



UNIVERSIDADE FEDERAL DO CEARÁ
INSTITUTO DE CIÊNCIAS DO MAR
CURSO DE GRADUAÇÃO EM OCEANOGRAFIA

JOÃO MATEUS LOBO GUERRA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA DETECÇÃO DE PADRÕES
DE TEMPERATURA SUPERFICIAL DO ATLÂNTICO TROPICAL**

FORTALEZA

2018

JOÃO MATEUS LOBO GUERRA

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA DETECÇÃO DE PADRÕES DE
TEMPERATURA SUPERFICIAL DO ATLÂNTICO TROPICAL

Trabalho de Conclusão de Curso apresentado
ao Curso de Graduação em Oceanografia do
Instituto de Ciências do Mar da Universidade
Federal do Ceará, como requisito parcial à
obtenção do grau de bacharel em Oceanografia.

Orientador: Prof. Dr. Antônio Geraldo
Ferreira

Coorientadora: Profa. Dra. Ana Paula
Morais Krelling

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

G963a Guerra, João Mateus Lobo.
APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS PARA DETECÇÃO DE PADRÕES DE
TEMPERATURA SUPERFICIAL DO ATLÂNTICO TROPICAL / João Mateus Lobo Guerra. – 2018.
39 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Instituto de Ciências do
Mar, Curso de Oceanografia, Fortaleza, 2018.

Orientação: Prof. Dr. Antônio Geraldo Ferreira.

Coorientação: Profa. Dra. Ana Paula Morais Krelling.

1. Self-Organizing Maps. 2. Temperatura Superficial do Mar. 3. Atlântico Tropical. 4. Oceanografia
Física. I. Título.

CDD 551.46

JOÃO MATEUS LOBO GUERRA

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA DETECÇÃO DE PADRÕES DE
TEMPERATURA SUPERFICIAL DO ATLÂNTICO TROPICAL

Trabalho de Conclusão de Curso apresentado
ao Curso de Graduação em Oceanografia do
Instituto de Ciências do Mar da Universidade
Federal do Ceará, como requisito parcial à
obtenção do grau de bacharel em Oceanografia.

Aprovada em: 10 de Dezembro de 2018

BANCA EXAMINADORA

Prof. Dr. Antônio Geraldo Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Profa. Dra. Ana Paula Morais
Krelling (Coorientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Carlos Eduardo Peres Teixeira
Universidade Federal do Ceará (UFC)

Dedico aos meus pais, por razões que são inúmeras! Aos meus irmãos, especialmente à Caroline, grande apaixonada pelos mares, por ter me incitado a escolher esse curso e também pelo enorme apoio e discussões sobre assuntos marítimos! À minha tia Elizabeth pelo enorme carinho e a sua admiração pela Oceanografia.

AGRADECIMENTOS

Na medida da minha capacidade de síntese, tentarei discorrer sobre as queridas pessoas que me ajudaram nessa empreitada. Ariela, meu bem querer, que sempre me ajuda em todos os aspectos da vida e que me ensina a viver e a aproveitar tudo que há nesse mundo!

À minha família, assim como também lhe dedico o resultado desse pequeno esforço mental, pelo todo apoio dado. :)

Erik Zarko Solha, que foi companheiro de TCC e que instigou a fazer um trabalho mais metodológico, sempre que possível falando de música (e cantando de Bee Gees a Vinny), além de trocentas curiosidades, como o nome dele ser muito oceanográfico (Zarco foi um explorador português e Solha, bem, é um peixe).

Agradeço à Ana Paula pela enorme ajuda na elaboração deste trabalho e pelo apoio e o aceite em orientar-me, assim como os diversos ensinamentos.

Aos amigos do Laboratório de Oceanografia Física (saudoso e *underground* LOF), Jonathan, Bárbara, Airton, Gabriela, Gustavim, Rafael e Ítele!

Agradeço também ao meu orientador, Geraldo, por ter aceitado a orientação nesse segundo semestre e pelas oportunidades de embarque.

Ao professor Carlos Teixeira, meus sinceros agradecimentos pela participação na banca e sua grande contribuição, assim por diversos outros momentos e conversas interessantes!

Fico muito agradecido por ter sido parte da grandiosa instituição que é a Universidade Federal do Ceará. Agradeço aos seus servidores, por permitirem que as engrenagens do dia-a-dia funcionem. Sem vocês, nada disso seria possível!

“Puppet Master: It can also be argued that DNA is nothing more than a program designed to preserve itself. Life has become more complex in the overwhelming sea of information. And life, when organized into species, relies upon genes to be its memory system. So man is an individual only because of his intangible memory. But memory cannot be defined, yet it defines mankind. The advent of computers and the subsequent accumulation of incalculable data has given rise to a new system of memory and thought, parallel to your own. Humanity has underestimated the consequences of computerization.

Nakamura: Nonsense! This babble is no proof at all that you’re a living, thinking life form!

Puppet Master: And can you offer me proof of your existence? How can you, when neither modern science nor philosophy can explain what life is?”

(Masamune Shirow)

RESUMO

Os *Self-Organizing Maps* (SOM) são um algoritmo de Redes Neurais Artificiais não supervisionado que é capaz de representar padrões dentro de um conjunto de dados. Baseia-se em dois pilares, competição e cooperação entre neurônios. Na Oceanografia Física, um cientista pode encontrar uma enorme quantidade de dados que nem sempre são usados ou analisados. Portanto, essa metodologia é útil dada a sua capacidade de iterar em grandes conjuntos de dados, extraindo padrões, dependendo apenas da capacidade de processamento disponível. Este trabalho tem como objetivos aplicar o algoritmo dos SOM em dados de temperatura da superfície do mar (TSM) de 30 anos do Atlântico Tropical, avaliar sua viabilidade e qualidade e compará-lo com métodos tradicionais. Essa mesma metodologia também será aplicada às anomalias de TSM. Conseguimos encontrar mudanças sazonais e pequenas variabilidades interanuais, que foram consistentes com aqueles encontrados anteriormente. Ao calcular os centroides para as frequências relativas de cada neurônio, a assimetria de aquecimento/resfriamento do Atlântico Tropical foi bem resolvida. Com relação às anomalias de TSM, o algoritmo teve um desempenho ligeiramente inferior, o que concluímos ser devido ao tamanho da grade definida, embora tenha sido capaz de identificar padrões semelhantes ao método das Funções Ortogonais Empíricas.

Palavras-chave: *Self-Organizing Maps*. Temperatura Superficial do Mar. Atlântico Tropical. Oceanografia Física.

ABSTRACT

The Self-Organizing Maps are an unsupervised Artificial Neural Network algorithm that is able to represent patterns within a dataset. It is based on two pillars, competition and cooperation between neurons. In Physical Oceanography, a scientist might find a huge amount of data that not always is used or analysed. Therefore, this methodology proves helpful given its ability to iterate through large datasets, extracting patterns, only dependant on the processing power available. This work aims to input a 30-year Tropical Atlantic's Sea Surface Temperature (SST) data into a Self-Organizing Map, assess its feasibility and quality and compare it with traditional methods. This same methodology will also be applied to SST anomalies. We were able to find both seasonal changes and slight interannual variabilities, which were consistent with previous findings. When plotting centroids for the relative frequency of each neuron, the heating/cooling assymetry of the Tropical Atlantic was well resolved. With regard to SST anomalies, the algorithm had a slightly weak performance, which we conclude to be due to the setted grid size, although it was able to identify patterns similar to the Empirical Orthogonal Functions method.

Keywords: Self-Organizing Maps. Surface Sea Temperature. Tropical Atlantic. Physical Oceanography.

LISTA DE FIGURAS

Figura 1	– Exemplo de um SOM retangular com k_x e $k_y = 4$	15
Figura 2	– Exemplo de um SOM utilizado com TSM, mostrando os dois padrões mais frequentes.	16
Figura 3	– Área amostral, exemplificando com dados de TSM obtidos a partir do conjunto de dados GHRSSST. Temperatura em graus Celsius.	19
Figura 4	– Esquema de pré-processamento dos dados. Cada imagem de temperatura (esquerda), uma matriz com 80 <i>pixels</i> de longitude por 42 <i>pixels</i> de latitude, é transformada em um vetor (direita), totalizando 2412 <i>pixels</i> , após excluir a máscara continental. Por fim, cada vetor é concatenado, totalizando 720 linhas, ou dias amostrais.	20
Figura 5	– Ilustração da organização de um SOM 5x3 após uma iteração. Note o neurônio vencedor m_{53} e a sua vizinhança, após uma iteração. Pontos em azul representam um conjunto de dados. Os neurônios são mostrados em preto. Em cinza estão as posições originais.	21
Figura 6	– Comparação entre SOM (a) e EOF (b) para quatro padrões de onda seguidas, com as respectivas frequências de ocorrência.	22
Figura 7	– Resultado da rede neural para TSM no Atlântico tropical, para um período amostral de 30 anos.	26
Figura 8	– Frequência relativa de cada neurônio, dividida por meses. O somatório de cada mês equivale a 100%. Cada célula equivale a um neurônio, onde as maiores porcentagens indicam a predominância do neurônio em cada mês.	28
Figura 9	– Centroides e a correspondente trajetória para as frequências da Figura 8.	29
Figura 10	– Resultado da subtração de temperaturas entre os neurônios 11 e 6	30
Figura 11	– Índice do Modo Meridional do Atlântico para o mês de março, entre os anos de 1986 a 2016. A linha central marca um MMA nulo. As cores azul e vermelha representam índices maiores ou menores que 1, respectivamente. Índices entre esses valores estão em preto. As linhas tracejadas indicam os valores de 1 e -1.	31

Figura 12 – Gráfico relacionando os neurônios tidos como vencedores com os anos mais similares para o mês de março. Cor azul indica MMA maior que 1. Pontos em vermelho indicam MMA menor que 1. Círculos pretos indicam MMA entre 1 e -1.	32
Figura 13 – Resultado da rede neural para anomalias de TSM no Atlântico tropical, para um período amostral de 30 anos.	33
Figura 14 – Anomalias de TSM, em °C, para o dia 01/03/2010.	34
Figura 15 – Primeiro (a) e segundo (b) modos para o EOF de TSM mensal, entre 1984-1987. Unidades em 1/100 °C	34
Figura 16 – Frequência de cada neurônio mensalmente.	39

LISTA DE ABREVIATURAS E SIGLAS

AVHRR	<i>Advanced Very High Resolution Radiometer</i>
BMU	<i>Best Matching Unit</i>
CSV	<i>Comma Separated Values</i>
EOF	<i>Empirical Orthogonal Functions</i>
EQ	Erro de Quantização
ESRL	<i>Earth System Research Laboratory</i>
ET	Erro Topográfico
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
GHR SST	<i>Group for High Resolution Sea Surface Temperature</i>
MATLAB	<i>Matrix Laboratory</i>
MMA	Modo Meridional do Atlântico
NCEI	<i>National Centers for Environmental Information</i>
NetCDF	<i>Network Common Data Form</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OPeNDAP	<i>Open-source Project for a Network Data Access Protocol</i>
PODAAC	<i>Physical Oceanography Distributed Active Archive Center</i>
SOM	<i>Self-Organizing Maps</i>
TSM	temperatura na superfície do mar
ZCIT	Zona de Convergência Intertropical

LISTA DE SÍMBOLOS

a_{ij}	Neurônio na posição ij da grade
k_x	Posição x na grade
k_y	Posição y na grade
m_{ij}	Vetor na posição ij da grade
X	Vetor de entrada

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Mapas auto-organizáveis (SOM)	15
<i>1.1.1</i>	<i>Exemplo de aplicação em Oceanografia</i>	<i>15</i>
2	OBJETIVOS	17
2.1	Geral	17
2.2	Específicos	17
3	METODOLOGIA	18
3.1	Área de estudo	18
3.2	Conjunto de dados	18
<i>3.2.1</i>	<i>Dados sinóticos de TSM</i>	<i>18</i>
<i>3.2.2</i>	<i>Dados para anomalia de TSM</i>	<i>19</i>
3.3	Pré-processamento	20
<i>3.3.1</i>	<i>Dados GHRSSST</i>	<i>20</i>
<i>3.3.2</i>	<i>Dados NOAA</i>	<i>20</i>
3.4	Redes Neurais de Kohonen	20
<i>3.4.1</i>	<i>SOM versus EOF</i>	<i>22</i>
<i>3.4.2</i>	<i>SOM Toolbox</i>	<i>23</i>
<i>3.4.2.1</i>	<i>Parâmetros da rede neural</i>	<i>23</i>
3.5	Determinação dos centroides	24
4	RESULTADOS	25
4.1	Dados GHRSSST	25
<i>4.1.1</i>	<i>Frequências relativas</i>	<i>27</i>
<i>4.1.2</i>	<i>Estudo de um mês específico</i>	<i>29</i>
4.2	Anomalias de temperatura	31
5	CONCLUSÕES E TRABALHOS FUTUROS	35
	REFERÊNCIAS	37
	APÊNDICES	39
	APÊNDICE A – Frequência relativa para anomalias	39

1 INTRODUÇÃO

Até os primeiros anos do século XXI estimava-se que apenas uma ínfima porcentagem de imagens obtidas por satélites era efetivamente analisada por cientistas (PETROU, 2004). Estipula-se uma restrição às análises principalmente devida ao tempo limitado do pesquisador para analisar grandes conjuntos de dados. Com o avançar dos anos, houve um incremento na quantidade de dados observacionais, embora ainda incipientes em certas regiões. Dados tais que podem ser obtidos de diversas formas: por meio de plataformas orbitais, por equipamentos fundeados, em boias ou por flutuadores, e ainda aqueles resultantes de modelos numéricos.

Para contornar tal problemática, pode-se recorrer ao método das redes neurais de Kohonen, ou SOM, mapas auto-organizáveis capazes de encontrar padrões em um conjunto multidimensional de dados. Tal método consiste em reduzir o conjunto a um espaço de menor dimensão, usualmente bidimensional, que preserva a topologia dos dados originais (LIU; WEISBERG, 2011).

Considerando o oceano entre 60° norte e sul, a temperatura é a principal variável para a determinação da densidade. Sendo, portanto, um dos principais parâmetros oceanográficos, é continuamente observada desde as primeiras expedições até à atualidade, inclusive por meio de satélites (TALLEY *et al.*, 2011; LIU; WEISBERG, 2011). Dessa maneira existe uma grande quantidade de dados de temperatura na superfície do mar (TSM) que pode ser analisada pelo método de SOM, o que auxilia na interpretação de padrões em imagens de satélite (RICHARDSON *et al.*, 2003).

No Atlântico tropical, a temperatura da superfície do mar está intimamente relacionada com alguns modos de variabilidade climática como, por exemplo, o Modo Meridional do Atlântico (MMA). Esse modo é caracterizado pelo gradiente de TSM entre as bacias do Atlântico tropical norte e do sul (FERREIRA; MELLO, 2005), intimamente relacionado com a oscilação da Zona de Convergência Intertropical (ZCIT), uma das principais regiões formadoras de nuvens. Nessa zona há a confluência dos ramos ascendentes das Células de Hadley, influenciando na precipitação das regiões norte e nordeste do Brasil.

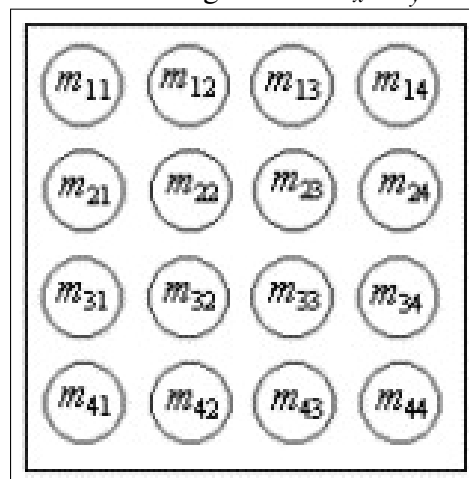
Tendo em mente essa possibilidade, aliada com a importância de estudos sobre variabilidade em parâmetros oceanográficos, especificamente da TSM, no Oceano Atlântico tropical em virtude de sua direta influência nos padrões climáticos da região Nordeste do Brasil, procede-se à aplicação desse método de Mapas Auto-organizáveis para detectar tais padrões, tanto na média quanto em anomalias.

1.1 Mapas auto-organizáveis (SOM)

Os mapas auto-organizáveis,¹ popularmente conhecidos pela sigla em inglês SOM, são um algoritmo de *clustering* não supervisionado, usando aprendizado competitivo e cooperativo. Em sua concepção por Teuvo Kohonen, o algoritmo teve como inspiração a fisiologia do cérebro humano, em que um único neurônio específico deve ser ativado, enquanto que os vizinhos devem permanecer inativos (KOHONEN, 2013). Por essa razão, também são chamados de redes neurais (ou mapas) de Kohonen, que é baseado em redes neurais artificiais (FACELI *et al.*, 2011; KOHONEN, 1998).

Esse algoritmo possui apenas duas camadas, uma de entrada e outra de saída, e se baseia em relações geométricas simples (KOHONEN, 1998). Ele é capaz de converter relações estatísticas não lineares entre conjuntos de dados multidimensionais (como parâmetros físicos no oceano) em relações num espaço de baixas dimensões. Esse espaço, normalmente bidimensional (LIU *et al.*, 2006), é chamado de grade, podendo ter o formato retangular ou hexagonal (*vide* Figura 1).

Figura 1 – Exemplo de um SOM retangular com k_x e $k_y = 4$.



Fonte: (BERNATAVIČIENĖ *et al.*, 2006)

1.1.1 Exemplo de aplicação em Oceanografia

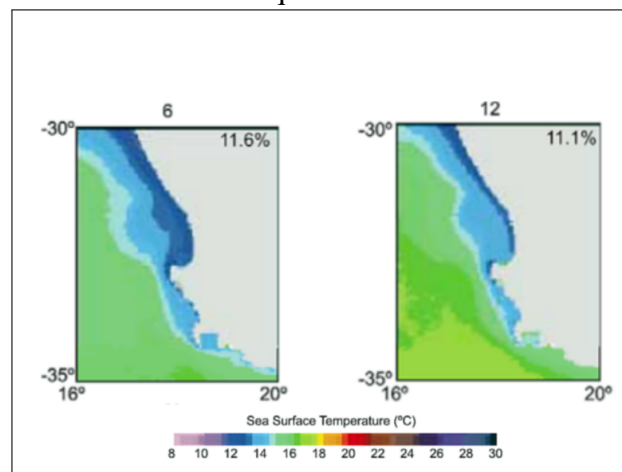
A metodologia dos Mapas de Kohonen, que embora seja uma técnica relativamente antiga dentro da área de aprendizado de máquinas, ainda é pouco explorada em Oceanogra-

¹ A definição a seguir tende a ser uma simplificação. Para um maior detalhamento do método, recomenda-se recorrer às obras citadas, notadamente Kohonen (1998) e Liu *et al.* (2006).

fia no âmbito nacional. A nível mundial, contudo, diversos artigos foram publicados em diferentes subáreas, desde sua aplicação em dados de sensoriamento remoto (altimetria, temperatura superficial, ventos em superfície *etc.*), àqueles provenientes de boias ou de estações oceanográficas, como no estudo de massas d'água (*vide* PIRES *et al.*, s.d., disponível em <http://www.novaims.unl.pt/docentes/vlobo/Publicacoes/3_12_clusters_oceano.pdf>). Diversos outros exemplos são listados em LIU; WEISBERG (2011).

Um desses estudos, como o de RICHARDSON *et al.* (2003), aplica mapas auto-organizáveis em padrões de TSM de escala sinótica a partir de imagens do *Advanced Very High Resolution Radiometer* (AVHRR) na região da Corrente de Benguela. Os autores identificam as variações sazonais (Figura 2), além de variações interanuais a partir das anomalias da temperatura.

Figura 2 – Exemplo de um SOM utilizado com TSM, mostrando os dois padrões mais frequentes.



Fonte: Adaptado de RICHARDSON *et al.*, 2003.

Por meio de mapas de frequência de cada nó e do centro de gravidade (centroide) para cada mês, os autores determinaram a variação temporal da TSM na região, identificando um período de resfriamento e de aquecimento desigual ao decorrer de cada ano.

2 OBJETIVOS

2.1 Geral

Identificar padrões na distribuição espaço-temporal da TSM no Oceano Atlântico tropical por meio de redes neurais de Kohonen.

2.2 Específicos

1. Aplicar o método de mapas auto-organizáveis em conjuntos de dados de temperatura superficial do mar no Oceano Atlântico tropical para um período de 30 anos.
2. Calcular anomalias de TSM e identificar seus padrões a partir de uma rede neural.

3 METODOLOGIA

A metodologia utilizada segue os moldes descritos por RICHARDSON *et al.* (2003), em que a técnica SOM é aplicada duas vezes: num primeiro momento, em séries temporais de temperatura obtidas por satélites, para a identificação de características sinóticas da área de estudo; em outro momento, em anomalias de TSM para poder observar regiões de aquecimento ou resfriamento anormais, isto é, alterações na TSM. Após a aplicação do método SOM e a posterior interpretação dos resultados, seguirá uma discussão e revisão bibliográfica acerca das vantagens, desvantagens e perspectivas na utilização do método para dados oceanográficos em regiões intertropicais.

3.1 Área de estudo

A área considerada para esse trabalho é um polígono limitado ao norte pelo paralelo de 28°N, ao sul a 20°S e meridionalmente entre 60°W e 20°E, como mostrado na Figura 3. Tal região é de interesse de oceanógrafos e meteorologistas por ser a área aproximada de ocorrência do modo meridional do Atlântico e da ZCIT, ambos fenômenos intimamente ligados com a TSM do Atlântico e diretamente relacionados com a ocorrência de chuvas no semiárido nordestino (FERREIRA; MELLO, 2005).

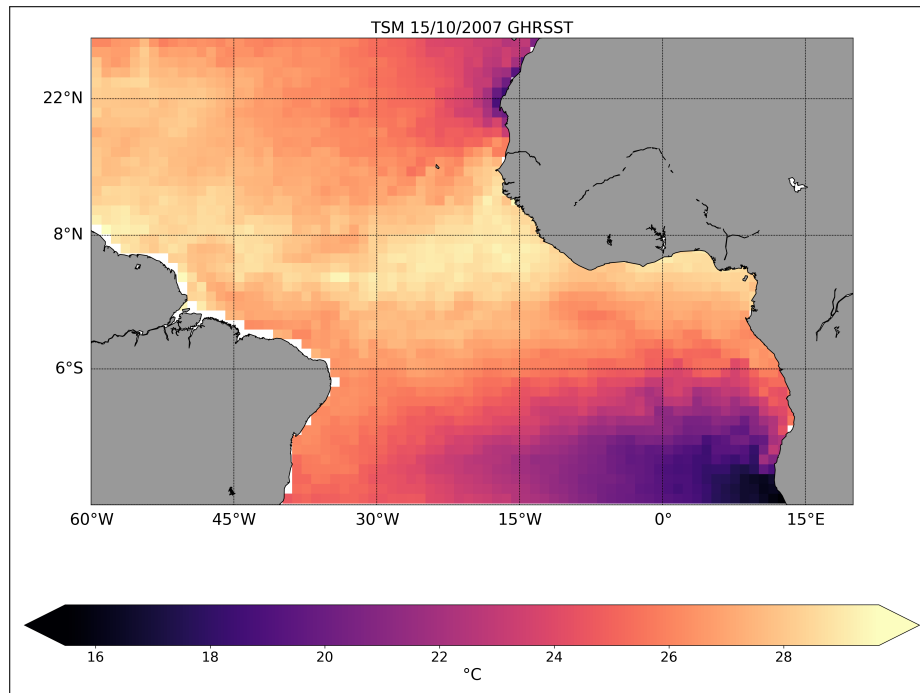
3.2 Conjunto de dados

3.2.1 Dados sinóticos de TSM

Os dados obtidos para a realização desse trabalho foram obtidos a partir do conjunto *Group for High Resolution Sea Surface Temperature* (GHRSSST). Tal conjunto possui domínio global e é produzido a partir da interpolação ótima de diferentes fontes, como dados do sensor orbital AVHRR, de boias e de comissões oceanográficas. É realizado pelo *National Centers for Environmental Information* (NCEI) e disponibilizado gratuitamente no *Physical Oceanography Distributed Active Archive Center* (PODAAC) no endereço <https://podaac.jpl.nasa.gov/dataset/AVHRR_OI-NCEI-L4-GLOB-v2.0>.

Foi elaborado um código na linguagem *Python* para obter os dados, em formato *Network Common Data Form* (NetCDF), dentro do polígono estabelecido, por meio do protocolo *Open-source Project for a Network Data Access Protocol* (OPeNDAP). Foram coletadas imagens

Figura 3 – Área amostral, exemplificando com dados de TSM obtidos a partir do conjunto de dados GHRSSST. Temperatura em graus Celsius.



Fonte: O autor

de TSM para cada dia 1° e 15 de cada mês (*e.g.* 01/02/1993, 15/02/1993, 01/03/1993 etc.), de 01/01/1987 a 01/01/2017, compreendendo, portanto, 30 anos de dados. No total obtiveram-se 720 imagens.

Quanto à resolução espacial, foi selecionado um único dado de TSM a cada grau, tanto de latitude quanto de longitude. Dessa forma, formou-se uma matriz 80×42 , cada imagem, portanto, possuindo um total de 2412 *pixels*, desconsiderando a massa continental.

3.2.2 Dados para anomalia de TSM

Para o cômputo das anomalias de TSM, utilizou-se a climatologia mensal da *National Oceanic and Atmospheric Administration* (NOAA), disponível em <<https://www.esrl.noaa.gov/psd/data/gridded/data.noaa.oisst.v2.html>>. Tal conjunto também é resultante de interpolação ótima, com resolução espacial de um grau de longitude por um grau de latitude.

O arquivo da climatologia consistia da média de cada mês ao longo dos 30 anos, ou seja, de 360 imagens de TSM. Cada mês teve, então, sua média calculada para os 30 anos, produzindo uma matriz com 12 imagens, cada uma com dimensões 80×42 *pixels*.

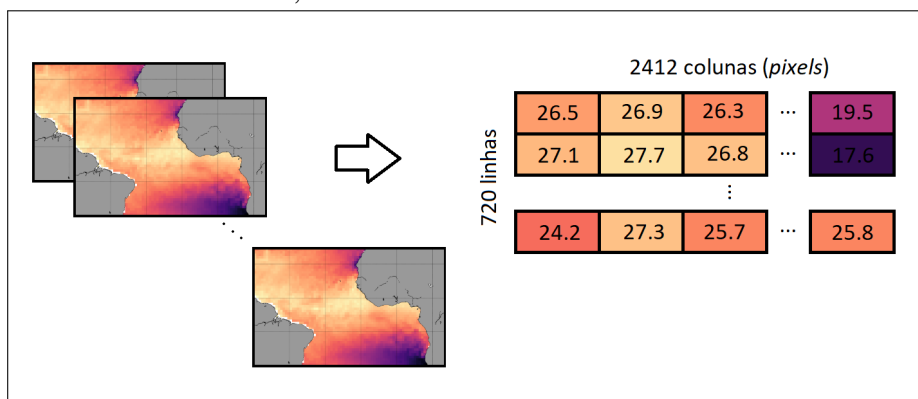
3.3 Pré-processamento

3.3.1 Dados GHRSSST

Um primeiro processamento foi a conversão de Kelvin para graus Celsius dos dados brutos, de acordo com a documentação do próprio arquivo NetCDF, *i.e.* subtraindo-se 273,15 de cada dado.

Para tornar os dados passíveis de serem aplicados à rede neural, cada matriz (ou imagem diária de TSM) de dados foi transformada em um vetor, tendo todos os 720 vetores resultantes concatenados em uma nova matriz. Destarte, cada coluna corresponde a um único *pixel*, específico, e cada linha, um dia de imagem, vide Figura 4.

Figura 4 – Esquema de pré-processamento dos dados. Cada imagem de temperatura (esquerda), uma matriz com 80 *pixels* de longitude por 42 *pixels* de latitude, é transformada em um vetor (direita), totalizando 2412 *pixels*, após excluir a máscara continental. Por fim, cada vetor é concatenado, totalizando 720 linhas, ou dias amostrais.



Fonte: O autor

3.3.2 Dados NOAA

Procedeu-se de forma semelhante ao processamento descrito na subseção anterior, à exceção da conversão da temperatura, uma vez que a mesma já estava em graus Celsius.

3.4 Redes Neurais de Kohonen


Cada unidade de entrada no SOM é associada a um peso, que pode ser estabelecido de forma aleatória, e conectada a um neurônio a_{ij} , em que i e j correspondem à posição do neurônio

na grade. Para o treinamento do SOM, uma série de passos é então realizada, resumidamente duas, inicialização e treinamento. O treinamento, por sua vez, pode ser dividido em três etapas: competição, cooperação e adaptação das sinapses.

Na fase de competição, em cada etapa da aprendizagem, um vetor de entrada X é passado para a rede neural, sendo calculada a distância euclidiana desse vetor X para o vetor m_{ij} . Na competição pela menor distância euclidiana entre um neurônio e o vetor X , o neurônio vencedor m_c é escolhido (BERNATAVIČIENĖ *et al.*, 2006).

Após a definição do neurônio vencedor, passa-se à etapa de estabelecer a vizinhança daquele neurônio. Essa fase de cooperação entre o neurônio central e seus vizinhos, toma como base as suas similaridades (*i.e.* neurônios mais similares possuem uma menor distância euclidiana do que dissimilares), vide Figura 5. Destarte, os nós vizinhos se ajustam ao longo do campo de dados de acordo com uma função de vizinhança.

Figura 5 – Ilustração da organização de um SOM 5x3 após uma iteração. Note o neurônio vencedor m_{53} e a sua vizinhança, após uma iteração. Pontos em azul representam um conjunto de dados. Os neurônios são mostrados em preto. Em cinza estão as posições originais.



Fonte: O autor

A seguir, após estabelecida uma vizinhança, os pesos são recalculados, de modo que o neurônio vencedor e os seus vizinhos aumentam seus valores de ativação para as próximas unidades de entrada que possuam similaridade (FACELI *et al.*, 2011). Essa última etapa é a da

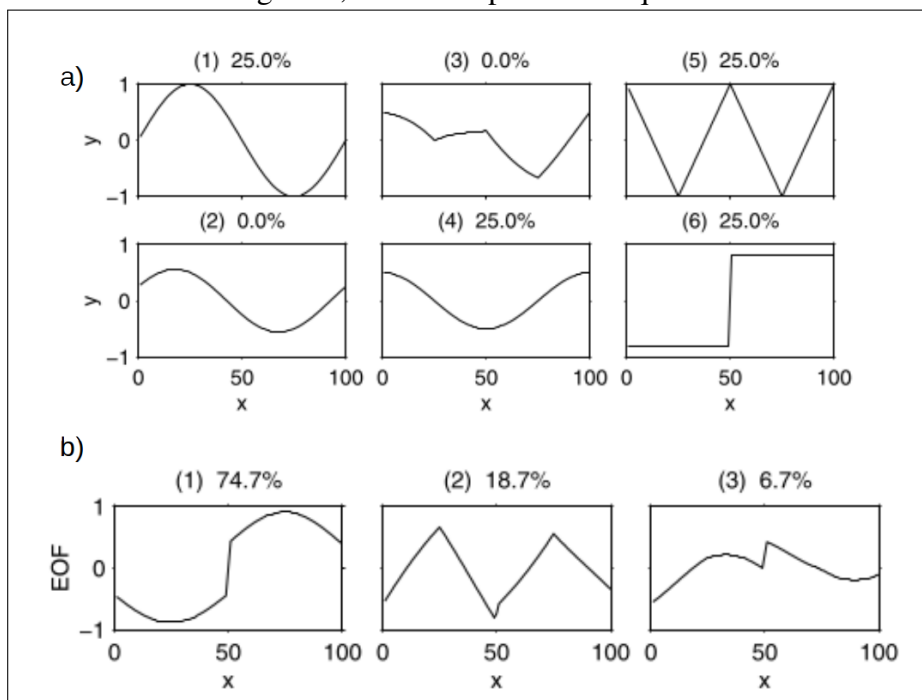
adaptação das sinapses. O processo segue, dessa forma, se 'auto-organizando' sem influência externa (*i.e.* não supervisionado), preservando a topologia do conjunto de dados.

3.4.1 SOM versus EOF

O método das *Empirical Orthogonal Functions* (EOF), como técnica clássica de análise de dados, quando aplicado a séries de dados, mostra modos em padrões de variabilidade (LIU; WEISBERG, 2011). Na literatura, como técnica não linear, o SOM demonstra superioridade em extração de padrões frente à análise linear de EOF, como mostrado por Liu & Weisberg (2005, 2007), Reusch *et al.* (2005 *apud* LIU; WEISBERG, 2011) e LIU *et al.* (2006), especialmente quando ambas as técnicas foram testadas com vários conjuntos de dados e de padrões complexos.

LIU *et al.*, (2006) comparam a performance do SOM com o EOF na extração de características em múltiplos padrões repetitivos. Após aplicar os dois métodos em quatro padrões em série (ondas seno, quadrada em escada, dente de serra e cosseno), percebeu-se que o SOM conseguiu extrair os quatro padrões, pouco dependendo dos parâmetros configurados. Com o método EOF, contudo, não se obteve êxito em nenhum dos três modos preponderantes (Figura 6).

Figura 6 – Comparação entre SOM (a) e EOF (b) para quatro padrões de onda seguidas, com as respectivas frequências de ocorrência.



Fonte: Adaptado de LIU *et al.*, 2006.

3.4.2 SOM Toolbox

Para a implementação da rede neural, recorreu-se ao *software Matrix Laboratory* (MATLAB). Utilizamos o pacote *SOM Toolbox*¹ para criar a rede neural, treiná-la e gerar uma matriz *codebook*. Essa matriz corresponde aos vetores de cada neurônio, *i.e.*, em uma grade com 15 neurônios, o *codebook* resultante terá 15 linhas. Cada coluna dessa matriz corresponde a uma variável, no caso, cada pixel de uma imagem de TSM. Posteriormente essa matriz é exportada como um arquivo *Comma Separated Values* (CSV), onde cada neurônio é reformatado para uma imagem de TSM.

3.4.2.1 Parâmetros da rede neural

O algoritmo de treinamento utilizado foi o modo *batch*. Este consiste em que os vetores de entrada são utilizados conjuntamente, a cada etapa, para atualizar os vetores peso, dessa forma, sendo mais eficiente do ponto de vista computacional (LIU *et al.*, 2006).

A inicialização da rede escolhida foi a randômica, que consiste na escolha de valores muito pequenos para cada peso. O treinamento realizou-se em uma grade 5×3 , retangular, com a função de vizinhança h_{ci} de Epanechnikov (ep), descrita em (3.1):

$$h_{ci}(t) = \max \{0, 1 - (\sigma_t - d_{ci}^2)\} \quad (3.1)$$

onde σ_t é o raio de vizinhança no tempo t e d_{ci} é a distância entre as unidades c e i na grade do mapa (LIU *et al.*, 2006). A duração do treinamento, em número de iterações, foi de 1000 e 50.000 para as fases *rough* e *fine tuning*, respectivamente.

Para testar a aproximação da análise SOM, utiliza-se dois valores, um Erro de Quantização (EQ), que é a distância média entre cada vetor de entrada e seu neurônio vencedor - *Best Matching Unit* (BMU) - e um Erro Topográfico (ET), que é a proporção de todos os vetores de entrada para que o primeiro e o segundo BMU não sejam unidades adjacentes, ou seja, vizinhos. Quanto menores os seus respectivos valores, melhor será o resultado do SOM, como para um baixo ET que equivale à preservação da topologia dos dados.

¹ Produzido na Universidade de Tecnologia de Helsinque por Esa Alhoniemi, Johan Himberg, Jukka Parviainen e Juha Vesanto. Disponível em <<https://github.com/ilarinieminen/SOM-Toolbox>>

3.5 Determinação dos centroides

De modo a observar o ciclo sazonal e o ciclo de anomalias para cada mês, serão determinados os centroides (ou centro de gravidade) dos neurônios de cada mês. Cada centroide é a posição média das frequências relativas para cada mês, dentro da grade do SOM. Assim, ao traçar uma linha que conecte o centroide de cada mês, é possível identificar uma trajetória que mostra o ciclo de variabilidade de TSM no Atlântico. As equações (3.2) e (3.3) abaixo determinam as coordenadas cartesianas (x,y) para a frequência relativa de cada neurônio.

$$\bar{x} = \frac{\sum_{i=0}^n x_i \cdot m_i}{\sum_{i=0}^n m_i} \quad (3.2)$$

$$\bar{y} = \frac{\sum_{i=0}^n y_i \cdot m_i}{\sum_{i=0}^n m_i} \quad (3.3)$$

Acima, \bar{x} e \bar{y} correspondem às coordenadas bidimensionais calculadas dos centroides, x_i é a coluna de cada neurônio, y_i , a linha desse neurônio, e m_i equivale à frequência relativa, para $n = 15$ (número total de neurônios) em ambos os casos.

4 RESULTADOS

4.1 Dados GHRSSST

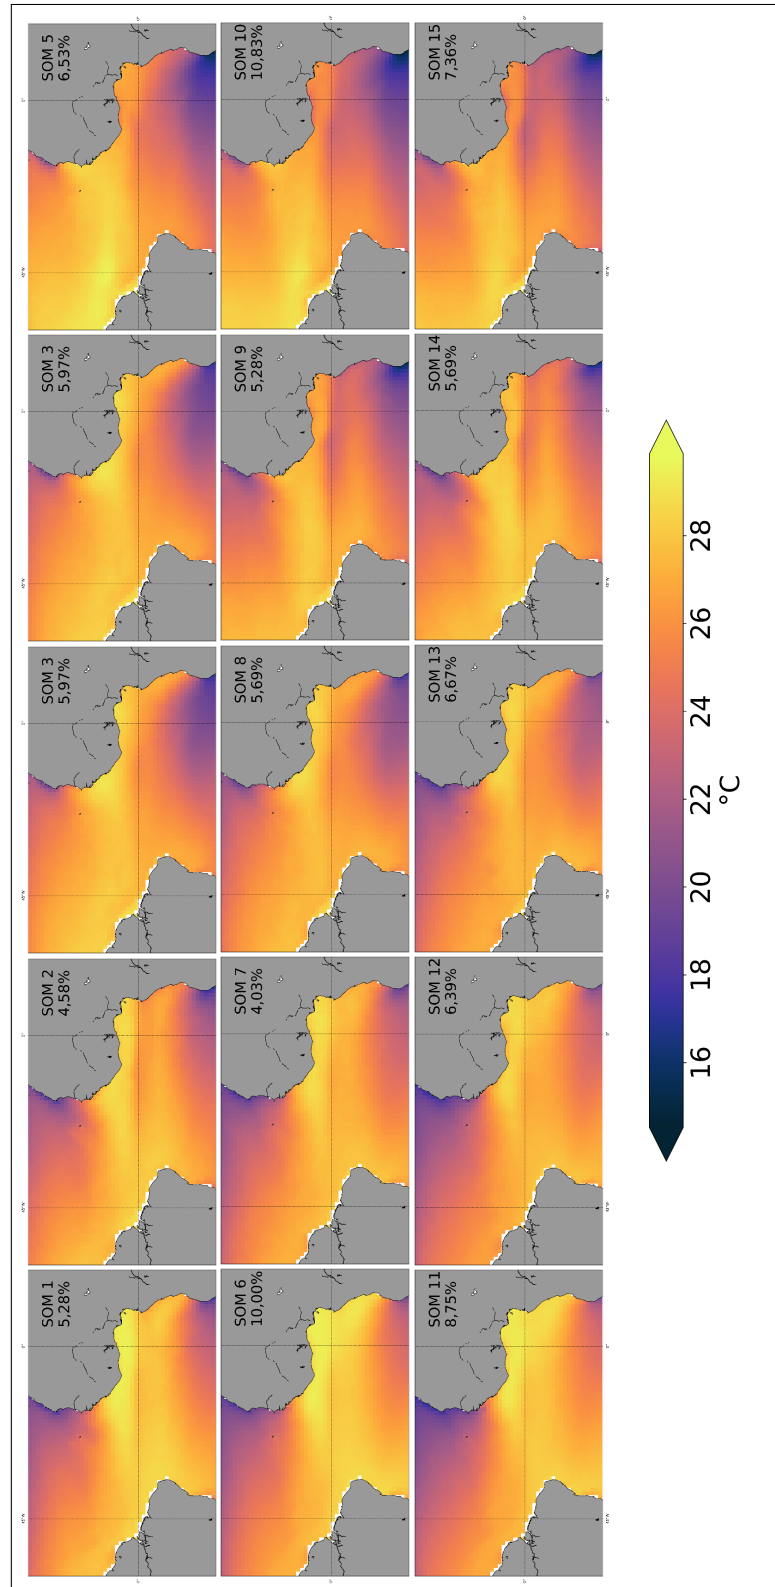
Com o intuito de se analisar os padrões sinóticos de temperatura da superfície do mar ao longo do Atlântico tropical, sucedeu-se à aplicação do método de redes neurais artificiais de Kohonen no conjunto de dados já discutidos na seção 3. Nesta subseção serão mostrados e discutidos os resultados quanto à variação sazonal e às anomalias de TSM.

O resultado da rede neural é mostrado na Figura 7. Dentro de cada imagem de TSM é mostrado o número do neurônio (por exemplo, SOM 2, referente ao segundo neurônio) e a sua frequência relativa, isto é, a porcentagem de vezes que tal nó foi escolhido o vencedor, ou BMU, de cada vetor de dado passado a ele. Seu EQ foi 30,3619, com um pequeno ET de 0,0958, o que caracteriza um bom mapeamento do conjunto de dados.

Ao lado esquerdo estão os neurônios que refletem padrões de uma maior temperatura superficial ao longo da linha equatorial. Ademais, na bacia boreal do Atlântico Tropical, há uma maior influência da pluma de água fria da costa noroeste da África. Na costa sudoeste africana, contudo, há uma menor pluma de água fria. De acordo com o modo do algoritmo de organizar os nós, entre cada dois pontos extremos da grade, há um continuum de variação, analogamente à ideia de um *gradiente*. Destarte, os padrões do lado esquerdo são contrastados pelos neurônios ao lado direito do mapa. Assim, tem-se temperaturas superficiais menores ao longo do equador (embora os neurônios centrais, *e.g.* SOM 9, representem bem isso em toda a grade), e uma grande extensão da pluma de água fria da costa sudoeste africana, deslocando-se da costa de Angola até aproximadamente a costa brasileira.

Os neurônios 6 e 10 tiveram as maiores frequências, respectivamente com 10,00% e 10,83%. Tais neurônios representam padrões opostos entre si da temperatura na superfície do mar. Observa-se que no neurônio 6 há uma menor influência da ressurgência de Benguela, no Atlântico Sul, enquanto que a ressurgência na costa noroeste da África apresenta-se intensa, com temperaturas menores do que 22 °C. Ao longo da linha equatorial há as maiores temperaturas, com uma grande faixa de temperaturas acima de 26,5 °C conectando a costa sul-americana com a africana. Essa faixa pode ser considerada como sinal indireto da ZCIT (FERREIRA; MELLO, 2005), deslocada ao máximo para sul. Os BMU associados a esse neurônio representam os meses de Abril (50%), Março (38%), Fevereiro (20%) e Maio (12%), *vide* Figura 8. Destarte, caracteriza-se o período de transição entre verão/inverno para outono/primavera, a depender

Figura 7 – Resultado da rede neural para TSM no Atlântico tropical, para um período amostral de 30 anos.



Fonte: O autor

do hemisfério de referência (sul e norte, respectivamente), onde o máximo de radiação solar migra da região equatorial para o hemisfério norte (HASTENRATH, 1991). Esse padrão reflete

a defasagem da resposta da troca de calor entre a superfície oceânica com a irradiação solar.

O neurônio 10, mais frequente dentre os 15, associa-se aos BMU de Agosto (35%), Setembro (78%) e Outubro (17%). Ele representa uma alta influência da ressurgência de Benguela no Atlântico Sul, com uma proeminente pluma de água mais fria, com aproximadamente 22 °C. A pluma é associada com ventos mais intensos na região, predominantemente de alísios de sudeste. Esse fato é devido ao deslocamento da ZCIT para o hemisfério norte, observada indiretamente pela faixa de aproximadamente 28 °C, ligeiramente ao norte da linha equatorial. Quanto a esse ponto, e de forma semelhante ao neurônio 6, também é realçada a defasagem do aquecimento e resfriamento da superfície do mar em resposta ao aquecimento solar, aproximadamente dois meses após o mínimo de inverno. Na costa noroeste da África, uma mancha de água fria (20 °C) se mantém próxima à costa, menos intensa quando comparada com o neurônio 6. Ventos alísios de nordeste com menor intensidade, resultando em um menor transporte de Ekman para longe da costa (e conseqüentemente desintensificando a ressurgência), podem ser a provável causa deste fenômeno.

O neurônio 15 é muito semelhante ao 10, com 7,36% de representatividade. Muito presente no BMU de Agosto (62%), pode indicar o máximo de temperatura do verão do hemisfério sul. Sua segunda maior representatividade é em Julho (23%). Em Setembro só alcança 3%.

A escolha de uma grade 5x3 é, portanto, capaz de mostrar o ciclo sazonal de temperatura no Atlântico tropical, representado pela maioria dos nós. Tal ciclo é o principal modo de variabilidade para os oceanos em geral, assim como especialmente para o Atlântico, como mostra CHEN; LI (2008) por meio de uma análise harmônica das amplitudes de TSM. Ademais, com essa configuração, o SOM conseguiu detectar pequenas variações dentro da sazonalidade, como será mostrado adiante (subseção 4.1.2). Tal configuração se mostra satisfatória para esse tipo de estudo.

4.1.1 Frequências relativas

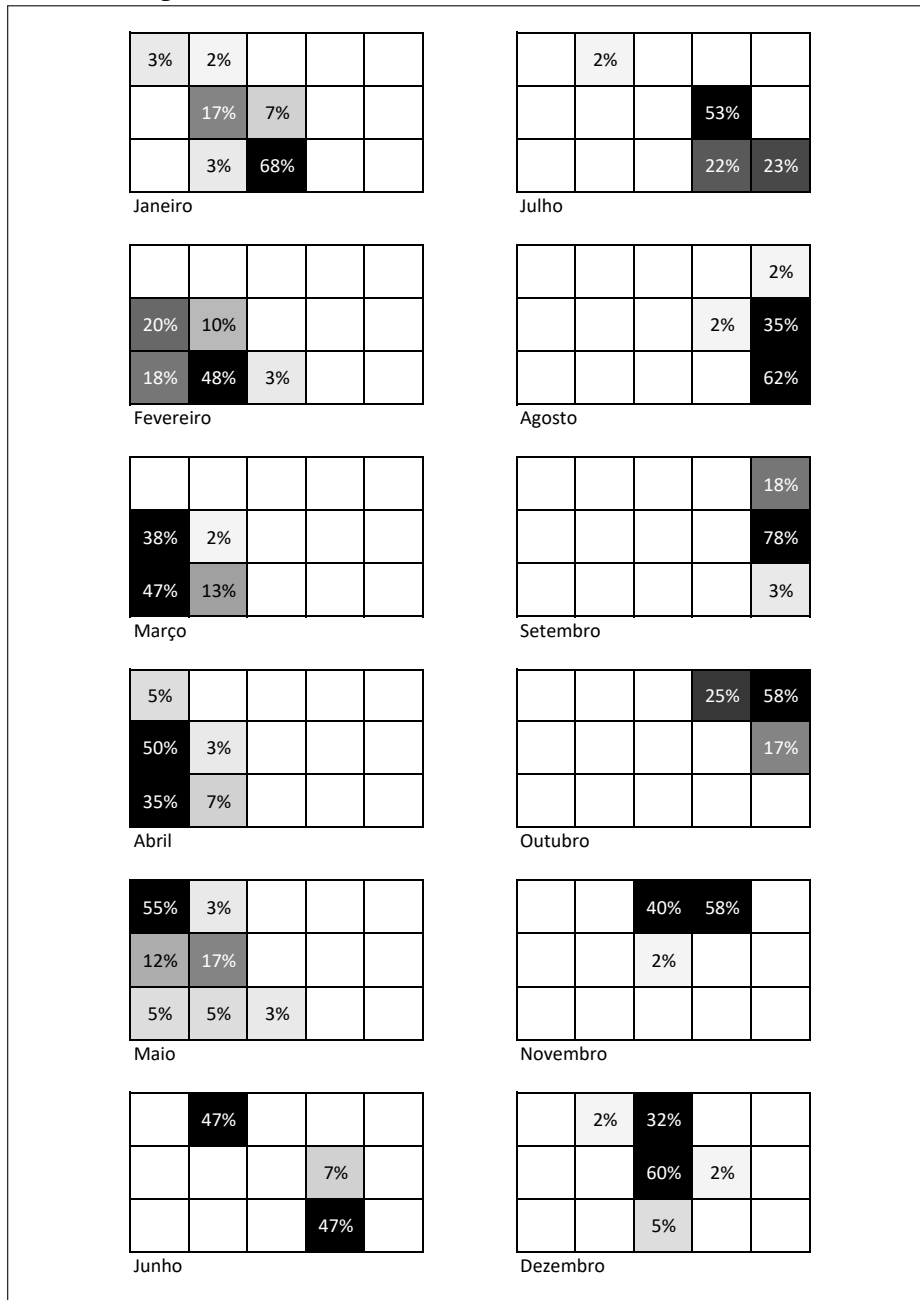
A partir da frequência relativa de cada mês, isto é, a proporção entre as vezes que cada neurônio foi determinado vencedor, em um vetor de dados, para a quantidade total de dados, é possível verificar a variabilidade de padrão de temperatura para cada mês.

A Figura 8 mostra o conjunto de tabelas de frequência para cada mês. Os meses de Junho, Setembro, Outubro e Novembro possuem apenas 3 padrões sinóticos, enquanto que Maio

se mostrou o mais variável, com 7 padrões.

De forma geral, cada mês possui um estado sinótico característico, com frequência superior a 30% (correspondente a 18 dias, de um total de 60 para qualquer mês).

Figura 8 – Frequência relativa de cada neurônio, dividida por meses. O somatório de cada mês equivale a 100%. Cada célula equivale a um neurônio, onde as maiores porcentagens indicam a predominância do neurônio em cada mês.



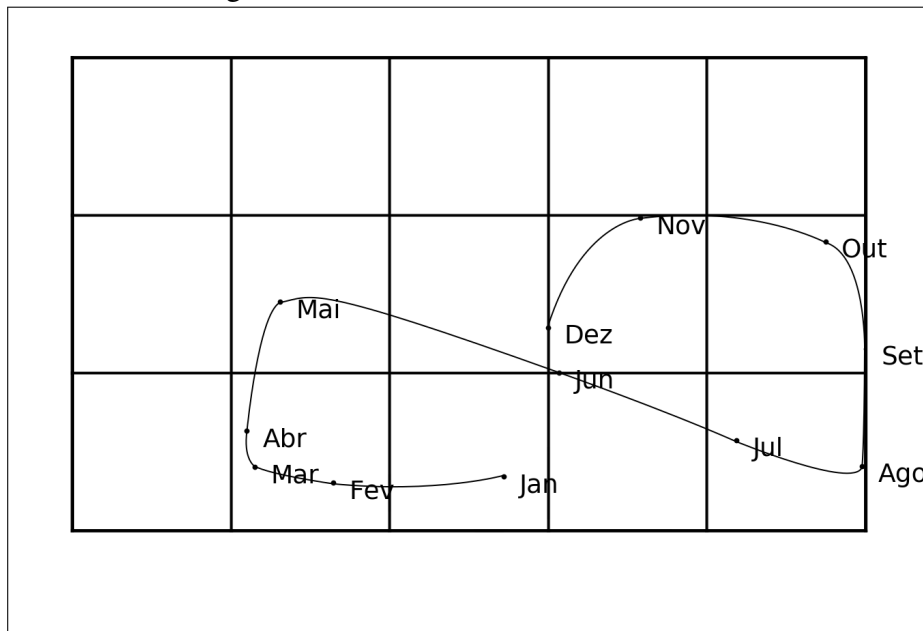
Fonte: O autor

A Figura 9 representa os centroides de cada mês e a respectiva trajetória ao longo dos neurônios. Observa-se um ciclo assimétrico, com os meses de Fevereiro, Março e Abril bastante

próximos, ao passo em que Maio, Junho e Julho estão bastante espaçados, estes percorrendo o mapa de um extremo a outro. Entre Agosto a Janeiro há um espaçamento levemente equânime, reiniciando-se o ciclo.

Entre os centroides de Maio a Agosto, um espaço temporal de 3 meses, há a inversão de padrões de TSM nas bacias. Tendo a bacia atlântica austral como referência, isso significa um resfriamento muito mais rápido do que seu aquecimento - aproximadamente a metade do tempo gasto -, permanecendo em um estado praticamente constante, desde Fevereiro até Maio. Esses resultados são constantes com o de OKUMURA; XIE (2004), ao analisar a TSM da pluma de água fria da costa oeste africana e que conectam tal fenômeno à proximidade da massas continentais africana e sul-americana, à mistura vertical causada pelos ventos de sul e a uma termoclina delgada no leste da bacia atlântica.

Figura 9 – Centroides e a correspondente trajetória para as frequências da Figura 8.



Fonte: O autor

4.1.2 Estudo de um mês específico

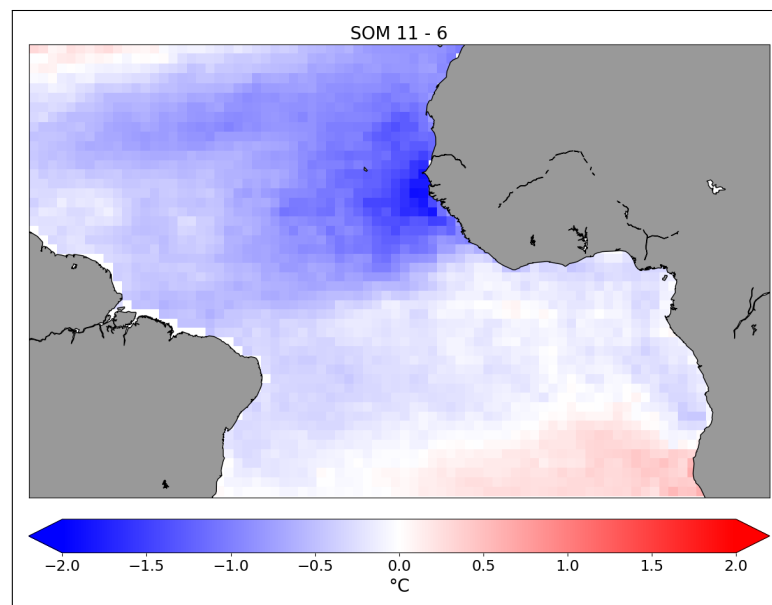
A quantidade de resultados gerados pela rede neural possíveis de serem discutidos é grande. Para exemplificar essa profundidade, relacionando com sistemas atmosféricos e modos de variabilidade climática, como o MMA, restringiu-se um mês específico para tal análise, *in casu*, março.

Primeiramente, de forma didática, deve-se categorizar o índice do Modo Meridional

do Atlântico (Figura 11) em três tipos: positivo, com MMA acima de 1; nulo, com índice entre 1 e -1; e negativo, com valores menores que -1. Os índices utilizados são aqueles da Universidade de Winsconsin, disponibilizados pelo *Earth System Research Laboratory* (ESRL) no endereço <<https://www.esrl.noaa.gov/psd/data/timeseries/monthly/AMM/>>.

É percebido que, em fases negativas do MMA (*i.e.* 1989, 1990, 1994, 1995, 1999, 2003, 2009, 2012, 2014, 2015 e 2016), o neurônio 11, o mais representativo para o mês de Março, é associado (*vide* Figura 12). Esse neurônio é similar ao 6, tendo um mesmo padrão de TSM, porém mais intensamente, com maiores valores absolutos de temperatura. Como explicitado anteriormente, os neurônios situados na extremidade esquerda do SOM, como os nós 6 e 11, mostram padrões com maiores valores de TSM ao longo do equador, com pouca ou nenhuma proeminência da pluma de água fria advinda das costas de Angola e da Namíbia. Com base nisso, observamos indiretamente (*vide* Figura 10) a intensificação da ressurgência na costa noroeste africana (diferença de temperatura próxima a $-2\text{ }^{\circ}\text{C}$) e, de forma inversa, a desintensificação da ressurgência na costa sudoeste africana. Essa característica, portanto, de temperaturas menores na bacia norte, típica de um MMA negativo, corresponde com aquele indicado pela rede neural.

Figura 10 – Resultado da subtração de temperaturas entre os neurônios 11 e 6



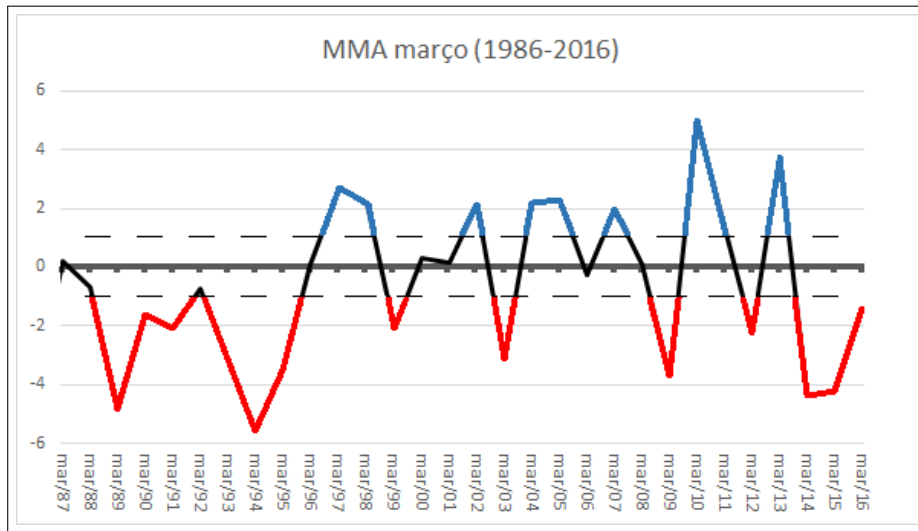
Fonte: O autor

De forma análoga, para os anos em que o MMA teve índice positivo (*i.e.* 1998, 2002, 2004, 2005, 2007, 2010 e 2013), associou-se o neurônio 6. É notada uma atipicidade somente em relação ao ano de 1997, em que os neurônios 7 e 12 foram vencedores.

Para os índices nulos, ou quase nulos, sempre foram associados mais de um neurônio,

possivelmente pela oscilação entre um MMA levemente positivo ou negativo ao longo de Março, contudo mantendo a média mensal nula.

Figura 11 – Índice do Modo Meridional do Atlântico para o mês de março, entre os anos de 1986 a 2016. A linha central marca um MMA nulo. As cores azul e vermelha representam índices maiores ou menores que 1, respectivamente. Índices entre esses valores estão em preto. As linhas tracejadas indicam os valores de 1 e -1.




Fonte: O autor

4.2 Anomalias de temperatura

O resultado da rede neural para as anomalias de TSM consta na Figura 13. O EQ atingiu 29,324, com ET 0,208. Tais valores representam uma baixa adequação à topologia dos dados, possivelmente devido aos parâmetros escolhidos para o *Toolbox*, como o tamanho da grade e a função de vizinhança.

A despeito disso é possível observar algumas variações interanuais características do Atlântico. Os neurônios 1, 4, 5 e 10 mostram um dipolo de anomalias entre as bacias norte e sul, com centro na posição média da ZCIT (SERVAIN *et al.*, 1999), enquanto que os demais caracterizam uma dispersão uniforme de anomalia ao longo do Atlântico tropical (*e.g.* 7, 8, 11 e 14). O neurônio 8 tem a maior representatividade, correspondente a um padrão aproximadamente neutro de anomalias. Esses dois padrões vão ao encontro daqueles citados por SERVAIN (1991), ilustrados na Figura 15, correspondentes a 20% da variabilidade de anomalia de TSM no Atlântico.

Figura 12 – Gráfico relacionando os neurônios tidos como vencedores com os anos mais similares para o mês de março. Cor azul indica MMA maior que 1. Pontos em vermelho indicam MMA menor que 1. Círculos pretos indicam MMA entre 1 e -1.



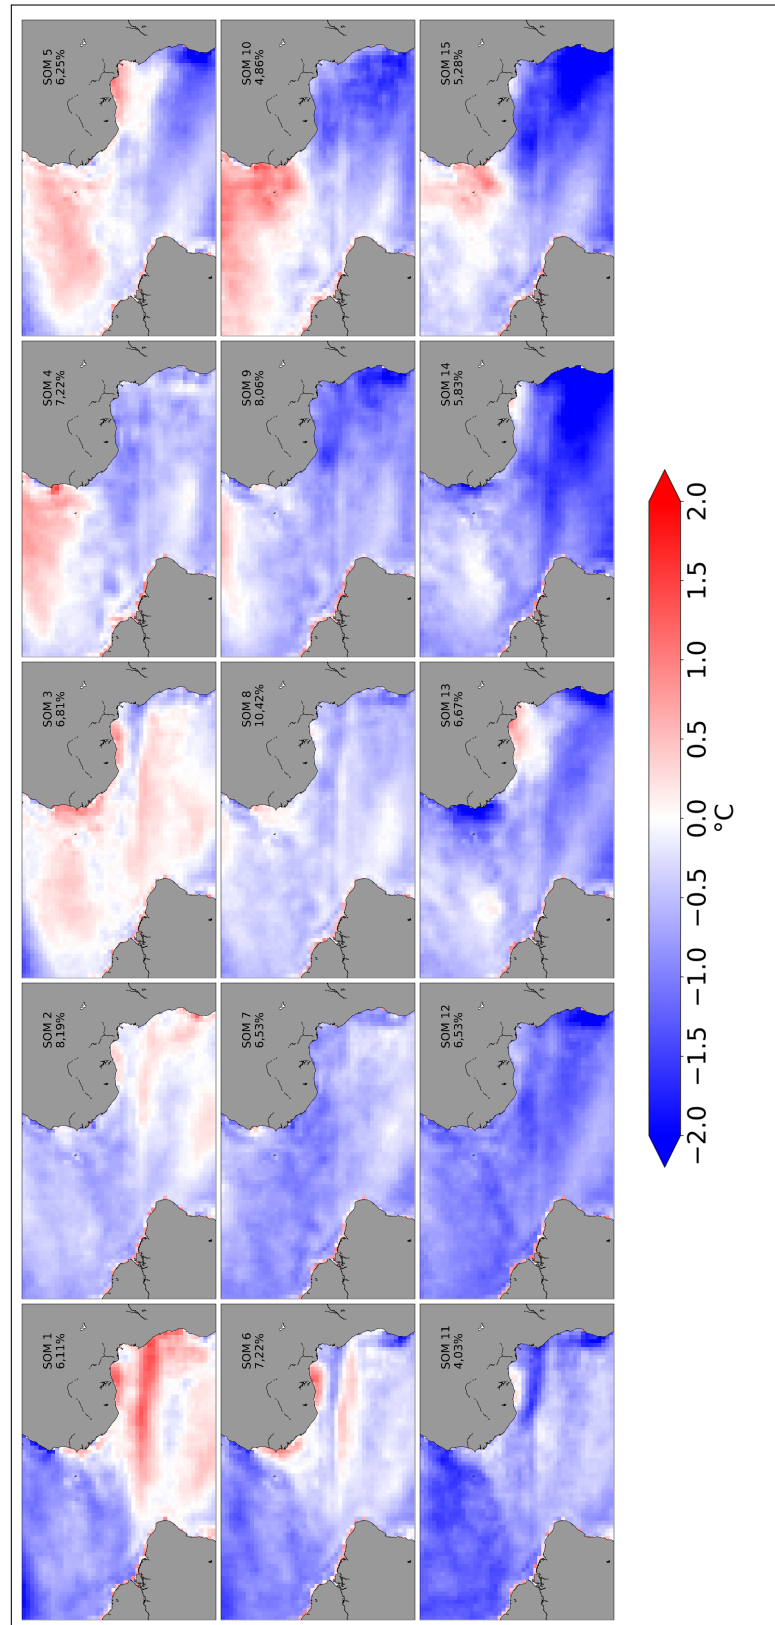
Fonte: O autor

No lado esquerdo do SOM, temos padrões relativos a índices negativos do MMA, isto é, os nós 1, 2, 6, 7 e 11. Opostamente, os nós 4, 5, 9, 10, 14 e 15 sugerem padrões de índices positivos. Os demais nós, centrais, refletem padrões neutros.

Quanto às frequências relativas para cada mês (*vide* Apêndice A), todos os meses apresentam uma alta variação de frequência para cada neurônio, a exceção de novembro, cujo neurônio 9 apresentou 20%, equivalente a 12 dias. Assim, não foi possível identificar alguma trajetória a partir dos centroides.

Tomando um período específico, de forma semelhante à seção 4.1.2, prosseguimos com a análise do mês de março quanto às anomalias. No ano de 2010, o índice calculado do Modo Meridional foi de 5,01, sendo o neurônio 4 escolhido o BMU para esse mês e ano específicos. Tal neurônio mostra uma anomalia positiva na maior parte da bacia norte, com

Figura 13 – Resultado da rede neural para anomalias de TSM no Atlântico tropical, para um período amostral de 30 anos.

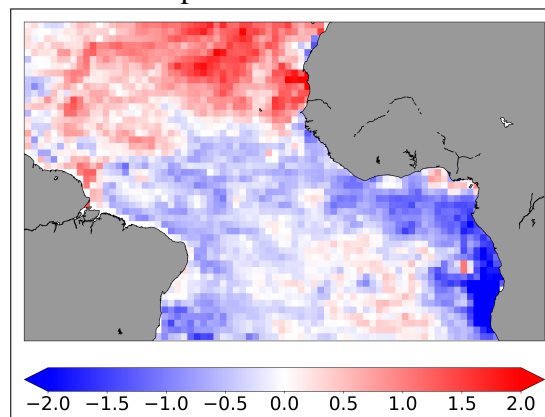


Fonte: O autor

anomalias negativas para o restante do Atlântico tropical. Tal resultado é corroborado pela Figura 14, referente à anomalia de 01/03/2010, gerada a partir do banco de dados GHRSSST e da climatologia da NOAA. Imagens de anomalia disponibilizadas pela Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) em <<http://www.funceme.br/index.php/areas/19-monitoramento/oceanográfico/403-campos-de-tsm-e-vento-no-atlantico-tropical>>, são igualmente similares, com a característica da costa noroeste africana de temperatura superficiais acima da média, mesmo embora tais imagens representem as anomalias para todo o mês de março de 2010.


Dessa forma, apesar dos índices ET e EQ, a rede neural mostrou-se capaz de corretamente identificar alguns padrões. Devido à grande variabilidade espaço-temporal das anomalias no Atlântico, a seleção de uma maior grade é imperiosa para a maior qualidade no detalhamento dos padrões pelo método das redes de Kohonen.

Figura 14 – Anomalias de TSM, em °C, para o dia 01/03/2010.



Fonte: O autor

Figura 15 – Primeiro (a) e segundo (b) modos para o EOF de TSM mensal, entre 1984-1987. Unidades em $1/100\text{ }^{\circ}\text{C}$



Fonte: BRAUD, 1990 *apud* SERVAIN, 1991.

5 CONCLUSÕES E TRABALHOS FUTUROS

Como bem notado por RICHARDSON *et al.* (2003), a utilização de mapas auto-organizáveis para imagens de parâmetros oceanográficos, a exemplo de TSM, é vantajosa na medida em que os resultados também são imagens, da mesma forma dos dados de entrada, portanto, mais fáceis de serem interpretados pelo cientista.

Ressalta-se a vasta gama de aplicações do algoritmo à Oceanografia Física, assim como na região do Oceano Atlântico tropical, como na correlação de padrões de variáveis oceanográficas (campo de vento, salinidade, pressão atmosférica na superfície do mar *etc.*), assim como sua relação com variáveis ecológicas e biológicas. É ainda mister testar, em futuros trabalhos, diversos parâmetros dentro do algoritmo para alcançar a melhor qualidade possível para os mapas gerados.

Foi possível observarmos o ciclo sazonal de TSM a partir dos centroides das frequências relativas mensais, que ressalta a assimetria entre o aquecimento e resfriamento no Atlântico. A escolha da grade 5x3 preservou tanto o ciclo sazonal, quanto pequenas variações interanuais da temperatura. Alguns neurônios ditos como vencedores se correlacionaram com padrões diferentes do Modo Meridional do Atlântico. Destarte, mostrou-se razoável do ponto de vista entre o balanço computacional e nível de detalhamento desejado.

Quanto aos resultados das anomalias, o método não revelou-se muito eficaz, como as eventuais divergências entre os resultados aqui mostrados com os de outros trabalhos, o que pode ser relacionado à resolução temporal do banco de dados. Possivelmente a escolha de apenas dois dias a cada mês, ao invés da média mensal, para o cálculo das anomalias tenha causado alguma divergência. É esperado que um novo estudo possa vir a corroborar com essa hipótese.

Um aspecto a ser ressaltado quanto à metodologia é a discricionariedade da regulação dos parâmetros dos Mapas Auto-Organizáveis. Enquanto que alguns, como a duração dos treinamentos e a função de vizinhança, possam ser quantificados frente a índices de qualidade do mapa, outros, como as dimensões da grade, não os são. Nesse estudo, mostrou-se que a escolha de 15 nós para compor a rede neural obteve sucesso ao mostrar o ciclo sazonal e pequenas modulações. Grades menores mostram menos padrões, e, caso o número de neurônios não seja suficientemente grande, possivelmente incorrem em neurônios com baixíssima ou nenhuma representatividade. Por outro lado, grades maiores tendem a requisitar maior esforço computacional, embora possam vir a discernir diferentes eventos de meso e pequena escala.

Frente a outros métodos tradicionais, os mapas auto-organizáveis de Kohonen pos-

sibilitam um estudo complementar a essas técnicas, como a das funções ortogonais empíricas, assim como um estudo aprofundado de cada padrão a partir das características de cada neurônio dentro do conjunto de dados utilizado. Embora não aqui apresentado, também é possível correlacionar diferentes variáveis a partir da visualização de planos de componentes, como aquelas provenientes de um conjunto de boias meteoceanográficas. A facilidade de uso e a interpretação de seus resultados a tornam uma técnica desejável para oceanógrafos de todas as concentrações, permitindo a análise de inúmeras variáveis em um único momento.

REFERÊNCIAS

- BERNATAVIČIENĖ, J.; DZEMYDA, G.; KURASOVA, O.; MARCINKEVIČIUS, V. Optimal decisions in combining the som with nonlinear projection methods. **European Journal of Operational Research**, v. 173, n. 3, p. 729 – 745, 2006. ISSN 0377-2217. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377221705006715>>.
- CHEN, G.; LI, H. Fine pattern of natural modes in sea surface temperature variability: 1985–2003. **Journal of Physical Oceanography**, v. 38, n. 2, p. 314–336, 2008.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. de. **Inteligência Artificial: Uma abordagem de aprendizagem de máquina**. Rio de Janeiro: LTC, 2011. ISBN 9788521618805.
- FERREIRA, A. G.; MELLO, N. G. da S. Principais sistemas atmosféricos atuantes sobre a região nordeste do brasil e a influência dos oceanos pacífico e atlântico no clima da região. **Revista Brasileira de Climatologia**, v. 1, n. 1, 2005. ISSN 2237-8642. Disponível em: <<https://revistas.ufpr.br/revistaabclima/article/view/25215>>.
- HASTENRATH, S. **Climate Dynamics of the Tropics**. 1. ed. [S.l.]: Springer Netherlands, 1991. ISBN 9780792312130.
- KOHONEN, T. The self-organizing map. **Neurocomputing**, v. 21, n. 1, p. 1 – 6, 1998. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231298000307>>.
- KOHONEN, T. Essentials of the self-organizing map. **Neural networks**, Elsevier, v. 37, p. 52–65, 2013.
- LIU, Y.; WEISBERG, R. H. A review of self-organizing map applications in meteorology and oceanography. In: **Self Organizing Maps-Applications and Novel Algorithm Design**. [S.l.]: InTech, 2011.
- LIU, Y.; WEISBERG, R. H.; MOOERS, C. N. Performance evaluation of the self-organizing map for feature extraction. **Journal of Geophysical Research: Oceans**, Wiley Online Library, v. 111, n. C5, 2006.
- OKUMURA, Y.; XIE, S.-P. Interaction of the atlantic equatorial cold tongue and the african monsoon. **Journal of Climate**, v. 17, n. 18, p. 3589–3602, 2004. Disponível em: <[https://doi.org/10.1175/1520-0442\(2004\)017<3589:IOTAEC>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<3589:IOTAEC>2.0.CO;2)>.
- PETROU, M. Preface. **Pattern Recognition Letters**, Elsevier BV, v. 25, n. 13, p. 1459, 2004.
- RICHARDSON, A.; RISIEN, C.; SHILLINGTON, F. Using self-organizing maps to identify patterns in satellite imagery. **Progress in Oceanography**, Elsevier BV, v. 59, p. 223–239, 2003.
- SERVAIN, J. Simple climatic indices for the tropical atlantic ocean and some applications. **Journal of Geophysical Research: Oceans**, v. 96, n. C8, p. 15137–15146, 1991. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/91JC01046>>.
- SERVAIN, J.; WAINER, I.; MCCREARY, J. P.; DESSIER, A. Relationship between the equatorial and meridional modes of climatic variability in the tropical atlantic. **Geophysical Research Letters**, v. 26, n. 4, p. 485–488, 1999. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/1999GL900014>>.

TALLEY, L. D.; PICKARD, G. L.; EMERY, W. J.; SWIFT, J. H. **Descriptive Physical Oceanography**. 6. ed. [S.l.]: Academic Press, 2011. ISBN 9780080939117.

APÊNDICE A – FREQUÊNCIA RELATIVA PARA ANOMALIAS

Figura A-1 – Frequência relativa de cada neurônio, por mês, para as anomalias de TSM.

8%	5%	5%	5%	5%
7%	13%	8%	7%	3%
7%	12%	3%	5%	7%

Janeiro

7%	7%	2%	5%	3%
15%	7%	5%	3%	8%
7%	10%	7%	8%	7%

Julho

8%	5%	5%	5%	5%
7%	13%	8%	7%	3%
7%	12%	3%	5%	7%

Fevereiro

8%	7%	7%	8%	5%
13%	7%	8%	12%	3%
3%	3%	5%	3%	7%

Agosto

8%	12%	10%	8%	8%
5%		5%	7%	8%
3%	7%	5%	10%	3%

Março

7%	13%	7%	12%	7%
3%	2%	13%	5%	8%
3%	5%	3%	7%	5%

Setembro

2%	5%	10%	8%	7%
8%	10%	17%	5%	3%
5%	7%	7%	7%	

Abril

3%	10%	5%	3%	10%
8%	7%	13%	7%	3%
3%	10%	8%	3%	5%

Outubro

7%	7%	3%	8%	7%
7%	8%	10%	15%	2%
5%	5%	8%	2%	7%

Maior

7%	8%	3%	5%	5%
7%	3%	15%	20%	2%
5%		8%	3%	8%

Novembro

7%	3%	8%	13%	7%
	7%	12%	5%	5%
2%	8%	10%	8%	5%

Junho

3%	8%	13%	7%	8%
3%	5%	12%	3%	8%
3%	8%	7%	8%	2%

Dezembro

Fonte: O autor.