


UNIVERSIDADE FEDERAL DO PARANÁ

PEDRO VITOR SOUZA ROCHA

PREVISÃO DA VARIABILIDADE DO GELO MARINHO NO SETOR ANTÁRTICO
SUL-AMERICANO COM O EMPREGO DE REDES NEURAIS ARTIFICIAIS

CURITIBA

2022



PEDRO VITOR SOUZA ROCHA

PREVISÃO DA VARIABILIDADE DO GELO MARINHO NO SETOR ANTÁRTICO
SUL-AMERICANO COM O EMPREGO DE REDES NEURAIIS ARTIFICIAIS

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Ambiental pelo Programa de Pós-Graduação em Engenharia Ambiental, Setor de Tecnologia, da Universidade Federal do Paraná.

Área de Concentração: *Atmosfera e Mudanças Globais*.

Orientador: Prof. Dr. Ricardo Carvalho de Almeida

CURITIBA

2022

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Rocha, Pedro Vitor Souza

Previsão da variabilidade do gelo marinho no setor antártico sul-americano com o emprego de redes neurais artificiais / Pedro Vitor Souza Rocha. – Curitiba, 2022.

1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Ambiental.

Orientador: Ricardo Carvalho de Almeida

1. Antártica. 2. Gelo. 3. Redes neurais (Computação). 4. Variáveis aleatórias. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Engenharia Ambiental. III. Almeida, Ricardo Carvalho de. IV. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA AMBIENTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **PEDRO VITOR SOUZA ROCHA** intitulada: **Previsão da variabilidade do gelo marinho no setor antártico sul americano com o emprego de redes neurais artificiais.**, sob orientação do Prof. Dr. RICARDO CARVALHO DE ALMEIDA, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 24 de Fevereiro de 2022.

Assinatura Eletrônica

25/02/2022 12:11:29.0

RICARDO CARVALHO DE ALMEIDA

Presidente da Banca Examinadora

Assinatura Eletrônica

25/02/2022 10:39:46.0

EMILIO GRACILIANO FERREIRA MERCURI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

25/02/2022 13:53:49.0

FLÁVIA RODRIGUES PINHEIRO

Avaliador Externo (CENTRO DE HIDROGRAFIA DA MARINHA)

AGRADECIMENTOS

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

Agradeço à minha família, por todo o apoio prestado desde a graduação até a pós, sempre me incentivando e me apoiando para que eu chegasse até aqui.

Ao meu orientador, professor Dr. Ricardo Carvalho de Almeida, por todos os conselhos, apoios, auxílios e dedicação, sobretudo durante a pandemia. Mesmo que de forma remota sempre se mostrou presente. Sou grato por toda a paciência e ajuda prestada para que meu trabalho fosse concluído.

À Dra. Flávia Rodrigues Pinheiro, por aceitar o convite para participar da composição da banca, contribuindo para melhorias no trabalho.

Ao professor Dr. Emílio Mercuri, por aceitar o convite em compor a banca e pelas contribuições fornecidas através das disciplinas ministradas durante o período do Mestrado e para melhorias no estudo.

Aos professores que tive desde minha graduação até àqueles com quem tive contato e aprendizados durante o período de Mestrado na UFPR.

Ao Programa de Pós-Graduação em Engenharia Ambiental da UFPR e à CAPES, pela concessão da bolsa de estudos, permitindo que este estudo fosse realizado, sempre contribuindo para o crescimento pessoal e profissional de minha jornada acadêmica.

Aos meus amigos que prestaram suporte durante todo meu período acadêmico, em especial à Elys, Rebeca, Felipe, Letícia, Tainá e Daniele que puderam acompanhar em alguns momentos meus estudos e que contribuíram, cada um à sua forma para que eu seguisse durante toda a minha jornada.

Aos que não foram mencionados, mas que de alguma forma estiveram presentes e contribuíram para a minha formação acadêmica, deixo aqui meus agradecimentos.

RESUMO

O objetivo deste trabalho é avaliar o desempenho da Rede Neural Artificial (RNA) de função de base radial (RBF) na previsão da extensão do gelo marinho no Setor Antártico Sul-Americano. Para isso, levou-se em consideração a importância da seleção de variáveis que possuem maior influência sobre a variabilidade do gelo. Sabendo-se disso, através de uma revisão sistemática, foram encontrados possíveis preditores para o modelo de previsão, que passaram por uma posterior seleção, através do método *stepwise* com passo *forward*, afim de se obter o melhor conjunto de variáveis de entrada para a rede. Para cada região e cada configuração de previsão proposta, a rede RBF foi desenvolvida e avaliada, apresentando diferentes resultados para cada uma delas. Comparando-se ao desempenho obtido pelo método de previsão por persistência, os resultados das previsões através da rede RBF se mostraram satisfatórios, sobretudo, para horizontes de previsão de até 3 meses para o Setor Antártico Sul-Americano e para a região da Península Antártica, com resultados menos satisfatórios para a região do Estreito de Drake. As variáveis de precipitação e temperatura da superfície do mar no Mar de Bellingshausen foram as que apareceram mais vezes nos experimentos de previsão da rede, indicando maior importância para os resultados.

Palavras-chave: Antártica. Gelo marinho. Redes Neurais Artificiais. Seleção de variáveis de entrada. Redes neurais RBF.

ABSTRACT

The objective of this work is to evaluate the performance of the Radial Basis Function (RBF) of Artificial Neural Network (ANN) in the prediction of sea ice extent in the South American Antarctic Sector. Therewith, the importance of selecting variables that have the greatest influence on ice variability was considered. Knowing that, through a systematic review, possible predictors were found for the forecast model, which underwent a subsequent selection, through the stepwise method with forward step, in order to obtain the best set of input variables for the network. For each region and each proposed forecast configuration, the RBF network was developed and evaluated, presenting different results for each one of them. Comparing to the performance obtained by the persistence forecasting method, the forecast results through the RBF network proved to be satisfactory, especially for forecast horizons of up to 3 months for the South American Antarctic Sector and for the Antarctic Peninsula region, with less satisfactory results for the Drake Strait region. The variables of precipitation and sea surface temperature in the Bellingshausen Sea were the ones that appeared more frequently in the network prediction experiments, indicating greater importance for the results.

Keywords: Antarctic. Sea ice. Artificial Neural Networks. Selection of input variables. RBF Neural Networks.

LISTA DE FIGURAS

Figura 1: Divisão de setores no continente Antártico. Fonte: Adaptado de Blank <i>et al</i> ; 2011.	24
Figura 2: Localização das áreas de estudo onde atuam as variações de gelo com maior influência no setor Antártico Sul-Americano. Fonte: Autor, 2021.	25
Figura 3: El Niño de 2015/2016 e La Niña de 1999/2000. Fonte: Adaptado de Climate.org apud Tempo.com, 2018.	31
Figura 4: Composições de anomalias de pressão ao nível do mar (linhas, Pa) e geopotencial em 500 hPa (cores, m ² /s ²) durante o inverno para o Modo Anular Sul (SAM), fase positiva (à esquerda) e negativa (à direita). Adaptado de Nieto <i>et al.</i> (2014 apud Barboza <i>et al.</i> , 2015).	33
Figura 5: Extensões máxima e mínima de gelo marinho antártico, conforme a climatologia de 1982 a 2011. Fonte: NOAA (2018, apud Silva, 2018).	34
Figura 6: Efeitos da cobertura e movimento do gelo marinho. Fonte: Adaptado de Schmitt, 2005.	36
Figura 7: Representação de um neurônio biológico. Fonte: extraído e adaptado de http://cs231n.github.io/neural-networks-1/	38
Figura 8: Esquema simples de uma rede neural artificial. Fonte: Autor, 2021	38
Figura 9: Estrutura de uma rede RBF. Fonte: Adaptado de Silva <i>et al.</i> (2010 apud Milléo, 2020).....	41
Figura 10: Gráfico de uma função Gaussiana. Fonte: Centro Brasileiro de Pesquisas Físicas (CBPF), 2003.	42
Figura 11: Área de estudo do presente trabalho está representada pela região hachurada em vermelho. Fonte: Autor, 2022.	49
Figura 12: Localização de ocorrência dos fenômenos atmosféricos que são possíveis influenciadores da variação do gelo marinho no setor Antártico Sul-Americano. Fonte: Autor, 2021. Na figura tem-se: EL NIÑO 3.4 Região que ocorre o El Niño; SAM/CCA MB Modo Anular Sul e Corrente Circumpolar Antártica no Mar de Bellingshausen; SAM/CCA MW Modo Anular Sul e Corrente Circumpolar Antártica no Mar de Weddell; DARWIN e TAHITI diferença de pressão atmosférica nas duas regiões; Jato Subtropical e Jato Polar correntes de jato.....	52
Figura 13: Médias climatológicas de temperatura na superfície do mar de Bellingshausen.	54

Figura 14: Médias climatológicas de temperatura na superfície do mar de Weddell.	55
Figura 15: Médias climatológicas de precipitação total na região do mar de Bellingshausen.	56
Figura 16: Médias climatológicas de precipitação total na região do mar de Weddell.	56
Figura 17: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da TSM do mar de Bellingshausen.	57
Figura 18: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da TSM do mar de Weddell.	58
Figura 19: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Precipitação Total na região do mar de Bellingshausen.	59
Figura 20: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Precipitação Total na região do mar de Weddell.	60
Figura 21: Médias (painel superior) e evolução temporal (painel inferior) da concentração de gelo marinho no setor Antártico Sul-Americano.	61
Figura 22: Médias (painel superior) e evolução temporal (painel inferior) da extensão de gelo marinho no setor Antártico Sul-Americano.	62
Figura 23: Médias e evolução temporal da área de gelo marinho no setor Antártico Sul-Americano.	63
Figura 24: Resultado da terceira repetição do método <i>stepwise</i> , para o limite de 20% da correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse, com horizonte de previsão de 1 mês e utilização de 15 neurônios na camada oculta no treinamento da RNA.	69
Figura 25: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.	76
Figura 26: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.	76
Figura 27: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com	

limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.	77
Figura 28: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.	77
Figura 29: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.	78
Figura 30: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.	78
Figura 31: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.	79
Figura 32: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.	79
Figura 33: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.	80
Figura 34: Médias climatológicas da velocidade do vento da componente v à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.	91
Figura 35: Médias climatológicas da velocidade do vento da componente v à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.	92
Figura 36: Médias climatológicas da velocidade do vento da componente u à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.	92
Figura 37: Médias climatológicas da velocidade do vento da componente u à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.	93

Figura 38: Médias climatológicas da Pressão ao nível do mar, no centro de pressão do mar de Bellingshausen.	94
Figura 39: Médias climatológicas da Pressão ao nível do mar, no centro de pressão do mar de Weddell.	94
Figura 40: Médias climatológicas da Temperatura na superfície do mar, na região do El Niño 3.4.	95
Figura 41: Médias climatológicas da Velocidade da componente u à 200 hPa na região do Jato Polar.	95
Figura 42: Médias climatológicas da Velocidade da componente u à 200 hPa na região do Jato Subtropical.	96
Figura 43: Médias climatológicas da Pressão ao Nível do Mar na região do Modo Anular Sul (SAM).	96
Figura 44: Médias climatológicas da Pressão ao Nível do Mar na região do mar de Darwin.	97
Figura 45: Médias climatológicas da Pressão ao Nível do Mar na região do mar de Tahiti.	97
Figura 46: Médias climatológicas da Temperatura do ar à 2m na região do mar de Bellingshausen.	98
Figura 47: Médias climatológicas da Temperatura do ar à 2m na região do mar de Weddell.	98
Figura 48: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente v à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.	99
Figura 49: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente v à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.	100
Figura 50: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente u à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.	101
Figura 51: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente u à 10 mm, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.	102

Figura 52: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão ao Nível do Mar, na região do centro de pressão do mar de Bellingshausen.	103
Figura 53: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão ao Nível do Mar, na região do centro de pressão do mar de Weddell.	104
Figura 54: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura da Superfície do Mar na região do El Niño 3.4.	105
Figura 55: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Velocidade da componente u à 200 hPa na região do Jato Polar.	106
Figura 56: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Velocidade da componente u à 200 hPa na região do Jato Subtropical.	107
Figura 57: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do Modo Anular Sul (SAM).	108
Figura 58: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do mar de Darwin.	109
Figura 59: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do mar de Tahiti.	110
Figura 60: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura do ar à 2m, na região do mar de Bellingshausen.	111
Figura 61: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura do ar à 2m, na região do mar de Weddell.	112
Figura 62: Médias (painel superior) e evolução temporal (painel inferior) da Anomalia da Concentração de Gelo Marinho no Estreito de Drake.	113
Figura 63: Médias (painel superior) e evolução temporal (painel inferior) da Anomalia da Área de Gelo Marinho no Estreito de Drake.	114

Figura 64: Médias (painel superior) e evolução temporal (painel inferior) da anomalia da Extensão de Gelo Marinho no Estreito de Drake.	115
Figura 65: Médias (painel superior) e evolução temporal (painel inferior) da Concentração de Gelo Marinho na Península Antártica.....	116
Figura 66: Médias (painel superior) e evolução temporal (painel inferior) da Área de Gelo Marinho na Península Antártica.....	117
Figura 67: Médias da Extensão de Gelo Marinho na Península Antártica.	118
Figura 68: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	120
Figura 69: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	121
Figura 70: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	122
Figura 71: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	123
Figura 72: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	124
Figura 73: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas	

e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	125
Figura 74: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	126
Figura 75: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	127
Figura 76: Resultados das 9 repetições do método <i>stepwise</i> para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	128
Figura 77: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	129
Figura 78: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	130
Figura 79: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	131

Figura 80: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	132
Figura 81: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	133
Figura 82: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	134
Figura 83: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	135
Figura 84: Resultados das 9 repetições do método <i>stepwise</i> para a região da Península Antártica, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	136
Figura 85: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	137
Figura 86: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira	

linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	138
Figura 87: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	139
Figura 88: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	140
Figura 89: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	141
Figura 90: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	142
Figura 91: Resultados das 9 repetições do método <i>stepwise</i> para a região do Estreito de Drake, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.	143
Figura 92: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.....	144
Figura 93: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com	

limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.....	145
Figura 94: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.....	145
Figura 95: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.....	146
Figura 96: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.....	146
Figura 97: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.....	147
Figura 98: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.....	147
Figura 99: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.....	148
Figura 100: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.....	148
Figura 101: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.....	149

Figura 102: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 3 meses.....	149
Figura 103: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.	150
Figura 104: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.	150
Figura 105: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.	151
Figura 106: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.	151
Figura 107: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.	152
Figura 108: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 3 meses.	152

LISTA DE TABELAS

Tabela 1: Localização das possíveis variáveis preditoras para previsão de gelo marinho no setor Antártico Sul-Americano.	53
Tabela 2: Correlações entre a área e extensão do gelo marinho nas regiões do Estreito de Drake, Península Antártica e Setor Antártico Sul Americano.	64
Tabela 3: Variáveis candidatas a preditoras de acordo com o limite pré-definido em 30% sobre a correlação cruzada entre as variáveis e a extensão do gelo marinho no Setor Antártico Sul Americano, com horizonte de previsão (atraso) de 1,2 e 3 meses.	65
Tabela 4: Resultados da seleção <i>stepwise</i> para a região do Estreito de Drake.	70
Tabela 5: Resultados da seleção <i>stepwise</i> para a região da Península Antártica. ...	70
Tabela 6: Resultado da seleção <i>stepwise</i> para a região do Setor Antártico Sul Americano.	71
Tabela 7: Resultados obtidos na avaliação da previsão por persistência.	72
Tabela 8: Desempenho da rede RBF para a previsão da extensão do gelo marinho no Estreito de Drake.	73
Tabela 9: Desempenho da rede RBF para a previsão da extensão do gelo marinho na Península Antártica.	74
Tabela 10: Desempenho da rede RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul Americano.	75
Tabela 11: Comparação dos resultados obtidos com as diferentes técnicas empregadas para a previsão da extensão do gelo marinho.	81
Tabela 12: Estatísticas calculadas a partir dos dados climáticos das possíveis variáveis preditoras.	119

LISTA DE ACRÔNIMOS

CCA	Corrente Circumpolar Antártica
CLP	Correlação Linear de Pearson
CNS	Coeficiente de Nash-Sutcliffe
CV	Covariância
DPA	Desvio Padrão
ECMWF	<i>European Centre for Medium-Range Weather Forecasts</i>
ERA5	<i>European Reanalysis</i>
EMA	Erro Médio Absoluto
ENSO	<i>El Niño South Oscillation</i> – el niño oscilação sul
ESSP	<i>Earth System Science Pathfinder</i>
GRACE	<i>Gravity Recovery and Climate Experiment</i>
MB	Mar de Bellingshausen
MW	Mar de Weddell
NSIDC	<i>National Snow and Ice Data Center</i>
PNM	Pressão ao Nível do Mar
RBF	<i>Radial Basis Function</i> – função de base radial
REQM	Raiz do Erro Médio Quadrático
RNA	Rede Neural Artificial
SAM	<i>Southern Annular Mode</i> – modo anular sul
T2M	Temperatura do ar à 2m
TSM	Temperatura da Superfície do Mar

LISTA DE SÍMBOLOS

Σ	Combinador linear de RNA
E_m	Erro quadrático médio
E_m^a	Erro médio quadrático anterior
E_m^{atual}	Erro médio quadrático atual
b	Viés (<i>bias</i>)
c	Centro da função gaussiana
f	Função de ativação
g	Função gaussiana
n	Número total
u	Pesos sinápticos da camada intermediária
w	Pesos sinápticos da camada de entrada
W	Vetor de pesos sinápticos
x	Sinal de entrada da RNA
y_e	Valores estimados
$\bar{y}_e$	Média dos valores estimados
y_o	Valores observados
$\bar{y}_o$	Média dos valores observados
y	Variável de interesse
y^*	Sinal de saída da RNA
θ	Limiar de ativação
σ	Desvio Padrão

SUMÁRIO

1 INTRODUÇÃO	22
2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA	27
2.1 METEOROLOGIA DA ANTÁRTICA	27
2.1.1 Características Climáticas do Setor Antártico Sul-Americano	28
2.2 GELO MARINHO	34
2.3 REDES NEURAIS ARTIFICIAIS	37
2.4 REDES DE FUNÇÃO DE BASE RADIAL.....	40
2.5 ALGORITMOS DA REDE RBF	44
2.6 SELEÇÃO DE VARIÁVEIS.....	46
2.6.1 Regressão <i>Stepwise</i>	46
3 METODOLOGIA	48
3.1 REVISÃO SISTEMÁTICA.....	48
3.2 ÁREA DE ESTUDO E BASES DE DADOS.....	49
3.3 PRÉ-SELEÇÃO DE PREDITORES.....	51
3.4 ANÁLISES EXPLORATÓRIAS PRELIMINARES	54
3.5 DESENVOLVIMENTO DO MODELO.....	64
3.6 ESTRUTURA DA RNA.....	65
3.7 PREVISÃO POR PERSISTÊNCIA	66
3.8 ANÁLISE DE DESEMPENHO DAS PREVISÕES	67
4 RESULTADOS DOS EXPERIMENTOS DE PREVISÃO	69
4.1 AVALIAÇÃO DE DESEMPENHO DO TREINAMENTO DOS MODELOS	69
4.2 PREVISÃO POR PERSISTÊNCIA	71
4.3 PREVISÃO PELA REDE NEURAL RBF	72
4.4 COMPARAÇÃO DE RESULTADOS	80
5 CONCLUSÃO E RECOMENDAÇÕES	83
6 REFERÊNCIAS.....	85
APÊNDICE A	91
A.1 MÉDIAS CLIMATOLÓGICAS DAS POSSÍVEIS VARIÁVEIS PREDITORAS	91
A.2 ANOMALIAS DAS POSSÍVEIS VARIÁVEIS PREDITORAS.....	99
A.3 MÉDIAS E ANOMALIAS DOS DADOS DE GELO MARINHO	113
APÊNDICE B	119
APÊNDICE C	120
APÊNDICE D	144

1 INTRODUÇÃO

O clima da Terra sofre grande influência da criosfera, que é formada, basicamente, pelo gelo continental encontrado na Groenlândia e Antártica, o gelo marinho, o permafrost (encontrado no hemisfério norte) e a neve. A natureza e as propriedades físicas do gelo e da neve influenciam e controlam diretamente as interações com outros componentes do clima, tanto local, quanto globalmente. Sua distribuição pelo planeta é importante devido à sua eficiência em refletir a radiação solar. A criosfera atua como um eficiente dissipador de calor para a atmosfera e os oceanos, através de seu albedo relativamente alto e de sua energia latente gerada pelo derretimento (Peixoto e Oort, 1992).

A Antártica, diferente da região polar do hemisfério norte, possui uma grande extensão de gelo continental, que sofre uma significativa variabilidade anual na formação de gelo marinho em seu entorno. Sua extensão pode atingir área superior à Europa e América do Norte juntas, quando atinge até 7% de toda a superfície terrestre (Wadhams, 2000).

O comportamento da extensão do gelo marinho na Antártica é discutido por diversos autores em busca de respostas sobre seu aumento ou diminuição. Holland e Kwok (2012), através de imagens de satélite do movimento do gelo para o período de 1992-2010, concluem que a cobertura do gelo marinho ao redor do continente sofreu uma ligeira expansão de área nas últimas décadas, enquanto Meehl *et al.* (2019) apontam para uma tendência de redução no gelo marinho após o final de 2016, que está associada a uma parte superior do Oceano Antártico mais quente, este é o culminar de uma tendência decenal negativa de ondulação de estresse do vento com Modo Anular Sul positivo (SAM), que resulta em água mais quente.

A inconclusão sobre o comportamento do gelo marinho na Antártica levou aos recentes estudos sobre a evolução e tendência da extensão do gelo marinho sob a influência de diferentes sistemas climáticos, que visam buscar uma justificativa para as alterações. Parkinson e Cavalieri (2012) utilizaram dados de satélites combinando médias diárias, mensais e anuais para o cálculo da tendência de concentração do gelo marinho. A evolução das médias de concentração do gelo marinho também foi analisada por Turner *et al.* (2015), que chegaram à conclusão de que a extensão total do gelo marinho aumentou desde o final dos anos 1970. Ambos os estudos utilizaram

os algoritmos NASA Team e Bootstrap. Já para Vaughan *et al.* (2003), o derretimento do gelo marinho na Antártica vem causando alterações nos sistemas climáticos.

Recentemente, dados do Centro Nacional de Dados de Neve e Gelo dos EUA mostraram que a cobertura do gelo marinho no Oceano Antártico caiu abaixo de 2 milhões Km² pela primeira vez desde que as medições foram iniciadas em 1979. Segundo Meier e Hobbs (2022), ainda não é possível dizer que tal evento tenha relação com a mudança climática, mas que deverá ser considerado para futuras análises (The Guardian, 2022).

A previsão do gelo marinho, com a devida análise dos dados de variação de área, extensão e concentração são importantes para órgãos como a Marinha do Brasil, que os utilizam para chegar ao continente com seus navios. Em épocas com maior extensão de gelo marinho, como no inverno, torna-se mais difícil o acesso ao continente Antártico pelo mar.

Como na maioria dos estudos, Parkinson e Cavalieri (2012) consideram cinco grandes regiões para a Antártica, são elas: Mar de Weddell, Oceano Índico, Oceano Pacífico Ocidental, Mar de Ross e a região dos mares de Amundsen e Bellingshausen (Figura 1).




Figura 1: Divisão de setores no continente Antártico. Fonte: Adaptado de Blank *et al*; 2011.

As análises de tendência e previsão do gelo marinho possuem comportamentos diferentes em cada uma dessas regiões. Poucos estudos possuem enfoque na região do setor Sul-Americano, a qual será enfocada no presente trabalho. Para caracterizar a área de estudo, foram consideradas as regiões da Antártica mais próximas ao continente sul-americano. As regiões da Península Antártica, do Estreito de Drake e dos mares de Weddell e Bellingshausen serão tomadas como base para o estudo (Figura 2).




Figura 2: Localização das áreas de estudo onde atuam as variações de gelo com maior influência no setor Antártico Sul-Americano. Fonte: Autor, 2021.

Dentre os diversos modelos de previsão de fenômenos meteorológicos e climáticos existentes, as Redes Neurais Artificiais (RNAs) vêm sendo cada vez mais utilizadas pela comunidade científica. Porém, seu crescente uso para estudos de previsões climáticas não incluem a utilização da estrutura para a previsão de gelo marinho, sendo pouco usado para essa finalidade. Lee *et al.* (2018) falam sobre a capacidade das RNAs de identificarem relações lineares e não-lineares entre variáveis preditoras e preditandos. Tais características fazem com que seja uma ferramenta promissora para estudos sobre a variabilidade e previsão do gelo marinho.

As variáveis utilizadas para o desenvolvimento de um modelo de previsão utilizando as RNAs são determinantes para o sucesso da rede. Sabendo disso, se faz necessária uma seleção criteriosa e apropriada de variáveis de entrada. Cada autor define em seu trabalho qual o melhor método para realizar essa seleção. Os métodos podem variar de acordo com as resoluções espacial, temporal e frequência com que estão disponibilizados os dados.

Sabendo-se da pouca utilização de RNAs para a previsão de gelo marinho e da falta de estudos que enfoquem a região do setor Antártico Sul-Americano, este trabalho tem como objetivo geral propor modelos de previsão mensal ou sazonal para a extensão do gelo marinho no setor Antártico Sul-Americano. O estudo das

componentes climáticas que possuem relação com a variabilidade do gelo marinho que mais aparecem na bibliografia é necessário para a pré-seleção das variáveis preditoras. Para alcançar o objetivo geral, foram definidos os objetivos específicos abaixo:

- Pré-selecionar as variáveis preditoras, a partir dos fenômenos e sistemas climáticos citados em trabalhos anteriores e que possuam relação e influência sobre o gelo marinho do setor antártico sul-americano.
- Identificar e selecionar definitivamente quais das variáveis possuem maior relação e influência no desempenho da rede neural na previsão do gelo marinho, utilizando o método de seleção *stepwise*.
- Desenvolver e validar modelos capazes de realizar a previsão de gelo marinho a partir de dados já disponíveis nas escalas mensal e sazonal.

2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA

2.1 METEOROLOGIA DA ANTÁRTICA

O manto de gelo da Antártica e seus arredores são grandes dissipadores de energia e calor que influenciam diferentes sistemas climáticos globais (Bromwich e Parish, 1998). Portanto, há grande interação entre as regiões costeiras e os mares em seu entorno, relativamente mais quentes comparando-se ao clima continental. Os sistemas sinóticos que atuam nessas áreas são os principais responsáveis pela troca de energia entre as regiões de média latitude e as regiões subpolares (Felicio, 2007).

Um segundo fator para o grande contraste e troca de energia entre os sistemas polares é a orografia acentuada do continente antártico, também citada por Bromwich e Parish (1998), já que a altitude média do continente chega a quase 2400 metros, sendo a mais alta entre os continentes. O principal fenômeno climático afetado pela orografia é o regime de ventos denominados catabáticos, que transportam ar de alta densidade de uma elevação descendo pela encosta devido à ação da gravidade, com fluxo que vai do centro do continente antártico até as extremidades.

Considerando a posição geográfica do continente Antártico, e sua elevada superfície de gelo, o balanço radiativo segue negativo na maior parte do ano. A neve e a superfície do gelo atuam com emissividade para ondas longas acima de 0,90. O albedo continental também chega a valores altos, sempre em torno de 0,80 ou mais (Bromwich e Parish, 1998).

King e Turner (1997) falam sobre como o elevado albedo do continente resulta em grande refletividade da radiação solar, e, portanto, diminui a temperatura do ar ao mesmo tempo em que a cobertura do gelo aumenta, o que tende a ampliar as mudanças de temperatura originais.

A variabilidade do gelo marinho, por sua vez, possui grande influência no clima da Antártica, promovendo alterações no regime de ventos e troca de calor no sistema oceano-atmosfera.

Os sistemas sinóticos promovem as conexões climáticas entre a Antártica e outras regiões do globo através do deslocamento de massas de ar. Elas possuem propriedade de se deslocarem para latitudes menores, transportando ar frio e precipitação associados à sistemas frontais. Em uma das conexões mais importantes,

é possível citar a interação entre as massas de ar polar e a massa de ar subtropical, que avança em direção a latitudes médias, mais conhecida como Frente Polar (Barry e Chorley, 2009). Nessas interações são formados os ciclones extratropicais, sistemas de baixa pressão com núcleo frio, que avançam em direção à América do Sul e afetam as condições de tempo no continente, causando precipitações fortes e quedas na temperatura do ar (Aquino; Setzer, 2005 apud Silva, 2018).

Existem pesquisas como a missão GRACE (*Gravity Recovery and Climate Experiment*), que faz parte do Programa ESSP (*Earth System Science Pathfinder*) da NASA, que estudam alterações na massa de gelo continental da Antártica. No entanto, o estudo proposto analisará somente as variações da extensão do gelo marinho, ou seja, aquele que se forma sobre o oceano no entorno da massa continental.

2.1.1 Características Climáticas do Setor Antártico Sul-Americano

Para caracterizar o clima da região de estudo, foram tomadas como base as influências climáticas ocorridas nas regiões da Península Antártica e seu entorno, já que possuem maior influência climática sobre o setor Sul-Americano. A Península Antártica se encontra ao sul da América do Sul, separada dessa pelo Estreito de Drake, a uma distância de quase 1000 quilômetros. A Península também separa geograficamente os mares de Weddell e de Bellingshausen.

Os ciclones extratropicais são responsáveis por grande parte dos fluxos de umidade e energia que ocorrem entre os continentes Antártico e Sul-Americano. As baixas temperaturas dos mares de Weddell e de Bellingshausen favorecem a formação de gelo marinho, refletindo também nas interações climáticas, promovendo maiores contrastes térmicos no continente Sul-Americano (Carpenedo, 2012). Segundo Hoskins e Hodges (2005 apud Gandra e Quadro, 2019), a costa leste da América do Sul e a Península Antártica são as áreas mais favoráveis para a formação de ciclones. Um dos fatores para que isso aconteça é a diferença entre as temperaturas da superfície do mar e do ar superficial. Quanto maior a temperatura da superfície do mar (TSM), maior será a quantidade de energia e umidade liberadas para a atmosfera (Reboita, 2008 apud Gandra e Quadro, 2019). Com o aumento do gradiente horizontal de temperatura, mais energia potencial é convertida em energia cinética, fortalecendo os ciclones que possuem conexões atmosféricas com a América do Sul.

A partir daqui serão apresentados alguns fenômenos climáticos que possuem influência sobre a área de estudo e que podem afetar a extensão do gelo marinho, bem como suas origens e localizações. Alguns desses fatores alteram os sistemas climáticos locais mesmo localizados em outras regiões, portanto, sistemas de pressão e campos atmosféricos serão apresentados para uma região maior, já que se contextualizam em áreas mais amplas.

A grande Corrente Circumpolar Antártica (CCA), é formada por correntes oceânicas que percorrem o entorno do continente Antártico no sentido geral leste, ligando-se com outras bacias dos oceanos Atlântico, Índico e Pacífico. A água flui em movimentos que vão para o norte e para o sul, trocando calor e salinidade com os outros oceanos e promovendo a regulação da temperatura oceânica a nível global (Marschoff, 2016).

Jacobs e Comiso (1997), apontam para o desvio da CCA que ocorre na Península Antártica, ocasionando diferenças de temperatura entre os mares de Weddell e Bellingshausen. O lado oeste da Península é cerca de 6° C mais quente do que o lado leste. Essa diferença expressiva é justificada pelo comportamento do regime de ventos na região. No mar de Weddell (leste da Península Antártica) os ventos têm predominância para o norte, enquanto no Mar de Bellingshausen (oeste da Península Antártica), os ventos possuem suas componentes intensificadas para o sul. Esses fatores limitam a formação e avanço do gelo marinho para o norte e oeste da Península (Jacobs e Comiso, 1997).

Os centros de baixa pressão formados na região da Península Antártica são resultantes dos sistemas sinóticos citados anteriormente. Bromwich *et al.* (1998) e White e Peterson (1996 apud Jacobs e Comiso, 1997), avaliam a variabilidade sinótica da Pressão ao Nível do Mar (PNM) no Mar de Weddell como influenciador na divergência de gelo marinho, limitando-se à Península Antártica, que bloqueia a deriva do gelo para oeste, sendo responsável também pelas temperaturas mais frias, que aceleram o congelamento do mar no local.

Holland e Kwok (2012) e Turner *et al.* (2015), apontam para os centros de baixa pressão existentes dentro da região circumpolar Antártica, com ênfase para os mares de Amundsen e Bellingshausen. A variabilidade dos centros de pressão possui grande influência no clima da Península Antártica. Os autores destacam as mudanças que ocorrem nos gradientes de PNM entre as estações costeiras da Antártica, além do volume de precipitação que, em combinação com o alto fluxo de calor do oceano,

podem induzir ou reforçar variações periódicas plurianuais na extensão do gelo marinho.

Desde o início das medições de temperatura na Península, foi percebido que os campos de temperatura nos mares de Weddell e de Bellingshausen sofrem grande influência do regime de ventos, principalmente quando há variações na direção. Lübbecke (2010 apud Silva, 2018) utilizou dados da TSM do Atlântico Sul para verificar as alterações relacionadas com variações de intensidade dos sistemas sinóticos da Península Antártica e do Atlântico Sul, e que podem ser utilizadas também para previsão de aquecimento nos oceanos.

Stammerjohn *et al.* (2008), identificam em sua análise que o movimento de avanço e recuo do gelo marinho está fortemente associado à localização e intensidade da CCA, que podem ser determinadas pelo gradiente meridional de temperatura no sul do Pacífico. Fletcher (1972 apud Jacobs e Comiso, 1997), observou uma correlação entre a temperatura do inverno no Oceano Antártico e a intensidade da circulação zonal do hemisfério sul. Ackley e Keliher (1976, apud Jacobs e Comiso, 1997) relataram que a extensão do gelo influencia os padrões climáticos de escala sinótica, as temperaturas do ar e a circulação atmosférica local. A correlação das extensões do gelo marinho com a temperatura foi maior e mais consistente em uma escala regional do que para toda a Antártica.

A variabilidade do gelo marinho antártico é documentada desde o final da década de 1970. Em diversas análises ocorridas nesse período, ela foi examinada em conexão com outros fenômenos dos sistemas atmosféricos terrestres, como o El Niño / Oscilação Sul (ENSO) (Parkinson e Cavalieri, 2012). O ENSO é um padrão climático recorrente que altera as temperaturas da água nos oceanos Pacífico tropical, central e oriental, caracterizado pelas anomalias na temperatura da superfície do mar. Esse padrão oscilatório de aquecimento e resfriamento afeta diretamente o regime de chuvas nos trópicos e pode ter grande influência no clima global (King, 2006). O ENSO é dividido em três fases: El Niño, La Niña e neutro. A fase do El Niño se inicia, geralmente, no meio do ano, quando há o aquecimento do Oceano Pacífico equatorial e oriental e mudanças no comportamento da circulação atmosférica, com variações nos regimes de ventos, pressão e de precipitação. No geral, quanto mais altas as anomalias de temperatura do oceano, mais forte é o El Niño (Robles, 2018). Esse estágio ocorre em períodos que variam de três a sete anos e pode durar até dezoito meses. Já na fase La Niña ocorre o resfriamento da TSM na mesma região do Oceano

Pacífico equatorial, juntamente com uma inversão das condições atmosféricas subjacentes (Figura 3). O intervalo entre os eventos de El Niño e La Niña é denominado Neutro, quando não há anomalias na temperatura da superfície do Oceano Pacífico e, portanto, não há alterações nas condições atmosféricas nesse período, sendo controlada por outros fatores climáticos (National Weather Service, 2021).




Figura 3: El Niño de 2015/2016 e La Niña de 1999/2000. Fonte: Adaptado de Climate.org apud Tempo.com, 2018.

Em seu estudo, Stammerjohn *et al.* (2008) analisam a relação do avanço e recuo do gelo marinho com o ENSO e citam que uma das principais características dessa teleconexão é o enfraquecimento do jato subtropical e o fortalecimento do jato de frente polar no Pacífico Sul durante os eventos La Niña. O fortalecimento do jato

de frente polar leva a mais tempestades, condições mais quentes e menos gelo marinho no sul de Bellingshausen e oeste dos mares de Weddell, mas condições mais frias e mais gelo marinho nos mares de Amundsen e Ross. O cenário oposto se aplica aos eventos El Niño. Este padrão de anomalia do gelo marinho entre os mares de Bellingshausen-Weddell e os mares de Amundsen-Ross durante os eventos ENSO é referido como o Dipolo Antártico.

O Modo Anular Sul (SAM), também conhecido como Oscilação Antártica, refere-se ao movimento de norte a sul do cinturão de vento oeste que circunda a Antártica, dominando as latitudes médias e altas do hemisfério sul, com seu núcleo entre 50° e 55° S. As mudanças que ocorrem dentro do cinturão de ventos influenciam na força e posição de frentes frias e sistemas de tempestades nas latitudes médias. Para o Modo Anular Sul existem duas fases, a positiva e a negativa (Bureau of Meteorology, 2012). Na fase positiva, os ventos do cinturão se contraem em direção ao continente Antártico, ocasionando mudanças nos ventos predominantes de oeste e causando aquecimento e secagem sobre o sul da América do Sul e consequente aumento da ressurgência de águas profundas quentes da região circumpolar e recessão glacial no oeste da Antártica e Península Antártica. Também ocorrem anomalias na pressão do ar, que fica mais baixa sobre a Antártica e mais alta nas latitudes médias. Já na fase negativa, os ventos se deslocam no sentido norte em direção ao equador, ocasionando frentes frias mais intensas e úmidas para a América do Sul, e, ao inverso do que ocorre na fase positiva, o gelo marinho avança e alcança maiores extensões (Davies, 2021). A figura 4 ilustra o comportamento das componentes climáticas durante cada fase do SAM.

Em seu estudo sobre as recentes mudanças no gelo marinho da Antártica, Turner *et al.* (2015), indicaram as evidências já existentes sobre a influência do SAM sobre o gelo marinho entre a Península Antártica e o Mar de Ross. Liu *et al.* (2004 apud Turner *et al.*, 2015), examinaram as tendências do gelo marinho entre os anos de 1979 e 2002 e descobriram que durante a fase positiva do SAM havia mais gelo marinho no setor oriental do mar de Ross / Amundsen e Bellingshausen / Norte de Weddell. Além disso, Comiso *et al.* (2011 apud Turner *et al.*, 2015) notaram que a variabilidade na cobertura do gelo sobre o Mar de Ross estava ligada a mudanças no SAM e, secundariamente, à CCA. Ainda ao final do estudo, os autores sugerem que as respostas de temperatura da superfície e da extensão do gelo marinho no Oceano Antártico ocorrem em duas escalas diferentes de tempo na polaridade do SAM. A

resposta inicial, em escala de tempo curta, é um resfriamento da superfície e aumento na extensão do gelo marinho, que é então seguido pelo aquecimento da superfície e redução da extensão do gelo marinho. No entanto, há uma incerteza considerável sobre a duração da transição entre as duas escalas de tempo, variando de alguns anos a algumas décadas. Embora sejam necessárias mais pesquisas sobre esse mecanismo, ele potencialmente ajuda a explicar pelo menos uma parte das mudanças que ocorrem no gelo marinho da Antártica.




Figura 4: Composições de anomalias de pressão ao nível do mar (linhas, Pa) e geopotencial em 500 hPa (cores, m^2/s^2) durante o inverno para o Modo Anular Sul (SAM), fase positiva (à esquerda) e negativa (à direita). Adaptado de Nieto *et al.* (2014 apud Barboza *et al.*, 2015).

A temperatura da superfície do mar (TSM) se refere à temperatura do milímetro superior do oceano. Uma anomalia é um desvio das condições médias (NASA Earth Observatory, 2021). Os fenômenos ENSO e SAM influenciam diretamente na TSM da região circumpolar Antártica, causando anomalias da temperatura das águas superficiais. Wang e Cai (2013) falam sobre a correlação existente entre esses fenômenos. Segundo os autores, a fase negativa do SAM é dominante durante os períodos de El Niño. Uma justificativa para essa relação é que durante a fase El Niño, as anomalias de TSM aumentam a temperatura global média, contribuindo para uma diminuição de pressão nas latitudes médias. A

correspondência entre as anomalias negativas no gelo marinho com as anomalias positivas na temperatura da superfície é significativa em praticamente todas as áreas do Oceano Antártico (Comiso *et al.*, 2017).

2.2 GELO MARINHO

O gelo marinho, de origem marítima, é qualquer forma de gelo resultante do congelamento da água do mar (Simões, 2004). Ele interage grandemente com as variáveis climáticas que compõem o planeta, sendo a faixa costeira da Antártica a que possui maior variância de cobertura de gelo ao longo do ano, alcançando cobertura máxima em setembro e diminuindo rapidamente durante o verão, atingindo a mínima em fevereiro (Figura 5). Toda essa variação (15,2 milhões de km²) supera a própria área do continente (14 milhões de km²) (Ferron, 1999).




Figura 5: Extensões máxima e mínima de gelo marinho antártico, conforme a climatologia de 1982 a 2011. Fonte: NOAA (2018, apud Silva, 2018).

O gelo marinho será caracterizado de acordo com sua concentração, extensão e área. A extensão é o resultado da somatória de todas as células que possuem ao menos 15% de cobertura de gelo marinho. Já a área corresponde a área de cada célula que apresenta cobertura de gelo multiplicada pela sua concentração, que por sua vez, é a razão de proporção de cobertura do gelo marinho sobre determinada área, ou seja, a porcentagem do oceano que está coberta por ele.

A partir dos dados de concentração disponíveis, é possível se obter os valores de extensão e área do gelo marinho. Sendo a extensão resultado da soma das células de gelo que possuíam ao menos 15% de concentração, e a área, o resultado da multiplicação entre seu tamanho total e sua concentração.

Como as superfícies de neve e gelo possuem um alto albedo (até 90%), o gelo marinho absorve uma baixa quantidade de energia solar, mantendo então, sua superfície resfriada por muito mais tempo. Ele também é capaz de influenciar o balanço de energia da superfície, justificado pela baixa condutividade térmica, reduzindo as trocas de calor oceano-atmosfera. Nos meses de inverno, o gelo marinho possui mais eficiência como isolante térmico do oceano, bloqueando a evaporação e influenciando na formação de nuvens, na estabilidade atmosférica e na precipitação (King e Turner, 1997).

Para Wallace e Hobbs (2006), com a sazonalidade da variação de gelo no oceano, o albedo é frequentemente afetado. Quando há redução do albedo do oceano, decorrente do derretimento de gelo marinho, há maior fluxo de calor, aumentando a temperatura do ar e da superfície do mar, impactando mais no derretimento durante o verão. A formação de gelo marinho é bastante vulnerável às mudanças no oceano e na atmosfera, definindo mais uma vez, sua importância para o sistema climático global.

King e Turner (1997) citam os processos de congelamento e derretimento do gelo marinho como influenciadores da estabilidade do oceano superior, já que ocorrem alterações na concentração de sal (figura 6). Tal mecanismo afeta diretamente na formação de massas de água, principalmente a água de Fundo Antártica, acarretando em variações na circulação termoalina do planeta.




Figura 6: Efeitos da cobertura e movimento do gelo marinho. Fonte: Adaptado de Schmitt, 2005.

As placas de gelo marinho à deriva que flutuam sobre o oceano estão sujeitas ao deslocamento pela ação do vento e das correntes oceânicas. A resposta do movimento do gelo ao vento ocorre em escala sinótica, em escalas de tempo de até 12 horas. A Corrente Circumpolar Antártica, que possui deslocamento no sentido horário ao longo da latitude 60° S, junto à corrente costeira da Antártica, são as principais responsáveis pela redistribuição do gelo nos diversos setores do Oceano Austral (Zwally *et al*; 2002).

As zonas de gelo marinho, principalmente as da borda do continente Antártico, influenciam diretamente os processos atmosféricos. Podemos citar primeiramente a diferença de temperatura existente entre o gelo marinho e a superfície do oceano, além das diferenças estruturais. Elas são responsáveis por afetarem o albedo, o balanço de radiação, fluxos de calor e a rugosidade superficial, que, por sua vez, causam aquecimento diferencial extremo e promovem maiores diferenças horizontais de temperatura na atmosfera e, assim, favorecendo a gênese de baixas polares nessas áreas (Rasmussen e Turner, 2003).

Taljaard (1972 apud Carpenedo, 2012) cita que a importância do gelo marinho na formação de massas de ar nas altas latitudes do hemisfério sul inclui sua retração e expansão. No verão, quando a extensão atinge sua mínima, a massa de ar formada

sobre o oceano, entre a convergência subtropical e a borda do gelo marinho é chamada de marítima polar. No entanto, no inverno, é formada uma massa de ar mais fria, a marítima antártica. Apenas a massa de ar marítima polar afeta diretamente o clima da América do Sul, ao ponto que a massa marítima antártica afeta diretamente o continente Antártico.

2.3 REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNAs) são modelos matemáticos computacionais que possuem a capacidade de aprendizagem de padrões, buscando reproduzir o que ocorre em neurônios biológicos. Elas são capazes de reconhecer e replicar padrões através de um treinamento baseado em uma amostra de dados pré-determinada. Sua capacidade de aproximação em relações funcionais, quando as mesmas não são lineares, é sua principal vantagem em relação aos métodos estatísticos mais convencionais. As RNAs são utilizadas para resolver diversos tipos de problemas, entre eles, o comportamento de fenômenos climáticos e meteorológicos, como a variação do gelo marinho, que apresenta alto nível de não-linearidade (Milléo, 2020).

Para melhor entendimento do funcionamento de uma RNA, é necessário entender o funcionamento de um neurônio biológico (figura 7), que possui a função de conduzir impulsos e produzir ações apropriadas de acordo com cada uma delas, memorizando as ações e repetindo-as. Ele é dividido em três partes principais: os dendritos, o corpo celular e o axônio. A principal função do dendrito é captar as informações advindas de outros neurônios (conectores) ou do meio externo em contato. O corpo celular é responsável por processar as informações vindas dos dendritos, com o objetivo de produzir um potencial de ativação, que indica se o sinal poderá seguir adiante ou não ao longo do axônio, que conduz os impulsos para outros neurônios conectores. A terminação do axônio é formada por ramificações denominadas terminações sinápticas (Silva *et al*; 2010).




Figura 7: Representação de um neurônio biológico. Fonte: extraído e adaptado de <http://cs231n.github.io/neural-networks-1/>

Os neurônios artificiais são representações dos neurônios biológicos. Sua função é analisar os dados (sinais captados pelos dendritos) de entrada e a partir de pesos sinápticos e de uma função de ativação (corpo celular), gerar os dados de saída (axônio). Os pesos sinápticos na função das RNAs servem para ponderação das variáveis de entrada, um viés (*bias*) pode ser utilizado para aumentar os graus de liberdade e para o ajuste dos pesos sinápticos (figura 8).




Figura 8: Esquema simples de uma rede neural artificial. Fonte: Autor, 2021

Na figura 8 os sinais de entrada x_1 , x_2 e x_3 , equivalentes aos impulsos captados pelos dendritos no neurônio biológico, são os sinais ou medidas advindas do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica. Já os valores dos pesos w_1 , w_2 e w_3 são utilizados para ponderação das variáveis (sinais) de entrada da rede, permitindo quantificá-las em

relação à funcionalidade do respectivo neurônio. O viés (*bias*) auxilia no ajuste dos pesos e aumenta o número de graus de liberdade. O combinador linear (Σ) possui a função de agregar todos os sinais de entrada já ponderados pelos pesos sinápticos, com a finalidade de produzir um valor potencial de ativação. A função de ativação (f) produz então a saída do neurônio, para então ser gerado um sinal de saída (y) que consiste no valor final produzido pelo neurônio, que pode ser um novo sinal de entrada para novos neurônios sequencialmente interligados (Silva *et al.*, 2010).

A equação 1 sintetiza o processo percorrido no neurônio artificial:

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (1)$$

sendo y , o sinal de saída, f , a função de ativação linear, w_i , o peso sináptico, b , o viés (*bias*) e x_i , o dado de entrada.

A rede é submetida a um processo de aprendizagem que ocorre durante o treinamento, que pode ser classificado de duas formas: supervisionado e não-supervisionado. No treinamento supervisionado, são apresentados para a rede os valores de entrada e de saída, de forma que os pesos sinápticos são ajustados pelo algoritmo de aprendizagem já definido, até que se chegue a uma reprodução do valor conhecido. Já para o treinamento não-supervisionado, não são apresentados dados de saída, fazendo com que a rede modifique os pesos de forma a identificar subconjuntos, também conhecidos como clusters, que possuam similaridades. A competição entre os dados de entrada da rede são a base de aprendizado nesse caso.

Existem diferentes tipos de estruturas de RNAs que podem ser empregados de acordo com o objetivo do trabalho a ser desenvolvido. Suas estruturas podem ser simples ou com mais de uma camada, onde podem existir camadas ocultas. Nas estruturas simples apenas uma camada de entrada e uma de saída são conectadas. Já em problemas mais complexos, sinais das camadas de saída podem se propagar como novos sinais de entrada, formando camadas que são realimentadas e propagam as sinapses para outra camada. As RNAs em que a alimentação dos neurônios com os sinais de entrada é enviada sempre adiante, para as próximas camadas de neurônio, são conhecidas como *feedforward*, já quando as saídas são realimentadas como sinais de entrada para outros neurônios, são conhecidas como recorrentes ou *backward*.

Algumas das estruturas de RNA são: Perceptron de camada simples, que possui alimentação *feedforward* e treinamento baseado na regra de Hebb; Perceptron multicamadas, também com alimentação *feedforward* de multicamadas, com método de treinamento baseado na regra delta generalizada; Redes de função de base radial (RBF), que possuem alimentação *feedforward* de multicamadas, com regra de aprendizado por competição combinada com a regra delta; Redes de contra propagação, com arquitetura *feedforward* de multicamadas, método de treinamento competitivo e arranjo de Grossberg.

Para a proposta deste trabalho, será utilizada a estrutura da rede de função de base radial (RBF), que será apresentada detalhadamente a seguir.

2.4 REDES DE FUNÇÃO DE BASE RADIAL

As redes denominadas como de funções de base radial (RBF) podem ser empregadas em diversos tipos de problemas, incluindo aqueles que envolvem aproximação de funções e classificação de padrões, sendo uma rede multicamada do tipo *feedforward*, onde as informações são transmitidas apenas em um sentido, sem realimentação. A rede possui 3 camadas: uma de entrada, uma oculta e uma de saída. Esse tipo de rede é funcional para solução de problemas não-lineares, como a previsão da extensão do gelo.




Figura 9: Estrutura de uma rede RBF. Fonte: Adaptado de Silva *et al.* (2010 apud Milléo, 2020)

Observando a figura 9 vemos que a propagação da rede se inicia na camada de entrada X , percorre a camada oculta Y (intermediária), onde passa pelas funções de ativação (funções de base radial), finalizando na camada neural de saída Z (função de ativação linear).

Para a rede RBF, o treinamento ocorre em dois estágios distintos. O primeiro, não-supervisionado, está associado ao ajuste dos pesos dos neurônios da camada intermediária W_{ij} . Já o segundo, supervisionado, é vinculado ao ajuste de pesos da camada de saída W_{jk} .

Tendo sido definido o número de neurônios, também se definirá o número de clusters. No primeiro estágio são realizados os ajustes dos pesos dos neurônios da camada intermediária, onde são empregadas funções de bases radiais, sendo que a função gaussiana é frequentemente utilizada nessa etapa. A expressão que define tal função está descrita a seguir:

$$g(u) = \frac{-(u-c)^2}{2\sigma^2} \quad (2)$$

onde c é o centro da função gaussiana e σ^2 é a variância da função, sendo σ o desvio padrão, e que indica o quão disperso está o potencial de ativação u em relação ao

centro (Silva *et al*; 2018). Vale ressaltar que a rede RBF é projetada para realizar um mapeamento não linear do espaço de entrada para o espaço oculto (camada intermediária), seguido de um mapeamento linear do espaço oculto para o espaço de saída (resultado esperado).

A figura 10 representa uma função gaussiana em seu formato geométrico dentro de um gráfico.




Figura 10: Gráfico de uma função Gaussiana. Fonte: Centro Brasileiro de Pesquisas Físicas (CBPF), 2003.

Os parâmetros livres a serem ajustados em uma função gaussiana são a posição do centro e o desvio padrão σ . Quanto maior o desvio padrão, mais larga será a base da função gaussiana. A posição do centro está diretamente ligada aos pesos do primeiro estágio de treinamento (camada oculta) e a entrada u_j^i é o próprio vetor de entrada X . A saída de cada neurônio j da camada oculta é expressa pela equação 3.

$$g_j^{(1)}(u_j^{(1)}) = \exp \frac{-\sum_{i=1}^p (x_i - w_{ij}^{(1)})^2}{2\sigma_j^2} \quad (3)$$

onde $j = 1, \dots, p$.

Quanto mais próximo do centro estiver o valor da amostra, maior será a significância do valor produzido pela função de ativação, que tenderá sempre para 1.

Nessa condição, o neurônio passará a produzir respostas similares a todos os padrões que estiverem localizados a uma distância radial igual do centro.

Os pesos sinápticos são os valores dos centros inicializados escolhidos aleatoriamente do arquivo de treinamento. No primeiro estágio de treinamento, calculam-se as distâncias Euclidianas entre o vetor de entrada e cada um dos centros. Aquele que apresentar a menor distância é considerado como “neurônio vencedor”, sendo o vetor selecionado incluído ao conjunto de amostras deste neurônio. Depois da classificação de todos os vetores, as posições dos centros são ajustadas levando-se em conta todas as amostras contidas nos conjuntos. Os ajustes dos centros são repetidos de forma iterativa, até que as posições dos centros entre as iterações estejam abaixo de um valor pré-definido que deve ser o mais próximo de zero, a ponto de garantir uma possível estagnação do processo de ajustes, este valor é definido arbitrariamente, testando diferentes valores até que se obtenha um resultado satisfatório. O número de iterações dentro do algoritmo de treinamento é definido como número de épocas.

Temos então, que o objetivo da camada oculta na estrutura da RBF é posicionar os centros de suas gaussianas da melhor maneira. Essas posições corresponderão às posições dos centros dos clusters. A segunda etapa do treinamento consiste no ajuste dos pesos da camada de saída, que deve ser executada após a finalização do primeiro estágio. Nesta etapa, o treinamento passa a ser supervisionado, quando são apresentados os vetores de entrada e de saída (resultados esperados), sendo as entradas, os vetores resultantes da função de ativação gaussiana utilizada na camada oculta (intermediária), seguindo então a seguinte função dada pela equação 4.

$$u_k^{(2)} = \sum_{j=1}^p W_{jk}^{(2)} \times g_j^{(1)}(u_j^{(1)}) - \theta_k \quad (4)$$

onde $W_{jk}^{(2)}$ e θ_k são, respectivamente, os pesos e os limiares de ativação relacionados à camada de saída do neurônio j da camada intermediária. Utilizando então, a função linear como ativação da camada de saída da RBF, as respostas produzidas pelos neurônios de saída passarão a ser resultados da função (equação 5):

$$y_k = g_k^{(2)}(u_k^{(2)}) \quad (5)$$

O valor do parâmetro k é igual ao número de neurônios existentes na camada oculta, já que a função de cada um deles é gaussiana conforme a equação 2, sendo os centros de cada uma delas representadas pelos respectivos vetores de peso.

2.5 ALGORITMOS DA REDE RBF

Para o primeiro estágio de treinamento da rede RBF, a sequência de passos a se fazer computacionalmente é descrita no quadro 1.

Quadro 1: Algoritmo da primeira etapa de treinamento da rede RBF. Fonte: (Silva *et al.*, 2010).

Passo 0: Definir o vetor de entrada para o treinamento.

Passo 1: Inserir os valores, selecionados de forma aleatória, de treinamento da camada intermediária $W_{ji}^{(1)}$.

Passo 2: Repetir os passos 3 a 7:

Passo 3: Para todas as amostras de treinamento, serão feitos os passos 4 e 5:

Passo 4: Calcular as distâncias euclidianas entre os vetores de entrada e o vetor da camada oculta ($W_{ij}^{(1)}$).

Passo 5: Selecionar o neurônio que apresenta a menor distância, para o agrupamento do vetor de entrada ao centro mais próximo.

Passo 6: Para todos os vetores de peso da camada oculta, realizar o passo 7.

Passo 7: Ajustar o vetor $W_{ij}^{(1)}$ da camada oculta para o valor médio de todos os vetores que pertencem ao conjunto.

Repetir os passos 4 a 7 até que o posicionamento dos clusters na camada oculta seja suficientemente pequena (inferior ao limite pré-estabelecido).

Passo 8: Para todos os valores do vetor da camada oculta, calcular a variância de cada uma das funções de ativação gaussianas.

Após a finalização do primeiro estágio do treinamento, a segunda etapa do treinamento consiste em ajustar os pesos sinápticos da camada de saída, para obtenção dos resultados da rede. A sequência de passos computacionais para esse estágio é apresentada no quadro 2 a seguir:

Quadro 2: Algoritmo da segunda etapa do treinamento da rede RBF. Fonte: Adaptado de Silva *et al.*, 2010).

Passo 0: Inserir os dados originais de entrada para o treinamento.

Passo 1: Inserir o vetor de saída, que é o valor conhecido ($d^{(k)}$) desejado para cada amostra (resultado esperado).

Passo 2: Iniciar o vetor de pesos dos neurônios da camada de saída ($W_{jk}^{(2)}$) com valores aleatórios.

Passo 3: Indicar a taxa de aprendizagem do treinamento e o erro máximo (ou precisão) requeridos.

Passo 4: Para todas as amostras, repetir o passo 5.

Passo 5: Obter os valores dos neurônios em relação ao vetor de entrada, utilizando a equação 3.

Passo 6: Iniciar o contador de épocas (iterações):

Passo 7: Repetir os passos 8 a 10.

Passo 8: O erro quadrático médio (E_m) será igual ao erro médio quadrático anterior (E_m^a).

Passo 9: Ajustar os pesos da camada de saída ($W_{jk}^{(2)}$) e o limiar (θ_j) para todos os pares de treinamento.

Passo 10: O erro médio quadrático obtido na época atual é igual a (E_m^{atual}).

Repetir até que o erro médio quadrático atual – o erro médio quadrático anterior ($E_m^{atual} - E_m^a$) seja menor que a precisão indicada.

O número de épocas pode ser um critério de parada quando a precisão indicada se torna inalcançável pelo treinamento. Após a finalização das etapas de treinamento das camadas, a rede deverá estar pronta para estimar as saídas do processo que foi mapeado, contando agora, com as novas amostras a serem apresentadas em suas entradas. A sequência de passos computacionais está descrita no quadro 3 a seguir.

Quadro 3: Estágio de operação da rede RBF. Fonte: Adaptado de Silva *et al.*, 2010.

Passo 0: Inserir uma amostra $\{x\}$.

Passo 1: Assumir os parâmetros (pesos das camadas oculta e de saída, variância e limiar de ativação) ajustados no treinamento.

Passo 2: Executar os passos 3 a 5.

Passo 3: Obter $g_j^{(1)}$, conforme a equação 3.

Passo 4: Obter $u_k^{(2)}$, conforme a equação 4.

Passo 5: Obter y_k , conforme a equação 5.

Passo 6: Apresentar as saídas da rede mediante os valores contidos em y_k .

2.6 SELEÇÃO DE VARIÁVEIS

Modelos de previsão como as utilizadas nas RNAs exigem variáveis de entrada preditoras que sejam relevantes à problemática a ser avaliada. O número de preditores possíveis para um mesmo modelo pode ser incontável, e, portanto, deve-se selecionar aqueles que possuem maior correlação entre si e entre os dados de saída esperados. Um menor número de variáveis que contenham um maior número de informações para os padrões que se buscam prever seria o ideal. A seleção evita que sejam selecionadas muitas variáveis que refletem as mesmas informações, tornando-se redundantes e simultaneamente diminui o tempo de processamento computacional do modelo.

Com o objetivo de selecionar as melhores variáveis de entrada para os modelos, foram criados alguns métodos de seleção de variáveis, como o *stepwise* que adiciona (passo *forward*) ou remove (passo *backward*) variáveis a partir de um critério de seleção estatístico.

2.6.1 Regressão *Stepwise*

Baseando-se na regressão *stepwise*, a seleção definitiva das variáveis preditoras deste estudo utilizou o passo *forward*, onde uma variável x^i deveria ser

escolhida para avaliar sua importância no modelo de previsão, utilizando-se de algum método estatístico. Em seguida, outra variável x^i é adicionada e avaliada. Quando o resultado do teste desta variável é melhor do que o resultado do teste da variável x^i anterior, ela é mantida para o modelo e, quando ocorre o inverso, deve ser excluída. A avaliação deverá ser repetida até que todas as possíveis variáveis de entrada sejam analisadas (Wilks, 2011).

O treinamento de uma rede RBF pode ser baseado no critério da menor Raiz do Erro Quadrático Médio (REQM), com o objetivo de selecionar o vetor de entrada que tenha o potencial de maximizar o desempenho do modelo de previsão. O treinamento segue adicionando-se novos vetores, um a um, avaliando o desempenho da rede para cada um deles.

Para o passo *backward* o mesmo método de avaliação é utilizado. No entanto, ao invés de adicionar as variáveis uma a uma, o processo se inicia com todas as preditoras possíveis para então removê-las de forma sucessiva, este passo não será adotado no método de seleção proposto para este estudo.

3 METODOLOGIA

Neste tópico serão apresentadas a metodologia de revisão dos estudos, definições da área de estudo, as bases de dados climatológicos e de gelo utilizadas, a pré-seleção das variáveis preditoras para os modelos de previsão, a metodologia empregada na análise inicial destas variáveis e da concentração, área e extensão do gelo marinho nas regiões do Estreito de Drake, Península Antártica e Setor Antártico Sul-Americano. Por fim, serão apresentadas as etapas de desenvolvimento do modelo de previsão e os métodos de avaliação de desempenho.

3.1 REVISÃO SISTEMÁTICA

Com o objetivo de se encontrar e pré-selecionar variáveis atmosféricas, foram utilizadas algumas técnicas do processo ProKnow-C de revisão sistemática. Afonso *et al.* (2012), descrevem o processo de seleção bibliográfica e de análise bibliométrica que podem ser aplicados na fase introdutória de um estudo.

O primeiro passo foi a definição das palavras-chave utilizadas para as pesquisas nas bases de dados selecionadas, foram elas: *Antarctica*, *Sea Ice*, *Numerical Models*, *variability* e *Artificial Neural Networks*. As bases de dados utilizadas foram o Scopus, Springer Link, Science Direct e Google Scholar.

Após pesquisar diferentes combinações das palavras-chave, foram filtrados artigos que possuíam alinhamento com o tema através do título e, posteriormente, do resumo, excluindo artigos com pouca relevância para o estudo. Após isso, os artigos foram classificados de acordo com métricas bibliométricas como a atualidade (ano de publicação), número de citações dos autores e os índices JCR (*Journal Citation Indicator*) e In Ordinatío. Dos 31 artigos pré-selecionados, 21 deles foram selecionados após a avaliação da adequação de seu conteúdo ao tema proposto pelo presente trabalho.

Mesmo com a revisão sistemática, não foram encontrados trabalhos prévios que utilizassem especificamente as RNAs como ferramentas para a previsão do gelo marinho na Antártica. Portanto, os trabalhos selecionados foram aqueles que apresentaram outros tipos de estudos numéricos sobre a variabilidade do gelo marinho e as relações entre as variáveis atmosféricas e a variação do gelo marinho no continente Antártico.

3.2 ÁREA DE ESTUDO E BASES DE DADOS

A área de estudo definida para o presente trabalho está localizada entre as longitudes 30° e 100° W, ao sul da latitude 40° S (figura 11). A base de dados climatológicos utilizada para a análise da influência dos fenômenos atmosféricos sobre a variabilidade do gelo marinho foi a ERA5 (*European Reanalysis*), produzido pelo *European Centre for Medium-Range Weather Forecasts* (ECMWF). O ECMWF é um centro de pesquisa e serviço operacional que produz e dissemina previsões meteorológicas numéricas para seus Estados-Membros (ECMWF, 2021).




Figura 11: Área de estudo do presente trabalho está representada pela região hachurada em vermelho. Fonte: Autor, 2022.

O ECMWF produz análises e previsões baseadas em conjuntos operacionais que descrevem a gama de cenários possíveis e sua probabilidade de ocorrência. As previsões do ECMWF cobrem períodos de tempo que variam de médio prazo a mensal e sazonal. O ECMWF usa periodicamente seus modelos de previsão e sistemas de assimilação de dados para reanalisar as observações arquivadas, criando conjuntos de dados globais que descrevem a história recente da atmosfera, superfície terrestre e oceanos. Uma reanálise do clima fornece uma descrição numérica do clima recente,

produzida pela combinação de modelos com observações. Ele contém estimativas de parâmetros atmosféricos, como temperatura do ar, pressão e vento em diferentes altitudes, e parâmetros de superfície, como precipitação, teor de umidade do solo, altura das ondas do oceano e temperatura da superfície do mar. A mais recente reanálise do ECMWF é a ERA5 (ECMWF, 2021). Os dados de reanálise do ECMWF estão disponíveis gratuitamente através do endereço eletrônico <https://www.ecmwf.int/en/forecasts/datasets/browse-reanalysis-datasets>.

A ERA5 fornece estimativas com resolução temporal de seis horas e seus dados cobrem a Terra em uma grade de, aproximadamente, 30 km de resolução horizontal, e 37 níveis da superfície até uma altura de 80 km. Em seu catálogo é possível encontrar os dados distribuídos em camada única ou em 37 níveis de pressão, que englobam 16 variáveis atmosféricas, tais como a cobertura de nuvens, umidade relativa, umidade específica, temperatura, componentes u e v do vento e velocidade vertical. Para o presente estudo, serão considerados os dados mensais da ERA5 de janeiro de 1979 a dezembro de 2020 (504 meses), em uma resolução espacial horizontal de 0, 25° x 0, 25°.

Para a concentração do gelo marinho foram utilizados dados disponíveis do *Sea Ice Concentrations from Nimbus-7 SMMR and DMSP SSM/I SSMIS Passive Microwave Data, Version 1*. Este conjunto de dados está disponível no *National Snow and Ice Data Center* (NSIDC), que gerencia e distribui dados científicos e realiza pesquisas científicas sobre a criosfera. Este conjunto de dados é gerado a partir de dados de temperatura de brilho derivados dos seguintes sensores: Radiômetro de micro-ondas multicanal de varredura Nimbus-7 (SMMR), Programa de satélite meteorológico de defesa (DMSP) F8, F11 e Sensor F13 de microondas/imageadores especiais (SSM/Is) e o gerador de imagens/sonorizadores com sensor especial de micro-ondas DMSP-F17 (SSMIS). Os dados são fornecidos na projeção estereográfica polar em um tamanho de célula de grade de 25 x 25 km. Os dados são gerados usando o algoritmo *NASA Team* desenvolvido pela *Oceans and Ice Branch, Laboratory for Hydrospheric Processes no Goddard Space Flight Center (GSFC)* da NASA, que possui dados desde 26 de outubro de 1978. A partir dos dados de concentração foram calculados os valores de extensão e área do gelo marinho, como definidos no subitem 2.2, considerando concentrações iguais ou superiores a 15% (Cavalieri *et al.*, 1996).

Para os dados de gelo marinho, as áreas consideradas para o estudo são as da Península Antártica, que fica entre as latitudes 60 a 65° S e longitudes 52° a 68° W, do Estreito de Drake, que fica entre as latitudes 55° a 63° S e longitudes 57° a 65° W e do Setor Antártico Sul-Americano, com os limites de latitude de 40° S até a costa Antártica e de longitude de 30° a 100° W.

A partir dos valores diários de concentração foram calculados os valores mensais, e a partir desses, as extensões e áreas mensais, de janeiro de 1979 a dezembro de 2020 (504 meses) para a análise de tendências mensais e sazonais. Os dados de gelo marinho estão disponíveis gratuitamente através do endereço eletrônico <https://nsidc.org/data/NSIDC-0051/versions/1>.

3.3 PRÉ-SELEÇÃO DE PREDITORES

Baseado no estudo climatológico apresentado na seção 2.1, alguns fenômenos atmosféricos foram pré-selecionados, levando em consideração suas influências sobre a variabilidade do gelo marinho no setor Antártico Sul-Americano. As localizações dos sistemas climatológicos considerados como relevantes são mostradas na figura 12. Na tabela 1 estão descritos tais fenômenos, que formam um conjunto de possíveis variáveis preditoras para os modelos de previsão que serão desenvolvidos. Essas variáveis são consideradas como possíveis (ou candidatas) a preditores pois passaram por uma seleção posterior, por meio do método *stepwise*, descrito no subitem 2.6.




Figura 12: Localização de ocorrência dos fenômenos atmosféricos que são possíveis influenciadores da variação do gelo marinho no setor Antártico Sul-Americano. Fonte: Autor, 2021. Na figura tem-se: EL NIÑO 3.4 Região que ocorre o El Niño; SAM/CCA MB Modo Anular Sul e Corrente Circumpolar Antártica no Mar de Bellingshausen; **SAM/CCA MW** Modo Anular Sul e Corrente Circumpolar Antártica no Mar de Weddell; **DARWIN e TAHITI** diferença de pressão atmosférica nas duas regiões; **Jato Subtropical e Jato Polar** correntes de jato.

Tabela 1: Localização das possíveis variáveis preditoras para previsão de gelo marinho no setor Antártico Sul-Americano.

Regiões	Coordenadas		Variáveis	Códigos
	Latitude	Longitude		
El Niño 3.4	05° N – 05° S	120° - 170° W	temperatura da superfície do mar	elnino34sst
	60° - 75° S	30° - 60° W	pressão ao nível do mar	cent_p_w
	60° - 80° S	30° - 60° W	precipitação	prec_w
	60° - 85° S	30° - 60° W	temperatura do ar à 2m	t2m_w
Mar de Weddell	60° - 70° S	30° - 60° W	temperatura da superfície do mar	sst_w
	60° - 75° S	60° – 100° W	pressão ao nível do mar	cent_p_b
	60° - 80° S	60° – 100° W	precipitação	prec_b
	60° - 85° S	60° – 100° W	temperatura do ar à 2m	t2m_b
Mar de Bellingshausen	60° - 70° S	60° – 100° W	temperatura da superfície do mar	sst_b
	60° - 70° S	100° - 160° W	pressão ao nível do mar	sam_a
Modo Anular Sul ou oscilação antártica	55° - 70° S	30° - 60° W	velocidade da componente v à 10m em Weddell	aao_w
	55° - 70° S	60° – 100° W	velocidade da componente v à 10m em Bellingshausen	aao_b
Jato subtropical	25° - 35° S	90° - 150° W	velocidade da componente u à 200 hPa	jst_p
Jato polar	45° - 55° S	90° - 150° W	velocidade da componente u à 200 hPa	jpol_p
Corrente Circumpolar Antártica	60° - 70° S	30° - 60° W	velocidade da componente u no mar de Weddell	acc_w
	60° - 70° S	60° - 100° W	velocidade da componente u no mar de Bellingshausen	acc_b
Darwin	12,45° S	130,84° E	pressão ao nível do mar	sfc_p_en_d
Tahiti	17,6° S	149,45° W	pressão ao nível do mar	sfc_p_en_t
Estreito de Drake	55° - 65° S	60° W	extensão do gelo no estreito de Drake	ext_drk
Península Antártica	65° - 80° S	60° W	extensão do gelo na península	ext_p
Setor Antártico Sul-Americano	40° - 90° S	30° - 100° W	extensão do gelo no SSA	ext_sa

3.4 ANÁLISES EXPLORATÓRIAS PRELIMINARES

Com o intuito de compreender melhor os objetos de entrada deste estudo, as médias climatológicas, as anomalias e a evolução temporal dos fenômenos climatológicos e atmosféricos serão apresentadas graficamente, assim como as médias e evoluções temporais para os dados de gelo marinho.

Foram calculadas médias climatológicas mensais para um período de 41 anos, iniciando em janeiro de 1979 até dezembro de 2020. As médias climatológicas para a temperatura na superfície do mar (TSM) (figs. 13 e 14) e precipitação total (soma de chuva e neve) (figs. 15 e 16) nos mares de Bellingshausen e Weddell, respectivamente, são apresentadas a seguir.




Figura 13: Médias climatológicas de temperatura na superfície do mar de Bellingshausen.

Na figura 13 é possível notar que as temperaturas médias na superfície do mar em Bellingshausen ficam mais baixas nos meses de junho a setembro, quando as médias ficam abaixo de -4°C . Em contrapartida, nos meses de dezembro a março, as médias ficam acima de 0°C .




Figura 14: Médias climatológicas de temperatura na superfície do mar de Weddell.

Na figura 14 é possível observar que o comportamento das médias climatológicas no mar de Weddell é mais intensa se comparada ao de Bellingshausen, com uma significativa diferença nas temperaturas, que ficam abaixo de $-14\text{ }^{\circ}\text{C}$ nos meses de junho a agosto e acima de $-2\text{ }^{\circ}\text{C}$ nos meses de dezembro a fevereiro, apresentando maior amplitude térmica durante o ano. Tal comportamento indica que há maior possibilidade de formação de gelo marinho e durante um maior período de tempo no mar de Weddell do que em Bellingshausen.

Na figura 15 nota-se a variação das médias de precipitação total no mar de Bellingshausen, sendo os meses de novembro e dezembro os que possuem as menores taxas de precipitação, ficando abaixo de $1,5\text{ mm/dia}$.




Figura 15: Médias climatológicas de precipitação total na região do mar de Bellingshausen.

Na figura 16 observa-se que há menor variação das médias de precipitação, além do clima mais seco durante o ano no mar de Weddell que em Bellingshausen, apresentando maiores valores para os meses de janeiro a março, onde ficam acima de 1,2 mm/dia.




Figura 16: Médias climatológicas de precipitação total na região do mar de Weddell.

Os histogramas e as evoluções temporais das anomalias de temperatura na superfície do mar e de precipitação total nos mares de Bellingshausen e Weddell, para o mesmo período são apresentados nas figuras a seguir.

Na figura 17 os valores de anomalias da temperatura da superfície do mar estão variando entre -4 e 4 °C. Percebe-se uma distribuição relativamente simétrica das anomalias em torno da média. No entanto, analisando em conjunto com o gráfico de evolução temporal percebe-se maior frequência das anomalias acima da média.




Figura 17: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da TSM do mar de Bellingshausen.

Na figura 18 os dados de anomalias da temperatura da superfície do mar de Weddell já apresentaram maior variação se comparado ao mar de Bellingshausen, com valores dentro do intervalo de -8 a 8 °C. Aqui também se nota uma distribuição mais simétrica das anomalias. A evolução temporal também apresentou maior variação na frequência, justificando também os valores mais baixos de TSM apresentados no gráfico das médias (figura 14).




Figura 18: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da TSM do mar de Weddell.

Na figura 19 os dados de anomalias da precipitação total na região de Bellingshausen mostram que a quantidade de anomalias próximas a 0 é consideravelmente mais alto do que a quantidade de anomalias próximas a 1 e -1 mm/dia. A evolução temporal também apresentou dados com uma alta frequência, dificultando a identificação de padrões.




Figura 19: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Precipitação Total na região do mar de Bellingshausen.

Na figura 20 as anomalias da precipitação total em Weddell concentraram-se entre -0,25 e 0,25 mm/dia, apresentando assimetria em sua distribuição. A evolução temporal, por sua vez, já se apresenta com menor frequência e com valores majoritariamente positivos. A diferença de frequência entre as anomalias de precipitação nos mares de Bellingshausen e Weddell complementam a análise feita entre as médias de precipitação nas duas regiões (figuras 15 e 16).




Figura 20: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Precipitação Total na região do mar de Weddell.

Com os dados de gelo marinho obtidos pelo NSIDC foram elaborados gráficos de médias e evolução temporal da extensão, área e concentração de gelo marinho em três regiões, a saber: setor Antártico Sul-Americano, o Estreito de Drake e a Península Antártica. Os gráficos de concentração (fig. 21), extensão (fig. 22) e área (fig. 23) para todo o setor Antártico Sul-Americano serão apresentados e analisados a seguir.




Figura 21: Médias (painel superior) e evolução temporal (painel inferior) da concentração de gelo marinho no setor Antártico Sul-Americano.

Na figura 21 observa-se que o comportamento da concentração de gelo durante o ano é mais intenso no inverno (maio a agosto) e menos intenso no verão (dezembro a março), mas com pouca variação, sempre apresentando concentrações

entre 70% e 80%. O gráfico de evolução temporal possui alta frequência, apresentando predominância de valores abaixo da média até o ano 2000, quando a intensidade da frequência diminui até 2020, já que um padrão de tendências fica mais evidente.

Na figura 22 é possível notar que as médias da extensão de gelo marinho possuem maior variabilidade se comparadas à concentração, atingindo sua máxima em agosto e a mínima em fevereiro, com uma amplitude de quase $2 \times 10^6 \text{ km}^2$ entre eles. Com significativa frequência, o gráfico de evolução temporal apresentou uma ligeira tendência de queda das anomalias da extensão do gelo marinho ao longo dos anos, com notável redução no valor a partir do ano 2000.




Figura 22: Médias (painel superior) e evolução temporal (painel inferior) da extensão de gelo marinho no setor Antártico Sul-Americano.

Na figura 23 nota-se que o comportamento da área do gelo segue uma tendência similar ao da extensão, com a amplitude entre as médias máximas e mínimas de aproximadamente $1 \times 10^6 \text{ km}^2$. A evolução temporal também possui alta frequência, com destaque para a tendência das anomalias que foi positiva entre os anos de 2010 e 2015, e que no período de 2015 a 2020 teve uma predominância de valores negativos.




Figura 23: Médias e evolução temporal da área de gelo marinho no setor Antártico Sul-Americano.

Os demais gráficos das médias, histogramas e evoluções temporais das variáveis atmosféricas, assim como os gráficos das médias e evoluções temporais dos dados de gelo marinho do Estreito de Drake e da Península Antártica são apresentados e comentados no Apêndice A.

As estatísticas de média, mediana, desvio padrão, covariância, valores máximos e mínimos, calculadas a partir dos dados das variáveis pré-selecionadas da ERA5 são apresentadas no Apêndice B.

3.5 DESENVOLVIMENTO DO MODELO

A partir das variáveis pré-selecionadas consideradas significativas para a construção do modelo foram necessárias algumas etapas para a seleção definitiva das variáveis de entrada. A primeira delas foi definir, de forma arbitrária, o atraso (horizonte de previsão) em meses para calcular a correlação cruzada entre as variáveis. Com isso, foram realizadas análises dessas correlações com atrasos de até 48 meses. Após a análise, foi observado que as correlações mais significativas (acima de 20%) ocorreram apenas para atrasos de até 3 meses, sendo definido 1, 2 e 3 meses como horizontes de previsão para o desenvolvimento dos modelos. Foi possível perceber também, que os valores de anomalias da extensão do gelo marinho de cada região possuem alta correlação com as anomalias da área, na tabela 2 são apresentadas as correlações calculadas entre elas.

Tabela 2: Correlações entre a área e extensão do gelo marinho nas regiões do Estreito de Drake, Península Antártica e Setor Antártico Sul-Americano.

Correlação entre Área e Extensão		
Estreito de Drake	Península Antártica	Setor Antártico Sul-Americano
0.96	0.96	0.94

Devido à alta correlação entre a área e a extensão do gelo marinho, foi definido que, para o modelo de previsão serão utilizados somente os dados da extensão.

Selecionados os possíveis preditores e identificados os meses que possuem as maiores correlações com as variáveis de entrada, foi aplicado o método de regressão *stepwise*, para a seleção final de preditores, reduzindo a quantidade de vetores de entrada, mantendo apenas os que possuem maior relevância para a previsão e que maximizam o desempenho do modelo. A próxima etapa da seleção

consistiu no treinamento do modelo de RNA, baseando-se no critério da menor Raiz do Erro Quadrático Médio (REQM), obtido da comparação entre os valores de extensão do gelo marinho observados e modelados. As variáveis são adicionadas uma a uma, avaliando-se o desempenho, até a última variável do conjunto de preditores possíveis. O método foi aplicado de forma automática, através de um programa desenvolvido na linguagem Fortran.

A tabela 3 apresenta todas as variáveis que se enquadraram dentro do limite de 30% de correlação cruzada, para 1, 2 e 3 meses de horizonte de previsão para a extensão do gelo no Setor Antártico Sul-Americano, exemplificando a diferença existente entre a quantidade de preditores para cada configuração do experimento.

Tabela 3: Variáveis candidatas a preditoras de acordo com o limite pré-definido em 30% sobre a correlação cruzada entre as variáveis e a extensão do gelo marinho no Setor Antártico Sul-Americano, com horizonte de previsão (atraso) de 1,2 e 3 meses.

Atraso (meses) x possíveis variáveis preditoras										
1	ext_sa	sam_a	t2m_w	aao_w	aao_b	sst_w	jpol_p	sst_b	cent_p_b	elnin
2	ext_sa	elnin	prec_b	t2m_w	aao_b	sst_b	sst_w			
3	prec_b	elnin	aao_b	sst_b	sst_w	ext_sa				

3.6 ESTRUTURA DA RNA

O programa de Rede Neural Artificial de RBF foi escrito pelo Prof. Ricardo Carvalho de Almeida e é composto por dois códigos escritos em linguagem de programação Fortran, um para os subconjuntos de treinamento e outro para a operação da rede. Os dados de entrada da rede foram separados em subconjuntos de treinamento, teste e validação, subdivididos em 85%, 10% e 5%, respectivamente. O número de neurônios na camada de entrada variou de um até o número de possíveis preditores de cada experimento, já o número de neurônios na camada oculta foi determinado experimentalmente, utilizando 5, 10 e 15 neurônios para posterior avaliação dos resultados obtidos. No treinamento da RNA RBF foi aplicado uma taxa de aprendizagem de 0,0002, com limite de 35000 épocas. Os dados dos parâmetros de entrada foram normalizados no intervalo $[-1, +1]$, para que as diferenças entre as ordens de grandeza não prejudiquem o aprendizado da rede, considerando que os dados que possuem maior grandeza podem prejudicar a importância daqueles que possuem menor grandeza.

O valor do peso inicial no início de cada treinamento é definido de forma aleatória. Portanto, um modelo de RNA diferente é gerado para cada processo do treinamento, gerando diferentes resultados. Sabendo-se disso, os resultados foram selecionados com base no desempenho médio obtido pela repetição do processo de geração do modelo em 5 iterações no procedimento de validação cruzada.

Para o treinamento, o tempo de operação da máquina variou de acordo com o número de variáveis preditoras e o número de neurônios na camada oculta utilizados. Variando de 2 minutos até mais de 2 horas para o processamento.

Após finalizar o treinamento, foi executado o segundo programa para a operação da RNA. Nessa etapa foram utilizadas as variáveis selecionadas após o método de seleção anterior, utilizada na etapa de treinamento, indicando para a rede qual o número de neurônios a ser utilizado na camada oculta, sendo 5, 10 ou 15, baseando-se nos resultados obtidos do treinamento, além disso, foram selecionados 10% dos dados utilizados no treinamento, sendo sempre os últimos 51 meses para cada caso. O tempo de processamento para a operação já foi bem menor comparado ao do treinamento, variando de 10 a 30 segundos conforme o número de variáveis e número de neurônios utilizados na camada oculta. Os resultados da operação serão comparados através de análises estatísticas definidas no subitem 3.8.

3.7 PREVISÃO POR PERSISTÊNCIA

As variáveis atmosféricas frequentemente apresentam dependência estatística com seus próprios valores passados ou futuros. Wilks (2011) aponta que essa dependência é conhecida como persistência. A persistência pode ser definida como a existência de dependência estatística (positiva) entre valores sucessivos de uma mesma variável, ou entre ocorrências sucessivas de um determinado evento. Geralmente, a dependência estatística das variáveis meteorológicas no tempo é positiva.

Essa dependência estatística indica o fato de a atmosfera possuir memória, ou seja, quando as variáveis são medidas de forma consecutiva em curtos intervalos de tempo considera-se que possuem alta correlação, mesmo em escalas de tempo e espaço diferentes. Tais características levam esse método a ser considerado simples e sem habilidade. Pela baixa qualidade da previsão resultante, métodos mais elaborados como os propostos neste trabalho devem apresentar maior acurácia em

seus resultados, comparando-se à previsão por persistência. Ocorrendo o inverso será considerado que a metodologia proposta não terá qualidade o suficiente para ser considerada em suas aplicações.

3.8 ANÁLISE DE DESEMPENHO DAS PREVISÕES

Algumas métricas estatísticas foram utilizadas para a validação das previsões realizadas pelo treinamento e operação do modelo da RNA. Nas equações 6 a 9, y_o representa os dados observados, y_e representa os dados estimados, n o número total de dados, $\bar{y}_e$ a média entre os dados estimados e $\bar{y}_o$ a média entre os dados observados.

- O Erro Médio Absoluto (EMA) indica a diferença média entre o valor observado (y_o) e o valor estimado (y_e). Quanto maior a diferença média, maior é a incerteza sobre o resultado, ou seja, representa a baixa qualidade dos dados simulados. O EMA é definido pela equação 6:

$$EMA = \frac{1}{n} \sum_{i=1}^n |y_e - y_o| \quad (6)$$

- A Raiz do Erro Quadrático Médio (REQM) é um índice que mede a acurácia do resultado em relação ao observado. Quanto mais próximo de zero, maior é a qualidade dos dados estimados. O REQM é definido pela equação 7:

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_e - y_o)^2} \quad (7)$$

- A Correlação Linear de Pearson (CLP) define o grau de correlação linear existente entre duas variáveis variando no intervalo $[-1, +1]$, sendo que $CLP = 0$ indica que não há correlação, $CLP > 0$ indica correlação positiva e $CLP < 0$ indica que há correlação negativa. O valor da CLP é definido pela equação 8:

$$CLP = \frac{\sum_{i=1}^n (y_e - \bar{y}_e)(y_o - \bar{y}_o)}{\sqrt{\sum_{i=1}^n (y_e - \bar{y}^*)^2} \sqrt{\sum_{i=1}^n (y_o - \bar{y})^2}} \quad (8)$$

- O Coeficiente de Nash-Sutcliffe é um índice adimensional que varia no intervalo $[-\infty, +1]$. Quando $CNS = 0$, indica que os resultados das previsões do modelo possuem precisão igual à média dos dados observados, já o $CNS = 1$ indica uma combinação perfeita entre os dados estimados e observados e o $CNS < 0$ indica que a média observada é melhor do que o uso do modelo. O CNS é definido pela equação 9:

$$CNS = 1 - \frac{\sum_{i=1}^n (y_o - y_e)^2}{\sum_{i=1}^n (y_o - \bar{y})^2} \quad (9)$$

Os resultados dos modelos de previsão também foram avaliados graficamente, por meio de gráficos de dispersão, complementando a análise das métricas estatísticas.

4 RESULTADOS DOS EXPERIMENTOS DE PREVISÃO

4.1 AVALIAÇÃO DE DESEMPENHO DO TREINAMENTO DOS MODELOS

Assim como descrito no subitem 3.4, para melhor avaliar o desempenho dos modelos gerados, os resultados foram avaliados graficamente, de acordo com a curva de evolução da REQM gerada para cada experimento de treinamento do modelo na execução do método *stepwise* de seleção de variáveis, analisando o comportamento da curva e selecionando as variáveis que apresentam valores com tendência de queda até atingir o truncamento, a partir do qual se observa o crescimento da curva da REQM. Na figura 24 é possível observar um dos gráficos da evolução dessa curva em um experimento, notando que a partir da variável *prec_w* (precipitação total no mar de Weddell) no modelo de previsão, os erros passaram a aumentar com a inclusão de novos preditores. Os demais gráficos são apresentados no apêndice C.




Figura 24: Resultado da terceira repetição do método *stepwise*, para o limite de 20% da correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse, com horizonte de previsão de 1 mês e utilização de 15 neurônios na camada oculta no treinamento da RNA.

Nesse caso, as variáveis selecionadas são todas aquelas que antecedem a variável *prec_w*, já que, após esse ponto, a curva do erro começa a crescer, resultando em 6 preditores selecionados entre os 17 possíveis para o experimento. Para cada experimento houve 3 repetições, obtendo-se 3 curvas para cada um. Após selecionar todas as variáveis que se enquadram dentro dos critérios estabelecidos, foram analisadas as métricas estatísticas de validação, levando em consideração a média das 3 repetições feitas para cada uma delas. Os melhores resultados para cada

região podem ser observados nas tabelas 4 a 6, onde já estão definidos os melhores números de neurônios na camada oculta para cada experimento. Cada configuração do treinamento apresentou um comportamento diferente no resultado da curva da REQM, levando a diferentes seleções de variáveis para cada uma.

Tabela 4: Resultados da seleção *stepwise* para a região do Estreito de Drake.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	10	ext_drk, jpol_p	2.52E+04	0.60	1.61E+04	0.81
	2	5	prec_b, sam_a	2.41E+04	0.38	1.60E+04	0.65
	3	10	sst_b, prec_b	2.75E+04	0.16	1.68E+04	0.44
25	1	10	ext_drk, jpol_p, t2m_w, sst_b, sst_w	1.73E+04	0.64	1.07E+04	0.80
	2	15	prec_b, sst_b, sst_w, aao_b	2.59E+04	0.32	1.73E+04	0.59
	3	15	prec_b	2.50E+04	0.03	1.56E+04	0.29
30	1	5	ext_drk, sst_b, sam_a, sst_w, aao_b	2.50E+04	0.53	1.64E+04	0.75
	2	10	sst_b, prec_b	2.82E+04	0.27	1.81E+04	0.56

Tabela 5: Resultados da seleção *stepwise* para a região da Península Antártica.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	5	ext_p, sst_b, sst_w, prec_w	3.58E+04	0.71	2.59E+04	0.85
	2	15	prec_b, t2m_b	4.34E+04	0.49	3.23E+04	0.71
	3	10	prec_b, acc_w, sst_b	4.96E+04	0.14	3.46E+04	0.40
25	1	10	ext_p, prec_b, jpol_p, aao_w, sst_w, t2m_b	3.88E+04	0.66	2.74E+04	0.83
	2	10	sst_b, prec_b, acc_w, sst_w	6.17E+04	0.44	4.49E+04	0.70
	3	10	prec_b, sst_b	6.07E+04	0.15	4.15E+04	0.47
30	1	5	t2m_b, prec_b, jpol_p, sam_a, sst_b, cent_p_b	3.94E+04	0.67	2.92E+04	0.83
	2	5	prec_b, sst_b, aao_b	5.23E+04	0.37	3.72E+04	0.63
	3	15	prec_b	7.23E+04	0.10	5.06E+04	0.37

Observa-se dos resultados das tabelas 4 a 6, analisando principalmente os valores de CNS e CLP, que as previsões para até dois meses de antecedência possuem acurácia razoável. Estes resultados definiram as configurações utilizadas na operação da rede RBF para a previsão da extensão do gelo marinho, já que apresentaram os melhores desempenhos durante os experimentos de treinamento.

Tabela 6: Resultado da seleção *stepwise* para a região do Setor Antártico Sul-Americano.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	10	ext_sa, aao_b, prec_w, prec_b	1.17E+05	0.77	9.26E+04	0.88
	2	10	prec_b, sst_b, ext_sa, prec_w	1.59E+05	0.58	1.26E+05	0.77
	3	10	ext_sa, prec_b	1.97E+05	0.27	1.55E+05	0.54
25	1	5	ext_sa, aao_w, aao_b, prec_b, sst_w	1.48E+05	0.70	1.17E+05	0.84
	2	15	ext_sa, prec_b, prec_w	1.59E+05	0.64	1.29E+05	0.81
	3	10	elnin, sst_w, sst_b	2.10E+05	0.38	1.66E+05	0.63
30	1	10	ext_sa, aao_b, sst_w	1.40E+05	0.72	1.09E+05	0.86
	2	15	ext_sa, prec_b, t2m_w, elnin	1.82E+05	0.45	1.39E+05	0.67
	3	10	elnin, ext_sa, sst_b	2.05E+05	0.28	1.58E+05	0.55

As variáveis mais recorrentes dos resultados apresentados nas tabelas 4 a 6 foram a precipitação no Mar de Bellingshausen (prec_b), ocorrendo em 13 dos 26 resultados, seguido pela temperatura na superfície do mar em Bellingshausen (sst_b), ocorrendo em 11 dos 26 resultados, indicando que tais variáveis possuem maior relevância para a previsão. Analisando ainda a ocorrência de variáveis por setor, é possível afirmar que as variáveis relacionadas ao Mar de Bellingshausen ocorrem com maior frequência, aparecendo 31 vezes. Em contrapartida, as relacionadas ao Mar de Weddell aparecem 11 vezes.

4.2 PREVISÃO POR PERSISTÊNCIA

Para a previsão da extensão do gelo marinho por persistência, foram utilizados os mesmos dados da série histórica disponível no NSIDC, de janeiro de 1979 a dezembro de 2020. Na seção 3.6 está descrita a técnica de previsão por persistência, e, por consistir em um método mais simples, já que realiza a previsão de um dado em determinado instante com base no dado que o precede. Essa técnica também serve para avaliar a amplitude da variação de determinado fenômeno ao longo do tempo, se é alta (muito persistente) ou baixa (pouco persistente). Com base

nas métricas estatísticas descritas na seção 3.7, os resultados podem ser observados na tabela 7 a seguir.

Tabela 7: Resultados obtidos na avaliação da previsão por persistência.

Região	Horizonte de Previsão (Meses)	REQM	CNS	EMA	CLP
Estreito de Drake	1	2.78E+04	0.27	1.52E+04	0.63
	2	3.83E+04	-0.39	2.28E+04	0.31
	3	4.32E+04	-0.76	2.73E+04	0.12
Península Antártica	1	5.11E+04	0.34	3.50E+04	0.67
	2	6.99E+04	-0.23	5.04E+04	0.38
	3	7.77E+04	-0.52	5.77E+04	0.24
Setor Antártico Sul-Americano	1	1.74E+05	0.54	1.36E+05	0.77
	2	2.43E+05	0.12	1.92E+05	0.56
	3	2.85E+05	-0.22	2.24E+05	0.39

Com base no desempenho obtido através desse método, é possível notar que os resultados se apresentaram melhores para um horizonte de previsão (atraso) de 1 mês para cada região, com destaque para a região do Setor Antártico Sul-Americano, que apresentou os menores valores de REQM e EMA, e os maiores valores de CNS e CLP. No entanto, em sua maioria se apresentou insatisfatório para 2 e 3 meses de horizonte de previsão. Este resultado já era esperado, pois quanto maior a sazonalidade da previsão, maior é a influência exercida pelos ciclos climáticos, o que dificulta a previsão por persistência, que atende melhor uma condição prevista mais próxima de seu antecessor.

4.3 PREVISÃO PELA REDE NEURAL RBF

Finalizada a seleção dos vetores de entrada pelo método *stepwise*, conforme apresentado nas tabelas 4 a 6, a operação da rede RBF para a previsão da extensão do gelo marinho seguiu as configurações de acordo com as variáveis selecionadas para cada uma e o melhor número de neurônios avaliados para a camada oculta, sendo 5, 10 ou 15. Assim como nos experimentos de treinamento da rede, na operação a rede dividiu os dados de entrada, sendo 85% para o conjunto de treinamento, 10% para o conjunto de teste e 5% para o conjunto de validação. Foram considerados satisfatórios as previsões que apresentaram valores de CLP acima de

0.7 e CNS acima de 0.5. Os desempenhos das previsões através da rede neural RBF é mostrado nas tabelas 8 a 10 a seguir.

Tabela 8: Desempenho da rede RBF para a previsão da extensão do gelo marinho no Estreito de Drake.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	10	ext_drk, jpol_p	2.09E+04	0.57	1.35E+04	0.79
	2	5	prec_b, sam_a	3.02E+04	0.23	1.95E+04	0.49
	3	10	sst_b, prec_b	3.28E+04	0.14	1.86E+04	0.40
25	1	10	ext_drk, jpol_p, t2m_w, sst_b, sst_w	2.42E+04	0.36	1.71E+04	0.62
	2	15	prec_b, sst_b, sst_w, aao_b	2.58E+04	0.23	1.54E+04	0.48
	3	15	prec_b	2.17E+04	-0.37	1.54E+04	-0.01
30	1	5	ext_drk, sst_b, sam_a, sst_w, aao_b	2.88E+04	0.39	1.78E+04	0.64
	2	10	sst_b, prec_b	2.46E+04	0.04	1.68E+04	0.33

Apenas uma configuração apresentou desempenho satisfatório para a previsão da extensão do gelo marinho na região do Estreito de Drake, com limite de correlação de 20%, 1 mês de horizonte de previsão e 10 neurônios na camada oculta.

Também se destaca a previsão com correlação de 25% com 3 meses de atraso, onde se observa valores de correlação negativos quando houve apenas uma variável selecionada.

Tabela 9: Desempenho da rede RBF para a previsão da extensão do gelo marinho na Península Antártica.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	5	ext_p, sst_b, sst_w, prec_w	4.16E+04	0.31	3.14E+04	0.65
	2	15	prec_b, t2m_b	5.22E+04	0.24	4.07E+04	0.50
	3	10	prec_b, acc_w, sst_b	5.63E+04	0.08	3.93E+04	0.32
25	1	10	ext_p, prec_b, jpol_p, aao_w, sst_w, t2m_b	3.58E+04	0.50	2.89E+04	0.74
	2	10	sst_b, prec_b, acc_w, sst_w	4.70E+04	0.06	3.44E+04	0.43
	3	10	prec_b, sst_b	6.15E+04	0.09	4.43E+04	0.32
30	1	5	t2m_b, prec_b, jpol_p, sam_a, sst_b, cent_p_b	4.81E+04	0.21	3.57E+04	0.52
	2	5	prec_b, sst_b, aao_b	4.65E+04	0.23	3.59E+04	0.49
	3	15	prec_b	6.23E+04	0.10	4.60E+04	0.38

Já para a previsão na região da Península Antártica, observa-se o melhor desempenho com limite de 25% de correlação, 1 mês de horizonte de previsão e 10 neurônios na camada oculta. Seu resultado ainda ficou acima do observado no limite de 20% com 1 mês de atraso, com um número de variáveis selecionadas superior.

Tabela 10: Desempenho da rede RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano.

Limite	Atraso (meses)	Neurônios na camada oculta	Variáveis	REQM	CNS	EMA	CLP
20	1	10	ext_sa, aao_b, prec_w, prec_b	1.75E+05	0.39	1.20E+05	0.71
	2	10	prec_b, sst_b, ext_sa, prec_w	2.00E+05	0.58	1.52E+05	0.77
	3	10	ext_sa, prec_b	2.56E+05	0.12	2.01E+05	0.37
25	1	5	ext_sa, aao_w, aao_b, prec_b, sst_w	1.51E+05	0.62	1.24E+05	0.81
	2	15	ext_sa, prec_b, prec_w	1.92E+05	0.45	1.46E+05	0.67
	3	10	elnin, sst_w, sst_b	2.34E+05	0.08	1.98E+05	0.32
30	1	10	ext_sa, aao_b, sst_w	1.88E+05	0.47	1.50E+05	0.69
	2	15	ext_sa, prec_b, t2m_w, elnin	1.98E+05	0.53	1.50E+05	0.73
	3	10	elnin, ext_sa, sst_b	2.49E+05	0.25	2.06E+05	0.51

No desempenho da previsão para todo o Setor Antártico Sul-Americano, a rede apresentou um maior número de resultados satisfatórios, sendo em 4 configurações:

- Limite de 20% de correlação, 1 mês de atraso e 10 neurônios na camada oculta.
- Limite de 20% de correlação, 2 meses de atraso e 10 neurônios na camada oculta.
- Limite de 25% de correlação, 1 mês de atraso e 5 neurônios na camada oculta.
- Limite de 30% de correlação, 2 meses de atraso e 15 neurônios na camada oculta.




Figura 25: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.




Figura 26: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.




Figura 27: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.




Figura 28: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.




Figura 29: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.




Figura 30: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.




Figura 31: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.




Figura 32: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 1 mês.




Figura 33: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.

4.4 COMPARAÇÃO DE RESULTADOS

Comparando-se os melhores resultados obtidos dos experimentos de previsão da extensão do gelo marinho em todas as regiões, obtidos das técnicas de persistência e RNA RBF, é possível notar significativas diferenças na maioria dos casos, com inferioridade dos resultados obtidos através da persistência. Os resultados da comparação estão apresentados na tabela 11.

Tabela 11: Comparação dos resultados obtidos com as diferentes técnicas empregadas para a previsão da extensão do gelo marinho.

Região	Horizonte de Previsão (Meses)	Técnica	REQM	CNS	EMA	CLP
Estreito de Drake	1	Persistência	2.78E+04	0.27	1.52E+04	0.63
		RNA RBF	2.09E+04	0.57	1.35E+04	0.79
	2	Persistência	3.83E+04	-0.39	2.28E+04	0.31
		RNA RBF	2.58E+04	0.23	1.54E+04	0.48
	3	Persistência	4.32E+04	-0.76	2.73E+04	0.12
		RNA RBF	3.28E+04	0.14	1.86E+04	0.40
Península Antártica	1	Persistência	5.11E+04	0.34	3.50E+04	0.67
		RNA RBF	3.58E+04	0.50	2.89E+04	0.74
	2	Persistência	6.99E+04	-0.23	5.04E+04	0.38
		RNA RBF	5.22E+04	0.24	4.07E+04	0.50
	3	Persistência	7.77E+04	-0.52	5.77E+04	0.24
		RNA RBF	6.23E+04	0.10	4.60E+04	0.38
Setor Antártico Sul-Americano	1	Persistência	1.74E+05	0.54	1.36E+05	0.77
		RNA RBF	1.51E+05	0.62	1.24E+05	0.81
	2	Persistência	2.43E+05	0.12	1.92E+05	0.56
		RNA RBF	2.00E+05	0.58	1.52E+05	0.77
	3	Persistência	2.85E+05	-0.22	2.24E+05	0.39
		RNA RBF	2.49E+05	0.25	2.06E+05	0.51

Também é possível notar que a previsão por persistência apresentou seus melhores resultados para as previsões mensais, ou seja, com horizonte de 1 mês. Já a RNA RBF obteve diferentes resultados, variando de acordo com a configuração em que foi realizada, apresentando desempenho superior ao da persistência, com valores maiores de CNS e CLP, e menores erros calculados na REQM e EMA, se destacando em algumas previsões sazonais com horizonte de previsão de 2 meses.

Os melhores desempenhos da rede neural RBF nas estimativas sazonais pode ser explicado pela seleção criteriosa feita para a seleção das variáveis de entrada, filtrando as que possuem maior correlação e relevância para o desempenho do modelo. Com valores da Correlação Linear de Pearson (CLP) acima de 0,7 em alguns casos, e, analisando os gráficos de dispersão dos dados, pode-se dizer que os resultados nessas configurações foram satisfatórios.

Nos gráficos de dispersão em que os pontos mais se aproximaram da reta $y = x$ são aqueles que também apresentaram os melhores resultados de acordo com as métricas estatísticas calculadas, indicando que os erros nesses casos foram menores do que aqueles em que os pontos no gráfico se apresentaram mais dispersos e

afastados da reta diagonal. Nota-se que para alguns casos, o desempenho da rede neural RBF apresentou melhores resultados para previsões sazonais do que mensais, o que indica a possibilidade de se utilizar o modelo para previsões com prazos um pouco maiores do que 1 mês, principalmente quando se abrange todo o Setor Antártico Sul-Americano, que apresentou mais variáveis de entrada possíveis em seus experimentos de treinamento e operação da rede RBF.

5 CONCLUSÃO E RECOMENDAÇÕES

Ferramentas geralmente utilizadas para o estudo e avaliação de previsões climáticas foram utilizadas neste trabalho com o objetivo de se contribuir para o desenvolvimento de um modelo de previsão pouco convencional quando se pensa no Setor Antártico Sul-Americano. O alcance do gelo marinho da região sofre influências diretas dos fenômenos climáticos que abrangem as regiões da Península Antártica e Estreito de Drake, banhados pelos mares de Weddell e Bellingshausen. A previsão da extensão do gelo marinho auxilia na tomada de decisões de instituições que possuem bases no continente Antártico, além de se tornar possível a previsão de impactos futuros sobre a variação do gelo marinho.

As Redes Neurais Artificiais (RNAs) possuem vantagem quando se estuda relações não lineares com alta complexidade entre as variáveis de entrada e saída e, por esse motivo, foram utilizadas para o desenvolvimento do modelo de previsão, avaliando-se o desempenho da rede neural de função de base radial (RBF) neste estudo.

Inicialmente, foi realizada uma revisão sistemática sobre os fenômenos físicos e climatológicos que influenciam na variação da extensão do gelo marinho, a partir de estudos prévios publicados em revistas, livros e jornais científicos. Sendo assim, foram pré-selecionadas variáveis que possuem relação com a formação do gelo marinho no Setor Antártico Sul-Americano, e que foram consideradas relevantes para a previsão da extensão no setor. A partir das possíveis variáveis selecionadas de acordo com os estudos analisados, o método de seleção *stepwise* foi aplicado para selecionar de forma definitiva as variáveis que possuem maior relevância para a previsão.

O desempenho do modelo desenvolvido através da RNA RBF foi avaliado através de métricas estatísticas definidas e comparadas ao desempenho de uma técnica mais simples de previsão, a de persistência, com o objetivo de verificar se o modelo desenvolvido apresenta maior acurácia em seus resultados.

A previsão por persistência para esse caso foi considerada inferior à previsão através da rede neural RBF, já que os resultados das métricas estatísticas avaliadas se apresentaram inferiores aos obtidos da avaliação do modelo desenvolvido.

O desempenho da rede variou de acordo com a configuração em que foi estabelecida a previsão. Para as previsões com horizonte de 2 e 3 meses para a

região do Estreito de Drake, observou-se que os melhores resultados avaliados, ainda que superiores aos da previsão por persistência, foram insatisfatórios. No entanto, para as previsões das regiões da Península Antártica e do Setor Antártico Sul-Americano, as métricas estatísticas avaliadas apresentaram desempenhos mais satisfatórios.

Apesar das diferentes configurações e variáveis selecionadas a partir do método *stepwise*, foi possível identificar quais variáveis são mais relevantes para o modelo, analisando sua frequência e repetição entre os experimentos. A dominância de variáveis atmosféricas que influenciam o Mar de Bellingshausen, como a precipitação e a temperatura da superfície do mar podem indicar que tal região possui maior relação com a variabilidade do gelo marinho no Setor Antártico Sul-Americano.

Por conseguinte, conclui-se que a rede neural RBF é adequada e apresenta avaliações de desempenho satisfatórias quando comparada ao modelo de previsão por persistência, com habilidade e complexidade menores. Em vista disso, pode-se dizer que a RNA RBF atendeu às expectativas quanto à sua habilidade em resolver e correlacionar problemas e variáveis de maior complexidade, como as que foram estudadas e selecionadas para o modelo de previsão.

Para trabalhos futuros, sugere-se estudos que indiquem com maiores detalhes as relações entre as variáveis selecionadas e identificadas neste estudo. Além da possibilidade de utilização de outros métodos de seleção de variáveis de entrada para o modelo não citados no presente trabalho, avaliando e comparando quais variáveis possuem maior importância para previsão do gelo marinho na região com métodos distintos.

6 REFERÊNCIAS

AFONSO, M. H. F.; SOUZA, J. V. de; ENSSLIN, S. R.; ENSSLIN, L. Como construir conhecimento sobre o tema de pesquisa? Aplicação do processo proknow-c na busca de literatura sobre avaliação do desenvolvimento sustentável. *Revista de Gestão Social e Ambiental*, São Paulo (SP), v. 5, n. 2, p. 47–62, 2012. DOI: 10.24857/rgsa.v5i2.424. Disponível em: <https://rgsa.emnuvens.com.br/rgsa/article/view/424>. Acesso em: 14 abr. 2021.

ANTARCTIC sea ice falls to lowest level since measurements began in 1979. THE GUARDIAN, 2022. Disponível em: <<https://www.theguardian.com/world/2022/feb/23/antarctic-sea-ice-falls-to-lowest-level-since-measurements-began-in-1979>>. Acesso em: 16 mar. 2022.

Barboza, E. G., Martins, E. M., Rosa, M. L. C. ECODIVERSIDADE E SUA SUSTENTABILIDADE NO QUATERNÁRIO. XV Congresso da Associação Brasileira de Estudos do Quaternário –ABEQUA& II Encontro Brasileiro do Tecnógeno (eds.) v. 2, n. 1. Imbé/RS: CECLIMAR/IBIO/UFRGS, 2015. ISSN: 2318-0986.

Barry, Roger G.; Chorley, Richard J. *Atmosfera, tempo e clima*. Bookman Editora, 2009.

Blank, Dionis M. P.; Marques, Julio R. Q.; Justino, F. B. *Análise dos quantis da temperatura mínima no Rio Grande do Sul e ligações com os setores da Concentração de Gelo Marinho Antártico*. *Rev. bras. meteorol.* v. 26, 2011. doi: <https://doi.org/10.1590/S0102-77862011000100005>.

Bromwich, D. H; T. R. Parish, 1998: *Meteorology of the Antarctic*. In *Meteorology of the Southern Hemisphere*, edited by D. J. Karoly and D. G. Vincent, Meteorological Monographs, v. 27, n. 49. American Meteorological Society, Boston, 175-196.

Bureau of Meteorology. *The Southern Annular Mode (SAM)*, 2012. Australian Government. Disponível em: <http://www.bom.gov.au/climate/enso/history/ln-2010-12/SAM-what.shtml>. Acesso em: 02 ago. 2021.

Carpenedo, Camila Bertoletti. *Interações entre os ciclones extratropicais e a variabilidade extrema do gelo marinho nos mares de Bellingshausen/Amundsen e no mar de Weddell*, Antártica. Dissertação de Mestrado. Universidade de São Paulo, 2012.

Cavalieri, D. J., C. L. Parkinson, P. Gloersen, and H. J. Zwally. 1996, updated yearly. Sea Ice Concentrations from Nimbus-7 SMMR and DMSP SSM/I-SSMIS Passive Microwave Data, Version 1. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center. <https://doi.org/10.5067/8GQ8LZQVL0VL>

Centro Brasileiro de Pesquisas Físicas, 2003. Disponível em: <https://www.cbpf.br/cat/pdsi/gauss.html>. Acesso em: 01 jul 2021.

Comiso, Josefino C. *et al. Positive Trend in the Antarctic Sea Ice Cover and Associated Changes in Surface Temperature*. 2017, Journal of climate. doi: <https://doi.org/10.1175/JCLI-D-16-0408.1>

Davies, B. *Southern Annular Mode*. Antarctic Glaciers, 2021. Disponível em: <http://www.antarcticglaciers.org/glaciers-and-climate/changing-antarctica/southern-annular-mode/>. Acesso em: 02 ago 2021.

European Centre for Medium-Range Weather Forecasts (ECMWF). ERA5, 2021. Disponível em: <https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5>. Acesso em 05 ago 2021.

Felicio, R. A. Antártida: A Geografia do Continente Gelado e as Operações Brasileiras. In: IV Semana de Geografia, 2007, São Paulo. Anais eletrônicos [...] São Paulo: USP, 2007. p. 9. Disponível em: <https://lcb.fflch.usp.br/sites/lcb.fflch.usp.br/files/upload/paginas/A10-Antartida.pdf>. Acesso em: 04 ago 2021.

Ferron, F. A. Variações nas razões de isótopos estáveis na neve e no gelo na Ilha Rei George, Antártica. 125 f. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, Porto Alegre, 1999.

Gandra, M., & Quadro, M. F. L. de. (2019). Gelo marinho Antártico e a trajetória de ciclones sobre o oceano Atlântico do sul. *Metodologias E Aprendizado*, 2, 57–62. <https://doi.org/10.21166/metapre.v2i0.1322>

Holland, P. R., Kwok, R. *Wind-driven trends in Antarctic sea-ice drift*. *Nature Geoscience* 5, 872-875 (2012). doi: <https://doi.org/10.1038/ngeo1627>

Jacobs, Stanley S.; Comiso, Josefino C. *Climate Variability in the Amundsen and Bellingshausen Seas*. American Meteorological Society, New York, 1997.

Kansas, W. *What is El Niño-Southern Oscillation (ENSO)?* National Weather Service, 2021. Disponível em: <https://www.weather.gov/ict/enso>. Acesso em: 16 jul 2021.

King, J. C; Turner, J. *Antarctic meteorology and climatology*, Cambridge: Cambridge University Press, 1997. DOI: 10.1017/S0032247400025754. Disponível em: https://www.researchgate.net/publication/248621362_Antarctic_meteorology_and_climatology_JC_King_and_J_Turner_1997. Acesso em 03 ago 2021.

King, J. C. *Antarctic climate variability and change*, Cambridge, Seminar on Polar Meteorology, 2006. Disponível em: <https://www.ecmwf.int/sites/default/files/elibrary/2007/10472-antarctic-climate-variability-and-change.pdf>. Acesso em: 08 jul 2021.

Lee, J., Kim, C.-G., Lee, J., Kim, N. e Kim, H. (2018). Application of artificial neural networks to rainfall forecasting in the geum river basin, korea. *Water*, 10(10):1448.

Liu, J; Curry, J. A; Martinson, D. G. *Interpretation of recent Antarctic Sea ice variability*, *Geophysical Research Letters*, 2004. doi:10.1029/2003GL018732.

Marschoff Enrique R. *Southern Ocean*. United Nations, 2016. Disponível em: https://www.un.org/depts/los/global_reporting/WOA_RPROC/Chapter_36H.pdf.

Acesso em: 02 ago. 2021

Meehl, G.A., Arblaster, J.M., Chung, C.T.Y. *et al.* *Sustained ocean changes contributed to sudden Antarctic sea ice retreat in late 2016*. Nat Commun 10, 14 (2019). doi: <https://doi.org/10.1038/s41467-018-07865-9>

Milléo, C. *Emprego de redes neurais artificiais na previsão climática de temperatura e precipitação no estado do Paraná*. Dissertação de Mestrado. Universidade Federal do Paraná, Curitiba, 2020.

NASA Earth Observatory. *Sea Surface Temperature & Sea Surface Temperature Anomaly*, 2021. Disponível em: https://www.earthobservatory.nasa.gov/global-maps/MYD28M/AMSRE_SSTAn_M. Acesso em: 03 ago 2021.

NSIDC - National Snow and Ice Data Center. *All about sea ice*. Disponível em: <https://nsidc.org/cryosphere/seaice/index.html>. Acesso em: julho de 2021.

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

Peixoto, J. P; Oort, A. H. *Physics of climate*. American Institute of Physics, New York. 1992.

Rasmussen, E. A; Turner, J. *Polar Lows: Mesoscale Weather Systems in the Polar Regions*. 2003. Cambridge: Cambridge University Press. Xii, p. 612. DOI: 10.1017/S0032247404213493. Disponível em: <https://app.amanote.com/v3.12.8/note-taking/document/MZzQ3HMBKQvf0BhiF7BM>. Acesso em 05 ago 2021.

Robles, T. El Niño e La Niña: efeitos e previsão, 2018. Disponível em: <https://www.tempo.com/noticias/actualidade/el-nino-e-la-ni-a-efeitos-e-previsao.html>. Acesso em 17 jul 2021.

Schmitt, C. *Interannual Variability in Antarctic Sea Ice Motion*. Tese (Doutorado em Ciências) – Faculdade de Física, Universidade de Karlsruhe (TH). Karlsruhe, p. 7. 2005. Disponível em: https://www.imk-tro.kit.edu/download/diss_schmitt_cl.pdf. Acesso em 05 ao 2021.

Silva, I. N; Spatti, D. H; Fauzino, R. A; *Redes neurais artificiais para engenharia e ciências aplicadas*. Artliber Editora Ltda, São Paulo, 2010. ISBN978-85-88098-53-4.

Silva, R. C. *Eventos Extremos de Gelo Marinho no Mar de Weddell e sua Relação com o Anticiclone Subtropical do Atlântico Sul*. Monografia (Graduação em Geografia) – Instituto de Geografia, Universidade Federal de Uberlândia. Uberlândia, p. 8. 2018.

Simões, J. C. *Glossário da língua portuguesa da neve, do gelo e termos correlatos*. Pesquisa Antártica Brasileira, 4, p. 119-154, 2004.

Stammerjohn, S.E., D.G. Martinson, R.C. Smith, X. Yuan, and D. Rind, 2008: *Trends in Antarctic annual sea ice retreat and advance and their relation to El Niño-Southern Oscillation and Southern Annular Mode variability*. J. Geophys. Res., 108, C03S90, doi:10.1029/2007JC004269.

Turner J, Hosking JS, Bracegirdle TJ, Marshall GJ, Phillips T. *Recent changes in Antarctic Sea Ice*. Philosophical Transactions Royal Society, 2015. A 373: 20140163. <http://dx.doi.org/10.1098/rsta.2014.0163>

Vaughan, D. & M. *et al.* (2003). Recent Rapid Regional Climate Warming on the Antarctic Peninsula. Climatic Change. 60. 243-274. 10.1023/A:1026021217991. Disponível em: <https://www.researchgate.net/publication/226931149>. Acesso em: 16 jun 2021.

Wadhams P. *Ice in the ocean*. Amsterdam: Gordon and Breach Science Publishers. 351 p., 2000.

Wallace, J. M; Hobbs, P. V. *Atmospheric Science: An Introductory Survey*. Elsevier, 2006.

Wang, G., Cai, W. Climate-change impact on the 20th-century relationship between the Southern Annular Mode and global mean temperature. *Scientific Reports* 3, n. 2039, 2013. Disponível em: <https://doi.org/10.1038/srep02039>. Acesso em: 25 out 2021.

Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences*, volume 100. Academic press.

Zwally, H. J. *et al. Variability of Antarctic sea ice 1979 – 1998*, *Geophysical Research Letters*, 107(C5), 3041, doi:10.1029/2000JC000733, 2002.

APÊNDICE A

A seguir são apresentadas as médias climatológicas e as anomalias das variáveis preditoras possíveis dos modelos de previsão, que foram obtidas pelo banco de dados do ECMWF (Tabela 1). Também serão apresentadas as médias e anomalias dos dados de gelo marinho obtidos pelo banco de dados do NSIDC para as regiões do Estreito de Drake e Península Antártica.

A.1 MÉDIAS CLIMATOLÓGICAS DAS POSSÍVEIS VARIÁVEIS PREDITORAS

Na figura 34 nota-se que as médias da velocidade da componente v da CCA em Bellingshausen são majoritariamente voltadas para a direção sul, o que justifica os valores invertidos do gráfico com maior intensidade nos meses de setembro, outubro e março e menor intensidade nos meses de abril a agosto.




Figura 34: Médias climatológicas da velocidade do vento da componente v à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.

Na figura 35 percebe-se que o comportamento das médias da componente v da CCA em Weddell é diferente, com ventos predominantes para o norte na maior parte do ano, com sua intensidade voltada de maneira menos intensa para o sul nos meses de setembro a dezembro. Vale destacar como os dois mares possuem diferenças significativas em relação à direção do vento, separados fisicamente pela Península Antártica, como citado por Jacobs e Comiso (1997), na seção 2.1.1. Ainda

Stammerjohn *et al.* (2008) aponta a associação existente entre a variabilidade do gelo marinho e à intensidade dos ventos da CCA.




Figura 35: Médias climatológicas da velocidade do vento da componente v à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.

A figura 36 indica que as médias de velocidade da componente u dos ventos da região da CCA em Bellingshausen é predominantemente voltada para Leste durante o ano todo, com intensidade menor entre os meses de dezembro e janeiro.




Figura 36: Médias climatológicas da velocidade do vento da componente u à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.

Na figura 37, as médias de velocidade da componente u na região da CCA em Weddell também possui predominância para leste, em menor intensidade se comparado à região de Bellingshausen, com menor intensidade nos meses de janeiro, fevereiro, junho e dezembro. Ressalta-se com essa análise, que os ventos da CCA em Bellingshausen voltam-se para o continente Antártico e em direção à Península, ao mesmo tempo em que os ventos de CCA em Weddell se voltam, na maior parte do ano, para o oceano e continente Sul-Americano.




Figura 37: Médias climatológicas da velocidade do vento da componente u à 10m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.

As figuras 38 e 39 apresentam as médias da PNM em Bellingshausen e Weddell, sendo possível notar a semelhança no comportamento das pressões ao longo do ano, com maior intensidade em Weddell que em Bellingshausen. As menores temperaturas registradas para a região do Mar de Weddell podem ser justificadas também pelo comportamento do centro de pressão, já que se apresenta com maior intensidade para a região do que em Bellingshausen.




Figura 38: Médias climatológicas da Pressão ao nível do mar, no centro de pressão do mar de Bellingshausen.




Figura 39: Médias climatológicas da Pressão ao nível do mar, no centro de pressão do mar de Weddell.

A figura 40 indica as médias climatológicas da TSM na região do El Niño 3.4, onde o aquecimento do oceano é intensificado nos meses de março a julho, com menor intensidade e menor variação no restante do ano.




Figura 40: Médias climatológicas da Temperatura na superfície do mar, na região do El Niño 3.4.

Nas figuras 41 e 42, as médias de velocidade da componente u na altura geopotencial de 200 hPa da região do Jato Polar e da região do Jato Subtropical no pacífico, apresentam diferentes comportamentos, com maior variabilidade e intensidade na região do Jato Subtropical. Destaca-se a oposição de comportamento entre as regiões, nos meses que se observa as menores médias para a região do Jato Polar, observa-se as maiores médias na região do Jato Subtropical.




Figura 41: Médias climatológicas da Velocidade da componente u à 200 hPa na região do Jato Polar.




Figura 42: Médias climatológicas da Velocidade da componente u à 200 hPa na região do Jato Subtropical.

A figura 43 apresenta as médias de PNM para o Modo Anular Sul (SAM), indicando significativa variabilidade durante o ano, com valores mais altos nos meses de verão e inverno, quando exerce maior influência sobre o continente Antártico. Nos meses de inverno, quando a pressão se intensifica, é quando os ventos para norte predominantes no SAM ocasionam frentes frias para a América do Sul (Davies, 2021).




Figura 43: Médias climatológicas da Pressão ao Nível do Mar na região do Modo Anular Sul (SAM).

O comportamento das médias de PNM nos mares de Darwin (figura 44) e Tahiti (figura 45) seguem um mesmo padrão, com valores mais altos nos meses de junho a outubro, e pouca variabilidade durante o ano.




Figura 44: Médias climatológicas da Pressão ao Nível do Mar na região do mar de Darwin.




Figura 45: Médias climatológicas da Pressão ao Nível do Mar na região do mar de Tahiti.

O mesmo padrão de variação das médias de temperatura da superfície do mar também ocorre para a temperatura do ar à 2m (T2M) das regiões de

Bellingshausen (figura 46) e Weddell (figura 47), com temperaturas mais baixas no inverno em ambos, com maior intensidade na região do Mar de Bellingshausen.




Figura 46: Médias climatológicas da Temperatura do ar à 2m na região do mar de Bellingshausen.




Figura 47: Médias climatológicas da Temperatura do ar à 2m na região do mar de Weddell.

A.2 ANOMALIAS DAS POSSÍVEIS VARIÁVEIS PREDITORAS

Nas figuras 48 e 49 os dados de anomalias da velocidade da componente v da CCA em Bellingshausen e Weddell apresentam variação dentro do intervalo de -4 a 4 e -3 a 3 m/s, respectivamente. Também se nota uma distribuição assimétrica das anomalias em ambos. As evoluções temporais apresentaram alta frequência e variação, sem identificação de padrões evidentes no intervalo, com uma variação ligeiramente maior para a região do Mar de Bellingshausen.




Figura 48: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente v à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.




Figura 49: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente v à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.

No histograma da figura 50 observa-se que há assimetria na distribuição das anomalias da velocidade da componente u à 10m em Bellingshausen. Sua evolução temporal também apresenta alta frequência, dificultando uma análise de comportamento e de padrões.




Figura 50: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente u à 10 m, na região da Corrente Circumpolar Antártica (CCA) do mar de Bellingshausen.

Já na região do mar de Weddell (figura 51), há uma maior simetria das anomalias da velocidade da componente u à 10m e sua evolução temporal apresentou menor frequência, se comparado ao mar de Bellingshausen, indicando menor variação da velocidade do vento. É possível analisar que os ventos mais intensos de Bellingshausen são àqueles que atingem o continente Antártico e Península, ao mesmo tempo que os ventos menos intensos de Weddell são os que convergem para as latitudes médias e, consequentemente, para o continente Sul-Americano.




Figura 51: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da velocidade da componente u à 10 mm, na região da Corrente Circumpolar Antártica (CCA) do mar de Weddell.

As anomalias da PNM dos centros de pressão nas regiões de Bellingshausen (figura 52) e Weddell (figura 53) apresentam certa simetria em seus respectivos histogramas. As evoluções temporais com alta frequência dificultam a identificação de padrões no comportamento da PNM nessas regiões.




Figura 52: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão ao Nível do Mar, na região do centro de pressão do mar de Bellingshausen.




Figura 53: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão ao Nível do Mar, na região do centro de pressão do mar de Weddell.

Diferentemente dos outros fenômenos, as anomalias da TSM na região do El Niño 3.4 (figura 54), a evolução temporal segue padrões de baixa frequência, sendo fácil de se identificar as épocas com maior aquecimento e resfriamento do oceano. Nota-se que os intervalos entre os picos de anomalia das temperaturas positivas e negativas não seguem um padrão, já que variam de acordo com a intensidade em que se ocorrem os eventos de El Niño e La Niña na região. Há uma certa assimetria entre as anomalias do histograma, que apresenta predominância de valores entre -1 e 1 °C.




Figura 54: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura da Superfície do Mar na região do El Niño 3.4.

A figura 55 apresenta os dados de anomalia da velocidade da componente u à 200 hPa para a região do Jato Polar, que apresenta simetria em sua distribuição no histograma, porém, uma alta frequência em sua evolução temporal dificulta uma análise mais aprofundada sobre seus padrões.




Figura 55: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Velocidade da componente u à 200 hPa na região do Jato Polar.

Na figura 56 percebe-se uma assimetria das anomalias da velocidade da componente u à 200 hPa na região do Jato Subtropical em seu histograma, que varia de -10 a 20 m/s. Sua evolução temporal apresenta alta frequência, sendo possível identificar anomalias positivas mais intensas em alguns intervalos do que negativas.




Figura 56: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Velocidade da componente u à 200 hPa na região do Jato Subtropical.

A anomalia da pressão na superfície do mar para o SAM é apresentada na figura 57, em que seu histograma está dentro do intervalo de -2000 a 2000 Pa. Sua evolução temporal indica alta frequência dos dados de anomalias, onde percebe-se que a partir de 2010 houve uma tendência de queda dessa variação, tornando-se menos ruidosa nesse período.




Figura 57: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do Modo Anular Sul (SAM).

A figura 58 indica as anomalias da PNM no mar de Darwin. Seu histograma apresenta assimetria, com um intervalo de -300 a 200 Pa. Sua evolução temporal apresenta menor frequência se comparado às demais evoluções já analisadas, e, é possível notar uma tendência de queda acentuada no intervalo inicial do período analisado, ao mesmo tempo em que se percebe uma tendência de aumento nos últimos anos.




Figura 58: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do mar de Darwin.

Já para as anomalias de PNM no mar de Tahiti (figura 59) o histograma apresentou maior simetria, com dados que variam de -400 a 300 Pa. Sua evolução temporal tem alta frequência, com valores negativos sobressaindo-se em relação aos positivos. No entanto, há uma tendência de aumento nos últimos anos, seguindo o mesmo padrão de comportamento da PNM no mar de Darwin a partir de 2015.




Figura 59: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Pressão na superfície do mar, na região do mar de Tahiti.

Na figura 60, as anomalias da temperatura do ar à 2m (T2M) em Bellingshausen apresentaram simetria no histograma com intervalo de -4 a 4 °C. Sua evolução temporal apresenta menor frequência se comparado às outras variáveis já analisadas, indicando menor variação ao longo do período analisado.




Figura 60: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura do ar à 2m, na região do mar de Bellingshausen.

A figura 61 mostra as anomalias da T2M em Weddell, com o intervalo do histograma variando de -6 a 6 °C e alto ruído e uma frequência maior em sua evolução temporal, seguindo o mesmo comportamento observado nos gráficos de médias e anomalias da TSM de cada região, com maior variabilidade para o Mar do Weddell do que em Bellingshausen.




Figura 61: Histograma (painel superior) e evolução temporal (painel inferior) dos valores de anomalias da Temperatura do ar à 2m, na região do mar de Weddell.

A.3 MÉDIAS E ANOMALIAS DOS DADOS DE GELO MARINHO

Na figura 62 nota-se que a concentração de gelo marinho no Estreito de Drake ocorre durante os meses de abril a dezembro, com maior intensidade nos meses de junho a setembro. Sua evolução temporal possui frequência mais baixa, notando-se tendência de queda ao longo dos anos, com menores variações a partir do ano 2000.




Figura 62: Médias (painel superior) e evolução temporal (painel inferior) da Anomalia da Concentração de Gelo Marinho no Estreito de Drake.

Na figura 63, o comportamento das médias da área de gelo marinho no Estreito de Drake apresenta menor intensidade ao longo do ano, com valores expressivos durante o inverno. Sua evolução temporal possui baixa frequência e percebe-se padrões de comportamento, com predominância negativa durante todo o intervalo e menor variação observada após o ano 2000.




Figura 63: Médias (painel superior) e evolução temporal (painel inferior) da Anomalia da Área de Gelo Marinho no Estreito de Drake.

A extensão do gelo marinho no Estreito de Drake (figura 64) apresentou maiores médias se comparado com a área, porém, com comportamento semelhante ao longo do ano. Sua evolução temporal também apresenta menor frequência, com predominância negativa e menor variação a partir do ano 2000.




Figura 64: Médias (painel superior) e evolução temporal (painel inferior) da anomalia da Extensão de Gelo Marinho no Estreito de Drake.

Na região da Península Antártica nota-se que as médias de concentração do gelo marinho (figura 65) são muito mais altas se comparado a região do Estreito de Drake, com maiores valores nos meses de abril a agosto. Sua evolução temporal já apresenta alta frequência com picos negativos em determinados intervalos, e predominância positiva nos últimos anos.




Figura 65: Médias (painel superior) e evolução temporal (painel inferior) da Concentração de Gelo Marinho na Península Antártica.

Na figura 66 observa-se que o comportamento das médias de área do gelo marinho na Península Antártica tem comportamento diferente da concentração, com maiores médias nos meses de junho a setembro. Sua evolução temporal apresenta baixa frequência com maior variação entre os picos de anomalias antes do ano 2000, com significativa redução a variação após esse período.




Figura 66: Médias (painel superior) e evolução temporal (painel inferior) da Área de Gelo Marinho na Península Antártica.

As médias de extensão do gelo marinho na Península Antártica (figura 67) apresentam comportamento semelhante ao da área, com sua extensão chegando a mais de 250.000 Km² em agosto, com variação de quase 200.000 Km² até fevereiro, quando atinge sua menor média. A evolução temporal também apresenta comportamento semelhante, com variações maiores no início do intervalo e menores nos últimos anos.




Figura 67: Médias da Extensão de Gelo Marinho na Península Antártica.

APÊNDICE B

As estatísticas de média, mediana, desvio padrão, covariância, valores máximos e mínimos, calculadas a partir dos dados das possíveis variáveis preditoras estão apresentadas na tabela 12.

Tabela 12: Estatísticas calculadas a partir dos dados climáticos das possíveis variáveis preditoras.

Variável	Região	Média	Mediana	Dpa	CV	máx	mês/ano	min	mês/ano
PNM (Pa)	Tahiti	101325	101329	174,7	0,172	100782	set/10	100798	fev/05
PNM (Pa)	Darwin	101297	101295	122,3	0,121	101628	ago/10	100863	jan/83
TSM (K)	El Niño 3.4	300,2	300,2	1,027	0,342	302,6	nov/97	297,4	out/88
Veloc. Comp. U, 10m (m/s)	CCA Weddell	1,847	1,863	1,461	79,09	7,010	set/16	-2,518	jan/03
Veloc. Comp. U, 10m (m/s)	CCA Bellingshausen	2,450	2,513	1,662	67,86	7,360	jul/85	-2,620	mai/90
PNM (Pa)	Weddell	98883	98862	524,9	0,531	100373	out/88	97437	set/17
PNM (Pa)	Bellingshausen	98667	98628	607,1	0,615	100324	jun/92	97240	out/10
Precip. Total (m)	Weddell	1,072	1,066	0,274	25,58	2,204	mai/13	0,299	jul/06
Precip. Total (m)	Bellingshausen	1,928	1,934	0,467	24,24	3,480	ago/16	0,720	nov/12
Temp. do ar , 2m (K)	Weddell	257,5	255,9	7,300	2,830	270,4	jan/97	243,8	jul/94
Temp. do ar , 2m (K)	Bellingshausen	258,9	257,8	5,034	1,944	268,4	jan/90	249,1	jul/95
TSM (K)	Weddell	265,4	265,4	5,810	2,190	273,5	jan/91	250,7	ago/06
TSM (K)	Bellingshausen	270,8	271,0	2,815	1,040	275,8	fev/06	262,1	jul/95
PNM (Pa)	Modo Anular do Sul	98529	98518	618,0	0,627	100853	jul/95	96804	ago/98
Veloc. comp. u, 200 hPa (m/s)	Jato Subtropical	26,99	28,21	11,40	42,24	53,39	ago/97	2,531	fev/89
Veloc. comp. u, 200 hPa (m/s)	Jato Polar	23,49	23,79	5,536	23,57	38,54	ago/98	7,080	jun/05
Veloc. comp. v, 10m (m/s)	CCA Weddell	0,304	0,251	1,159	381,9	3,458	mai/16	-2,936	out/10
Veloc. comp. v, 10m (m/s)	CCA Bellingshausen	-0,892	-0,973	1,388	-155,6	4,081	jul/95	-5,914	set/08

APÊNDICE C

Nas figuras 68 a 76 são apresentados os resultados dos 9 ciclos do método *stepwise* para o Setor Antártico Sul-Americano.




Figura 68: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 69: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 70: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 71: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 72: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 73: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 74: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 75: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 76: Resultados das 9 repetições do método *stepwise* para o Setor Antártico Sul-Americano, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 78: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 20% de correlação cruzada entre as variáveis selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 79: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 80: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 81: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 82: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 83: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 84: Resultados das 9 repetições do método *stepwise* para a região da Península Antártica, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.

Nas figuras 85 a 91 são apresentados os resultados dos 8 ciclos do método *stepwise* para a região do Estreito de Drake.




Figura 85: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 86: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 87: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 20% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 3 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 88: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 89: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 25% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 90: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 1 mês de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.




Figura 91: Resultados das 9 repetições do método *stepwise* para a região do Estreito de Drake, para 30% de correlação cruzada entre as variáveis pré-selecionadas e a variável de interesse e 2 meses de horizonte de previsão. Para os gráficos da primeira linha foram utilizados 5 neurônios na camada oculta, para a segunda linha, 10 neurônios e para a terceira linha, 15 neurônios.

APÊNDICE D

Nas figuras 92 a 108 são apresentados os gráficos de dispersão entre os dados observados e os dados modelados pela rede RBF para cada configuração do modelo de previsão.




Figura 92: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.




Figura 93: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.




Figura 94: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.




Figura 95: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.




Figura 96: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Estreito de Drake, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.




Figura 97: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 2 meses.




Figura 98: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.




Figura 99: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.




Figura 100: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.




Figura 101: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 2 meses.




Figura 102: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho na Península Antártica, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 3 meses.




Figura 103: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 1 mês.




Figura 104: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 20% e horizonte de previsão (atraso) de 3 meses.




Figura 105: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 2 meses.




Figura 106: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 25% e horizonte de previsão (atraso) de 3 meses.




Figura 107: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 1 mês.




Figura 108: Gráfico de Dispersão entre os dados observados e os dados modelados pela RBF para a previsão da extensão do gelo marinho no Setor Antártico Sul-Americano, com limite de correlação entre as variáveis de 30% e horizonte de previsão (atraso) de 3 meses.