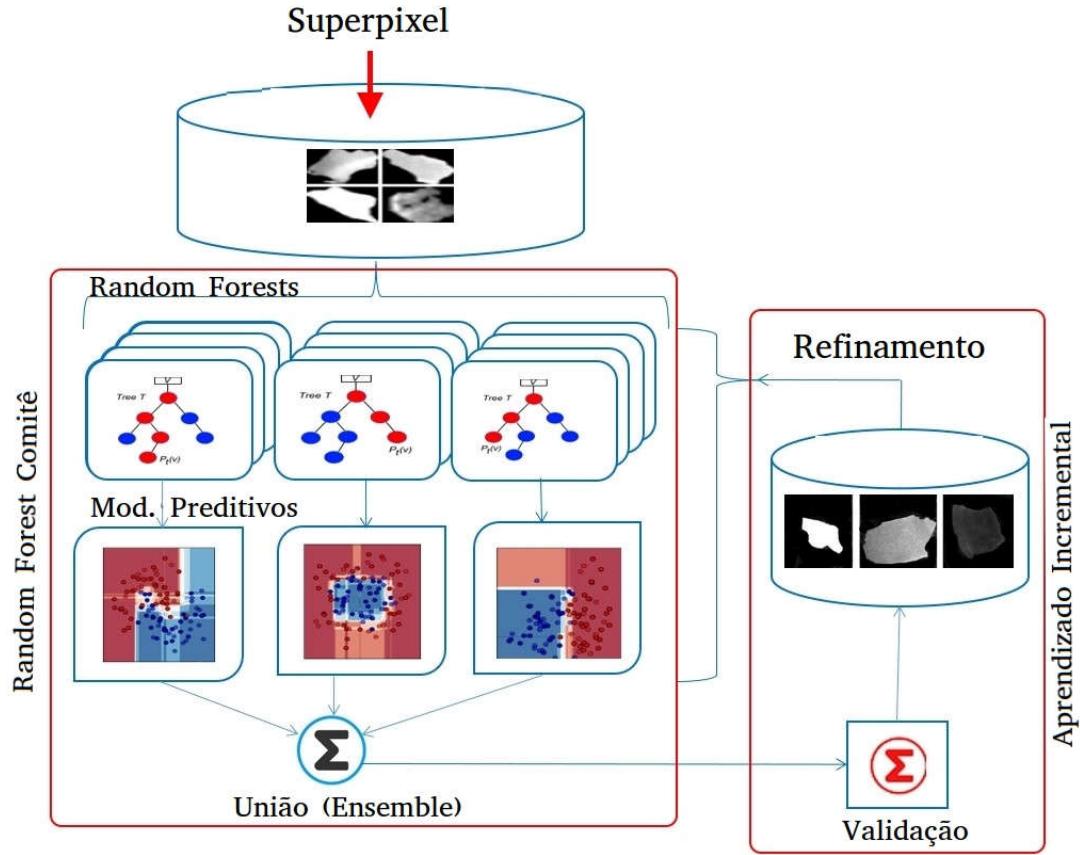


Figura 31. Representação do processo de aprendizado proposto utilizando comitê de máquinas e aprendizado incremental.

Na prática, a abordagem de aprendizagem proposta começa com uma hipótese inicial resultante de um conjunto de treinamento básico derivado por seleção manual contendo 100 instâncias (50 icebergs e 50 não-icebergs), preenchendo alguns requisitos: (i) deve apresentar grau elevado de diversidade conforme as principais assinaturas observadas em imagens SAR em decorrência de variabilidades do sensor (i.e. polarização, órbita, ângulo de incidência), atmosféricas ou oceanográficas, (ii) o total de amostras de treinamento deve ser equilibrado em

ambas as classes (iceberg e não-iceberg) e (iii) amostras de treinamento e validação devem ser distintas sem intersecções.

Nas etapas subsequentes, os icebergs e elementos de fundo que foram classificados em rodadas anteriores são usados como referência para rotular novas amostras. Gradualmente, um operador de avaliação recebe feedback sobre as novas amostras classificadas a partir do nível de confiança dos classificadores e verifica o ganho de informação do candidato (amostra) para o conjunto de treinamento aplicando validação cruzada do tipo *k-fold* [Kirschen et al. 1995, Cutler et al. 2007, Arlot & Celisse 2010, Zhou 2012]. Fluxograma apresentado na **Figura 32**.

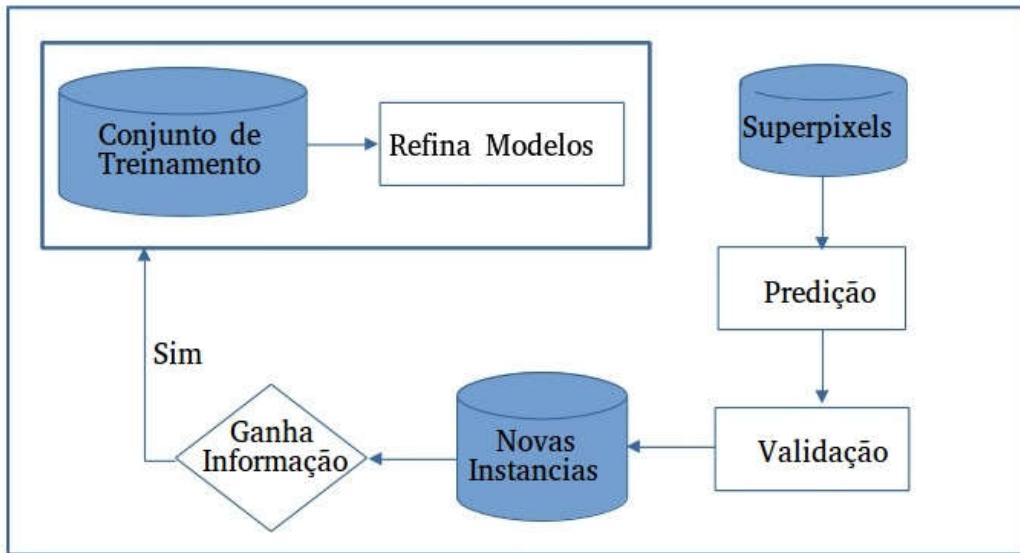


Figura 32. Fluxograma referente a abordagem de aprendizado incremental proposta.

O método de validação cruzada por *k-fold* é um método estatístico para avaliar a qualidade de um modelo de predição dividindo o conjunto de instâncias em dois segmentos, um para treinamento e outro para validação. Na prática, o método cria diversos subgrupos (*k-folds*) e os intercala testando distintas métricas de qualidade de modelo preditivo como precisão e falso positivos em relação aos diferentes

subconjuntos de validação em um número definido de rodadas de teste [Kirschen et al. 2000].

Para esta abordagem, se a precisão do modelo a partir do novo conjunto de amostras aumentar, o novo modelo é usado. Desta forma, a ampla variabilidade capturada pelas imagens SAR é adicionada ao conjunto de treinamento dinamicamente, permitindo que o mesmo conjunto de treinamento seja usado em diferentes conjuntos de dados SAR com desempenho satisfatório. O desempenho total dos modelos preditivos pode variar dependendo do nível de variabilidade entre conjuntos de dados distintos. No entanto, uma vez que a abordagem incremental começa a receber novas amostras, o desempenho tende a se estabilizar.

4.3.4. Pós classificação, metadados e estatísticas

Após a conclusão do processo de classificação, um banco de dados é alimentado com as principais métricas individuais e coletivas dos icebergs identificados. Incluindo rótulo individual único (ID), geolocalização, classe de tamanho, área, volume e massa e informações de cena como número de objetos identificados, número total de icebergs, área inspecionada e densidade de iceberg por área. Os dados individuais são derivados de métricas básicas baseadas nas propriedades espaciais dos Superpixels (SP) (área, perímetro, eixo principal, eixo secundário e centroid) da seguinte forma:

1. **ID:** Para cada iceberg é definido um único código de identificação (DATA_IMGID_ICE_ID). Onde DATA é referente a imagem base, IMGID é a união da data e horário de aquisição, ICE define que se trata de um iceberg e por fim ID é o identificador sequencial referente ao iceberg detectado na cena inspecionada.

2. **Geolocalização:** Computadas a partir da coordenada central (centroid) do superpixel (x, y) e das propriedades geoespaciais da cena, conforme:

$$\begin{aligned} \text{latitude} &= d \times x + e \times y + yoff \\ \text{longitude} &= a \times x + b \times y + xoff \end{aligned} \quad (25),$$

onde $xoff$ e $yoff$ caracterizam o canto superior esquerdo da imagem, a e e a largura e altura do pixel respectivamente e b e d a rotação, sendo 0 se a imagem estiver sentido norte (*north up*).

3. **Classe de tamanho:** Categorizados de acordo com o comprimento do eixo horizontal principal como growler ($0 - 5m$), bergy bit ($5 - 15m$), pequeno ($15 - 60m$), médio ($60 - 120m$), grande ($120 - 220m$), muito grande ($220m - 18.5km$) e Giant ($> 18.5km$).

$$\text{SizeClass}_{\text{iceberg}} = \text{MajorAxis} \times \text{pixelSize}_m \quad (26),$$

4. **Área:** Estimados a partir da área horizontal e do perímetro do superpixel (sp).

$$\text{area}_{km^2} = \left(\left(\text{sp_area}_{\text{pixels}} - \left(\frac{\text{sp_perimeter}_{\text{pixels}}}{2} \right) \right) \times \text{pixelSize}_{m^2} \right) \times 10^{-6} \quad (27),$$

onde $\text{sp_area}_{\text{pixels}}$ representa a área horizontal do superpixel (segmento) e $\text{sp_perimeter}_{\text{pixels}}$ o comprimento do perímetro em pixels. Metade do perímetro é removido, uma vez que esses pixels definem a área limítrofe entre iceberg e seus arredores.

5. **Volume:** Considerando que a altura o eixo vertical é variável conforme o tamanho e a região de origem dos icebergs (geleiras, plataformas flutuantes ou icebergs maiores), estabelecemos comprimentos fixos baseados no comprimento médio

de eixo vertical sugerido por classe de tamanho (**Tabela 1**) e para icebergs gigantes o comprimento conservativo de 250m foi adotado, assumindo um erro médio de ~36% [Jacobs & Hellmer 1992] consistente com estudos prévios [Gladstone et al. 2001, Wesche & Dierking 2012, Rackow et al. 2017].

$$Volume_{iceberg} = Area_{iceberg} \times EV \quad (28),$$

onde *EV* corresponde ao comprimento médio de eixo vertical associado a classe de tamanho do iceberg (**Tabela 1**) ou 250 para icebergs gigantes.

6. **Massa:** Assumido densidade (ρ) de 858 kg/m^3 para icebergs com classe de tamanho 10-400m e 883 kg/m^3 para classes superiores 400m [Jacka & Giles 2007].

$$Massa_{iceberg} = Volume_{iceberg} \times \rho \quad (29),$$

4.3.5. Rastreamento de icebergs a partir de imagens SAR

O monitoramento de icebergs através de imagens SAR é resultante da captura e armazenamento da variabilidade espaço-temporal destes objetos em diferentes cenas. Para isto, de modo a viabilizar o monitoramento de icebergs ao longo de sua trajetória de deriva é mandatório que os objetos em questão possam ser individualizados através de uma assinatura única, de forma que estes possam ser reconhecidos em diferentes posições geográficas e datas em meio a tantos outros objetos semelhantes.

Para cada iceberg uma assinatura única é definida com base em suas propriedades morfo-espaciais, uma vez que estas são mais conservativas ao longo

do tempo quando comparadas com propriedades baseadas em intensidade de pixel ou padrões de textura. Neste sentido, mesmo que embora fratura, desintegração ou rolamento sejam possíveis de acontecer, a variabilidade imposta por estes fenômenos é relativamente periódica e determinística ao contrário da variabilidade pseudoaleatória imposta por parâmetros baseados em coeficiente de retroespalhamento que tendem a oscilar sujeitos a dinâmica oceânica, atmosférica e de composição do iceberg.

Na prática, todas as propriedades morfo-espaciais são computadas diretamente dos Superpixels definidos na fase de segmentação e posteriormente classificados como icebergs. Ao todo, cinco parâmetros são empregados para construção da assinatura individual de cada iceberg: eixos principal e secundário, perímetro, área e forma. A forma é o principal parâmetro utilizado, computada com base na distância entre o centro do iceberg (centroid) e seu perímetro externo (**Equação (30)**), seguindo o contorno do iceberg em 360°, conforme exemplificado na

Figura 33.

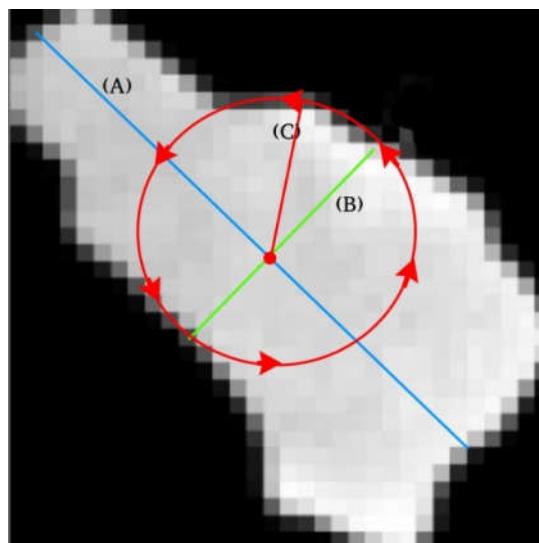


Figura 33. Ilustração dos descritores utilizados para rastreamento. (A) eixo principal, (B) eixo secundário, (C) representa a distância entre o centro do iceberg e seu limite externo (parâmetro computado em 360° sentido anti-horário).

$$d = (X_{perimetro} - X_{centroid})/\cos(\theta) \text{ ou} \\ d = (Y_{perimetro} - Y_{centroid})/\sin(\theta) \quad (30),$$

Na sequência, um vetor unidimensional contendo o conjunto de parâmetros é construído e ordenado, criando assim uma assinatura (sinal digital) invariável à rotação e robusta ao ruído, semelhante à abordagem usada por Silva & Bigg [2005]. Para o rastreamento, é feito o cruzamento entre as assinaturas de icebergs em pares, testando a semelhança entre os sinais, através de três métricas de semelhança computados:

Correlação cruzada: amplamente aplicada no processamento digital de sinais [Zhang et al. 2003, Kohn 2005, Hale 2006, Liu et al. 2018]. Aplicamos correlação cruzada para medir mudanças relativas entre os pares de sinal. Considerando dois sinais 1-D f e g , a correlação cruzada é definida por:

$$c(u) = (f * g)(u) \equiv \int_{-\infty}^{\infty} dx f(x)g(x+u) \quad (31),$$

onde u representa o atraso na correlação cruzada entre os sinais.

Distância de Jaccard: considerando dois sinais f e g , com o mesmo comprimento. Distância de Jaccard mede a relação entre o número de blocos que são comuns a ambos os sinais [Niwattanakul et al. 2013, Vorontsov et al. 2013, Santisteban & Tejada Carcamo 2015]. Medida pertinente para objetos passíveis a fragmentar.

$$Jaccard(f, g) = \frac{|f \cap g|}{|f \cup g|} \quad (32),$$

Distância euclidiana: Considerando dois sinais f e g , com o mesmo comprimento (N). A distância euclidiana representa o comprimento entre cada ponto do sinal [Barrett 2005, Liwei Wang et al. 2005].

$$d(f, g) = \sqrt{\sum_{i=1}^N (f_i - g_i)^2} \quad (33),$$

Na sequência, para que um cruzamento de pares seja aceito alguns requisitos mínimos devem ser cumpridos:

- Um limite mínimo de similaridade de 80% para todas as métricas de semelhança.
- Os pares cruzados de icebergs devem estar dentro de um raio de distância máxima (km), estabelecido com base na velocidade média de deriva por classe de tamanho [Bigg et al. 1997, Gladstone et al. 2001, Gladstone & Bigg 2002, Schodlok et al. 2006, Collares et al. 2018]. Esta é uma heurística fraca, entretanto, permite que erros óbvios observados na relação entre distância e tempo de deriva sejam removidos.
- Uma diferença de tempo máxima de 60 dias entre os pares foi definida a fim de evitar variações abruptas na forma do objeto e também reduzir a exigência do limite do raio máximo, visto que os padrões de deriva de icebergs usualmente não são lineares.

Por fim, os pares aceitos são removidos da busca e recursivamente para cada nova detecção dentro da trajetória a assinatura do iceberg referente a posição anterior é atualizada, uma vez que as propriedades morfo-espaciais do iceberg podem variar ao longo da deriva.

4.3.5.1. Estimativa de velocidade

Para esta abordagem de rastreamento, a velocidade de deriva dos icebergs é estimada com base na translação entre as coordenadas centrais dos objetos rastreados e no intervalo de tempo.

Neste sentido, a velocidade é computada a partir da distância euclidiana em quilômetros entre as posições centrais (em latitude e longitude) de pontos consecutivos de detecção do mesmo iceberg com uma data (dd/mm/aa) associada. Desta forma, a velocidade em ($km\ d^{-1}$) é computada dividindo a distância percorrida pelo intervalo de tempo em dias entre os pontos consecutivos, semelhante a abordagem aplicada em trabalhos anteriores [Gladstone & Bigg 2002, Schodlok et al. 2006, Collares et al. 2015, 2018].

Por fim, a velocidade média de deriva do iceberg ao longo de sua trajetória é estimada pela média de cada velocidade calculada entre os pares de pontos consecutivos ponderadas pelo tempo rastreado de cada iceberg.

Capítulo V: Resultados científicos

5.1. Artigo1: *An adaptive machine learning approach to improve automatic iceberg detection from SAR images*

O primeiro artigo, de autoria de Mauro M. Barbat, Christine Wesche, Adriano V. Werlhi e Mauricio M. Mata, é intitulado “***An adaptive machine learning approach to improve automatic iceberg detection from SAR images***” e encontra-se publicado no periódico “***ISPRS Journal of Photogrammetry and Remote Sensing***”, volume 156 (2019), páginas 247-259.
<https://doi.org/10.1016/j.isprsjprs.2019.08.015>.

5.1.1. Síntese do artigo 1

Neste artigo é apresentado e descrito um método original para detecção e monitoramento automático de icebergs em larga escala através de uma arquitetura alternativa de aprendizado de máquina com aplicação à imagens de alta resolução derivadas de radar de abertura sintética (*Synthetic Aperture Radar - SAR*). O método é baseado no conceito de adaptabilidade, com foco na melhoria do desempenho para a identificação automática de icebergs em contextos ambíguos com ampla variabilidade radiométrica (cor), textural, de tamanho e de forma tanto de icebergs quanto demais objetos pertencentes a cena. Desta forma, melhora-se a estimativa de área/massa de icebergs a partir de $0,1 \text{ km}^2$ de área superficial mesmo em condições ambientais desafiadoras, atingindo acurácia média de $97 \pm 0,6\%$, taxa de falso positivos de $2,3 \pm 0,4\%$ e de perdas de $3,3 \pm 0,4\%$.

Os resultados descritos neste artigo apresentam notáveis avanços em comparação a abordagens recorrentes descritas na literatura, estas frequentemente, baseadas em limiares de coeficiente de retro-espalhamento. Finalmente, o artigo discute as vantagens e desvantagens da arquitetura adaptativa proposta de aprendizado de máquina em relação a modelos lineares usualmente aplicados para separar icebergs do plano de fundo.

An adaptive machine learning approach to improve automatic iceberg detection from SAR images

Barbat, Mauro M.¹, Wesche, Christine³, Werhli, Adriano V.² and Mata, Mauricio M.¹

¹Institute of Oceanography, Federal University of Rio Grande-FURG, Rio Grande-RS, 96203-900, Brazil

²Computer Science Centre, Federal University of Rio Grande-FURG, Rio Grande-RS, 96203-900, Brazil

³Alfred Wegener Institute for Polar and Marine Research-AWI, Bremerhaven, 27570, Germany

Correspondence to: Barbat, Mauro M. (maurobarbat@furg.br)

Keywords: Icebergs, Detection, SAR, Southern Ocean, Machine learning

5.1.2. Abstract

Iceberg distribution, dispersion and melting patterns are fundamental aspects in the balance of heat and freshwater in the Southern Ocean; yet these features are not fully understood. This lack of understanding is, in part, due to the difficulties in accurately identifying icebergs in different environmental conditions. To improve the understanding, reliable iceberg detection tools are necessary to achieve a detailed picture of iceberg drift and disintegration patterns, and thus to gain further information on the freshwater input into the Southern Ocean. Here, we present an accurate automatic large-scale iceberg detection method using an alternative machine learning architecture applied to high resolution Synthetic Aperture Radar (SAR) images. Our method is based on the concept of adaptability and focuses on improving the performance of identifying icebergs in ambiguous environmental contexts with wide radiometric, textural, size and shape variability. The fundamentals of the method are

centred on superpixel segmentation, ensemble learning and incremental learning. The method is applied to a dataset containing 586 ENVISAT Advanced SAR images acquired during 2003-2005 (Weddell Sea region) and to the Radarsat-1 Antarctic Mapping Project (RAMP) mosaic, covering the Antarctic wide near-coastal zone. These images cover scenes under heterogenous backscattering signatures for all seasons with variable meteorological, oceanographic and acquisition parameters (e.g. band, polarization). Our method is highly adaptable to distinguish icebergs from ambiguous objects hidden in the images. The average false positive rate and miss rate are $2.3 \pm 0.4\%$ and $3.3 \pm 0.4\%$, respectively. Overall, 9512 icebergs with sizes varying from 0.1 - 4567.82 km 2 are detected with average classification accuracy of $97.5 \pm 0.6\%$. The results confirm that the method presented here is robust for widespread iceberg detection in the Antarctic seas.

5.1.3. Introduction

Glacial ice fragments, from few meters (growler, bergy bit) up to dozens of kilometres (Jackson and Apel, 2005, pp. 411; Williams et al. 1999), are able to drift away from their region of origin, subject to fractures and gradual melting associated with water temperature, wave action, ocean currents and wind regime (Bigg et al. 1997). Starting from 15 m length, those fragments are known as icebergs (Jackson and Apel, 2005, pp. 411) and can cause substantial impacts on the global climate and ocean dynamics and circulation. The freshwater flux from iceberg melting plays an important role in disrupting temperature and salinity patterns (Schodlok et al. 2006; Romanov et al. 2008; Stern et al. 2016) and may affect the ocean's biological activity, carbon uptake, sea-ice, ocean circulation and deep-water formation (Silva and Bigg,

2005; Silva et al. 2006; Schodlok et al. 2006; Schwarz and Schodlok, 2009; Shaw et al. 2011; Stern et al, 2016). However, little is known about icebergs' individual trajectories and the amount of freshwater exported to the open ocean due to their melting (Silva and Bigg, 2005; Mazur et al. 2017). There are relevant studies on the iceberg's trajectories (e.g. Schodlok et al. 2005; Jansen et al. 2007; Bouhier et al, 2018), but those are limited to single icebergs or small regions of the Southern Ocean. One of the main issues regarding Southern Ocean observational, modelling, and remote sensing efforts is related to the complexity of identification and monitoring of icebergs (e.g. Jacka and Giles, 2007; Romanov et al. 2012; Wesche and Dierking, 2012; Stern et al. 2016). Satellite data, such as Synthetic Aperture Radar (SAR) images, are derived from an active principle of emission of microwaves and have advantages to avoid contamination from the dense clouds that are ubiquitous in the polar seas. SAR technique is capable of penetrating the dense polar atmosphere under adverse weather conditions even at night (Marino et al. 2016). Furthermore, SAR data provide high spatial and temporal coverage on Antarctica since 1991 and has become a standard dataset for iceberg, glaciers and sea ice research.

Although SAR products provide a useful tool to study the polar environment, in most cases the iceberg signatures in those radar-derived images are not unambiguous with respect to the background. Oscillations in backscatter intensity, attributed to weather conditions, sea state and the presence of sea ice, rough water, and snow-covered islands, can produce similar and ambiguous signatures between icebergs and their surroundings. **Figure 1** shows a typical example of SAR images where variable features coexist in the same image. Rectangles A, D, E, F in **Figure 1** give examples of clusters of small icebergs surrounded by ice-melange (mix of iceberg, snow and sea ice) and sea ice, presenting low intensity (signal) contrast,

hence lacking sharp boundary definition. Rectangles B, C, D give examples of iceberg spectral (gray-level intensity), textural and morphological heterogeneity, and G, H give examples of drifting multiyear fast ice with similar radar signature compared to darker icebergs. Therefore, icebergs have high likelihood to be mistakenly identified from other coexisting features in SAR images. This makes an accurate identification of icebergs in SAR images a complex, challenging and necessary task. To our best knowledge, the differentiation of icebergs from other features in SAR images has relied for a long time on empirical relationships of surface and backscatter intensity expressed by probability density functions, essentially applying linear models to separate icebergs from the background (e.g. Williams et al. 1999; Silva and Bigg, 2005; Wesche and Dierking, 2012). Many studies on iceberg detection using SAR imagery were published in the last decades and we briefly highlight only the most relevant to the present study. Williams et al. (1999) focused on edge detection using image texture and contrast properties, followed by a pixel bonding segmentation to separate icebergs from the background. The differences between the backscattering intensities of icebergs and their surroundings were used by Silva and Bigg (2005) and Wesche and Dierking (2012). The method presented by Frost et al (2016) uses a Constant False Alarm Rate (CFAR) by constantly computing false alarm probabilities based on the assumption given by the user about expected probability density function of the backscatter intensity in the observed region. Methods using polarimetric SAR data have also been tested (Dierking and Wesche, 2014; Marino et al. 2016). Nevertheless, polarimetric data are very limited in availability and spatial coverage. In a recent study, Mazur et al. (2017) developed a method based on brightness and spatial parameters computed from five scale levels of segmentation in that area.

Nevertheless, all these methods rely on empirical relations of the backscatter intensities which can be violated in different situations (Wesche and Dierking, 2015). This limitation constraints the use of a reliable screening procedure that performs iceberg identification automatically and universally. Hours of visual inspection appears to be the only way to improve detection performance, so an accurate automatic iceberg detection method is a demanding and necessary tool for many applications.

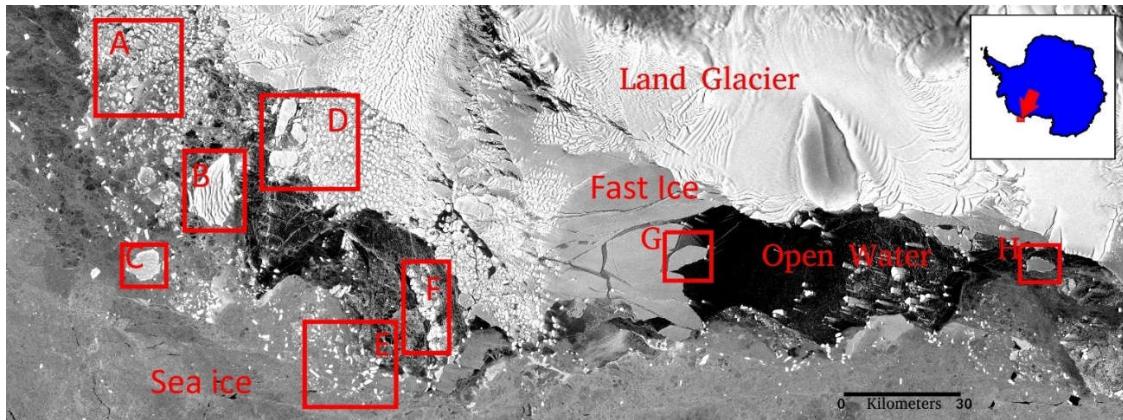


Figure 1. Example of a SAR scene with large spectral, textural and morphological variability. [Rectangles A, D, E, F] give examples of clusters of small icebergs surrounded by ice-mélange (mix of iceberg, snow and sea ice), presenting low intensity contrast and lacking boundary definition. Rectangles [B, C] give an example of iceberg spectral (grey level intensity), textural and morphological heterogeneity, and [G, H] give an example of drifting fast ice and free sea ice with similar dark iceberg radar signature.

In general, accurate iceberg identification relies on the performance of distinguishing icebergs from open water or sea ice under different meteorological, sea state or iceberg surface conditions. These conditions result in substantial variations from highly bright to dark objects shown in the derived images. This variable spectral behaviour along with changing textural and morphological patterns makes it difficult to establish a general predictive model applicable to differentiate icebergs from coexisting features in SAR images, hence supporting the need for adaptive approaches.

In this sense, we propose an alternative pixel-based machine learning architecture, which employs an intuitive solution to address the aforementioned problem. Essentially, the method relies on using the predictions derived from different models based on various image properties, instead of using output from only one model. As the main result of this approach, the ability to predict multi-modal objects is strongly improved, thus reducing the instability of individual classifiers and increasing versatility to adapt to new samples, even outliers.

In the subsequent sections, we present the dataset used in this study and describe the proposed machine learning architecture and performance evaluation metrics, followed by the results and a thorough performance evaluation of the method. The final two sections bring a detailed discussion of the results and the conclusions, which summarize and complete this study.

5.1.4. Data

We introduced two distinct datasets to evaluate the performance of our proposed method. The first dataset is the 586 Envisat ASAR (Advanced Synthetic Aperture Radar) WSM (Wide Swath Mode - 400 km wide range) medium resolution (pixel size 75m x 75m) images (ASA_WSM_1P), acquired at C-Band (5.3 GHz, wave length ~5.6 cm) and HH polarization (Envisat ASAR Product Handbook, 2007) during 2003-2005. The main observation area is the Weddell Sea (centred at 70° S, 45° W) for all seasons. The second dataset is the RAMP AMM-1 amplitude mosaic, constructed from over 3000 individual frames acquired by the Canadian Radarsat-1 in C-Band at a pixel size of 25m x 25m (resampled onto 100m x 100m resolution) during September-October of 1997 for the Antarctic wide near-coastal zone (Jezek et

al. 1998). All images were (i) calibrated (each pixel intensity (grayscale) can be directly related to the radar backscatter strength; Rosich and Meadows, 2004), (ii) re-projected onto EPSG:3031 WGS 84 / Antarctic Polar Stereographic projection (Latitude of origin -90°, Central meridian 0°, Standard parallel -71°), (iii) speckle reduced with a Lee-Sigma filter (Lee, 1981; Lee, 1983), (iv) land data removed, and (v) converted into 8-bit unsigned integer Geotiff images. Both datasets add up to approximately 7 TByte of data storage.

5.1.5. Method

Our proposed method is based on the grid-graph-based superpixel segmentation (Felzenszwalb and Huttenlocher, 2004), ensemble learning (Zhou, 2012) and incremental learning (Polikar, 2006). An overview of our method is presented in **Figure 2**, where we show of the main characteristics of our architecture and the roles of the three backbone methodologies cited above. Further details will be explained in the following subsections. In order to individualize the different objects that are present in the scenes, the graph-based superpixel segmentation captures redundancies by reducing the high-resolution pixel space to a set of meaningful homogeneous regions. It also preserves details in low-variability image regions, while ignoring details in high-variability regions. Random Forest Committee is an ensemble learning method that uses a set of Random Forest classifiers (Breiman, 2001) as base learner, based on different arrangements of image features. Polikar's (2006) incremental learning improves the distinct predictive models by the incremental addition of new samples and refines the models continuously rather than having a one-shot training phase.

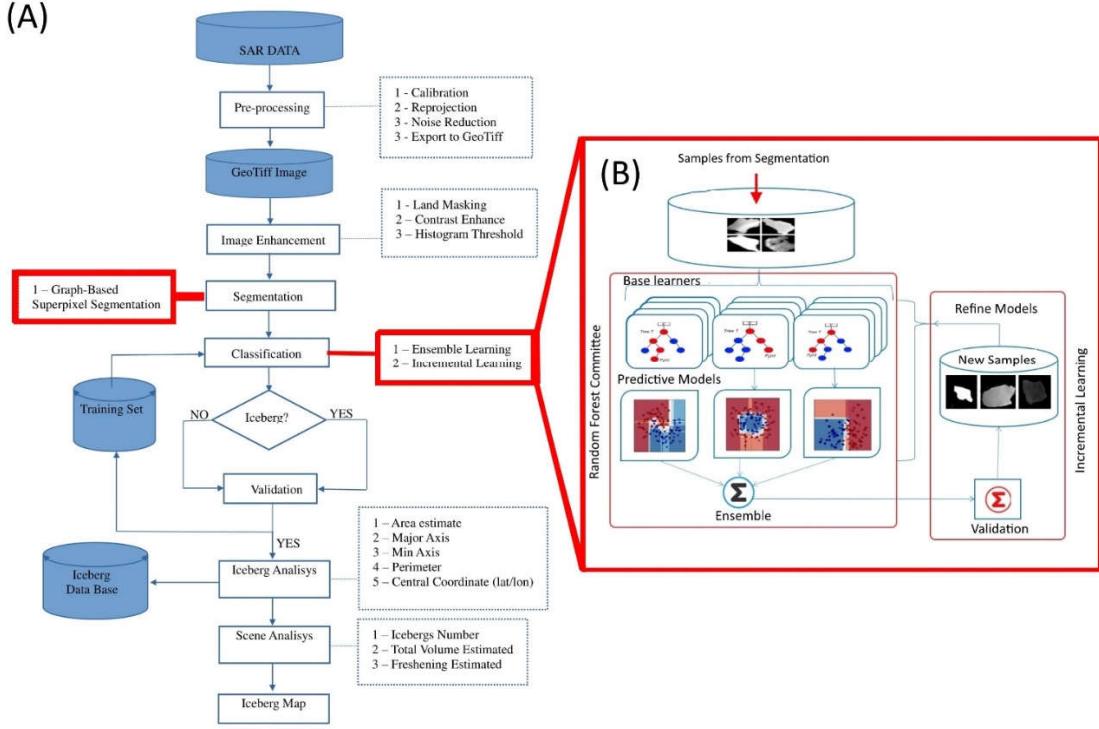


Figure 2. Overview of the proposed detection method architecture. Panel (A) shows an overview of the detection framework. The red rectangles highlight the superpixel segmentation, ensemble learning and incremental learning stages. Panel (B) is a zoom-in in the classification stage disclosing the machine learning architecture, exposing ensemble learning and incremental learning.

5.1.5.1. Segmentation

The detection of icebergs in SAR imagery requires a separation of each individual iceberg and a reliable description of the backscattering behaviour of each object using the image features. Superpixel algorithms are capable to capture image redundancies and group single pixels into perceptually meaningful atomic regions (Achanta et al. 2011). It provides a convenient basis to compute image features, spatial properties and reduces the complexity of subsequent image processing tasks by decreasing the rigid pixel grid structure to a set of atomic regions (Achanta et al. 2010; Zhang et al. 2017).

There are different variants of superpixel segmentation algorithms (Comaniciu and Meer, 2002; Felzenszwalb and Huttenlocher, 2004; Veldadi and Soatto, 2008;

Achanta et al. 2010 and Zhengqin et al. 2015). Operationally, we particularly aim to individualize possible icebergs in SAR images under such conditions: (i) icebergs can appear partially connected to one or more objects, (ii) plausible icebergs present very low contrast to the background, (iii) icebergs can appear in a wide range of sizes and (iv) adherence to iceberg boundaries is of paramount importance to allow to compute spatial metadata. In this sense, we conducted a series of experiments to evaluate computational efficiency and the performance of preserving shape details in complex targets. We found that the graph-based segmentation proposed by Felzenszwalb and Huttenlocher (2004) has the best performance for our task. In practice, the superpixel graph-based method performs simple greedy decisions based on three parameters (settings used in this study are within parentheses): (i) scale – sets the observation level, higher means less and bigger segments (50); (ii) sigma – performs a median filter over the image (0); and (iii) minimal size – minimum number of pixels to create a single segment (10). The goal is to produce a cluster of pixels as nodes on a graph. Each node (segment) is recursively adjusted considering a minimum distance (L), defined as $L(v_i, v_j) = |I(p_i) - I(p_j)|$, where $L(v_i, v_j)$ is the edge distance between the nodes v_i and v_j . $I(p_i) - I(p_j)$ is the Euclidean distance, in terms of pixel intensity, between each pixel inside the node and its neighborhood. The number of detected segments is directly associated to the image contrast and can be indirectly controlled by the scale parameter. For more information on the segmentation technique used here it is referred to Felzenszwalb and Huttenlocher (2004).

After the initial segmentation, usually large icebergs with a wide horizontal area can present a wide textural gradient resulting in over segmentation (segments inside bigger segments). To reduce these inconsistencies, we gradually merge the similar segments hierarchically using the Region Adjacency Graph (RAG) technique

(Tremeau and Colantoni, 2000), applying an intensity distance threshold of 15% defined by several tests. This produces superpixels that adhere well to the limits of icebergs, even if they have irregular geometry and/or large surface texture gradient. It also allows us to estimate the iceberg area based on the superpixel spatial properties as:

$$area_{km^2} = \left(\left(sp_area_{pixels} - \left(\frac{sp_perimeter_{pixels}}{2} \right) \right) \times pixelSize_{m^2} \right) \times 10^{-6} \quad (1)$$

where *sp_area* is the superpixel horizontal area and *sp_perimeter* is the superpixel perimeter size. Half of the perimeter size is removed since those pixels define the bordering area between iceberg and its surroundings. **Figure 3** shows an example of segmentation applying Felzenszwalb and Huttenlocher (2004) method on a SAR image (panel A) where the red lines in panel (B) define the segmentation boundaries. It is possible to observe the adherence of the segments boundaries to the shape of the different objects present in the image, panel (C) shows a detailed view in icebergs segmented by the method.

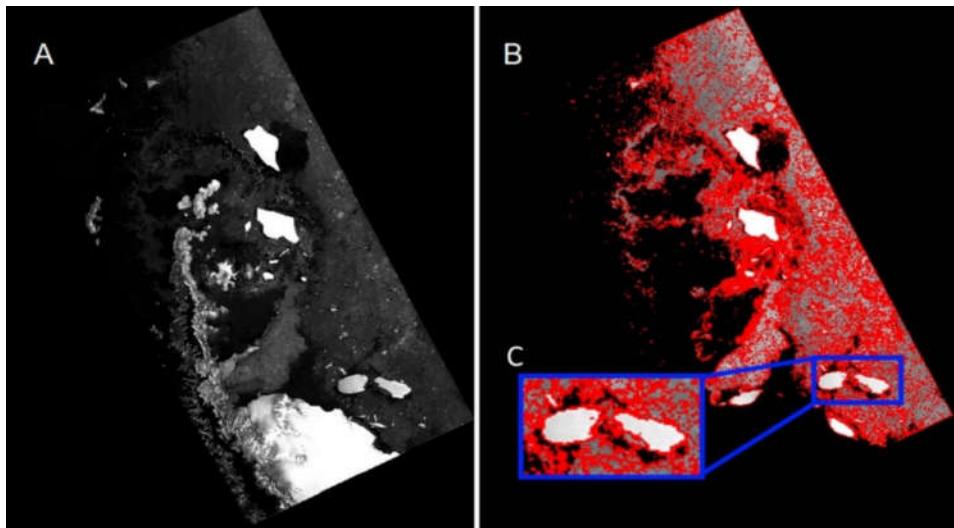


Figure 3. Segmentation applying Felzenszwalb and Huttenlocher (2004) method to a SAR image (panel A). Red lines (panel B) defines the segmentation boundaries. Panel (C) zoom in icebergs segmented by the method.

5.1.5.2. Image features selection

Variations of backscattering signatures from icebergs, sea ice and open water surface caused by environmental conditions often result in objects with wide radiometric variability. The radar backscattering coefficient (σ^0) of an iceberg is the sum of surface and volume contributions (Wesche and Dierking, 2012). The surface of icebergs can be covered by snow, firn and/or melt ponds. Additionally, icebergs can roll over, in such case exposing their surface as pure glacial ice, frequently not exhibiting a positive contrast compared to the background. In regions, where the air temperatures are above the melting point, liquid water and/or wet snow on the iceberg surface reduces the volume scattering, resulting in “dark” icebergs (Wesche and Dierking, 2012). Wind roughened open water can have very high backscatter intensity which depends on the wind direction relative to the radar imaging direction (Williams et al. 1999). The backscatter intensity from sea ice increases as it is broken into small floes or it is low-salinity multi-year sea ice (Williams et al. 1999; Gladstone and Bigg, 2002).

Analysing the main variations observed in icebergs and their background from the SAR images, we determined 32 image features for iceberg detection. The aim is to compute a set of image features capable to describe icebergs and background from distinct perspectives. Here, we give a brief overview on the features applied. In addition, Appendix A provides further details on the formal definition of each of those features (with the exception of basic statistics).

- Five statistical spectral variables (mean, standard deviation, median, mode and energy) are used. They are based on pixel intensity derived from the backscatter coefficient (σ^0), which is the most common parameter describing icebergs

(Williams et al. 1999; Gladstone and Bigg, 2002; Wesche and Dierking, 2012; Mazur et al. 2017).

- Seven histogram-based statistical moments (mean, variance, skewness, kurtosis, entropy, mode and slope) are used. They are derived from observing the histogram of an image. They can be specified independently of any real image content by a discrete probability distribution (Blachnik and Laaksonen, 2008). Moreover, these moment parameters are powerful tools to analyse spatial texture characteristics (Chen et al. 2002; Singh and Singh, 2002).
- Two frequency texture features (mean and variance) are used. They are based on a wavelet-based Gabor filter, extracting fine texture measures with translation, rotation, illumination and scale invariance from the spectral energy patterns (Masotti et al. 2008; Mishra et al. 2010; Shihavuddin, 2014; Ismail, et al. 2014).
- Twelve texture measures are derived from three parameters (contrast, homogeneity and dissimilarity) per angle (0° , 45° , 90° and 135°). They are based on the Grey Level Co-occurrence Matrix (GLCM) proposed by Haralick et al. (1973). It is an useful method to provide statistics about texture patterns. Essentially, it counts how many combinations of different grey levels occur in the image in different angles;
- Six morphological features are used. They are based on superpixel shape (i) eccentricity – the ratio of the distance between the two focal points of an ellipse that has the same second-moments as the superpixel region, (ii) equivalent diameter to a circle that has the same area as the superpixel region (roundness), (iii) ratio of pixels in the superpixel to pixels of the convex hull (solidity), (iv) compactness degree (Polsby-Popper test (Polsby and Popper, 1991)), (v)

normalized perimeter index, and (vi) fractal dimension (De Keersmaecker et al. 2003).

5.1.5.3. Ensemble learning

For automatic detection systems, the diversity of objects from the same class causes problems. This is because predictive models (linear or polynomial) usually are not able to separate objects with similar features. In ensemble learning approaches, different predictive models are combined to increase the prediction accuracy, reducing the instability of individual classifiers (Dietterich, 2000). In contrast to ordinary learning approaches, diversity is a fundamental issue in improving the ensemble methods (Zhou, 2012). Intuitively, it is understandable that the individual predictive models must be different to gain from combination. In cases where the hypotheses space is too large to explore, several different hypotheses reduce the risk of choosing the wrong one. Diversity can be achieved with distinct approaches, e.g. manipulating the training samples to generate multiple hypotheses (bagging/bootstrap), training each classifier with a random subset of the training set (Breiman, 2001) or manipulating the input features so that each classifier is trained with a subset of the features space (Eibl and Pfeiffer, 2005). **Figure 4** shows an example of decision boundaries applied over ambiguous objects (adapted from Zhou, 2012).

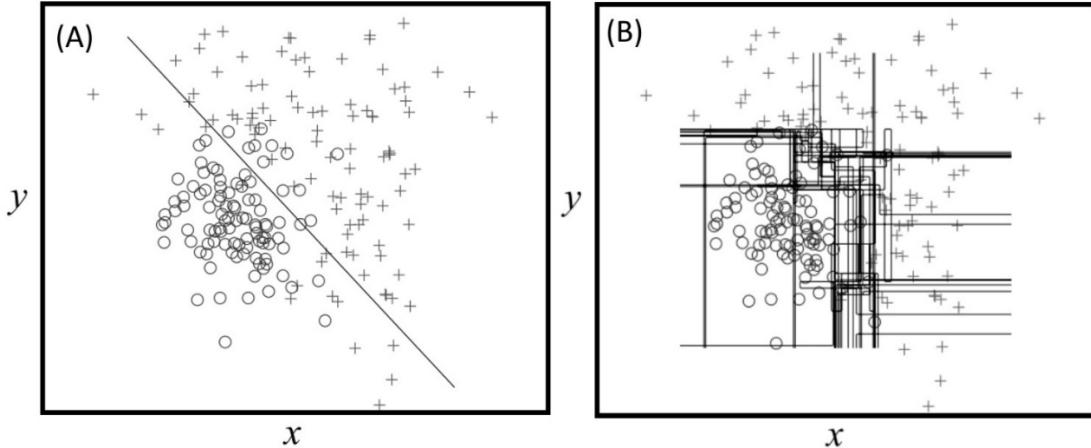


Figure 4. Example of decision boundaries applied over ambiguous objects (adapted from Zhou, 2012). Panel (A) shows a linear predictive model, presenting the classification errors from both targets. Panel (B) shows the RF decision boundaries. Different from linear approaches, the RF is defined through a merge of distinct decision boundaries computed from a set of heterogeneous decision trees based on different arrangements of image features. It results in predictive boundaries which are more flexible, thus leading to a better generalization skill.

Among the classic ensemble classifiers, the non-linear and non-parametric Random Forest (RF) algorithm proposed by Breiman (2001) has been gaining attention and has been widely investigated and applied to distinct problems (Beard, K., 2007, Özçift A., 2011, Hayes et al. 2014, Ghosh et al. 2014; Puissant et al. 2014; Du et al. 2015). The RF algorithm has the following advantages: (i) its efficiency allows the prediction of inputs of different natures (Ghosh et al. 2014), (ii) it presents high computational performance (Gislason et al. 2006; Du et al. 2015), (iii) it allows a feature measure importance, (iv) it is less sensitive to the quality of training samples and noise (Puissant et al. 2014), (v) it is robust to outliers and overfitting, even if the number of trees is increased in the forest (Özçift A., 2011), and (vi) it is suitable to problems where the dimensionality and highly correlated data pose major challenges to other classification methodologies (Belgiu and Dragu, 2016).

In the method proposed here, we constructed a meta-ensemble (an ensemble of ensemble classifiers) approach, where a RF Committee is created from the

combination of a set of heterogeneous RF base classifiers, as illustrated in **Figure 2**.

The committee is defined by five base learners, (i) CFS-RF, using the twelve most representative image features defined by Correlation-based Feature Selection (CFS) (Hall, 1999), presented in Table 1; (ii) Morpho-RF based on morphological features; (iii) GLCM-RF, specialist in textural variation in different angles; (iv) HistoGabor-RF specialist in textural properties in space and frequency domain, using histogram statistics and Gabor features; and (v) Spectral-RF, specialist on statistical intensity features, derived from the radar backscatter intensity.

Table 1 - Feature representability ranked by information gain. Computed by Correlation-based Feature Selection (CFS). 0 means no relevance and 1.0 maximum relevance.

Name	Feature Domain	CFS
GLCM 0 Contrast	Texture	0.563
GLCM 180 Contrast	Texture	0.539
Equivalent diameter	Morphology	0.530
Fractal Dimension	Morphology	0.509
Polsby-Popper	Morphology	0.498
GLCM 270 Contrast	Texture	0.471
Spectral STD	Intensity	0.437
GLCM 90 Contrast	Texture	0.424
Histogram Mean	Texture	0.417
Histogram skewness	Texture	0.417
Histogram kurtosis	Texture	0.414
Histogram Slope	Texture	0.396

The predictive result from the RF Committee is built by combining the individual votes from the five RF classifiers used as base learners. Each RF base learner casts a single vote and its associated confidence level, thus indicating the probability with

which the vote is true. The applied combination method is defined by the weighted average of the votes (weighted by the confidence level) between the different RF classifiers. The RF committee gives the combined output $RF(x)$ as:

$$RF(x) = \sum_{i=1}^T w_i h_i(x) \quad (2)$$

where w_i is the weight for h_i , and the weights w_i 's are usually assumed to be constrained by

$$w_i \geq 0 \text{ and } \sum_{i=1}^T w_i = 1 \quad (3)$$

Supposing that the true function capable to separate all objects is $f(x)$, x is sampled according to a distribution $p(x)$, and the output of each base learner can be written as the true value plus an error:

$$h_i(x) = f(x) + \epsilon(x), \quad i = 1, \dots, T \quad (4)$$

The ensemble error for weighted vote can be write as (Perrone and Cooper, 1993):

$$err(RF) = \int (\sum_{i=1}^T w_i h_i(x) - f(x))^2 p(x) dx \quad (5)$$

5.1.5.4. Incremental learning

Supervised learning approaches are widely applied to machine learning problems, due to their performance and flexibility derived from a predictive model using a preconditioned and labelled training set. However, a manually obtained training set is often time expensive, demanding several hours for an expert to provide diversified instances capable of fitting an accurate predictive model.

Icebergs and background elements from SAR images usually contain different scales of variability and signatures. It results in a wide range of image patterns which is not usually contemplated by the training set. Therefore, we adopted an incremental learning approach known as batch learning mainly due to its versatility and performance to adapt to new samples introduced dynamically to the training set. In this way, new validated (high confidence levels from all committee members) samples are gradually merged into a training set automatically, adapting the predictive models to new samples subsequently (Impoco and Tuminello, 2015).

In practice, the proposed learning approach starts with an initial hypothesis from all base learners given by an initial manually derived training set containing 100 instances (50 icebergs and 50 non-iceberg samples). In the following steps, iceberg and background elements that have been classified in previous rounds are used as reference to label new samples. Gradually, an evaluation operator receives feedback from further new samples and checks the candidate to the new model applying a cross-validation. If the model accuracy and precision increase, the new model is used. In this way, the wide variability captured by SAR images is added into the training set dynamically, allowing the same training set to be used on different SAR datasets with high performance. The full performance of the predictive models can vary depending on the level of variability between distinct datasets, however once the incremental approach starts to receive new samples, performance tends to stabilize.

5.1.6. Performance analysis

The purpose of the method is to improve the performance of automatic iceberg detection in SAR images under large spectral, textural and morphological variability.

Two approaches are used to compute the ensemble/incremental learning performance of iceberg detection in SAR images. First, a visual inspection was performed over five frames with large iceberg density from RAMP AMM-1 mosaic looking for misses and false positives, similar to the approach used by Wesche and Dierking (2015), followed by a comparison of the RF committee performance against the individual classifier's base learner (all using the same training set). We manually set up a test dataset with 1850 samples and computed five machine learning evaluation metrics. Those metrics are achieved by assuming true positives (TP) for correct iceberg, true negatives (TN) for correct non-iceberg, false positives (FP) for incorrect iceberg and false negatives (FN) for incorrect non-iceberg:

1. **Accuracy (ACC):** Returns the rate of correct predictions without differentiating positives from negatives.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

2. **Precision:** Reflects the proportion of predicted positives that are real positives, which is the ratio between the number of icebergs classified correctly and the amount of objects classified as iceberg.

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

3. **Miss rate:** Reflects the probability to miss a positive object, in this case an iceberg.

$$Miss\ rate = 1 - \frac{TP}{TP+FN} \quad (8)$$

4. **False Positive Rate (FPR):** Reflects the probability of false alarms.

$$FPR = 1 - \frac{TN}{TN+FP} \quad (9)$$

5. **Matthews Correlation Coefficient (MCC):** Reports the quality of binary classifications, where 0 indicates random classification and 1 indicates perfect prediction score (Matthews, 1975).

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (10)$$

5.1.7. Results and performance evaluation

5.1.7.1. Segmentation performance

Similar to Williams et al. (1999) and Silva and Bigg (2005), the segmentation performance analysis was carried out by comparing individual segments produced by the superpixel approach with visual interpretation. We selected 250 icebergs bigger than 30 image pixels in order to observe the superpixel adherence to the object shape. In this case study, 234 (93.6%) of the previously selected icebergs produced a solid and well-defined segmentation (when the segment contour fits a single object), robust to bounding objects under both low and high spectral variability. The worst performance was observed in scenes with presence of clusters of icebergs, which were partially connected, and in scenes where large icebergs presented abrupt textural and spectral variability over its surface. In these situations, iceberg clusters were compacted into single segments resulting in over segmentation and/or poorly defined segmentation.

5.1.7.2. Detection performance by visual inspection

Following the automatic detection, five RAMP AMM-1 frames with large iceberg density were selected. Obvious false positives, mainly objects partially connected to coastline, sea-ice ridges and spots of rough open water were visually counted. In total,

34321 targets (icebergs and background) were bounded, resulting in 1809 automatically detected icebergs from those five SAR frames. Applying visual inspection, 47 false positives, identified as sea-ice or spots of rough open water, were noted. Also, 63 obvious misses were detected, which were usually icebergs partially connected with one or more icebergs and/or due to segmentation failure. The number of false positives and misses represented 2.6% and 3.5% of the total number of icebergs automatically detected, respectively. However, a considerable number of misses resulted from the presence of small objects < 15 image pixels. The number of misses is partly caused by the minimal area threshold (10 image pixel) used for the automatic iceberg classification. The minimal area threshold was defined in order to allow the computation of textural features and reliable surface intensity statistics. Table 2 shows the total number of objects (icebergs and background elements) bounded by the segmentation stage for each analysed frame. Table 2 also shows the number of automatically detected icebergs as well as the number of missed and false positives icebergs, which were counted by visual inspection.

Table 2 – Total number of objects (icebergs and background elements) bounded by the segmentation stage for each analysed frame. Also, find below the number of automatically detected icebergs and the number of missed and false positives icebergs, which were counted by visual inspection.

	Objects	Icebergs	Miss	False Positive
Frame 1	8163	343	5	7
Frame 2	5480	188	7	4
Frame 3	6966	339	8	11
Frame 4	9840	489	32	13
Frame 5	3872	450	11	12

5.3 Detection performance by machine learning evaluation

In total, 1850 new balanced samples (icebergs and non-icebergs), showing a wide signature variability, were manually selected to be used as a test set free of errors. This allows a straightforward comparison between the proposed ensemble learning method (RF Committee) and the different base classifiers used. The goal is to monitor the gain from the combination of heterogeneous base classifiers for iceberg detection. Please note that each base classifier is a specialist in a class of image features and all base classifiers are trained to use the same training set through incremental learning.

The **Figure 5** shows the Matthews correlation coefficient (MCC), accuracy (ACC) and precision computed from the RF committee and all base classifiers used. The proposed RF committee achieved an ACC, precision and MCC of 98%, 98% and 95%, respectively. In general, the RF Committee shows significant improvements in all three parameters (ACC, precision and MCC) when compared to the single base classifiers. The average ACC, precision and MCC showed by the base classifiers are $88.6 \pm 5\%$, $88.4 \pm 5.4\%$ and $77.2 \pm 10\%$, respectively. The major gain from ensemble learning approaches can be better expressed by the false positive and miss rate. To our best knowledge, even recent methods usually demand manual false positive reduction (Mazur et al. 2017) and manual detection of missed icebergs (Wesche and Dierking, 2015) to improve accurate automatic iceberg detection. These tasks are time expansive, exhausting and not feasible to be applied over large-scale detection as well as for operational near real-time tasks.

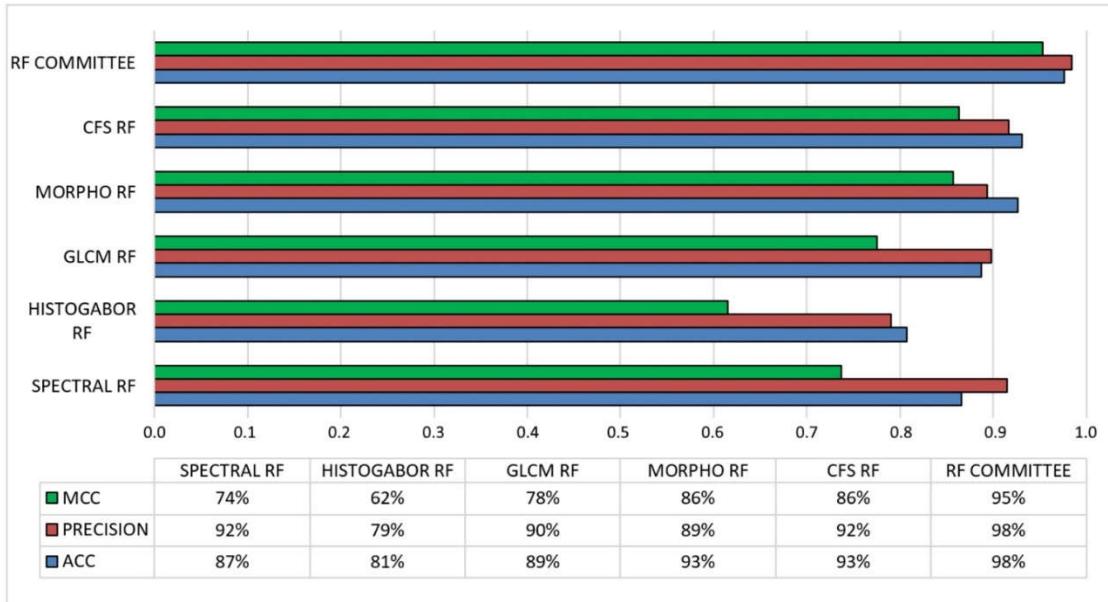


Figure 5. Matthews correlation coefficient (MCC), accuracy (ACC) and precision computed from RF committee and all base learner used.

A comparison of the false positive and miss rates between the proposed RF Committee and the base classifiers is shown in **Figure 6**. The RF committee notably outperforms all base classifiers presenting a False Positive Rate (FPR) of 2% and miss rate of 3%. CFS RF, Morpho RF and HistoGabor RF showed a much higher FPRs and miss rates. The adaptive approach proposed in this study results in a high identification rate with low miss and false positive rates, which agrees with the ensemble learning proposal of minimizing misclassification errors (Zhou, 2012). The variability observed between the distinct base learner scores reflects the diversity observed in SAR images. The RF Committee predicts taking advantage of a set of heterogenous models, rather than trying to find the best model for each situation. The improvement arises from the main problem for iceberg classification variability (i.e. the usual signal ambiguity with the background), in those situations the combination of the distinct models, even limited ones, plays a key role. If we directly compare the precision, the Spectral RF shows a precision of 92%, with a FPR and a miss rate of 7

% and 19 %, respectively. The RF Committee amounts the precision to 98% and a FPR and miss rate of 2% and 3%, respectively. This improvement is noteworthy and robust, thus reducing the need for manual verification.

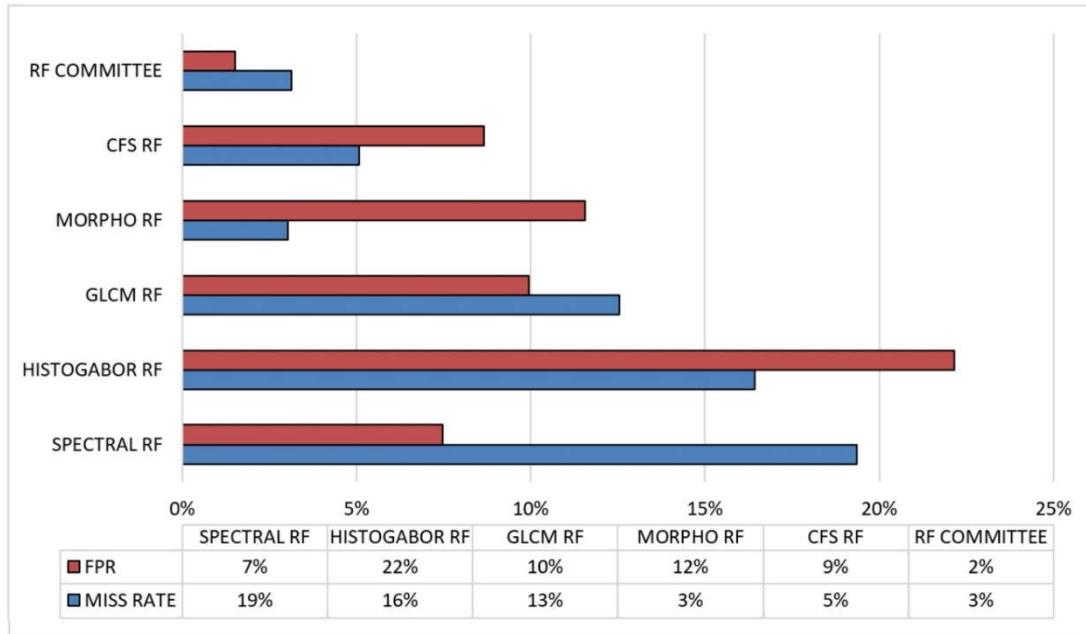


Figure 6. False positive and miss rate comparison between the proposed RF Committee and the base classifiers individually.

5.1.7.3. Relationship between Incremental Learning and Ensemble learning

The incremental learning approach proposed in this study dynamically introduces batches of new samples into the training set in order to improve the diversity. Since iceberg and background elements show large variability, it is not uncommon to find new objects with outlier characteristics. To evaluate the robustness of the RF Committee to incremental learning, we compared the ACC as a function of the number of training samples, adding manually batches of 100 balanced samples at a time (**Figure 7**).

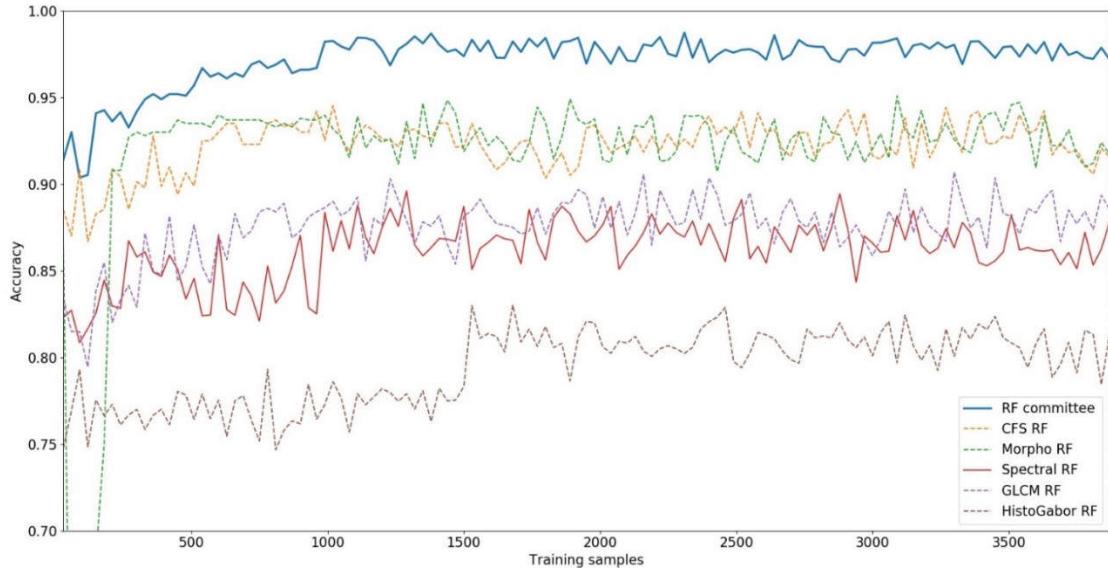


Figure 7. Classification accuracy as function of number of training samples between the proposed RF committee (full blue line) and its distinct base classifiers individually. The full red line highlights Spectral RF accuracy performance.

This ensemble approach shows stable behavior when compared to any of its base classifiers. This behavior is expected, once the ensemble method is robust to outliers and overfitting due to the combination of heterogeneous base learners (Dietterich, 1998; Breiman, 1999; Özçift A., 2011). The Spectral RF accuracy (full red line in **Figure 7**) shows a wide variability due to the presence of icebergs with bright and dark signatures. In practice, the strong generalization achieved by the combination of heterogeneous predictive models can be attributed to three fundamental issues: (i) statistical - in cases that the hypothesis space is too large to choose one, diversity can reduce the chance to choose the wrong one, (ii) computational - single learning algorithms can get stuck in the local optima, and (iii) representation - in many cases the true hypothesis could not be represented by any hypothesis individually (Zhou, 2012).

5.1.7.4. Detection results

Overall, 9512 icebergs were detected with 1863 from the Envisat ASAR dataset and 7649 from RAMP AMM-1 mosaic. Assuming a minimal area threshold of 10 image pixels, it was possible to identify icebergs with areas between 0.1-4567.82 Km² subdivided in five size classes, A1=0.1-1Km², A2=1-10Km², A3=10-100Km², A4=100-1000Km² and A5 > 1000Km², as proposed by Wesche and Dierking (2015). It is important to note that the total number of icebergs from the Envisat ASAR dataset reflects the actual number of icebergs identified from all images, which contain recurrences. These recurrences are due to overlapping images from different satellite orbits. Another factor contributing to the recurrences is due the wide imaging range in wide swath mode (400 km), the time span of the ENVISAT images and the iceberg mobility. Also, we cannot discard recurrences from the RAMP AMM-1 dataset, however in this case the mosaic is generated from images spanning ~1.5 months, in which case the major part of the recurrences were restrict to class A1 icebergs. **Figure 8** shows an examples of RAMP AMM-1 SAR frames [Panels A and C] used as basis for the classification. Classification results are shown in [Panels B and D]. Both SAR frames shows complex targets with wide gray-level intensity, textural, size and shape variability.

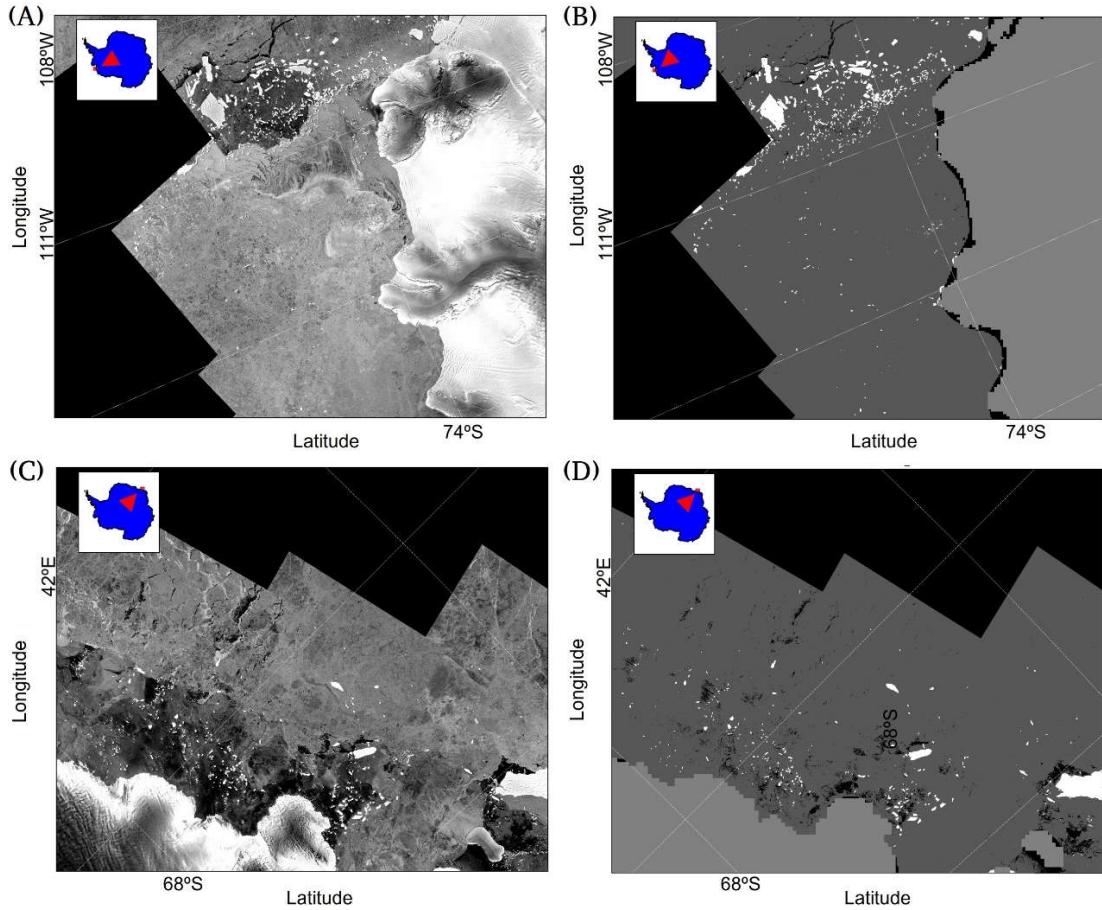


Figure 8. Example of RAMP AMM-1 SAR frames [Panels A and C] used as basis for the classification. Classification results as a mapping product are shown in [Panels B and D]. White objects in B and D are icebergs while light grey shades define the background (e.g. sea ice, open water), dark grey shades define fixed structures (e.g. continental land, ice shelves, ice tongues and glaciers) and black areas represent no-data.

A summary of the size class distribution (with recurrence effect removed) of icebergs detected in this study is presented in **Figure 9**. The total number of individual icebergs is 8064. Class A1 has the largest number in our detection scheme and occupies ~69% in our datasets. The most icebergs class A3, A4 and A5 detected come from the Envisat dataset, which is restricted to the Weddell Sea. We point out that, although the estimated sizes are realistic and reasonable, possible biases towards the size estimates should be considered. It is not uncommon that small fragments of iceberg do not present a robust scattering signal or extra pixels signatures distinct from very bright sea ice, which eventually is found attached to those fragments.

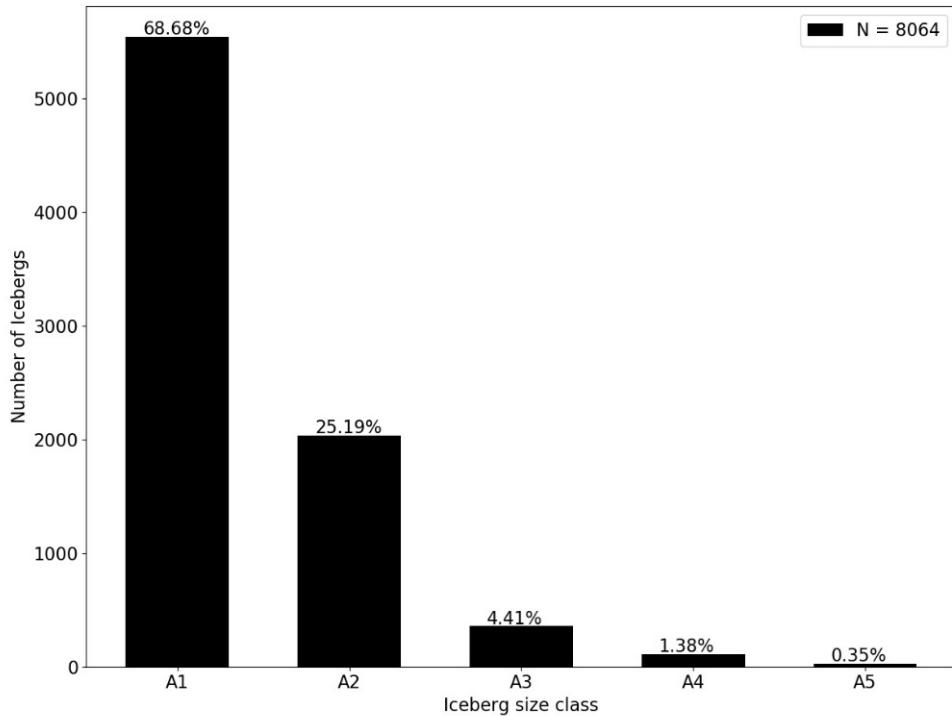


Figure 9. Icebergs size class distribution, identified from RAMP AMM-1 mosaic (1997) and Envisat ASAR dataset (2003,2004-2005). Size classes defined as A1=0.1-1Km², A2=1-10Km², A3=10-100Km², A4=100-1000Km² and A5 > 1000Km².

The spatial and size distribution from all detected icebergs is shown in **Figure 10**. The high concentration close to the coast is due to the geographic limitations of the RAMP AMM-1 mosaic, since this mosaic was developed for continental studies (Jezek et al. 1998). In terms of detection, the spatial restriction allows us to perform a classification under high diversity of sea-ice coverage, one of the main obstacles in standard iceberg classification methods. In order to perform a detection in open sea and in different seasons, the ENVISAT ASAR dataset was used (thus restricted to Weddell Sea).

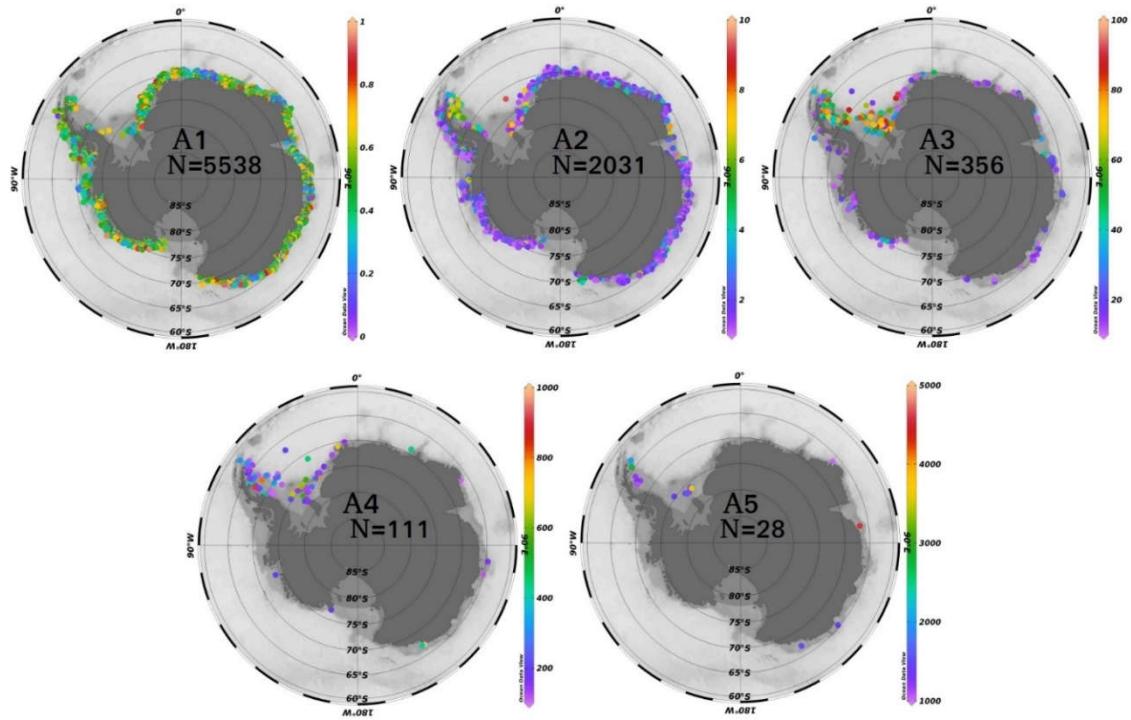


Figure 10. Spatial distribution of icebergs around the Antarctic continent identified from RAMP AMM-1 mosaic (1997) and Envisat ASAR dataset (2003,2004-2005). Panels are divided by iceberg size class (**Figure 9**). The colour scales represent the iceberg size in Km².

No significant seasonal variability related to the method performance was observed. Nevertheless, the number of detected icebergs is higher in winter and spring than in summer and autumn. As described by Wesche and Dierking (2012), the winter season appears to be more suitable for iceberg identification since the environmental conditions (air temperature, presence of smooth new sea ice) foster the contrast between glacial ice and the background (i.e. sea ice). So, the increase can be associated with the sea ice extension cycle, with a minimum in summer and maximum in winter (Parkinson and Cavalieri, 2012).

5.1.8. Discussion

In the previous sections, we have presented a novel iceberg detection adaptive machine learning method. We have focused our efforts in improving the iceberg detection performance under large image background variability, not only in terms of size but also regarding intensity and texture. The main difference to more traditional methods is that our approach is not centred on the use of predictive models based on backscatter intensity (Williams et al. 1999; Silva and Big, 2005; Wesche and Dierking, 2012 and 2015; Frost et al. 2016; Mazur et al. 2017). Instead, we use different predictive models that are individually weak, but robust when combined together since they are all based on different ambiguous image patterns. Moreover, the method continuously receives feedback from previous detections in order to improve the detection over targets with patterns that were not previously seen by the predictors.

In general, the ensemble/incremental learning method – more specifically, the proposed RF Committee, shows noteworthy performance improvements for ambiguous and outlier samples compared with models based on standard features that have been used to separate icebergs from the background. We achieve an average detection accuracy (from machine learning evaluation and visual inspection) of $97.5 \pm 0.6\%$, an average false positive rate of $2.3 \pm 0.4\%$ and an average miss rate of $3.3 \pm 0.4\%$, without any manual correction of the results. These results are quite good when compared to the different methods already mentioned above. For instance, Williams et al. (1999) show an accuracy of 84%, Silva and Big (2005) achieved an accuracy of 70% and Wesche and Dierking (2015) show an average accuracy of 77%, whereas icebergs smaller than 5 km^2 are detected with an accuracy of only 46%. In recent studies, Frost et al. (2016) show an average accuracy of 90%, while Mazur et al. (2017) achieve an accuracy of 96.2%, 3.8% misses and 7% of false positives.

However, we must point out that each of the method mentioned above was based on different types of SAR data (e.g. ERS, Envisat, Sentinel, TerraSAR and RadarSat) and distinct acquisition parameters as spatial and temporal resolution, band, polarization, incidence angle and orbit. Furthermore, each method was applied over different regions, being susceptible to regional variability and uniqueness.

However, despite of the significant detection performance archived by our novel methodology, the proposed RF committee method is sensitive to non-balanced training sets, tending to favour the most representative class. These aspects are similar to the observations by Dalponte et al. (2013), who applied Random Forests to tree species classification from hyperspectral data. In this sense, our method should be used with caution while applying it in conjunction with incremental learning for iceberg identification, since icebergs represent a large minority in occurrences when compared to the background (i.e. the scheme possibly tends to oversample background targets). Furthermore, the miss rate seems to be the major concern in our method, being strongly related to the segmentation stage. This is usually observed in scenes with the presence of clusters of icebergs partially connected by less than 20 intensity levels (greyscale) of distance and in scenes were large icebergs presented abrupt textural and spectral variability over their surfaces. In these situations, icebergs clusters were aggregated in single segments resulting in an over segmentation or yet a poorly defined segmentation. Although segmentation faults are not entirely explored in this study, the segmentation is an important stage to bounding icebergs and was discussed in detail by Williams et al. (1999) and Mazur et al. (2017).

Finally, although the proposed method has been developed and validated for Antarctic conditions, where the presence of tabular icebergs is the dominant feature, we believe that the adaptive method presented here can achieve satisfactory

performance also for the Arctic environment. In that area, the icebergs are less tabular, often in stormy seas and/or wrapped by packs of ice with different characteristics when compared to Antarctica.

5.1.9. Conclusion

Automatic iceberg detection from SAR images is a challenging task. The icebergs have wide spectral signature, texture, morphology and size variability, due to a broad range of environmental conditions, impose ambiguous classification scenarios. The ambiguity between the different classification targets makes it difficult to establish an accurate predictive model, normally requiring extensive manual inspection to remove false positives and to include missing targets. This hamper extensive iceberg detection using SAR imagery, which is essential for operational applications and studies on iceberg distribution patterns as well as their role in the input of freshwater into the ocean and therefore in the climate.

The method introduced in this study is an alternative machine learning approach, which employs an adaptive solution to extensive automatic iceberg identification from SAR images. We show that the ambiguity between icebergs and background can be bypassed by improving the generalization through a gradual learning information flow and the combination of heterogenous predictive models. The iceberg detection method uses a superpixel segmentation (Graph-based), ensemble learning (Random Forest Committee) and incremental learning (Batch learning).

The proposed method is robust detecting Antarctic icebergs with areas between 0.1 and 4567.82 km². The graph-based superpixel segmentation algorithm was capable to produce solid and well-defined segmentation, providing a convenient

basis to compute image features and estimate iceberg spatial properties. The ensemble/incremental strategy resulted in an average accuracy, false positive rate and miss rate of $97.5\pm0.6\%$, $2.3\pm0.4\%$ and $3.3\pm0.4\%$, respectively. The high performance is attributed to the strong generalization achieved by the combination of heterogeneous predictive models. Each model has a unique view of the differences between icebergs and background, based on different image features. Moreover, the continuously dynamic addition of new samples to the predictive models has a strong positive influence on the performance of the iceberg detection.

Finally, our method has the potential to contribute to oceanographic and cryospheric research by offering a suitable and robust approach focused on the improvement of detecting icebergs under wide range of scenarios in digital SAR images. Operationally, the proposed method fixes the problem of detecting icebergs under large radar backscattering variability. Moreover, our results clearly demonstrate that the error in separating icebergs from their surrounding can be reduced by combining heterogeneous predictive models, which are incrementally improved to adjust to outliers. Altogether, our results highlight the potential of machine learning approaches for remote sensing applications where highly ambiguous scenarios pose as major obstacles for classification and analysis. The detection method presented here has been recently used to compute the pan-Antarctic near-coastal iceberg distribution complementing previous studies restricted to open-water regions (Barbat et al. 2019). Moreover, this technique can be used as basis for future drifting iceberg studies that would throw light on the patterns of freshwater input from icebergs in the Southern Ocean.

5.1.10. Appendix A: Features description

- Frequency texture features based on Gabor filter:

Gabor wavelet can be applied locally resulting in a Gabor filtered image. When applying a Gabor filter to the original image, the content is broke down in different scales and orientations that can be effectively used for pattern recognition (Ismail et al. 2014). The formal definition of Gabor filter is given as follows:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(j\omega x) \quad (\text{A1})$$

Where x, y are pixel coordinates, $j = \sqrt{-1}$, and ω is frequency.

The mean and variance are computed from the filtered image.

- Texture features based on Gray-Level Co-Occurrence Matrix (GLCM) (Haralick et al. 1973), which is defined as follows:

The element point $p(i, j)$ in GLCM represents the frequency of two pixels in a certain grayscale image window, and the adjacent distance is d in the θ direction. Usually, d takes 1 or 2, and θ take four directions $0^\circ, 45^\circ, 90^\circ$ and 135° . Each element values of GLCM are then computed as follows:

$$p(i, j) = \frac{p(i, j, d, \theta)}{\sum_{i=1}^N \sum_{j=1}^N p(i, j, d, \theta)} \quad (\text{A2})$$

The Haralick texture features used in our method are computed for each direction as follows:

$$\text{Contrast: } \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 p(i, j) \quad (\text{A3})$$

$$\text{Homogeneity: } \sum_{i=1}^N \sum_{j=1}^N \frac{p(i, j)}{1 + (i - j)^2} \quad (\text{A4})$$

$$\text{Dissimilarity: } \sum_{i=1}^N \sum_{j=1}^N |i - j| \cdot p(i, j) \quad (\text{A5})$$

- Morphological features are based on object shape, defined as follows:

$$\text{Eccentricity: } \sqrt{1 - \frac{b^2}{a^2}} \quad (\text{A6})$$

Where a is the length of the major axis and b is the length of the minor axis.

Defining the convex hull as the minimum convex polygon that can enclose an image object geometry:

$$\text{Roundness: } \frac{4\pi \text{area}}{(\text{convex hull perimeter})^2} \quad (\text{A7})$$

Where *convex perimeter* is the perimeter of the convex hull that encloses the object.

$$\text{Solidity: } \frac{\text{area}}{\text{convex hull area}} \quad (\text{A8})$$

Where *convex area* is the area of the convex hull that encloses the object.

$$\text{Polsby-Popper test: } \frac{4\pi A_o}{P_o^2} \quad (\text{A9})$$

Where A_o is the object area and P_o is the object perimeter. A score of 1 indicates maximal compactness.

$$\text{Normalized perimeter index: } \frac{2\sqrt{\pi \text{area}}}{\text{perimeter}} \quad (\text{A10})$$

$$\text{Fractal dimension: } \frac{\log r}{\log s} \quad (\text{A11})$$

Where r is the number of self-similar pieces, each scaled down by a factor s .

5.1.11. Acknowledgments

This study is a contribution to the activities of the Brazilian High Latitudes Oceanography Group (GOAL) and the Brazilian National Institute of Science and Technology of the Cryosphere (INCT-CRIOSFERA; CNPq 465680/2014-3, FAPERGS 17/2551-0000518-0). The GOAL has been funded by the Brazilian Antarctic Program (PROANTAR) through the Brazilian Ministry of the Environment (MMA), the Brazilian Ministry of Science, Technology, Innovation and Communication (MCTIC), the Council for Research and Scientific Development of Brazil (CNPq; 442628/2018-8), and CAPES Foundation (AUXPE 1995/2014). M. M. Barbat acknowledges the fellowships from CNPq (140910/2016-6) and CAPES Foundation (88881.177236/2018-01). M. M. Mata acknowledges CNPq grant 306896/2015-0. We also thank the European Space Agency (ESA) and the Canadian Cryospheric Information Network (CCIN) for providing the Envisat ASAR images and the RAMP AMM-1 mosaic used in this study. In addition, we have uploaded the source-code for the presented method to the institutional website of Federal University of Rio Grande, Brazil at <https://goal.furg.br/producao-cientifica/supplements/202-b2019-icedt> repository.

5.2. Artigo 2: *Three years of near-coastal Antarctic iceberg distribution from a machine learning approach applied to SAR imagery*

O segundo artigo, de autoria de Mauro M. Barbat, Thomas Rackow, Hartmut H. Hellmer, Christine Wesche e Mauricio M. Mata, é intitulado “***Three years of near-coastal Antarctic iceberg distribution from a machine learning approach applied to SAR imagery***” e encontra-se publicado no periódico “***Journal of Geophysical Research: Oceans***”, volume 124 (2019), páginas 6658-6672.

<https://doi.org/10.1029/2019JC015205>

5.2.1. Síntese do artigo 2

A representação realista dos padrões interanuais de icebergs próximos à costa tem implicações para futuros estudos de modelagem climática que objetivam considerar estimativas do fluxo de água doce do derretimento de icebergs. Este estudo tem como objetivo principal identificar, documentar e discutir a evolução espaço-temporal e a variabilidade em termos de tamanho/distribuição de massa de icebergs em toda a zona costeira antártica para os anos de 1997, 2000 e 2008. Além disso, demonstra-se a aplicabilidade de métodos de inteligência artificial a esse problema através de uma abordagem alternativa de aprendizado de máquina baseada em imagens de alta resolução derivadas de radar de abertura sintética (*Synthetic Aperture Radar - SAR*).

Os resultados apresentados complementam muito bem as discussões em andamento sobre a distribuição de icebergs em regiões de oceano aberto no oceano

Austral e fornecem conjuntos de dados iniciais confiáveis que podem ser usados para inicializar modelos climáticos com módulos de oceano-iceberg acoplados. Por fim, este trabalho destaca a aplicabilidade de novos métodos automáticos para detecção de icebergs em larga escala a partir de imagens de SAR e também contribui para os esforços contínuos para entender o papel e o impacto do derretimento de icebergs na circulação oceânica, cobertura de gelo marinho, formação da densa água de fundo e, por consequência, no clima.

Three years of near-coastal Antarctic iceberg distribution from a machine-learning approach applied to SAR imagery

Mauro M. Barbat¹, Thomas Rackow², Hartmut H. Hellmer², Christine Wesche², and Mauricio M. Mata¹

¹Federal University of Rio Grande-FURG, Rio Grande, Brazil

²Alfred Wegener Institute, Helmholtz Centre for Polar and Marine Research, Bremerhaven, Germany

5.2.2. Key Points:

- A novel automatic machine learning approach is applied to SAR imagery, with minimal visual inspection.
- Near-coastal iceberg size distributions are presented for 1997, 2000, and 2008.
- Mass distribution for smaller icebergs appears to be relatively stable, while less frequent large icebergs strongly bias the distribution.

Corresponding author: M. M. Barbat, maurobarbat@furg.br

5.2.3. Abstract

Mass loss around the Antarctic Ice Sheet is driven by basal melting and iceberg calving, which constitute the two dominant paths of freshwater flux into the Southern Ocean. Although of similar magnitude, icebergs play an important and still not fully understood role in the balance of heat and freshwater around Antarctica. This lack of understanding is partly due to operational difficulties in large-scale monitoring in polar regions, despite observational and remote sensing efforts. In this study, a novel machine learning approach, augmented by visual inspection, was applied to three Synthetic Aperture Radar (SAR) mosaics of the whole Antarctic continent and its adjacent coastal zone. Although originally intended for a mapping of the Antarctic continent, the SAR mosaics allow us to document the evolution and distribution of the size (and mass) of icebergs in the pan-Antarctic near-coastal zone for the years 1997, 2000, and 2008. Our novel algorithm identified 7649 icebergs in 1997, 13712 icebergs in 2000, and 7246 icebergs in 2008 with surface areas between 0.1 and 4567.82 km² and total masses of 4641.53 Gt, 6862.81 Gt, and 5263.69 Gt, respectively. Large regional variability was observed, although a zonal pattern distribution is present. This has implications for future climate modelling studies that try to estimate the freshwater flux from melting icebergs, which demands a realistic representation of the interannually varying near-coastal iceberg pattern to initialize the simulations.

5.2.4. Plain Language Summary

When icebergs melt in the Southern Ocean, they cool the surrounding ocean. They also distribute freshwater, which potentially impacts the circulation, biological activity, sea-ice cover, and the formation of the densest waters of the world's oceans. However, all these influences are not fully understood because we are lacking reliable methods to detect icebergs from space via satellites. This study has the main objective to determine how iceberg mass is distributed in the coastal zone around the Antarctic continent and how this distribution changes between individual years. We show that a novel machine learning approach can be applied to this problem, which is capable to identify icebergs in satellite images of the near-coastal ocean region almost automatically. The method also works in severe conditions, e.g. when the icebergs are affected by ocean waves or when they are surrounded by sea ice. Our results complement the ongoing discussion about the distribution of Antarctic icebergs in open-ocean regions that are not affected by sea ice. The resulting data can also be used in computer models that simulate the input of iceberg freshwater into the ocean.

5.2.5. Introduction

Icebergs calving from glaciers, ice shelves, and ice tongues constitute one of the dominant causes of mass loss from the Antarctic Ice Sheet, with similar magnitude to basal melting (Bigg, & Nicholls, 2006; Depoorter et al. 2013; Silva Tournadre, Girard-Ardhuin, Bouhier, & Remy, 2016). Every year, thousands of objects ranging from several meters to tens of kilometers drift away from their region of origin (Rackow et al. 2017), subject to fracture, breaking and gradual

melting associated with swell, wave erosion, ocean temperature, currents, and winds (e.g., Bigg, Wadley, Stevens, & Johnson, 1997; Bouhier, Tournadre, Remy, & Gourves-Cousin, 2018). Fracture and melting icebergs are a significant contributor to the freshwater flux from the AIS to the Southern Ocean (Tournadre et al. 2016), and rapid changes in iceberg flux can have an impact on climate (Bigg, 2015).

The freshwater discharge from icebergs into the Southern Ocean (Hellmer, Doake, Jenkins, & Frolich, 1992; Gladstone, 2001; Jacobs; Rackow et al. 2017) is capable of disrupting temperature and salinity patterns and affecting ocean circulation, biological activity, as well as sea ice dynamics, depending on the location and quantity of the diluted mass (Schodlok, Hellmer, Rohardt, & Fahrbach, 2006; Silva et al. 2006; Romanov, Romanova, & Romanov, 2008; Stern, Adcroft, & Sergienko, 2016). In particular, the cold and dense Antarctic Bottom Water (AABW) (Gordon, 2001; Purkey & Johnson, 2013) is an essential component for the global Meridional Overturning Circulation (MOC) (Ohshima et al. 2013; Bigg, 2015) and understanding its sensitivity to external changes is required to improve projections of future climate change (Shimada, Aoki, Ohshima, & Rintoul, 2012). Freshwater flux estimates are usually based on numerical models, using either estimates of calving fluxes as boundary conditions (Gladstone, 2001; Merino et al. 2016) or realistic realizations of the iceberg distribution as initial condition (Rackow et al. 2017). Because of large and giant iceberg calving which usually happens on decadal timescales, meltwater fields based on the latter approach could potentially be biased towards the chosen year. Additional iceberg distributions should thus be provided to reduce the uncertainty of iceberg meltwater estimates.

Despite the potential large impacts resulting from melting icebergs, estimates of their spatial distribution and temporal variability remain a particular challenge (Tournadre, Girard-Ardhuin, & Legresy, 2012). Different authors used distinct approaches to fill this lack of understanding. Jacka and Giles (2007) discussed the idea of iceberg population and life cycle between 60°E and 150°E in terms of calving regions and ocean currents. Romanov et al. (2008) and Romanov, Romanova, and Romanov (2012) focused on spatial distribution and multi-year variability of icebergs in the Atlantic-Indian sector of the Southern Ocean and the general distribution in terms of shape and size. Wesche and Dierking (2015) presented the spatial distribution of icebergs around Antarctica in near-coastal waters for the year 1997 in relation to the type of calving fronts. In a series of papers (Tournadre et al. 2012, 2016; Tournadre, Whitmer, & Girard-Ardhuin, 2008; Bouhier et al. 2018), the recent iceberg distribution in open water for the whole Southern Ocean was shown, discussing size distribution, melting, and fragmentation.

Estimates are usually limited to the monitoring of giant icebergs and/or icebergs in open water, i.e., free of sea-ice coverage. Over the last four decades, the United States National Ice Center (U.S. NIC, http://www.natice.noaa.gov/Main_Products.htm, last visit 28.03.2019) and the Brigham Young University (BYU, <http://www.scp.byu.edu/data/iceberg/>, last visit 28.03.2019) has been actively detecting and tracking icebergs larger than 10 nautical miles (longest axis) in the Southern Ocean using spaceborne scatterometer (Stuart & Long, 2011). Also, previous studies have presented iceberg distributions for different regions of the Southern Ocean applying distinct approaches, namely either observational data (Jacka & Giles, 2007; Romanov et

al. 2012), satellite altimetry (Tournadre et al. 2008, 2012, 2016), numerical models (Gladstone, 2001; Stern et al. 2016; Rackow et al. 2017), or Synthetic Aperture Radar (SAR) (Silva et al. 2006; Wesche & Dierking, 2015). SAR bridges a gap between observational, altimetry, and scatterometer methods, since it enables detection of icebergs from lengths of a few tens of meters up to several kilometers even during polar night and independent of the prevailing cloud conditions. Furthermore, SAR data provide high spatial and temporal coverage for Antarctic coastal and open water environments since 1991 and have become a standard data set for iceberg research (Gladstone, 2001; Gladstone & Bigg, 2002; Silva & Bigg, 2005; Wesche & Dierking, 2012, 2015).

In this study, the objective is to identify and document the spatial evolution and size distribution of icebergs in the whole Antarctic near-coastal zone for a wide range of iceberg sizes, and to demonstrate the applicability of an automatic machine learning approach to this problem. Using three high-resolution SAR mosaics, a total of 28607 icebergs were identified with sizes between 0.1 km² and 4567.82 km². This work revisits the data set used by Wesche and Dierking (2015), the comprehensive Radarsat-1 Antarctic Mapping Project (RAMP) Antarctic Mapping Mission-1 (AMM-1) mosaic representative for 1997 conditions (Jezek, Sohn, & Noltmier, 1998), and compares it with subsequent satellite image mosaics from the RAMP Modified Antarctic Mapping Mission (MAMM) (2000) and the Radarsat-2 Antarctic Mapping Initiative (2008) (MacDonald & Ltd, 2014). The use of the Radarsat Mosaics, although limited to only three observations, offers a unique opportunity for repeated observations of the pan-Antarctic near-coastal environment. To our best knowledge, this is the first time an autonomous machine learning method is applied for massive iceberg

detection, resulting in estimates of their spatial distribution as well as their local size distribution. Using the three available data sets also allows to provide an estimate of year-to-year and decadal iceberg evolution in the pan-Antarctic coastal zone with implications for modelling studies on freshwater fluxes.

The paper is structured as follows. We present the data and the novel machine learning method used in this study in section 2. The results are presented in section 3. A discussion and conclusion complete this paper (section 4).

5.2.6. Data and Methods

5.2.6.1. The Satellite Image Mosaics

This study uses three Antarctic SAR mosaics (**Figure 1**), built from collections of high-resolution C-band SAR images acquired from the Canadian RADARSAT-1 and RADARSAT-2 satellites at a pixel size of 100 m × 100 m pixel size (Canadian Space Agency, 2010). First, the RAMP AMM-1 8-bit amplitude mosaic was an initiative between different space agencies to map the Antarctic continent, composed from over 3000 individual RADARSAT-1 frames acquired between September and October 1997 (Jezek et al. 1998). The MAMM 8-bit amplitude mosaic was a second RAMP mission with the objective to observe potential changes in the ice sheet compared to the 1997 mosaic, built from imagery acquired between September and November 2000. The third, the Radarsat-2 Antarctic Mapping Initiative's 8-bit mosaic, was intended to produce an updated continental mosaic, consistent with the 1997 RAMP, composed of imagery from 370 swaths and 3150 frames acquired between October and

December 2008 (MacDonald & Ltd, 2014). More detailed information about the SAR mosaics can be accessed online (<https://www.polardata.ca/pdcsearch/>; accessed 26.02.2019).

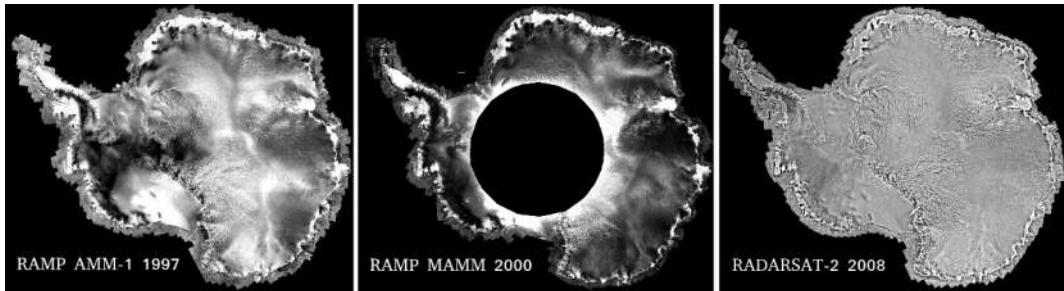


Figure 1. Radarsat-1 and Radarsat-2 satellite image mosaics for the years 1997 (left), 2000 (middle), and 2008 (right). Originally intended for mapping of the Antarctic continent, the near-coastal ocean is also covered providing a snapshot of the local and pan-Antarctic iceberg distribution.

5.2.6.2. Identifying Icebergs Automatically Using Machine Learning

Although SAR products are widely explored to study the polar environment, for icebergs a decisive radar-derived signature is still missing. This results from backscatter oscillations attributed to different meteorological/sea-state conditions, iceberg surface coverage (e.g., wet snow, melt ponds) and physical iceberg properties (e.g., density, layering, and air inclusions) (Gladstone & Bigg, 2002; Silva & Bigg, 2005; Wesche & Dierking, 2012). In juxtaposition with sea ice, ice melange, snow covered islands, and rough water, highly ambiguous radar-derived iceberg signatures are produced. The ambiguity makes large-scale iceberg identification from SAR images a complex and challenging task. To our knowledge, it had been previously limited to empirical considerations based on the surface and backscatter strength. However, these empirically motivated

assumptions are often violated, which makes it difficult to use autonomous systems to perform such tasks (e.g., Wesche & Dierking, 2015).

In practice, accurate iceberg identification relies on the performance to distinguish icebergs from open water and sea ice under different meteorological, sea state, or iceberg surface conditions. These conditions result in substantial variations from highly bright to dark targets (Wesche & Dierking, 2012). Such volatile spectral behaviour along with changing textural and morphological patterns makes it difficult to establish a general predictive model applicable to separate icebergs from an equally ambiguous background. This immediately suggests the need for adaptive methods.

The iceberg detection method applied in this study employs an intuitive solution to address the aforementioned problem (Barbat et al. 2019). Herein referred to as the B2019 method, it assumes that the ambiguity between iceberg and coexisting features, yielded by SAR imagery, can be bypassed through improving generalization. In simple terms, this means that instead of basing iceberg detection on a single feature class like backscatter (color) alone—which can be highly ambiguous—two additional feature classes, namely morphology (iceberg shape or form) and texture (color variability in space), are accounted for by our detection method. It is intuitively clear that by adding more characteristics, the sensitivity of the whole method to ambiguities in a single feature should be much reduced. A more complete description of how this is achieved is given in Appendix A.

The B2019 method was applied to and validated for two different data sets: first, for 586 ENVISAT Advanced SAR (ASAR) images acquired between 2003–2005, in order to capture seasonal variability, and secondly for the RAMP AMM-

1 mosaic (presented in this study) in order to have a wide variability in terms of backscattering intensity, texture, size, and shape. The method shows an average accuracy performance of $97.5 \pm 0.6\%$, an average false positive rate (e.g., when background elements are classified as icebergs) of $2.3 \pm 0.4\%$, and a miss rate (real icebergs that were not detected) of $3.3 \pm 0.4\%$. The method proved to be a robust alternative to extensive iceberg detection even in scenes where ambiguity imposes major obstacles to an automatic detection. An overview about the performance of the detection method is available in Appendix B, and the method details are presented in Barbat et al. (2019).

The B2019 method requires a previous definition of the minimal object-area threshold that allows to compute reliable statistics based on grey-level intensity (derived from backscatter intensity), texture, and morphology features. For this study, a minimal area threshold of 10 image pixels is set to define an iceberg object. The threshold allows to detect iceberg sizes as small as 0.1 km^2 , which aims to increase the spatial resolution compared to the study by Wesche and Dierking (2015) (30 image pixels). As an example of the detection results, we show a complex scene from the Western Pacific Ocean ($90^\circ\text{E}-160^\circ\text{E}$), captured by the RAMP mission in 1997 close to Totten Ice Shelf (**Figure 2**, panel “A”). The complexity is due to the presence of icebergs that are captured by fast ice and which are also surrounded by different sea-ice conditions; moreover, clusters of small icebergs and a large range of size classes and radar-based signature patterns are present. Another scene shows a different kind of complexity (**Figure 2**, panel “C”), close to Larsen Ice Shelf at the western Antarctica Peninsula, captured by the Radarsat-2 Antarctic Mapping Initiative in the year 2008. In this scene, icebergs are surrounded by well-consolidated sea-

ice with high backscatter values. For comparison, **Figure 2** also shows the results of the autonomous detection approach based on machine learning (white patches in panels **Figures 2B and 2D**).

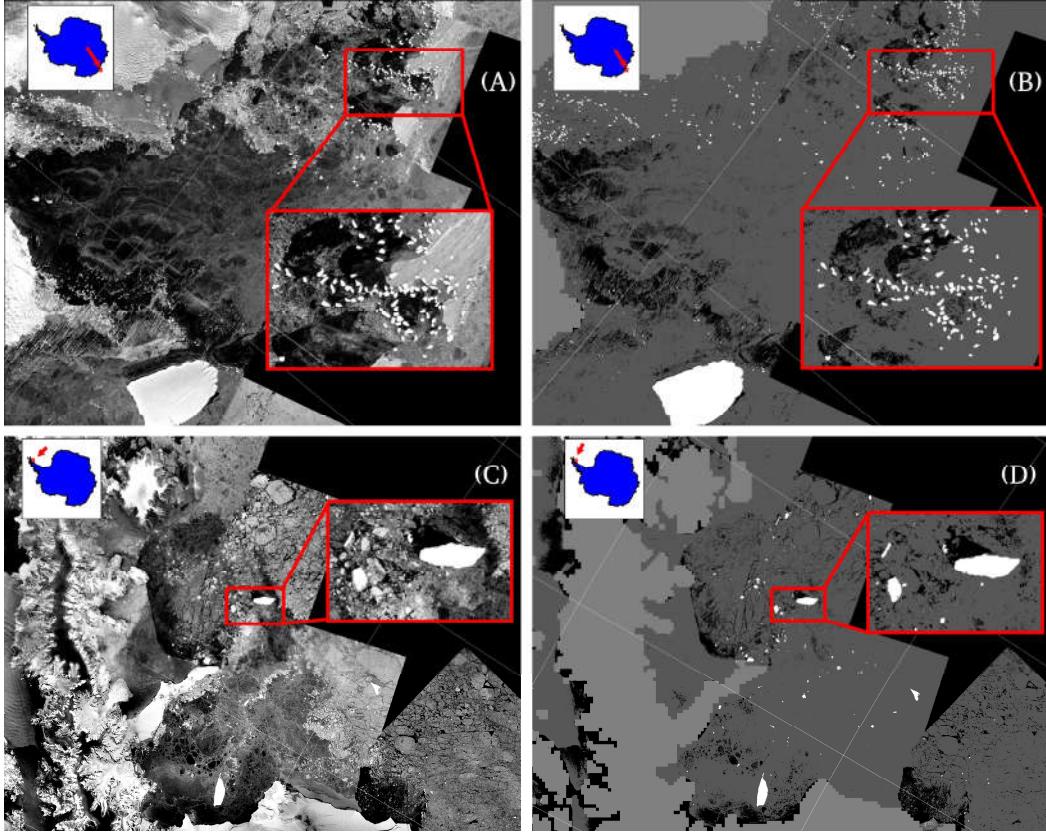


Figure 2. Comparison of SAR scenes from the RAMP AMM-1 mission (A) and from the Radarsat-2 Antarctic Mapping Initiative mosaic (C) with iceberg detection results using the autonomous detection method based on adaptive machine learning in (B) and (D), respectively. Bright white pixels are icebergs, dark grey areas are covered by sea-ice/fast ice structures, and black areas are open water. The land mask (light grey areas) is derived from the RAMP AMM-1 coastline data set (<http://research.bpcrc.osu.edu/rsl/radarsat/data/>) and from the NSIDC Antarctic coastline (Mouginot et al. 2017; Rignot et al. 2013). The location of the scene (red arrow) is indicated in the overview map in the top left corner for all panels. Zoomed areas are shown to highlight the contrast between icebergs and background.

5.2.6.3. Estimating Iceberg Area and Mass

Once classified as iceberg, spatial meta data is computed based on horizontal surface properties (i.e., area, perimeter, as well as major and minor axis - all in image pixels). The iceberg area [km^2] is then calculated as:

$$area_{km^2} = \left(Narea_{pixels} - \frac{Nperimeter_{pixels}}{2} \right) \times Apixel_{m^2}/10^6 \quad (1)$$

where $Narea_{pixels}$ is the number of pixels identified as an iceberg unit, $Nperimeter_{pixels}$ is the number of pixels of the iceberg outline (perimeter), and $Apixel_{m^2}$ is the typical physical area [in m²] covered by a pixel in the mosaics. Half of the perimeter size is removed since those pixels define the bordering area between an iceberg and its surroundings.

Using the detected surface area, the iceberg mass is estimated based on a typical density of $\rho = 850$ kg/m³ for icebergs in the Southern Ocean (Rackow et al. 2017; Silva et al. 2006; Stern et al. 2016), and assuming a potential error of ~36% (Jacobs et al. 1992), a fixed iceberg thickness of 250 m, consistent with previous studies (Gladstone, 2001; Rackow et al. 2017; Wesche & Dierking, 2015)). Rackow et al. (2017) note that this choice can be considered to be a more conservative estimate than the 360 m also discussed by Wesche and Dierking (2015).

5.2.7. Results

Overall, 28607 icebergs were detected in the Antarctic near-coastal zone. For the specific years, the numbers are 7649 with areas widely varying between 0.1–4567.82 km² (1997), 13712 between 0.1–3358.6 km² (2000), and 7246 between 0.1–4249.3 km² (2008). The pan-Antarctic data has been divided into five size classes and five major Antarctic sectors (**Figure 3**). Following Wesche and Dierking (2015), the size classes are A1 = 0.1–1 km², A2 = 1–10 km², A3 = 10–100 km², A4 = 100–1000 km², and A5 > 1000 km². The five major Antarctic

sectors are Ross Sea (160°E-130°W), Bellingshausen/Amundsen (B&A) Seas (130°W-60°W), Weddell Sea (60°W-20°E), Indian Ocean (20°E-90°E), and West Pacific Ocean (90°E-160°E)), following Parkinson and Cavalieri (2012).

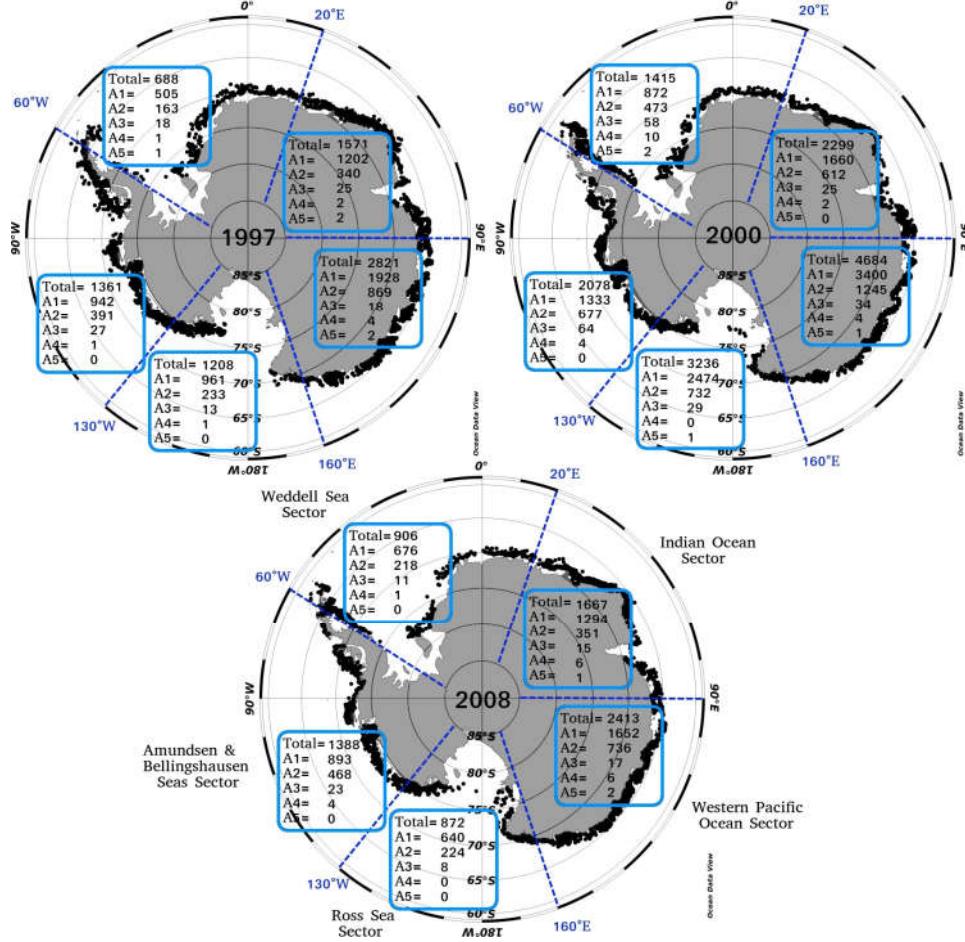


Figure 3. Iceberg counts for the five different size classes (A1–A5) in the five major Southern Ocean sectors (Ross Sea, Bellingshausen/Amundsen Seas, Weddell Sea, Indian Ocean, and West Pacific Ocean) in 1997, 2000, and 2008. Black dots near the Antarctic coast represent individual icebergs.

5.2.7.1. Iceberg Size Distribution

For the three years considered (**Figure 4**), the majority of icebergs (98.44% or 28162 icebergs) belong to classes A1–A2 (0.1–10 km²) and a mere 445 icebergs to classes A3–A5 (bigger than 10 km²). Of the latter, only 54 giant

icebergs larger than 18.5 km in length (see Silva et al. (2006)) and 12 with area larger than 1000 km² were detected. Although the predominance of the percentages in classes A1 and A2 remains practically unchanged for all years (98.5%, 98.3%, and 98.7%), large variability was observed in iceberg counts and between the distinct size classes. Particularly, the year 2000 presents an anomalous behaviour with a substantial increase in the total number of icebergs when compared to the 1997-estimate (+55.7%). Similarly, when comparing the 2000 and 2008 estimates, a substantial decrease of iceberg counts in the year 2008 (-52.81%) is evident. A large part of this variability is related to changes within the classes A1–A3 (0.1–100 km²). Although giant icebergs calve only on decadal timescales and are far fewer compared to smaller icebergs, they represent a significant iceberg mass. Regarding the number of giant icebergs — although an increase was noted over the considered years from 13 (1997) to 20 (2000) and 21 giant icebergs (2008)— it is not possible to determine a trend in this study. Giant icebergs in Antarctic near-coastal waters can have a decadal life time, i.e., might be present in different mosaics used. Also, some giant icebergs were not detected because they were only partially within the area of data coverage or because they were connected to an ice shelf. The smallest of these giant icebergs covered an area of 44.67 km² (detected in 2008) and the biggest an area of 4567.82 km² (detected in 1997). Combining all size classes (A1-A5) covering the 0.1–4568 km² range, the size measurements fit a power law slope of -1.83 (**Figure 5**). We also fitted power laws for all three years separately (not shown), which results in an average slope of -1.77 ± 0.04 (plus/minus one standard deviation).

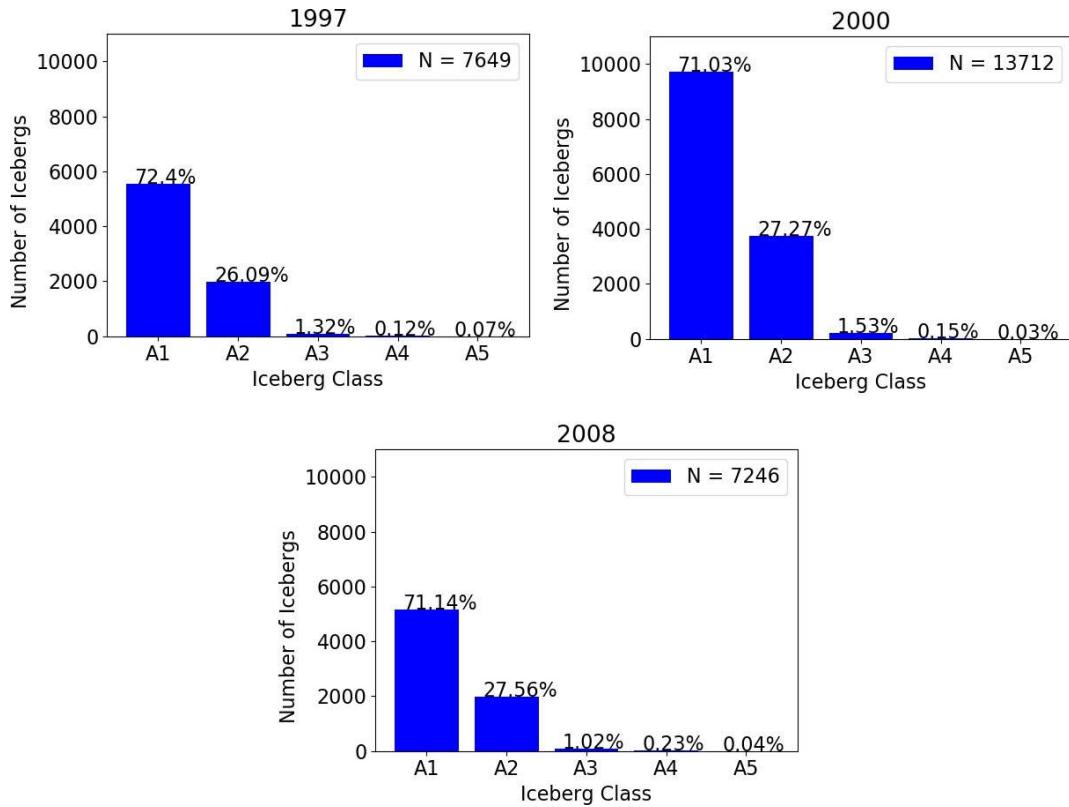


Figure 4. Iceberg size distribution in the Antarctic near-coastal zone for (left) 1997, (right) 2000, and (bottom) 2008. The size classes A1-A5 are defined as for Fig. 3.

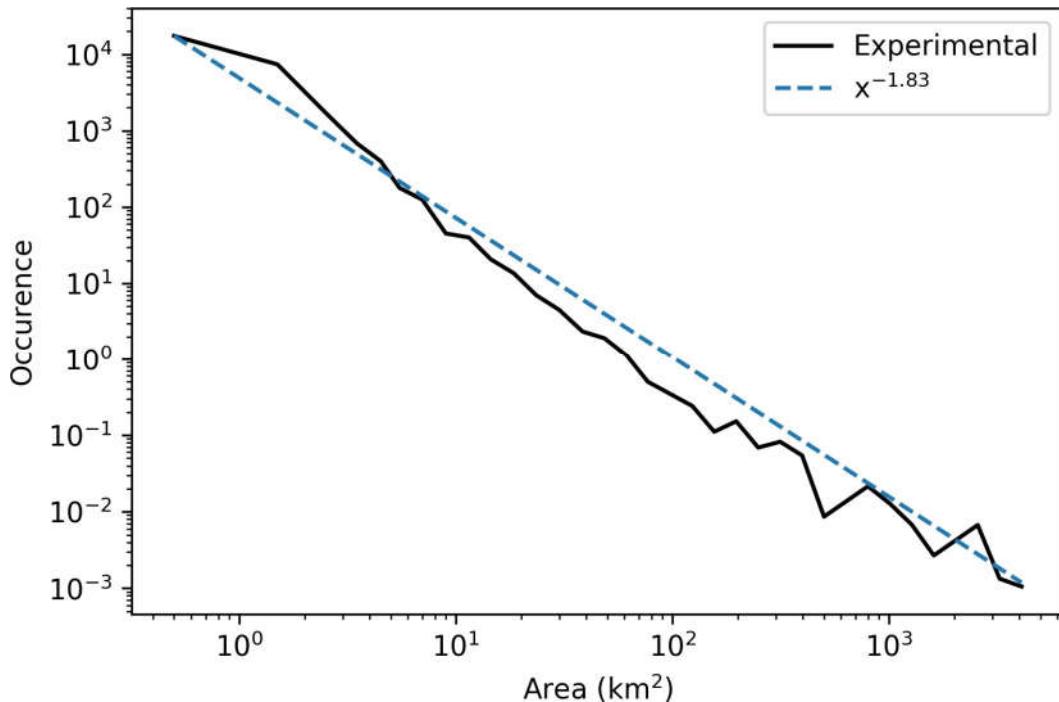


Figure 5. Iceberg size distribution for the near-coastal regions around Antarctica (black line), using all data for 1997, 2000, and 2008. The blue dashed line is a fitted power law with slope of -1.83.

5.2.7.2. Iceberg Spatial Distribution

Despite the limitations of the spatial coverage in the used mosaics, which cover the whole Antarctic continent but only limited areas of the Southern Ocean with a near-coastal width between 20 and 300 km, the use of the SAR mosaics allows to present an overview of the pan-Antarctic near-coastal iceberg distribution for the years 1997, 2000, and 2008. This complements previous studies for the near-coastal zone (1997 only; Wesche & Dierking, 2015) and the longer-term results for 1992–2014 by Tournadre et al. (2012, 2016) which, however, are limited to open-ocean regions.

The spatial distribution is dominated by smaller icebergs (A1 and A2) along the whole Antarctic coast. Significant regional variability exists between the five major Antarctic sectors (**Figure 6**). The Indian Ocean and Western Pacific Ocean sectors together (20°E – 160°E) represent on average $54.9\pm2.8\%$ of the total iceberg counts, followed by the B&A Seas with an average of $17.4\pm1.6\%$, the Ross Sea ($17.1\pm4.8\%$), and the Weddell Sea ($10.6\pm1.4\%$). The West Pacific Sector, although the most consistent in iceberg number, presents a small negative trend from 36.9% in 1997 to 34.2% in 2000 (-2.7%) and to 33.3% in 2008 (-0.9%). The Ross Sea sector exhibits the largest variability of all five sectors with 15.8% in 1997, increasing to 23.6% in 2000 (+7.8%) and decreasing to 12% in 2008 (-11.6%). The Weddell Sea, in contrast, has a positive trend, increasing from 9% in 1997 to 10.3% in 2000 and to 12.5% in 2008.

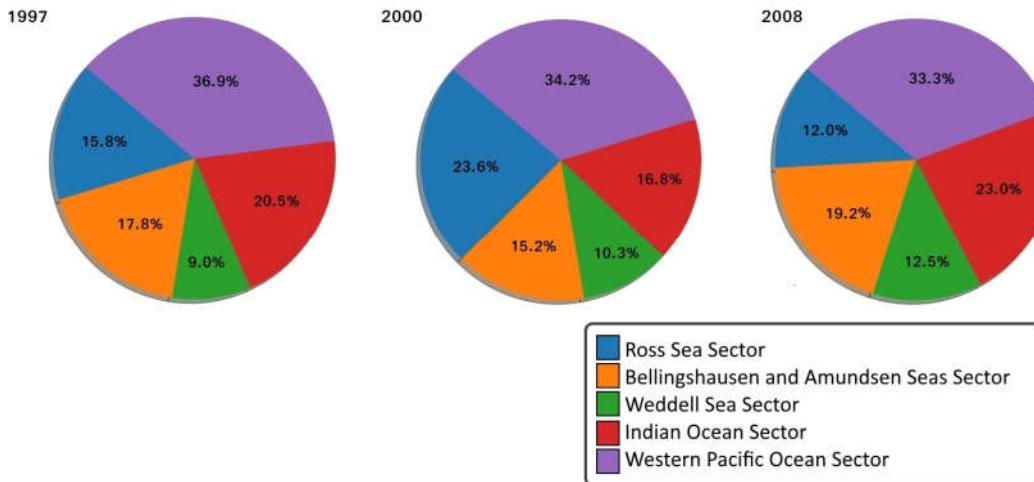


Figure 6. Percentage of total number of icebergs within five major sectors of the near-coastal Southern Ocean for (left) 1997, (middle) 2000, and (right) 2008.

The zonal near-coastal iceberg distribution differs between years, although some common pattern can be identified between 1997, 2000, and 2008 (**Figure 7**). One major peak exists within each sector. However, the West Pacific Ocean shows high iceberg concentration for all its zonal extension with maximal concentration between 120°E – 130°E , close to Totten and Holmes Ice Shelves. The Indian Ocean typically presents high concentration between 40°E – 50°E west of Amery Ice Shelf, but a singular maximum between 80°E – 90°E is seen in 2000, close to the Amery and West Ice Shelves. The Bellingshausen/Amundsen Seas sector shows two main concentration peaks, between $65\text{--}80^{\circ}\text{W}$ (Bellingshausen Sea) and $100\text{--}120^{\circ}\text{W}$ (Amundsen Sea) close to George VI, Wilkins, Pine Island Glacier, Dotson, and Getz.

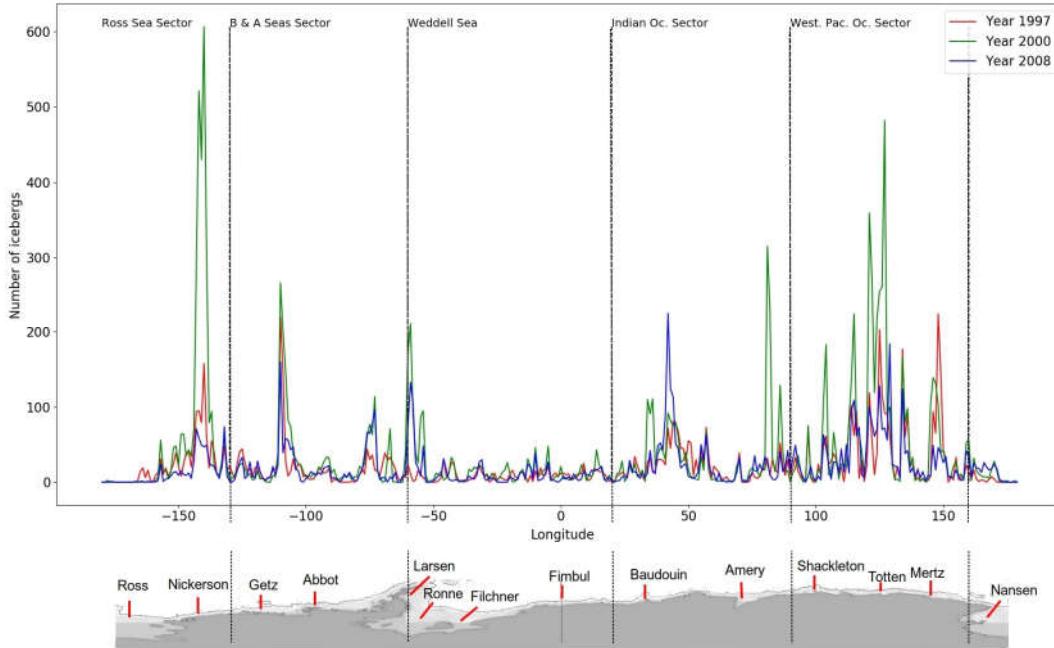


Figure 7. Zonal near-coastal iceberg distribution for the years 1997 (red line), 2000 (green line), and 2008 (blue line). The division into Antarctic sectors is indicated at the top. The location of specific ice shelves is presented in the overview map below.

The Ross Sea sector exhibits a strong variability between 140–150°W close to Swinburne, Sulzberger and Nickerson Ice Shelves, with a maximum number of icebergs noted in 2000 close to 150°W. During the three years considered, the Weddell Sea sector has the smallest number of icebergs. The maximum between 50°W–60°W in 2000 and 2008 along the Antarctic Peninsula's eastern coast suggests a high calving incidence from Larsen Ice Shelf in combination with the transport of icebergs from the eastern Weddell Sea driven by the clockwise Weddell Gyre circulation (Collares et al. 2018; Gladstone, 2001; Schodlok et al. 2006).

In order to study zonal iceberg variability in the period 1997–2008 from our three realizations, differences between the years 2000 and 1997, 2008 and 2000, as well as 2008 and 1997 have been calculated. They show an increase between 1997–2000 and a decrease between 2008–2000 for all sectors.

However, the 11-year interval, comparing 1997 with 2008 (**Figure 8**), exhibits regional variability such as the increase near Larsen Ice Shelf (Weddell Sea sector), between Pine Island and Getz Ice Shelves (B&A sector), and close to Ross Ice Shelf (Ross Sector). It is important to note that the used data is based on snapshots in time, which raises obvious limitations for the interpretation of the data (see Discussion in section 4).

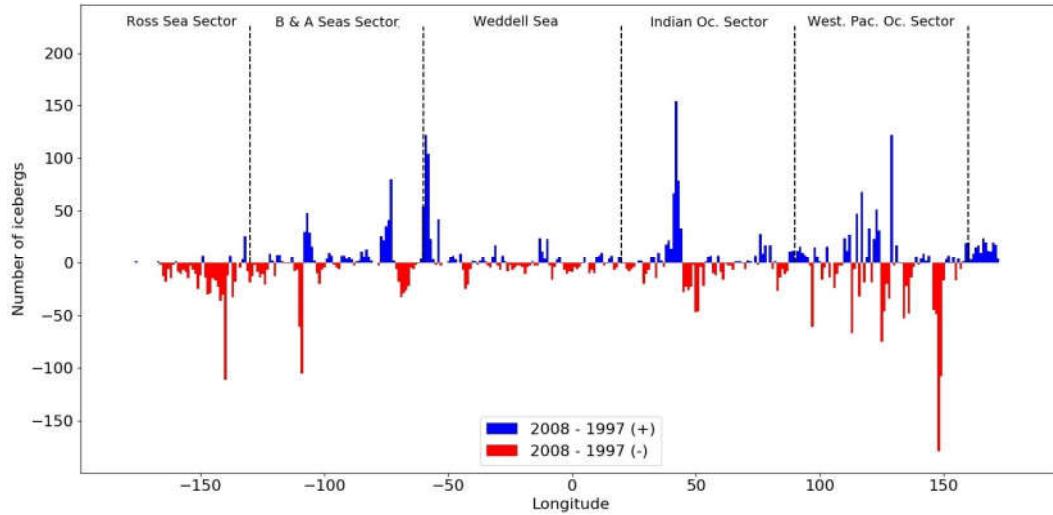


Figure 8. Straightforward difference between 2008 and 1997 in number of icebergs per longitude degree. Bars in blue (red) represent an increase (decrease) in the iceberg counts. The different Southern Ocean sectors are shown at the top.

5.2.7.3. Icebergs mass estimate and distribution

On average, 5589.34 ± 935 Gt of iceberg mass floated in the pan-Antarctic near-coastal zone. Divided into the three years, the numbers are 4641.53 Gt in 1997, 6862.81 Gt in 2000 (+32.4%), and 5263.69 Gt in 2008 (-23.3%). When considering mass per degree longitude, the average for the three years is 46.58 ± 150.1 Gt/lon. The high standard deviation is due to the presence of large and giant icebergs in the classes A4 and A5. The same analysis, limited to the classes A1–A3 of smaller icebergs, results in an average mass of 21.42 ± 31.32

Gt/Ion. The inter-annual mass variability for each Antarctic sector is summarized in **Figure 9**. Clear differences are observed between the distinct sectors in terms of mass magnitude and mass distribution per iceberg size class, usually biased by the presence of giant icebergs from class A5. In contrast with other sectors, the Western Pacific Ocean had a stable mass magnitude (> 1500 Gt) for the three years, although the mass distribution between the size classes is varying. The Indian Ocean sector also showed variations between iceberg size classes, but a huge mass reduction is seen in 2000. The latter is in contrast to the Ross Sea sector, which generally has a mass magnitude < 500 Gt in 1997 and 2008, but a huge increase to 1000–1500 Gt in 2000. More than 50% of the 2000 iceberg mass is in class A5, which could also explain part of the percent-wise increase (decrease) of giant iceberg mass in 2008 in the Western Pacific Ocean sector (in the Ross Sea sector) compared to 2000, due to possible westward drift. The Weddell Sea and Amundsen/Bellingshausen Seas sector also showed mass variability in the three years analysed.

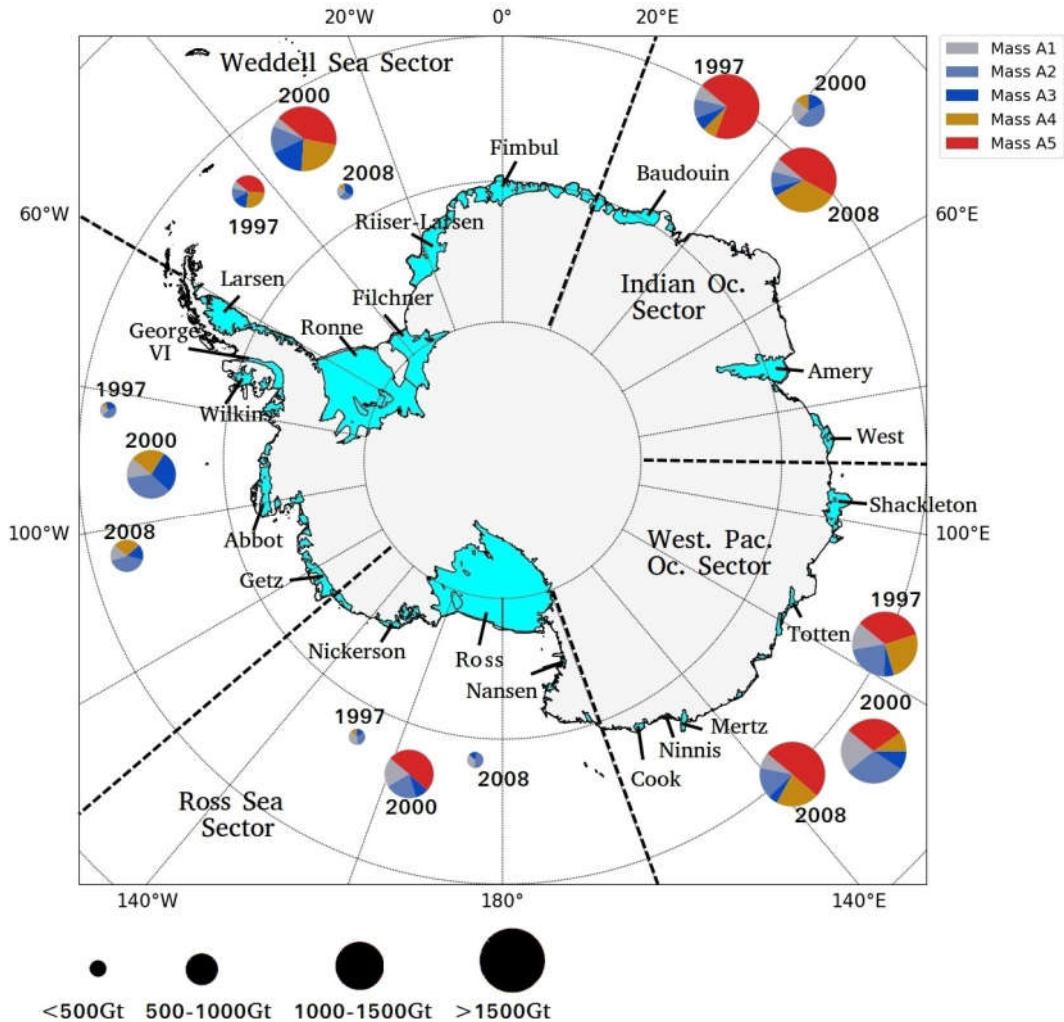


Figure 9. Iceberg mass distribution in the pan-Antarctic near-coastal zone for 1997, 2000, and 2008. Pie chart sizes represent four mass categories, < 500 Gt, 500–1000 Gt, 1000–1500 Gt, and > 1500 Gt. The color scale identifies iceberg mass per iceberg size class (**Figure 3**). The borders of the Southern Ocean sectors and location of ice shelves discussed in this work are also shown.

The first showed an increase from 1000–1500 Gt (1997) to > 1500 Gt (2000) followed by a drastic reduction to < 500 Gt (2008). The 2000 increase could partly be explained by giant iceberg drift from the neighbouring Indian Ocean sector, which showed a huge mass reduction in 2000 with no giant icebergs remaining in class A5. Finally, the Amundsen/Bellingshausen Seas sector showed similar behaviour, increasing from < 500 Gt (1997) to 1000–1500 Gt (2000) and then reducing to 500–1000 Gt (2008). No icebergs larger than 1000

km^2 (class A5) were detected in the three available years in the Amundsen/Bellingshausen Seas.

The relationship between iceberg size class and iceberg mass (**Figure 10**) demonstrates that, although the majority belongs to the classes A1 and A2, in terms of mass their percent-wise contribution is less dominant: 31.6% in 1997, 41.4% in 2000 (+9.8%), and 28.3% in 2008 (-13.1%). On average, although classes A1 and A2 represent $98.5 \pm 0.16\%$ of the total number, their mass contribution was on average only $33.7 \pm 5.5\%$. The results highlight the major role of less frequent icebergs $> 100 \text{ km}^2$ (A4), and in particular icebergs $> 1000 \text{ km}^2$ (A5), since they can easily 'bias' the near-coastal iceberg distribution. In fact, the classes A4 and A5 represent a very small percentage of the iceberg counts with 0.19% in 1997, 0.18% in 2000, and 0.27% in 2008. However, their mass contribution was 58.9% in 1997, 43.5% in 2000, and an overwhelming 63.4% in 2008.

Although the near-coastal iceberg distribution is potentially subject to seasonal and inter-annual variability (Jacobs et al. 1992; Rackow et al. 2017), the iceberg mass appears to be relatively stable when comparing 1997 and 2008 (**Figure 9**). However, a more detailed zonal resolution (**Figure 11**) reveals a major mass increase close to Totten, Mertz, and Ninnis Ice Shelves in the West Pacific Ocean. In addition, increases were noted close to Amery and West Ice shelves (Indian Ocean), along Larsen Ice Shelf (Weddell Sea), and close to George VI and Pine Island Ice Shelves (Bellingshausen/Amundsen Sea), while the Ross Sea sector did not show any significant increases.

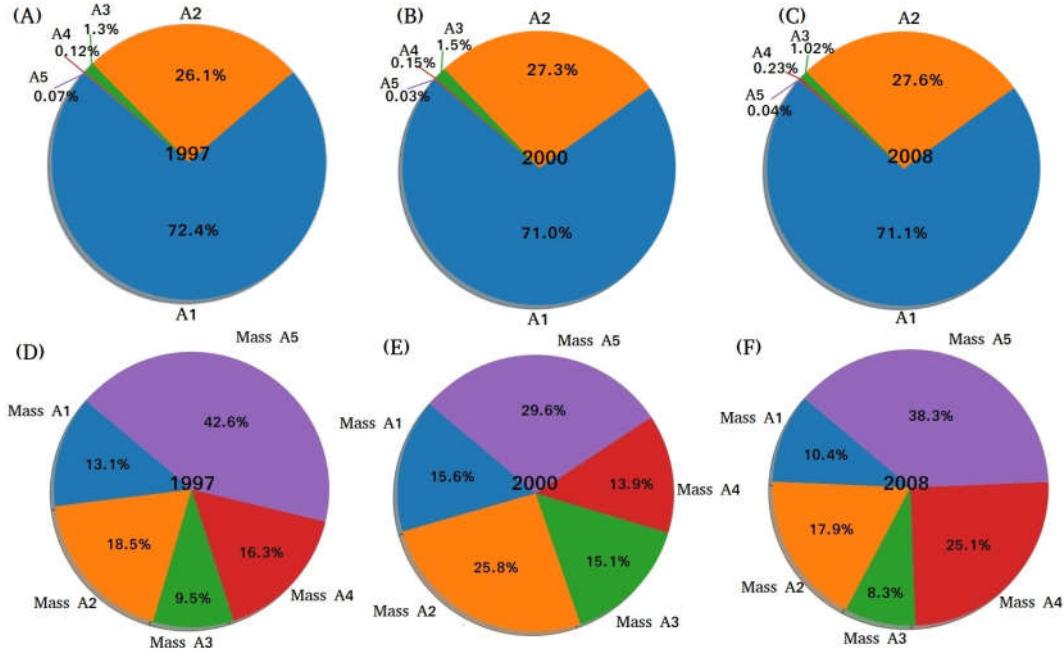


Figure 10. Relationship between iceberg size class (A, B, C – upper) and iceberg mass (C, D, E – lower) for 1997, 2000, and 2008, respectively.

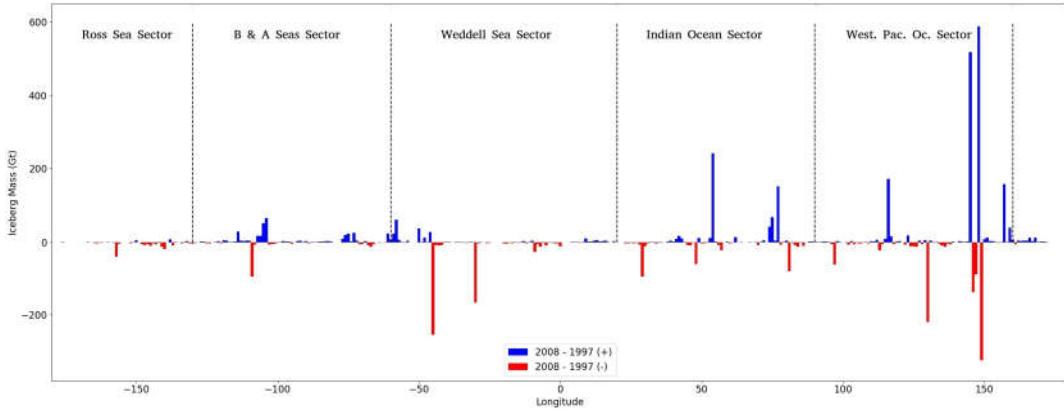


Figure 11. Longitudinal difference in pan-Antarctic iceberg mass [Gt] between 2008 and 1997.

Finally, we compare iceberg distribution (**Figure 12**, panels A, B, and C) with mass distribution (**Figure 12**, panels D, E, and F), divided into the five sectors for the three years 1997, 2000, and 2008, respectively. Although the percentage of icebergs in the five sectors remains relatively unchanged between 1997, 2000, and 2008 (upper panels), the mass distribution depicts a highly dynamic

variability (lower panels). In 1997, the Indian Ocean sector is the major contributor of iceberg mass with 36.7%, which reduces to 10.4% in 2000 (-26.3%), but almost reaches the 1997-level in 2008 with 36.6% (+26.2%). Second in terms of iceberg mass is the Western Pacific Ocean, which contributes 34.1% in 1997, 25.6% in 2000 (-8.5%), and 41.8% in 2008 (+16.2%). In general, near-coastal iceberg mass seems to be primarily concentrated in the Indian and West Pacific Ocean sectors, documented by high combined percentages of 70.8% in 1997 and 78.4% in 2008. In the year 2000, a very different pattern is observed with a much larger percentage of iceberg mass concentrated in the Weddell Sea and Ross Sea sectors. The increases result from more icebergs of classes A3–A5, i.e., more than 3 times in the Weddell Sea (from 20 to 70 icebergs) and more than double in the Ross Sea (from 14 to 30 icebergs). This makes the Weddell Sea sector the most dominant in terms of near-coastal iceberg mass in this particular year, highlighting the large potential for mass/freshwater input to the Weddell and Ross seas, where the biggest ice shelves are located.

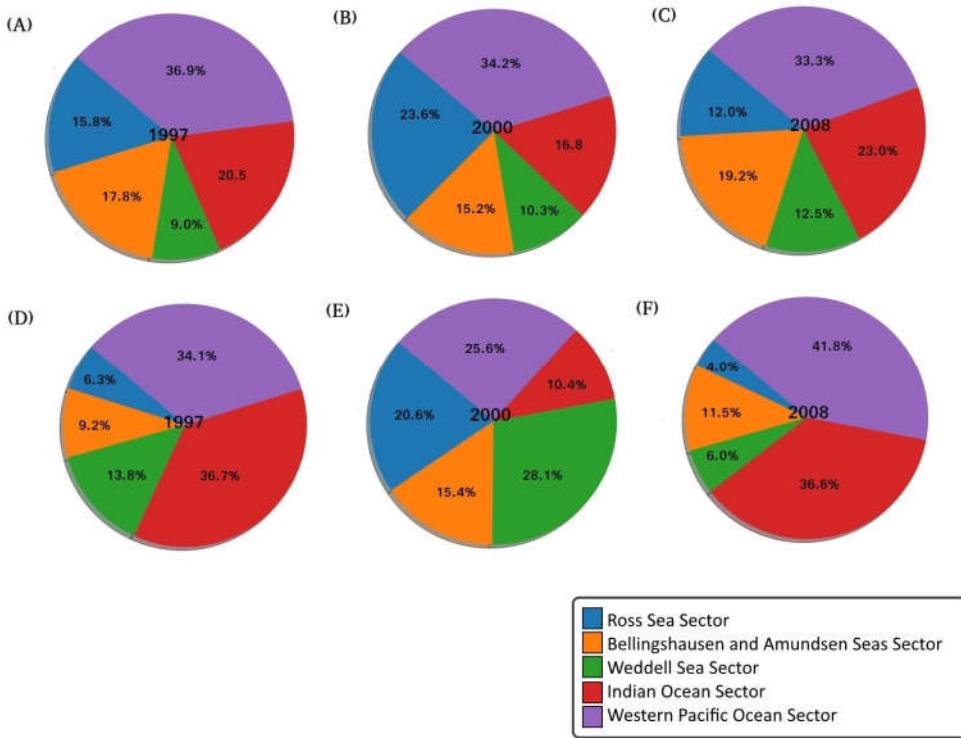


Figure 12. Iceberg (A, B, C – upper) and mass (D, E, F – lower) distributions for the five sectors in (left) 1997, (middle) 2000, and (right) 2008.

5.2.8. Discussion and Conclusions

An autonomous machine learning approach to detect icebergs, followed by visual inspection to remove false positives, was applied to three Antarctic near-coastal high-resolution satellite image mosaics. Provided by the Canadian Cryospheric Information Network (CCIN), all mosaics were built from large collections of Synthetic Aperture Radar (SAR) images acquired for the years 1997, 2000, and 2008. The goal was to investigate the main patterns of iceberg size and mass distribution and to identify their variability in time. The latter is a very important information for current model-based efforts to estimate the iceberg meltwater distribution in the Southern Ocean. The use of a minimal pixel area threshold of 10 image pixels allowed us to identify 28607 icebergs in total with a horizontal surface area between 0.1 and 4567.82 km².

Although the mosaics used in this study represent snapshots in time and are geographically restricted to the Antarctic near-coastal zone, the data sets allow us to perform a large-scale overview of the pan-Antarctic coastal conditions. To our best knowledge, this is the first time that autonomous machine learning methods have been applied for the detection of icebergs, resulting in estimates of their spatial distribution as well as their local size distribution. For oceanographic studies, such as the freshwater input from melting icebergs, we emphasize that the actual iceberg distribution is much broader than the coastal zone (Gladstone, 2001; Wesche & Dierking, 2015). Our results, however, nicely complement the ongoing discussion about the Antarctic iceberg distribution in the open Southern Ocean (Tournadre et al. 2016, 2012, 2008) and provide reliable data sets that can be used for initializing coupled ocean-iceberg models. The determined iceberg size distribution follows reasonably well the $-3/2$ power law slope observed and modelled for brittle fracture (Astrom, 2006). Our slope of -1.83 (Fig. 5) matches the -1.52 ± 0.32 slope given by Tournadre et al. (2016), although we notice that it is on the low end of their given range. This might be indicative of the difference between the coastal and open-ocean environments, where different processes might be at work leading to iceberg fragmentation. Moreover, giant icebergs are often grounded along the coast or shielded from their surroundings when captured in sea ice, and we suspect this could affect the right tail of the distribution and thus the computed slopes. In addition, the combined data set by Tournadre et al. (2016) for small and large icebergs lacked medium-sized icebergs entirely. Although limited to the coastal region only, our results fill this gap in the range from $8\text{-}200\text{ km}^2$. We therefore did a sensitivity test where we ignored all medium-sized icebergs in the range between $8\text{-}200\text{ km}^2$

but got virtually identical slope estimates, which confirms the assumption made by Tournadre et al. (2016) to determine a global power law. The updated power law computed here for near-coastal Antarctica can be used by modellers to initialize the iceberg size distribution close to the coast. Such models are capable to compute the open-ocean iceberg distribution and the meltwater contribution along their drift.

In line with previous studies (Rackow et al. 2017; Wesche & Dierking, 2015), the pattern of iceberg size distribution around Antarctica depicts a major occurrence of icebergs smaller than 1 km^2 , covering the whole Antarctic coastal zone. Despite a potential seasonal and inter-annual variability of the near-coastal distribution, our counts of small icebergs (A1 and A2) in the three years appear to be representative for the near-coastal regions, in agreement with Rackow et al. (2017). Furthermore, the regional variability and the large-scale spatial patterns resemble the findings of Jacobs et al. (1992), Gladstone (2001), Tournadre et al. (2012), Tournadre et al. (2016), and Rignot et al. (2013): High iceberg accumulation close to small ice shelves that calve frequently in contrast to the two large ice shelves Filchner-Ronne in the Weddell Sea sector and Ross Ice Shelf in the Ross Sea sector that typically calve large icebergs at a lower rate. Although the number of icebergs in these sectors is not particularly high compared to the other sectors, the presence of massive ice shelves and the possibility for calving of large icebergs may 'bias' the mass distribution in any particular year (Silva et al. 2006). Also, the peaks of iceberg concentration fit well with the presence of ice shelves exhibiting a dense pattern of surface structure (e.g., Amery, Shackleton, Mertz). Wesche, Jansen, and Dierking (2013) separated the regions defined in this study into even smaller entities (A, B, C, D),

where the Western Pacific Ocean Sector (their sectors B and C) has the highest number of small ice shelves with such a pattern, which might cause the calving of small icebergs. The latter is supported by Tournadre et al. (2012), who identified, based on altimeter data for the open-ocean between 2002 and 2010, a maximum iceberg concentration between 65°E–120°E. Due to the prevailing westward drift in the coastal current (Romanov et al. 2008), the icebergs could have been calved from the Amery, Shackleton, and West Ice shelves.

The total mass input per year from ice sheets to the ocean is given by calving fluxes along the Antarctic coastline (Wesche & Dierking, 2015) and has been presented and discussed in the last decades by numerous authors using different approaches that evolved over time. Jacobs et al. (1992) calculated a total calving rate of 2016 ± 672 Gt/yr based on ship observations. Gladstone (2001) estimated 1331 Gt/yr based on balance flux calculations using the net accumulation rate. Silva et al. (2006) estimated 1089 ± 300 Gt/yr only from giant icebergs. Recently, more reliable estimates have been applied, which remove the restriction to giant iceberg detection and reduce the large uncertainties associated with temporal and spatial limitations of ship observations, errors in size estimates, and duplicate sights. Depoorter et al. (2013) estimated a total calving flux of 1321 ± 144 Gt/yr based on altimetry data and SAR interferometry. Rignot et al. (2013) present a total calving flux of 1089 ± 139 Gt/yr from high-resolution glaciological estimates of ice-shelf melting around the entire continent. Wesche and Dierking (2015) estimate a total near-coastal iceberg mass of 5167 Gt (for September/October 1997) based on the RAMP AMM-1 mosaic. Here, we calculate 4641.53 Gt in 1997, 6862.81 Gt in 2000, and 5263.69 Gt in 2008, in partial agreement with the results for 1997 presented by Wesche and Dierking

(2015). Part of the difference between the 1997-estimates can be attributed to a different number of detected icebergs in class A4 and to differences in the applied area estimate method. We missed four icebergs of class A4 in the Indian Ocean sector due to segmentation failure that resulted from partially connected icebergs, causing the underestimate. Again, we need to stress that manual detection was not performed and only false positives were removed by visual inspection. On the other side, the estimate given by Wesche and Dierking (2015) appears to be a slight overestimate for the actual 1997-conditions. Although the relation between calving flux per time and (near-coast) iceberg mass observed at a given time is not directly comparable, the mass computed in this study is on average 4–6 times larger than the annual calving flux provided in previous studies. The 4-6 times discrepancy between our iceberg mass in the Antarctic coastal zone, calculated for three specific years, and the mean calving fluxes from other studies might indicate a strong inter-annual variability of the fluxes and/or an iceberg mean residence time of 4-6 years on the Antarctic continental shelf.

Although our results provide a realistic picture about the near-coastal iceberg conditions around Antarctica, estimating the total mass from snapshots in time and their interpretation has to be done with caution. Iceberg decay is governed by different half-life times depending on size (Rackow et al. 2017), geographic location, and oceanographic and atmospheric conditions (Orheim, 1980). Part of the detected icebergs may have been present for longer time, particularly in the near-coastal environment due to grounding, and others might have been newly calved. Furthermore, some large and giant icebergs, which can potentially impact the mass distribution between the sectors significantly in any

particular year, might have drifted out of the near-coastal zone shortly before the snapshots were taken and therefore were missed by our analysis.

Despite the obvious limitations when studying snapshots in time, our results demonstrate the applicability of autonomous machine-learning methods based on SAR images for large-scale iceberg studies. We present and compare the pan-Antarctic near-coastal iceberg distribution for the years 1997, 2000, and 2008, discussing the wide range of iceberg sizes and estimates for the spatial distribution of iceberg mass. The results highlight the predominance of smaller icebergs and the relevance of less frequent large and giant icebergs that can strongly impact the iceberg mass in any given year. The spatial distribution complements previous studies restricted to open-ocean regions, showing that regional variability cannot be neglected. In addition, although our mass estimates are limited both in time and by a fixed iceberg thickness, they allow to discuss regional mass variability and to estimate an average residence time for icebergs in the near-coastal ocean of about 4–6 years. Altogether, our results highlight that potential future campaigns leading to SAR mosaics for the entire Southern Ocean would be of great interest, because they would shed light on the iceberg mass variability in space and time and bridge the existing gap between ongoing efforts to estimate open-ocean and near-coastal iceberg distributions. The latter might become essential for future climate studies that consider in detail the fresh water fluxes from the Antarctic Ice Sheet.

5.2.9. Appendix A: Improving Generalization of the Detection Method

Improved generalization of the B2019 method is achieved through an adaptive machine-learning architecture, centered on (i) graph-based superpixel

segmentation to reduce the high-resolution pixel space to a set of meaningful homogeneous regions (Felzenszwalb & Huttenlocher, 2004). Moreover, it is achieved through (ii) a gradual learning curve based on incremental learning (Impoco & Tuminello, 2015; Polikar, 2006) and by (iii) the combination of heterogeneous predictive models (ensemble learning) that are specialized in different aspects of the same problem, using different arrangements of image features (Dietterich, 2000; Marbach et al. 2012; Polikar, 2006; Zhou, 2012). The goal is to improve the classification over ambiguous targets, individualizing the different objects present in the SAR scenes; preserving details in low-variability image regions while ignoring details in high-variability regions; and to provide a convenient primitive to compute a set of heterogeneous image features, capable to describe the objects under distinct aspects. At the same time, the ensemble/incremental predictor reduces the instability of individual predictive models while increasing the versatility to adapt to new targets, even outliers.

5.2.10. Appendix B: Detection Method Performance

The main problem in detecting icebergs from SAR images comes from the ambiguous signature reflected by icebergs and their surroundings. The ambiguity arises from oscillations in the radar backscatter intensity (σ_0) caused by meteorological, sea-state, and surface variability (e.g., due to the presence of snow accumulation and melt ponds) and acquisition parameters (e.g., polarization and incidence angle). This behavior often causes radar-based iceberg signatures to overlap with signatures from surrounding objects—mainly sea-ice—which makes iceberg identification in the near-coastal environment a challenging task. Regarding the technical details of our machine learning

approach for automatic iceberg detection from SAR images, we explore the magnitude of the method's errors and expose main difficulties.

The analysis follows in part the approach applied by Wesche and Dierking (2015). After the automatic detection, a visual inspection was applied in order to reduce the magnitude of potential errors. Obvious 'false positives' were manually removed, usually noted as objects partially connected to the coastline, sea-ice ridges, and spots of rough open water. This way, 616 objects were removed (2.12% of the total), resulting in a detection accuracy of 97.8%.

Of the 616 objects removed, 364 have been discarded due to a connection with the coastline, 204 due to sea-ice ridges, and 48 were attributed as bright spots of rough open water. By the visual inspection false positives were predominantly caused by the identification of small ice shelf 'corners' as icebergs. This issue has been related to the low resolution/precision of the coastline along some ice shelves (possibly due to the collapse of small parts) and along some coastal corners, falsely identifying land or ice shelf pixels as icebergs.

Missed icebergs were observed for both size extremes, usually related to small icebergs surrounded by very bright sea-ice, and/or large icebergs with wide texture variation. Four large icebergs were missed, directly associated to faults on the segmentation stage. Frequently, the misses were related to (i) clusters of icebergs with pixel distance less than 20 grey-scale levels and (ii) due to a wide textural (or spectral) gradient across the iceberg surface. As a consequence of the segmentation failures, missed icebergs were discarded before the identification stage. Different to the approach adopted by Wesche and Dierking (2015) although we applied some manual inspection to remove false positives—we avoided manual detection entirely, although it represents a deficit in the

computed total iceberg number. This operational choice was made to avoid possible errors from manual methods, since they depend on the operator's precision to contour the iceberg shape. Moreover, an entirely automatic method allows for easier applicability to very large data sets, which would be rather time-consuming with methods that partly rely on manual detection.

In addition to the method's errors, we need to consider that some small icebergs (less than 1 km²) were detected more than once, because all mosaics were built from large image collections covering a time interval of months. Therefore, some icebergs might have drifted during the acquisition and thus appeared in different images. Obvious double counting of icebergs > 5 km² was manually removed, and double counting of icebergs > 100 km² was not detected by visual inspection. In agreement with Wesche and Dierking (2015), double counting is mainly restricted to classes A1 and A2 and represents a minor influence on the local distribution.

To estimate the error of iceberg area, we compared the automatic sightings with manually selected icebergs by counting the number of pixels using an image editor software. Then, we applied the equation described in Section 2.3, similar to the one used by Mazur, Wahlin, and Krezel (2017); Silva and Bigg (2005); Wesche and Dierking (2015); Williams, Rees, and Young (1999). Positive and negative pixel count deviations were noted, on average 10±4%, associated to variations of the iceberg contour definition resulting from the automatic method. We also compared the results with the segmentation-based method proposed by Williams et al. (1999), which over- or underestimates iceberg area by ±20%. The method by Wesche and Dierking (2012) tends to overestimate iceberg area by approximately 10 ± 21% while Mazur et al. (2017) presented average errors of

$\pm 25\%$. Based on the performance analysis, the method achieves a robust detection accuracy of 97.76%. The iceberg area estimate, based on the number of pixels inside the iceberg contour, also seems to be reliable. In general, the method's performance is sometimes reduced in the segmentation stage. However, the ensemble learning in conjunction with the incremental learning proved to be efficient and robust with regard to iceberg detection in a wide range of different gray-level, texture, and shape combinations.

5.2.11. Acknowledgments

This study is a contribution to the activities of the Brazilian High Latitudes Oceanography Group (GOAL) and the Brazilian National Institute of Science and Technology of the Cryosphere (INCT-CRIOSFERA; 465680/2014-3). The GOAL has been funded by the Brazilian Antarctic Program (PROANTAR) through the Brazilian Ministry of the Environment (MMA), the Brazilian Ministry of Science, Technology, Innovation and Communication (MCTIC), the Council for Research and Scientific Development of Brazil (CNPq; 405869/2013-4), and CAPES Foundation (AUXPE 1995/2014). M. M. Barbat acknowledges the fellowships from CNPq (140910/2016-6), CAPES Foundation (88881.177236/2018-01) and Alfred Wegener Institute for Polar and Marine Research (AWI). M. M. Mata acknowledges CNPq grant 306896/2015-0. We also thank the Canadian Cryospheric Information Network (CCIN) for providing the SAR data used in this study, which can be accessed at <https://www.polardata.ca/pdcsearch/>. In addition, we have uploaded the full iceberg database and software used in this work to the institutional website of Federal University of Rio Grande, Brazil at <https://goal.furg.br/producao-cientifica/supplements>.

5.3. Artigo 3: *Automated iceberg tracking with a machine learning approach applied to SAR imagery: A Weddell Sea case study*

O terceiro artigo, de autoria de Mauro M. Barbat, Thomas Rackow, Christine Wesche, Hartmut H. Hellmer e Mauricio M. Mata, é intitulado **“Automated iceberg tracking with a machine learning approach applied to SAR imagery: A Weddell Sea case study”** e será submetido ao periódico **“ISPRS Journal of Photogrammetry and Remote Sensing”**.

5.3.1. Síntese do artigo 3

Embora os potenciais riscos à navegação e os impactos oceanográficos atribuídos aos icebergs, operacionalmente o monitoramento é usualmente limitado a regiões livres da presença de gelo marinho e/ou a icebergs gigantes. Estas limitações devem-se, em parte, às dificuldades relacionadas à detecção e rastreamento no ambiente polar.

Neste estudo, um método alternativo e automatizado para rastreamento e análise de icebergs a partir de imagens SAR é apresentado. Para demonstrar a aplicabilidade do método, foi realizado um estudo de caso para a região do Mar de Weddell, no Oceano Austral, baseado em um conjunto de 1213 imagens adquiridas entre 2002 e 2011. No total, 414 icebergs com áreas superficiais a partir de $3,4 \text{ km}^2$ foram investigados em relação aos seus padrões de deriva, tamanho e desintegração. Esta última permitiu monitorar e estimar o aporte de água doce a partir da variação de área superficial das estruturas originais.

Automated iceberg tracking with a machine learning approach applied to SAR imagery: A Weddell Sea case study

Barbat, Mauro M.¹, Rackow, Thomas², Wesche, Christine², Hellmer, Hartmut H.² and Mata, Mauricio M.¹

¹Institute of Oceanography, Federal University of Rio Grande-FURG, Rio Grande-RS, 96203-900, Brazil

²Alfred Wegener Institute, Helmholtz Centre for Polar and Marine Research, Bremerhaven, Germany

Correspondence to: Barbat M. M. (maurobarbat@gmail.com)

Keywords: icebergs, SAR, monitoring, tracking, Southern Ocean, machine learning, Antarctic

5.3.2. Key points

- A robust machine learning method for iceberg detection was extended by tracking capabilities.
- Long-term tracking is challenging due to abrupt changes in iceberg morphology.
- Using 3 different metrics, a wide range of icebergs can be tracked.
- The method allows to monitor freshwater input over time because the surface area detection is reliable, even in difficult polar environment with presence of sea ice or ocean waves.
- Global automatic iceberg tracking appears feasible with more complete datasets.
- More work is required to follow iceberg until full disintegration.

5.3.3. Abstract

Icebergs are huge continental ice fragments that range in size from a few meters up to tens of kilometres. Once in the ocean, they may drift far away from their region of origin. Steered mainly by ocean currents and winds, drifting icebergs represent a significant hazard for polar navigation and are able to impact the ocean environment around them. Freshwater flux and the associated cooling from melting icebergs can locally decrease salinity and temperature and thus affect ocean circulation, biological activity, sea ice, and --on larger spatial scales-- the whole climate system. However, despite their potential impact, the large-scale operational monitoring of drifting icebergs in sea ice-covered regions is as of today typically restricted to giant icebergs larger than 18.5km only. This is due to difficulties in accurately identifying and following the motion of much smaller features in polar ocean regions from space. So far, tracking of smaller icebergs from satellite imagery thus has been limited to open-ocean regions not covered by sea ice. In this study, a novel automated iceberg tracking method, based on a machine learning-approach for automatic iceberg detection, is presented. To demonstrate the applicability of the method, a case study was performed for the Weddell Sea region, Antarctica, using 1213 Advanced Synthetic Aperture Radar (ASAR) satellite images acquired between 2002-2011. Overall, a subset of 414 icebergs with surface areas between 3.4 km^2 and 3612 km^2 were investigated with respect to their prevalent drift patterns, size variability, and average disintegration. Between 2002-2011, the majority of the tracked icebergs drifted between 1.3 km to 2679.2 km westward around the Antarctic continent, following the Antarctic Coastal Current and the Weddell Gyre, at an average drift speed of $3.6 \pm 7.4 \text{ km day}^{-1}$. The method also allows to estimate an average annual

disintegration rate of $20.8 \pm 18.3\%$, which amounts to an estimated average annual mass loss of 199 ± 153 Gt/year into the Weddell Sea. Our machine-learning approach is a robust alternative for detection of highly dynamic objects such as icebergs, even under ambiguous SAR background signatures. The extension to an automated long-term tracking method for icebergs is more challenging as the iceberg shape can vary significantly due to abrupt disintegration or calving of smaller bergy bits; this complicates a matching between individual iceberg detections and grouping them into a set of long-term trajectories. Nevertheless, using more complete future data sets, an automatic monitoring of Antarctic icebergs will likely be possible even in the challenging near-coastal environment where the presence of sea ice and coastal ocean dynamics such as surface waves usually pose major obstacles for other approaches.

5.3.4. Introduction

Icebergs are key components in the interaction between the ice sheet and the Southern Ocean (Silva and Bigg, 2005). Thousands of icebergs drift through the Southern Ocean and away from their region of origin, suffering from fractures and gradual melting associated with rising ocean temperatures and increasing wave action on their way to the Antarctic Circumpolar Current (ACC) (Bigg et al., 1997), and higher basal melting after crossing the southern ACC front (Rackow et al., 2017). The injection of cold fresh water through iceberg melting (cooling and freshening) can play an import role in disrupting temperature and salinity patterns, and affect ocean circulation, sea ice, and bottom water formation

(Enderlin et al., 2016; Romanov et al., 2008; Schodlok et al., 2006). However, although the integrated freshwater input from icebergs into the Southern Ocean has been found to be of similar magnitude to basal melting (Depoorter et al., 2013; Jacobs and Hellmer, 1992; Silva et al., 2006), little is known about individual iceberg trajectories, iceberg calving, and melting as they are still poorly quantified by observations (Mazur et al., 2017; Silva and Bigg, 2005; Stuart and Long, 2011). This lack in information is partly due to the complexity of large-scale detection and monitoring of icebergs in polar regions. The dense polar atmosphere, shipping hazards, sparse iceberg locations, and the wide range of iceberg sizes and shapes imposes major obstacles for observational as well as modelling and remote sensing efforts (e.g. Jacka and Giles, 2007; Romanov et al., 2012; Stern et al., 2016; Rackow et al., 2017; Wesche and Dierking, 2012). This often restricts monitoring to giant icebergs larger than 18.5 km in length (Collares et al., 2018; Gladstone and Bigg, 2002; Silva et al., 2006; Stuart and Long, 2011).

While smaller icebergs have been documented by ship observations (Jacka and Giles, 2007) and by space altimeter (Tournadre et al., 2016), giant icebergs have been systematically tracked by the U.S. National Ice Center (NIC) and the Brigham Young University (BYU), using scatterometer data (Stuart and Long, 2011). However, ship observations are severely limited in space and time, and the study by Tournadre et al. (2016) was limited to open-ocean regions. Moreover, although the presence of giant icebergs has the potential to significantly increase the amount of fresh water input from icebergs in any given year (Barbat et al., 2019a), the calving of giant icebergs is usually a decadal event and giant icebergs are thus much less in number when compared to smaller

icebergs that calve more regularly (Barbat et al., 2019a; Rackow et al., 2017). New alternatives for large-scale detection and monitoring of icebergs –for a wide range of size classes– are particularly necessary to fill our knowledge gap about the main drift paths and to determine reliable estimates of the spatially and temporally varying freshwater flux from the Antarctic ice sheet to the Southern Ocean, based on the whole range of icebergs sizes.

Synthetic Aperture Radar (SAR) satellite images are derived by emission of microwaves that penetrate the dense polar atmosphere even under adverse weather conditions, and allowing to produce images even at night (Wesche and Dierking, 2012). Furthermore, SAR data have become a standard dataset for sea ice and iceberg research due to the high spatial and temporal coverage around Antarctica since the year 1991 (Wesche and Dierking, 2012).

The main objective of this study is to (i) document the main iceberg drift patterns in the Weddell Sea, Antarctica, and (ii) to explore the applicability of an autonomous method to large-scale iceberg tracking from SAR images, where the detection part is based on a novel machine learning approach. We thus propose an alternative to more traditional methods based on scatterometer data that are usually restricted to giant icebergs only, typically bigger than 18.5 km in length (Silva et al., 2006).

As a proof of concept, we initially focus here on the Weddell Sea, Antarctica, using a dataset consisting of 1213 Synthetic Aperture Radar (SAR) images, although the method can potentially be applied globally in the future to a more complete dataset. In our case study, 414 individual drifting icebergs with horizontal surface areas between 3.4 km^2 (about 1.8km side length) and 3612 km^2 were tracked between 2002—2011. We then investigated their prevalent drift

patterns and size variability, and determined an estimated mass loss based on the observed surface area reduction. The iceberg drift pattern follows the main (surface) ocean currents in the Weddell Sea region and we could determine the general paths of freshwater input from icebergs. This work presents a promising alternative for large-scale tracking of icebergs and their freshwater dispersion from space that is completely autonomous and that covers a much larger iceberg size range than what typical current methods can achieve. It thus has potential implications not only for studies of oceanography and glaciology, but also for shipping safety in polar seas.

In the subsequent sections, we present the data and the tracking method, followed by the iceberg drift and disintegration results. A discussion and conclusion completes this paper.

5.3.5. Data and Methods

5.3.5.1. Advanced Synthetic Aperture Radar Images

In this study, 1213 ENVISAT Advanced Synthetic Aperture Radar (ASAR) Wide Swath Mode (WSM) images of the Weddell Sea region, acquired between 2002 and 2011, were used. All ASAR images were acquired at C-Band (5.3 GHz, wavelength ~5.6 cm) and with HH (Horizontal-Horizontal) polarization. The spatial resolution is 150m (i.e., a pixel size of 75m x 75m) and temporal resolution is 35 days (ESA, 2007). The WSM products present distinct advantages due to enhanced capabilities in terms of coverage (400 km wide range). They also offer more options with respect to incidence angles, polarization, and modes of operation.

For this study, the dataset was initially calibrated (so that each pixel intensity can be directly related to the radar backscattering strength), re-projected (to the EPSG:3031 WGS 84 projection), and speckle-reduced. Moreover, land data was removed and the images were converted to 8-bit unsigned integer GeoTIFF images. For our tracking purposes, the wide strip of covered ocean of approximately 400km x 400km resulting from the ASAR WSM images further improves the temporal resolution of 35 days. Due to overlapping of different passages of the satellite over the same area, individual drifting icebergs are often observed in different scenes, which effectively increases the temporal resolution. An example for how the temporal resolution can be increased is given in **Figure 1**.

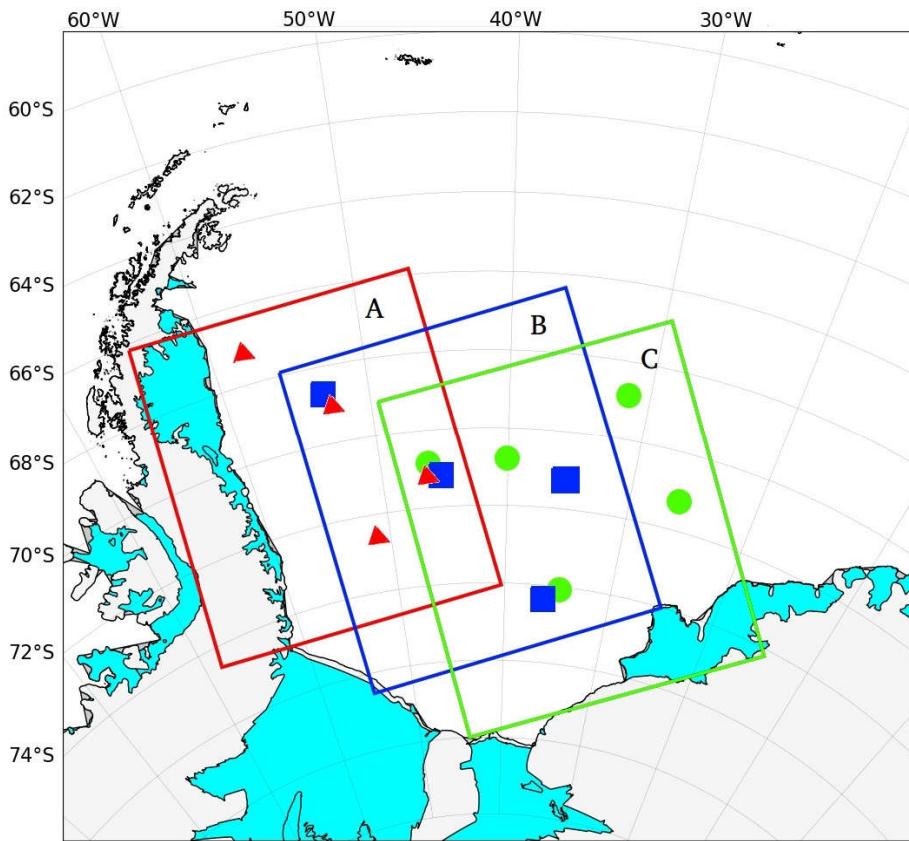


Figure 1 – Example for the overlapping resulting from different sensor passages over the same target area (rectangle A, B, and C). The wide strip of covered ocean, in addition with the fact that icebergs tend to drift between the individual passages, allows us to re-image the same objects

more frequently, in slightly different scenes. This can effectively increase the temporal resolution to a couple of days, which is much higher than the usual revisit period of 35 days. In this example, 2 objects in scene A (red triangles) are re-imaged in scenes B (blue squares) and C (green dot) ---long before the exact same area A will be revisited at the same viewing angle (see also <https://www.nrcan.gc.ca/maps-tools-publications/satellite-imagery-air-photos/remote-sensing-tutorials/satellites-sensors/temporal-resolution/9365>).

5.3.5.2. Automatic iceberg detection using machine learning

Although SAR products provide a widely explored platform for iceberg detection in polar environments, a distinct radar-derived signature for icebergs is missing. This is due to variability in backscatter intensity related to weather/sea state conditions, iceberg surface coverage (e.g., the presence of melt ponds or wet snow) and physical iceberg properties (e.g. iceberg density, layering, and air inclusions) (Gladstone and Bigg, 2002; Silva and Bigg, 2005; Wesche and Dierking, 2012; Mazur et al., 2017). The possible combination of sea ice, ice mélange, rough water, and snow-covered islands within the same satellite scene presents a very challenging and complex task for automatic iceberg detection, which would usually demand manual corrections due to the ambiguity between an iceberg and its surroundings.

For this study, an automatic machine learning method for iceberg detection from ASAR images is applied. The method proposed by Barbat et al. (2019b), herein referred to as B2019, assumes that the ambiguity between icebergs and the variety of possible background objects, yielded by SAR imagery, can be bypassed through a gradual learning flux and by basing the detection on several feature classes. Broadly speaking, the B2019 method consists of three stages: (i) graph-based superpixel segmentation (Felzenszwalb and Huttenlocher, 2004) in order to individualize the different objects present in the satellite scenes; the graph-based superpixel segmentation captures redundancies and reduces the

high-resolution pixel space to a set of meaningful homogenous regions. To reduce the instability of individual predictive models based on ambiguous features, (ii) ensemble learning (Dietterich, 2000; Marbach et al., 2012; Polikar, 2006; Zhou, 2012) is applied through the combination of heterogeneous models that are specialized in different icebergs properties observed in SAR imagery. In addition, (iii) the incremental learning approach (Impoco and Tuminello, 2015; Polikar, 2006) is applied to improve the method's versatility to adapt to new targets or even outliers.

In addition, the B2019 method provides a reliable alternative to estimate iceberg mass based on the horizontal surface properties (i.e., area, perimeter, and major and minor axes – all in image pixels), calculated in km² as

$$area_{km^2} = (NP_{pixels} - \frac{P_{pixels}}{2}) \times A_{m^2} / 10^6, \quad (1)$$

where NP_{pixels} is the number of pixels identified as an iceberg unit, P_{pixels} is the number of pixels of the iceberg outline (perimeter), and A_{m^2} is the typical physical area (m^2) covered by a pixel (spatial resolution). Half of the perimeter is removed since those pixels define the border area between the iceberg and its surroundings.

For the determination of iceberg volume and mass, we multiply the identified surface areas by a fixed thickness of 250m as in Barbat et al. (2019b) and by a typical density of $\rho = 850 \text{ kg m}^{-3}$ for icebergs in the Southern Ocean, which is consistent with previous studies (Gladstone et al., 2001; Merino et al., 2015; Rackow et al., 2017).

5.3.5.3. Extending the detection method to automatically track icebergs

To perform iceberg tracking over time, the detected icebergs must be individualized and identified in order to be recognized in different times and positions. For each iceberg, a unique signature is defined based on its morphological properties (i.e. based on iceberg shape or form). All properties are computed directly from the superpixels defined by the graph-based method in the segmentation stage, since the superpixel method adheres well to the objects boundaries (Felzenszwalb and Huttenlocher, 2004). In total, five morphological features are computed, namely major/minor axis, perimeter, area, and shape. The shape is the main feature. It is determined by computing the distance from the iceberg centroid towards its border, following the entire iceberg contour in a circular manner (360°). This way, an unidimensional array that describes the iceberg shape is filled. Afterwards, to determine the signature, this array is sorted to create a robust digital signal ---invariant to rotation and robust to noise--- similar to the approach used by Silva and Bigg (2005). A match is made by comparing the iceberg signatures in pairs and by testing for the similarity between signals. If the icebergs are matched, they are grouped and belong to the same trajectory; detected but unmatched icebergs, on the other side, are dropped from our tracking analysis. To measure the signature similarity between two 1-D signals f and g (with same length N), we compute three different similarity metrics:

- Cross-correlation c : Ubiquitous in digital signal processing (Hale, 2006; Kohn, 2005; Liu et al., 2018; Zhang et al., 2003). We use cross-correlation to

measure relative shifts between signal pairs. The cross-correlation is defined by

$$c(u) = (f * g)(u) \equiv \int_{-\infty}^{\infty} f(x)g(x + u) dx , \quad (2)$$

where u denotes the cross-correlation lag.

- Jaccard distance j : It measures the relationship between the number of sub-samples that are common to both signals and the total number of sub-samples (Niwattanakul et al., 2013; Santisteban and Tejada Carcamo, 2015; Vorontsov et al., 2013). It is defined as follows

$$j(f, g) = \frac{|f \cap g|}{|f \cup g|} , \quad (3)$$

where \cap determines common sub-samples between two signals f and g , and \cup the total number of sub-samples. This metric is useful because it can potentially recognize icebergs even after they broke into several parts, analysing each part of the iceberg perimeter.

- Euclidean distance d : It is the length of the path that connects two points directly (Barrett, 2005; Liwei Wang et al., 2005):

$$d(f, g) = \sqrt{\sum_{i=1}^N (f_i - g_i)^2} \quad (4)$$

Furthermore, to accept a pair match, the following requirements have to be fulfilled:

- A minimal similarity threshold of 80% for all similarity metrics.
- The matched iceberg pairs must be inside a maximal distance radius (km), based on the average drift velocity by size class (Bigg et al., 1997; Collares et al., 2018; Gladstone and Bigg, 2002; Gladstone et al., 2001; Schodlok et

al., 2006) and on the difference in days between the detected pairs. This is a very approximate radius limit; however, it allows us to remove obvious matching errors.

- A maximal time distance between the matched pairs (< 60 days) was defined in order to avoid abrupt shape variations and to reduce error from the radius limit requirement.

Finally, pairs already matched are removed from the search and, recursively, for every new iceberg detection the previous iceberg signature is updated. This is important since the morphological iceberg properties will vary over the course of the drift due to disintegration, melting, or breaking into smaller chunks.

5.3.5.4. Iceberg speed estimates

In order to estimate iceberg speed from the satellite images, we directly used the Euclidean distance in kilometres between the central position (in latitude and longitude) of consecutive samples for the same iceberg with a known date. To achieve a unit of velocity (km day^{-1}), we simply divided by the elapsed time between the dates in days, similar to previous tracking approaches based on image tracking (Gladstone and Bigg, 2002; Schodlok et al., 2006; Collares et al., 2018). This approach might underestimate the actual iceberg drift speed, which can be strongly increased after wind bursts or due to tidal oscillations on shorter time scales than the temporal resolution here. In addition, an average iceberg drift speed along the trajectories was estimated from the speed computed between pairs of samples.

5.3.6. Weddell Sea features

In the Southern Ocean, the Weddell Sea (**Figure 2**) has a special role as it is one of the few sites where deep and bottom water are formed along the Antarctic continental margin (Beckmann et al., 1999; Gordon, 2010). As of today, the Weddell Sea is the major contributor to Antarctic Bottom Water (AABW) formation, which is then exported to the deep global ocean (Orsi et al., 1999; Kerr et al., 2012; Ferreira and Kerr, 2017). Limited by topographic and hydrographic features, its circulation pattern is dominated by a strong cyclonic (clockwise) circulation (the Weddell Gyre, see **Figure 2**), driven at the surface by the influence of winds (Orsi et al., 1995; Su et al., 2014). The coastal regime is determined by the Antarctic Coastal Current (ACoC), where the open-ocean water masses interact with ice shelves (Fahrbach et al., 1992; Carter et al., 2008; Nicholls et al., 2009). The cold and oxygen rich ---but also relatively fresh--- Weddell Sea Bottom Water (WSBW) highlight the special role of this sector in the Southern Ocean and for the Meridional Overturning Circulation (MOC) in particular (Bigg et al., 1997; Gladstone et al., 2001; Nicholls et al., 2009).

The dominant glacial features in the Weddell sector are the Ronne-Filchner and Larsen ice shelves, floating over the southern and western Weddell Sea continental shelves, respectively (see blue areas in **Figure 2**) (Nicholls et al., 2009). From its massive ice shelves, the prevailing cyclonic circulation in the Weddell Sea leads icebergs northwards and into the ACC, where the dominant iceberg velocity component becomes eastward (Rackow et al., 2017). Gradually melting icebergs and basal melting of the floating ice shelves around Antarctica constitute the two main freshwater paths to the Southern Ocean (Silva et al., 2006; Depoorter et al., 2013). From March to September, a typically about 1m

thick sea ice cover is formed in the Weddell Sea, which can extend to about 60°S (Schodlok et al., 2006). From October/November, sea ice cover starts to retreat with a climatological minimal extent in February/March (Parkinson and Cavalieri, 2012) (**Figure 2**).

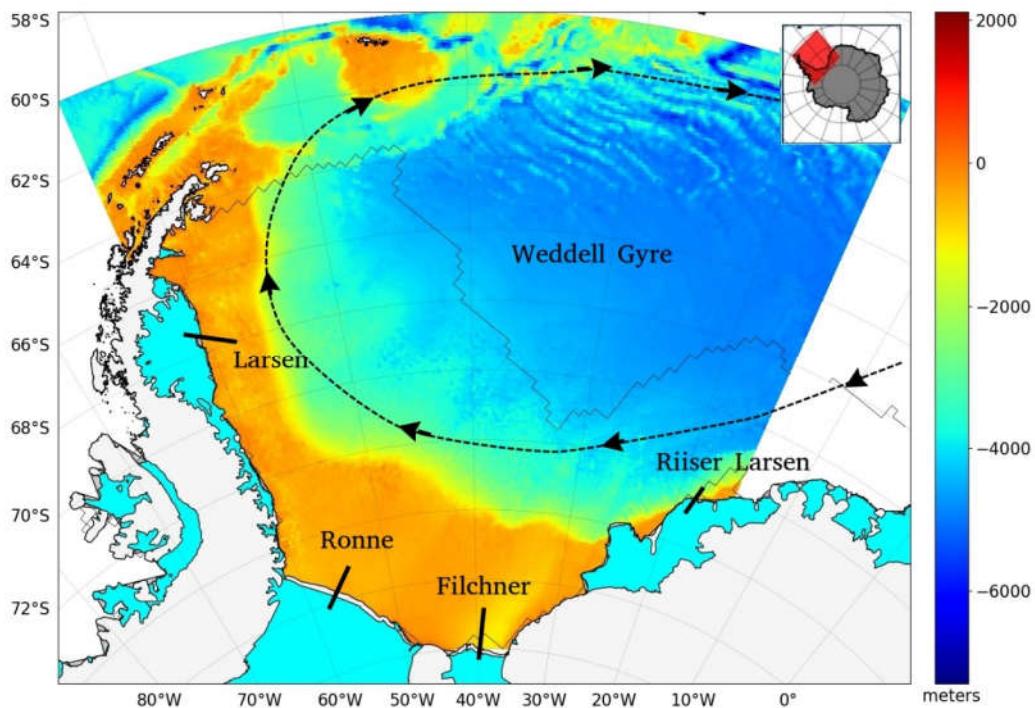


Figure 2 – Regional map of the Weddell Sea. A schematic clockwise Weddell Gyre circulation (adapted from Rintoul, 2011) is shown with a black dashed line. In addition, the average (minimal) sea ice extent in February (2002–2012) is shown with a thin grey line (https://nsidc.org/data/seacie_index/archives/). The bathymetry map is from ETOPO (colourmap) and the main ice shelves in the Weddell Sea region are depicted by blue areas. An overview map is shown in the top right corner.

5.3.7. Results

Altogether, 414 individual icebergs with horizontal surface areas ranging between 3.4 km² and 3612 km² were tracked in 2002–2011. Here, we will analyse these icebergs with respect to their prevalent drift patterns and size variability; and we will estimate an average disintegration rate from the available satellite imagery for the Weddell Sea sector. Initially, a high number of 81 new

icebergs were tracked in 2003, after the collapse of Larsen B in 2002, decreasing to a minimal of 15 newly tracked icebergs in 2011. Considering the total number of tracked icebergs by year (including drifting iceberg from previous years), we find a residence time inside the Weddell Sea sector of about 2-4 years for the investigated icebergs. A maximal number of 98 drifting icebergs was reached in 2003, and a minimal number of 17 icebergs in 2011. As a limitation of our method, part of the “new icebergs” might be “child icebergs” in the open ocean that could not be matched with a previously determined iceberg signature (e.g. after a calving or disintegration event), although formally belonging to a previously identified parent iceberg. Besides newly calved icebergs from the major ice shelves in the Weddell Sea sector, a parameter of very high relevance to climate, the “new icebergs” also include icebergs that drifted into the Weddell Sea sector from the East, or icebergs that were previously missed by the detection method.

The annual distribution of the monitored icebergs is shown in **Figure 3**.

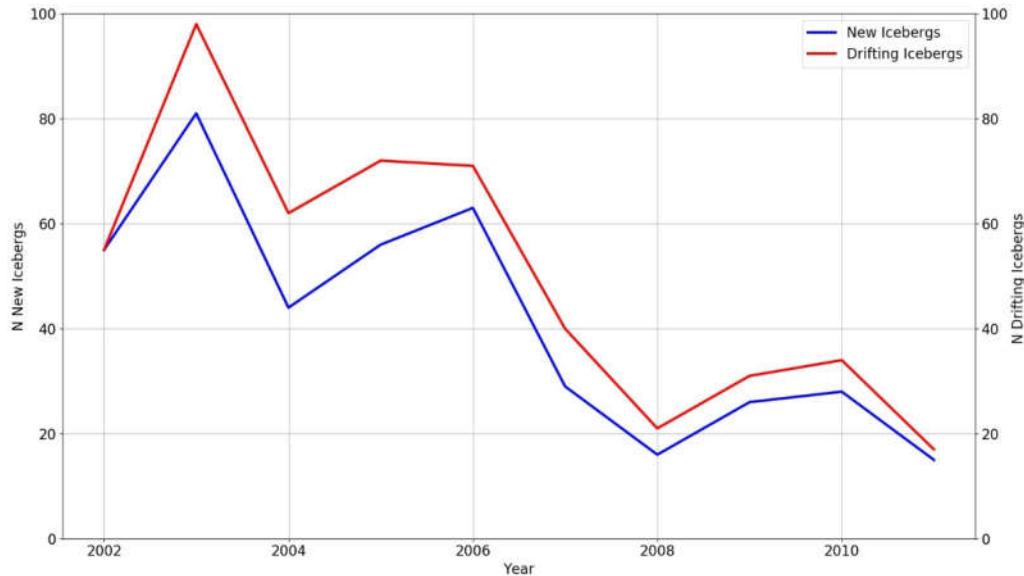


Figure 3 – Number of automatically tracked icebergs over time in the 3.4–3612 km² area range (2002–2011). The total number of present icebergs (including icebergs calved in previous years) is shown (red line) along with the newly detected icebergs by year (blue line).

5.3.7.1. Basin-scale variability

In order to explore the variability of iceberg drift inside the Weddell Sea sector, the icebergs investigated in this study were divided into two groups: “free-drifting” and stationary icebergs. We found 362 free-drifting icebergs and 52 stationary ones, the latter of which might be grounded or possibly contained within sea (or fast) ice. In order to study iceberg trajectories of significant length only, 134 free-drifting icebergs with a minimal of 4 re-detections were used for the speed statistics.

Additionally, the icebergs were grouped into four boxes; three in close proximity to the major Weddell Sea ice shelves and their potential calving fronts, and one in open water. Hereafter, those boxes are called “Larsen”, with initially 243 icebergs, “Ronne-Filchner” with 152 icebergs, “Riiser-Larsen” with 9, and “Openwater” with the remaining 10 icebergs. To better study iceberg size variability, the objects were further grouped into four size classes, $A_2 = 1\text{-}10 \text{ km}^2$, $A_3 = 10\text{-}100 \text{ km}^2$, $A_4 = 100\text{-}1000 \text{ km}^2$, and $A_5 > 1000 \text{ km}^2$, following the classification by Wesche and Dierking (2015). 30 small icebergs were counted in the A_2 class and 257 bergs in A_3 , while 104 and 23 icebergs belong to the (giant) classes A_4 and A_5 , respectively. The initial position of every tracked iceberg (points), the size class distribution for the tracked icebergs (colour of the points and pie chart), and their group (boxes) are depicted in **Figure 4**. It is apparent that the Ronne-Filchner and Larsen ice shelves can produce A_5 icebergs larger than 1000 km^2 , while this class is absent in the Riiser-Larsen sector or in the “Openwater” sector in the considered dataset. A reason might be that this size class typically stays close to the Antarctic coast (Rackow et al., 2017).

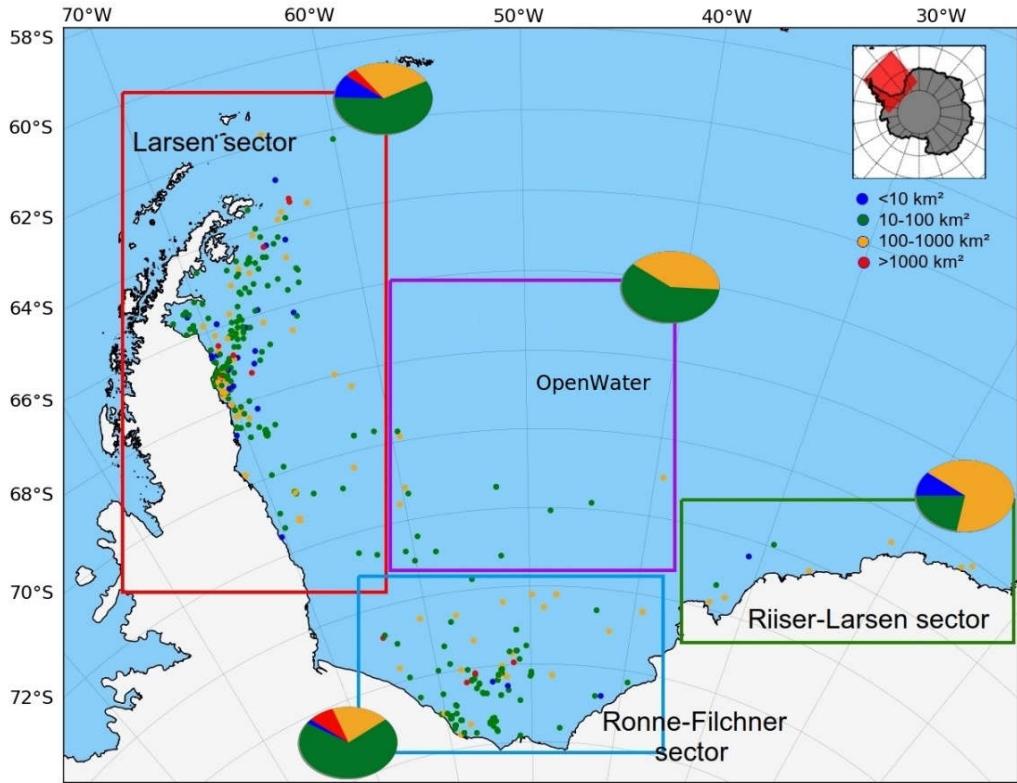


Figure 4 - Initial position for all detected icebergs (points), grouped by possible calving sector (boxes) and by size class (coloured points). In addition, the size distribution for each sector is presented (pie charts). The Weddell Sea location (red area) is indicated in the overview map (top right corner).

For icebergs in “free drift”, the observed basin-scale drift (**Figure 5**, panel B) depicts a prominent pattern: Icebergs in the Southern Weddell Sea initially follow a westward trajectory, followed by mean daily drift rates of up to $3.2 \pm 4.9 \text{ km day}^{-1}$ when they are propelled northward along the western edge of the Weddell Gyre, parallel to the Antarctic Peninsula. On average, the investigated icebergs were observed for about a year (242 ± 422 days), with typically 19 ± 42 re-detection points (recurrences) per iceberg trajectory (i.e. the same iceberg in different positions over time). The distance covered by the icebergs ranged from 1.3 km (within a period of 6 days) to about 2679.2 km (over a period of 1345 days), with 290 ± 364 km on average. The large variability is partly due to the wide range of

considered size classes; moreover, some icebergs very likely became grounded in shallow areas on the continental shelf or were contained by (fast) sea ice during part of their drift.

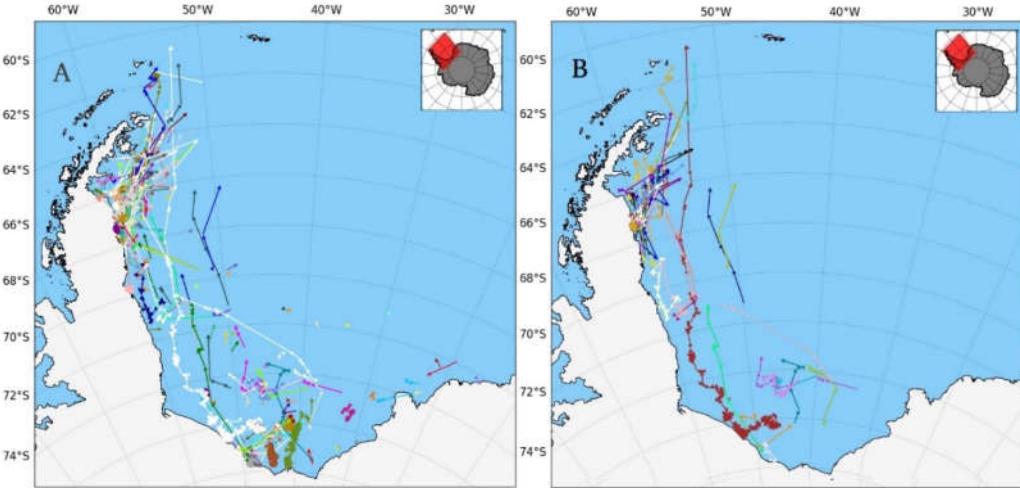


Figure 5 – Automatically monitored trajectories of icebergs in the Weddell Sea sector. Panel A shows all tracked icebergs, while panel B shows the longest trajectories of free-drifting icebergs. Icebergs follow the prevailing winds and the clockwise ocean circulation and sea surface tilt. Individual icebergs are distinguished by separate colors. An overview map is shown as well (top right corner).

Although the vast majority of monitored iceberg has been drifting inside the Weddell Sea zone of permanent sea ice year-round (**Figure 2**), a general relationship can be found between iceberg size (area) and speed. As expected, a general inverse relationship was noted. Icebergs from class A3 showed an average drift speed of $3.7 \pm 5.9 \text{ km day}^{-1}$, while icebergs in the larger classes are successively getting slower with size. The icebergs in A4 drifted at an average speed of $2.2 \pm 2.5 \text{ km day}^{-1}$, about half the speed of A3 icebergs, while A5-icebergs decrease in speed compared to A4-bergs once more to about $1.5 \pm 1.9 \text{ km day}^{-1}$. This is expected from modelling since iceberg dynamics was shown to be different dependent on the iceberg size (Rackow et al., 2017), so that small icebergs are more sensitive to wind perturbations while larger icebergs drift with

a speed closer to the (much slower) geostrophic ocean current (compare Fig. 3 in Rackow et al., 2017).

On average, the disintegration rate (based on surface area) experienced during the drift was inversely proportional to iceberg size, with $23.4 \pm 20.8\% \text{ yr}^{-1}$ (A3 size class), $18.6 \pm 9.3\% \text{ yr}^{-1}$ (A4), and $8.2 \pm 4.7\% \text{ yr}^{-1}$ (A5). We want to highlight that, although it is possible to get an idea about the average disintegration rate, the monitored icebergs showed a very high variability in terms of duration of their tracked drift. Very likely because of their more characteristic signature, which facilitates the matching of iceberg pairs and therefore tracking, bigger icebergs were usually also observed for longer periods.

In terms of average iceberg mass for the period 2002-2011, a total mass of 3743 ± 1742 Gt for the 414 drifting icebergs was computed in the Weddell Sea sector (**Figure 6**, top). The maximal mass was determined for the year 2003 (6776 Gt), possibly containing drifting icebergs from the Larsen B collapse; much smaller mass is found in the later years, with a minimal total mass found in 2011 (1309 Gt). Given that we focus on a subset of 414 tracked icebergs and thereby potentially still miss a considerable amount of iceberg mass, existing model estimates for the present-day iceberg mass in the Atlantic Sector (64°W to 30°E) of the Southern Ocean appear too low, even when compared to the year 2011. Those estimates are 589 Gt, as given by Rackow et al. (2017) for the NEMO iceberg climatology (Merino et al., 2016), and 153-245 Gt, based on the FESOM-IB model (Rackow et al., 2017).

We estimate an annual-mean mass loss (i.e. potential freshwater input) of 199 ± 153 Gt year^{-1} between 2002 and 2011 (**Figure 6**, bottom right). The high standard deviation is due to the large size class variability and the presence of giant

icebergs. The mass loss is the sum of all individual mass losses, estimated based on the individual surface area reduction rate for every iceberg (the disintegration rate is on average: $20.8 \pm 18.3\% \text{ yr}^{-1}$). We chose to estimate mass losses from linear fits to the individual surface area time series, in order to reduce the effect of iceberg surface area variations due to the presence of, e.g., bright sea ice around the iceberg boundary, which can even lead to slight increases of icebergs mass between two matches. With respect to size class (**Figure 6**, bottom right), we computed an annual mass loss of $0.2 \pm 0.4 \text{ Gt year}^{-1}$ and $21.8 \pm 15.2 \text{ Gt year}^{-1}$ for classes A2 and A3, respectively, followed by $37 \pm 4 \text{ Gt year}^{-1}$ and $139 \pm 117 \text{ Gt year}^{-1}$ for classes A4 and A5.

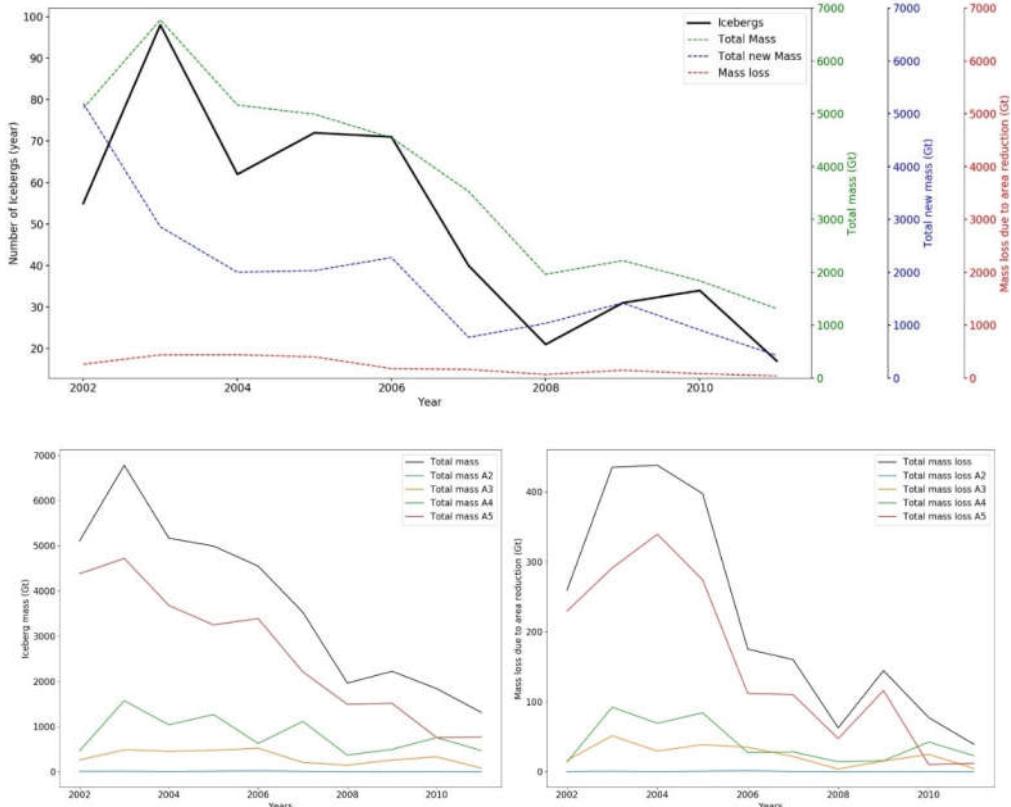


Figure 6 - (top) Total number of icebergs (black line) and total iceberg mass (green dashed line) in the Weddell Sea sector over the period 2002-2011. The total new mass per year (blue dashed) and the mass loss per year (red dashed) are given as well. Icebergs with surface area larger than 3.4 km^2 were considered. **(bottom left)** Total iceberg mass and **(bottom right)** mass loss in the Weddell Sea sector over the period 2002-2011, plotted separately for the different size classes. Most of the signal is from few A4 + A5 icebergs (green and red line), while classes A2 to A3 (blue

and yellow line) play a minor role and contribute only a fraction of the mass/mass loss (despite their large number).

5.3.7.2. Variability in close proximity to major ice shelves

For the two major regions in the Weddell Sea in close proximity to major ice shelves (Larsen and Ronne-Filchner), large variability was noted in terms of iceberg numbers, drift patterns, and iceberg mass per year. The majority of the tracked icebergs (64.3%) were detected in the Larsen sector, with largest iceberg concentration between 65°S–68°S, close to the segments “B” and “C” of the Larsen ice shelf (**Figure 7**). With areas ranging between 3.4 km² and 2753.9 km², Larsen’s icebergs reveal predominant northward/northeastward trajectories at an average speed of 4.4 ± 8.3 km day⁻¹. The estimated average area reduction was 27.6 ± 30.2 % per year, with 6 ± 17 detection points (re-detections) per iceberg trajectory. On average, the annual drifting iceberg mass computed inside the Larsen sector was 1331 ± 1112 Gt with a mass loss of 70 ± 62 Gt yr⁻¹. The high iceberg numbers in the Larsen sectors do not necessarily suggest that all these icebergs originated from the Larsen ice shelf; in fact, the “iceberg alley” along the Antarctic Peninsula is the major pathway to the north for icebergs from the Southern Weddell Sea (Rackow et al., 2017). A substantial number of icebergs could thus originate from Ronne-Filchner (or even ice shelves in East Antarctica), which is discussed next.

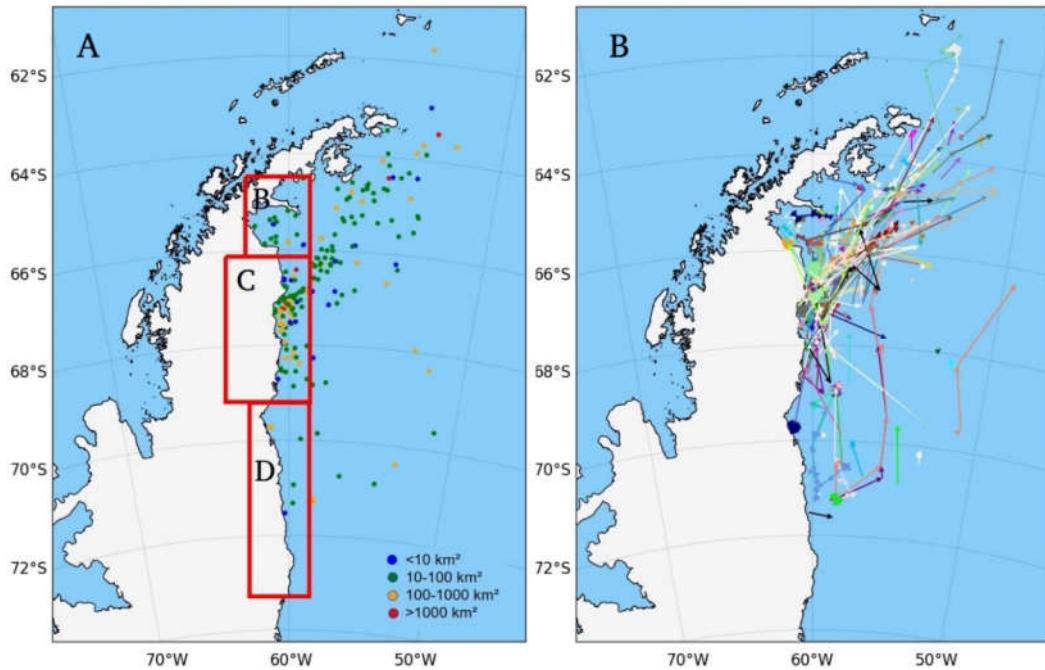


Figure 7 – Major Larsen ice shelf segments B, C, and D. Initial tracking position by size class (panel A) and tracking pathways (panel B).

The Ronne-Filchner sector (**Figure 8**) features larger icebergs, ranging between 8.5 km² and 3612 km². Two prominent drifting patterns are apparent, (i) westward drift following the coastal current, and (ii) northward drift until approximately 74°S, from where the trajectories turn to the west. The average drift speed experienced in the Ronne-Filchner sector for free-drifting icebergs was $2.5 \pm 5.1 \text{ km day}^{-1}$ (~60% slower compared to the Larsen icebergs), with an average area reduction of $13.8 \pm 15\%$ per year. As an annual mean, we found a drifting iceberg mass of $2362 \pm 870 \text{ Gt}$, with an associated total mass loss of $146 \pm 101 \text{ Gt yr}^{-1}$, which is approximately 2 times the Larsen value.

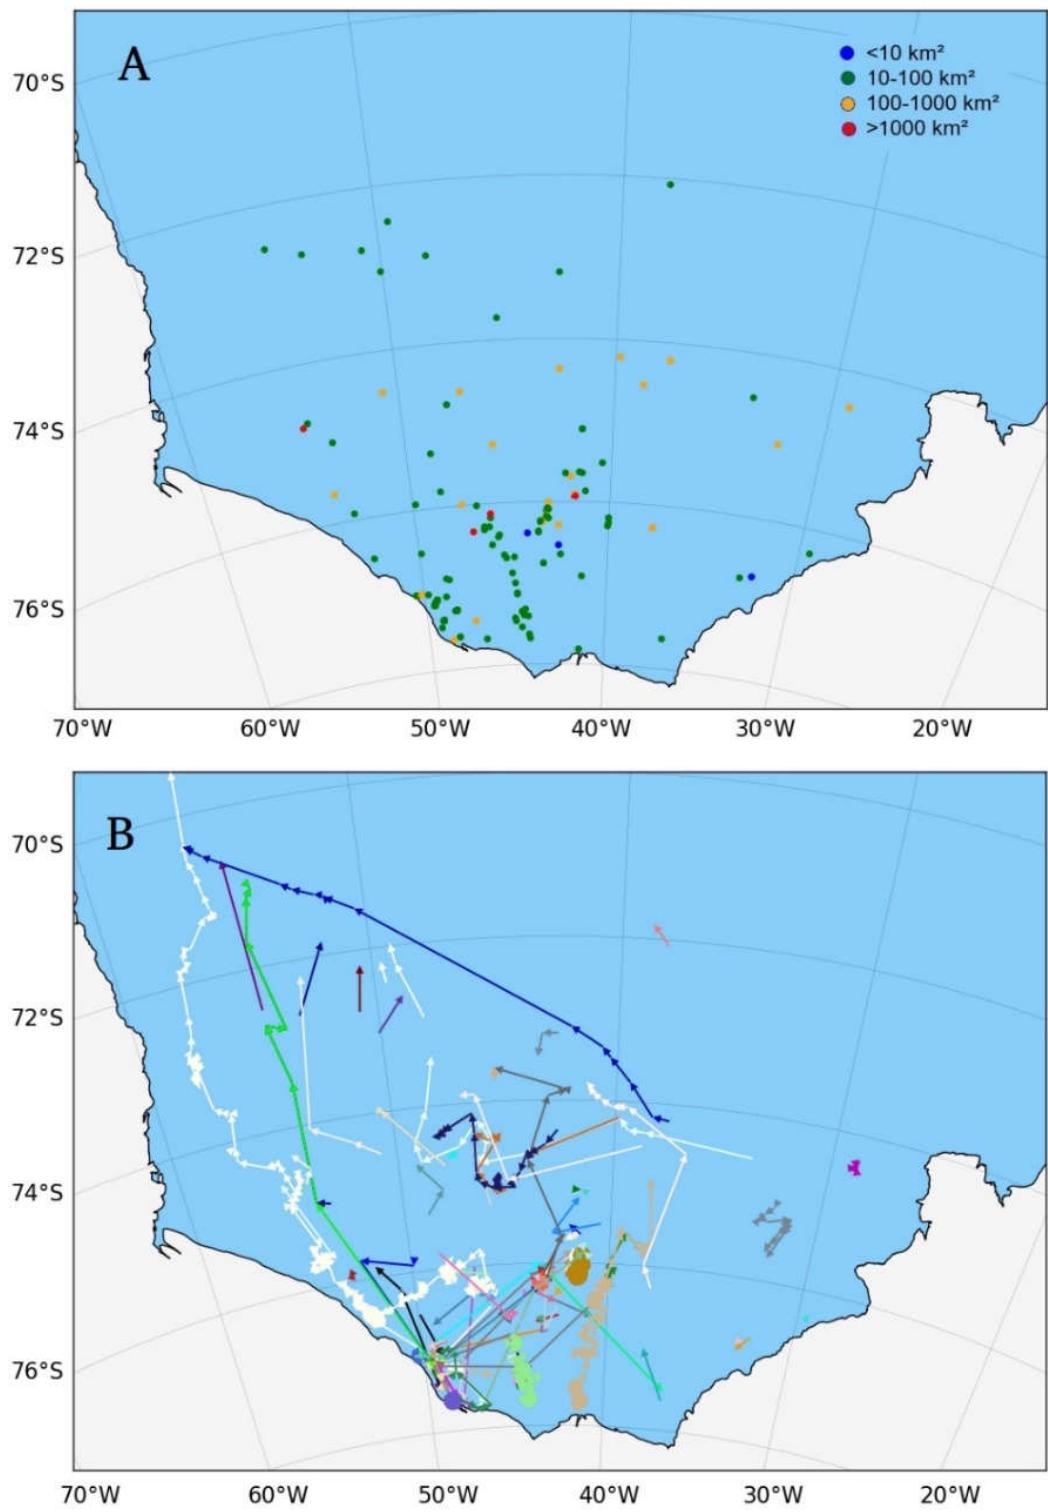


Figure 8 - Ronne-Filchner ice shelf sector. Initial tracking position by size class (panel A) and trajectories (panel B).

5.3.7.3. Example: Giant iceberg trajectories from B2019 and in the NIC database

When compared to the Larsen icebergs directly, the drift and disintegration rate inside the Ronne-Filchner sector is slower and less uniform, with bigger icebergs and a large number of stationary icebergs. Being grounded in a zone of high ice concentration year-round or being captured in fast ice, thus shielded from eroding surface waves, those icebergs can survive for many years within the coastal regime. The described behaviour is expected since the massive Ronne and Filchner ice shelves tend to release large tabular icebergs, such as the giants A22a and A23b, which were detected and investigated in this study (**Figure 9**). When compared to the two according giant iceberg tracks by the U.S. National Ice Center (NIC) and Brigham Young University (BYU) (Stuart and Long, 2011), a good fit can be seen between the operational product and our automatic tracking result. In particular, the spatial variability of the tracks is reproduced (compare yellow to purple line in **Figure 9**). Interestingly, the method is able to match iceberg signatures even after an extended period of no re-detections (stemming from incomplete satellite imagery or due to consecutive misses by our method), as highlighted by the linear jump of the yellow trajectory of A22a towards the end of the tracking period. Using more complete future datasets with better spatial and temporal coverage, an automatic monitoring of Antarctic icebergs should thus be possible with accuracy comparable to the NIC data base, even in the challenging near-coastal environment where the presence of sea ice and ocean surface waves usually poses difficulties for iceberg detection.

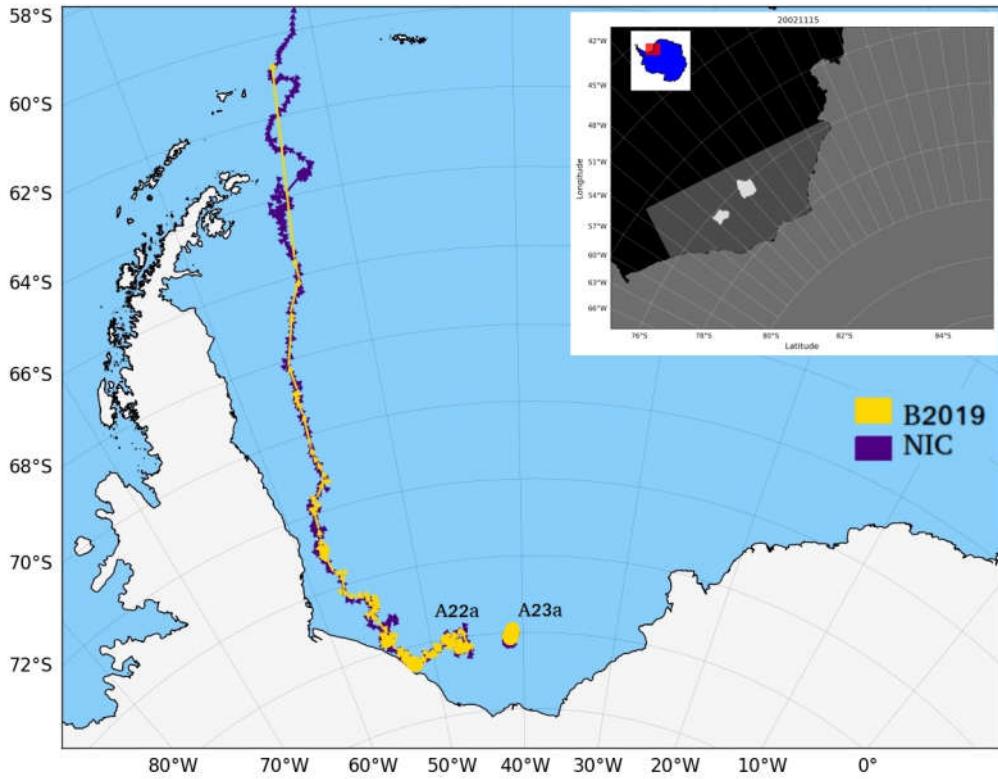


Figure 9 - Icebergs A22A and A23a in the Ronne-Filchner ice shelf sector. The automatic tracking with the method described in this study (yellow line) matches the observations by NIC (purple line) well. Linear jumps are likely due to a combination of missing input data or consecutive misses by our automatic method. The top right corner gives the areal extent of the two giant icebergs.

5.3.8. Discussion and conclusion

In this study, we present an alternative approach for automatic iceberg tracking based on a machine learning approach applied to Synthetic Aperture Radar images (SAR). To our knowledge, this is the first time that a machine learning approach for iceberg detection has been extended to automatically track a wider size range of icebergs from space, a problem that usually requires manual corrections and that is typically limited to giant icebergs >18.5 km only. The goal was to demonstrate the potential applicability of the novel approach for large-scale iceberg monitoring as a possible alternative to more traditional tracking

methods based on scatterometer data, which, again, are usually limited to giant icebergs or to a detection in open water not affected by sea ice cover.

The machine learning method for iceberg detection and analysis proposed by Barbat et al. (2019b) was applied to satellite images provided by the European Space Agency (ESA). The images were acquired between 2002-2011 and cover almost the entire Weddell Sea, Antarctica. We extend the B2019 detection method here and adapt a similar shape-based approach for iceberg recognition and tracking as proposed by Silva and Bigg (2005). The vast number of images available for this study (1213 images, amounting to about 1.6 TB of data), in addition with very wide swath coverage of 400 km, offered a sufficiently good opportunity for the detection of recurrences (i.e., for re-detecting the same iceberg in distinct images). Although an even more complete dataset could be beneficial for future studies, this case study already allowed us to perform a relatively long-term tracking and to estimate the freshwater dispersion from free-drifting icebergs in the near-coastal area, even when surrounded by sea ice. The latter is an important contribution for current ongoing efforts to estimate the role of Antarctic icebergs for the spatio-temporal meltwater redistribution over the Southern Ocean (Silva and Bigg, 2005; Silva et al., 2006; Raiswell, 2011; Tournadre et al., 2016, 2012; Merino et al., 2016; Kirkham et al., 2017; Rackow et al., 2017; Collares et al., 2018; Barbat et al., 2019a).

Overall, a subset of 414 individual icebergs with surface area between 3.4 km² and 3612 km² were investigated with respect to their prevalent drift patterns, size variability, and average disintegration. We find a general clockwise drift for icebergs in the near-coastal Antarctic zone, which is strongly related to the surface ocean circulation pattern and bathymetry. Icebergs are likely transported

by the ocean currents in the calving region and are additionally influenced by sea ice coverage, according to findings by Lichéy and Hellmer (2001). Typically, after calving, icebergs from the Weddell Sea ice shelves follow the Weddell Gyre circulation, are propelled northward, and start to drift eastward as soon as they are swept into the ACC (Gladstone et al., 2001; Stuart and Long, 2011; Rackow et al., 2017; Collares et al., 2018).

When grouping the icebergs by their proximity to the major ice shelves in the Weddell Sea, the Larsen and Ronne-Filchner ice shelves, three distinct drift patterns were observed. Icebergs drifting from the northern segments of the Larsen ice shelf show a more uniform behaviour with northward/northeastward drift at a speed of 4.4 ± 8.3 km day $^{-1}$. Using SAR imagery, Collares et al. (2018) estimated an average speed of 7.9 ± 5.02 km day $^{-1}$ for 25 icebergs primarily located on the western Weddell Sea continental shelf; Gladstone and Bigg (2002) estimated speeds of approximately 6.5 km day $^{-1}$ in the Southwestern region close to the Larsen Ice Shelf. Applying a different approach based on DCPs (ARGOS system), Schodlok et al. (2006) reported average speeds lower than 4.6 ± 6.9 km day $^{-1}$ for groups of icebergs close to the Antarctic Peninsula. The different speed estimates are likely due to different icebergs that have been tracked, with large variability in sizes, and due to different time periods that have been studied. It appears that icebergs along the Antarctic Peninsula are typically faster than icebergs close to Ronne-Filchner with their average speed of 2.5 ± 5.1 km day $^{-1}$; in this way, it is possible that the icebergs first need to accelerate in the Weddell Gyre, or their speed might depend on the strength of the surrounding sea ice in these areas (Lichéy and Hellmer, 2001; Schodlok et al., 2006).

For the Ronne-Filchner icebergs, two drift patterns were observed: First, westward drift with the coastal current and a second more northward pattern with icebergs drifting initially until approximately 74°S, from where they likewise turn to the west. All drifting icebergs were inside the average minimal sea ice extension: Icebergs present in this region are surrounded by a more extensive sea ice coverage (Hoeber, 1991; Parkinson and Cavalieri, 2012) and the variability in drift could partly be driven by the fact whether the (expanding) sea ice is strong enough to capture icebergs in an individual year or not, as demonstrated by the model study of Lichy and Hellmer (2001). Another model study showed a strong sensitivity of giant iceberg trajectories to a doubling of the sea surface slope (Rackow et al., 2017) and thus potentially to variability of the Weddell Gyre strength. For the giant icebergs that calved from the Filchner-Ronne ice shelf, direct contact with bathymetry on the shallow continental shelf could play a role for icebergs with very deep draft, thus potentially impacting the shape of the observed trajectories.

Although our case study was focused on only part of the Southern Ocean, it was possible to estimate the contribution of the tracked icebergs to the meltwater injection into the Weddell Sea, which has a special role as it is one of the few sites where deep and bottom water are formed along the Antarctic continental margin (Beckmann et al., 1999; Gordon, 2010). For 2002-2011, we computed an average mass loss of 199 ± 153 Gt yr⁻¹ for the 414 drifting icebergs covered by this study, which is not unlike previous (model-based) estimates, and an annual average disintegration rate of $20.8 \pm 18.3\%$ for all icebergs.

Our tracking results indicate an average residence time of 2-4 years for the icebergs tracked and are coherent with the results provided by Collares et al.

(2018), who estimated an average disintegration rate of 17.06%. However, the very different iceberg sizes, geographic locations, and the variability in oceanographic parameters as well as the duration of the tracking must be considered. When comparing the annual disintegration rates between Larsen and Ronne-Filchner icebergs, we find that it is $27.6 \pm 30.2\%$ compared to $13.8 \pm 15\%$ ---even with longer drifting periods for the Ronne-Filcher icebergs (116 ± 308 days) when compared against Larsen icebergs (93 ± 251 days).

Although our shape-based method defines a robust iceberg identity/signature that can be used to recognize the object in different satellite scenes, the recognition is sensible to abrupt changes in the iceberg shape. Applying a minimal similarity threshold of 80% for all similarity metrics (cross-correlation, Jaccard, and Euclidean distances), icebergs can be recognized automatically until a maximal shape variation of about 60%, as determined by visual inspection. Some of the described limitations, like linear jumps in the automatically tracked trajectories, stem at least partly from incomplete satellite imagery so that we expect improved tracking results with a more complete future dataset. The machine learning method was shown to robustly detect icebergs even in the coastal area, in the presence of sea ice and ocean waves, and for a wide range of sizes classes smaller than 18.5km. However, more work is required to better match all the identified icebergs into pairs and to reliably group them into individual trajectories, as the total number of icebergs identified by our method is far bigger than the 414 icebergs that could be reliably re-detected and thus tracked in this paper. Moreover, it is still an open question how best to deal with the generation of child icebergs and how to automatically assign these icebergs to their parent's iceberg trajectory, even when the children are very different to

the parent's signature. In practice, this of course means that the present method is not yet able to follow icebergs until they disintegrate entirely. However, in this first case study, the method can already automatically track some icebergs with sizes down to about 3.4 km^2 (or about 1.8 km side length), even under the presence of sea ice, which we already consider a significant advance compared to the typical minimal length limit of 18.5km known from current operational methods. Using more complete future datasets with improved time and spatial resolution, an automatic monitoring of Antarctic icebergs appears possible even in the challenging near-coastal environment where the presence of sea ice and coastal ocean dynamics such as surface waves usually pose major obstacles for other approaches.

5.3.9. Acknowledgments

This study is a contribution to the activities of the Brazilian High Latitudes Oceanography Group (GOAL) and the Brazilian National Institute of Science and Technology of the Cryosphere (INCT-CRIOSFERA; 465680/2014-3). The GOAL has been funded by the Brazilian Antarctic Program (PROANTAR) through the Brazilian Ministry of the Environment (MMA), the Brazilian Ministry of Science, Technology, Innovation and Communication (MCTIC), the Council for Research and Scientific Development of Brazil (CNPq; 405869/2013-4), and CAPES Foundation (AUXPE 1995/2014). M. M. Barbat acknowledges the fellowships from CNPq (140910/2016-6) and CAPES Foundation (88881.177236/2018-01). M. M. Mata acknowledges CNPq grant 306896/2015-0. We also thank the European Space Agency (ESA) for providing the Envisat ASAR images used in this study.

Capítulo VI: Síntese da Discussão e Conclusões

Tendo em vista o cenário de alterações observadas no oceano Austral e no clima, nesta tese de doutoramento foram investigados e discutidos os regimes de distribuição e dispersão de icebergs no oceano Austral. Com isso, espera-se contribuir no entendimento sobre a importância destes nos sinais de diluição observados no entorno da Antártica, comparando as principais diferenças/semelhanças entre as distintas áreas fonte.

Para tanto, parte dos esforços foi dedicado ao desenvolvimento de uma nova metodologia computacional baseada em inteligência artificial. Esta, focada

em prover uma plataforma acurada para detecção, monitoramento e análise de icebergs a partir de imagens de radar de abertura sintética. O método desenvolvido provou-se altamente adaptável mostrando que a ambiguidade recorrente entre os distintos elementos que compõem as cenas em ambientes polares pode ser reduzida, possibilitando o estudo de icebergs em larga escala mesmo sob condições atmosféricas e oceanográficas adversas.

Diferentemente dos métodos tradicionais baseados na intensidade do sinal de retroespalhamento, o método proposto emprega uma abordagem adaptativa através do fluxo gradual de aprendizado e da união de modelos preditivos distintos, parcialmente especializados em diferentes perspectivas dos mesmos objetos. A abordagem proposta apresentou elevado grau de generalização e se provou robusta, sendo capaz de separar icebergs de elementos de fundo com acurácia de $97,5 \pm 0,6\%$, taxa de falsos positivos de $2,3 \pm 0,4\%$ e $3,3 \pm 0,4\%$ de perdas.

Com base nos resultados obtidos, foi possível investigar a distribuição pan-Antártica de icebergs sobre a plataforma continental e relacionar com as principais regiões fonte através de 28607冰bergs detectados com áreas superficiais entre $0,1 - 4567 km^2$. Desta forma, complementando discussões recentes sobre a distribuição de icebergs que são restritas à regiões em águas abertas. A distribuição de classes de tamanho determinada mostrou que icebergs na região costeira da Antártida seguem, razoavelmente bem ($-1,83$), uma distribuição de $-3/2$ modelada para mar aberto e referente a inclinação da curva da lei potência. Isso indica que parte representativa dos icebergs menores se originam a partir da ruptura de icebergs maiores (*Brittle fracture*). Essa informação é importante pois pode indicar que um número maior do que o

esperado de icebergs deriva e dilui longe das principais regiões fonte. Parte da diferença entre as distribuições pode ser associada a diferenças entre a região costeira e oceânica, onde diferentes processos assim como a presença de icebergs aprisionados por gelo marinho ou encalhados podem se tornar importantes no cômputo final. Além disso, embora exista uma potencial variabilidade sazonal e interanual sobre a incidência de icebergs, é demonstrado que a expressiva ocorrência de icebergs com área menor do que 10 km^2 ($\sim 99\%$) representa impacto minoritário (36%) sobre a massa potencial de água doce proveniente de icebergs, evidenciando o impacto massivo referente ao aporte de icebergs maiores que 10 km^2 . Em relação à distribuição espacial ao longo das principais regiões fonte é observado o acúmulo de icebergs próximo à plataformas de gelo menores, principalmente no setor referente ao oceano Pacífico Oeste na região de *Adélie* e *George V land*. Isso indica elevada frequência no aporte de icebergs em comparação com plataformas maiores como as plataformas de *Ronne-Filchner* e *Ross* nos mares de Weddell e Ross, respectivamente. No entanto, embora menos expressivas em relação à frequência no aporte de icebergs, a presença destas massivas plataformas flutuantes representa um potencial deslocamento na distribuição anual de massa, quando considerada a possibilidade da ruptura de icebergs de grande porte e gigantes.

Em termos de injeção anual de água doce proveniente de icebergs: embora a relação entre fluxo de ruptura (*Calving rate*) e massa total residente (massa de icebergs) não seja diretamente comparável visto que o fluxo de ruptura considera apenas a incidência de novos icebergs, enquanto a massa total residente pode conter icebergs residentes do setor. Neste trabalho, foi

estimada massa anual de $\sim 6000 \text{ Gt/ano}$ condizente com estudos anteriores capazes de amostrar a região costeira integralmente. Desta forma, encontrou-se uma discrepância de $4 - 6 \text{ anos}$ entre massa residente e fluxo de ruptura na região costeira, o qual tem sido estimado em $\sim 1300 \text{ Gt/ano}$.

Com base na capacidade de rastreamento do método apresentado, foi possível monitorar não apenas o movimento de icebergs ao longo do tempo, mas também, a potencial injeção de água doce a partir destes, automaticamente. A partir do estudo de caso centrado no mar de Weddell, um total de 414 icebergs com áreas superficiais entre $3,4 \text{ km}^2$ e 3612 km^2 foram monitorados, os quais destacaram um padrão geral predominante de deriva no sentido horário ao longo da costa. Este padrão está fortemente relacionado com a circulação oceânica superficial, acompanhando o fluxo da Corrente Costeira Antártica (ACoC) e do giro de Weddell, como esperado para o setor. Quando limitado a icebergs em deriva livre, e agrupados por proximidade com as principais plataformas de gelo flutuantes (Larsen e Ronne-Filchner), foi possível observar dois padrões distintos de deriva. Icebergs com ponto inicial próximo à região da plataforma Larsen apresentaram comportamento mais uniforme, derivando sentido norte/nordeste com velocidade média de $4,4 \pm 8,3 \text{ km dia}^{-1}$. Estes, mais velozes e estáveis quando comparados com os padrões norte/noroeste observados próximo a plataforma Ronne-Filchner, derivam com velocidade média de $2,5 \pm 5,1 \text{ km dia}^{-1}$. Estes valores indicam uma possível aceleração, embora a região de Ronne-Fichner apresente maiores incidências de icebergs encalhados ou aprisionados por gelo marinho. Em termos de contribuição de água doce, foi possível estimar um montante anual médio de $199 \pm 153 \text{ Gt ano}^{-1}$ para o conjunto de icebergs investigado os quais apresentaram desintegração (redução

de área) anual média de $20,8 \pm 18,3\% \text{ ano}^{-1}$, condizente com os resultados obtidos por modelagem numérica e, mais uma vez, destacando a expressiva contribuição em termos de massa dos icebergs com classe de tamanho superior a 10km^2 .

Embora os resultados apresentados nesta tese de doutoramento provenham uma representação realista e em grande escala acerca da distribuição espacial e de magnitude (tamanho e massa) de icebergs na região costeira Antártica para os anos estudados, relacionar diretamente os icebergs como importantes agentes nos sinais de diluição observados no entorno do continente Antártico, assim como quantificar seu papel na circulação oceânica e no clima, deve ser tomado com cautela. Principalmente, deve se ter cautela em relação a seu impacto local sobre as principais regiões de formação de água de fundo, uma vez que estas podem ser impactadas de forma diferente, tendo em vista a variabilidade regional destas e seu papel na formação da AABW como um todo.

Por fim, tendo em mente as limitações intrínsecas ao conjunto de dados disponível para esse trabalho, assim como os resultados obtidos e as ponderações resultantes destes, retornamos à hipótese:

“As distribuições de icebergs seguem padrões definidos, sendo importantes agentes nos sinais de diluição percebidos no entorno da Antártica e passíveis de serem observados em grande escala através da união entre técnicas de inteligência artificial e sensoriamento remoto.”

Sim, os padrões de distribuição e dispersão de icebergs mostram-se bem definidos, com intensa atividade próxima as plataformas de gelo menores

principalmente, em setores próximos à ação da ACC como os setores do Oceano Pacífico Oeste e Oceano Índico. Adicionalmente, o montante de massa de água doce observado mostrou-se expressivo em comparação com os índices discutidos em trabalhos análogos, evidenciando uma discrepância em magnitude e tempo de residência passivas de influenciar os sinais de diluição observados no entorno Antártico. Por fim, a união entre inteligência artificial e sensoriamento remoto provou-se uma alternativa robusta para a detecção e análise de icebergs em grande escala no ambiente polar, sendo capaz de diferenciar icebergs mesmo em cenários altamente ambíguos e em ampla faixa de classes de tamanho.

6.1. Sugestões para trabalhos futuros

Embora o aporte e consequente derretimento de icebergs abriguem o potencial de influenciar a formação das águas densas de fundo, essa premissa não é direta, sendo dependente do impacto potencial sobre as distintas variedades regionais que compõem a AABW.

Como base nas distribuições de iceberg apresentadas e discutidas neste trabalho, dentre as três principais variantes regionais que compõem a AABW formadas no mar de Weddell (WSBW), Ross (RSBW) e região de Adélie Land/George V (ALBW), a salina água de fundo do mar de Ross (RSBW) pode ser tomada como possuindo o maior potencial de ser impactada, corroborando com estudos que mostram o enfraquecimento na produção desta variedade. Seguido pela variante (ALBW) e por fim (WSBW). Contudo, a variabilidade interanual,

climática e o potencial bruto contido nas plataformas de *Ronne-Filchner* e *Ross* podem mudar significativamente essa estimativa.

Com base nesta premissa, trabalhos futuros contemplando séries temporais amplas de imagens SAR em conjunto com a aplicação de modelos numéricos (iceberg-oceano-atmosfera), podem elevar a percepção acerca da influência dos icebergs sobre a formação de massas de água de fundo e no clima. Desta forma, podem vir a prover uma estratégia de alta resolução capaz de acompanhar o processo de desintegração e diluição de icebergs a partir das principais áreas fonte, valendo-se de representações reais acerca da distribuição em larga escala de icebergs para a inicialização de modelos numéricos capazes de quantificar a injeção continua de água doce a partir destes.

Capítulo VII: Referências

- Achanta, R, Shaji, A., Smith, K., Lucchi, A., Fua, P., & Susstrunk, S. (2010) SLIC Superpixels, (June). <https://doi.org/10.1109/TPAMI.2012.120>
- Achanta, Radhakrishna, Shaji, A., Smith, K., Lucchi, A., Fua, P., & Susstrunk, S. (2012) SLIC Superpixels Compared to State-of-the-art Superpixel *IEEE Trans. on Pat. Anal. and Mach. Intel.*, 34(1), 1–8. <https://doi.org/10.1109/tpami.2012.120>
- Aggarwal, M. (2013) Performance analysis of different feature selection methods in intrusion detection *International Journal of Scientific & Technology Research*, 2(6), 225–231. Retrieved from www.ijstr.org
- Al-amri, S. S., Kalyankar, N. V, & Khamitkar, S. D. (2010) Linear and Non-linear Contrast Enhancement Image *Journal of Computer Science*, 10(2), 139–143. Retrieved from http://paper.ijcsns.org/07_book/201002/20100222.pdf
- Alpaydın, E. (2012) Introduction to machine learning *The MIT Press*, XXXIII(2), 81–87. <https://doi.org/10.1007/s13398-014-0173-7.2>

- Arifin, A. Z., & Asano, A. (2006) Image segmentation by histogram thresholding using hierarchical cluster analysis *Pattern Recognition Letters*, 27(13), 1515–1521. <https://doi.org/10.1016/j.patrec.2006.02.022>
- Arlot, S., & Celisse, A. (2010) A survey of cross-validation procedures for model selection *Statistics Surveys*, 4, 40–79. <https://doi.org/10.1214/09-SS054>
- Astrom, J. A. (2006). Statistical models of brittle fragmentation. *Advances in Physics*, 55 (3-4), 247-278. Retrieved from <https://doi.org/10.1080/00018730600731907> doi: 10.1080/00018730600731907
- Bamber, J. L., Griggs, J. A., Hurkmans, R. T. W. L., Dowdeswell, J. A., Gogineni, S. P., Howat, I., et al. (2013) A new bed elevation dataset for Greenland *Cryosphere*, 7(2), 499–510. <https://doi.org/10.5194/tc-7-499-2013>
- Barbat, M. M., Wesche, C., Werhli, A. V., & Mata, M. M. (2019b) An adaptive machine learning approach to improve automatic iceberg detection from SAR images *ISPRS Journal of Photogrammetry and Remote Sensing*, 156(March), 247–259. <https://doi.org/10.1016/j.isprsjprs.2019.08.015>
- Barbat, M. M., Rackow, T., Hellmer, H. H., Wesche, C., & Mata, M. M. (2019a) Three Years of Near-Coastal Antarctic Iceberg Distribution From a Machine Learning Approach Applied to SAR Imagery *Journal of Geophysical Research: Oceans*, (124), 6658–6672. <https://doi.org/10.1029/2019jc015205>
- Barrett, P. (2005) Euclidean Distance Whitepaper *The Technical Whitepaper Series 6*, 26. Retrieved from <http://www.pbarrett.net/techpapers/euclid.pdf>
- Beard, K. H. (2007) Random Forests for Classification in Ecology, 88(11), 2783–2792. <https://doi.org/10.1890/07-0539.1>
- Beckmann, A., Hellmer, H. H., & Timmermann, R. (1999) A numerical model of the Weddell Sea: Large-scale circulation and water mass distribution *Journal of Geophysical Research: Oceans*, 104(C10), 23375–23391. <https://doi.org/10.1029/1999jc900194>
- Belgiu, M., & Drăgu, L. (2016) Random forest in remote sensing: A review of applications and future directions *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

Bigg, G. R. (2015) *Icebergs : their science and links to global change*. Cambridge, United Kingdom Cambridge University Press.
<https://doi.org/10.1017/CBO9781107589278>

Bigg, G. R., Wadley, M. R., Stevens, D. P., Johnson, J. A., Science, C. R., Bigg, G. R., et al. (1997) Modelling the dynamics and thermodynamics of icebergs *Cold Regions Science and Technology*, 26(2), 113–135.
[https://doi.org/10.1016/S0165-232X\(97\)00012-8](https://doi.org/10.1016/S0165-232X(97)00012-8)

Bigg, G. R., Cropper, T. E., O'Neill, C. K., Arnold, A. K., Fleming, A. H., Marsh, R., et al. (2018) A model for assessing iceberg hazard *Natural Hazards*, 92(2), 1113–1136. <https://doi.org/10.1007/s11069-018-3243-x>

Blachnik, M., & Laaksonen, J. (2008) Image classification by histogram features created with learning vector quantization In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 5163 LNCS, pp. 827–836). https://doi.org/10.1007/978-3-540-87536-9_85

Bouhier, N., Tournadre, J., Rémy, F., & Gourves-Cousin, R. (2018) Melting and fragmentation laws from the evolution of two large Southern Ocean icebergs estimated from satellite data *Cryosphere*, 12(7), 2267–2285.
<https://doi.org/10.5194/tc-12-2267-2018>

Breiman L. (2001) Machine Learning, 45(1), 5–32. *Statistics Department, University of California, Berkeley, CA 94720.*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>

Broecker, W. S. (1991) The great ocean conveyor *Oceanography*, 4(2).

Bügelmayer, M., Roche, D. M., & Renssen, H. (2015) How do icebergs affect the Greenland ice sheet under pre-industrial conditions? - A model study with a fully coupled ice-sheet-climate model *Cryosphere*, 9(3), 821–835.
<https://doi.org/10.5194/tc-9-821-2015>

Canadian Space Agency (2010) A New Satellite, a New Visiiion.

Carter, L., McCave, I. N., & Williams, M. J. M. (2008) Circulation and Water Masses of the Southern Ocean: A Review In *Developments in Earth and*

Environmental Sciences (Vol. 8, pp. 85–114). [https://doi.org/10.1016/S1571-9197\(08\)00004-9](https://doi.org/10.1016/S1571-9197(08)00004-9)

Chen, J., Pappas, T. N., Mojsilovic, A. A., & Rogowitz, B. E. (2003) Perceptual color and spatial texture features for segmentation *Human Vision and Electronic Imaging VIII, SPIE-5007*, 340–351. <https://doi.org/10.1117/12.485528>

Collares, L. L., Mata, M. M., Arigony-Neto, J., Kerr, R., Arigony-neto, J., & Kerr, R. (2015) Identificação e monitoramento de icebergs em imagens advanced synthetic aperture radar no noroeste do mar de Weddell, Antártica *Revista Brasileira de Cartografia*, 67(3), 569–589.

Collares, L. L., Mata, M. M., Kerr, R., Arigony-Neto, J., & Barbat, M. M. (2018) Iceberg drift and ocean circulation in the northwestern Weddell Sea, Antarctica *Deep-Sea Research Part II: Topical Studies in Oceanography*, 149(March), 10–24. <https://doi.org/10.1016/j.dsr2.2018.02.014>

Comaniciu, D. & Meer, P. (2002) Mean Shift: A robust approach towards feature space analysis. *IEEE Transactions on PAMI*, 24(5), 603-619.

Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Kyle, T., Gibson, J., et al. (2007) Random Forests for Classification in Ecology Published by : Ecological Society of America *Ecology*, 88(11), 2783–2792. <https://doi.org/10.1890/07-0539.1>

Dalponte, M., Orka, H. O., Gobakken, T., Gianelle, D., Naesset, E., (2013) Tree species classification in boreal forests with hyperspectral data. *IEEE Trans. Geosci. Remote Sens.* 51, 2632–2645

Danielsson, P. E. (1981) Getting the Median Faster *Computer Graphics and Image Processing*, 17(1), 71–78. [https://doi.org/10.1016/S0146-664X\(81\)80010-X](https://doi.org/10.1016/S0146-664X(81)80010-X)

Deacon, G. E. R. (1979) The Weddell gyre *Deep Sea Research Part A, Oceanographic Research Papers*, 26(9), 981–995. [https://doi.org/10.1016/0198-0149\(79\)90044-X](https://doi.org/10.1016/0198-0149(79)90044-X)

De Keersmaecker, M.L., Pierre, F., Isabelle, T., (2003) Using fractal dimensions for Characterizing Intra-urban Diversity: The Example of Brussels. *Geogr. Anal.* 35, 310–328.

Depoorter, M. A., Bamber, J. L., Griggs, J. A., Lenaerts, J. T. M., Ligtenberg, S. R. M., Van Den Broeke, M. R., & Moholdt, G. (2013) Calving fluxes and basal melt rates of Antarctic ice shelves. *Nature*, 502(7469), 89–92. <https://doi.org/10.1038/nature12567>

Diemand, D. (2001) Icebergs In *Encyclopedia of Ocean Sciences* (pp. 1255–1264). Academic Press. <https://doi.org/10.1016/B978-012374473-9.00002-3>

Dietterich, T. G. (2000) Ensemble methods in machine learning. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1857 LNCS, 1–15. https://doi.org/10.1007/3-540-45014-9_1

Du, P., Samat, A., Waske, B., Liu, S., & Li, Z. (2015) Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 38–53. <https://doi.org/10.1016/j.isprsjprs.2015.03.002>

Duin, R. P. W., Haringa, H., & Zeelen, R. (1986) Fast percentile filtering. *Pattern Recognition Letters*, 4(4), 269–272. [https://doi.org/10.1016/0167-8655\(86\)90007-3](https://doi.org/10.1016/0167-8655(86)90007-3)

Eibl, G., Pfeiffer, K. P. (2005) Multiclass Boosting for Weak Classifiers. *Journal of Machine Learning Research*, 6, 189–210. Retrieved from <http://www.jmlr.org/papers/volume6/eibl05a/eibl05a.pdf>

Enderlin, E.M., Hamilton, G.S., Straneo, F., Sutherland, D.A., (2016) Iceberg meltwater fluxes dominate the freshwater budget in Greenland's iceberg-congested glacial fjords. *Geophys. Res. Lett.* 43, 11,287-11,294. <https://doi.org/10.1002/2016GL070718>

Envisat/ESA handbook (2007) *ASAR Product Handbook*.

Fahrbach, E., Rohardt, G., & Krause, G. (1992) The Antarctic coastal current in the southeastern Weddell Sea. *Polar Biology*, 12(2), 171–182.

<https://doi.org/10.1007/BF00238257>

Fahrbach, E., Rohardt, G., Schröder, M., & Strass, V. (1994) Transport and structure of the weddell gyre *Annales Geophysicae*, 12(9), 840–855.
<https://doi.org/10.1007/s00585-994-0840-7>

Felzenswalb, P. F., & Huttenlocher, D. P. (2004) Efficient graph-based image segmentation *International Journal of Computer Vision*, 59(2), 167–181.
<https://doi.org/10.1023/B:VISI.0000022288.19776.77>

Ferreira, M. L. de C., & Kerr, R. (2017) Source water distribution and quantification of North Atlantic Deep Water and Antarctic Bottom Water in the Atlantic Ocean *Progress in Oceanography*, 153, 66–83.
<https://doi.org/10.1016/j.pocean.2017.04.003>

Foster, T. D., & Carmack, E. C. (1976) Temperature and Salinity Structure in the Weddell Sea *Journal of Physical Oceanography*. [https://doi.org/10.1175/1520-0485\(1976\)006<0036:tassit>2.0.co;2](https://doi.org/10.1175/1520-0485(1976)006<0036:tassit>2.0.co;2)

Foster, T. D., & Middleton, J. H. (1980) Bottom water formation in the western Weddell Sea *Deep Sea Research Part A, Oceanographic Research Papers*, 27(5), 367–381. [https://doi.org/10.1016/0198-0149\(80\)90032-1](https://doi.org/10.1016/0198-0149(80)90032-1)

Freiwald, A., Wilson, J. B., & Henrich, R. (1999) Grounding pleistocene icebergs shape recent deep-water coral reefs *Sedimentary Geology*, 125(1–2), 1–8.
[https://doi.org/10.1016/S0037-0738\(98\)00142-0](https://doi.org/10.1016/S0037-0738(98)00142-0)

Frost, A., Ressel, R., & Lehner, S. (2016) Automated iceberg detection using high resolution X - band SAR images *Canadian Journal of Remote Sensing*, 42(4), 354–366.

Gaull, B. A., Adamson, D. A., & Pickard, J. (1992) Seismicity associated with icebergs calving from glaciers near Mawson, East Antarctica *Australian Journal of Earth Sciences*, 39(4), 473–480. <https://doi.org/10.1080/08120099208728039>

Ghosh, A., Sharma, R., & Joshi, P. K. (2014) Random forest classification of urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion *Applied Geography*, 48, 31–41.
<https://doi.org/10.1016/j.apgeog.2014.01.003>

- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006) Random forests for land cover classification In *Pattern Recognition Letters* (Vol. 27, pp. 294–300). <https://doi.org/10.1016/j.patrec.2005.08.011>
- Gladstone, R., & Bigg, G. R. (2002) Satellite tracking of icebergs in the Weddell Sea *Antarctic Science*, 14(3), 278–287. <https://doi.org/10.1017/S0954102002000032>
- Gladstone, R. M., Bigg, G. R., & Nicholls, K. W. (2001) Iceberg trajectory modeling and meltwater injection in the Southern Ocean *Journal of Geophysical Research: Oceans*, 106(C9), 19903–19915. <https://doi.org/10.1029/2000JC000347>
- Gordon, A. L. L. (2001) Bottom Water Formation In *Encyclopedia of Ocean Sciences* (pp. 415–421). <https://doi.org/10.1006/rwos.2001.0006>
- Grosfeld, K., Schröder, M., Fahrbach, E., Gerdes, R., & Mackensen, A. (2001) How iceberg calving and grounding change the circulation and hydrography in the Filchner Ice Shelf-Ocean System *Journal of Geophysical Research: Oceans*, 106(C5), 9039–9055. <https://doi.org/10.1029/2000jc000601>
- Gwiazda, R. H., Hemming, S. R., & Broecker, W. S. (1996) Tracking the sources of icebergs with lead isotopes: The provenance of ice-raftered debris in Heinrich layer 2 *Paleoceanography*, 11(1), 77–93. <https://doi.org/10.1029/95PA03135>
- Hale, D. (2006) An efficient method for computing local cross-correlations of multi-dimensional signals *Colorado School of Mines Consortium Project on Seismic Inverse Methods for Complex Structures*, 253–260.
- Hall, M. (1999) Correlation-based feature selection for machine learning *Diss. The University of Waikato*, 21i195-i20(April), 1–5. <https://doi.org/10.1.1.149.3848>
- Haralick, R. M., Shanmugan, K. and I. D. (1973) Textural Features for Image Classification *IEEE Transactions on Systems, Man and Cybernetics*, 6(November), 610–621. <https://doi.org/10.7497/j.issn.2095-3941.2013.02.007>
- Haralick, R. M. (1979) Statistical and structural approach to texture *Proceeding of IEEE Vol 67 No 5*, 67(5), 786–804. <https://doi.org/10.1109/PROC.1979.11328>
- Hassanpour, H., & Samadiani, N. (2015) Using morphological transforms to

enhance the contrast of medical images *The Egyptian Journal of Radiology and Nuclear Medicine*, 46(2), 481–489. <https://doi.org/10.1016/j.ejrm.2015.01.004>

Hayes, M., Koo, J., & Cho, Y. (2014) Tracking based on Template matching with Online Random Forests. Retrieved from http://cau.ac.kr/~mhhgtx/courses/AdaptiveFilters/lectures/Projects_Part_2.pdf

Heinrich, H. (1988) Origin and consequences of cyclic ice rafting in the Northeast Atlantic Ocean during the past 130,000 years *Quaternary Research*, 29(2), 142–152. [https://doi.org/10.1016/0033-5894\(88\)90057-9](https://doi.org/10.1016/0033-5894(88)90057-9)

Hemming, S. R. (2004) Heinrich events: Massive late Pleistocene detritus layers of the North Atlantic and their global climate imprint *Reviews of Geophysics*, 42(1). <https://doi.org/10.1029/2003RG000128>

Hewitt, C. D., Broccoli, A. J., Crucifix, M., Gregory, J. M., Mitchell, J. F. B., & Stouffer, R. J. (2006) The effect of a large freshwater perturbation on the glacial North Atlantic Ocean using a coupled general circulation model *Journal of Climate*, 19(17), 4436–4447. <https://doi.org/10.1175/JCLI3867.1>

Hoeber, H., (1991) Sea-ice dynamics in the Weddell Sea in winter. *Ann. Glaciol.* 15, 9–16. <https://doi.org/10.3189/1991aog15-1-9-16>

Hulbe, C. L., MacAyeal, D. R., Denton, G. H., Kleman, J., & Lowell, T. V. (2004) Catastrophic ice shelf breakup as the source of Heinrich event icebergs *Paleoceanography*, 19(1), n/a-n/a. <https://doi.org/10.1029/2003PA000890>

Huppert, H. H., & Turner, J. S. (1978) On Melting Icebergs *Nature*, 271(5), 46–48.

Impoco, G., & Tuminello, L. (2015) Incremental learning to segment micrographs *Computer Vision and Image Understanding*, 140, 144–152. <https://doi.org/10.1016/j.cviu.2015.03.007>

Ismail, A. S., Gao, X., & Deng, C. (2014) SAR image classification based on texture feature fusion 2014 *IEEE China Summit and International Conference on Signal and Information Processing, IEEE ChinaSIP 2014 - Proceedings*, 153–156. <https://doi.org/10.1109/ChinaSIP.2014.6889221>

Jacka, T. H., & Giles, A. B. (2007) Antarctic iceberg distribution and dissolution

from ship-based observations *Journal of Glaciology*, 53(182), 341–356.
<https://doi.org/10.3189/002214307783258521>

Jackson C.R. & Apel J.R. (2005) Synthetic aperture radar marine user's manual. National Oceanic and Atmospheric Administration US Department of Commerce, Washington, DC

Jacobs, S. S., & Hellmer, H. H. (1992) Melting of ice shelves and the mass balance of Antarctica *Journal of Glaciology*, 38(130), 375–387.
<https://doi.org/10.3198/1992JoG38-130-375-387>

Jacobs, S. S., Amos, A. F., & Bruchhausen, P. M. (1970) Ross sea oceanography and antarctic bottom water formation *Deep-Sea Research and Oceanographic Abstracts*, 17(6), 935–962. [https://doi.org/10.1016/0011-7471\(70\)90046-X](https://doi.org/10.1016/0011-7471(70)90046-X)

Jansen, D., Sandhäger, H., Rack, W., (2005) Evolution of tabular iceberg A-38B, observation and simulation A-38B A-38A Ronne A-38A A-38B. October 16.

Jenkins, A. (1991) A one-Dimensional Model of Ice Shelf-Ocean Interaction *Journal of Geophysical Research*, 96(C11), 671–677.

Jezeck, K.C., Sohn, H.G., Noltimier, K.F., (1998) The RADARSAT Antarctic Mapping Project. IGARSS '98. Sens. Manag. Environ. 1998 IEEE Int. Geosci. Remote Sensing. Symp. Proceedings. (Cat. No.98CH36174) 2462–2464 vol.5.
<https://doi.org/10.1109/IGARSS.1998.702246>

Jezeck, K. C., Sohn, H. G., & Noltimier, K. F. (2002) The RADARSAT Antarctic Mapping Project *IEEE International Geoscience and Remote Sensing.*, 5(October 1997), 2462–2464. <https://doi.org/10.1109/igarss.1998.702246>

Jezeck, K. C., Farness, K., Carande, R., Wu, X., & Labelle-Hamer, N. (2003) RADARSAT 1 synthetic aperture radar observations of Antarctica: Modified Antarctic Mapping Mission, 2000 *Radio Science*, 38(4), n/a-n/a.
<https://doi.org/10.1029/2002rs002643>

Jongma, J. I., Renssen, H., & Roche, D. M. (2013) Simulating Heinrich event 1 with interactive icebergs *Climate Dynamics*, 40(5–6), 1373–1385.
<https://doi.org/10.1007/s00382-012-1421-1>

Kerr, R., Heywood, K. J., Mata, M. M., & Garcia, C. A. E. (2012) On the outflow

of dense water from the Weddell and Ross Seas in OCCAM model *Ocean Science*, 8(3), 369–388. <https://doi.org/10.5194/os-8-369-2012>

Kerr, Rodrigo, Dotto, T. S., Mata, M. M., & Hellmer, H. H. (2018) Three decades of deep water mass investigation in the Weddell Sea (1984–2014): Temporal variability and changes *Deep-Sea Research Part II: Topical Studies in Oceanography*, 149, 70–83. <https://doi.org/10.1016/j.dsr2.2017.12.002>

Kirkham, J.D., Rosser, N.J., Wainwright, J., Vann Jones, E.C., Dunning, S.A., Lane, V.S., Hawthorn, D.E., Strzelecki, M.C., Szczuciński, W., (2017) Drift-dependent changes in iceberg size-frequency distributions. *Sci. Rep.* 7, 1–10. <https://doi.org/10.1038/s41598-017-14863-2>

Kirschen, R. H., O'Higgins, E. A., & Lee, R. T. (1995) A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection *International Joint Conference on Artificial Intelligence*. <https://doi.org/10.1067/mod.2000.109032>

Kirschen, R. H., O'Higgins, E. A., & Lee, R. T. (2000) The Royal London Space Planning: An integration of space analysis and treatment planning part II: The effect of other treatment procedures on space *American Journal of Orthodontics and Dentofacial Orthopedics*, 118(4), 456–461. <https://doi.org/10.1067/mod.2000.109032>

Kohn, A. F. (2005) Cross-correlation between EMG and center of gravity during quiet stance: Theory and simulations *Biological Cybernetics*, 93(5), 382–388. <https://doi.org/10.1007/s00422-005-0016-x>

Kupidura, P. (2016) Comparison of filters dedicated to speckle suppression in SAR images *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41(July), 269–276. <https://doi.org/10.5194/isprsarchives-XLI-B7-269-2016>

Lee, J. Sen (1981) Speckle analysis and smoothing of synthetic aperture radar images *Computer Graphics and Image Processing*, 17(1), 24–32. [https://doi.org/10.1016/S0146-664X\(81\)80005-6](https://doi.org/10.1016/S0146-664X(81)80005-6)

Lee, J. Sen, (1983) Digital image smoothing and the sigma filter. *Comput. Vision, Graph. Image Process.* 24, 255-269. [https://doi.org/10.1016/0734-189X\(83\)90047-6](https://doi.org/10.1016/0734-189X(83)90047-6)

Lichéy, C., Hellmer H., H.H., (2001) Modeling giant-iceberg drift under the influence of sea ice in the Weddell Sea, Antarctica. *J. Glaciol.* 47, 452–460.
<https://doi.org/10.3189/172756501781832133>

Lin, H., Rauschenberg, S., Hexel, C. R., Shaw, T. J., & Twining, B. S. (2011) Free-drifting icebergs as sources of iron to the Weddell Sea *Deep-Sea Research Part II: Topical Studies in Oceanography*, 58(11–12), 1392–1406.
<https://doi.org/10.1016/j.dsr2.2010.11.020>

Liu, T., Niu, M., & Yang, Y. (2018) Ice velocity variations of the Polar Record Glacier (East Antarctica) using a rotation-invariant feature-tracking approach *Remote Sensing*, 10(1). <https://doi.org/10.3390/rs10010042>

Liwei Wang, Yan Zhang, & Jufu Feng (2005) On the Euclidean distance of images *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8), 1334–1339. <https://doi.org/10.1109/tpami.2005.165>

Luckman, A., Padman, L., & Jansen, D. (2010) Persistent iceberg groundings in the western Weddell Sea, Antarctica *Remote Sensing of Environment*, 114(2), 385–391. <https://doi.org/10.1016/j.rse.2009.09.009>

MacAyeal, D.R., Okal, M.H., Thom, J.E., Brunt, K.M., Kim, Y.J., Bliss, A.K., (2008) Tabular iceberg collisions within the coastal regime. *J. Glaciol.* 54, 371–386. <https://doi.org/10.3189/002214308784886180>

MacDonald, D., & Ltd, A. (2014) RADARSAT-2 Antarctica Mosaics and Tiles, 2008. Canadian Cryospheric Information Network (CCIN).

Machajdik, J., & Hanbury, A. (2010) Affective image classification using features inspired by psychology and art theory In *Proceedings of the international conference on Multimedia - MM '10* (p. 83).
<https://doi.org/10.1145/1873951.1873965>

Maini, R., & Aggarwal, H. (2010) A Comprehensive Review of Image Enhancement Techniques, 2(3), 8–13.
<https://doi.org/10.1016/j.jchromb.2015.11.031>

- Marbach, D., Costello, J. C., Kućffner, R., Vega, M., Nicole, Prill, R. J., Camacho, D. M., Zimmer, R. (2012) Wisdom of crowds for robust gene network inference. *Nature Methods*, 9 (8), 796–804. doi: 10.1038/nmeth.2016
- Marino, A., Rulli, R., Wesche, C., Hajnsek, I., (2015) A new algorithm for iceberg detection with dual-polarimetric SAR data. *Int. Geosci. Remote Sens. Symp.* 2015-Novem, 3446–3449. <https://doi.org/10.1109/IGARSS.2015.7326561>
- Marino, A., Dierking, W., & Wesche, C. (2016) A Depolarization Ratio Anomaly Detector to Identify Icebergs in Sea Ice Using Dual-Polarization SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5602–5615. <https://doi.org/10.1109/TGRS.2016.2569450>
- Marshall, J., & Speer, K. (2012) Closure of the meridional overturning circulation through Southern Ocean upwelling. *Nature Geoscience*, 5(3), 171–180. <https://doi.org/10.1038/ngeo1391>
- Masotti, M., & Campanini, R. (2008) Texture classification using invariant ranklet features, 29, 1980–1986. <https://doi.org/10.1016/j.patrec.2008.06.017>
- Mazur, A. K., Wåhlin, A. K., & Kręzel, A. (2017) An object-based SAR image iceberg detection algorithm applied to the Amundsen Sea. *Remote Sensing of Environment*, 189, 67–83. <https://doi.org/10.1016/j.rse.2016.11.013>
- Merino, N., Le Sommer, J., Durand, G., Jourdain, N. C., Madec, G., Mathiot, P., & Tournadre, J. (2016) Antarctic icebergs melt over the Southern Ocean : Climatology and impact on sea ice. *Ocean Modelling*, 104, 99–110. <https://doi.org/10.1016/j.ocemod.2016.05.001>
- Mishra, P., Chatterjee, R., & Mahapatra, V. (2010) Texture Segmentation Using Gabor Filters and Wavelets, (10606026). Retrieved from <http://ethesis.nitrkl.ac.in/1616/>
- Mouginot, J., Scheuchl, B., & Rignot, E. (2017) MEaSUREs Antarctic Boundaries for IPY 2007-2009 from Satellite Radar, Version 2. NASA National Snow and Ice Data Center Distributed Active Archive Center. doi: <https://doi.org/10.5067/AXE4121732AD>

- Muckenhuer, S., Korosov, A.A., Sandven, S., (2016) Open-source feature-tracking algorithm for sea ice drift retrieval from Sentinel-1 SAR imagery. *Cryosphere* 10, 913-925. <https://doi.org/10.5194/tc-10-913-2016>
- Nicholls, K. W., Østerhus, S., Makinson, K., Gammelsrød, T., & Fahrbach, E. (2009) Ice-ocean processes over the continental shelf of the Southern Weddell Sea, Antarctica: A review. *Reviews of Geophysics*, 47(3), 1–23. <https://doi.org/10.1029/2007RG000250>
- Niwattanakul, S., Singthongchai, J., Naenudorn, E., & Wanapu, S. (2013) Using of Jaccard Coefficient for Keywords Similarity. *Proceedings of the International MultiConference of Engineers and Computer Scientists, I.* <https://doi.org/ISBN 978-988-19251-8-3>
- Ohshima, K. I., Fukamachi, Y., Williams, G. D., Nihashi, S., Roquet, F., Kitade, Y., et al. (2013) Antarctic Bottom Water production by intense sea-ice formation in the Cape Darnley polynya. *Nature Geoscience*, 6(3), 235–240. <https://doi.org/10.1038/ngeo1738>
- Orheim, T. (1980) Physical Characteristics and life expectancy of tabular Antarctic icebergs. *Annals of Glaciology*, 1, 11-18.
- Orsi, A. H., Johnson, G. C., & Bullister, J. L. (1999) Circulation, mixing, and production of Antarctic Bottom Water. *Progress in Oceanography*, 43(1), 55–109. [https://doi.org/10.1016/S0079-6611\(99\)00004-X](https://doi.org/10.1016/S0079-6611(99)00004-X)
- Orsi, Alejandro H., & Wiederwohl, C. L. (2009) A recount of Ross Sea waters. *Deep-Sea Research Part II: Topical Studies in Oceanography*, 56(13–14), 778–795. <https://doi.org/10.1016/j.dsr2.2008.10.033>
- Orsi, Alejandro H., Whitworth, T., & Nowlin, W. D. (1995) On the meridional extent and fronts of the Antarctic Circumpolar Current. *Deep-Sea Research Part I*, 42(5), 641–673. [https://doi.org/10.1016/0967-0637\(95\)00021-W](https://doi.org/10.1016/0967-0637(95)00021-W)
- Özçift, A. (2011) Random forests ensemble classifier trained with data resampling strategy to improve cardiac arrhythmia diagnosis. *Computers in Biology and Medicine*, 41(5), 265–271. <https://doi.org/10.1016/j.compbiomed.2011.03.001>
- Paradella, W. R., Mura, J. C., Gama, F. F., Santos, A. R. dos, & Silva, G. G. da

(2015) Radares Imageadores (SAR) orbitais: tendências em sistemas e aplicações *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de Abril de 2015*, (1), 2506–2513. <https://doi.org/10.1017/CBO9781107415324.004>

Pardo, P. C., Pérez, F. F., Velo, A., & Gilcoto, M. (2012) Water masses distribution in the Southern Ocean: Improvement of an extended OMP (eOMP) analysis *Progress in Oceanography*, 103, 92–105. <https://doi.org/10.1016/j.pocean.2012.06.002>

Parkinson, C. L., & Cavalieri, D. J. (2012) Antarctic sea ice variability and trends, 1979-2010 *Cryosphere*, 6(4), 871–880. <https://doi.org/10.5194/tc-6-871-2012>

Perrone, M., & Cooper, L. (1993) *Improving regression estimation: Averaging methods for variance reduction with extensions to general convex measure optimization.*

Polikar, R., (2006) Ensemble based systems in decision making. *Circuits Syst. Mag. IEEE* 6, 21-45. <https://doi.org/10.1109/MCAS.2006.1688199>

Polsby, D. D., & Popper, R. (1991) The Third Criterion: Compactness as a Procedural Safeguard Against Partisan Gerrymandering *Yale Law & Police Review*, 9(2). <https://doi.org/10.2139/ssrn.2936284>

Puissant, A., Rougiera, S., & Stumpf, A. (2014) Object-oriented mapping of urban trees using random forest classifiers *International Journal of Applied Earth Observation and Geoinformation*, 26(1), 235–245. <https://doi.org/10.1016/j.jag.2013.07.002>

Purkey, S. G., & Johnson, G. C. (2013) Antarctic bottom water warming and freshening: Contributions to sea level rise, ocean freshwater budgets, and global heat gain *Journal of Climate*, 26(16), 6105–6122. <https://doi.org/10.1175/JCLI-D-12-00834.1>

Rackow, T., Wesche, C., Timmermann, R., Hellmer, H. H., Juricke, S., & Jung, T. (2017) A simulation of small to giant Antarctic iceberg evolution: Differential impact on climatology estimates *Journal of Geophysical Research: Oceans*, 122(4), 3170–3190. <https://doi.org/10.1002/2016JC012513>

- Raiswell, R. (2011) Iceberg-hosted nanoparticulate Fe in the Southern Ocean: Mineralogy, origin, dissolution kinetics and source of bioavailable Fe *Deep-Sea Research Part II: Topical Studies in Oceanography*, 58(11–12), 1364–1375. <https://doi.org/10.1016/j.dsr2.2010.11.011>
- Raju, P. D. R., & Neelima, G. (2012) Image Segmentation by using Histogram Thresholding *IJCSET*, 2(1), 776–779.
- Rignot, E., Jacobs, S., Mouginot, J., & Scheuchl, B. (2013) Ice-shelf melting around Antarctica. *Science*, 341 (6143), 266–270. doi: 10.1126/science.1235798
- Rintoul, S. R. (1998) On the origin and influence of Adélie land bottom water *Antarctic Research Series*, 75, 151–171. <https://doi.org/10.1029/ar075p0151>
- Rintoul, Stephen R. (2011) The Southern Ocean in the Earth System *Science Diplomacy: Science, Antarctica, and the Governance of International Spaces*, 175–187. <https://doi.org/10.5479/si.9781935623069.175>
- Romanov, Yuri A., Romanova, N. A., & Romanov, P. (2012) Shape and size of Antarctic icebergs derived from ship observation data *Antarctic Science*, 24(1), 77–87. <https://doi.org/10.1017/S0954102011000538>
- Romanov, Yury A., Romanova, N. A., & Romanov, P. (2008) Distribution of icebergs in the Atlantic and Indian ocean sectors of the Antarctic region and its possible links with ENSO *Geophysical Research Letters*, 35(2). <https://doi.org/10.1029/2007GL031685>
- Rosich, B., & Meadows, P. (2004) Absolute calibration of ASAR Level 1 products generated with PF-ASAR - Browse Document Library - Earth Online - ESA, (1), 26. Retrieved from <https://earth.esa.int/web/guest/-/absolute-calibration-of-asar-level-1-products-generated-with-pf-asar-4503>
- Rudin, L. I., Osher, S., & Fatemi, E. (1992) Nonlinear total variation based noise removal algorithms *Physica D: Nonlinear Phenomena*, 60(1–4), 259–268. [https://doi.org/10.1016/0167-2789\(92\)90242-F](https://doi.org/10.1016/0167-2789(92)90242-F)
- Sang, Q., Lin, Z., & Acton, S. T. (2016) Learning automata for image segmentation *Pattern Recognition Letters*, 74, 46–52. <https://doi.org/10.1016/j.patrec.2015.12.004>

Santisteban, J., & Tejada Carcamo, J. L. (2015) Unilateral Jaccard similarity coefficient *CEUR Workshop Proceedings*, 1393(1), 23–27.

Shimada, K., Aoki, S., Ohshima, K. I., & Rintoul, S. R. (2012) Influence of Ross Sea Bottom Water changes on the warming and freshening of the Antarctic Bottom Water in the Australian-Antarctic Basin. *Ocean Science*, 8 (4), 419–432. doi: 10.5194/os-8-419-2012

Schodlok, M. P., Hellmer, H. H., Rohardt, G., & Fahrbach, E. (2006) Weddell Sea iceberg drift: Five years of observations *Journal of Geophysical Research: Oceans*, 111(6), 1–14. <https://doi.org/10.1029/2004JC002661>

Schwarz, J. N., & Schodlok, M. P. (2009) Impact of drifting icebergs on surface phytoplankton biomass in the Southern Ocean: Ocean colour remote sensing and in situ iceberg tracking *Deep-Sea Research Part I: Oceanographic Research Papers*, 56(10), 1727–1741. <https://doi.org/10.1016/j.dsr.2009.05.003>

Selvakuberan, K., Indradevi, M., & Rajaram, R. (2008) Combined Feature Selection and classification – A novel approach for the categorization of web pages, 3(2), 83–89.

Shaw, T. J., Raiswell, R., Hexel, C. R., Vu, H. P., Moore, W. S., Dudgeon, R., & Smith, K. L. (2011) Input, composition, and potential impact of terrigenous material from free-drifting icebergs in the Weddell Sea *Deep-Sea Research Part II: Topical Studies in Oceanography*, 58(11–12), 1376–1383. <https://doi.org/10.1016/j.dsr2.2010.11.012>

Shimada, K., Aoki, S., Ohshima, K. I., & Rintoul, S. R. (2012) Influence of Ross Sea Bottom Water changes on the warming and freshening of the Antarctic Bottom Water in the Australian-Antarctic Basin *Ocean Science*, 8(4), 419–432. <https://doi.org/10.5194/os-8-419-2012>

Silva, T. A.M., Bigg, G. R., & Nicholls, K. W. (2006) Contribution of giant icebergs to the Southern Ocean freshwater flux *Journal of Geophysical Research: Oceans*, 111(3), 1–8. <https://doi.org/10.1029/2004JC002843>

Silva, Tiago A.M., & Bigg, G. R. (2005) Computer-based identification and tracking of Antarctic icebergs in SAR images *Remote Sensing of Environment*,

94(3), 287–297. <https://doi.org/10.1016/j.rse.2004.10.002>

Singh, M., & Singh, S. (2002) Spatial texture analysis: a comparative study *Proceedings of the 16th International Conference on Pattern Recognition*, 1, 676–679. <https://doi.org/10.1109/ICPR.2002.1044843>

Shaw, T.J., Raiswell, R., Hexel, C.R., Vu, H.P., Moore, W.S., Dudgeon, R., Smith, K.L., (2011) Input, composition, and potential impact of terrigenous material from free-drifting icebergs in the Weddell Sea. *Deep. Res. Part II Top. Stud. Oceanogr.* 58, 1376–1383. <https://doi.org/10.1016/j.dsr2.2010.11.012>

Shihavuddin A.S.M. (2014) Automated Underwater Object Classification using Optical Imagery, 176.

Smith, K. L. (2011) Free-drifting icebergs in the Southern Ocean: An overview *Deep-Sea Research Part II: Topical Studies in Oceanography*, 58(11–12), 1277–1284. <https://doi.org/10.1016/j.dsr2.2010.11.003>

Smith, W. O., Sedwick, P. N., Arrigo, K. R., Ainley, D. G., & Orsi, A. H. (2012) The Ross Sea in a sea of change *Oceanography*, 25(3), 90–103. <https://doi.org/10.5670/oceanog.2012.80>

Snapir, B., Waine, T., & Biermann, L. (2019) Maritime Vessel Classification to Monitor Fisheries with SAR: Demonstration in the North Sea *Remote Sensing*, 11(3), 353. <https://doi.org/10.3390/rs11030353>

Stephenson, G. R., Sprintall, J., Gille, S. T., Vernet, M., Helly, J. J., & Kaufmann, R. S. (2011) Subsurface melting of a free-floating Antarctic iceberg *Deep-Sea Research Part II: Topical Studies in Oceanography*, 58(11–12), 1336–1345. <https://doi.org/10.1016/j.dsr2.2010.11.009>

Stern, A. A., Adcroft, A., & Sergienko, O. (2016) The effects of Antarctic iceberg calving-size distribution in a global climate model *Journal of Geophysical Research: Oceans*, 121(8), 5773–5788. <https://doi.org/10.1002/2016JC011835>

Stuart, K.M. & Long, D.G., (2011) Tracking large tabular icebergs using the SeaWinds Ku-band microwave scatterometer. *Deep. Res. Part II Top. Stud. Oceanogr.* 58, 1285–1300. <https://doi.org/10.1016/j.dsr2.2010.11.004>

Su, Z., Stewart, A.L., Thompson, A.F., (2014) An Idealized Model of Weddell

Gyre Export Variability. J. Phys. Oceanogr. 44, 1671–1688.
<https://doi.org/10.1175/jpo-d-13-0263.1>

Surowiecki, J. (2005) The wisdom of Crowds. New York, NY: Anchor Books, a division of Random House, Inc.

Teoh, S. H., & Ibrahim, H. (2012) Median Filtering Frameworks for Reducing Impulse Noise from Grayscale Digital Images: A Literature Survey *International Journal of Future Computer and Communication*, 1(4), 323–326.
<https://doi.org/10.7763/IJFCC.2012.V1.87>

Thulasiraman, K. & Swamy, M. N. S. (2011) Graphs: Theory and Algorithms. John Wiley & Sons, 480 pages, ISBN: 111803257

Toan, T. Le (2007) SAR images statistics and preprocessing SAR measurement Statistical properties and data.

Tournadre, J., Bouhier, N., Girard-Ardhuin, F., & Rémy, F. (2016) Antarctic icebergs distributions 1992-2014 *Journal of Geophysical Research: Oceans*, 121(1), 327–349. <https://doi.org/10.1002/2015JC011178>

Tournadre, Jean, & Tarasenko, A. (2019) ICEBERG STUDIES USING SATELLITE ALTIMETER DATA In *IEEE International Geoscience and Remote Sensing Symposium* (pp. 3986–3989). <https://doi.org/978-1-5386-9154-0/19/>

Tournadre, Jean, Whitmer, K., & Girard-Ardhuin, F. (2008) Iceberg detection in open water by altimeter waveform analysis *Journal of Geophysical Research: Oceans*, 113(8). <https://doi.org/10.1029/2007JC004587>

Tournadre, Jean, Girard-Ardhuin, F., & Legrésy, B. (2012) Antarctic icebergs distributions, 2002-2010 *Journal of Geophysical Research: Oceans*, 117(5), 2002–2010. <https://doi.org/10.1029/2011JC007441>

Tremeau, A. (1995) Regions Adjacency Graph Applied to color image segmentation.

Veldadi, A. & Soatto, S. (2008) Quick Shift and kernel methods for mode seeking. Proc. of ECCV, 705-718.

Vorontsov, I. E., Kulakovskiy, I. V., & Makeev, V. J. (2013) Jaccard index based

similarity measure to compare transcription factor binding site models *Algorithms for Molecular Biology*, 8(1), 1. <https://doi.org/10.1186/1748-7188-8-23>

Wagner, T. J. W., Dell, R. W., & Eisenman, I. (2016) An analytical model of iceberg drift *American Meteorological Society*, 1605–1616. <https://doi.org/10.1175/JPO-D-16-0262.1>

Wang, C., Zhang, L., Lee, S. K., Wu, L., & Mechoso, C. R. (2014) A global perspective on CMIP5 climate model biases *Nature Climate Change*, 4(3), 201–205. <https://doi.org/10.1038/nclimate2118>

Wesche, C., & Dierking, W. (2012) Iceberg signatures and detection in SAR images in two test regions of the Weddell Sea, Antarctica *Journal of Glaciology*, 58(208), 325–339. <https://doi.org/10.3189/2012J0G11J020>

Wesche, C., & Dierking, W. (2015) Near-coastal circum-Antarctic iceberg size distributions determined from Synthetic Aperture Radar images *Remote Sensing of Environment*, 156, 561–569. <https://doi.org/10.1016/j.rse.2014.10.025>

Wesche, C., Jansen, D., & Dierking, W. (2013) Calving Fronts of Antarctica: Mapping and Classification *Remote Sensing*, 5(12), 6305–6322. <https://doi.org/10.3390/rs5126305>

Williams, R. N., Rees, W. G., & Young, N. W. (1999) A technique for the identification and analysis of icebergs in synthetic aperture radar images of Antarctica *International Journal of Remote Sensing*, 20(15–16), 3183–3199. <https://doi.org/10.1080/014311699211697>

Wu, S. Y., & Hou, S. (2017) Impact of icebergs on net primary productivity in the Southern Ocean *Cryosphere*, 11(2), 707–722. <https://doi.org/10.5194/tc-11-707-2017>

Zhang, G., Doviak, R. J., Vivekanandan, J., Brown, W. O. J., & Cohn, S. A. (2003) Cross-correlation ratio method to estimate cross-beam wind and comparison with a full correlation analysis *Radio Science*, 38(3), n/a-n/a. <https://doi.org/10.1029/2002rs002682>

Zhang, Q., Liu, Y., Zhu, S., & Han, J. (2017) Salient object detection based on super-pixel clustering and unified low-rank representation *Computer Vision and*

Image Understanding, 161, 51–64. <https://doi.org/10.1016/j.cviu.2017.04.015>

Zhou, Z.-H. (2012) *Ensemble methods Foundations and Algorithms Machine Learning & Pattern Recognition Series*. Retrieved from <https://books.google.co.jp/books?id=MFzRBQAAQBAJ>.

Apêndice I: Produtos e trabalhos derivados

A. 1. Artigos científicos

“An adaptive machine learning approach to improve automatic iceberg detection from SAR images” publicado no periódico ***“ISPRS Journal of Photogrammetry and Remote Sensing”***, volume 156 (2019), páginas 247-259. <https://doi.org/10.1016/j.isprsjprs.2019.08.015>

“Three years of near-coastal Antarctic iceberg distribution from a machine learning approach applied to SAR imagery” publicado no periódico ***“Journal of Geophysical Research: Oceans”***, volume 124 (2019), páginas 6658-6672.<https://doi.org/10.1029/2019JC015205>

“Automated iceberg tracking with a machine learning approach applied to SAR imagery: A Weddell Sea case study” em processo de submissão no periódico ***“ISPRS Journal of Photogrammetry and Remote Sensing”***.

A. 2. Programa de Computador Registrado

Patente: Programa de Computador. Número do registro: BR512019002151-7, data de registro: 01/07/2019, título: "***AutoIceDTA (AUTOnomous ICEberg Detection, Tracking and Analysis)***", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial. BARBAT, M. M. & MATA, M. M. (2019).

A. 3. Orientações e trabalhos derivados

GAMA, Nitchele R.; BARBAT, Mauro M.; MATA, Mauricio M. (2017). ***ESTUDO SOBRE PRE-PROCESSAMENTO DE IMAGENS DE RADAR.*** Agraciado com o "Prêmio Destaque Congresso de Iniciação Científica (CIC), MPU/FURG 2017".

GAMA, Nitchele R.; BARBAT, Mauro M.; MATA, Mauricio M. (2018). ***ESTUDO SOBRE A UTILIZAÇÃO DE MÉTODOS SUPERPIXEL PARA SEGMENTAÇÃO DE IMAGENS SAR: ESTUDO DE CASO PARA IDENTIFICAÇÃO DE ICEBERGS NO OCEANO AUSTRAL.*** Agraciado com o "Prêmio Destaque Congresso de Iniciação Científica (CIC), MPU/FURG 2018".