

UNIVERSIDADE FEDERAL DE SANTA CATARINA - UFSC  
CENTRO DE FÍSICA E MATEMÁTICA - CFM  
COORDENADORIA ESPECIAL DE OCEANOGRÁFIA - OCN  
CURSO BACHARELADO EM OCEANOGRÁFIA

RAFAEL SCHERNOVEBER CAMPANHOLA

**CARACTERIZAÇÃO DO CLIMA DE ONDAS DE SANTA CATARINA ATRAVÉS DE  
REFINAMENTO ESTATÍSTICO**

FLORIANÓPOLIS  
2019



UNIVERSIDADE FEDERAL DE SANTA CATARINA - UFSC  
CENTRO DE FÍSICA E MATEMÁTICA - CFM  
COORDENADORIA ESPECIAL DE OCEANOGRÁFIA - OCN  
CURSO BACHARELADO EM OCEANOGRÁFIA

RAFAEL SCHERNOVEBER CAMPANHOLA

**CARACTERIZAÇÃO DO CLIMA DE ONDAS DE SANTA CATARINA ATRAVÉS DE  
REFINAMENTO ESTATÍSTICO**

Monografia apresentada ao curso de bacharelado em Oceanografia da Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do título de Bacharel em Oceanografia.

Orientador: Ph.D. Antonio Fernando Härter Fetter Filho

FLORIANÓPOLIS

2019

*Dedico este trabalho aos meus pais.*

## AGRADECIMENTOS

Em primeiro lugar gostaria de agradecer a minha família, especialmente meus pais, pela compreensão, apoio e confiança nas minhas decisões, pela paciência com meus erros e por todas as vezes que me ergueram das minhas quedas.

A minha irmã Camila, uma das pessoas que leva a vida da forma mais alegre e leve que já conheci, e estava junto comigo me passando essa tranquilidade enquanto eu fazia o vestibular para oceanografia na UFSC. Hoje já não dividimos mais a mesma casa, mas sabemos que estamos sempre lado a lado.

Agradeço ao Vitório Razzera, Daniel Pompeu e André Magnani por todo o tempo que dividimos juntos já nos primeiros dias em Florianópolis, também ao João Pedro Steil e Matheus Caiaffa por todos os momentos durante esses anos.

Ao meu orientador prof. Antonio Fernando Härter Fetter Filho pela ajuda durante o processo de desenvolvimento do trabalho. À Charline por sempre estar disposta a ajudar, aos companheiros de laboratório pelos momentos de descontração e aprendizado.

E por último, mas não menos importante, todos os amigos que não estão próximos mas fazem parte da minha vida há muito tempo, portanto também são responsáveis pela conclusão de mais essa fase.

A todos, sou grato.

*“Eddie would go.”*

*-Mark Foo*

## RESUMO

Este trabalho apresenta uma caracterização do clima de ondas de Santa Catarina através da metodologia de refinamento estatístico com abordagem por *weather-types*. A principal vantagem dos métodos estatísticos é o baixo custo computacional envolvido nos cálculos, o que possibilitou que diferentes tamanhos de grade local e tempos de viagem de ondas fossem testados. Comparando os resultados obtidos com a série de dados original, o modelo de melhor desempenho alcançou correlações de 0,78, 0,64 e 0,83 para altura significativa de onda, período de pico e direção média de onda, respectivamente. O valor médio de Hs da série gerada pelo modelo foi de 1,93 m, comparado a 1,92 m da série original, ambas as séries têm 9,1 s como valor médio para Tp e para direção média o modelo obteve um valor médio de 115,5°, sendo 115,75° a média da série original. As análises de correlação realizadas entre as seis primeiras componentes principais e nove diferentes índices climáticos (MEI.v2, ONI, PDO, AAO, SAOD, NINO 3.4, TSA, AMM e SOI) mostraram que todos os índices analisados têm correlação significativa com pelo menos uma das componentes, enaltecendo a complexidade dos processos responsáveis pela geração de ondas na costa catarinense. Análises estatísticas mostraram que períodos de calibração menores do que 5 anos prejudicaram o desempenho do modelo em prever a série de ondas, bem como intervalos de validação inferiores a 5 meses não foram reproduzidos com qualidade pelo mesmo. A redução de resolução espacial de 0,5°x0,5° para 2°x2°, considerando apenas o intervalo de calibração acima de 5 anos, obteve uma diferença de correlação de no máximo 0,01 e reduziu o tempo de execução dos cálculos significativamente.

## ABSTRACT

The objective of this work was to characterize the Santa Catarina wave climate through the statistical downscaling methodology with a weather-type approach. The main advantage of statistical methods is the low computational cost involved in the calculations, which allowed different local grid sizes and wave travel times to be tested. Comparing the results obtained with the original data series, the best performance model reached correlations of 0.78, 0.64 and 0.83 for significant wave height, peak period and mean wave direction, respectively. The mean value of  $H_s$  of the series generated by the model was 1.93 m, compared to 1.92 m of the original series, both series have 9.1 s as mean value for  $T_p$  and for average wave direction the model obtained an average value of  $115,5^\circ$ , being  $115,75^\circ$  the average of the original series. The correlation analyzes performed between the first six principal components and nine different climate indexes (MEI.v2, ONI, PDO, AAO, SAOD, NINO 3.4, TSA, AMM and SOI) showed that all indices analyzed have a significant correlation with at least one of the components, highlighting the complexity of the processes responsible for the generation of waves on the coast of Santa Catarina. Statistical analysis showed that calibration periods shorter than 5 years impaired the performance of the model in predicting the wave series, as well as validation intervals shorter than 5 months were not reproduced with quality by the same. The spatial resolution reduction of  $0.5^\circ \times 0.5^\circ$  to  $2^\circ \times 2^\circ$ , considering only the calibration interval above 5 years, obtained a correlation difference of at most 0,01 and reduced the execution time of the calculations significantly.



## LISTA DE FIGURAS

- Figura 1. Mapa do fluxo de energia sazonal que se propaga para a costa catarinense. Fonte: Imagens desenvolvidas no âmbito de uma colaboração entre o *Surf and Surge Research Group* - Universidade da Cantábria (Espanha) e a Universidade Federal de Santa Catarina (UFSC).....9
- Figura 2. Localização geográfica de Santa Catarina, com destaque para sua linha de costa, no Sul do Brasil. Fonte: João Pedro Steil, 2018.....10
- Figura 3. Fluxograma representando a metodologia de refinamento estatístico adotada. Fonte: Adaptado de Camus et al., 2014b.....15
- Figura 4. Destacada em vermelho a área selecionada para o preditor ( $0,5^{\circ}\text{S}$  a  $62,5^{\circ}\text{S}$ ;  $70,5^{\circ}\text{O}$  a  $22,5^{\circ}\text{L}$ ). Fonte: o autor.....17
- Figura 5. Destacado em preto o ponto selecionado como preditando ( $27^{\circ}43'12''\text{S}$ ;  $48^{\circ}4'48''\text{O}$ ). Fonte: o autor.....18
- Figura 6. Vento geostrófico médio (vetores) e PNMM média (área colorida) para o período de 1979 a 2010. Fonte: o autor.....20
- Figura 7. Grades locais utilizadas para avaliação da melhor área de geração de ondas chegando em até um dia na costa. Fonte: o autor.....21
- Figura 8. Esquematização da decomposição da matriz realizada pela singular value decomposition. Fonte: Adaptado de Sumiyoshi et al., (2018).....23
- Figura 9. Esquematização da redução da dimensionalidade dos dados para “k” (número de EOFs que explicam 99% da variância dos dados). Fonte: Adaptado de Sumiyoshi et al., (2018).....24
- Figura 10. Esboço das regiões usadas para diversos índices Niño. Fonte: Trenberth (2019).....30
- Figura 11. A área colorida representa as regiões cujo fluxo de energia chegam à costa catarinense, as linhas cinza e preta (isocronas) representam o tempo de viagem da onda até a região de estudo e as linhas pontilhadas vermelhas dividem a direção em 16 setores. A isocrona de 4 dias encontra-se destacada em amarelo. Fonte: Imagem

desenvolvida no âmbito de uma colaboração entre o <i>Surf and Surge Research Group</i> - Universidade da Cantábria (Espanha) e a Universidade Federal de Santa Catarina (UFSC).....	35
Figura 12. Área pertencente a grade local 4 (laranja) e área regional (verde). Fonte: o Autor.....	38
Figura 13. Comparação entre os modelos de regressão linear no período de calibração para o modelo M24 e ESTELA. Fonte: o Autor.....	39
Figura 14. Comparação entre os modelos de regressão linear no período de validação para o modelo M24 e ESTELA. Fonte: o Autor.....	40
Figura 15. Gráfico de sobreposição da série de ondas gerada para o período de calibração (vermelho), para o período de validação (verde) sobre a série de ondas original (azul), para o modelo ESTELA. Fonte: o Autor .....	41
Figura 16. Gráfico de sobreposição da série de ondas gerada para o período de calibração (vermelho), para o período de validação (verde) sobre a série de ondas original (azul), para o modelo M24. Fonte: o Autor .....	42
Figura 17. A esquerda o histograma de probabilidade de ocorrência de Hs da série gerada pelo modelo M24 e a direita o histograma de probabilidade de ocorrência da série de Hs da base de dados ROW. Fonte: o Autor .....	43
Figura 18. A esquerda o histograma de probabilidade de ocorrência de Tp da série gerada pelo modelo M24 e a direita o histograma de probabilidade de ocorrência da série de Tp da base de dados ROW. Fonte: o Autor .....	43
Figura 19. A esquerda o histograma polar de probabilidade de ocorrência de Dir da série gerada pelo modelo M24 e a direita o histograma polar de probabilidade de ocorrência da série de Dir da base de dados ROW. Fonte: o Autor .....	43
Figura 20. 36 weather-types gerados baseados nas 570 EOFs (unidade em anomalia de pressão). Fonte: Paula Gomes da Silva, 2019.....	45
Figura 21 e Figura 22. Probabilidade de ocorrência de cada WT para todo o período e por estação do ano. Fonte: Paula Gomes da Silva, 2019.....	46
Figura 23. Histogramas de probabilidade de ocorrência de Hs associados a cada WT. Fonte: o Autor .....	46

Figura 24. Histogramas de probabilidade de ocorrência de Tp associados a cada WT. Fonte: o Autor .....	47
Figura 25. Histogramas polares de probabilidade de ocorrência de Dir associados a cada WT. Fonte: o Autor .....	48
Figura 26. Weather-type 10 e seus gráficos de probabilidade de ocorrência de Hs, Tp e Dir associados. Fonte: o Autor .....	49
Figura 27. Weather-type 30 e seus gráficos de probabilidade de ocorrência de Hs, Tp e Dir associados. Fonte: o Autor .....	50
Figura 28. Weather-type 18 e seus gráficos de probabilidade de ocorrência de Hs, Tp e Dir associados. Fonte: o Autor .....	51
Figura 29. Função ortogonal empírica 1 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	52
Figura 30. Função ortogonal empírica 2 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	53
Figura 31. Função ortogonal empírica 3 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	53
Figura 32. Função ortogonal empírica 4 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	54
Figura 33. Função ortogonal empírica 5 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	54
Figura 34. Função ortogonal empírica 6 (mapa) e sua componente principal (gráfico). Fonte: o Autor .....	55
Figura 35. Gráfico ampliado da PC da EOF 1. Fonte: o Autor .....	55

## LISTA DE TABELAS

Tabela 1. Valores encontrados para os períodos de calibração e validação de Hs utilizando a metodologia ESTELA. ....	34
Tabela 2. Valores de correlação obtidos para altura significativa (Hs) durante o período de calibração. ....	36
Tabela 3. Valores de correlação obtidos para altura significativa (Hs) durante o período de validação. ....	36
Tabela 4. Valores de correlação obtidos para período de pico (Tp) durante o período de calibração. ....	37
Tabela 5. Valores de correlação obtidos para período de pico (Tp) durante o período de validação. ....	37
Tabela 6. Valores de correlação obtidos para direção média (Dir) durante o período de calibração. ....	37
Tabela 7. Valores de correlação obtidos para direção média (Dir) durante o período de validação. ....	37
Tabela 8. Valores de correlação de Pearson entre as 6 primeiras EOFs e 9 índices climáticos. ....	56
Tabela 9. Valores de correlação de Pearson para os diferentes CPs analisados. ....	58
Tabela 10. Correlações de Pearson para os diferentes VPs analisados. ....	59
Tabela 11 e Tabela 12. Correlações de Pearson para os diferentes lags analisados para a metodologia ESTELA utilizando dados HR (esquerda) e LR (direita). ....	60
Tabela 13 e Tabela 14. Correlações de Pearson para os diferentes CPs analisados utilizando dados HR (esquerda) e LR (direita). ....	62

## LISTA DE ABREVIATURAS E SIGLAS

- SD – Refinamento estatístico (*Statistical refinamento*)
- DD – Refinamento dinâmico (*Dynamical refinamento*)
- Hs – Altura significativa de onda
- Tp – Período de pico
- Dir – Direção média de onda
- Lag – Tempo de viagem das ondas (em dias) de uma região do oceano até a costa
- GCMs – Modelos de circulação global (*Global circulation models*)
- CP – Período de calibração (*Calibration period*)
- VP – Período de validação (*Validation period*)
- SLP – Pressão ao nível médio do mar (*Sea level pressure*)
- SLPA – Anomalia de pressão ao nível médio do mar (*Sea level pressure anomaly*)
- SVD – Decomposição de valor singular (*Singular value decomposition*)
- PCs – Componentes principais (*Principal component*)
- PCA – Análise de componentes principais (*Principal component analysis*)
- EOF – Função ortogonal empírica (*Empirical orthogonal function*)
- SST – Temperatura da superfície do mar (*Sea surface temperature*)
- CI – Índice climático (*Climate Index*)
- ENSO – *El Niño southern oscillation*
- MEI.v2 – *Multivariate ENSO index version 2*
- SAM – *Southern annular mode*
- ONI – *Oceanic Niño index*
- AAO – *Antarctic oscillation index*
- PDO – *Pacific decadal oscillation index*
- SAOD – *South Atlantic Ocean dipole index*
- TSA – *Tropical South Atlantic index*

AMM – *Atlantic meridional mode index*

SOI – *Southern oscillation index*

CSF – *Climate forecast system*

CFSR – *Climate forecast system reanalysis*

NOAA – *National Oceanic and Atmospheric Administration*

NCEP – *National Centers for Environmental Prediction*

NCAR - *National Center for Atmospheric Research*

GOW – *Global Ocean Waves*

SWAN – *Simulating waves nearshore*

R – *Correlação de Pearson*

EQM – *Erro quadrático médio*

IQM – *Inclinação quadrática média*

IE – *Índice de espalhamento*

MRL – *Modelo de regressão linear*

M24 – *Modelo de lag 2 e grade 4*

WT – *Weather-type*

WC – *Clima de ondas (Wave climate)*

IH-CANTABRIA – *Instituto de hidráulica ambiental da Universidade de Cantabria*

ESTELA - *Evaluating the source and travel time of the wave energy reaching a local area methodology*

SSRG – *Surf and Surge Research Group*

KMA – *Algoritmo de k-médio*

WR – *Waverider Florianópolis*

OLR – *Radiação de onda longa refletida (ongoing longwave radiation)*

## LISTA DE SÍMBOLOS

SLP – Valores de pressão ao nível médio do mar

$\Delta x$  – Distância entre longitudes

$\Delta y$  – Distância entre latitudes

GradX – Gradiente de pressão ao nível médio do mar para a componente longitudinal

GradY – Gradiente de pressão ao nível médio do mar para a componente latitudinal

i – Valor de latitude

j – Valor de longitude

D – Matriz de dados preparados para a análise de decomposição de valor singular

U – Matriz de componentes principais

S – Matriz de valores singulares

V – Matriz de funções ortogonais empíricas

xHs – Vetor de coeficientes para Hs

xTp – Vetor de coeficientes para Tp

xDir – Vetor de coeficientes para Dir

PCs.calibração – Componentes principais utilizadas no período de calibração

Hs.calibração – Valores de Hs da série original para o período de calibração

Tp.calibração – Valores de Tp da série original para o período de calibração

Dir.calibração – Valores de Dir da série original para o período de calibração

Hs.calibração.modelo – Valores de Hs obtidos pelo modelo para o período de calibração

Tp.calibração.modelo - Valores de Tp obtidos pelo modelo para o período de calibração

Dir.calibração.modelo - Valores de Dir obtidos pelo modelo para o período de calibração

PCs.validação - Componentes principais utilizadas no período de validação

Hs.modelo - Valores de Hs obtidos pelo modelo

Tp.modelo - Valores de Tp obtidos pelo modelo

Dir.modelo - Valores de Dir obtidos pelo modelo



## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	1
<b>2. OBJETIVOS</b> .....	4
2.1. OBJETIVO GERAL.....	4
2.2. OBJETIVOS ESPECÍFICOS .....	4
<b>3. FUNDAMENTAÇÃO TEÓRICA</b> .....	5
3.1. CLIMA DE ONDAS.....	5
3.2. REFINAMENTO ESTATÍSTICO.....	5
3.3. ÍNDICES CLIMÁTICOS.....	6
3.4. METODOLOGIA ESTELA.....	7
<b>4. MÉTODOS</b> .....	10
4.1. ÁREA DE ESTUDO.....	10
4.1.1. CLIMA.....	11
4.1.2. REGIME DE ONDAS.....	11
4.2. METODOLOGIA DE REFINAMENTO ESTATÍSTICO.....	12
4.3. DADOS.....	15
4.3.1. Preditor .....	15
4.3.2. Preditando .....	17
4.3.3. Processamento de dados .....	19
4.3.4. Calibração e validação .....	25
4.3.5. Classificação em weather-types .....	28
4.3.6. Correlação com índices climáticos .....	29
<b>5. OUTRAS ANÁLISES REALIZADAS</b> .....	32
5.1. EXECUÇÃO DA METODOLOGIA ESTELA.....	32

5.2. ANÁLISE DE DIFERENTES PERÍODOS DE CALIBRAÇÃO E VALIDAÇÃO .....	33
5.3. TESTE PARA DIFERENTES RESOLUÇÕES ESPACIAIS .....	33
<b>6. RESULTADOS E DISCUSSÃO .....</b>	<b>34</b>
6.1. ESTELA.....	34
6.2. MODELO DE REFINAMENTO ESTATÍSTICO OBTIDO (M24).....	36
6.3. CARACTERIZAÇÃO DO CLIMA DE ONDAS PARA SANTA CATARINA .....	42
6.3.1. Comparação com dados de reanálise validados.....	42
6.3.2. Classificação por weather-types.....	44
6.3.3. Associação dos modos de variabilidade (EOFs) com índices climáticos ...	52
6.4. RESULTADOS DAS OUTRAS ANÁLISES REALIZADAS.....	58
6.4.1. Diferentes períodos de calibração e validação.....	58
6.4.2. Diferentes resoluções espaciais.....	60
<b>7. CONCLUSÃO .....</b>	<b>63</b>
<b>8. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>64</b>

## 1. INTRODUÇÃO

O Estado de Santa Catarina, no Sul do Brasil, concentra 68% da sua população na zona costeira (POLLETE *et al.*, 1995), e possui um litoral com aproximadamente 538 km de linha costa (7% da costa brasileira) (HORN FILHO, 2013). Sua rica fisiografia inclui baías, estuários, enseadas, praias abertas, promontórios e ilhas. A economia local baseia-se no turismo, em atividades agrícolas e industriais, sendo a indústria pesqueira bem desenvolvida, além da existência de três portos importantes, bem como um terminal marítimo operado pela PETROBRAS (ARAÚJO *et al.*, 2003).

De acordo com Araújo *et al.* (2003) este uso intensivo da área costeira do estado exige uma boa compreensão das condições oceanográficas da região. A caracterização minuciosa de climas de ondas é essencial em uma série de setores, tais como transporte marítimo (SEMEDO *et al.*, 2011), indústria offshore (CAMUS *et al.*, 2014), engenharia costeira e oceânica (CALLAGHAN *et al.*, 2008), energias renováveis marinhas (HUGHES e HEAP, 2010), ecologia marinha (STORLAZZI *et al.*, 2005) e gerenciamento costeiro (NICHOLLS *et al.*, 2013).

Estudos de Munk (1947), Munk *et al.* (1963), Barber e Ursell (1948) e Snodgrass *et al.* (1966) contribuíram significativamente para a base científica e introduziram alguns dos paradigmas atualmente aceitos, como a propagação de ondas em grandes círculos e pequena dissipação das ondulações (*swells*). Infelizmente esses estudos foram limitados pela disponibilidade de medidas *in situ*, bem como os de Bacon e Carter (1991, 1993) e vários outros investigadores os quais utilizaram dados de alguns navios e bóias meteorológicas isoladas, que cobriam apenas um curto período de tempo, com longas lacunas e eram insuficientes para descrever a distribuição espacial completa das mudanças no clima de ondas.

Como consequência da limitação de dados, os estudos sobre a variabilidade espacial e temporal do clima de ondas levaram a uma grande melhoria na física dos modelos numéricos. A física melhorada e a disponibilidade de maior poder computacional resultaram em bancos de dados de reanálise de ondas de alta qualidade (RASCLE *et al.* 2008; REGUERO *et al.*, 2012). Os dados homogêneos e contínuos de *hindcasts* (modelos matemáticos) superam as limitações dos dados

instrumentais, sendo uma ferramenta útil para melhorar nossa compreensão sobre propagação de ondas ao redor do globo (PÉREZ *et al.*, 2014). As bóias fornecem dados mais confiáveis, no entanto, seus registros geralmente não possuem mais de 20 anos, têm lacunas notáveis e estão muito dispersos no mar. As observações por satélite, que apresentam uma cobertura global, só estão disponíveis a partir de 1992 e com uma resolução temporal não regular. Sendo assim, as bases de dados de reanálise de ondas tornaram-se uma valiosa fonte de informação (CAMUS *et al.*, 2014).

Assim como para os dados de onda, as reanálises atmosféricas também tiveram seus modelos aprimorados ao longo do tempo. A partir dos dados gerados por esses modelos sofisticados é possível definir o clima de ondas para diferentes locais. Os métodos adotados para esse procedimento são geralmente o refinamento dinâmico (*dynamical downscaling* - DD) e o refinamento estatístico (*statistical downscaling* - SD). O DD consiste no uso de simulações regionais de alta resolução para extrapolar dinamicamente os efeitos dos processos climáticos em larga escala para escalas regionais ou locais de interesse (KNUTSON *et al.*, 2013). Os métodos de SD baseiam-se na relação entre o clima de ondas local (preitando) e os padrões atmosféricos sobre uma região (preditor) (WANG *et al.*, 2004; IZAGUIRRE *et al.*, 2012; CASAS-PRAT *et al.*, 2014).

A principal vantagem da abordagem estatística é ter um custo computacional extremamente baixo, sendo, portanto, adequado para uma caracterização mais rápida do preitando, para realizar simulações de longo prazo, ou para desenvolver múltiplas realizações de diferentes condições de forçantes (por exemplo, cenários de mudanças climáticas) (CAMUS *et al.*, 2014).

Diferentes abordagens podem ser aplicadas para desenvolver um modelo de SD. Giorgi *et al.* (2001) classificaram os métodos em: (i) funções de transferência, (ii) abordagem de *weather-types* (WTs) e (iii) geradores climáticos estocásticos. O desempenho dessas técnicas pode ser encontrado em um grande número de trabalhos para diferentes regiões do globo usando uma ampla gama de preitados. Por exemplo, Gutiérrez *et al.* (2013) compararam os desempenhos de diferentes métodos de SD para temperaturas na Espanha.

Cada método tem seus próprios pontos fortes e fracos, reproduzindo certas características estatísticas do preditando com mais ou menos precisão, sendo difícil selecionar um contra o outro, sempre dependendo de cada caso particular (CAMUS *et al.*, 2014).

Nesse contexto, o presente estudo tem como objetivo caracterizar o clima de ondas de Santa Catarina no intervalo entre 1979 a 2010, utilizando a metodologia de refinamento estatístico com abordagem de *weather-types*, a fim de auxiliar na compreensão e no aprimoramento do método em questão e verificar a aplicabilidade do mesmo para a costa catarinense, uma vez que essa metodologia de análise ainda não foi empregada em estudos no local.

## 2. OBJETIVOS

### 2.1. OBJETIVO GERAL

Caracterizar o clima de ondas de Santa Catarina no intervalo entre 1979 a 2010 utilizando a metodologia de refinamento estatístico com abordagem de *weather-types*, a fim de auxiliar na compreensão e no aprimoramento do método em questão e verificar a aplicabilidade do mesmo para a costa catarinense.

### 2.2. OBJETIVOS ESPECÍFICOS

a) Utilização dos resultados já existentes da metodologia “*evaluating the source and travel time of the wave energy reaching a local area*” (ESTELA) para identificação das regiões oceânicas que influenciam no clima de ondas da costa catarinense para a delimitação do preditor.

b) Relação dos diferentes estados de mar com o respectivo *weather-type* responsável por sua geração (estabelecimento da conexão preditor-preditando).

c) Validação do clima de ondas encontrado comparando com dados de reanálise ROW utilizando parâmetros estatísticos descritos na literatura.

### **3. FUNDAMENTAÇÃO TEÓRICA**

#### **3.1. CLIMA DE ONDAS**

O clima de ondas (WC) pode ser definido como a característica estatística de longo prazo dos seguintes parâmetros: altura significativa de onda ( $H_s$ ), período de pico ( $T_p$ ) e direção média ( $Dir$ ) das ondas de um local em questão (HOLTHUIJSEN, 2007). É regido tanto por ondas geradas pela ação de ventos locais (vagas), quanto por ondas de tempestades distantes (marulhos) (SVERDRUP & MUNK, 1946). Essas ondas são geradas por ventos que sopram sobre a superfície do mar e suas características dependem da intensidade, duração e pista do vento (SVERDRUP & MUNK, 1946). À medida que deixam a área de geração, elas se propagam a velocidades que dependem do seu comprimento de onda, viajando longas distâncias sem uma significativa dissipação de energia. A dissipação da energia ocorre nas regiões costeiras e é a principal força motriz da dinâmica dos sistemas costeiros, controlando as características morfológicas do litoral (KOMAR, 1998).

Além dos processos morfodinâmicos costeiros, o conhecimento do clima de ondas de diferentes regiões torna-se cada vez mais importante devido ao crescente uso de áreas costeiras. Por ser o lar de aproximadamente 70% da população mundial (CHERFAS, 1990), as atividades nas áreas costeiras demandam a compreensão das condições forçantes regionais. Assim, a necessidade de dados precisos de ondas há muito tempo tem incentivado os estudos sobre a geração e a propagação de ondas oceânicas globais.

#### **3.2. REFINAMENTO ESTATÍSTICO**

O refinamento estatístico é baseado na premissa de que um clima local é condicionado por dois fatores: o estado climático de larga escala e características fisiográficas regionais/locais (por exemplo, topografia, distribuição continente-oceano e batimetria) (VON STORCH, 1995, 1999). A partir dessa perspectiva, a informação climática local é derivada, primeiramente, pela determinação de um modelo estatístico

que relacione as variáveis atmosféricas (preditores) de larga escala às variáveis locais (preditandos). De acordo com FOWLER *et al.* (2007) um dos aspectos mais relevantes e que determina a eficiência do método de SD é a escolha do preditor em relação às variáveis e ao domínio espacial. Os conjuntos preditores são tipicamente derivados da pressão ao nível médio do mar (SLP), altura geopotencial, campos de vento, umidade absoluta ou relativa e variáveis de temperatura, sua escolha dependendo sempre do preditando em questão. Essas variáveis são normalmente provenientes de modelos climáticos operacionais e de reanálise. Em seguida, o preditor escolhido alimenta o modelo estatístico para estimar as características climáticas locais correspondentes (WILBY *et al.*, 2004). No caso das ondas de superfície do mar, os campos de SLP e os campos de gradiente SLP ao quadrado demonstraram ser bons preditores (WANG *et al.*, 2012; CASAS-PRAT *et al.*, 2014).

Uma das principais vantagens das técnicas de refinamento estatístico é que elas envolvem um baixo custo computacional e, portanto, podem ser facilmente aplicadas aos *outputs* de diferentes rodadas de *Global Circulation Models* (GCMs) (CAMUS *et al.*, 2014). Outra vantagem é que elas podem ser usadas para fornecer informações específicas do local, o que pode ser crítico para muitos estudos de impacto das mudanças climáticas. A principal fraqueza teórica dos métodos de SD é que sua suposição básica não é verificável, ou seja, as relações estatísticas desenvolvidas para o clima atual também se mantêm sob as diferentes condições de forçamento de possíveis climas futuros - uma limitação que também se aplica às parametrizações físicas de modelos dinâmicos.

### 3.3. ÍNDICES CLIMÁTICOS

Um índice climático (CI) pode ser definido como um valor usado para descrever o estado e as variações do clima. Cada CI é baseado em certos parâmetros e descreve apenas determinados aspectos do clima. Portanto, há uma variedade de índices climáticos que foram definidos e examinados em numerosas publicações. Para cada índice climático existe uma equação definidora que usa os chamados “elementos



climáticos”. Estes são parâmetros mensuráveis que influenciam as propriedades do sistema climático, principalmente, por exemplo, parâmetros atmosféricos como pressão do ar, temperatura do ar, precipitação e radiação solar, mas também parâmetros não atmosféricos como temperatura da superfície do mar ou cobertura de gelo. Tais índices permitem um estudo estatístico das variações dos aspectos climatológicos dependentes, como análise e comparação de séries temporais, médias, extremos e tendências (ICDC, 2019).

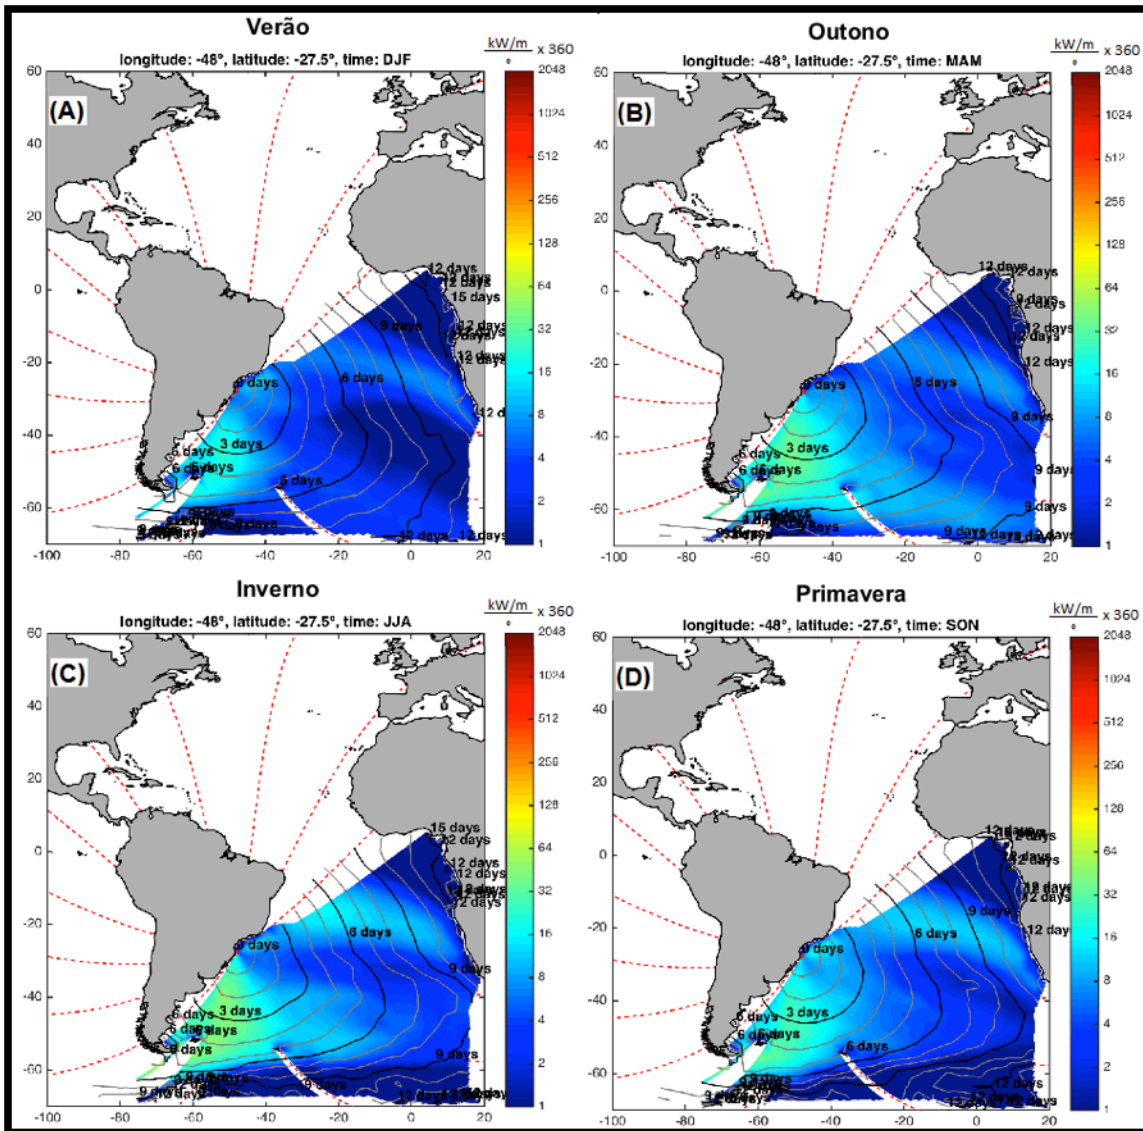
Os CIs utilizados nesse estudo foram *Southern Oscillation Index (SOI)*, *Pacific Decadal Oscillation (PDO)*, *Antartic Oscillation (AAO)*, *Multivariate ENSO Index Version 2 (MEI.v2)*, *Oceanic Niño Index (ONI)*, *Niño 3.4 Index*, *South Atlantic Ocean Dipole (SAOD)*, *Tropical South Atlantic (TSA)* e *Atlantic Meridional Mode (AMM)*.

### 3.4. METODOLOGIA ESTELA

O objetivo da metodologia “*evaluating the source and travel time of the wave energy reaching a local area*” (ESTELA) é caracterizar as regiões oceânicas que influenciam na dinâmica de ondas de qualquer local costeiro específico em todo o mundo (PÉREZ *et al.*, 2014). Entre as características que a metodologia calcula estão: o fluxo de energia ( $\text{kW/m}^{\circ}$ ) em direção a costa proveniente de cada ponto de grade analisado e o tempo de viagem (em dias) das ondas de sua origem até o destino sendo estudado (lag), no caso as coordenadas  $48^{\circ}\text{S } 27,5^{\circ}\text{O}$  (aproximadamente o centro do litoral de Santa Catarina). O método é baseado em uma análise de escala global usando critérios baseados geograficamente e fisicamente. Os critérios geográficos baseiam-se no pressuposto de que as ondas de águas profundas percorrem grandes trajetórias circulares. Isso limita a área de influência, negligenciando a energia que não pode atingir o ponto alvo, pois seu caminho é bloqueado pela terra. As partições espectrais individuais de uma reanálise global de ondas são usadas para reconstruir as informações espectrais e aplicar os critérios fisicamente baseados, os quais selecionam a fração de energia que viaja em direção ao ponto de destino para cada ponto de grade analisado (PÉREZ *et al.*, 2014).

Os resultados pré-existentes provenientes do método servem como delimitadores, do domínio espacial e temporal, das áreas geradoras de ondas que chegam até a costa de Santa Catarina (Figura 1). É possível notar que em todas as estações do ano a região do Sul do Brasil até o sul da Argentina contribui com a maior parte da energia de ondas que chega à costa do estado, o que corrobora com as áreas de ciclogênese identificadas por Gan & Rao (1991). Pode-se notar também que a região à nordeste do Atlântico Sul tem participação considerável na quantidade de energia propagada à costa no inverno e na primavera. Além disso, é possível identificar uma pequena região à nordeste da costa catarinense, principalmente durante a primavera, que é responsável pelas vagas, isto é, estados de mar gerados por ventos locais.

Figura 1. Mapa do fluxo de energia sazonal que se propaga para a costa catarinense.



Fonte: Imagens cedidas por Fernando Javier Méndez Incera através de comunicação pessoal.

## 4. MÉTODOS

### 4.1. ÁREA DE ESTUDO

Estendendo-se entre os paralelos 25°57'41" e 29°23'55" de latitude sul e entre os meridianos de 48°19'37" e 53°50'00" de longitude oeste (IBGE, 2000), Santa Catarina faz fronteira ao norte com o estado do Paraná, ao sul com o Rio Grande do Sul e a oeste com a Argentina (SANTA CATARINA, 2006) (Figura 2). Seu litoral localiza-se a leste, é banhado pelo Oceano Atlântico, apresenta uma vasta diversidade de ecossistemas costeiros que se estendem por aproximadamente 538km de costa (HORN FILHO, 2013) e é densamente populado (POLLETE *et al.*, 1995).

Figura 2. Localização geográfica de Santa Catarina, com destaque para sua linha de costa, no Sul do Brasil.



Fonte: João Pedro Steil, 2018.

#### 4.1.1. CLIMA

As características meteorológicas da região são consideradas de clima mesotérmico subtropical (NIMER, 1989) e são regidas pelo sistema semifixo de alta pressão chamado alta subtropical do Atlântico Sul (ASAS), cujo resultado são ventos de norte/nordeste, simultaneamente ao efeito local da brisa marítima (MONTEIRO & FURTADO, 1995), sendo influenciada também por ciclones relacionados à passagem de frentes frias e anticiclones extratropicais (SIEGLE & ASP, 2007). Santa Catarina é comumente atingida por cerca de três a quatro frentes frias por mês, as quais se deslocam no sentido sudoeste/nordeste, acompanhadas de ventos intensos que sopram dos quadrantes sul/sudoeste (RODRIGUES *et al.*, 2004). Tais ventos associados à passagem das frentes frias são normalmente mais fortes durante os meses de outono e inverno devido a maior intensidade e frequência de ciclogênese (NIMER, 1989; GAN & RAO, 1991), refletindo, conseqüentemente, em eventos de alta energia de ondas mais frequentes (PIANCA *et al.*, 2010).

#### 4.1.2. REGIME DE ONDAS

A costa de Santa Catarina está voltada para leste em direção ao oceano Atlântico e de acordo Araújo *et al.* (2003) recebe ondulações de cinco direções provenientes de cinco sistemas diferentes. A alta tropical do Atlântico Sul gera vagas de Leste/Nordeste com períodos entre 3 e 8 segundos e alturas de onda entre 0,5 e 1,5 m, as quais ocorrem 10% do tempo. Ondas de Leste geradas pela alta subtropical do Atlântico Sul são as mais comuns, compondo 50% dos estados de mar verificados no litoral catarinense, com Hs entre 1,0 e 1,5 m e Tp entre 6 e 11 s. Marulhos de Sul/Sudeste de longos períodos (7 a 16 s) chegam a costa 25% do tempo com alturas entre 1 e 2 m. Frentes frias, por sua vez, antes de sua passagem ocasionam vagas de Norte/Nordeste com Tp de 4 a 5 s, e após sua passagem geram ondas de Sul com Hs de 1 a 3,5 m, Tp entre 4 e 8 s. Os estados de mar gerados por frente frias prevalecem em 10% do tempo em Santa Catarina. Em se tratando de valores extremos, ondas de até 13,8 m (Hs de 7,2 m) já foram registradas no litoral de Santa Catarina, como

relatado por Melo Filho *et al.* (2006), resultado de eventos extremos que causaram prejuízos para a população.

Araújo *et al.* (2003) também estudaram a ocorrência simultânea de vagas e marulhos e relataram que mais de 32% dos estados de mar apresentam mais de um pico na região, sendo que os mares bi-modais são responsáveis por 97% desses casos. Ao separarem as ocorrências por estação do ano verificaram que no inverno em aproximadamente 24% do tempo ocorrem mares bi-modais, comparados a 38% no verão. Para outono e primavera encontraram frequências similares em média de 32% dos casos.

Alves (1996), Alves e Melo (2001), Araújo *et al.* (2003), Klein (2004), Miot da Silva (2006), Hesp *et al.* (2009), Signorin (2010) e Pianca *et al.* (2010) resumiram o clima de ondas de Santa Catarina como tendo uma ondulação sul dominante com um período de 12 s e altura média entre 1 e 1,5 m, aumentando para 2 m no inverno, enquanto mares gerados localmente chegam de leste a nordeste com um Período de 7 s e altura média de 1-1,25 m, particularmente durante o outono e inverno.

## 4.2. METODOLOGIA DE REFINAMENTO ESTATÍSTICO

Trabalhando com o clima de ondas, o objetivo de um método de refinamento estatístico é estimar as ondas locais (preeditando) a partir de condições atmosféricas globais (preditor), com base em uma relação estatística. A metodologia adotada nesse estudo utilizou dados de reanálise de 1979 a 2010, pois, de acordo com Sterl (2004), somente após 1980 pode-se assumir uma homogeneidade na cobertura de dados no hemisfério sul e os dados da reanálise de SLP do CFSR pararam de ser atualizados em 2010. Foi feita uma adaptação da estrutura de SD proposta por Camus *et al.* (2014) (Figura 3), que consiste em 5 principais etapas:

### 1) Coleta de dados históricos para preditor e preeditando

O preditor utilizado nesse estudo foi a pressão ao nível médio do mar do produto de reanálises do *Climate Forecast System Reanalysis* (CFSR). Essa base de dados será abordada com maiores detalhes na seção 4.3.1. Esses dados são disponibilizados

pela NOAA pelo endereço [https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/climate-forecast-system-version2-cfsv2#CFS%20Reanalysis%20\(CFSR\)](https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/climate-forecast-system-version2-cfsv2#CFS%20Reanalysis%20(CFSR)).

Para o preditor foram coletados dados históricos de onda, provenientes da base de dados de reanálise IH-DATA de ondas em escala local ROW. Essa base de dados será abordada com maiores detalhes na seção 4.3.2. Os referidos dados de onda podem ser adquiridos mediante requisição ao IH-Cantabria.

## 2) Delimitação do preditor

O domínio espacial e a cobertura temporal do preditor devem ser especificados para cada local onde os parâmetros da série de ondas forem refinados. O domínio espacial deve cobrir a área da bacia oceânica da geração de ondas que atinge essa localização específica. Condições históricas recentes devem ser incluídas no preditor para levar em conta os processos de geração e propagação das ondas atingindo um local específico (CAMUS *et al.* 2014).

Através dos resultados obtidos através do método ESTELA (evaluating the source and travel time of the wave energy reaching a local area) (PÉREZ *et al.*, 2014), cedidos por Fernando Javier Méndez Incera através de comunicação pessoal, foi possível delimitar a grade do preditor para as regiões oceânicas que influenciam no clima de ondas da costa catarinense.

## 3) Calibração e Validação do modelo de refinamento estatístico

Após o processamento dos dados do preditor, uma matriz foi criada para a realização da decomposição de valor singular (SVD) (seção 4.3.3). Como resultado da SVD foram obtidas as componentes principais (*principal components* - PCs), que reduzem a dimensionalidade dos dados e simplificam o processo de classificação. Foram obtidas também as funções ortogonais empíricas (*empirical orthogonal functions* - EOFs) do preditor e a matriz de valores singulares.

Para testar a eficiência das diferentes condições adotadas (no presente estudo foram testadas 50 combinações de condições), modelos de regressão linear para os parâmetros Hs, Tp e Dir foram implementados para os períodos selecionados para calibração e validação.

Cada modelo de regressão linear gerou sua própria série de Hs, Tp e Dir, para ambos os períodos, as quais foram comparadas com a base de dados de reanálise de ondas ROW por meio do Coeficiente de correlação de Pearson (R). O modelo que gerou os resultados mais próximos da série original foi selecionado para as etapas 4 e 5, para as demais análises realizadas no presente trabalho, inclusive análise de outros parâmetros estatísticos como Erro Quadrático Médio (EQM), Viés, Índice de Espalhamento (IE) e Inclinação Quadrática Média (IQM).

#### 4) Classificação dos dados de pressão ao nível médio do mar em weather-types

A classificação em WTs é obtida combinando técnicas de “mineração de dados” que foi realizada durante a SVD. As EOFs obtidas foram então agrupadas utilizando o algoritmo de k-médio (*k-means algorithm* - KMA). O KMA divide o espaço de dados em um número de grupos, cada um definido por um protótipo e formado pelos dados para os quais o protótipo é o mais próximo (HASTIE *et al.*, 2001). Combinando as funções ortogonais empíricas agrupadas pelo algoritmo, foram gerados os WTs. Por fim, esse conjunto de weather-types foi organizado utilizando um critério de similaridade (CAMUS *et al.*, 2014).

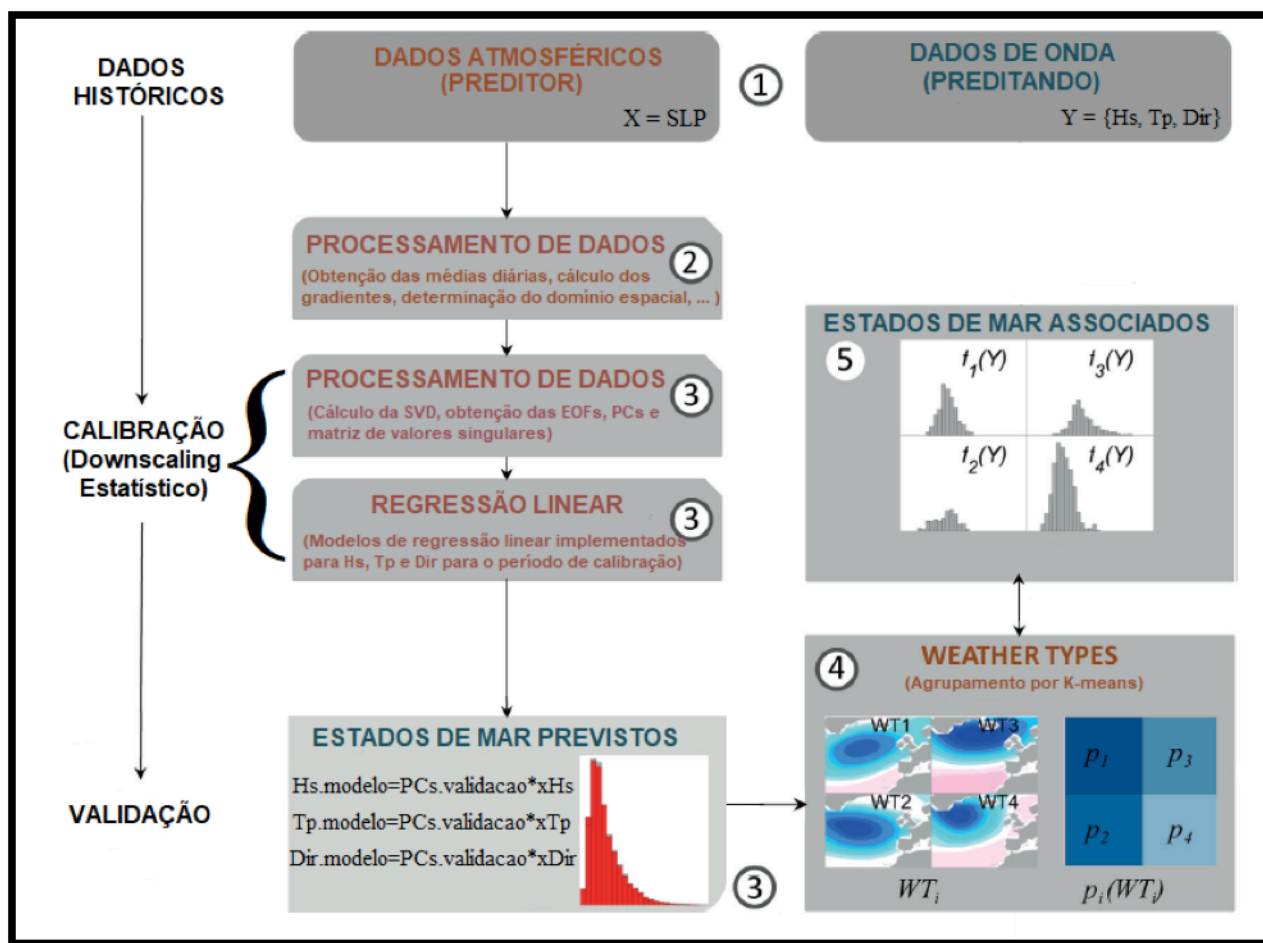
#### 5) Estabelecimento da relação entre preditor e preditando

Os dados históricos de ondas, por sua vez, sofreram uma divisão em diferentes estados de mar. Cada condição do mar foi projetada sobre os diferentes *weather-types* de forma comparativa. Ao final das projeções, cada estado de mar com seus próprios parâmetros de Hs, Tp, e Dir teve sua geração associada a um WT.

Para todos os cálculos e análises acima citados foi utilizada apenas a ferramenta estatística e gráfica MATLAB.



Figura 3. Fluxograma representando a metodologia de refinamento estatístico adotada.



Fonte: Adaptado de Camus et al. (2014b).

### 4.3. DADOS

#### 4.3.1. Preditor

O objetivo dos projetos de reanálises é produzir análises globais de campos atmosféricos. Para isso, os projetos assimilam dados de diversas fontes, tais como estações meteorológicas em superfície, radiossondas, navios, satélites, aeronaves e outras. Estes dados são cedidos por diferentes países e organizações de todo o mundo (KALNAY *et al.*, 1996).

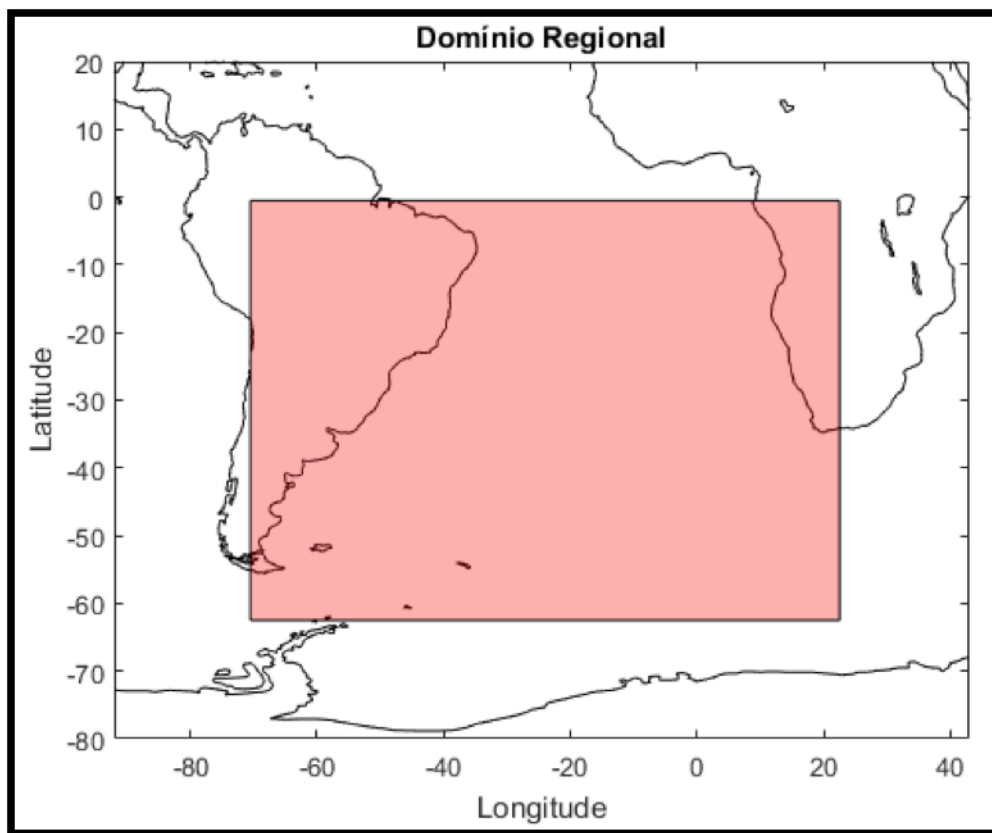
De acordo com Wang *et al.* (2012) e Casas-Prat *et al.* (2014), os dados de SLP e gradiente de SLP ao quadrado, em escala temporal diária, demonstraram ser ótimos

preditores para a identificação de ondas da superfície do mar, por representarem as condições do vento geostrófico. Este fator é especialmente relevante para aplicações de projeções climáticas, já que a variável SLP é supostamente menos tendenciosa do que os campos de vento dos GCMs (CAIRES *et al.*, 2006). Portanto, nesse estudo o dado de larga escala escolhido como preditor foi pressão ao nível médio do mar do produto de reanálises do *Climate Forecast System Reanalysis* (CFSR) do *National Centers for Environmental Prediction* (NCEP) para 1979-2010 (SAHA *et al.*, 2010). Esses dados consistem em campos de grades globais de 0,5° por 0,5° longitude-latidade com resolução temporal horária. Esta reanálise foi executada com alta resolução, acoplando dados do sistema oceano-atmosfera e gelo da superfície do mar.

Os dados são fornecidos no formato *.grib* (*General Regularly-distributed Information in Binary Form*) e para sua utilização foi necessária a conversão para o formato NetCDF (*Network Common Data Form*), feita através da ferramenta NCTOOLBOX (SCHLINING *et al.*, 2009), que está disponível online no endereço: <https://github.com/nctoolbox/nctoolbox/releases>. Uma vez no formato NetCDF, as variáveis (latitude, longitude, SLP e data) puderam ser extraídas diretamente pelas funções próprias do software MATLAB.

O domínio espacial foi selecionado de forma a contemplar todas as regiões identificadas como contribuintes com fluxo de energia para a costa de Santa Catarina pela rotina ESTELA. Sendo assim, os dados adquiridos abrangem de 0,5°S a 62,5°S e 70,5°O a 22,5°L (Figura 4), englobando tanto as regiões oceânicas identificadas pela rotina, quanto uma área excedente para a garantia que não haveria perda de informação proveniente dessas áreas durante as análises.

Figura 4. Destacada em rosa a área selecionada para o preditor ( $0,5^{\circ}\text{S}$  a  $62,5^{\circ}\text{S}$ ;  $70,5^{\circ}\text{O}$  a  $22,5^{\circ}\text{L}$ ).



Fonte: o autor.

#### 4.3.2. Preditando

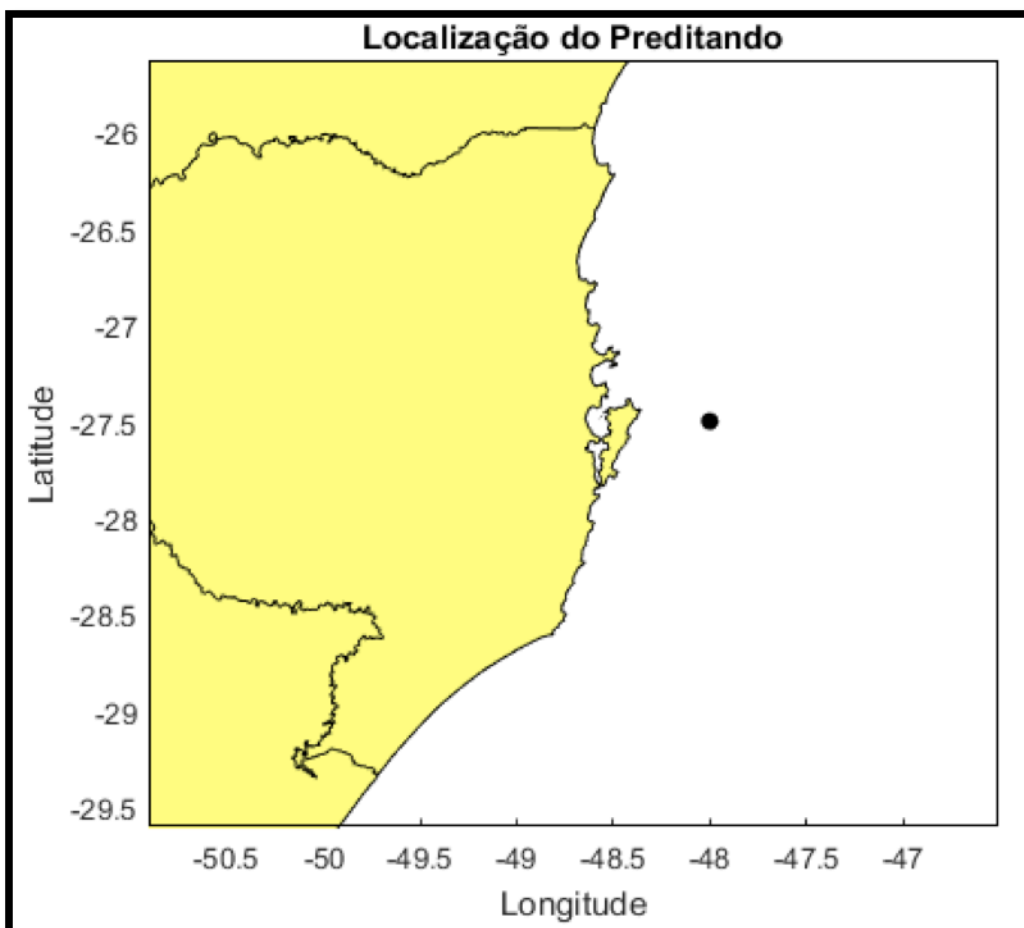
Como o objetivo deste trabalho é a obtenção de um clima de ondas para Santa Catarina, o preditando selecionado foi o ponto singular de coordenadas  $27^{\circ}43'12''\text{S}$  e  $48^{\circ}4'48''\text{O}$  (Figura 5), o mesmo utilizado por Araújo et al. (2003) e Melo et al. (2005), aproximadamente o ponto central da costa catarinense. Para esse ponto foram adquiridos dados históricos dos parâmetros de onda ( $H_s$ ,  $T_p$  e  $Dir$ ), provenientes da base de dados de reanálise IH-DATA de ondas em escala local ROW (RODRÍGUEZ & IZAGUIRRE, 2016), cedidos pelo IH-CANTABRIA.

A caracterização histórica das ondas nessa área é complexa, pois os dados das observações não são homogêneos nem no espaço nem no tempo. Tendo isto em vista, torna-se apropriado introduzir o conceito de bóia virtual como um ponto de reanálise

em que, usando um modelo numérico, a série histórica de ondas em um local específico é simulada (RODRÍGUEZ & IZAGUIRRE, 2016), pois é necessária uma longa série de dados para o procedimento de calibração. A geração da base de dados ROW inclui a modelagem de ondas em águas rasas, utilizando o modelo *Simulating Waves Nearshore* (SWAN) na sua versão 41.01, forçado com ventos de alta resolução (SWStaCatarina) (RODRÍGUEZ & IZAGUIRRE, 2016), ondas do modelo *Global Ocean Waves* (GOW) (REGUERO *et al.*, 2012) e usando informações batimétricas detalhadas.

Os dados de ondas ROW já são validados por Rodríguez e Izaguirre (2016) com medições instrumentais da bóia costeira WR.

Figura 5. Destacado em preto o ponto selecionado como preditando ( $27^{\circ}43'12''S$ ;  $48^{\circ}4'48''O$ ).



Fonte: o autor.

#### 4.3.3. Processamento de dados

Os dados históricos de SLP adquiridos do CFSR tem resolução temporal horária. Para a realização dos procedimentos estatísticos foi necessário calcular as médias diárias dos campos de pressão para todos os 32 anos que foram analisados (1979-2010).

Em seguida foram calculados os gradientes de SLP para todos os pontos do domínio escolhido, os quais foram obtidos através da derivada centrada, que por sua vez pode ser obtida pelas seguintes fórmulas:

$$GradX = \frac{SLP(i, j + 1) - SLP(i, j - 1)}{2 * \Delta x(i, j)}$$

$$GradY = \frac{SLP(i + 1, j) - SLP(i - 1, j)}{2 * \Delta y(i, j)}$$


Sendo que “i” se refere às latitudes e “j” às longitudes sendo analisadas para cada ponto da grade.

Neste procedimento, para o cálculo de  $\Delta x$  e  $\Delta y$ , foi utilizada a função `dist2.m` (NABNEY, 2001) (Anexo 1), que calcula a distância entre duas latitudes e duas longitudes selecionadas, sendo assim possível automatizar o cálculo dos gradientes para todos os pontos da grade. Esta função está disponível em <http://www.mathworks.com/matlabcentral/mlc-downloads/submissions/2654/versions/1/previews/dist2.m/index.html>.

Como passo seguinte, a fim de se fazer uma análise qualitativa do preditor, foi feita uma média da SLP e gradiente de SLP para todo o período. Tais dados foram comparados ao padrão atmosférico dominante da região. O vento geostrófico médio foi então obtido a partir do gradiente. Assim, observou-se a predominância de uma alta

pressão sobre o oceano Atlântico Sul, o que está de acordo com o domínio do sistema semifixo ASAS inferido por (MONTEIRO & FURTADO, 1995), bem como a predominância dos ventos de Norte/Nordeste na região de Santa Catarina. Mais ao norte do Brasil pode-se notar o predomínio dos alísios. Por fim, confirmou-se a qualidade dos dados e procedimentos realizados.

Figura 6. Vento geostrófico médio (vetores) e PNMM média (área colorida) para o período de 1979 a 2010.



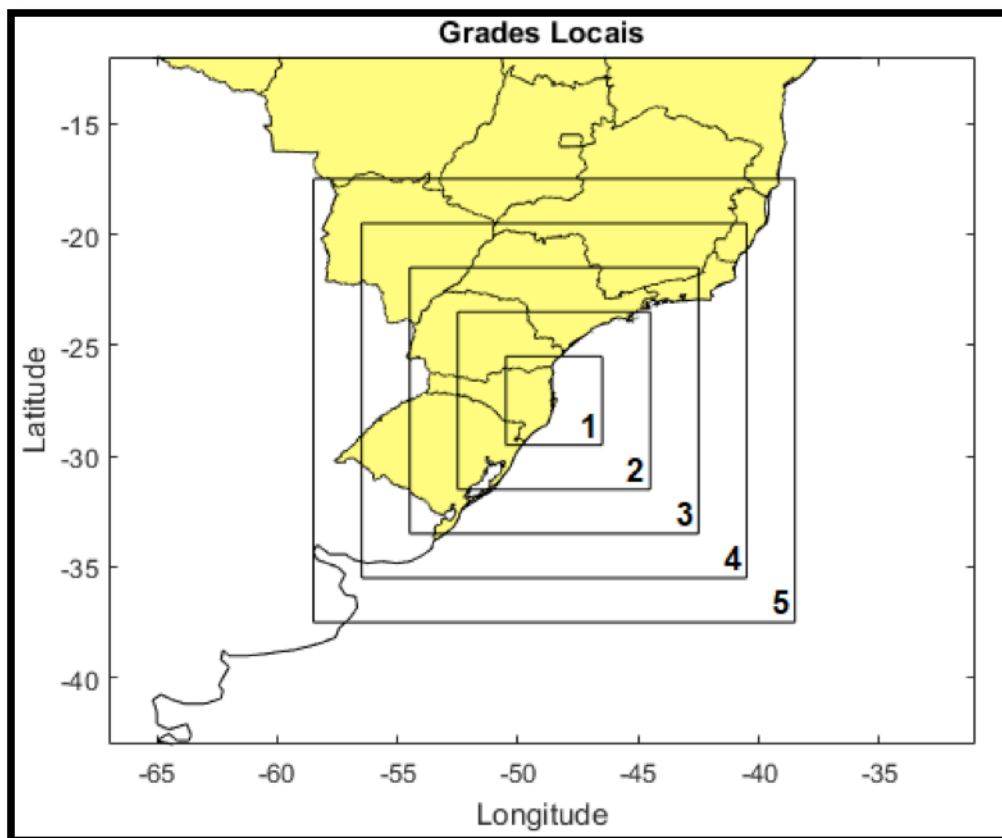
Fonte: o autor.

Os pontos sobre o continente dentro do domínio selecionado foram desconsiderados, de forma a evitar o forte modo de variabilidade do gradiente de pressão (o procedimento também foi adotado para SLP) nas regiões sobre terra, como descrito por Camus *et al.* (2014b). Para eliminar os pontos de grade que não estão sobre o oceano, foi utilizada a função `landmask.m` (GREENE, 2014) (Anexo 2) disponível em <https://www.mathworks.com/matlabcentral/fileexchange/48661->

landmask, que, de forma sucinta, retorna 1 para pontos sobre a terra e 0 para pontos sobre água, possibilitando assim aplicar a máscara continental à grade de dados.

Por fim, as matrizes de pressão ao nível médio do mar e gradiente de pressão ao nível médio do mar foram utilizadas para estruturar outras matrizes, as quais passaram pelo processo de SVD. A estruturação dessas matrizes contempla, a fim de melhor representar o tempo de viagem das ondas de sua região de geração até a costa (CAMUS *et al.*, 2014b), uma grade local, na qual admite-se que as ondas geradas dentro do perímetro da grade chegam em até um dia no litoral e, para as ondas fora da grade local, ou seja, pertencentes a grade regional, foram testados intervalos de 1 até 10 dias de viagem (*lag*) com o intuito de achar o tamanho de grade e local e intervalo de viagem das ondas mais adequado para a região de estudo. Nesse trabalho foram utilizados 5 diferentes tamanhos de grade local, os quais estão representados na Figura 7.

Figura 7. Grades locais utilizadas para avaliação da melhor área de geração de ondas chegando em até um dia na costa.



Fonte: o autor.

O tamanho das grades locais foi baseado nas coordenadas relativas das isocronas obtidas nos resultados da rotina ESTELA. Foram escolhidas coordenadas internas à isocrona de 1 dia (grade 1) até coordenadas entre a isocrona de 3 e 4 dias (grade 5). As grades e suas respectivas coordenadas são:

- 1) Grade Local 1: 25,5°S a 29,5°S e 50,5°O a 46,5°O;
- 2) Grade Local 2: 23,5°S a 31,5°S e 52,5°O a 44,4°O;
- 3) Grade Local 3: 21,5°S a 33,5°S e 54,5°O a 42,5°O;
- 4) Grade Local 4: 19,5°S a 35,5°S e 56,5°O a 40,5°O;
- 5) Grade Local 5: 17,5°S a 37,5°S e 58,5°O a 38,5°O.

A estruturação das matrizes para a SVD se dá de forma que os valores de SLP dentro da grade local são, coluna por coluna, colocados em linha na nova matriz. Na sequência o mesmo procedimento é executado para os valores de gradiente de SLP. Depois os pontos da grade regional de SLP são organizados da mesma forma e colocados em sequência na mesma linha, por fim seguidos pelos pontos da grade regional de gradiente de SLP. De forma resumida, a nova matriz apresenta mapas em suas linhas e séries temporais, de cada ponto da grade, em suas colunas.

No total foram criadas 50 matrizes contemplando as condições supracitadas a fim de verificar qual dos parâmetros adotados retornaria o melhor resultado.

Após a estruturação das matrizes, elas foram submetidas a decomposição de valor singular (SVD), que consiste em um método de decomposição de matriz para reduzi-la às suas partes constituintes, a fim de tornar certos cálculos matriciais subsequentes mais simples. Ela é uma generalização da autodecomposição que pode ser usada para analisar matrizes retangulares (a autodecomposição é definida apenas para matrizes quadradas). Por analogia com a autodecomposição, que decompõe uma matriz em duas matrizes simples, a ideia principal da SVD é decompor uma matriz retangular em três matrizes simples: duas matrizes ortogonais e uma matriz diagonal.




Por fornecer uma estimativa mínima quadrada de uma determinada matriz por uma matriz de classificação inferior de mesmas dimensões, a SVD é equivalente à análise de componentes principais (PCA) e funções ortogonais empíricas (EOF) e é, portanto, uma ferramenta essencial para análise multivariada (ABDI, 2007). O software MATLAB possui dentro de suas ferramentas uma função que permite o cálculo da decomposição singular de uma matriz através da seguinte sentença:

$$[U S V] = svd(D, 0)$$

Onde “D” é a matriz de dados “m × n” que deseja-se decompor, “U” é uma matriz “m × m”, “S” é uma matriz diagonal “m × n”, e “V” é a transposta de uma matriz “n × n”, como exemplificado na Figura 8.

Figura 8. Esquematização da decomposição da matriz realizada pela singular value decomposition.




Fonte: Adaptado de Sumiyoshi et al., (2018).

As colunas de “V” são as EOFs (funções ortogonais empíricas). Elas estão organizadas em ordem decrescente de representação da variância dos dados, ou seja, a primeira EOF é responsável pela maior parte dessa variância. As EOFs podem ser interpretadas como modos de variabilidade, pois o método encontra padrões espaciais nas séries temporais (BJORNSSON & VENEGAS, 1997).

As colunas da matriz “U” são chamadas de PCs (componentes principais). Elas estão diretamente relacionadas com as EOFs. Cada PC mostra como sua respectiva EOF varia no tempo, funcionando como um índice para a mesma.

Os valores diagonais na matriz “S” também estão diretamente relacionados com as EOFs. Eles são conhecidos como os valores singulares da matriz original “D”. Antes da SVD ser realizada, é indicado subtrair a média de cada série temporal dos valores da série, ou seja, transformar a média de cada série temporal em 0, assim nas diagonais de “S” obtém-se os valores de desvio padrão de cada EOF, os quais, se elevados ao quadrado, representam a variância. No presente estudo, foi utilizado também o gradiente de SLP na matriz de SVD, então para obter esse resultado é necessário também dividir cada série temporal por seu respectivo desvio padrão. Por fim, após a aplicação da SVD às 50 matrizes, foi possível obter os principais modos climáticos responsáveis pelas alterações na circulação atmosférica (EOFs), seus respectivos índices (PCs) e a variância no conjunto de dados explicada por cada um deles. Nesse estudo foi considerada uma variância de 99%, ou seja, as outras que EOFs que explicam o 1% restantes da variância foram descartadas, como ilustrado na Figura 9, sendo “k” o número de EOFs necessárias para alcançar a porcentagem de variância que se deseja explicar. De acordo com Camus *et al.* (2014), com esse procedimento é possível reduzir a dimensionalidade dos dados e manter um alto valor de explicação da variância.

Figura 9. Esquematização da redução da dimensionalidade dos dados para “k” (número de EOFs que explicam 99% da variância dos dados).



Fonte: Adaptado de Sumiyoshi *et al.*, (2018).

#### 4.3.4. Calibração e validação

O período de calibração é a etapa aonde o modelo é alimentado e “treinado” com dados de onda para realizar a previsão durante o período de validação. No CP, são utilizadas as PCs obtidas na SVD referentes ao mesmo período juntamente com os dados de onda, também do mesmo período, para treinar o modelo através de uma regressão linear entre esses dados. O resultado dessa regressão linear são coeficientes (“x”) que são utilizados para reconstruir a série de ondas no VP, multiplicando-os pelas PCs para o referido período.

Após a realização da SVD, um modelo de regressão linear entre os valores diários da reanálise de Hs (Hs.calibração), Tp (Tp.calibração) e Dir (Dir.calibração) e as “k” PCs (PCs.calibração) diárias foi implementado, novamente para as 50 matrizes anteriormente citadas, para um período de calibração definido como 21 anos (1979 a 1999), seguindo a proporção relativa ao tamanho da série temporal adotada por Camus *et al.* (2014), visando selecionar uma “cobertura temporal” mais adequada para o preditor regional, bem como o tamanho de grade local mais apropriado. Embora no estado da técnica os métodos de refinamento estatístico sejam às vezes calibrados separadamente para cada estação, nesse trabalho, o processo de classificação foi executado durante todo o período de calibração, devido ao fato de que climas sazonais futuros podem não corresponder exatamente aos atuais (MARAUN *et al.*, 2010).

O modelo de regressão linear para os referidos parâmetros, dentro da ferramenta MATLAB, pode ser obtido pela seguinte linha de comando:

$$xHs = PCs.calibracao \ Hs.calibracao$$

$$xTp = PCs.calibracao \ Tp.calibracao$$

$$xDir = PCs.calibracao \ Dir.calibracao$$

A regressão linear tenta modelar a relação entre duas variáveis ajustando uma equação linear aos dados observados. Uma variável é considerada uma variável

explicativa e a outra é considerada uma variável dependente. Antes de tentar ajustar um modelo linear aos dados observados, deve-se primeiro determinar se existe ou não uma relação entre as variáveis de interesse. Isso não implica necessariamente que a variação de um parâmetro cause a variação do outro, mas sim que existe uma associação significativa entre as duas variáveis. Gráficos de dispersão são ferramentas úteis para determinar a força do relacionamento entre duas variáveis. Se parece não haver associação entre as variáveis explanatórias e dependentes propostas (isto é, o gráfico de dispersão não indica nenhuma tendência crescente ou decrescente), então ajustar um modelo de regressão linear aos dados provavelmente não fornecerá um modelo útil.

Com o vetor coeficiente (“x”), obtido através da regressão linear, foi possível calcular os novos parâmetros de onda provenientes de cada modelo para o período de calibração (cada uma das 50 matrizes fornecerá PCs diferentes, resultando assim, conseqüentemente, em modelos diferentes). Os novos parâmetros foram modelados multiplicando as PCs obtidas para o período de calibração pelo vetor coeficiente de cada parâmetro:

$$Hs.calibracao.modelo = PCs.calibracao * xHs$$

$$Tp.calibracao.modelo = PCs.calibracao * xTp$$

$$Dir.calibracao.modelo = PCs.calibracao * xDir$$

As séries de onda resultantes de cada modelo foram então correlacionadas com a série de ondas original, em busca de representar a capacidade de cada modelo de reproduzir a condição real da ondulação que chega até a costa.

O coeficiente de correlação de Pearson (R) é uma valiosa medida numérica de associação entre duas variáveis, indicando a força dessa associação dos dados observados para as duas variáveis (YUDS, 1998). A análise de correlação consiste em determinar quão bem duas (ou mais) variáveis co-variam no tempo (ou espaço) (EMERY; THOMSON, 2001). O R varia de -1 a 1. O sinal indica direção positiva ou negativa do relacionamento e o valor sugere a força da relação entre as variáveis. Uma correlação perfeita (-1 ou 1) indica que os valores de uma variável podem ser

determinados exatamente ao se saber os valores da outra. Por outro lado, uma correlação nula (zero) indica que não há relação linear entre as variáveis (FIGUEIREDO & BRITO, 2009).

Por fim, para o período de validação, novamente um modelo de regressão linear foi empregado, porém, dessa vez, utilizando as PCs (PCs.validação) obtidas para um período de 11 anos (2000 a 2010), porém, ainda o vetor coeficiente encontrado na calibração. Nessa etapa do procedimento o vetor “x” não possui nenhuma informação sobre as medidas de onda do período, pois foi gerado com os dados de 1979 a 1999, portanto, os dados de saída da validação dos modelos (Hs.modelo, Tp.modelo e Dir.modelo) são uma previsão da série de ondas, e foram calculados através das seguintes expressões:

$$Hs.modelo = PCs.validacao * xHs$$

$$Tp.modelo = PCs.validacao * xTp$$

$$Dir.modelo = PCs.validacao * xDir$$

Como última etapa da validação, o processo se repetiu e as séries previstas por cada modelo foram correlacionadas com a série ROW de ondas para seu respectivos períodos, dessa vez com o intuito de representar a capacidade de cada modelo de prever uma condição supostamente ainda não conhecida da ondulação que chega até a costa. Após essa etapa, a série de ondas do modelo que apresentou a melhor correlação para a validação foi submetida a posteriores análises estatísticas de parâmetros utilizados na literatura como Erro Quadrático Médio (EQM), Viés (V), índice de Espalhamento (IE) e Inclinação Quadrática Média (IQM), os quais podem ser calculados pelas seguintes fórmulas:

$$V = \bar{x} - \bar{y}$$

$$EQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}$$

$$IE = \frac{EQM}{\bar{x}}$$

$$IQM = \sqrt{\frac{\sum_{i=1}^n y_i^2}{\sum_{i=1}^n x_i^2}}$$

#### 4.3.5. Classificação em weather-types

A decomposição em valores singulares da matriz utilizada pelo melhor modelo considerou um “k” (número necessário de EOFs para explicar 99% da variância dos dados), de um total modos de variabilidade encontrados pela SVD. Com algoritmo de k-médio, e utilizando essas EOFs, foram criados 36 diferentes grupos baseados em critérios de similaridade, visando reduzir ainda mais a dimensionalidade dos dados que explicam o clima de ondas. Cada grupo foi então convertido em um mapa, sendo cada um deles um weather-type. Cada WT teve, por sua vez, uma probabilidade associada ao seu acontecimento durante todo o período analisado e também para cada estação do ano. Nessa etapa da metodologia foram utilizados resultados cedidos por Paula Gomes da Silva.

De forma geral, cada weather-type corresponde a uma média das EOFs que foram agrupadas para gerá-lo. As EOFs representam as configurações mais típicas da atmosfera na área do preditor analisado e seus valores são expressos em unidades de anomalia de pressão.

Por fim, diferentes estados de mar foram associados aos seus respectivos WTs responsáveis por sua geração, ou seja, cada weather-type possui parâmetros de onda

(Hs, Tp e Dir) próprios e, por consequência, estes parâmetros também possuem suas probabilidades de ocorrerem.

#### 4.3.6. Correlação com índices climáticos

Com o intuito de melhor entender quais são os fenômenos que influenciam na variabilidade do clima de ondas, uma análise de correlação foi realizada entre as PCs das 6 primeiras EOFs e diversos índices climáticos conhecidos por sua maior influência na área de estudo. Como os índices climáticos normalmente são disponibilizados em valores mensais, foi realizada uma nova SVD para a matriz cujos parâmetros apresentaram melhores resultados no período de validação, porém, dessa vez, utilizando médias mensais de SLP.

De forma geral o *Southern Oscillation Index* (SOI), o *Pacific Decadal Oscillation* (PDO) e o *Antartic Oscillation* (AAO) são os índices mais frequentemente estudados no sul do Brasil devido a sua maior influência nessa região (DALINGHAUS, 2016). Porém foram analisadas também correlações com os índices *Multivariate ENSO Index Version 2* (MEI.v2), *Oceanic Niño Index* (ONI), *Niño 3.4 Index*, *South Atlantic Ocean Dipole* (SAOD), *Tropical South Atlantic* (TSA) e *Atlantic Meridional Mode* (AMM), os quais também são comumente abordados em estudos climáticos no Hemisfério Sul.

O SOI é uma medida das flutuações de grande escala baseado na diferença da SLPA (anomalia de SLP) entre um local no sudeste tropical ou subtropical do Pacífico, geralmente o Taiti, e um no Pacífico tropical ocidental, geralmente Darwin, Austrália, durante episódios de El Niño e La Niña. Esses locais são usados porque a oscilação descrita por eles representa, ou está correlacionada com um número de variações climáticas ocorrendo muito além do Pacífico tropical. Taiti e Darwin são comumente usado em parte porque eles têm dados SLP razoavelmente confiáveis que se estendem por várias décadas, uma raridade nessa região (SHWING *et al.*, 2002).


Em geral, as séries temporais suavizadas do SOI correspondem muito bem às mudanças na temperatura dos oceanos no Pacífico tropical oriental. A fase negativa do SOI representa pressão de ar abaixo do normal no Taiti e pressão de ar acima do

normal em Darwin. Períodos prolongados de valores de SOI negativos (positivos) coincidem com as águas oceânicas anormalmente quentes (frias) em todo o Pacífico tropical do leste, típico dos episódios de El Niño (La Niña) (NOAA, 2019).

Apesar do SOI ser amplamente utilizado, de acordo com o National Center for Atmospheric Research (NCAR), o Niño 3.4 Index e o ONI são os índices mais usados para medir o El Niño Oscilação Sul (ENOS). Os valores para esse IC encontram-se disponíveis em <https://www.ncdc.noaa.gov/teleconnections/enso/indicators/soi/data.csv>.

De acordo com a definição operacional usada pelo NOAA, as anomalias do Niño 3.4 podem ser consideradas como representando as SSTs equatoriais médias em todo o Pacífico na região compreendida entre as coordenadas (5°N-5°S, 170°W-120°W). O índice Niño 3.4 normalmente usa uma média de execução de 5 meses, e os eventos El Niño ou La Niña são definidos quando o Niño 3.4 SSTs excede +0.4°C ou -0.4°C por um período de seis meses ou mais. O ONI usa a mesma região que o índice Niño 3.4 (Figura 10), porém, por sua vez, o ONI usa uma média de execução de 3 meses e, para ser classificado como El Niño ou La Niña, as anomalias devem exceder +0.5°C ou -0.5°C por pelo menos cinco meses consecutivos. ICs disponíveis respectivamente em [https://www.esrl.noaa.gov/psd/gcos\\_wgsp/Timeseries/Data/nino34.long.data](https://www.esrl.noaa.gov/psd/gcos_wgsp/Timeseries/Data/nino34.long.data) e [https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php).

Figura 10. Esboço das regiões usadas para diversos índices Niño.



Fonte: Trenberth (2019).

O MEI.v2 é definido pela série temporal das principais EOFs combinadas de cinco variáveis diferentes (pressão ao nível médio do mar, temperatura da superfície do mar, componentes zonal e meridional do vento de superfície e radiação de onda longa refletida (*ongoing longwave radiation* - OLR) sobre a bacia tropical do Pacífico (30°S-



30°N e 100°L-70°O). As principais características dos eventos positivos MEI.v2 incluem SSTs anormalmente quentes em todo o Pacífico equatorial leste-central, PNMM anormalmente alta sobre a Indonésia e o Pacífico tropical ocidental e baixa PNMM sobre o Pacífico tropical oriental, redução ou reversão de ventos tropicais do leste do Pacífico (ventos alísios), suprimida convecção tropical (OLR positiva) sobre a Indonésia e Pacífico Ocidental e convecção aumentada (OLR negativa) sobre o Pacífico central. As principais características dos eventos MEI negativos são na sua maioria o oposto (NOAA, 2019). Este índice encontra-se disponível pelo endereço <https://www.esrl.noaa.gov/psd/enso/mei/data/meiv2.data>.

A PDO tem uma característica oscilatória análoga ao ENSO, também baseada na SST, porém com período mais longo (20 a 30 anos em comparação com 6-18 meses do ENSO) e mais visível nos extratropicais (HARE, 2002). Na fase influenciada pelo El Niño (fase positiva da PDO) há um resfriamento do Pacífico Oeste e aquecimento do Pacífico Leste, sendo que na fase negativa o oposto ocorre e há predominância do evento La Niña. Índice disponível em <http://research.jisao.washington.edu/pdo/PDO.latest.txt>.

A Oscilação Antártica (AAO) é o padrão dominante de variações de circulação troposférica não sazonais ao sul de 20°S, e é caracterizada por anomalias de pressão de um sinal centrado na Antártica e anomalias do sinal oposto centradas em torno de 40-50S. O AAO também é conhecido como o modo anular do sul (Southern Annular Mode -SAM) (MITCHELL, 2003). Esse índice é determinado como a diferença da pressão média do nível do mar zonal entre 40°S e 65°S. A média zonal de cada mês é padronizada pela média/desvio padrão determinado para o período de tempo climatológico. Então, o valor de 65°S é subtraído do valor de 40°S para cada mês. Este modo descreve a variabilidade de baixa frequência dos extratropicais do Hemisfério Sul. Um índice positivo (baixa pressão polar) está associado a ventos zonais mais fracos nos extratropicais (GONG & WANG, 1999), maior atividade ciclônica em médias latitudes com deslocamento para o norte e a intensidade e ocorrência de anticiclones pode aumentar (DALINGHAUS, 2016). Um valor negativo está associado a ventos zonais mais fortes. Disponível em <http://research.jisao.washington.edu/data/aao/aao19482002>.

O índice TSA foi definido por Enfield *et al.*, (1999) como sendo a anomalia média da SST sobre uma região retangular de coordenadas (20°S-0° e 30°O-10°L). Este índice é bastante utilizado como um dos estimadores do dipolo no Atlântico tropical. Disponível em <https://www.esrl.noaa.gov/psd/data/correlation/tsa.data>.

O AMM é definido pela análise de máxima covariância na SST no Atlântico tropical considerando as componentes zonal e meridional, do campo de vento a 10 metros (CHIANG & VIMONT, 2004). Disponível em <https://www.esrl.noaa.gov/psd/data/timeseries/monthly/AMM/ammsst.data>.

Por fim, o SAOD é o mecanismo de aquecimento das águas superficiais das costas da África Central e Ocidental Equatorial, associado a resfriamentos concomitantes de magnitude similar nas costas Argentina-Uruguai-Brasil. Esses padrões de temperatura da superfície do mar são acoplados ao campo de circulação atmosférica e climas regionais. O SAOD é definido pela diferença da média da anomalia de SST entre duas regiões, descritas por suas localizações no Oceano Atlântico Sul como o polo nordeste de coordenadas (10°L–20°O e 0°–15°S) e o polo sudoeste de coordenadas (10°O–40°O e 25°S-40°S) (NNMACHI & ANYADIKE, 2011). Disponível em <http://ljp.gcess.cn/dct/page/65592>.

## **5. OUTRAS ANÁLISES REALIZADAS**

### **5.1. EXECUÇÃO DA METODOLOGIA ESTELA**

A metodologia ESTELA foi executada utilizando os mesmos dados e mesmos períodos de calibração e validação. Por ela contemplar isocronas em sua análise (linhas de mesmo tempo de viagem da área de geração até a costa), foi possível escolher até qual distância da costa, em dias, seria considerada.

Foram escolhidos intervalos de 1 a 12 dias de viagem e, posteriormente, realizados os procedimentos de calibração e validação para cada um deles. Assim, analisando as correlações obtidas para ambos os períodos das diferentes áreas analisadas, é possível inferir até qual distância da costa a geração de ondas contribui significativamente para o fluxo de energia de ondas em Santa Catarina.

Os resultados obtidos também foram utilizados a título de comparação do modelo obtido durante este estudo com uma metodologia já consolidada.

## 5.2. ANÁLISE DE DIFERENTES PERÍODOS DE CALIBRAÇÃO E VALIDAÇÃO

Para melhor entender os efeitos do tamanho da série temporal utilizada no período de calibração, bem como suas consequências no resultado do período de validação e também inferir intervalos mínimos recomendáveis para ambos os períodos, foram explorados diversos valores para ambos os parâmetros, até os limites impostos pela própria extensão da série temporal, a qual, nesse estudo, abrange 32 anos.

O período de calibração foi testado desde o intervalo de 1 ano até 32 anos (menos a última semana), sendo o período de validação sempre o intervalo complementar ao de calibração para completar a extensão da série temporal.

A análise foi iniciada para um período de calibração de 31 anos, 11 meses e 3 semanas, sendo retirada 1 semana do intervalo a cada análise posterior, até atingir 31 anos e 11 meses. Após esse momento, foram retirados, a cada análise, intervalos de 1 mês do período de calibração até ele atingir um período total de 31 anos. A partir dos 31 anos de extensão foram retirados intervalos de 1 ano a cada análise, até atingir 1 ano de calibração. As correlações para a série de Hs obtidas através de cada combinação de períodos foram calculadas e tabeladas.

Para toda a análise supracitada foram utilizadas as PCs do modelo cujas correlações dos parâmetros de ondas foram as maiores durante a fase de validação do trabalho.

## 5.3. TESTE PARA DIFERENTES RESOLUÇÕES ESPACIAIS

Como anteriormente citado neste trabalho, o refinamento estatístico é baseado na premissa de que um clima local é condicionado por dois fatores: o estado climático de larga escala e características fisiográficas regionais/locais. Tendo em vista que um dos objetivos principais do SD é reproduzir características de um clima local com baixo custo computacional, todos os procedimentos foram repetidos para os mesmos dados,

com uma resolução espacial 4 vezes inferior ( $2^\circ \times 2^\circ$ ). Os resultados para os períodos de calibração e validação dos dados de baixa resolução foram então comparados com o dado original ( $0,5^\circ \times 0,5^\circ$ ) com a finalidade de identificar se a utilização de uma base de dados de menor qualidade comprometeria a capacidade do modelo. Esses procedimentos também foram realizados para a metodologia ESTELA.

## 6. RESULTADOS E DISCUSSÃO

### 6.1. ESTELA

Os valores de Hs gerados para as séries de ondas através da metodologia ESTELA, contemplando as áreas de geração de ondas de 1 até 12 dias de viagem (lag) até costa, passaram por uma análise de correlação de Pearson com a série de ondas de reanálise ROW e os resultados encontrados para os períodos de calibração e validação se encontram na Tabela 1.

Tabela 1. Valores encontrados para os períodos de calibração e validação de Hs utilizando a metodologia ESTELA.

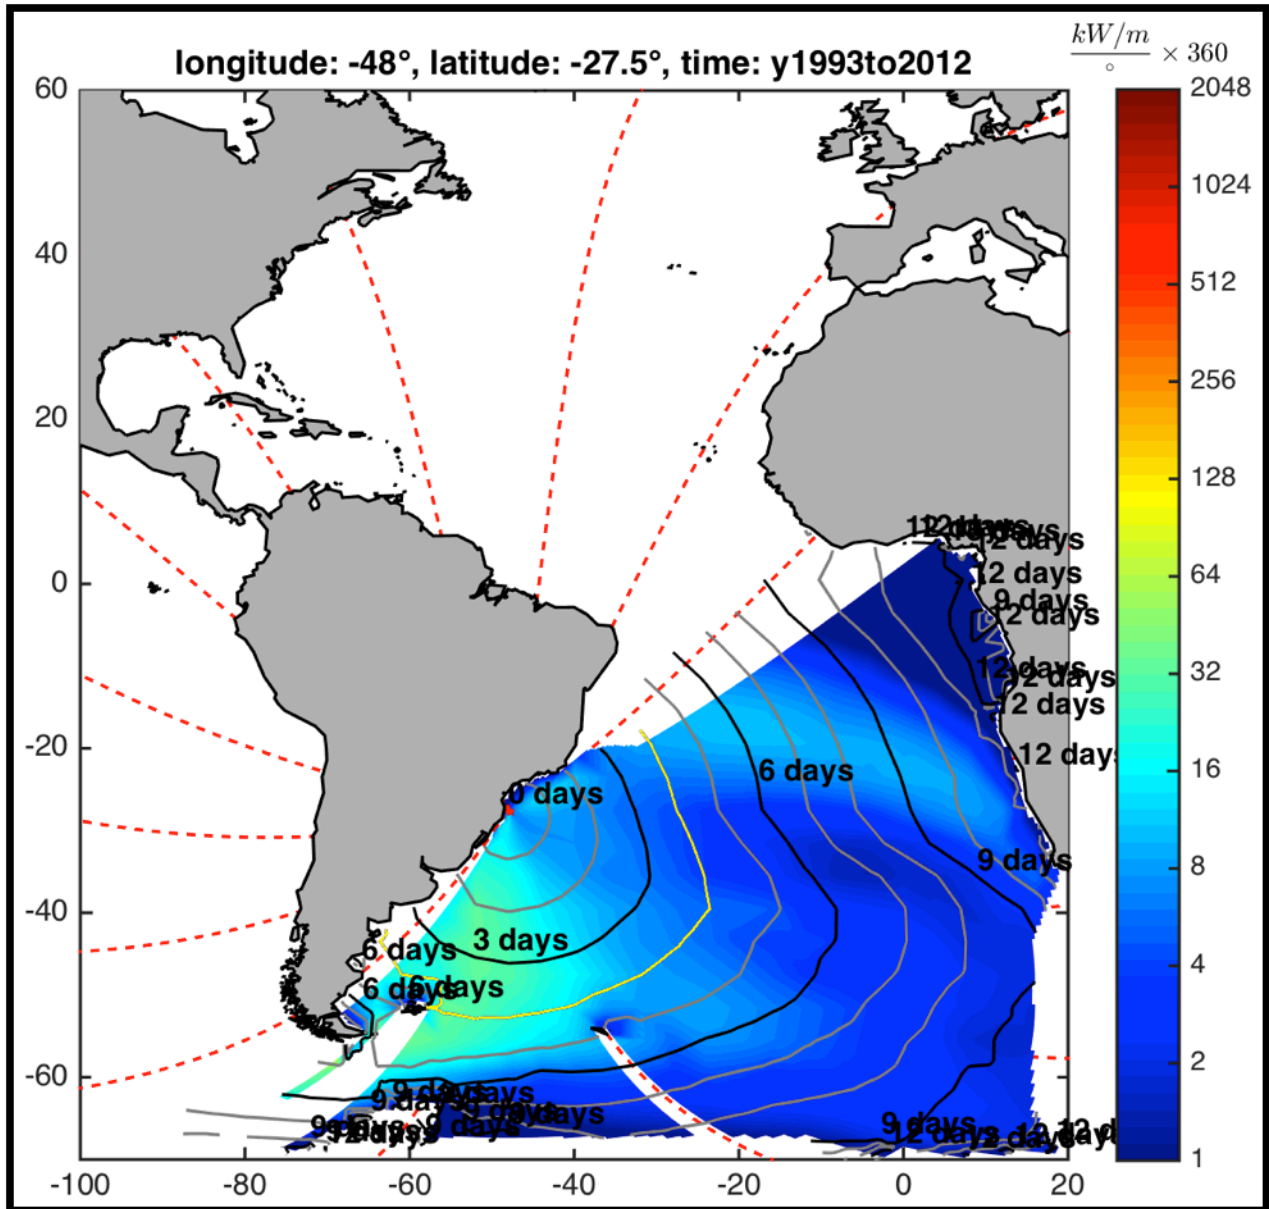
ESTELA	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
Calibração	0,76	0,81	0,83	0,83	0,84	0,84	0,84	0,84	0,85	0,85	0,85	0,85
Validação	0,75	0,80	0,81	0,82	0,81	0,81	0,81	0,81	0,81	0,81	0,80	0,81

Observando os valores de correlação encontrados é possível perceber que, durante o período de calibração os valores sobem constantemente até o maior lag analisado, chegando ao seu valor máximo de 0,85. Porém, isso não se repete para o processo de validação, aonde a maior correlação encontrada foi de 0,82 para o lag 4, cuja calibração apresentou uma correlação de 0,83 com série de ondas da reanálise.

Interpretando os resultados pré-existentes da metodologia ESTELA para Santa Catarina (Figura 11), pode-se perceber que a maior energia de ondas geradas que chega até a costa catarinense pertence justamente à área dentro da isocrona de 4 dias

(isocrona em amarelo), que tem seu ponto mais ao sul nas proximidades das Malvinas e o ponto mais ao norte na altura de Cabo Frio - RJ.

Figura 11. A área colorida representa as regiões cujo fluxo de energia chegam à costa catarinense, as linhas cinza e preta (isocronas) representam o tempo de viagem da onda até a região de estudo e as linhas pontilhadas vermelhas dividem a direção em 16 setores. A isocrona de 4 dias encontra-se destacada em amarelo.



Fonte: Imagens cedidas por Fernando Javier Méndez Incera através de comunicação pessoal.

Conectando ambos os resultados é possível inferir que os campos de pressão presentes a mais do que 4 dias de viagem da costa não afetam significativamente no

resultado do modelo. Por outro lado, quando se começa a retirar informação da área dentro da isocrona de 4 dias, é perceptível que os valores de correlação voltam a cair até o seu mínimo, considerando apenas a área dentro do lag 1 (0,75).

## 6.2. MODELO DE REFINAMENTO ESTATÍSTICO OBTIDO (M24)

Os resultados das correlações obtidas entre os parâmetros das séries de ondas geradas pelos modelos analisados neste estudo e os parâmetros da série de reanálise, para os períodos de calibração e validação, se encontram nas Tabelas 2, 3, 4, 5, 6 e 7. Os maiores valores de correlação encontrados estão representados em negrito e os menores valores em vermelho.

Tabela 2. Valores de correlação obtidos para altura significativa (Hs) durante o período de calibração.

Hs	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,81	0,81	0,77	0,71	0,68	0,67	0,67	0,66	0,66	0,66
Grade 2	0,81	0,81	0,77	0,73	0,70	0,68	0,68	0,68	0,68	0,68
Grade 3	0,81	0,81	0,78	0,74	0,71	0,69	0,69	0,69	0,69	0,69
Grade 4	0,80	0,82	0,79	0,75	0,72	0,71	0,71	0,71	0,70	0,70
Grade 5	0,80	0,82	0,79	0,75	0,72	0,71	0,71	0,71	0,71	0,70

Tabela 3. Valores de correlação obtidos para altura significativa (Hs) durante o período de validação.

Hs	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,77	0,77	0,72	0,67	0,63	0,61	0,61	0,59	0,59	0,60
Grade 2	0,77	0,77	0,73	0,68	0,65	0,63	0,63	0,61	0,62	0,63
Grade 3	0,77	0,78	0,74	0,69	0,66	0,64	0,64	0,63	0,63	0,64
Grade 4	0,77	0,78	0,75	0,71	0,67	0,66	0,66	0,65	0,65	0,65
Grade 5	0,77	0,78	0,75	0,71	0,68	0,66	0,66	0,65	0,65	0,66

Tabela 4. Valores de correlação obtidos para período de pico ( $T_p$ ) durante o período de calibração.

Tp	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,63	0,70	0,67	0,56	0,46	0,42	0,41	0,42	0,41	0,41
Grade 2	0,62	0,70	0,68	0,57	0,48	0,44	0,43	0,44	0,43	0,43
Grade 3	0,62	0,70	0,68	0,58	0,49	0,46	0,45	0,45	0,44	0,45
Grade 4	0,62	0,71	0,69	0,59	0,50	0,47	0,47	0,47	0,46	0,46
Grade 5	0,62	0,70	0,69	0,60	0,51	0,48	0,48	0,47	0,47	0,47

Tabela 5. Valores de correlação obtidos para período de pico ( $T_p$ ) durante o período de validação.

Tp	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,55	0,63	0,59	0,43	0,31	0,27	0,23	0,24	0,21	0,21
Grade 2	0,55	0,63	0,59	0,44	0,33	0,29	0,26	0,26	0,24	0,24
Grade 3	0,55	0,63	0,60	0,45	0,35	0,30	0,28	0,28	0,26	0,26
Grade 4	0,55	0,64	0,61	0,47	0,37	0,33	0,31	0,32	0,30	0,29
Grade 5	0,54	0,64	0,61	0,48	0,39	0,35	0,33	0,34	0,32	0,31

Tabela 6. Valores de correlação obtidos para direção média ( $Dir$ ) durante o período de calibração.

Dir	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,84	0,78	0,70	0,63	0,59	0,57	0,56	0,55	0,55	0,55
Grade 2	0,85	0,84	0,81	0,78	0,75	0,74	0,74	0,73	0,73	0,73
Grade 3	0,85	0,85	0,83	0,80	0,78	0,77	0,76	0,76	0,75	0,76
Grade 4	0,85	0,86	0,84	0,81	0,79	0,78	0,78	0,78	0,77	0,77
Grade 5	0,85	0,86	0,84	0,82	0,80	0,79	0,78	0,78	0,78	0,78

Tabela 7. Valores de correlação obtidos para direção média ( $Dir$ ) durante o período de validação.

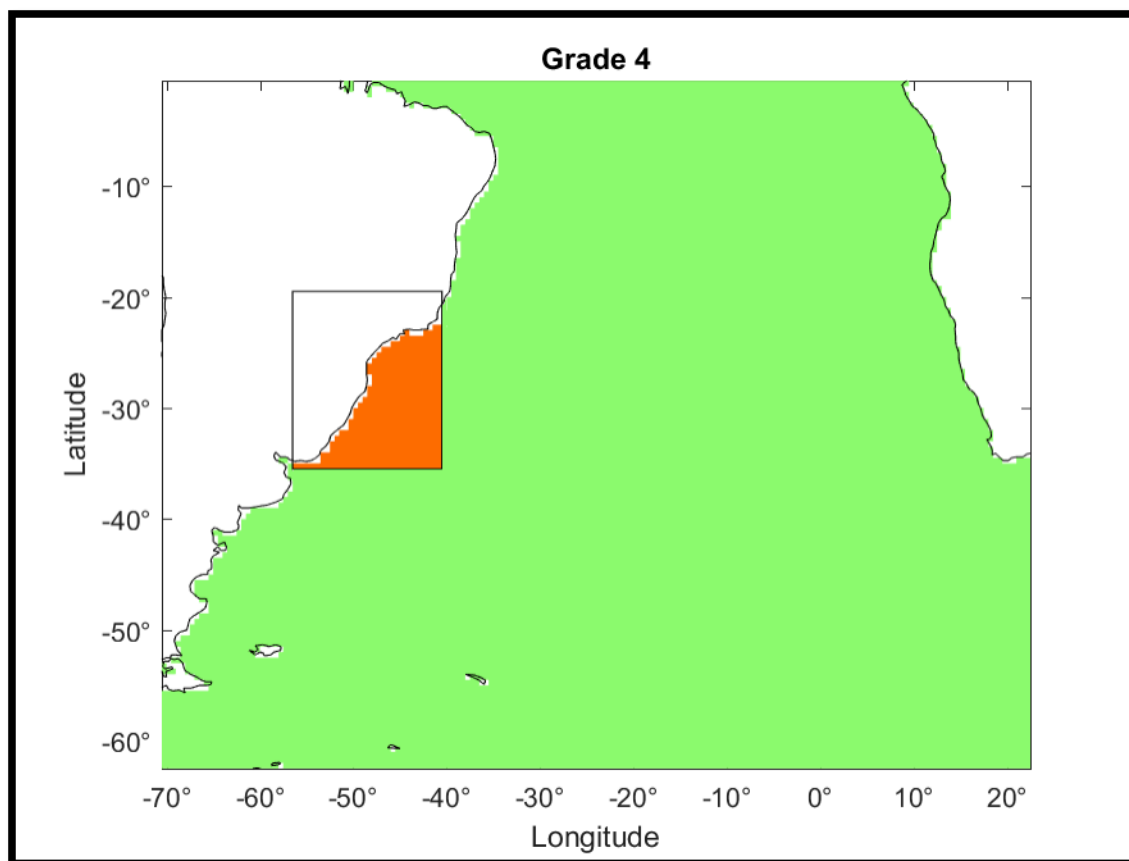
Dir	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10
Grade 1	0,82	0,73	0,61	0,53	0,47	0,44	0,42	0,40	0,39	0,37
Grade 2	0,83	0,82	0,78	0,73	0,71	0,69	0,68	0,67	0,67	0,67
Grade 3	0,83	0,83	0,80	0,76	0,74	0,72	0,71	0,71	0,71	0,71
Grade 4	0,83	0,83	0,82	0,78	0,76	0,74	0,73	0,73	0,74	0,73
Grade 5	0,83	0,83	0,82	0,79	0,77	0,76	0,75	0,74	0,75	0,74

Analisando os resultados para ambos os períodos e para os 3 parâmetros, é notável que os modelos utilizando até lag 3 obtiveram os melhores desempenhos, enquanto os modelos de lag 8, 9 e 10 da grade 1 encontraram os piores valores. Apesar de todas as 5 grades apresentarem correlações muito próximas, os melhores resultados foram encontrados para os modelos que utilizaram as grades 4 e 5.

Os modelos de lag 2 e grades 4 e 5 obtiveram as melhores performances em ambos os períodos e para todos os parâmetros. Os valores de correlação de ambos os modelos para Hs foram de 0,82 para o período de calibração e 0,78 para o período de validação, para Dir ambos os modelos obtiveram uma correlação de 0,86 para a calibração e 0,83 para a validação, porém, para o Tp o modelo de melhores parâmetros foi o de lag 2 e grade 4 (M24), devido ao seu melhor desempenho na calibração do Tp, 0,71 sobre 0,70 do modelo de lag 2 e grade 5, embora ambos tenham alcançado a mesma correlação de 0,64 para a validação.

A Figura 12 ilustra a melhor representação do tempo de viagem das ondas encontrado, aonde as ondas geradas dentro da grade local 4 (área laranja) chegam num intervalo de 0 a 1 dia à Santa Catarina (lag 0) e as ondas geradas na grade regional (área verde) levam de 2 até 3 dias para chegar à costa (lag 2).

Figura 12. Área pertencente a grade local 4 (laranja) e área regional (verde).




Fonte: o Autor.



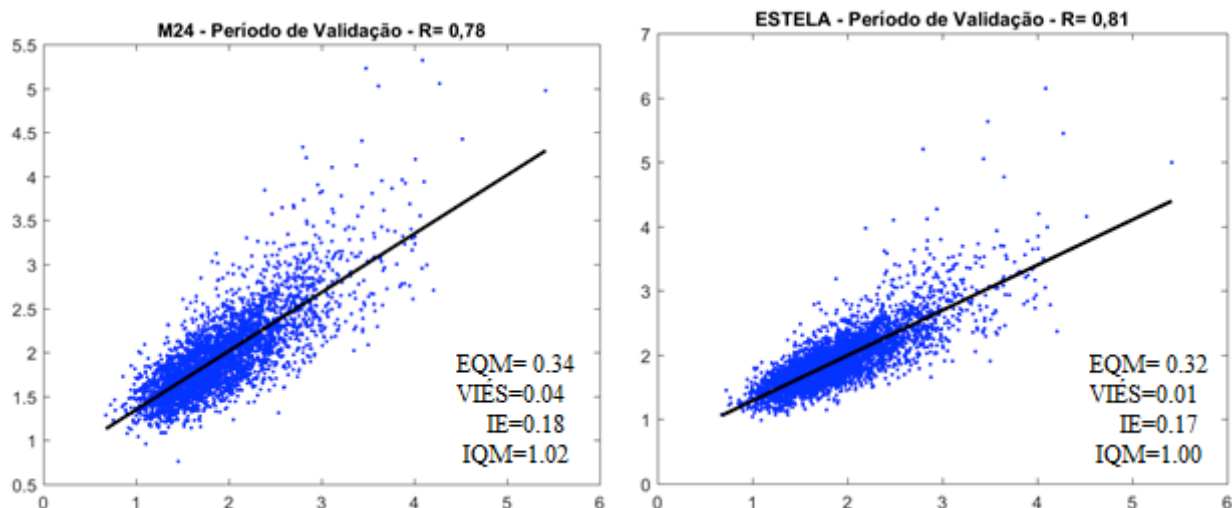
Considerando os resultados da metodologia ESTELA em que o melhor resultado contemplava a área até aonde as ondas demoravam 4 dias para chegar a costa e os resultados obtidos pelos modelos testados, aonde as melhores correlações foram observadas até os modelos de lag 3, ou seja, de 3 a 4 dias de viagem até a costa, pode-se constatar que os resultados corroboram e, apesar de ser menos sofisticado em termos de identificação do tempo de viagem de cada área de geração e identificação do fluxo de energia proveniente de cada uma delas, o modelo gerado reproduziu com qualidade a série de ondas, obtendo uma correlação de apenas 0,04 abaixo da metodologia ESTELA. As figuras 13 e 14 comparam os modelos de regressão linear resultantes para a calibração e validação dos dois métodos.

Figura 13. Comparação entre os modelos de regressão linear no período de calibração para o modelo M24 e ESTELA.



Fonte: o Autor.

Figura 14. Comparação entre os modelos de regressão linear no período de validação para o modelo M24 e ESTELA.

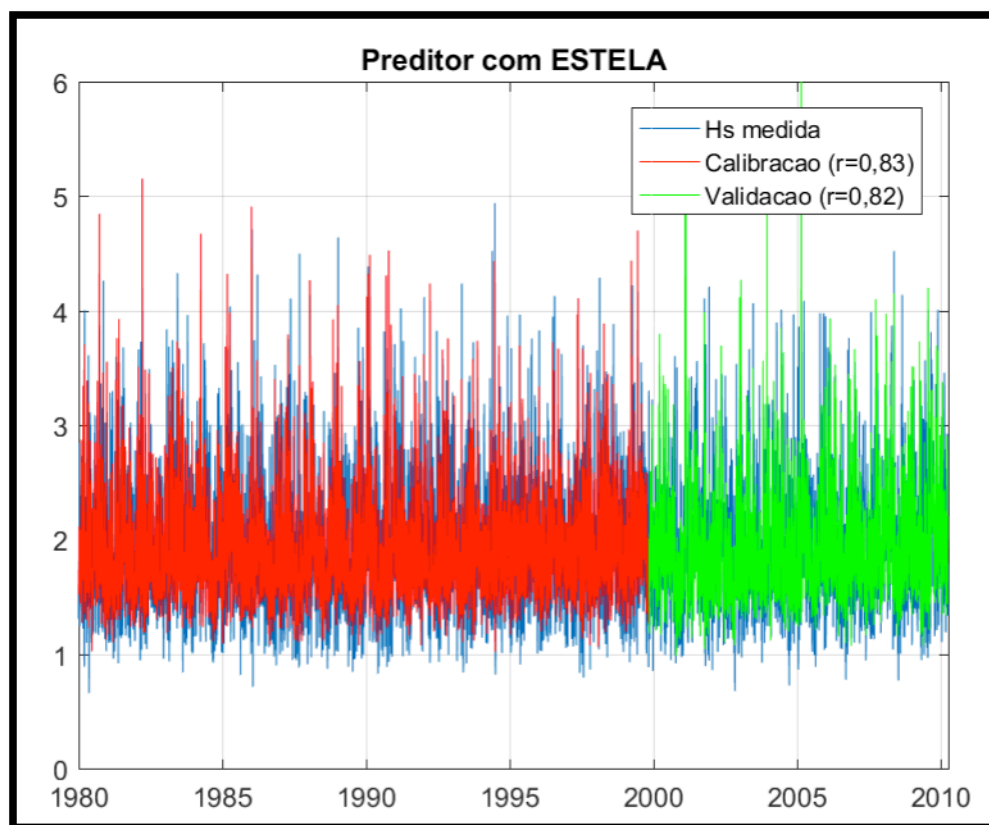


Fonte: o Autor.

Os valores de EQM apontam um erro de 34 cm para a validação do M24 e 32 cm para a validação do modelo ESTELA. Os IEs também apontam um leve desvio dos valores ideais. O Viés e o IQM por sua vez (tendência a sub ou superestimação) apresentaram valores notavelmente baixos, havendo uma pequena superestimação dos dados de Hs em ambos os modelos. Apesar das variações encontradas, os parâmetros estatísticos analisados apresentaram valores baixos para ambas as metodologias e os valores de correlação de Pearson acima de 0,7 sugerem um forte ajuste entre os dados já validados e os simulados.

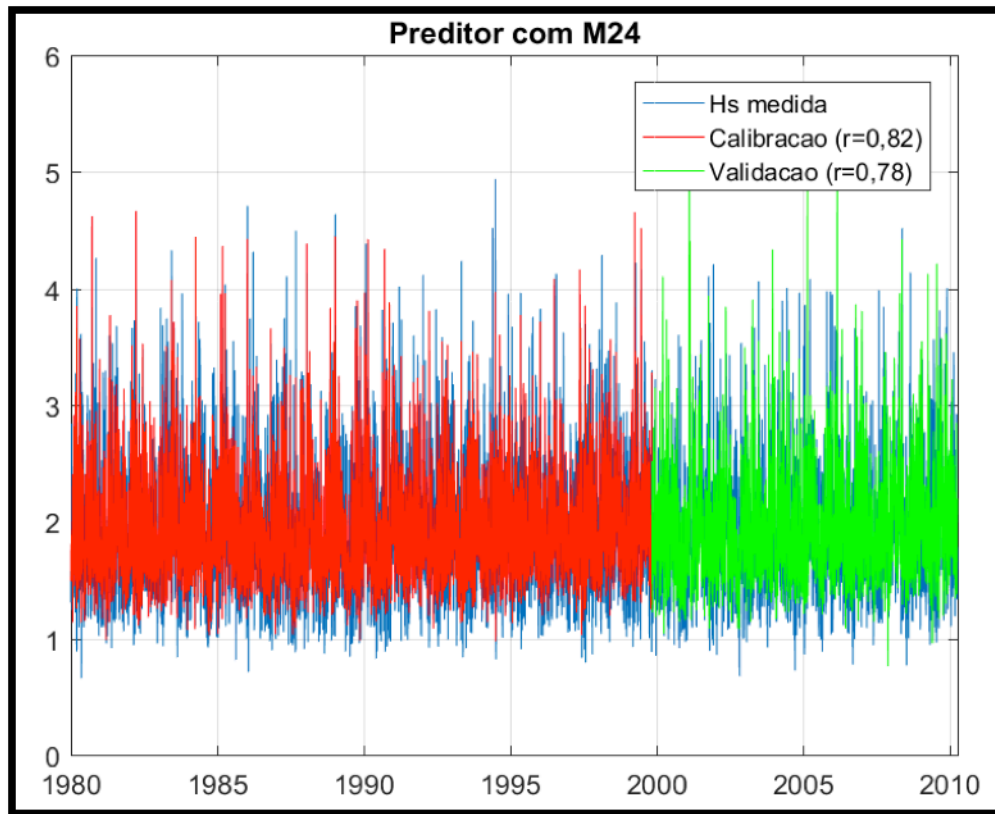
As figuras 15 e 16 são gráficos de sobreposição da série de ondas gerada para o período de calibração (vermelho) e validação (verde) sobre a série de ondas original (azul) para o modelo ESTELA e M24, respectivamente.

Figura 15. Gráfico de sobreposição da série de ondas gerada para o período de calibração (vermelho), para o período de validação (verde) sobre a série de ondas original (azul), para o modelo ESTELA.



Fonte: o Autor.

Figura 16. Gráfico de sobreposição da série de ondas gerada para o período de calibração (vermelho), para o período de validação (verde) sobre a série de ondas original (azul), para o modelo M24.




Fonte: o Autor.

### 6.3. CARACTERIZAÇÃO DO CLIMA DE ONDAS PARA SANTA CATARINA

#### 6.3.1. Comparação com dados de reanálise validados


Nas Figuras 17, 18 e 19 os histogramas de probabilidade de altura significativa, período de pico e direção médias obtidas pelo modelo M24 são comparados com os da base de dados ROW.

Figura 17. A esquerda o histograma de probabilidade de ocorrência de  $H_s$  da série gerada pelo modelo M24 e a direita o histograma de probabilidade de ocorrência da série de  $H_s$  da base de dados ROW.




Fonte: o Autor.

Figura 18. A esquerda o histograma de probabilidade de ocorrência de  $T_p$  da série gerada pelo modelo M24 e a direita o histograma de probabilidade de ocorrência da série de  $T_p$  da base de dados ROW.



Fonte: o Autor.

Figura 19. A esquerda o histograma polar de probabilidade de ocorrência de  $Dir$  da série gerada pelo modelo M24 e a direita o histograma polar de probabilidade de ocorrência da série de  $Dir$  da base de dados ROW.



Fonte: o Autor.

A série de Hs gerada pelo modelo apresentou um valor médio de 1,93m, enquanto a média da base de dados ROW foi de 1,92 m. Ambas as séries de período de pico obtiveram como valor médio 9,1 s. Para as séries de direção média, novamente os valores médios foram muito próximos, sendo 115,5° para os dados gerados pelo modelo e 115,75° para os dados ROW.

É notável a proximidade dos dados dos 3 parâmetros analisados com a série original, porém, a distribuição das probabilidades sofreu alterações marcantes. Essas alterações são mais facilmente visualizadas no gráfico de direção, o qual mesmo com o maior valor de correlação dos três parâmetros (0,83), apresentou uma tendência a concentrar as maiores probabilidades de ocorrência justamente nas proximidades do valor médio da série, o que não corresponde à distribuição de probabilidade de direções original com qualidade, portanto, informações de direção desse modelo deve ser utilizadas com cautela.

### 6.3.2. Classificação por weather-types

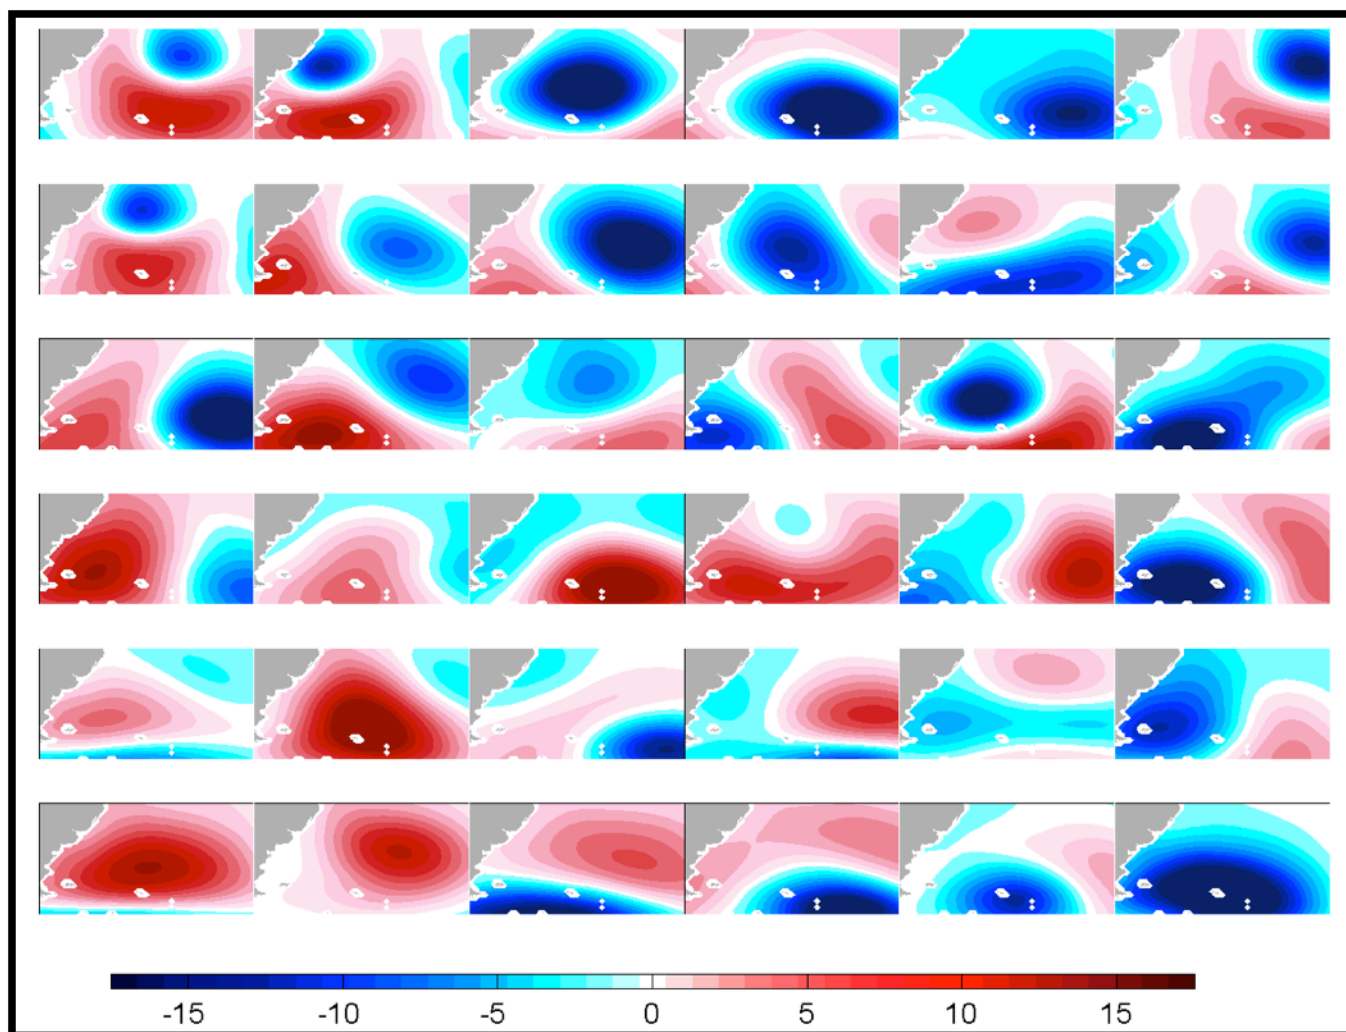
O resultado da decomposição em valores singulares da matriz utilizada pelo modelo M24 considerou um “k” de 570 (número necessário de EOFs para explicar 99%

da variância dos dados). Os 36 mapas que representam seus respectivos *weather-types* estão dispostos na Figura 20.

A Figura 21 representa a probabilidade da situação atmosférica representada por cada WT ocorrer para o intervalo inteiro analisado (1979-2010), enquanto a Figura 22 separa essas probabilidades sazonalmente.

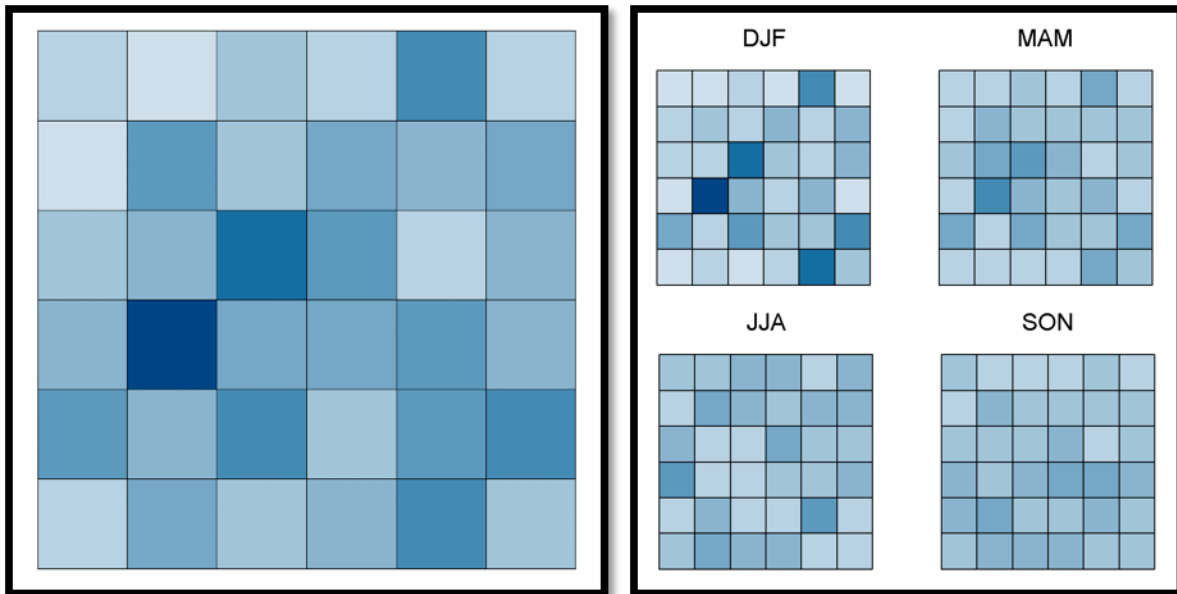
A altura significativa de onda e o período de pico gerado por cada *weather-type* estão representados nas Figuras 23 e 24, respectivamente, por histogramas de probabilidade de ocorrência e a direção de cada estado de mar está disposta na Figura 25 por meio de histogramas polares de probabilidade de ocorrência.

Figura 20. 36 *weather-types* gerados baseados nas 570 EOFs (unidade em anomalia de pressão).



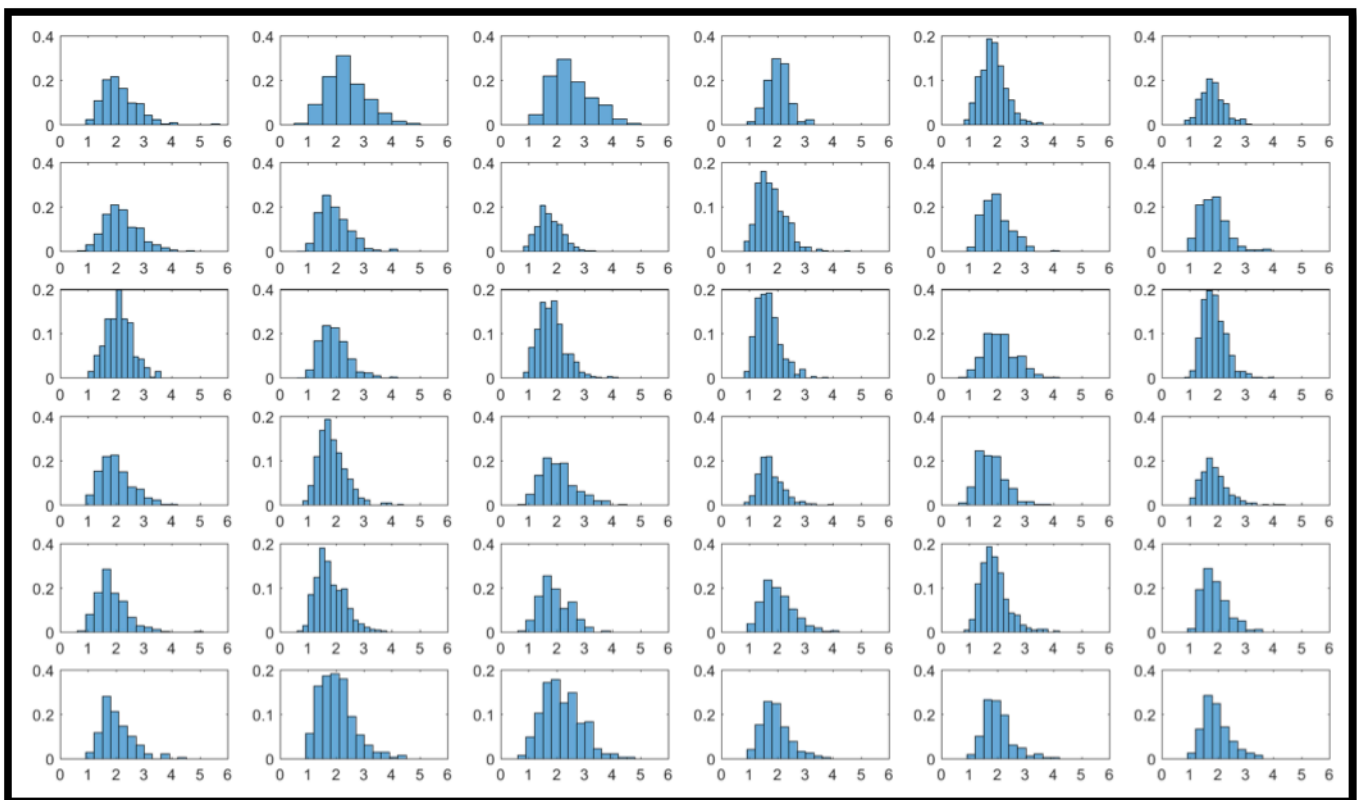
Fonte: Paula Gomes da Silva, 2019.

Figura 21 e Figura 22. Probabilidade de ocorrência de cada WT para todo o período e por estação do ano.



Fonte: Paula Gomes da Silva, 2019.

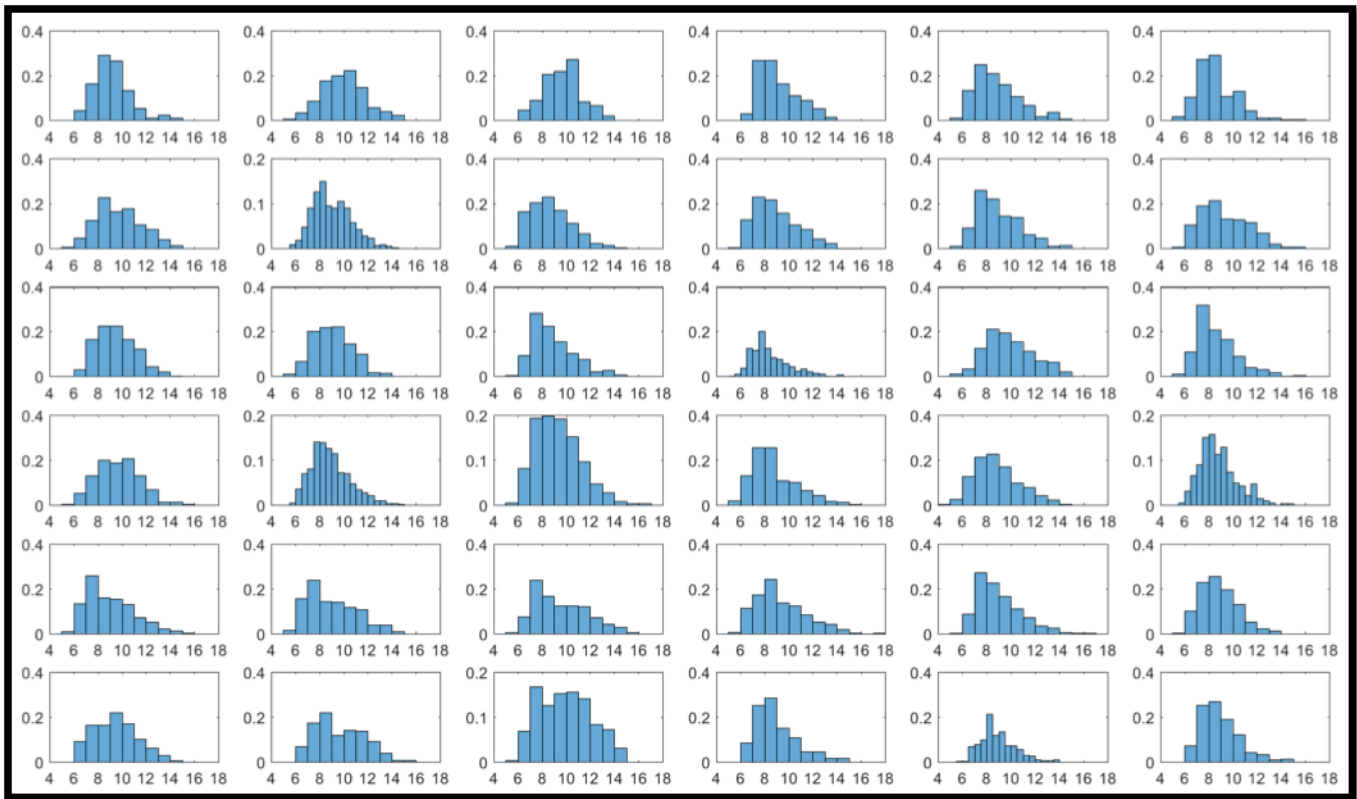
Figura 23. Histogramas de probabilidade de ocorrência de Hs associados a cada WT.



Fonte: o Autor.




Figura 24. Histogramas de probabilidade de ocorrência de  $T_p$  associados a cada WT.



Fonte: o Autor.

Figura 25. Histogramas polares de probabilidade de ocorrência de Dir associados a cada WT.

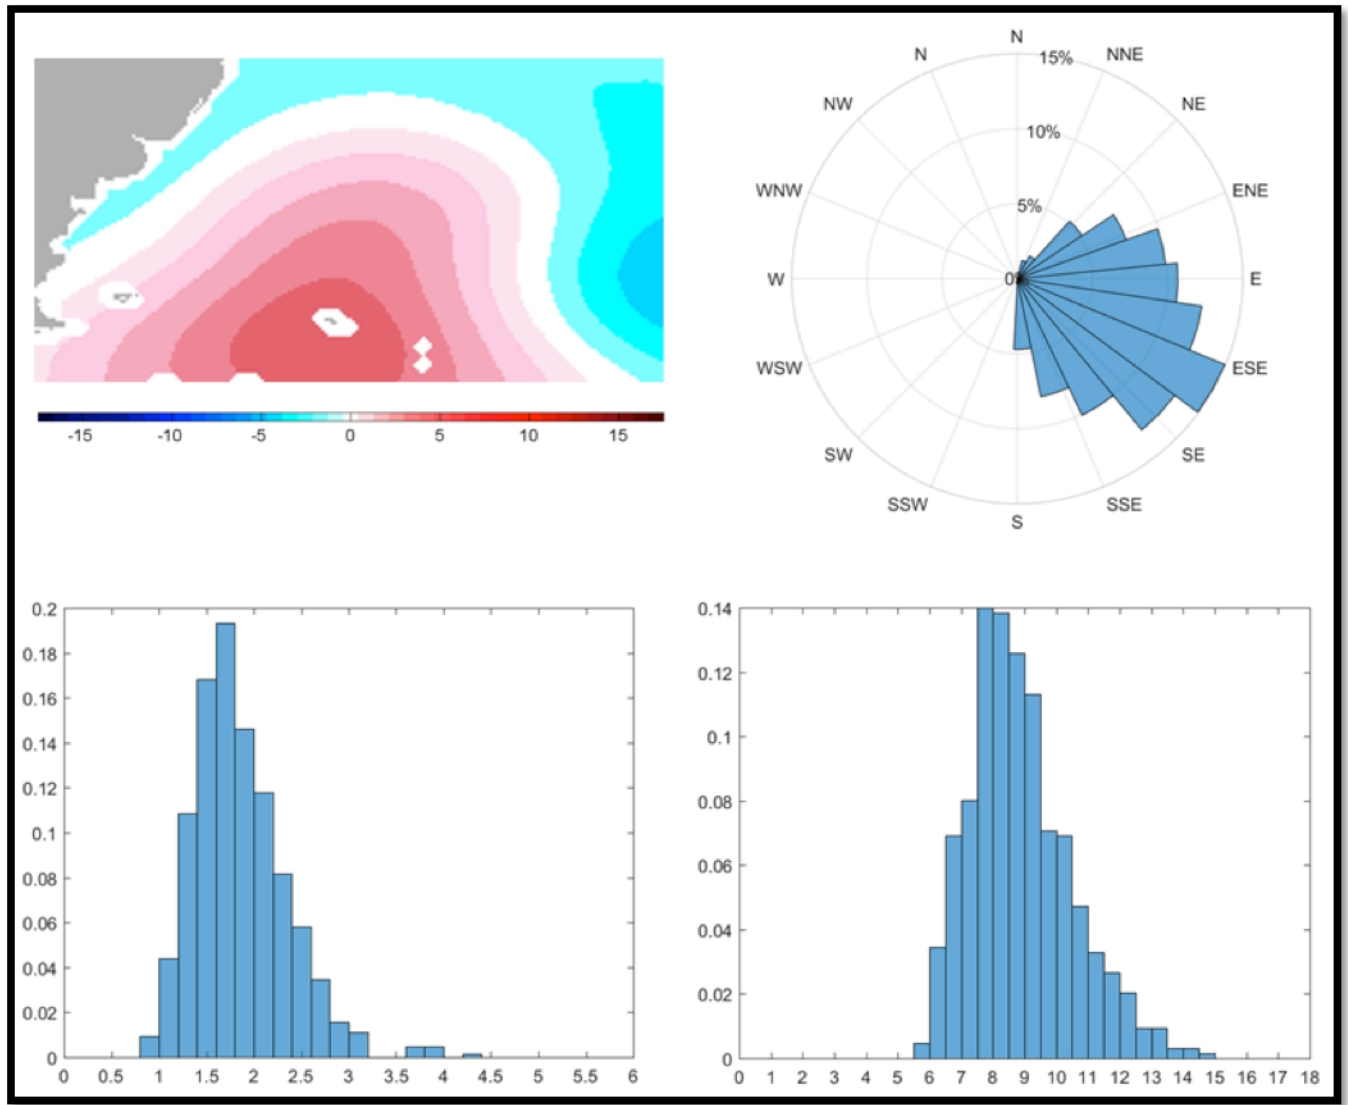


Fonte: o Autor.

Este processo consistiu na conclusão da caracterização do clima de ondas para a região, tendo em vista que foram determinadas as principais condições atmosféricas atuantes, os estados de mar gerados por elas e suas respectivas probabilidades de ocorrerem, inclusive por estação do ano. Observando gráficos e mapas de forma integrada é possível notar que cada configuração atmosférica é responsável por gerar estados de mar com características únicas.

De acordo com Camus *et al.* (2011) , os resultados obtidos de técnicas utilizando KMA aplicadas a dados de reanálise de onda, são de extrema utilidade para analisar graficamente a combinação de três ou mais parâmetros de onda e extrair os diferentes estados do mar definidos pelos parâmetros considerados pelo conjunto. Ainda de acordo com Camus *et al.* (2011), análises como a identificação do intervalo de alturas significativas de onda e a faixa de direções associadas aos estados de mar e seus respectivos períodos de pico podem ajudar na identificação dos padrões atmosféricos associados a “storm surges”, vagas e marulhos. Por exemplo, o WT10 (Figura 26):

Figura 26. Weather-type 10 e seus gráficos de probabilidade de ocorrência de Hs, Tp e Dir associados.

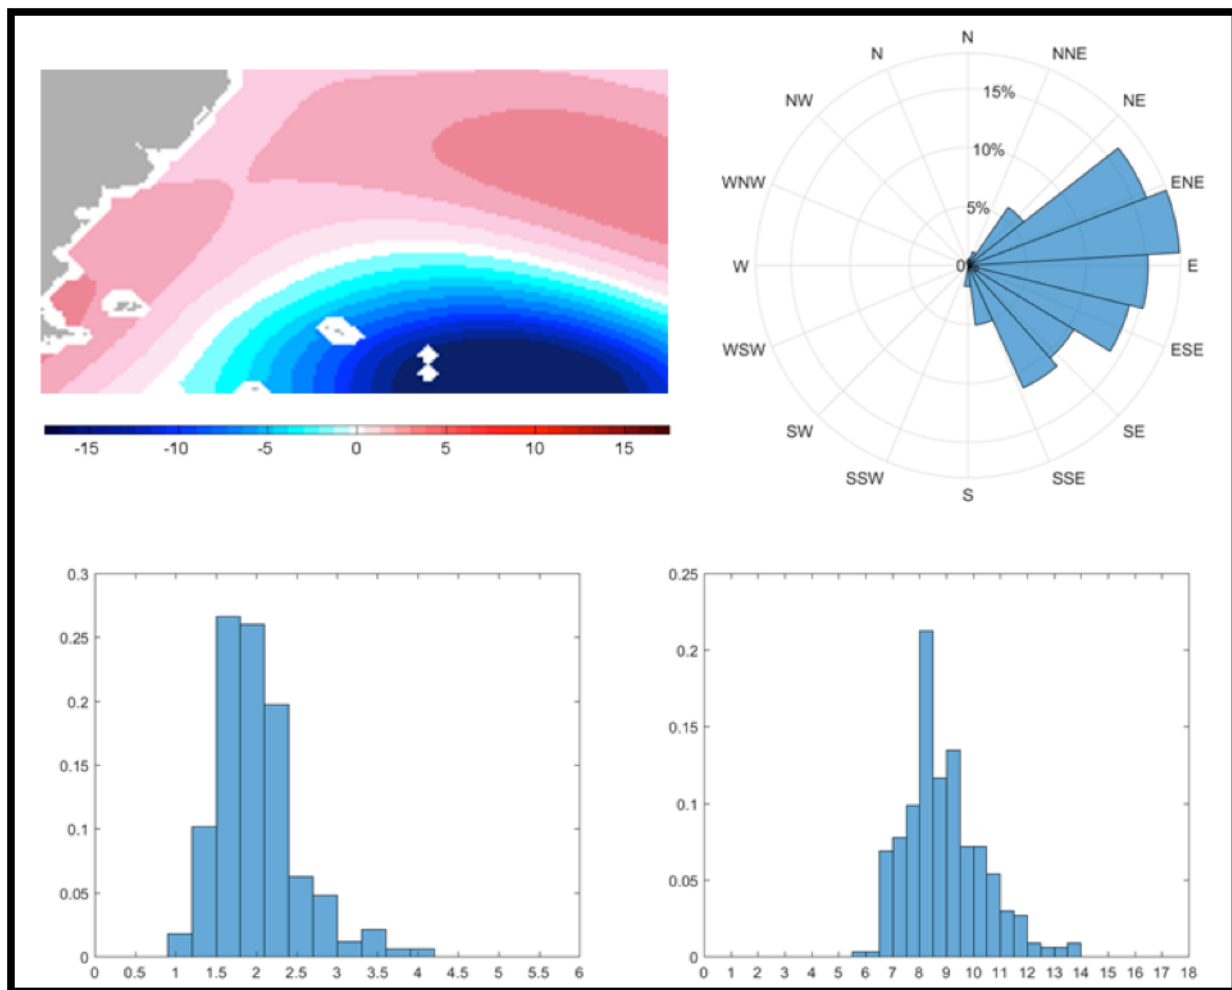


Fonte: o Autor.

O weather-type 10 foi o que apresentou a maior probabilidade de ocorrência. De acordo com Araújo *et al.* (2003), estados de mar gerados pela alta sub-tropical do Atlântico Sul são predominantes em Santa Catarina, geralmente ocasiando ondas de direção leste/sudeste com intervalos de  $H_s$  entre 1 e 1,5 m e intervalo de  $T_p$  entre 6 e 11 s. O WT10 tem como valor de altura significativa média 1,8 m e período de pico médio 8,9s, sendo de certa forma condizente com a condição de *swell* anteriormente citada.

Ao se fazer uma análise conjunta dos gráficos relativos ao WT30 (Figura 27) é notável a predominância dos casos de Leste/Nordeste na condição de anomalia atmosférica apresentada.

Figura 27. Weather-type 30 e seus gráficos de probabilidade de ocorrência de  $H_s$ ,  $T_p$  e Dir associados.

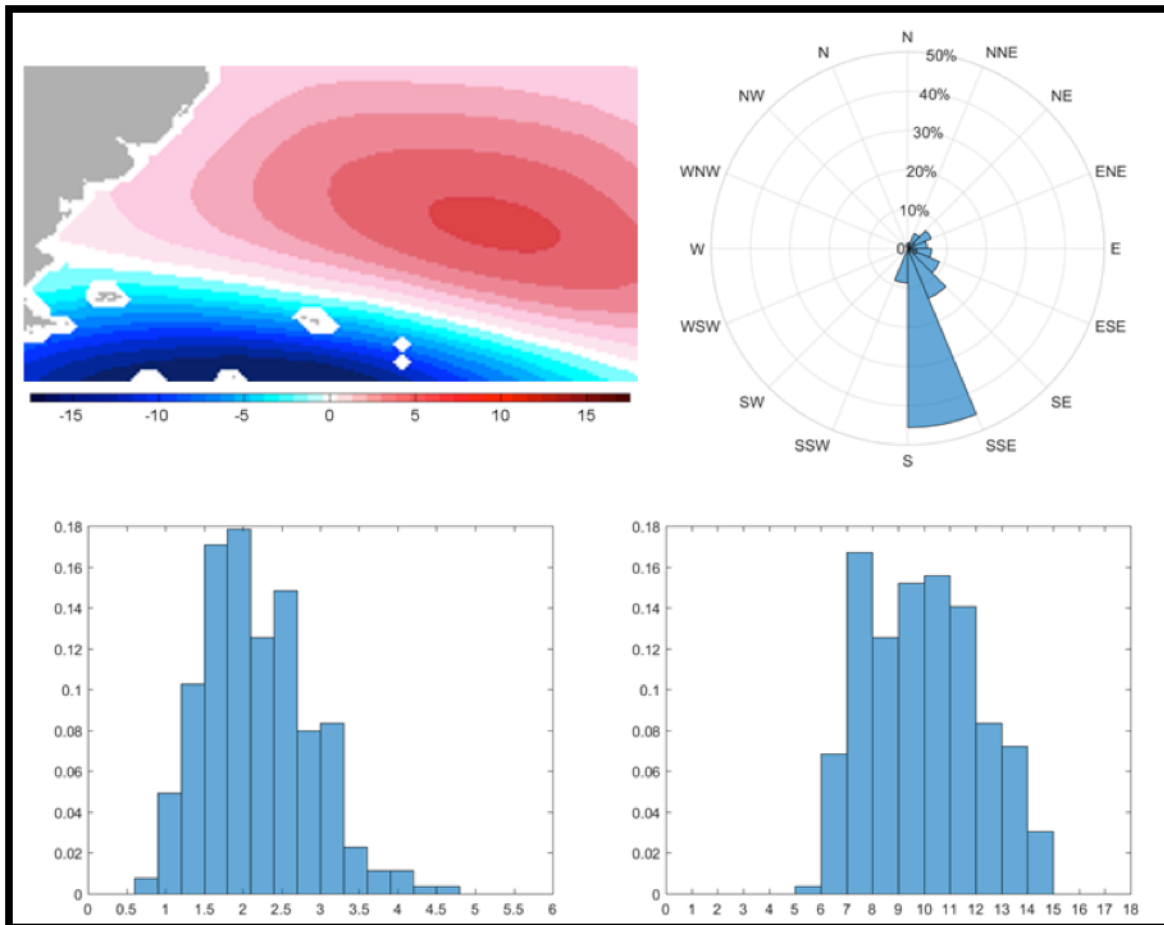


Fonte: o Autor.

As características dos parâmetros de onda apresentadas por esse weather-type se aproximam das descritas por Araújo *et al.* (2003) a respeito das *vagas*, os quais são predominantemente de direção leste, de períodos curtos em torno de 8 s e altura significativa média de 1,25 m.

Por fim, através da interpretação do WT18 (Figura 28), conjugada com os respectivos parâmetros de onda gerados por ele, é possível estimar que a condição atmosférica configurada por este WT possa estar relacionada com o sistema de ondulações longínquas com direção de pico de sul/sudeste, geradas em altas latitudes do Oceano Atlântico Sul descritas por Olivera (2017), devido a posição dos centros de anomalia de pressão, pela predominância da direção sul/sudeste e também pelo longo período apresentado ( $T_p > 14$  s).

Figura 28. Weather-type 18 e seus gráficos de probabilidade de ocorrência de  $H_s$ ,  $T_p$  e  $Dir$  associados.

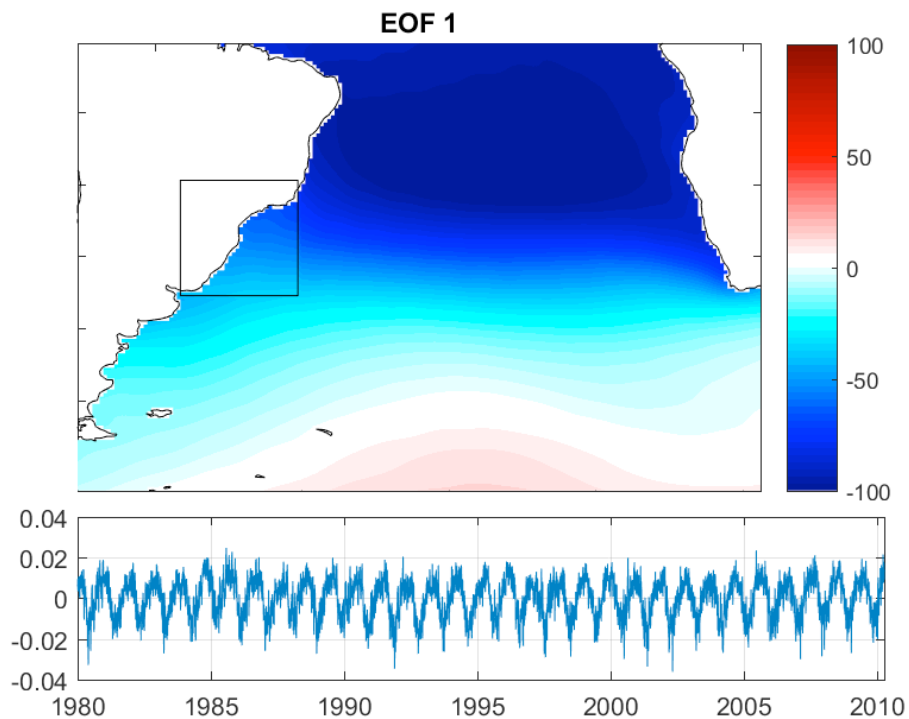


Fonte: o Autor.

### 6.3.3. Associação dos modos de variabilidade (EOFs) com índices climáticos

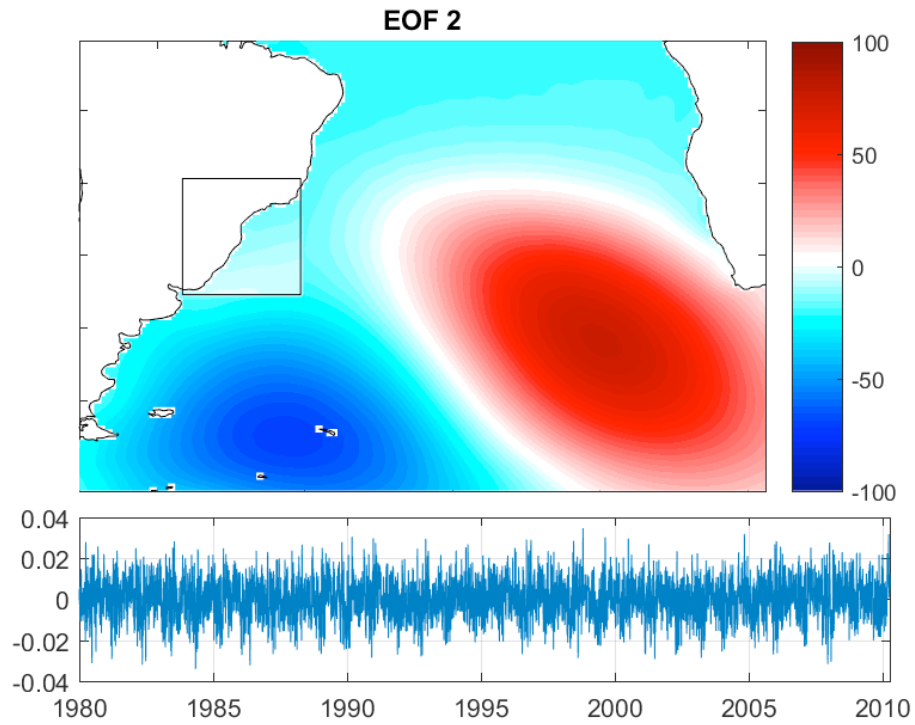
As 6 primeiras EOFs e suas respectivas PCs estão representadas graficamente da Figuras 29 a 34. Os mapas são expressos em unidades de anomalia de pressão. As módulos de variabilidade foram organizados automaticamente por ordem de variância explicada, portanto, a EOF responsável pela maior parte da variância dos dados é a EOF 1, que explica 17,3%, seguida pelas EOF 2: 7,3%, EOF 3: 6,6%, EOF 4: 5,6%, EOF 5: 5% e, por fim, EOF 6: 4,2%. No total, os 6 primeiros modos de variabilidade juntos explicam 46% da variância dos dados.

Figura 29. Função ortogonal empírica 1 (mapa) e sua componente principal (gráfico).



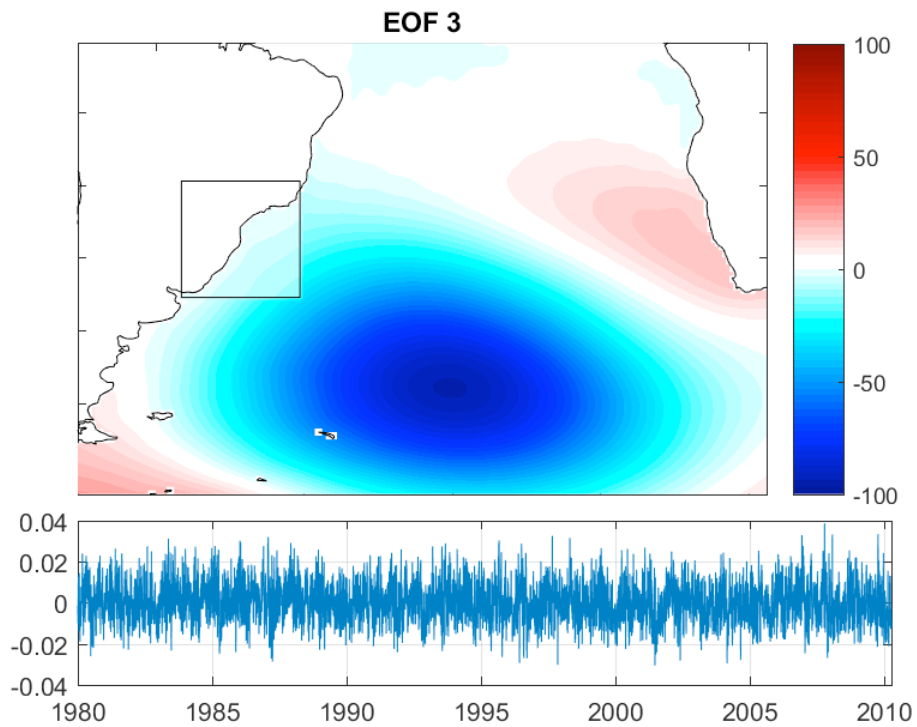
Fonte: o Autor.

Figura 30. Função ortogonal empírica 2 (mapa) e sua componente principal (gráfico).



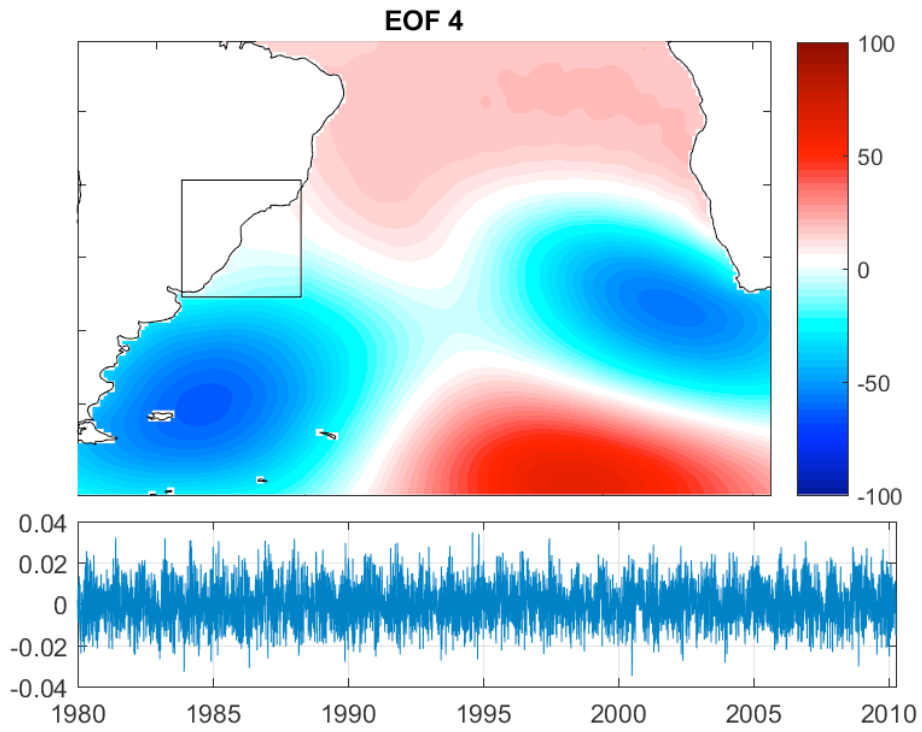
Fonte: o Autor.

Figura 31. Função ortogonal empírica 3 (mapa) e sua componente principal (gráfico).



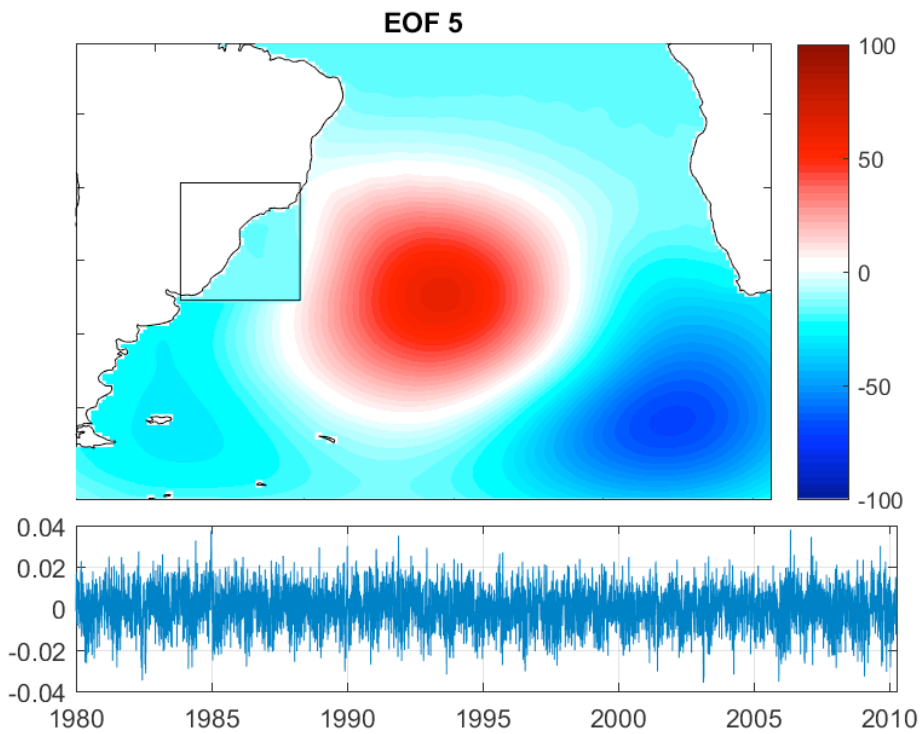
Fonte: o Autor.

Figura 32. Função ortogonal empírica 4 (mapa) e sua componente principal (gráfico).



Fonte: o Autor.

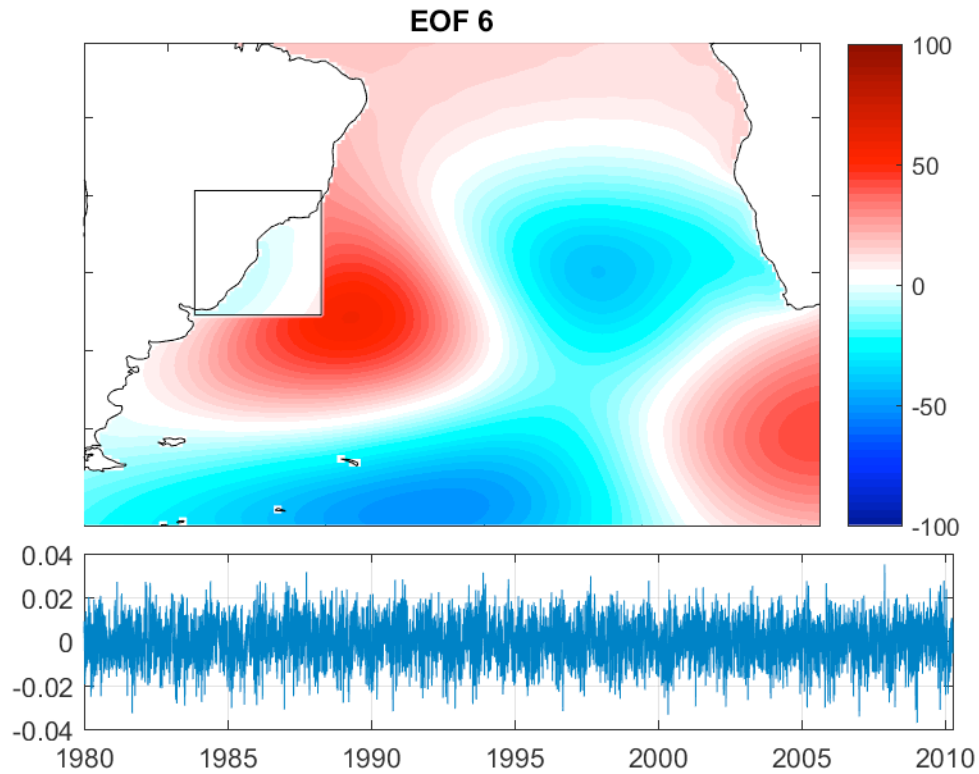
Figura 33. Função ortogonal empírica 5 (mapa) e sua componente principal (gráfico).



Fonte: o Autor.




Figura 34. Função ortogonal empírica 6 (mapa) e sua componente principal (gráfico).



Fonte: o Autor.

Observando o gráfico da PC referente a EOF 1 de forma mais minuciosa (Figura 35), foi possível identificar um padrão que se repete ano a ano, o que remete a um ciclo sazonal. É pertinente associar a maior variação dos dados à sazonalidade da área de interesse, tendo em vista que vários estudos como os de Araújo *et al.* (2003) e Melo Filho & Franco (2008) associam a probabilidade de ocorrência de diferentes parâmetros de estado de mar para cada estação e, inclusive, separam probabilidades de ocorrências de mares uni, bi e multi-modais de forma sazonal.

Figura 35. Gráfico ampliado da PC da EOF 1.



Fonte: o Autor.

Já as PCs das demais EOFs apresentam padrões extremamente complexos e difíceis de se extrair alguma informação de forma empírica. Para melhor interpretar a forma como esses modos de variabilidade se comportam foram realizadas análises de correlação com índices climáticos.

Os valores de correlação encontrados as correlações entre as 6 primeiras componentes principais e os 9 índices climáticos adotados nesse estudo se encontra na Tabela 8. Os valores em negrito representam as correlações significantes, consideração um nível de significância de 95%, enquanto os valores em vermelho correspondem a correlações não significativas.

Tabela 8. Valores de correlação de Pearson entre as 6 primeiras EOFs e 9 Índices climáticos.

	MEI	ONI	PDO	AAO	SAOD	NINO3.4	TSA	AMM	SOI
PC1	-0,04	-0,06	-0,03	-0,02	0,08	-0,05	0,17	-0,06	0,04
PC2	-0,12	-0,11	-0,12	0,04	-0,10	-0,16	0,03	0,06	0,12
PC3	0,21	0,19	0,13	-0,33	0,05	0,29	0,03	-0,26	-0,21
PC4	0,02	0,06	0,00	-0,36	-0,05	0,05	0,02	-0,02	-0,03
PC5	0,02	0,02	-0,01	-0,14	-0,05	-0,01	-0,07	-0,04	0,02
PC6	0,05	0,05	-0,03	0,22	0,09	-0,01	0,15	-0,10	-0,02

Os resultados demonstram que, apesar de não apresentarem forte correspondência, todos os índices analisados possuem alguma influência na forma como pelo menos um modo de variabilidade se comporta, embora não sejam os únicos fatores que explicam esse comportamento. Também foi possível notar pela Tabela 8 que algumas EOFs sofrem influência significativa de mais do que 1 dos índices investigados e o maior valor de correlação encontrado foi de -0,36.

A *Pacific Decadal Oscillation* apresentou correlação significativa somente com a EOF 3, a correlação encontrada foi de 0,13. Campos (2009) demonstrou haver uma correlação positiva entre a PDO e eventos gerados por ciclones, ou seja, há um aumento do número de ciclones nas fases positivas da PDO, justamente quando as águas do Pacífico Leste estão mais quentes (El Niño), cuja correlação com a EOF 3 também foi significativa e positiva.

A *Antarctic Oscillation* foi o índice climático que apresentou correlações significativas com o maior número de modos de variabilidade, sendo estes as EOFs 3, 4, 5 e 6. De acordo com Hemer et al. (2010) o AAO é um dos principais modos de variabilidade do Hemisfério Sul, o que torna compreensível sua correspondência com um maior número de EOFs. Os primeiros modos de variabilidade de altura de onda e direcional encontrados por eles no Hemisfério Sul estão fortemente correlacionados com a AAO. Ainda de acordo com Hemer et al. (2010) o Atlântico Sul e a região adjacente ao sudoeste da Austrália mostraram um leve giro da direção para Sudoeste e consequente diminuição na altura das ondas com um índice de AAO positivo e uma maior incidência da direção Sul para uma AAO negativa.

O índice Niño 3.4 obteve uma correlação significativamente negativa com a EOF 2 e positiva com a EOF 3. Segundo Cavalcanti (2003), nos anos de El Niño o forte aquecimento na região do Pacífico Equatorial cria um aumento no gradiente de temperatura, intensificando a corrente do jato subtropical, localizada entre 20°S e 35°S. Berlato & Fontana (2003) sugeriram que intensificação do jato cause bloqueios na atmosfera, tornando as frentes frias estacionárias no extremo Sul brasileiro, configuração meteorológica que favorece a formação de ondas de leste na região. De acordo com Faraco *et al.* (2004) durante os episódios de La Niña, a diminuição dos bloqueios do sistema frontal poderia aumentar o número de frentes frias que chegam ao sul do Brasil, havendo predomínio das ondulações sul e sudeste. Os índices MEI e ONI, por também serem relativos ao ENSO, possuem índices similares ao Niño 3.4 e, inclusive, suas correlações significativas foram encontradas com os mesmo modos de variabilidade e também possuem interação inversa com a EOF 2 e direta com a EOF 3.

A *Southern Oscillation Index*, por ser um índice inversamente relacionado ao ENSO (HEMER *et al.*, 2010), gera efeitos similares ao La Niña em sua fase positiva e El Niño em sua fase negativa. Essa associação inversa pode ser percebida também pelas correlações obtidas, sendo que a PC 2 apresentou uma correlação de -0,16 para o índice Niño 3.4 e 0,12 para o SOI, e a PC 3 apresentou 0,29 para Niño 3.4 e -0,21 para SOI.

Os demais índices climáticos cujas correlações com os modos de variabilidade foram testadas, apesar de também apresentarem correlação significativa com uma ou mais EOF, não possuem estudos voltados à sua influência no clima de ondas para a costa brasileira. Alguns estudos como o de Alonso *et al.* (2015) analisaram a correlação linear entre o TSA e a anomalia de energia mensal de ondas para a costa uruguaia, porém ela não foi significativa, por outro lado, Solari e Losada (2012) encontraram uma forte correlação entre o TSA e a direção média das ondas para o Oceano Atlântico Sul.

#### 6.4. RESULTADOS DAS OUTRAS ANÁLISES REALIZADAS

##### 6.4.1. Diferentes períodos de calibração e validação

Os valores de correlação entre Hs da série gerada pelo modelo M24 e os dados de Hs da reanálise ROW encontrados para os períodos de calibração, de 1 ano a 31 anos estão dispostos na Tabela 9. Separados, na Tabela 10, estão os valores encontrados para os períodos de validação de 1 semana até 1 ano.

Na tabela 9 os valores do cabeçalho se referem ao período adotado para a calibração. Na tabela 10 os valores do cabeçalho se referem ao período adotado para a validação. As tabelas são complementares e estão separadas apenas para melhor interpretação dos resultados. Os valores em vermelho representam as correlações não significativas.

Tabela 9. Valores de correlação de Pearson para os diferentes CPs analisados.

	<b>1 ano</b>	<b>2 anos</b>	<b>3 anos</b>	<b>4 anos</b>	<b>5 anos</b>	<b>6 anos</b>	<b>7 anos</b>	<b>8 anos</b>	<b>9 anos</b>	<b>10 anos</b>	
<b>Calibração</b>	1,00	0,97	0,93	0,90	0,88	0,86	0,85	0,85	0,84	0,84	
<b>Validação</b>	0,03	0,38	0,60	0,65	0,68	0,70	0,72	0,74	0,74	0,75	
	<b>11 anos</b>	<b>12 anos</b>	<b>13 anos</b>	<b>14 anos</b>	<b>15 anos</b>	<b>16 anos</b>	<b>17 anos</b>	<b>18 anos</b>	<b>19 anos</b>	<b>20 anos</b>	
	0,83	0,83	0,83	0,83	0,82	0,82	0,82	0,82	0,82	0,82	
	0,75	0,76	0,76	0,77	0,77	0,77	0,78	0,78	0,78	0,78	
	<b>21 anos</b>	<b>22 anos</b>	<b>23 anos</b>	<b>24 anos</b>	<b>25 anos</b>	<b>26 anos</b>	<b>27 anos</b>	<b>28 anos</b>	<b>29 anos</b>	<b>30 anos</b>	<b>31 anos</b>
	0,82	0,81	0,81	0,81	0,81	0,81	0,81	0,81	0,81	0,81	0,81
	0,78	0,79	0,78	0,79	0,79	0,79	0,79	0,78	0,78	0,80	0,81

Analisando os valores expostos na Tabela 9, fica claro que curtos períodos de calibração, apesar de apresentarem uma alta correlação nessa etapa, geram modelos sem capacidade de prever as séries de onda com qualidade. Apesar dos curtos períodos testados, apenas com 1 ano de calibração o resultado do modelo obtido não teve uma correlação significativa.

O aumento do intervalo de tempo utilizado para a calibração gera uma constante queda da correlação para este período, até se estabilizar em um valor de 0,81 com 22 anos de intervalo, mantendo o mesmo valor até 31 anos. Essa queda na correlação do período de calibração não necessariamente significa que o modelo está piorando. Na verdade, as correlações para a validação sofreram uma constante melhora enquanto o intervalo de calibração aumentava, e isso ocorreu até o intervalo de 22 anos, quando alcançou um valor de 0,79. Após os 22 anos as correlações para a validação se estabilizaram e oscilaram entre 0,78 e 0,79 até o período de 29 anos. Com 30 anos de intervalo para calibração a correlação da validação subiu para 0,80, seguida de outra melhora com 31 anos, chegando a 0,81.

Tabela 10. Correlações de Pearson para os diferentes VPs analisados.

	1 semana	2 semana	3 semana	1 mês	2 meses	3 meses	4 meses
Calibração	0,81	0,81	0,81	0,81	0,81	0,81	0,81
Validação	0,00	0,13	0,62	0,59	0,70	0,72	0,70

	5 meses	6 meses	7 meses	8 meses	9 meses	10 meses	11 meses
	0,81	0,81	0,81	0,81	0,81	0,81	0,81
	0,79	0,82	0,80	0,79	0,81	0,81	0,82

Como Tabela 10 complementa a Tabela 9, ao se considerar 1 semana de validação, consequentemente se tem 31 anos, 11 meses e 3 semanas para a calibração, a qual seguiu constante com correlações de 0,81 até esse intervalo.

Os valores de correlação para a validação mostraram uma grande e constante melhora até o intervalo de 5 meses, quando alcança 0,79. Em seguida, com 6 meses o valor sobe para 0,82, porém, oscila nos próximos intervalos adotados entre 0,79 e 0,82

até os 11 meses. Por consequência com a Tabela 9, é conhecido que aos 12 meses (1 ano de validação e 31 de calibração) a correlação da validação voltará para 0,81.

#### 6.4.2. Diferentes resoluções espaciais

Os resultados para as correlações utilizando as resoluções espaciais de 0,5°x0,5° (HR) e 2°x2° (LR) para a metodologia ESTELA estão organizados nas tabelas 11 e 12, respectivamente.

*Tabela 11 e Tabela 12. Correlações de Pearson para os diferentes lags analisados para a metodologia ESTELA utilizando dados HR (esquerda) e LR (direita).*

HR	Calibração	Validação
Lag 1	0,75	0,75
Lag 2	0,81	0,80
Lag 3	0,83	0,81
Lag 4	0,83	0,82
Lag 5	0,84	0,81
Lag 6	0,84	0,81
Lag 7	0,84	0,81
Lag 8	0,84	0,81
Lag 9	0,85	0,81
Lag 10	0,85	0,81
Lag 11	0,85	0,80
Lag 12	0,85	0,80

LR	Calibração	Validação
Lag 1	0,75	0,74
Lag 2	0,81	0,80
Lag 3	0,82	0,81
Lag 4	0,83	0,81
Lag 5	0,83	0,81
Lag 6	0,84	0,81
Lag 7	0,84	0,81
Lag 8	0,84	0,81
Lag 9	0,84	0,81
Lag 10	0,84	0,80
Lag 11	0,85	0,80
Lag 12	0,85	0,80

Apesar de ocorrerem algumas condições aonde a HR resulta em melhores valores de correlação, eles são de apenas 0,01, havendo a predominância de valores iguais para ambas as resoluções analisadas.

Os resultados encontrados para o CP e o VP, com as diferentes resoluções, para o modelo M24 utilizando diferentes períodos de calibração são comparados nas tabelas 13 e 14.

Confirmando os resultados expostos anteriormente para a metodologia ESTELA, os valores obtidos para as correlações de ambas as resoluções para o modelo M24 são também extremamente próximos. Os resultados apresentaram algumas maiores discrepâncias apenas nos intervalos de calibração mais curtos, sendo que elas

praticamente desaparecem a partir de um intervalo de 5 anos para a calibração. Para os períodos maiores que 5 anos, os resultados são todos praticamente iguais e, quando apresentam diferenças, são também de no máximo 0,01.

Como cada grade analisada com  $0,5^{\circ} \times 0,5^{\circ}$  de resolução possuía 24,003 pontos, o período selecionado possui 11,657 dias e, considerando que a matriz utilizada para a single value decomposition contempla tanto dados de SLP quanto gradiente de SLP em sua composição, foram utilizados um total de 559,605,942 pontos de grade para executar o modelo M24 com HR, o que levou aproximadamente 48 horas para ser calculado com um computador com 16 GB de memória RAM. Ao diminuir a resolução para  $2^{\circ} \times 2^{\circ}$ , houve uma redução de 419,704,457 pontos a serem processados, continuou-se a obter altas correlações e os resultados foram extremamente aproximados e o tempo de execução dos cálculos para a SVD foi menor do que 5 segundos.

Tabela 13 e Tabela 14. Correlações de Pearson para os diferentes CPs analisados utilizando dados HR (esquerda) e LR (direita).

HR	Calibração	Validação
1 ano	1,00	0,01
2 anos	0,97	0,38
3 anos	0,93	0,60
4 anos	0,90	0,65
5 anos	0,88	0,68
6 anos	0,86	0,70
7 anos	0,85	0,72
8 anos	0,85	0,74
9 anos	0,84	0,74
10 anos	0,84	0,75
11 anos	0,83	0,75
12 anos	0,83	0,76
13 anos	0,83	0,76
14 anos	0,83	0,77
15 anos	0,82	0,77
16 anos	0,82	0,77
17 anos	0,82	0,78
18 anos	0,82	0,78
19 anos	0,82	0,78
20 anos	0,82	0,78
21 anos	0,82	0,78
22 anos	0,81	0,79
23 anos	0,81	0,78
24 anos	0,81	0,79
25 anos	0,81	0,79
26 anos	0,81	0,79
27 anos	0,81	0,79
28 anos	0,81	0,78
29 anos	0,81	0,78
30 anos	0,81	0,80
31 anos	0,81	0,81

LR	Calibração	Validação
1 ano	1,00	0,03
2 anos	0,96	0,44
3 anos	0,91	0,62
4 anos	0,89	0,67
5 anos	0,87	0,68
6 anos	0,85	0,70
7 anos	0,84	0,72
8 anos	0,84	0,74
9 anos	0,84	0,74
10 anos	0,83	0,75
11 anos	0,83	0,75
12 anos	0,82	0,75
13 anos	0,82	0,76
14 anos	0,82	0,77
15 anos	0,82	0,77
16 anos	0,81	0,77
17 anos	0,81	0,77
18 anos	0,81	0,77
19 anos	0,81	0,77
20 anos	0,81	0,78
21 anos	0,81	0,78
22 anos	0,81	0,78
23 anos	0,81	0,78
24 anos	0,81	0,78
25 anos	0,81	0,79
26 anos	0,80	0,79
27 anos	0,81	0,79
28 anos	0,81	0,78
29 anos	0,81	0,78
30 anos	0,80	0,80
31 anos	0,80	0,80



## 7. CONCLUSÃO

Neste trabalho caracterizou-se o clima de ondas de Santa Catarina através da metodologia de refinamento estatístico com abordagem por weather-types. A metodologia foi considerada eficiente, originando séries com valores de parâmetros de onda coerentes para o período analisado.

Foi possível notar que a região do oceano Atlântico com maior influência na geração de ondas que atingem Santa Catarina se encontra a uma distância de até 4 dias de viagem da costa, sendo que a utilização da informação contida fora dessa região não contribuiu com melhorias significativas para a performance do modelo.

A utilização de weather-types para a caracterização dos diferentes parâmetros de onda se mostrou de grande utilidade, principalmente devido ao fato de que a costa catarinense possui a característica de mar bi-modal, facilitando a identificação das características intrínsecas a cada estado de mar e sua respectiva configuração atmosférica associada.

O fator que contribuiu com a maior parte da variância do clima de ondas foi a sazonalidade da região, porém, as correlações significativas com diversos índices climáticos, mesmo de fenômenos com seu centro de atuação fora do Atlântico Sul (por exemplo ENSO), demonstram que o clima de ondas da região é de caracterização complexa.

Os testes para diferentes períodos de calibração mostraram que estes devem ser os mais longos possíveis, porém, respeitando o intervalo de pelo menos um ano para o período de validação, a fim de garantir a qualidade dos resultados do modelo de SD. Períodos muito curtos para a calibração (< 5 anos) mostraram-se incapazes de reproduzir bons resultados durante o período de validação. Por sua vez, períodos muito curtos de validação (< 5 meses), mesmo com longos intervalos de calibração, foram mal simulados pelo modelo de refinamento estatístico.

Por fim, utilizar base de dados com resolução de até  $2^{\circ} \times 2^{\circ}$  demandou um esforço computacional extremamente menor do que os dados de resolução  $0,5^{\circ} \times 0,5^{\circ}$ , com um resultado final com diferenças irrisórias.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS (formatar e arrumar as inseridas por último)

Alonso, R., Solari, S. and Teixeira, L. "Wave energy resource assessment in Uruguay." **Energy** 93 (2015): 683-696.

Abdi, Hervé. "Singular value decomposition (SVD) and generalized singular value decomposition." **Encyclopedia of measurement and statistics** (2007): 907-912.

Alves, J.H.G.M. Refração do Espectro de Ondas Oceânica em Águas Rasas: Aplicações à Região Costeira de São Francisco do Sul, SC. 1996. 89p.

Araújo, Carlos ES, Davide Franco, Eloi Melo, and Felipe Pimenta. "Wave regime characteristics of the southern Brazilian coast." In Proceedings of the sixth international conference on coastal and port engineering in developing countries, **COPEDEC VI**, Colombo, Sri Lanka, Paper, no. 097, p. 15. 2003.

Bjornsson, H., and S. A. Venegas. "A manual for EOF and SVD analyses of climatic data." **CCGCR Report** 97, no. 1 (1997): 112-134.

Caires, Sofia, Val R. Swail, and Xiaolan L. Wang. "Projection and analysis of extreme wave climate." **Journal of Climate** 19, no. 21 (2006): 5581-5605.

Callaghan, D.P., Nielsen, P., Short, A., Ranasinghe, R., 2008. Statistical simulation of wave climate and extreme beach erosion. **Coast. Eng.** 55, 375–390.

Camus, P., Cofiño, A., Mendez, F.J., Medina, R., 2011b. Multivariate wave climate using self-organizing maps. **J. Atmos. Oceanic Technol.** 28, 1554–1658.

Camus, P., Menéndez, M., Méndez, F.J., Izaguirre, C., Espejo, A., Cánovas, V., Pérez, J., Rueda, A., Losada, I.J., Medina, R., 2014. A weather-type statistical refinement framework for ocean wave climate. **J. Geophys. Res.: Oceans** 119 (11), 7389–7405.

Casas-Prat M, Wang X. L., Sierra JP (2014) A physical-based statistical method for modeling ocean wave heights. **Ocean Model** 73:59–75

Cherfas, C. The fringe of the ocean – under siege from land. **Science**, v. 248, n. 4952, p. 163-164, 1990.

da Silva, Graziela Miot, Seyed Mostafa Siadat Mousavi, and Felix Jose. "Wave-driven sediment transport and beach-dune dynamics in a headland bay beach." **Marine Geology** 323 (2012): 29-46.

Enfield, D. B., Mestas-Nuñez, A.m., Mayer, D. A., & Cid-Serrano, L. 1999. How ubiquitous is the dipole relationship in tropical Atlantic sea surface temperatures? **Journal of Geophysical Research: Oceans**, 104(C4), 7841-7848.

Figueiredo Filho, Dalson Britto, and José Alexandre da Silva Júnior. "Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)." (2009).

Fowler, H. J., S. Blenkinsop, and C. Tebaldi (2007), Linking climate change modelling to impact studies: Recent advances in refinement techniques for hydrological modelling, **Int. J. Climatol.**, 27, 1547–1578.

Giorgi, F., B. Hewitson, J. Christensen, M. Hulme, H. von Storch, P. Whetton, R. Jones, L. Mearns, and C. Fu (2001), Regional climate information-Evaluation and projections, in Climate Change 2001. **The Scientific Basis**. Contribution of Working Group to the Third Assessment Report of the IPCC: Contribution to Working Group I, edited by J. T. Houghton et al., chap. 10, pp. 583–638, Cambridge Univ. Press, Cambridge, U. K.

Gong, Daoyi, and Shaowu Wang. "Definition of Antarctic oscillation index." **Geophysical research letters** 26, no. 4 (1999): 459-462.

Gutiérrez, J. M., D. San-Martín, S. Brands, R. Manzanos, and S. Herrera (2013), Reassessing statistical refinement techniques for their robust application under climate change conditions, **J. Clim.**, 26(1), 171–188.

Holthuijsen, L.H., 2007. Waves in Oceanic and Coastal Waters. **Cambridge University Press**, Cambridge, p. 387.

Horn-Filho, N., O., Silva, M. Roteiro Ecológico-Ambiental ao Longo da Planície Costeira da Ilha de Santa Catarina, SC, Brasil. 2010. **Revista Discente Expressões Geográficas**, no 07, Florianópolis, ano VII, p. 210 – 231.

Horn-Filho, N. O., Setorização Da Província Costeira de Santa Catarina Em Base Aos Aspectos Geológicos, Geomorfológicos E Geográficos Introdução. **Geosul** (UFSC), v. 35, n.18, p. 71–98, 2013.

Hughes, M.G., Heap, A.D., 2010. National-scale wave energy resource assessment for Australia. **Renew. Energy** 35, 1783–1791.

IBGE. *Pesquisa nacional por amostra de domicílios: síntese de indicadores 1999*. **Ibge**, 2000.

Izaguirre C, Menéndez M, Camus P, Mendez FJ, Minguez R, Losada IJ (2012) Exploring the Interannual variability of extreme wave climate in the Northeast Atlantic Ocean. **Ocean Model.** 59–60:31–40

Klein, Antonio Henrique da F., Andrew D. Short, and Jarbas Bonetti. "Santa Catarina beach systems." In **Brazilian Beach Systems**, pp. 465-506. Springer, Cham, 2016.

Knutson, Thomas R., Joseph J Sirutis, Gabriel A Vecchi, Stephen T Garner, Ming Zhao, Hyeong-Seog Kim, Morris A Bender, Robert E Tuleya, Isaac M Held, and G Villarini, September 2013: Dynamical refinement projections of 21st century Atlantic hurricane activity: CMIP3 and CMIP5 model-based scenario. **Journal of Climate**, 26(17), DOI:10.1175/JCLI-D-12-00539.1.

Komar, P. D., **Beach processes and sedimentation**. 2nd ed. Upper Saddle River, N.J.: Prentice Hall, 1998. 544 p.

Maraun, Douglas, F. Wetterhall, A. M. Ireson, R. E. Chandler, E. J. Kendon, M. Widmann, S. Brienen et al. "Precipitation refinement under climate change: Recent developments to bridge the gap between dynamical models and the end user." **Reviews of Geophysics** 48, no. 3 (2010).

Melo Filho, E., Hammes, G. R., & Franco, D. 2006. Estudo de caso: a ressaca de agosto de 2005 em Santa Catarina.

Monteiro, A.M. & Furtado, S.M. O clima do trecho Florianópolis – Porto Alegre: uma abordagem dinâmica. **Geosul**, v. 9, p. 117-133, 1995.

Nicholls, R.J., Townend, I.H., Bradbury, A., Ramsbottom, D., Day, S.A., 2013. Planning for long-term coastal change: experiences from England and Wales. **Ocean Eng.** 71, 3–16.

Nimer, E., Climatologia da Região Sul. **Revista Brasileira de Geografia**, v. 34(1), p.142-154, 1989.

Nnamchi, H.C., J. P. Li. and R. N. C. Anyadike, 2011: Does a dipole mode really exist in the South Atlantic Ocean? **J. Geophys. Res.**, 116, doi: 10.1029/2010JD015579.

NOAA. "Southern Oscillation Index (SOI)", **Teleconnections**, National Centers for Environmental Information (NCEI). Disponível em: <<https://www.ncdc.noaa.gov/teleconnections/enso/indicators/soi/>> Acesso em 22 mar. 2019.

NOAA. "MEI.v2". **ESRL**. Disponível em: <<https://www.esrl.noaa.gov/psd/enso/mei/>> Acesso em 22 mar. 2019.

Oliveira, Bruna Alves de. "Variabilidade do clima de ondas de Santa Catarina-Brasil utilizando o modelo Wavewatch III." (2017).

Pérez, Jorge, Fernando J. Méndez, Melisa Menéndez, and Inigo J. Losada. "ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area." **Ocean Dynamics** 64, no. 8 (2014): 1181-1191.

Pianca, Cássia, Piero Luigi F. Mazzini, and Eduardo Siegle. "Brazilian offshore wave climate based on NWW3 reanalysis." **Brazilian Journal of Oceanography** 58, no. 1 (2010): 53-70.

Pollete, M.; Souza, J. G. & Mazzer, A. M. 1995. **Geocologia da paisagem costeira do Estado de Santa Catarina**. In: Regional conference of Latin American and Caribbean Countries – International geographical Union. Latin American in the World: Environment Society and Development. Havana, Cuba. Resumos, 200p.

Raschle N, Ardhuin F, Queffelec P, Croizé-Fillon D (2008) A global wave parameter database for geophysical applications. Part 1: Wave–current–turbulence interaction parameters for the open ocean based on traditional parameterizations. **Ocean Model** 25(3–4):154–171.doi:10.1016/j.ocemod.2008.07.006

Reguero BG, Menéndez M, Méndez FJ, Mínguez R, Losada IJ (2012) A Global Ocean Wave (GOW) calibrated reanalysis from 1948 onwards. **Coast. Eng.** 65:38–55. doi: 10.1016/j.coastaleng. 2012.03.003

Rodrigues, M.L.G.; Franco, D.; Sugahara, S. Climatologia de frentes frias no litoral de Santa Catarina. **Revista Brasileira de Geofísica**, v. 22(2), p. 135-151, 2004.

Saha, S., S. Moorthi, H. Pan, X. Wu, J. Wang, and Coauthors, 2010: The NCEP Climate Forecast System Reanalysis. **Bulletin of the American Meteorological Society**, 91, 1015–1057

SANTA CATARINA (Estado). Decreto nº 5.010, de 22 de dezembro de 2006. Regulamenta a Lei n. 13.553, de 16 de novembro de 2005. **Lex**: coletânea de legislação e jurisprudência, Florianópolis, 2006.

Schlining, B., Signell, R., Crosby, A. "nctoolbox (2009)", **GitHub repository**. Disponível em: <<https://github.com/nctoolbox/nctoolbox>> Acesso em: 10 abr. 2019

Semedo, A., Sušelj, K., Rutgersson, A., Sterl, A., 2011. A global view on the wind-sea and swell climate and variability from ERA-40. **J. Clim.** 24 (5), 1461–1479.

Siegle, Eduardo, and Nils Edvin Asp. "Wave refraction and longshore transport patterns along the southern Santa Catarina coast." **Brazilian Journal of Oceanography** 55, no. 2 (2007): 109-120.

Solari, Sebastián, and Miguel Ángel Losada. "Parametric and non-parametric methods for the study of the variability of wave directions: application to the Atlantic Uruguayan coasts." **Coastal Engineering Proceedings** 1, no. 33 (2012): 14.

Storlazzi, C.D., Brown, E., Field, M.E., Rodgers, K., Jokiel, P.L., 2005. A model for wave control on coral breakage and species distribution in the Hawaiian Islands. **Coral Reefs** 24 (1), 43–55.

Sumiyoshi, Chika & Fujino, Haruo & Sumiyoshi, Tomiki & Yasuda, Yuka & Yamamori, Hidenaga & Fujimoto, Michiko & Hashimoto, Ryota. (2018). Semantic Memory Organization in Japanese Patients With Schizophrenia Examined With Category Fluency. **Frontiers in Psychiatry**. 9. 87. 10.3389/fpsy.2018.00087.

Sverdrup, Harald Ulrik, and Walter Heinrich Munk. "Empirical and theoretical relations between wind, sea, and swell." **Eos, Transactions American Geophysical Union** 27, no. 6 (1946): 823-827.

Trenberth, Kevin & National Center for Atmospheric Research Staff (Eds). Last modified 11 Jan 2019. "**The Climate Data Guide: Nino SST Indices (Nino 1+2, 3, 3.4, 4; ONI and TNI).**" Retrieved from <https://climatedataguide.ucar.edu/climate-data/nino-sst-indices-nino-12-3-34-4-oni-and-tni>.

UNIVERSITY OF WASHINGTON (2019). "*Antarctic Oscillation (AAO)*". Disponível em: <http://research.jisao.washington.edu/data/aa0/>> Acesso em 23 mar. 2019.

Wall, Michael E., Andreas Rechtsteiner, and Luis M. Rocha. "Singular value decomposition and principal component analysis." In *A practical approach to microarray data analysis*, pp. 91-109. **Springer**, Boston, MA, 2003.

Wang, X. L., Y. Feng, and V. R. Swail (2012), North Atlantic wave height trends as reconstructed from the 20th century reanalysis, **Geophys. Res. Lett.**, 39, L18705, doi: 10.1029/2012GL053381.

Wang X. L., Zwiers FW, Swail VR (2004) "North Atlantic Ocean wave climate change scenarios for the twenty-first century". **J Clim** 17:2368–2383

Woolf, David K., P. G. Challenor, and P. D. Cotton. "Variability and predictability of the North Atlantic wave climate." **Journal of Geophysical Research: Oceans** 107, no. C10 (2002).

YALE UNIVERSITY. "Linear Regression". Disponível em: <http://www.stat.yale.edu/Courses/1997-98/101/linreg.htm>> Acesso em 17 abr. 2019.