



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE CRATEÚS
CURSO DE ENGENHARIA CIVIL

FRANCISCO IGOR SIQUEIRA EVANGELISTA

**PREVISÃO CLIMÁTICA SAZONAL PARA A REGIÃO HIDROGRÁFICA DOS
SERTÕES DE CRATEÚS UTILIZANDO REDES NEURAS ARTIFICIAIS**

CRATEÚS
2019

FRANCISCO IGOR SIQUEIRA EVANGELISTA

PREVISÃO CLIMÁTICA SAZONAL PARA A REGIÃO HIDROGRÁFICA DOS SERTÕES
DE CRATEÚS UTILIZANDO REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Civil da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Engenharia Civil.

Orientador: Prof. Dr. Alan Michell Barros Alexandre.

Crateús

2019

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)

- E92p Evangelista, Francisco Igor Siqueira.
Previsão climática sazonal para a região hidrográfica dos Sertões de Crateús utilizando redes neurais artificiais / Francisco Igor Siqueira Evangelista. – 2019.
80 f. : il.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Crateús, Curso de Engenharia Civil, Crateús, 2019.
Orientação: Prof. Dr. Alan Michell Barros Alexandre.
1. Previsão climática. 2. Índices TSM. 3. Random Forest. 4. Redes Neurais Artificiais. I. Título.
CDD 620
-

FRANCISCO IGOR SIQUEIRA EVANGELISTA

PREVISÃO CLIMÁTICA SAZONAL PARA A REGIÃO HIDROGRÁFICA DE CRATEÚS
UTILIZANDO REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Civil da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Engenharia Civil.

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Alan Michell Barros Alexandre (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Carla Beatriz Costa de Araújo
Universidade Federal do Ceará (UFC)

Prof. Ms. Tatiane Lima Batista
Universidade Federal do Ceará (UFC)

A Deus;

A minha família, em especial aos meus pais,
Cosmo Lopes e Antonisa Siqueira.

AGRADECIMENTOS

Primeiramente agradeço a Deus, que permitiu que tudo isso acontecesse, ao longo da minha vida, e não somente nestes anos como universitário, mas em todos os momentos é o maior mestre que alguém pode conhecer.

Agradeço ao meu orientador, Prof. Dr. Alan Michell, por toda credibilidade depositada em mim e pelo empenho dedicado à elaboração deste trabalho.

Agradeço à minha família, meu pai Cosmo Lopes, minha mãe Antonisa Siqueira, meu irmão Romário Siqueira e em especial a minha irmã Michelly Joyce, por todo o apoio e carinho que me foi dedicado durante esse período.

Agradeço a Ms. Thais Carvalho pelo tempo e conhecimento disponibilizado para a elaboração deste trabalho.

Agradeço a todas as amigas que foram construídas no decorrer dos cursos de Engenharia Ambiental e Civil, que ajudaram de forma direta e indireta na minha formação.

Aos professores participantes da banca examinadora Dr. Carla Beatriz e Ms. Tatiane Lima pelo tempo, pelas valiosas colaborações e sugestões.

Agradeço a todos os professores por me proporcionar o conhecimento não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional, por tanto que se dedicaram a mim, não somente por terem me ensinado, mas por terem me feito aprender.

E agradeço a todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

“As nuvens mudam sempre de posição, mas são sempre nuvens no céu. Assim devemos ser todo dia, mutantes, porém leais com o que pensamos e sonhamos; lembre-se, tudo se desmancha no ar, menos os pensamentos”.

(Paulo Beleki)

RESUMO

A região hidrográfica do Sertões de Crateús passou nos últimos anos (2011 a 2017) por um longo período de estiagem, gerando um esvaziamento dos mananciais do sistema de abastecimento municipais. Plano de emergências como contingenciamento hídrico e a transposição de águas de outras regiões hidrográficas foram colocados em prática de forma a evitar o desabastecimento das cidades da região hidrográfica do Sertões de Crateús. Desta forma, verifica-se a necessidade de planejamento à curto prazo do uso dos recursos hídricos naturalmente limitados, evidenciando a importância da precisão climática, uma vez que auxilia na tomada de decisões. O presente trabalho tem o objetivo principal de avaliar a previsibilidade do regime pluviométrico da região hidrográfica dos Sertões de Crateús a partir da variabilidade da Temperatura de Superfície do mar (TSM) utilizando técnicas de redes neurais artificiais. Para isso, são analisados quatro períodos preditivos: dezembro a maio (DJFMAM), fevereiro a maio (FMAM), dezembro a fevereiro (DJF) e março a maio (MAM), utilizando como preditor 12 índices TSM com os trimestres imediatamente anteriores a cada período preditivo, isto é, analisando o período preditivo de DJFMAM, o preditor seria a média dos índices TSM dos trimestres de setembro a novembro (SON), junho a agosto (JJA), MAM e DJF, respectivamente. Onde inicialmente é obtido através do *Random Forest* (RF) os índices que possuem maior importância e em seguida é realizada a previsão climática sazonal utilizando Redes Neurais Artificiais (RNA) com diferentes quantidades de variáveis de entrada, variando de 1 a 12 índices (que são organizados por ordem de importância). O índice Atlântico Sul Tropical foi classificado mais vezes como a variável mais importante, seguido do Dipolo do Atlântico Tropical. Os modelos com maior acurácia, isto é, os que obtiveram melhores resultados de correlação e NASH foram o período preditivo de MAM onde o período de DJF foi utilizado como preditor, tendo valores de correlação e NASH de 0,883 e 0,663, respectivamente. Por fim, teve-se que o modelo RNA obteve resultados satisfatórios de correlação, porém os valores de NASH foram baixos.

Palavras-chave: Previsão climática. Índices TSM. *Random Forest*. Redes Neurais Artificiais.

ABSTRACT

The hydrographic region of the Backlands of Crateús has been in the last years (2011 to 2017) for a long period of drought, causing an emptying of the municipal supply system springs. Emergency plans such as water contingency and the transposition of waters from other watersheds were put in place in order to avoid the shortage of cities in the Backlands of Crateús hydrographic region. Thus, there is a need for short-term planning of the use of naturally limited water resources, highlighting the importance of climate accuracy, as it helps in decision making. The present work has as main objective to evaluate the predictability of the rainfall of the Backlands of Crateús hydrographic region from the Sea Surface Temperature (SST) variability using artificial neural networks techniques. For this, four predictive periods are analyzed: December to May (DJFMAM), February to May (FMAM), December to February (DJF) and March to May (MAM), using 12 SST indices with the quarters immediately preceding each one. predictive period, that is, analyzing the predictive period of DJFMAM, the predictor would be the average of the TSM indices of the quarters from September to November (SON), June to August (JJA), MAM and DJF, respectively. Where initially obtained through the Random Forest (RF) are the most important indices and then the seasonal climate prediction is performed using Artificial Neural Networks (ANN) with different amounts of input variables, ranging from 1 to 12 indices (which are organized in order of importance). The Tropical South Atlantic Index was classified more often as the most important variable, followed by the Tropical Atlantic Dipole. The models with the highest accuracy, that is, those that obtained the best correlation and NASH results were the predictive period of MAM where the DJF period was used as a predictor, having correlation and NASH values of 0.883 and 0.663, respectively. Finally, the ANN model obtained satisfactory correlation results, but the NASH values were low.

Keywords: Climate forecasting. SST indices. Random Forest. Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1 - Rede Neural de múltiplas entradas.	28
Figura 2 - Regiões hidrográficas do Estado do Ceará.	33
Figura 3 - Disposição espacial das estações pluviométricas.	36
Figura 4 - Precipitação média para cada mês.	37
Figura 5 - Estratégia metodológica utilizada para determinação da precipitação na RH de Crateús.	38
Figura 6 - <i>Boxplot</i> para os índices TSM analisados no período de SON	43
Figura 7 - <i>Boxplot</i> para os índices TSM analisados no período de JJA.	44
Figura 8 - <i>Boxplot</i> para os índices TSM analisados no período de MAM.	44
Figura 9 - <i>Boxplot</i> para os índices TSM analisados no período de DJF.	44
Figura 10 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON	45
Figura 11 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA	46
Figura 12 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM	46
Figura 13 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF.	46
Figura 14 - <i>Boxplot</i> para os índices analisados no período de SON.	49
Figura 15 - <i>Boxplot</i> para os índices analisados no período de JJA	49
Figura 16 - <i>Boxplot</i> para os índices analisados no período de MAM	50
Figura 17 - <i>Boxplot</i> para os índices analisados no período de DJF.	50
Figura 18 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON	51
Figura 19 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA	51
Figura 20 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM	52
Figura 21 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF.	52
Figura 22 - <i>Boxplot</i> para os índices analisados no período de SON	55
Figura 23 - <i>Boxplot</i> para os índices analisados no período de JJA	55

Figura 24 - <i>Boxplot</i> para os índices analisados no período de MAM	55
Figura 25 - <i>Boxplot</i> para os índices analisados no período de DJF	56
Figura 26 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON	57
Figura 27 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA	57
Figura 28 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM	57
Figura 29 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF	58
Figura 30 - <i>Boxplot</i> para os índices analisados no período de DJF	60
Figura 31 - <i>Boxplot</i> para os índices analisados no período de SON	60
Figura 32 - <i>Boxplot</i> para os índices analisados no período de JJA	61
Figura 33 - <i>Boxplot</i> para os índices analisados no período de MAM	61
Figura 34 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM	62
Figura 35 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON	62
Figura 36 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA	63
Figura 37 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM	63
Figura 38 - Comparação entre a precipitação calculada no treinamento a precipitação observada	66
Figura 39 - Comparação entre a precipitação calculada na validação a precipitação observada	66
Figura 40 - Frequência relativa.....	67
Figura 41 - Frequência relativa acumulada	67

LISTA DE TABELAS

Tabela 1 – População dos municípios da RH dos Sertões de Crateús.....	34
Tabela 2 - Reservatórios da Rh dos Sertões de Crateús.	34
Tabela 3 - Estações pluviométricas utilizadas.	35
Tabela 4 - Índices climáticos utilizados como preditores.....	38
Tabela 5 - Três maiores correlações da precipitação de DJFMAM com os preditores analisados.	48
Tabela 6 - Três maiores valores de NASH da precipitação de DJFMAM com os preditores analisados.	48
Tabela 7 - Três maiores correlações da precipitação de FMAM com os preditores analisados	54
Tabela 8 - Três maiores valores de NASH da precipitação de FMAM com os preditores analisados	54
Tabela 9 - Três maiores correlações da precipitação de DJF com os preditores analisados.....	59
Tabela 10 - Três valores de NASH da precipitação de DJF com todos os preditores analisados	59
Tabela 11 - Três maiores correlações da precipitação de MAM com todos os preditores analisados	64
Tabela 12 - Três valores de NASH da precipitação de MAM com todos os preditores analisados	65
Tabela 13 - Maiores valores de correlação e NASH	65

LISTA DE ABREVIATURAS E SIGLAS

AD	Árvores de Decisão
AR5	Quinto Relatório do IPCC
AMO	Oscilação Multidecadal do Atlântico (<i>Atlantic multidecadal oscillation</i>)
ANA	Agência Nacional de Águas
CCM	Complexos Convectivos de Mesoescala
COGERH	Companhia de Gestão de Recursos Hídricos
DJFMAM	Período de dezembro a maio
DJF	Período de dezembro a fevereiro
EQM	Erro Quadrático Médio
ENOS	El Niño – Oscilação Sul
ESRL	<i>Earth System Research Laboratory</i>
FMAM	Período de fevereiro a maio
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
IPECE	Instituto de Pesquisa e Estratégia Econômica do Ceará
LI	Linhas de Instabilidade
MAM	Período de março a maio
MEI	ESNO Multivariado (<i>Multivariate ENSO Index</i>)
NAO	Oscilação do Atlântico Norte (<i>North Atlantic Oscillation</i>)
NEB	Nordeste Brasileiro
NINO1.2	Niño 1+2
NINO3	Niño 3
NINO3.4	Niño 3.4
NINO4	Niño 4
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OL	Ondas de Leste
ONI	Niño Oceânico (<i>Oceanic Niño Index</i>)
OOB	<i>Out-of-Bag</i>
PDO	Oscilação Decadal do Pacífico (<i>Pacific Decadal Oscillation</i>)
RF	<i>Random Forest</i>

RH	Região Hidrográfica
RNA	Redes Neurais Artificiais
SF	Sistemas Frontais
SIN	Sistema Interligado Nacional
SRH	Secretaria de Recursos Hídricos
TAD	Dipolo do Atlântico Tropical (<i>Tropical Atlantic Dipole</i>)
TNA	Atlântico Norte Tropical (<i>Tropical Southern Atlantic</i>)
TSA	Atlântico Sul Tropical (<i>Tropical Northern Atlantic</i>)
TSM	Temperatura de Superfície do Mar
VCAN	Vórtices Ciclônicos de Alto Nível
ZCIT	Zona de Convergência Intertropical

SUMÁRIO

1 INTRODUÇÃO	16
1.1 Objetivo	17
<i>1.1.1 Objetivo geral</i>	<i>17</i>
<i>1.1.2 Objetivos específicos</i>	<i>18</i>
1.2 Roteiro de trabalho	18
2 REVISÃO BIBLIOGRÁFICA	19
2.1 Caracterização climática	19
<i>2.1.1 Sistemas meteorológicos atuantes no regime pluviométrico do NEB</i>	<i>19</i>
<i>2.1.2 Sistemas meteorológicos que influenciam a precipitação no Ceará</i>	<i>21</i>
2.2 Temperatura de Superfície do Mar	21
<i>2.2.1 Dipolo do Atlântico</i>	<i>22</i>
<i>2.2.2 El Niño – Oscilação Sul</i>	<i>22</i>
<i>2.2.3 Oscilação Decadal do Pacífico</i>	<i>24</i>
<i>2.2.4 Oscilação Multidecadal do Atlântico</i>	<i>25</i>
<i>2.2.5 Oscilação do Atlântico Norte</i>	<i>25</i>
2.3 Random Forest	26
2.4 Redes Neurais Artificiais	27
<i>2.4.1 Introdução às Redes Neurais</i>	<i>27</i>
<i>2.4.2 Multilayer Perceptron</i>	<i>29</i>
3 METODOLOGIA	33
3.1 Região de estudo	33
3.2 Levantamento dos dados	34
3.3 Estratégia metodológica	37
3.4 Classificação por ordem de importância dos índices climáticos	39
3.5 Previsão climática utilizando MLP	39
3.6 Abordagem estatística	41
4 RESULTADOS E DISCUSSÃO	43
4.1 Previsão da precipitação para o semestre de dezembro a maio	43
<i>4.1.1 Análise dos preditores através do Random Forest</i>	<i>43</i>
<i>4.1.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais</i>	<i>45</i>
4.2 Previsão da precipitação para a quadra chuvosa	49
<i>4.2.1 Análise dos preditores através do Random Forest</i>	<i>49</i>

<i>4.2.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais</i>	51
4.3 Previsão da precipitação para o trimestre de dezembro a fevereiro	54
<i>4.3.1 Análise dos preditores através do Random Forest</i>	54
<i>4.3.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais</i>	57
4.4 Previsão da precipitação para o trimestre de dezembro a fevereiro	60
<i>4.4.1 Análise dos preditores através do Random Forest</i>	60
<i>4.4.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais</i>	62
4.5 Síntese dos resultados	65
5 CONCLUSÃO	68
REFERÊNCIAS	70
APÊNDICE A – DADOS DE PRECIPITAÇÃO	77

1 INTRODUÇÃO

O clima do Nordeste Brasileiro (NEB) se caracteriza pelo clima predominantemente semiárido, em que existe uma grande variação na distribuição da precipitação em escala temporal e espacial. Para o NEB, tanto os períodos longos de escassez hídrica quanto o de chuvas intensas acarretam sérios problemas sociais e econômicos, os quais são agravados pela recorrência dos eventos (NOBRE, 2016).

A região está localizada na Zona Intertropical e é caracterizada por uma climatologia complexa, os principais sistemas meteorológicos que a influenciam são a Zona de Convergência Intertropical (ZCIT), Linhas de Instabilidade (LI), Vórtices Ciclônicos de Altos Níveis (VCAN) e Sistemas Frontais (SF), principalmente em escala sazonal. Em termos interanual e decadal ou principais fenômenos são o El Niño-Oscilação Sul (ENOS) e a Oscilação Decadal do Pacífico (PDO) (ARAÚJO JÚNIOR *et al.*, 2019).

O regime de chuvas no NEB é delimitado por uma estação chuvosa curta e uma estação seca. A estação chuvosa reflete a configuração da circulação atmosférica de grande escala e a interação oceano-atmosfera nos oceanos Pacífico e Atlântico, que influenciam diretamente a atuação de sistemas meteorológicos na região (FERREIRA; MELLO, 2005).

A variabilidade interanual da precipitação no NEB, associada aos baixos índices pluviométricos anuais do semiárido nordestino, são fatores preponderantes para a ocorrência de secas sobre a região, onde a intensa diminuição total pluviométrico sazonal durante o período chuvoso se concentra normalmente no primeiro semestre. De forma geral a variação interanual da pluviometria sobre o NEB está relacionada a variações de padrões de Temperatura da Superfície do Mar (TSM) sobre os oceanos tropicais, os quais alteram a posição e a intensidade da ZCIT sobre o Oceano Atlântico, originando a pluviometria sobre o Nordeste Setentrional (REPELLI e ALVES, 1996).

De acordo com as projeções de temperatura e de frequência de eventos extremos apresentados pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC) no AR5 (Quinto Relatório do IPCC) realizado em 2014, o NEB apresentará a redução das chuvas, o aumento da temperatura, como também dos número de dias secos e das ondas de calor para todas as projeções realizadas para o século XXI (IPCC, 2014). Portanto, diante destes cenários, a previsibilidade dos períodos chuvosos e sua intensidade tornam-se cada vez mais importante para todos os setores relacionados a disponibilidade hídrica na região.

O Estado do Ceará possui seu território quase que totalmente inserido dentro dos limites do semiárido nordestino, o que sempre o torna propenso às secas severas (COSTA;

SILVA, 2017). Diversos autores, como Nóbrega *et al.* (2002), Silva *et al.* (2012) e Da Silva *et al.* (2013) demonstraram que a precipitação do Ceará é influenciada principalmente pelo El Niño Oscilação Sul, Dipolo do Atlântico e a Oscilação Decadal do Pacífico.

A região hidrográfica do Sertões de Crateús está localizada na macrorregião de Sertões de Crateús, na porção oeste do Estado do Ceará, sendo composto por nove municípios e consta com uma população estimada de 240 mil habitantes (IPECE, 2017). Os efeitos da estiagem prolongada na região podem ser caracterizados a partir do município de Crateús, o mais populoso da região com aproximadamente 75 mil habitantes dos quais 70% encontra-se na zona urbana.

O principal manancial do sistema de abastecimento do município de Crateús, o açude Carnaubal entrou em colapso já no ano de 2000 (FUNCEME, 2019), fazendo-se necessária a construção da adutora emergencial do açude Araras (região do hidrográfica do Acaraú) distante 160 km do município de Crateús. A adutora esteve em funcionamento até o início de 2019, como única fonte de abastecimento dos municípios de Crateús, Ipaporanga e Nova Russas (CAGECE, 2017).

Percebe-se, então, a necessidade da alocação racional de águas tanto em períodos de estiagem quanto em períodos de cheias. Neste processo a previsão de precipitação pode contribuir tanto em nível de planejamento quanto em nível operacional de várias atividades socioeconômicas, tais como alerta precoce de desastres naturais, gestão de recursos hídricos, agricultura, saúde, turismo e outras, com o intuito de minimizar os impactos negativos de eventos climáticos extremos (ARAÚJO *et al.*, 2014).

A alta variabilidade climática da região torna a previsão da precipitação um problema de difícil solução. Neste caso, a utilização de redes neurais artificiais vem se mostrando uma ferramenta poderosa e eficiente na modelagem de fenômenos complexos, não lineares e multivariados, como é o caso da relação entre variáveis hidrológicas e informações climáticas e meteorológicas, devido a sua grande capacidade de aprendizagem, visto que são baseadas no princípio de funcionamento do cérebro humano (ARAÚJO *et al.*, 2014).

1.1 Objetivo

1.1.1 Objetivo geral

Este estudo tem o objetivo principal de avaliar a previsibilidade do regime pluviométrico sazonal da região hidrográfica dos Sertões de Crateús a partir da variabilidade da temperatura superfície do mar (TSM), utilizando técnicas de redes neurais artificiais (RNA).

1.1.2 Objetivos específicos

Como objetivos específicos, tem-se:

- Identificar os índices TSM que possuem maior influência na precipitação da área de estudo;
- Determinar modelos de previsão de precipitação a partir da associação dos diferentes índices TSM por ordem de influência;
- Avaliar a acurácia dos diferentes modelos de previsão sazonal de precipitação;
- Definir o modelo preditor de melhor desempenho para os diferentes períodos preditivos adotados.

1.2 Roteiro de trabalho

Este trabalho é composto por cinco seções. Nesta primeira seção é evidenciado sucintamente o tema desenvolvido, seguido do problema que motivou a sua realização, além da justificativa para a sua elaboração e os objetivos pretendidos, finalizando com a delimitação da análise realizada. Posteriormente, é exposta a revisão bibliográfica sobre os sistemas meteorológicos e índices TSM que influenciam a precipitação do NEB e do Ceará.

Na terceira seção, é esclarecido a metodologia utilizada, isto é, têm-se a descrição de como os modelos citados no tópico anterior serão utilizados. A seção quatro apresenta os resultados obtidos e as discussões em decorrência dos mesmos. Por fim, na última seção são exibidas as considerações finais.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar uma revisão bibliográfica que sirva de apoio ao presente trabalho. Primeiramente, é realizada a caracterização climática e a descrição dos principais índices TSM que podem influenciar a área de estudo. Em seguida, apresenta-se o *Random Forest*, método utilizado para classificar os índices por sua importância e por fim, tem-se a discussão sobre as Redes Neurais Artificiais.

2.1 Caracterização climática

Este tópico tem o objetivo de apresentar os principais sistemas meteorológicas de precipitação do Nordeste Brasileiro (NEB) e em seguida, os que possuem maior influência no Ceará.

2.1.1 Sistemas meteorológicos atuantes no regime pluviométrico do NEB

As chuvas no Nordeste Brasileiro (NEB) podem ser causadas por mecanismos de grande escala, meso e microescala, onde os de grande escala são responsáveis por cerca de 30% a 80% da pluviosidade a depender do local. Dentre os mecanismos de precipitação de grande escala, destaca-se a Zona de Convergência Intertropical (ZCIT) e o Sistemas Frontais (SF). Com relação aos de mesoescala, ressalta-se, os Vórtices Ciclônicos de Alto Nível (VCAN), Complexos Convectivos de Mesoescala (CCM), Ondas de Leste (OL), Linhas de Instabilidade (LI) e brisas marítima e terrestre. Por último, os de mecanismos de microescala seriam as circulações orográficas e pequenas células convectivas (MOLION; BERNARDO, 2002; UVO; BERNDTSSON, 1996).

O ZCIT é uma zona de baixa pressão na região equatorial, formada pela confluência dos ventos Alísios do hemisfério norte e do hemisfério sul, em baixos níveis (o choque entre eles faz com que o ar quente e o úmido ascenda e propicie a formação de nuvens), sendo uma região de altas temperaturas de superfície do mar e alto regime de precipitação (FERREIRA, MELLO, 2005).

O mecanismo supracitado migra de sua posição mais ao sul, normalmente variando de 4°S, entre fevereiro e abril para uma posição mais ao norte, por volta 14°N, entre agosto e outubro. Estudos de Uvo *et al.* (1998) evidencia que a seca do NEB coincide com o posicionamento do ZCIT mais ao norte. Além disso, este é o principal mecanismo de

precipitação do norte do NEB durante a sua quadra chuvosa, que inicia em fevereiro e termina em maio (NAMIAS, 1972).

Os SF consistem em camadas de nuvens que são formadas no encontro entre uma massa de ar quente (menos densa) com uma massa de ar frio (mais densa), no encontro o ar quente e o úmido elevam-se e promove a formação de nuvens e em consequência, a geração de chuvas. Normalmente as precipitações do período de novembro a janeiro do NEB são causadas por estes sistemas (ARAÚJO JÚNIOR *et al.*, 2019).

Os VCAN são um conjunto de nuvens que tem a forma aproximada de um círculo girando em sentido horário, tendo em suas periferias nuvens causadoras de chuvas, enquanto no centro há movimentos de ar em sentido descendente, impossibilitando a formação de nuvens (FERREIRA; MELLO, 2005). Estes Vórtices se formam no oceano atlântico, adentrando no NEB, principalmente nos meses de novembro a março, onde sua trajetória tem o sentido de leste a oeste, tendo maior frequência em janeiro e fevereiro (GAN *et al.*, 1982).

O NEB também é influenciado por distúrbios ondulatórios no campo dos ventos Alísios, sendo mais conhecido como Ondas de Leste (OL). Estas ondas são formadas por perturbações que acontece no campo dos ventos Alísios, causado por penetrações de sistemas frontais em baixas latitudes, onde os ventos do sul, associado aos sistemas frontais, com ventos do leste, provocam distúrbios ondulatórios nos Alísios, propagando-se para oeste do Atlântico Sul (MOLION; BERNARDO, 2002). Além disso, Ferreira *et al.* (1990) observou que a maior frequência dessas perturbações acontece no período de março a maio (MAM).

As LI são caracterizados por aglomerados de nuvens do tipo Cumulus-nimbus, organizados em forma de linha (COHEN *et al.* 1989). São formados devido à grande quantidade de raio solar que incide sobre a região tropical (que contribui para a formação de nuvens cumulus), atingindo uma maior quantidade no fim da tarde e início da noite, quando a convecção é máxima, contribuindo para a geração de chuvas. A proximidade do ZCIT nos meses de fevereiro a março contribui ainda mais para este sistema (FERREIRA; MELLO, 2005).

Os CCM são caracterizados por uma intensa atividade convectiva, apresentando-se como uma única célula nebulosa com forma arredondada (CABRAL *et al.*, 2015). Este mecanismo de precipitação é formado devido condições locais favoráveis, como pressão, relevo, temperatura entre outros, provocando fortes chuvas com curta duração, tendo um ciclo de vida de 10 a 20 horas. Ocorrem principalmente no hemisfério sul, durante os meses de primavera e verão (SOUZA *et al.*, 1998).

Com relação as brisas marítimas e terrestres, tem-se que o oceano aquece mais lento que o continente, estabelecendo um gradiente térmico, com as temperaturas mais baixas no

oceano. Dessa forma, cria-se uma região de pressão mais baixa e forçando a entrada do ar marinho com temperaturas mais baixas (brisa marinha), o movimento do ar ascendente propicia a formação de nuvens e conseqüente, chuvas. Ao entardecer, o ar do oceano tem uma menor taxa de resfriamento, revertendo o gradiente térmico, tendo temperaturas mais elevadas nos oceanos, assim, tem-se a circulação do ar do continente da terra para o mar com movimentos ascendentes (brisa terrestre), possibilitando a formação de nuvens (MOLION; BERNARDO, 2002).

2.1.2 Sistemas meteorológicos que influenciam a precipitação no Ceará

Estudos de Santos *et al.* (2015) apresentam que o ZCIT e VCAN possui uma maior atuação na precipitação do Estado do Ceará, concentrando-se em sua maioria nas estações de verão e outono. Os VCAN influenciam a precipitação no Ceará em meados de dezembro para algumas regiões localizadas ao sul do estado, porém tem maior participação no mês de janeiro (SANTOS; SOARES, 2015).

O ZCIT é intensificado em fevereiro e no período do verão para o inverno, ocasionando precipitações e reduzindo a influência dos vórtices ciclônicos, que também pode influenciar negativamente as chuvas, uma vez que pode inibir a translação do ZCIT do hemisfério norte para o sul. Além disso, o ZCIT é principal sistema causador de chuvas no Ceará (COUTINHO; SOKOMOTO, 2017).

Coutinho *et al.* (2017) apresenta um estudo de caso para um evento extremo de precipitação envolvendo o Ceará, causado por VCAN seguido das OL nos dias de pré-estação analisado (referente ao mês de janeiro). Moraes *et al.* (2019) faz uma análise parecida para outro caso de caso de precipitação intensa no município de Fortaleza - CE, sendo os CCM o sistema meteorológico causador dessa precipitação.

2.2 Temperatura de Superfície do Mar

A região norte do NEB é uma região que possui alta previsibilidade da precipitação média sazonal (NOBRE; MOURA; SUN, 2001; RAJAGOPALAN; LALL; ZEBIAK, 2002; MARENGO *et al.*, 2003). A alta predição da precipitação é devida principalmente a influência dos oceanos Atlântico Tropical e Pacífico Equatorial nos mecanismos que proporcionam a chuva (NOBRE, 2012). Sendo apresentado a seguir os principais sistemas de Temperatura de Superfície do Mar (TSM) que influencia a região de estudo.

2.2.1 Dipolo do Atlântico

O dipolo do Atlântico é um fenômeno oceano-atmosférico discernido como a mudança anômala da temperatura de superfície do mar no Oceano Atlântico Tropical, isto é, quando as águas do Atlântico Tropical Sul (TSA – *Tropical Southern Atlantic*) estão mais quentes e as águas do Atlântico Tropical Norte (TNA – *Tropical Northern Atlantic*) estão mais frias, propicia a formação de nuvens no Nordeste, intensificando a ocorrência de chuvas, sendo conhecido como a fase negativa do dipolo. Em contrapartida, quando as águas do TSA estão mais frias e as águas do TNA estão mais quentes, ocorre movimentos descendentes transportando o ar frio e seco dos altos níveis da atmosfera sobre a região central, sertão e setentrional do Nordeste, inibindo a formação de nuvens e diminuindo a precipitação, sendo conhecido como a fase positiva do dipolo (HASTENRATH; HELLER, 1977; MOURA; SHUKLA, 1981).

Este padrão de anomalias TSM proporciona a ocorrência de gradientes meridionais de anomalias de TSM, influenciando consideravelmente a posição longitudinal do ZCIT, acarretando na alteração da distribuição sazonal de precipitação pluviométrica sobre o norte do Nordeste (NOBRE; SUKLA, 1996).

Para monitorar as alterações da TSM relacionado a este fenômeno, tem-se o índice TSA, com anomalia da média de TSM mensal de 0°–20°S e 10°E–30°W, o TNA com anomalia da média de TSM mensal de 5,5°N a 23,5°N e 15°W a 30°W (ESRL; 2018). Além disso, tem-se o gradiente meridional entre o Atlântico Sul e Norte, denominado como o Dipolo do Atlântico Tropical (CARTON *et al.*, 1996).

Moura *et al.* (2009) observou a correlação entre a precipitação e o TSM do atlântico é superior ao do TSM do pacífico, além de que as anomalias positivas de TSM no Atlântico Tropical Sul produzem precipitação sobre o leste do NEB. Araújo *et al.* (2014) e Araújo Júnior *et al.* (2019) realizam uma previsão climática para as vazões do açude Orós-CE, utilizando o TNA e TSA como um de seus preditores, obtendo resultados satisfatórios para os seus modelos. Anjos (2015) avaliou a variabilidade de frequências de 2 a 4, 4 a 6 e 6 a 8 anos das afluições históricas do Sistema Interligado Nacional, utilizando a análise de ondeletas, que permitiu avaliar as causas dessas variabilidades através de índices climáticos, no entanto, nenhum índice pôde ser relacionado com significância a variabilidade analisada das vazões afluentes.

2.2.2 El Niño – Oscilação Sul

O El Niño e a Oscilação do Sul são um fenômeno global resultante de interações

oceano-atmosférico, sendo conhecido como ENOS. O El Niño é o aquecimento da água do mar no Pacífico Tropical da costa do Peru/Equador até o oeste do Pacífico. A Oscilação do Sul é a variação anômala da pressão atmosférica tropical, sendo uma resposta aérea ao El Niño, associado a mudanças na circulação geral da atmosfera (ARAGÃO, 1998).

O ENOS é dividido em duas fases: positiva (La Niña) e negativa (El Niño). O resfriamento anômalo das águas do Pacífico Equatorial e a intensificação dos ventos alísios caracteriza-se como a La Niña, enquanto que o aquecimento do Pacífico Equatorial e o enfraquecimento dos ventos alísios é denominado como o El Niño (FARIAS; COELHO; SOUZA, 2006). Esses dois eventos tem impactos diferentes para o NEB, com a ocorrência do El Niño, tem-se a ocorrência de secas severas do Nordeste, enquanto que no caso da La Niña tem um aumento da precipitação desta mesma região (SIQUEIRA, 2012).

Estudos de Marengo *et al.* (2003) expõe que durante El Niño o ZCIT se encontra mais ao norte de sua posição normal, fazendo com que os ventos alísios do Nordeste e Sudeste sejam mais fracos, reduzindo a umidade que penetra no NEB. No entanto, Aragão (1998) buscou relacionar os eventos do El Niño em diversas intensidades e o NEB, tendo como resultado que o ZCIT no hemisfério norte não é sinônimo de seca.

Para monitorar as alterações da TSM no Oceano Pacífico e o fenômeno El Niño/La Niña, foram criados quatro índices climáticos: Niño 1+2, Niño 3, Niño 3.4 e Niño 4. As regiões referentes a cada índice El Niño são:

- Niño 1+2: 0°–10°S e 90°W–80°W
- Niño 3: 5°N–5°S e 150°W–90°W
- Niño 3.4: 5°N–5°S e 170°W–120°W
- Niño 4: 5°N–5°S e 160°E–150°W

Além desses quatro índices, outros índices climáticos também auxiliam na quantificação do fenômeno ENOS. Sendo o Niño Oceânico (ONI – *Oceanic Niño Index*), que é a média de três meses consecutivos de anomalias da região Niño 3.4, com base na mudança do período base que consiste em vários períodos básicos de 30 anos. Além do ENSO multivariado (MEI – *Multivariate ENSO Index*), onde suas séries temporais são bimestrais, ou seja, o valor de janeiro representa o valor entre os meses de janeiro e fevereiro e é centrado entre os meses (ESRL; 2018).

Anjos (2015) utilizou dentre outros índices, o Niño 3.4, MEI e ONI para analisar a variabilidade de afluência aos reservatórios hidrelétricos brasileiros, sendo observado que a variabilidade de baixa frequência dos índices climáticos estudados não poderia necessariamente ser considerada influente para a variabilidade de baixa frequência dos reservatórios brasileiros.

Araújo (2013), adotou o MEI como um dos índices oceânicos para analisar a variabilidade climática no NEB, porém, foi observado que a PDO e TNA foram os que mais interferiram nas chuvas da região, tanto em anos de secas quanto úmidos.

Com base nos resultados de Rolim *et al.* (2019), notou-se uma correlação entre a variabilidade climática da bacia do São Francisco e Niño 3.4, sendo as maiores correlações em escala interdecadal. Ferreira *et al.* (2004) analisou a precipitação de janeiro a abril, para o Sertão Central e Inhamuns, tendo como uns dos preditores o Niño 1+2, Niño 3, Niño 4 e Niño 3.4, tendo como resultado a correlação de -0,49, -0,51, -0,41 e -0,48, respectivamente.

Araújo *et al.* (2014) e Araújo Júnior *et al.* (2019) realizam uma previsão climática para o açude Orós-CE, utilizando o Niño 3 como um de seus preditores, obtendo resultados satisfatórios para os seus modelos. Souza Filho *et al.* (2004) também utilizou este índice para realizar a previsão de vazões sazonais e interanuais para um sistema de reservatórios no Estado do Ceará.

2.2.3 Oscilação Decadal do Pacífico

A Oscilação Decadal do Pacífico (PDO – *Pacific Decadal Oscillation*) é caracterizado por uma variabilidade a longo prazo na configuração das TSM no Oceano Pacífico, sendo semelhante ao ENOS. Enquanto que o ENOS tem normalmente uma variação climática de 6 a 18 meses, a PDO dura cerca de 20 a 30 anos. Este fenômeno também é dividido em duas fases, sendo a fase positiva quando existe um aumento das temperaturas do pacífico e fase negativa, referente a diminuição das temperaturas (MANTUA *et al.*, 1997).

Com a fase positiva do PDO, tem-se uma menor recorrência do La Niña e menos intensos, enquanto tem uma tendência maior para a ocorrência do El Niño com maior intensidade. Já na fase negativa, tem uma maior tendência de episódios da La Niña, que tendem a ser mais intensos, e menor frequência do El Niño, tendendo a ser curtos e rápidos (ANDREOLI; KAYANO, 2005). Assim, a fase negativa é favorável para o NEB, uma vez que propicia a formação de chuvas (SILVA; GALVÍNCIO, 2011).

Estudos de Alves *et al.* (2013) evidencia que a PDO afeta significativamente o regime de vazões dos postos do Sistema Interligado Nacional (SIN), além de que mudanças negativas no patamar das vazões coincidem com a fase negativa do PDO, sendo equivalente ao caso da fase positiva do PDO. Marengo *et al.* (2007) observou que uma variabilidade na escala de tempo interdecadal do NEB, pode estar associado entre outros fatores, à variabilidade ao PDO.

Rolim *et al.* (2019) notou uma correlação entre a variabilidade climática da bacia do São Francisco e PDO, sendo as maiores correlações em escala interdecadal. Fernandes *et al.* (2019) observou que as séries de vazões médias anuais do Ceará mostram sinais de variabilidade interanual e decadal, estando relacionado ao PDO, afetando significativamente esse regime de vazão, onde observa que uma mudança de patamares nas vazões coincide com mudanças de patamares do índice PDO.

2.2.4 Oscilação Multidecadal do Atlântico

A Oscilação Multidecadal do Atlântico é caracterizada pela alteração da TSM do Oceano Atlântico Norte, ocorrendo por um longo período. Esta oscilação é parecida com a PDO, uma vez que também é considerada de baixa frequência, além de possuir duas fases distintas: uma fria e outra quente. Ademais, seu tempo de duração é muito longo se comprado ao ONI, por exemplo, que perdura apenas por alguns meses (SIQUEIRA, 2012). A AMO é o principal mecanismo de variação climática de baixa frequência do Oceano Atlântico (ROCHA *et al.*, 2019).

Barreiro *et al.* (2014) mostraram que o índice AMO tem influência na precipitação da América do Sul. CAPOZZOLI *et al.* (2017) obteve resultados em que exibe que o AMO possui influência na variabilidade nos principais rios das bacias brasileiras. Estudos realizados por Silva *et al.* (2011) para a precipitação envolvendo o Ceará utilizando o PDO e AMO exibiram que existe uma possível relação para estes índices, todavia as influências individuais não foram quantificadas. Rocha *et al.* (2019) detectou a influência conjunta das variações de TSM do oceano atlântico e pacífico nas precipitações do Alto Jaguaribe, podendo-se concluir que períodos com fase simultaneamente positiva e negativa da PDO e AMO tem comportamentos mais definidos de precipitação, sendo esperado maiores valores de precipitação quando estes índices forem simultaneamente negativos.

2.2.5 Oscilação do Atlântico Norte

A Oscilação do Atlântico Norte (NAO – *North Atlantic Oscillation*) é o principal modo de variabilidade de circulação atmosférica do Atlântico Norte (TRIGO *et al.*, 2002). É definido como um índice que mede a diferença entre os centros de baixas pressões subpolares e os centros de altas pressões subtropicais, sendo observável através da diferença de pressão entre Stykkishoulmur na Islândia e Ponta Delgada em Portugal. O NAO consiste num dipolo norte-sul de anomalias, com um centro localizado sobre a Islândia e outro, de sinal oposto

abrangendo as latitudes centrais do Norte Atlântico entre os 35°N e os 40°N (OLIVEIRA; CUNHA; PAIVA, 2017).

A NAO é dividida em duas fases: positiva e negativa. A fase positiva reflete alturas (geopotenciais) e pressões à superfície abaixo do normal ao longo das latitudes elevadas do Atlântico Norte e acima do normal para o centro do Atlântico Norte. A fase negativa reflete oposto de anomalias relativo as alturas geopotenciais e pressões da superfície sobre as mesmas regiões (HURRELL, 1995).

Estudos de Labat (2008) exibiu que o NAO é um pouco correlacionado com as descargas dos grandes rios da América do Sul. Entretanto, Anjos (2015) obteve resultados que apresenta que este fenômeno não teve grande relevância para os principais rios do Brasil, com a banda variando de 2, 4, 6 e 8 anos. Por fim, Marengo *et al.* (2007) observou que uma variabilidade na escala de tempo interdecadal do NEB, pode estar associado entre outros fatores, à variabilidade da NAO.

2.3 Random Forest

As florestas de decisão são um conjunto de Árvores de Decisão (AD) criadas a partir de uma base de dados (RIQUETI; RIBEIRO; ZÁRATE, 2018). A AD é uma maneira simples e eficaz de representar o conhecimento, onde são baseadas na metodologia de “dividir para conquistar”, isto é, existe uma divisão sucessiva do conjunto de dados utilizados em vários subconjuntos, até cada um destes pertencer a uma mesma classe ou até uma dessas classes serem majoritárias (GARCIA, 2003).

O principal obstáculo ao gerar uma floresta de decisão está relacionado em obter uma boa variabilidade nas árvores que a compõem, levando a um maior poder de generalização para o modelo. Devido isso, é introduzido por Breiman (2001) o algoritmo de Florestas Aleatórias ou *Random Forest* (RF), sendo um método utilizado para gerar essa floresta de decisão (RIQUETI; RIBEIRO; ZÁRATE, 2018).

O RF é um popular e eficaz algoritmo de aprendizado de máquina para seleção de variáveis (BREIMAN, 2001). O bom desempenho do RF está relacionado principalmente à sua aleatoriedade em criar as árvores, onde para cada nó da AD o modelo escolhe a melhor divisão de um subconjunto aleatório de variáveis de entrada. Além disso, ao inicializar o conjunto de treinamento para cada árvore, por volta de um terço dos dados analisados são omitidos para a avaliação do desempenho, a amostra *Out-of-Bag* (OOB). A amostra OOB é empregada para obter uma estimativa imparcial do erro de predição (GENUER *et al.*, 2010).

A diferença entre a média do erro (taxa de classificação errônea para classificação e Erro Quadrático Médio (EQM) para regressão) para os dados modificados e originais do OOB, dividida pelo erro padrão, é uma medida da importância da variável (CUTLER, 2007). Outra medida é o aumento da pureza do nó, que se relaciona com a função de perda que por melhores divisões são escolhidas, para classificação a função de perda é a impureza Gini. Quanto mais útil é a variável, maior é o aumento na pureza do nó (CARVALHO; 2019).

O EQM é uma medida mais informativa do que a pureza do nó. Na Equação 2.1 é exposto o cálculo do EQM.

$$EQM_{OOB} = n^{-1} \sum_{i=1}^n \left\{ y_i - y_i^{OOB} \right\}^2 \quad (2.1)$$

Em que: y_i é a previsão da observação i e y_i^{OOB} é média das previsões para a observação i (LIAW; WIENER, 2002). Assim como Carvalho (2019), o EQM foi adotado como a medida de importância variável representando a classificação.

Fernández-Delgado *et al.* (2014) realizou experimentos comparando 17 famílias de classificadores (179 classificadores no total) em 121 bases de dados, e concluiu que a família do RF obteve os melhores resultados de predição. Carvalho (2019) que utilizou o RF para a classificação de variáveis, obteve que este modelo resultou em dos melhores subconjuntos para a previsão dos dados analisados.

2.4 Redes Neurais Artificiais

Este tópico tem o objetivo de introduzir ao conteúdo das Redes Neurais Artificiais (RNA) e em seguida, apresentar as principais características do modelo utilizado neste trabalho, isto é, o *Perceptron Multilayer* (MLP).

2.4.1 Introdução às Redes Neurais

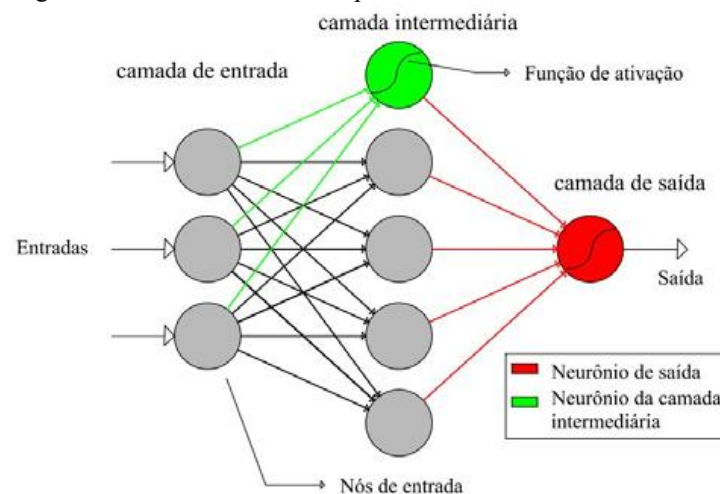
O desenvolvimento das RNA foi instigado pela grande capacidade do cérebro humano aprender e realizar tarefas extremamente complexas após passar por algum processo de aprendizagem. A principal unidade do sistema nervoso, isto é, o cérebro humano, é um sistema de processamento de informações altamente complexo, não-linear e paralelo formado por um conjunto de unidades fundamentais: os neurônios, que organizadas de tal forma a realizar certos processamentos muito mais rápidos que qualquer computador digital atualmente conhecido (HAYKIN, 2001).

Uma rede neural é composta por um conjunto de elementos de processamento,

sendo normalmente conhecido por neurônios, onde o primeiro passo consiste em especificar o número de neurônios (GALVÃO *et al.*, 1999). O funcionamento do neurônio artificial é similar ao neurônio biológico, em que cada neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural (HAYKIN, 2001).

Dentre os vários tipos de arquiteturas de RNA existentes, a rede neural de múltiplas camadas tem sido utilizada em diversos artigos acadêmicos (BIRIKUNDAVY *et al.*, 2002; DAWSON *et al.*, 2002; STOKELJ *et al.*, 2002; DAWSON; WILBY, 2001). Esta arquitetura é composta por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, facilitando a construção de algoritmos de operação e de treinamento. Os dados que alimentam a rede ingressam através da camada de entrada e são posteriormente processados através das diferentes camadas intermediárias, produzindo ao final um resultado apresentado na camada de saída (BRAVO *et al.*, 2008).

Figura 1 - Rede Neural de múltiplas entradas



Fonte: Matos *et al.* (2014).

Os dados de entrada devem ser normalizados, para evitar problemas de estabilidade com a RNA. Esta normalização é geralmente realizada nos intervalos de $[-1,1]$ ou $[0,1]$. (OLIVEIRA; PEDROLLO; CASTRO, 2014).

A função de ativação define como será repassada a informação entre os neurônios artificiais, em que acontece pela adição do produto dos pesos sinápticos, mais um estímulo externo, para produzir um resultado que servirá como entrada para o neurônio subsequente (ROCHA *et al.* 2012).

Ademais, salienta-se que diversas pesquisas obtiveram excelentes resultados com a aplicação de RNA na área de recursos hídricos e hidrologia, principalmente no desenvolvimento de modelos para simulação, previsão e classificação (JAIN *et al.*, 2004; BOWDEN *et al.*, 2005; JAIN; KUMAR, 2007; OLIVEIRA *et al.*, 2013). Apesar de resultados promissores, este modelo

é rotulado como “caixa preta”, uma vez que não explica os processos internos que relacionam os dados analisados (HSU *et al.*, 1995; JAIN *et al.*, 2004).

Dentre os vários tipos de redes neurais, destaca-se o *Multilayer Perceptron*, que é amplamente utilizado na área de recursos hídricos, podendo ser observados em diversos autores: Figueiredo *et al.* (2007), Gomes *et al.* (2010), Cruz *et al.* (2010), Rocha *et al.* (2013), Telles *et al.* (2013), Araújo *et al.* (2014), Debastiani *et al.* (2016), Charles (2017), Araújo Júnior *et al.* (2019) e Carvalho (2019).

2.4.2 Multilayer Perceptron

As redes *Multilayer Perceptron* (MLP) são caracterizadas pela presença de uma camada de entrada (responsável por receber os dados que alimentam a rede) e outra de saída (possui a finalidade de dar as respostas corretas para os estímulos do modelo), entre essas localiza-se pelo menos uma camada intermediária de neurônios, também denominado como camada oculta, sendo o responsável pelo aumento da capacidade da RNA em extrair o comportamento mais complexo, com base nos dados disponíveis no processo de treinamento (ARAÚJO, 2019).

As MLP possuem elevadas possibilidades de aplicações em diversos problemas relacionado as mais diferentes áreas do conhecimento, sendo considerada uma das arquiteturas mais versáteis quanto à aplicabilidade. As áreas com maior potencial de aplicação são: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (SILVA; SPATTI, FLAUZINO, 2010).

A rede MLP passa inicialmente por um processo denominado treinamento, onde os dados de entrada e os dados de saída separados para esta fase são introduzidos simultaneamente no modelo e com isso a rede vai ser treinada, ou seja, vai aprender a correlacionar os dados de entrada com os de saída.

Após treinada, a rede passará pela etapa de validação. O conjunto de dados que não foram utilizados no treinamento serão empregados. Nesta etapa, é introduzido apenas os dados de entrada e é solicitado que a rede retorne com os dados de saída estimados. Em seguida, é realizado um comparativo entre os dados observados e os estimados pela rede, então é calculado o erro absoluto, fazendo a diferença entre os dados observadas e estimadas (ROCHA *et al.*, 2012).

A aprendizagem do modelo consiste na alteração de todos os pesos sinápticos (w_{kj}) e limiares existentes (b_k), baseado na experiência conhecido pelo fenômeno estudado. Esta

experiência é representada por um conjunto de dados contendo as entradas e saídas conhecidas para o problema a ser modelado, sendo este conjunto exposto na Equação 2.2 (HAYKIN, 2001).

$$\prod_{l=1}^L (\{x_l\}, \{d_l\}) \quad (2.2)$$

Em que \prod , L , $\{x_l\}$ e $\{d_l\}$, significa respectivamente, conjunto de dados de entrada utilizados na modelagem, número de entradas e saídas conhecidas no conjunto de dados de treinamento, conjunto de entrada para os L -exemplos existentes no conjunto de dados de treinamento e, conjuntos de saída para os mesmos L -exemplos (ARAÚJO *et al.*, 2019).

Para o treinamento da rede, é utilizado o algoritmo conhecido como algoritmo de retropropagação de erros, sendo baseado na regra de aprendizagem por correção de erros. Onde a seguir é exposto a demonstração que envolve o algoritmo de retropropagação de erros e a regra do delta generalizada feita por Haykin (2001). Iniciando pelo sinal do erro do neurônio k (Equação 2.3), que é obtido pela diferença entre o valor de saída i -ésimo exemplo conjunto de treinamento e o resultado do neurônio $y_k(i)$.

$$e_k(i) = d_k(i) - y_k(i) \quad (2.3)$$

Sendo $e_k(i)$ e (i) , respectivamente, o sinal do erro do neurônio k , saída desejada para o neurônio k . O sinal do erro $e_k(i)$ aciona um mecanismo de controle, tendo o propósito de ajustes corretivos aos pesos sinápticos dos neurônios k . Os ajustes corretivos tem o objetivo de aproximar passo a passo o sinal de saída $y_k(n)$ da resposta desejada $d_k(n)$.

Tal objetivo é alcançado ao minimizar a função de custo ou índice de desempenho $E(n)$. A função de custo utilizada para avaliar o desempenho da rede MLP no conjunto de treinamento é o erro quadrático instantâneo, dado pela Equação 2.4:

$$E(n) = \frac{1}{2} \sum_{k \in c} e_k^2(i) \quad (2.4)$$

Onde c é o conjunto de todos os neurônios da camada de saída do exemplo i do conjunto de treinamento.

Considerando o processo de treinamento em lote, no qual o conjunto de pesos sinápticos é fixo para todos os L -exemplos existentes no conjunto de treinamento, a função de custo é o erro quadrático médio $E_{méd}(n)$, sendo obtido pela Equação 2.5.

$$E_{méd}(n) = \frac{1}{2d} \sum_{i=1}^L \sum_{k \in c} [d_k(i) - y_k(i)]^2 \quad (2.5)$$

No qual n é o passo do tempo discreto, correspondente a cada alteração do conjunto de pesos sinápticos no conjunto de treinamento.

O objetivo deste processo de treinamento é alterar o vetor dos pesos sinápticos até

que o erro quadrático médio ou instantâneo seja mínimo. Assim, os ajustes sucessivos no vetor dos pesos sinápticos de um determinado neurônio da camada de saída, como o neurônio $y_k(n)$, pode ser realizado de acordo com a Equação 2.6.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \Delta w_{kj}(n) \quad (2.6)$$

Em que w_{kj} é vetor de peso sinápticos na época n . Essa alteração ocorre de forma iterativa por meio de ajustes sucessivos no vetor de pesos sinápticos, percorrendo a superfície de $E_{med}(\{w_{kj}\})$ na direção e sentido oposto ao do gradiente do erro quadrático médio (∇E_{med}), dado pela Equação 2.7.

$$\nabla E_{med}(n) = \frac{\partial E_{med}(n)}{\partial w_{kj}(n)} \quad (2.7)$$

Assim, o ajuste do vetor de pesos sinápticos para o neurônio $y_j(n)$ pode ser feito de acordo com a Equação 2.8.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n) - \eta \nabla E_{med}(n)\} \quad (2.8)$$

Onde η é a taxa de aprendizagem. Com isso, ao desenvolver a fórmula do erro quadrático médio (Equação 2.6) e aplicar os resultados obtidos pela equação do gradiente do erro quadrático médio (Equação 2.8), tem-se a Regra do Delta (Equação 2.9), que é uma expressão para o ajuste do vetor de pesos sinápticos para o neurônio $y_k(i)$ da camada de saída.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \frac{\eta}{l} \sum_{i=1}^l \sum_{k \in c} \delta_j \{y_j(l)\} \quad (2.9)$$

Onde $w_{kj}(n+1)$ é o vetor de pesos sinápticos entre os nós k (saída) e j (entrada) na iteração $n+1$ e δ_j é gradiente local do neurônio. No caso de um neurônio da camada oculta, o cálculo direto do gradiente local não é possível, visto que produz um sinal que se propaga até a camada seguinte, não produzindo assim, nenhum sinal de erro. Diante disso, aplicando o Algoritmo de Retropropagação do Erro, o gradiente local de uma camada oculta é dado pela Equação 2.10.

$$\delta_j(i) = -\frac{1}{L} f' \left(v_j(i) \sum_{i=1}^L \sum_{k \in c} \delta_k(i) \{w_{kj}(n)\} \right) \quad (2.10)$$

Em que o gradiente local do neurônio $y_j(n)$, isto é, $\delta_k(i)$ é obtido pela Equação 2.11.

$$\delta_k(i) = e_k f'(v_k(n)) \quad (2.11)$$

No qual $v_k(i)$ é campo local induzido do neurônio $y_k(i)$ no i -ésimo exemplo do conjunto de treinamento.

Por fim, para aumentar a taxa e aprendizagem η com o objetivo de evitar o perigo

de instabilidade é a inclusão do constante momento α (HAYKIN, 2001). Diante disso, a alteração dos pesos sinápticos conhecida como Regra do Delta Generalizada, é obtida pela Equação 2.12.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \frac{\eta}{L} \sum_{i=1}^L \sum_{k \in c} \delta_j(i) \{y_j(n)\} + \alpha \{\Delta w_{kj}(n-1)\} \quad (2.12)$$

3 METODOLOGIA

A metodologia utilizada foi a pesquisa quantitativa, baseando-se em dados mensuráveis, buscando verificar a relação entre Temperatura de Superfície do Mar (TSM) e a precipitação da Região Hidrográfica (RH) dos Sertões de Crateús. O método de pesquisa adotado neste trabalho é dividido em 5 partes: Levantamento de dados, estratégia metodológica, classificação por ordem de importância dos índices climáticos, previsão climática utilizando MLP e a abordagem estatística, sendo explicado cada tópico a seguir.

3.1 Região de estudo

A região hidrográfica dos Sertões de Crateús possui uma área de 10.821 km², compreendendo a rede de drenagem do Rio Poti. Além disso, possui uma capacidade de acumulação de águas superficiais de 446.685.647 m³. Na Figura 2 é exposto a localização da área de estudo em relação as outras regiões do Estado do Ceará (SRH, 2013).

Figura 2 - Regiões hidrográficas do Estado do Ceará



Fonte: SRH (2013).

Esta região é constituída por nove municípios, tendo uma população total de 240.714 habitantes, sendo possível observar na Tabela 1 cada município com sua respectiva população. Além disso

Tabela 1 – População dos municípios da RH dos Sertões de Crateús

Município	População (Censo 2010)
Crateús	72.812
Independência	25.573
Novo Oriente	27.453
Quiterianópolis	19.921
Tamboril	25.451
Ipaporanga	11.343
Ararendá	10.491
Nova Russas	30.965
Monsenhor Tabosa	16.705

Fonte: SRH (2013).

Além disso, a área de estudo possui um total de 10 açudes monitorados pela Companhia de Gestão dos Recursos Hídricos (COGERH), sendo na Tabela 2 cada reservatório com sua respectiva capacidade (FUNCEME, 2019).

Tabela 2 - Reservatórios da Rh dos Sertões de Crateús

Reservatório	Capacidade (hm ³)	Reservatório	Capacidade (hm ³)
Carnaubal	73,2	Barra Velha	99,56
Realejo	31,55	Cupim	4,6
Barragem do Batalhão	1,64	Colina	4,29
Flor do Campo	105	São José III	6,6
Jaburú II	101,54	Sucesso	7,96

Fonte: FUNCEME (2019).

3.2 Levantamento dos dados

As anomalias de TSM utilizados nas análises podem ser obtidos a partir do sítio do *Earth System Research Laboratory* (ESRL) do *National Oceanic and Atmospheric Administration* (NOAA) em <http://www.esrl.noaa.gov/psd/data/climateindices/list>. Como critério de escolha dos índices disponíveis, utilizou-se aqueles em que foram mais utilizados em dissertações ou artigos publicados em análises envolvendo o Nordeste, com mais enfoque no estado Ceará, como os estudos de Ferreira *et al.* (2004), Araújo *et al.* (2014), Anjos (2015), Araújo Júnior (2019), Fernandes *et al.* (2019), Rolim *et al.* (2019).

A série de dados da precipitação foi obtido a partir da realização da média de

precipitação utilizando o Thiessen com base nas estações pluviométricas da região hidrográfica de Crateús, disponibilizado pela Agência Nacionais de Água (ANA), podendo ser adquirido no sítio <http://www.snirh.gov.br/hidroweb>. Sendo exposto na Tabela 3, as estações pluviométricas utilizadas para a previsão.

Tabela 3 - Estações pluviométricas utilizadas

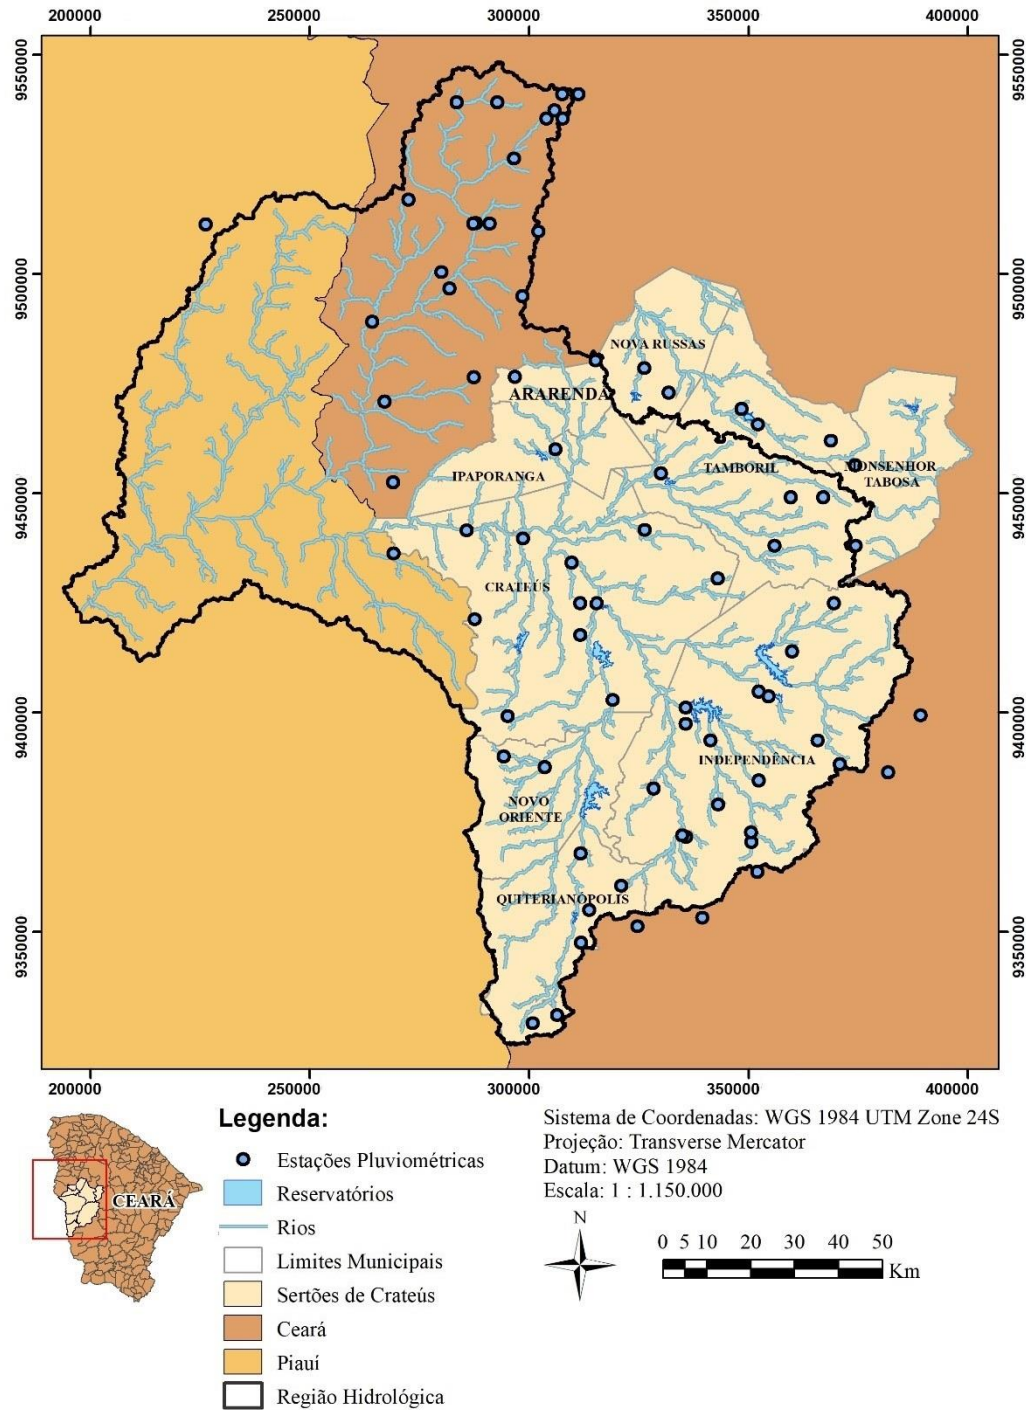
Cód. Estação	Nome do Posto	Cód. Estação	Nome do Posto	Cód. Estação	Nome do Posto
640037	Baixio	440003	Curatis	540035	Recife
640041	Algodões	440068	Curatis	540111	Fazenda Gracinha
540052	Quiterianópolis	440020	Sucesso	540028	Tucuns
540002	Coutinho	440055	Ipaporanga	540034	Ematuba
540042	Cruz	440007	Tamboril	540020	Aeroporto (Crateús)
540041	Monteiro	440080	Açude Carão	540000	Crateús
540030	Iapi	440060	Canindezinho	540026	Irapuã
540033	Várzea Grande	440044	Ararenda	540025	Morro Alegre
540115	Muquem	440017	Nova Russas	540039	Barreiros
540113	Fazenda Realeza	440045	Santo Antônio	540044	Oliveira
540007	Iapi	440001	São João Das Lontras	540043	Logradouro
540005	Tranqueiras	440004	Carnaubal	540107	Poti
540038	Cachoeira Do Fogo	440005	Croatá	441005	Pedro Ii
540003	Novo Oriente	440018	Poranga	441015	Santa Tereza
540054	Caminho Da Cachoeira	440023	Guaraciaba Do Norte	441014	Saudoso
540040	Emaus	440047	Croatá	539021	Riachão Do Banabuiu
540036	Jandrangoeira	440048	Sítio Várzea Redonda	540023	Ibiapaba
540108	Desejo	440050	Picada	540045	Santa Tereza
540032	Monte Sinai	440051	Limoeiro	540047	Bom Jesus
540024	Monte Nebo	440057	Matriz	540048	São João Do Trissi
540031	Jaburu	440058	América	540112	Fazenda Belo Horizonte
540027	Vila Santo Antônio	440072	São José	541002	Fazenda Boa Esperança
540019	Independência	440074	Morrinhos Novos	541013	Oiticica
540016	Independência	440075	Croatá	441016	Santana
540029	Santa Terezinha				

Fonte: Autoria própria (2019).

Para os casos em que existia mais de uma estação com mesma coordenada e período de funcionamento diferente, foram criadas estações com a união dos dados, criando estações equivalentes. Após esse período de verificação, restaram na área de estudo as 73 estações pluviométricas presentes na Tabela 3, destas, 48 estão localizadas na área dos Sertões de Crateús, as demais estações encontram-se espalhadas ao longo da área da região hidrológica, como apresentado na Figura 3.

A série histórica de precipitação estudada compreende os anos de 1911 a 2018, porém como o NOAA possui dados apenas a partir de 1950 e com término em 2017 para alguns índices, foi necessário restringir a série histórica para o período de 1950 a 2017.

Figura 3 - Disposição espacial das estações pluviométricas



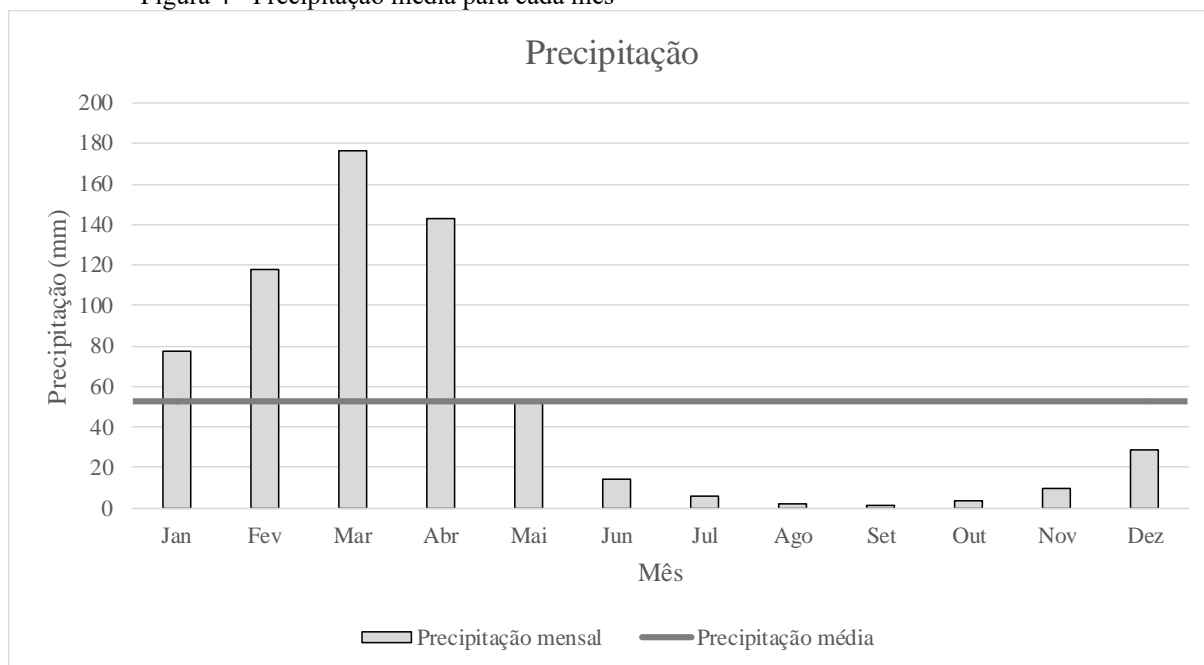
Fonte: Autoria própria (2019).

Após isso, obtém-se uma série de precipitação média para toda a região hidrográfica, nessa etapa, as séries das estações que possuem influência na área de estudo são selecionadas e utilizando de um código de programação feito com base na linguagem R o Thiessen mensal é gerado, resultando em uma resposta de série única e continua no tempo, sendo possível observar os valores obtidos na Tabela A.1 do Apêndice A.

Na Figura 4 é exposto a média de precipitação para cada mês, sendo possível

observar que o período de maior precipitação são os meses de dezembro a maio. Além disso, percebe-se que a quadra chuvosa inicia no mês de fevereiro e termina em maio, uma vez que os meses de dezembro e janeiro são caracterizados com uma pré-estação.

Figura 4 - Precipitação média para cada mês



Fonte: Autoria própria (2019).

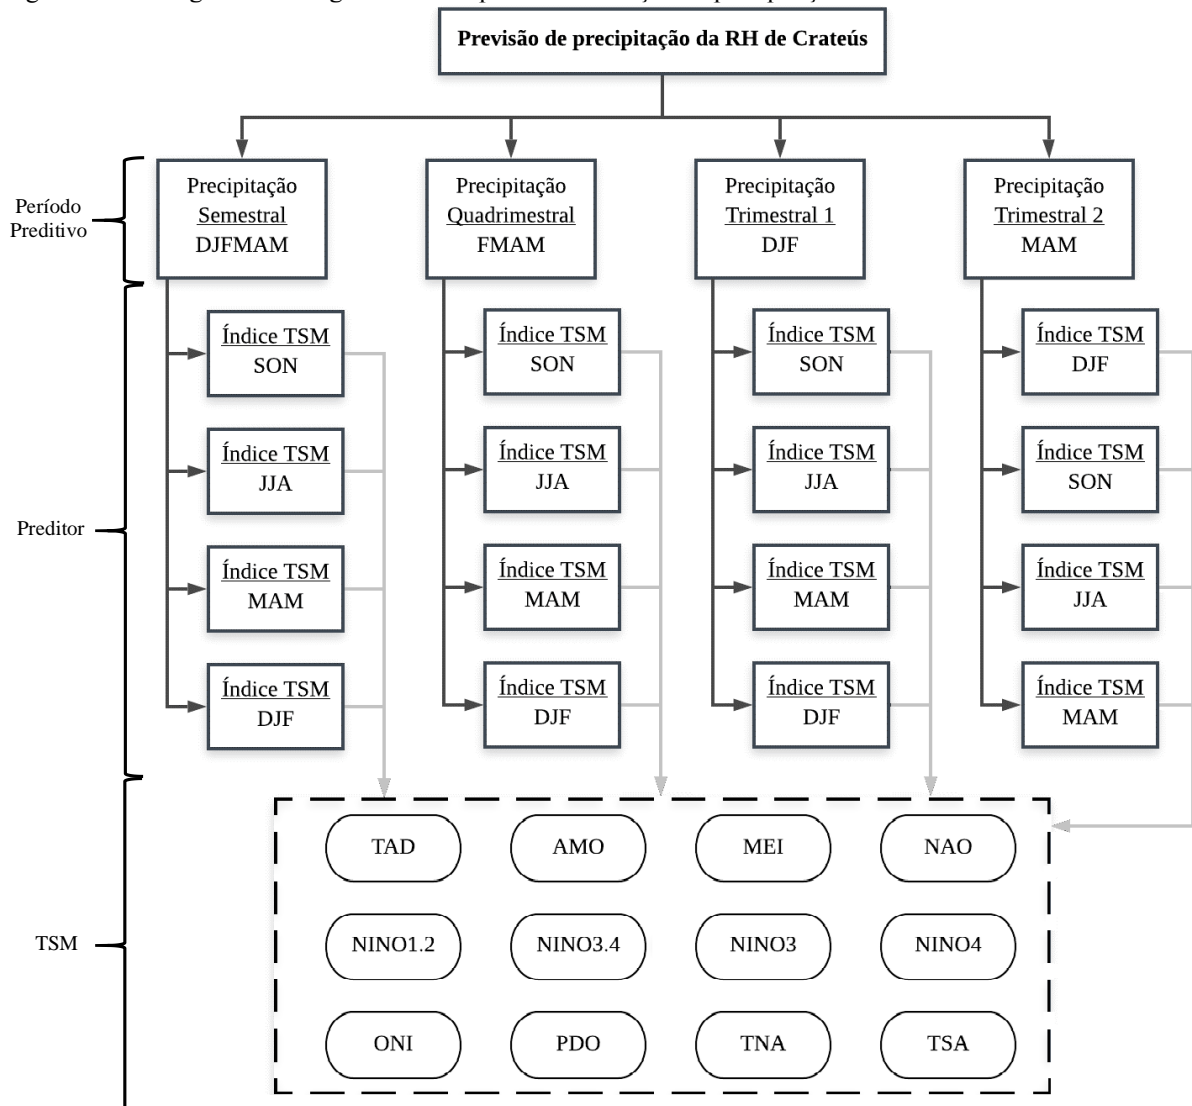
Por fim, tem-se que a precipitação média anual é de 631,28 mm e que a precipitação máxima e mínima ocorrida em apenas em um mês é de 488,23 mm e 0 mm, respectivamente.

3.3 Estratégia metodológica

Esta seção expõe a estratégia metodológica utilizada para a previsão da precipitação da Região Hidrográfica dos Sertões de Crateús, onde é empregado quatro períodos preditivos (que consiste nos dados de precipitação), e para cada período preditivo é usado quatro período de preditores, onde são utilizados 12 índices TSM, conforme Figura 5.

O primeiro período de precipitação a ser analisado é o semestral, sendo os meses de dezembro a maio (DJFMAM), adotando este semestre por conter os meses com maiores precipitações. Como preditor para este caso é analisado separadamente os quatro períodos de índices TSM imediatamente anteriores, referindo-se aos trimestres setembro a novembro (SON), julho a agosto (JJA), março a maio (MAM) e de dezembro a fevereiro (DJF), respectivamente. Vale salientar que esta mesma sequência de preditores é utilizada nos dois períodos preditivos subsequentes.

Figura 5 - Estratégia metodológica utilizada para determinação da precipitação na RH de Crateús



Fonte: Autoria própria (2019).

O segundo período preditivo a ser utilizado é a quadra chuvosa, isto é, os meses de fevereiro a maio, e o terceiro é o trimestral 1, estando relacionado aos meses de dezembro a fevereiro. Por fim, tem-se a análise da precipitação de março a maio, sendo denominado como o trimestral 2, utilizando os períodos de DJF, SON, JJA e MAM. Para todos os casos foi utilizado os mesmos índices climáticos, exposto na Tabela 1.

Tabela 4 - Índices climáticos utilizados como preditores

Sigla	Índice (em inglês)	Índice (em português)
TAD	<i>Tropical Atlantic Dipole</i>	Dipolo do Atlântico Tropical
TNA	<i>Tropical Northern Atlantic</i>	Atlântico Tropical Norte
TSA	<i>Tropical Southern Atlantic</i>	Atlântico Tropical Sul
NINO1.2	<i>Niño 1+2</i>	Niño 1+2
NINO3.4	<i>Niño 3</i>	Niño 3.4
NINO3	<i>Niño 3.4</i>	Niño 3

Tabela 4 - Índices climáticos utilizados como preditores

Sigla	Índice (em inglês)	Índice (em português)
NINO4	<i>Niño 4</i>	Niño 4
NAO	<i>North Atlantic Oscillation</i>	Oscilação do Atlântico Norte
MEI	<i>Multivariate ENSO Index</i>	ENSO multivariado
PDO	<i>Pacific Decadal Oscillation</i>	Oscilação Decadal do Pacífico
AMO	<i>Atlantic multidecadal oscillation</i>	Oscilação Multidecadal do Atlântico
ONI	<i>Oceanic Niño Index</i>	Niño Oceânico

Fonte: Autoria própria (2019).

3.4 Classificação por ordem de importância dos índices climáticos

Para classificar os índices climáticos por ordem importância foi utilizado o *Random Forest* (RF). Assim como em Carvalho (2019), a mediana da medida de importância para cada variável foi tomada para classificá-las, possibilitando assim que as anomalias de TSM sejam organizadas por ordem de importância. Onde a medida de importância é dado pela média do erro quadrático médio, dividido pelo desvio padrão.

Além disso, o modelo foi compilado com 50 *sets* de treino/teste, onde a etapa de treino corresponde a criação das Árvores de Decisão (AD), salientando que o modelo escolhe a melhor divisão de um subconjunto aleatório de variáveis de entrada e, fase de teste consiste em analisar o desempenho do modelo.

O método foi implementado usando o *software* Rstudio, utilizando o pacote “randomForest”, que é baseado no algoritmo clássico de Breiman (LIAW; WIENER, 2002). Os dois principais parâmetros é “mtry” e “ntree”. O parâmetro “mtry” é o número de variáveis de entrada escolhidas aleatoriamente em cada divisão, sendo adotado o número de variáveis explicativas dividido por três (arredondado para baixo), assim como em Carvalho (2019). O “ntree” é o número de árvores no RF, adotando-se o valor de 400 para os testes realizados.

3.5 Previsão climática utilizando MLP

No desenvolvimento do modelo *Perceptron Multilayer* (MLP) foi necessário a normalização dos dados utilizados, tanto dos dados de entrada (relativo as anomalias de TSM) e dos dados de saída (referente a série de dados a precipitação). Assim, os valores dos dados de entrada e saída foram normalizados, com valores variando de 0 e 1. A Equação 3.1 evidencia a fórmula utilizada para a normalização dos dados.

$$x_j^* = 2 \left(\frac{x_j - x_j^{\min}}{x_j - x_j^{\max}} \right) - 1 \quad (3.1)$$

Onde o vetor x consiste nos dados que são normalizados. Os dados utilizados na modelagem foram separados aleatoriamente, com um percentual de 80% para o treinamento e apenas 20% para a etapa de validação, ficando assim uma série de dados de 53 anos para o treinamento e 14 anos para a validação. Embora a quantidade utilizada na fase de validação possa ser pequena, utilizou-se devido à pouca quantidade de dados para a modelagem de um fenômeno tão complexo que foi analisado.

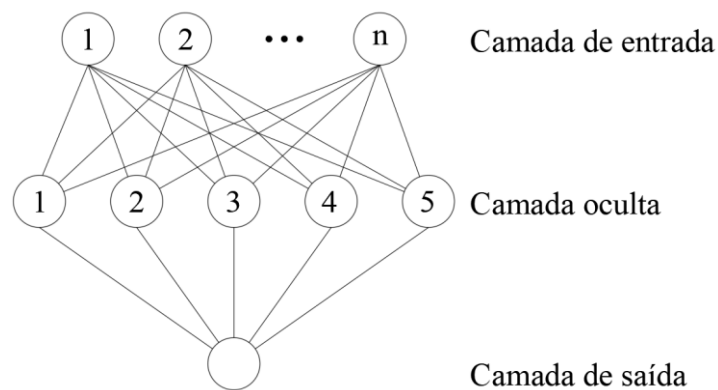
Um das funções de ativação mais utilizada é a função sigmoide, sendo utilizada neste trabalho, sendo apresentada na Equação 3.2 (ARAÚJO, 2015).

$$\varphi(v) = \frac{1}{1 + e^{(-x)}} \quad (3.2)$$

Vale ressaltar que a etapa de treinamento consiste no processo de aprendizagem da rede neural, enquanto o processo de validação é relativo a analisar se a rede apresenta resultados satisfatórios do fenômeno estudado.

Para calcular a precipitação pelo modelo MLP, elaborou-se 12 modelos com quantidade diferente de preditores, onde o Modelo 1 (M1) é calculado com o índice de maior importância, o Modelo 2 (M2) é obtido com a utilização dos 2 preditores mais importantes e assim sucessivamente, ou seja, o Modelo n (Mn) é calculado com as n variáveis mais importantes, como é exposto na camada de entrada da Figura 6.

Figura 6 - Estrutura do modelo de previsão de precipitação da RH dos Sertões de Crateús



Fonte: Autoria própria (2019).

A arquitetura da rede neural utilizado foi a Perceptron *Multilayer*, sendo implementado usando o pacote “RSNNS” no *software* Rstudio, onde os quatro principais parâmetros são “hidden”, “inputsTest”, “targestTest” e “learnFunc”. O parâmetro “hidden” está relacionada ao número de neurônios, sendo adotado o valor de 5 para as situações analisadas, como é apresentado na camada oculta da Figura 6. “inputsTest” está relacionado a matriz com as variáveis de entrada para o treinamento e “targestTest” corresponde a entrada dos dados de

validação (BEGMEIR; BENÍTEZ, 2012).

O “learnFunc” é a função de aprendizagem que define como o aprendizado ocorre na rede, sendo utilizado o “Std_Backpropagation”, que possui dois parâmetros: a taxa de aprendizado e a diferença máxima de saída. A taxa de aprendizado geralmente é um valor entre 0,1 e 1, especificando a largura da etapa de descida do gradiente. A diferença máxima define qual diferença entre a saída e o valor de destino é tratada como erro zero e não é retropropagada, sendo utilizado para evitar o excesso de treinamento (ZELL *et al.*, 1993). Ademais, foi utilizado o máximo de 1000 iterações para a compilação do modelo, além de que a função sigmoide foi utilizada como a função de ativação.

3.6 Abordagem estatística

Para a caracterização dos resultados do RF, adotou-se o *boxplot* (diagrama de caixa), uma vez que é utilizado para representar a variabilidade de dados observados por meio de quartis (ROSS, 2004). Os limites do *boxplot* é normalmente denominado como Limite Inferior (*LI*) e Limite Superior (*LS*), sendo obtido pelas Equações 3.3 e 3.4.

$$LI = Q_1 - c \cdot AIQ \quad (3.3)$$

$$LS = Q_3 + c \cdot AIQ \quad (3.4)$$

Onde Q_1 e Q_3 corresponde, respectivamente, ao primeiro e terceiro quartil, isto é, as variáveis que constituem a posição de 25% e 75% dos dados organizados por ordem crescente. *AIQ* é a amplitude interquartil, sendo obtida pela altura da caixa e, c é uma constante que pertence aos números reais, sendo geralmente adotado de 1,5. Um ponto além dos limites inferior ou superior é chamado de *outlier*. Por fim, tem-se que o segundo quartil é igual a mediana do espaço amostral (BUSSAB; MURETTIN, 2012). O método foi implementado utilizando a função “boxplot” do *software* Rstudio.

Para a análise da performance das redes neurais são aplicados inicialmente o Coeficiente de Correlação de Pearson (R), que é a medida da associação linear entre as observações e previsões, sendo definido na Equação 3.5.

$$R = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{P_i - \bar{P}}{S_p} \right) \left(\frac{O_i - \bar{O}}{S_o} \right) \quad (3.5)$$

Onde O e P são os valores observados e os da previsão, S é o desvio padrão, \bar{P} e \bar{O} são as médias das previsões e observações e N o número de observações. Este índice é adimensional, podendo variar de 1 a -1, sendo o valor de 1 correspondente para a previsão

perfeita (GUARNIERI, 2006).

O segundo parâmetro utilizado para analisar o desempenho do modelo RNA é o coeficiente de eficiência do modelo de Nash – Sutcliffe (1970) ou apenas NASH, sendo exposto na Equação 3.6.

$$NASH = 1 - \frac{\sum (P_{cal}^t + P_{obs}^t)^2}{\sum (P_{obs}^t + \overline{P_{obs}})^2} \quad (3.6)$$

Onde P_{obs} é a precipitação observada, P_{calc} é a precipitação calculado pelo RNA e t é referente a precipitação no tempo t . Este índice pode variar de $-\infty$ a 1, em que o valor 1 para o NASH corresponde a uma combinação perfeita entre a precipitação observada e a precipitação calculada. Em casos de eficiência igual a zero, indica que a precipitação obtida pelo modelo é tão precisa quanto a média observada. Em casos de NASH negativo, tem-se que a média da precipitação observada é um melhor preditor do que a saídas do modelo (MORIASI *et al.*, 2007). Além disso, o NASH adotado prioriza precipitações altas (ESTÁCIO; SOUZA FILHO; ROCHA, 2019).

Esses dois métodos foram implementados utilizando o *software* Excel, sendo implementado o cálculo do NASH pelo autor e a correlação foi obtida empregando a função “CORREL”. Ademais, para o caso com maior valor de correlação e NASH é realizado uma comparação com a precipitação calculada e a observada, por meio da distribuição de frequência acumulada.

4 RESULTADOS E DISCUSSÃO

Na determinação dos diferentes períodos de precipitação na região hidrográfica em estudo, foram avaliados como preditores 12 índices climáticos derivados da temperatura da superfície do mar (TSM), com 1 a 4 trimestres de antecedência (com lag variando de 1 a 4).

4.1 Previsão da precipitação para o semestre de dezembro a maio


Para a previsão da precipitação de dezembro a maio (DJFMAM), analisou-se como preditores índices climáticos de quatro trimestres imediatamente anteriores.

4.1.1 Análise dos preditores através do *Random Forest*

Para os índices analisados, foi realizado com 50 *sets* de treino/teste, além de que a mediana da medida de importância para cada variável foi tomada para classifica-las, assim sendo, os índices vão estar organizados por ordem de importância.


As Figuras 7, 8, 9 e 10 representam os *boxplot* obtido pelo modelo *Random Forest* (RF) para a média das anomalias de TSM de setembro a novembro (SON), junho a agosto (JJA), março a maio (MAM) e dezembro a janeiro (DJF), respectivamente. Salienta-se que o símbolo \circ é referente aos *outliers*.

Figura 7 - *Boxplot* para os índices TSM analisados no período de SON




Fonte: Autoria própria (2019).

Figura 8 - *Boxplot* para os índices TSM analisados no período de JJA.



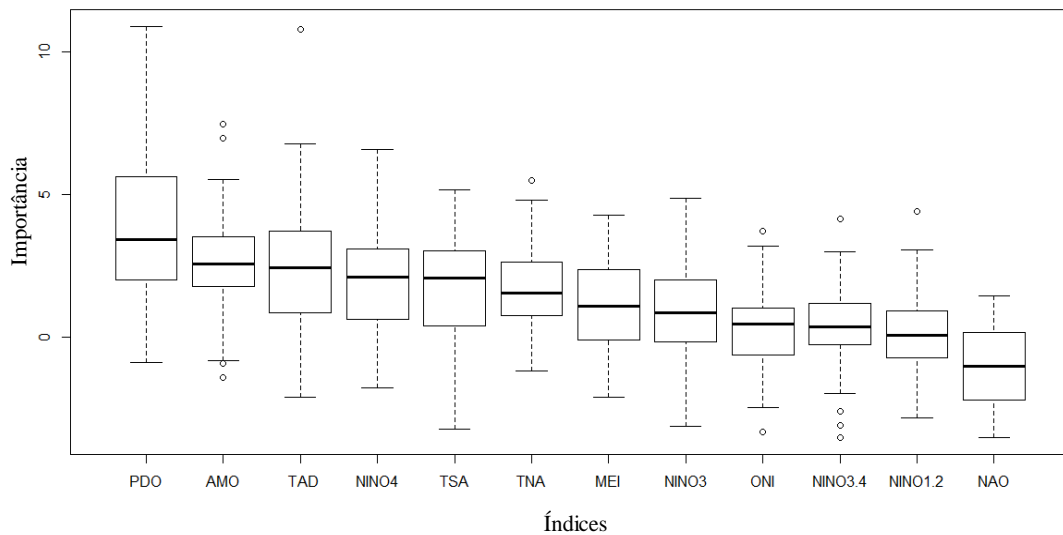
Fonte: Autoria própria (2019).

Figura 9 - *Boxplot* para os índices TSM analisados no período de MAM.



Fonte: Autoria própria (2019).

Figura 10 - *Boxplot* para os índices TSM analisados no período de DJF.



Fonte: Autoria própria (2019).

A partir da Figura 7, nota-se que para o período SON o Dipolo do Atlântico Tropical foi classificado como a variável mais importante, seguida do Atlântico Tropical Sul e da Oscilação do Atlântico Norte. A Oscilação Multidecadal do Pacífico e o Atlântico Tropical Norte apresentaram valores de importância negativo, indicando que estes índices possuem menor importância para a previsão.

Com base na Figura 8, percebe-se que para o período JJA, o Atlântico Tropical Sul e Dipolo do Atlântico Tropical novamente foram classificados como as variáveis mais importantes, alterando apenas as posições entre eles. Desta vez, a Oscilação Decadal do Pacífico e a Oscilação Atlântico Norte apresentaram valores de importância negativo.


Para o período MAM, tem-se que mais uma vez o Atlântico Tropical Sul foi classificado como o índice de maior importância, seguido do Niño 3 e Niño 1+2, sendo possível observar na Figura 9. O Dipolo do Atlântico Tropical que nos dois casos anteriores foi qualificado como a primeira ou segunda variável mais importante, desta vez apresentou valores negativos de importância, sendo classificado como a variável menos importante.

Baseado na Figura 10, a Oscilação do Atlântico Norte obteve resultados de importância negativa para o período DJF. A Oscilação Decadal do Pacífico que nos dois últimos casos teve resultados negativos, para este caso foi classificada como o índice mais importante, seguido da Oscilação Multidecadal do Pacífico. O Dipolo do Atlântico Tropical que obteve mediana negativa no caso anterior, foi classificado como uma das variáveis mais importantes.

4.1.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais


Nas Figuras 11, 12, 13 e 14 é exposta a correlação e o NASH da precipitação observada de DJFMAM com relação a precipitação obtida pelo modelo RNA, utilizando os índices climáticos dos períodos SON, JJA, MAM e DJF.

Figura 11 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON




Fonte: Autoria própria (2019).

Figura 12 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA




Fonte: Autoria própria (2019).

Figura 13 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM



Fonte: Autoria própria (2019).

Figura 14 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF



Fonte: Autoria própria (2019).

Verificando a Figura 11, tem-se que a correlação para o preditor SON obteve maiores valores nos modelos da etapa de validação, apresentado o maior resultado de 0,738 para o Modelo 3 (M3), onde o Dipolo do Atlântico Tropical, Atlântico Tropical Sul e Oscilação do Atlântico Norte foram utilizados como preditores. Já na outra etapa, o maior valor foi de 0,606 no Modelo 12 (M12). Além disso, o gráfico da etapa de treinamento foi crescente até o M4, tendo um comportamento assintótico após este modelo, no caso da validação, foi crescente até o M3 e decrescente até M5, tendo um comportamento mais constante nos modelos seguintes.

Vale salientar que essa estabilização do gráfico implica que o modelo não apresenta um ganho significativo na precisão com a adição de mais índices TSM como preditor.

O NASH para este mesmo preditor, exibiu maiores valores na etapa de validação até o M4, com o máximo de 0,364, onde Dipolo do Atlântico Tropical, Atlântico Tropical Sul, Oscilação do Atlântico Norte e Niño 3 foram utilizados como preditores, tendo na etapa de treinamento melhores resultados nos modelos seguintes, com o maior valor de 0,345 no M12. O comportamento do NASH na etapa de treinamento é análogo ao da correlação, já na etapa de validação apresentou valores crescentes até o M4, tendo poucas variações nos modelos subsequentes. Portanto, nota-se que tendo a utilização de pouco preditores já teve bons resultados quando comparado com os modelos com mais preditores.

Com base na Figura 12, a etapa de validação apresentou os maiores valores de correlação, tendo a maior valor de 0,630 no M7, enquanto no treinamento a maior correlação foi de 0,559 no M12, com relação ao NASH, a etapa de validação teve os maiores valores até o M3, com o máximo de 0,254, após este modelo, a etapa de treinamento apresentou melhores resultados, possuindo o maior valor de 0,310 no M10. Tanto na correlação quanto no NASH, a etapa de treinamento foi crescente até o M5, apresentando um comportamento assintótico nos modelos subsequentes, não sendo observado o mesmo comportamento na validação. Tendo novamente a utilização do Atlântico Tropical Sul e Dipolo do Atlântico Tropical como os primeiros preditores, observou-se um comportamento assintótico no treinamento.

Observando a Figura 13, tem-se que para o preditor MAM, a etapa de treinamento apresentou os maiores valores de correlação e NASH (com máximo de 0,618 no M12 e 0,377 no M11, respectivamente). No caso da validação, teve a máxima correlação de 0,204 no M1, além de ter valores negativos de NASH, indicando que a média observada é um melhor preditor que as saídas do modelo neste caso. O gráfico da etapa de treinamento sempre aumentou a correlação com o acréscimo de preditores, com exceção do M8; já na validação, teve grandes oscilações, mas em sua maioria foi decrescente. Ademais, percebe-se que não tendo a utilização do Dipolo do Atlântico Tropical como uma das variáveis mais importante, o gráfico do treinamento não teve um comportamento assintótico.

A etapa de treinamento apresentou os maiores valores de correlação e NASH para o preditor DJF, sendo o máximo de 0,556 e 0,300 respectivamente, no M12, sendo possível perceber na Figura 14. Assim como no caso anterior, a validação apresentou baixos valores de correlação (sendo o maior de 0,208 no M3) quando comparado ao treinamento e valores negativos de NASH (com mínimo de -0,355 no M12). O gráfico de treinamento tem uma maior taxa de crescimento até o M3, tendo um comportamento mais assintótico nos modelos seguintes,

não sendo observado o mesmo comportamento no caso do NASH. Além disso, tendo novamente a utilização do Dipolo do Atlântico como uma das variáveis mais importantes, o gráfico do treinamento teve um comportamento assintótico, porém apenas quando foi empregado o Dipolo do Atlântico Tropical e Atlântico Tropical Sul nas primeiras posições é que teve melhores valores de correlação e resultados positivos de NASH.

Por fim, tem-se que a correlação da precipitação observada com a precipitação obtida pelas Redes Neurais Artificiais foi maior utilizando o preditor de um trimestre de antecedência (SON), tanto na etapa de validação quanto no treinamento, tendo ocorrido o mesmo caso com o NASH, sendo possível observar na Tabela 5 e 6, onde 1º, 2º e 3º significa os modelos com os maiores resultados, com exceção dos dois últimos preditores do NASH, visto que os valores são negativos, sendo organizados com os menores resultados.

Tabela 5 - Três maiores correlações da precipitação de DJFMAM com os preditores analisados.

Preditor	Treinamento						Validação					
	1º		2º		3º		1º		2º		3º	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,606	12	0,600	11	0,600	10	0,738	3	0,667	4	0,643	9
JJA	0,559	12	0,558	10	0,557	11	0,630	7	0,608	3	0,606	4
MAM	0,618	12	0,616	11	0,569	10	0,204	1	0,195	3	0,186	11
DJF	0,556	12	0,525	11	0,523	9	0,208	3	0,185	5	0,162	4

Fonte: Aatoria própria (2019).

Tabela 6 - Três maiores valores de NASH da precipitação de DJFMAM com os preditores analisados.

Preditor	Treinamento						Validação					
	1º		2º		3º		1º		2º		3º	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,362	12	0,359	10	0,358	9	0,364	4	0,351	8	0,345	12
JJA	0,310	10	0,305	11	0,294	12	0,261	12	0,254	3	0,252	7
MAM	0,377	11	0,375	12	0,322	10	-0,244	8	-0,208	10	-0,204	6
DJF	0,300	12	0,274	11	0,266	7	-0,355	12	-0,336	11	0,330	8

Fonte: Aatoria própria (2019).

A etapa de validação apresentou melhores resultados apenas nos preditores com menor antecedência (SON e JJA), apresentando para o preditores finais (MAM e DJF) baixas correlações e valores negativos de NASH. Por fim, a etapa de treinamento teve os melhores resultados nos três últimos modelos, isto é, os modelos com maiores quantidade de índices agregados, enquanto a validação apresentou maior variação dos modelos que apresentavam melhor desempenho, porém os últimos modelos dificilmente apareceram entre os melhores.


4.2 Previsão da precipitação para a quadra chuvosa

Para a previsão da precipitação para a quadra chuvosa (FMAM), analisou-se como preditores índices climáticos de quatro trimestres imediatamente anteriores.

4.2.1 Análise dos preditores através do *Random Forest*


Para os índices analisados, foi realizado com 50 *sets* de treino/teste, além de que a mediana da medida de importância para cada variável foi tomada para classifica-las, possibilitando que sejam organizados por ordem de importância. As Figuras 15, 16, 17 e 18 representam o *boxplot* obtido pelo modelo RF para a média das anomalias de TSM de SON, JJA, MAM e DJF, respectivamente. Salienta-se que o símbolo \circ é referente aos *outliers*.

Figura 15 - *Boxplot* para os índices analisados no período de SON.




Fonte: Autoria própria (2019).

Figura 16 - *Boxplot* para os índices analisados no período de JJA




Fonte: Autoria própria (2019).

Figura 17 - *Boxplot* para os índices analisados no período de MAM



Fonte: Autoria própria (2019).

Figura 18 - *Boxplot* para os índices analisados no período de DJF



Fonte: Autoria própria (2019).

Pela Figura 15, nota-se que para o preditor SON, o Dipolo do Atlântico Tropical foi classificado como a variável mais importante, seguida do Oscilação Multidecadal do Atlântico e Niño Oceânico. O Niño 1+2 teve importância próxima a zero, porém ainda com valor negativo, evidenciando que este índice possui menor importância para a previsão da precipitação.

Baseado na Figura 16, observa-se que para o preditor JJA, a Oscilação Multidecadal do Atlântico e o Dipolo do Atlântico Tropical novamente foram classificados como as variáveis mais importantes, mudando apenas a posição entre eles, seguidos do Atlântico Tropical Sul e Norte. Este foi o caso do período preditivo de FMAM que teve a maior ocorrência de variáveis com mediana negativa, com o total de seis índices: Niño 1+2, Niño 3.4, ENSO Multivariado, Oscilação do Atlântico Norte, Niño 4 e Oscilação Decadal do Pacífico.


Para o preditor MAM, percebe-se que o Atlântico Tropical Sul novamente foi classificado como uma das variáveis mais importante, tendo desempenho inferior apenas ao Niño 3, sendo possível observar na Figura 17. O Niño Oceânico teve importância próxima a zero, tendo performance inferior apenas a Oscilação Decadal do Atlântico e do Pacífico.

Por fim, tem-se que pela Figura 18 que para o período DJF, o Dipolo do Atlântico Tropical e a Oscilação Multidecadal do Atlântico outra vez foram classificados como os índices mais importantes. O Niño oceânico mais uma vez está entre as variáveis de menor importância, sendo o único com mediana negativa e, conseqüentemente, sendo identificado como a variável menos relevante.

4.2.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais


Nas Figuras 19, 20, 21 e 22 é exposta a correlação e o NASH da precipitação observada da quadra chuvosa com relação a precipitação obtida pelo modelo RNA, utilizando os índices TSM dos períodos de SON, JJA, MAM e DJF.

Figura 19 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON




Fonte: Autoria própria (2019).

Figura 20 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA




Fonte: Autoria própria (2019).

Figura 21 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM



Fonte: Autoria própria (2019).

Figura 22 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF



Fonte: Autoria própria (2019).

Analisando a Figura 19, tem-se que a validação para o preditor SON, obteve os melhores resultados no Modelo 1 (M1) ao Modelo 4 (M4) e no Modelo 10 e 11, sendo o maior valor de 0,627 no Modelo 4 (M4), onde Dipolo do Atlântico Tropical, Oscilação Multidecadal do Atlântico, Oscilação do Atlântico Norte e Atlântico Tropical Norte foram utilizados como preditores, no caso do treinamento o maior valor foi de 0,603 no Modelo 10 (M10). O gráfico da correlação no treinamento é crescente até o M5, tendo um comportamento assintótico nos modelos seguintes, já no caso da validação, apresenta grandes oscilações, em que possui intervalos que é crescente e em outros são decrescentes.

O NASH para este mesmo preditor teve os melhores valores no treinamento, onde o maior valor foi de 0,361 no M10, enquanto que na etapa de validação o máximo foi de 0,300 no M10. O comportamento do gráfico do NASH na etapa de treinamento é equivalente ao caso da correlação, enquanto que na validação ocorre algumas oscilações, mas é predominantemente crescente. Logo, é notável que tendo a utilização de pouco preditores já teve bons resultados quando comparado com os modelos com mais preditores agregados.

A partir da Figura 20, nota-se que para o preditor JJA a etapa de validação apresentou os maiores valores de correlação (com máximo de 0,724 no M2), enquanto que o

maior resultado para o treinamento foi de 0,558 no M12, com relação ao NASH, os maiores valores na etapa de treinamento, sendo as exceções o M2 e M3, com o máximo de 0,302 no M11, no caso da validação, o máximo é de 0,240 no M12. Além disso, tanto na correlação quanto no NASH, a etapa de treinamento foi crescente até o M5, apresentando um comportamento assintótico nos modelos subsequentes, não sendo observado o mesmo comportamento na validação. Assim, evidencia-se que tendo novamente a utilização da Oscilação Multidecadal do Atlântico e o Dipolo do Atlântico Tropical como os primeiros preditores teve um percurso em que o gráfico no treinamento exibiu um comportamento assintótico.

O treinamento apresentou os maiores valores de correlação e NASH para o preditor MAM (com máximo de 0,631 e 0,393 no M12, respectivamente), sendo possível observar na Figura 21. No caso da validação, teve a máxima correlação de 0,227 no M11, além de ter valores negativos de NASH, com o mínimo de -0,297 no M7. Nota-se no gráfico do treinamento que aumentou a correlação com o acréscimo de preditores, enquanto no caso do NASH só teve características crescentes a partir do M7. Ademais, tem-se que não tendo a utilização do Oscilação Multidecadal do Atlântico e o Dipolo do Atlântico Tropical como as variáveis mais importante, o gráfico do treinamento não teve um comportamento assintótico.

Com base na Figura 22, observa-se que no treinamento obteve os melhores valores de correlação e NASH para o período DJF, com máximo de 0,447 no M12 para a correlação e 0,224 para o M12. Em relação a validação, o maior valor de correlação foi de 0,261 no M8, já no caso do NASH, os resultados foram negativos, com mínimo de -0,218 no M12. O gráfico da etapa de treinamento foi sempre crescente, enquanto que na etapa de validação fora predominantemente constante até o M8, tendo um comportamento decrescente nos modelos subsequentes.

Por fim, no treinamento a correlação e o NASH da precipitação observada com a precipitação obtida pela RNA foram maiores utilizando o preditor do terceiro trimestre de antecedência (MAM), sendo possível observar na Tabela 7 e 8, onde 1º, 2º e 3º significa os modelos com os maiores resultados, com exceção do último preditor do NASH, visto que os valores são negativos, sendo organizados assim com os menores resultados.

A etapa de validação possui os maiores valores de correlação, tendo melhores valores de correlação com o preditor JJA. Em todos casos do NASH a etapa de treinamento teve um melhor desempenho, sendo o maior com o preditor MAM. Ademais, a etapa de treinamento teve os melhores resultados nos três últimos modelos, isto é, os modelos com

maiores quantidade de índices agregados, enquanto a validação apresentou maior variação dos modelos que apresentavam melhor desempenho.

Tabela 7 - Três maiores correlações da precipitação de FMAM com os preditores analisados

Preditores	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,603	10	0,603	12	0,599	9	0,627	4	0,620	3	0,609	10
JJA	0,558	12	0,554	11	0,532	10	0,724	2	0,689	3	0,679	4
MAM	0,631	12	0,605	11	0,586	10	0,227	11	0,191	9	0,186	10
DJF	0,447	12	0,463	11	0,441	10	0,261	8	0,250	9	0,243	2

Fonte: Autoria própria (2019).

Tabela 8 - Três maiores valores de NASH da precipitação de FMAM com os preditores analisados

Preditores	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,361	10	0,358	9	0,354	11	0,300	10	0,291	12	0,279	11
JJA	0,302	11	0,283	12	0,281	10	0,240	12	0,239	10	0,239	3
MAM	0,393	12	0,363	11	0,340	10	0,297	7	0,297	5	0,293	6
DJF	0,224	12	0,211	11	0,193	10	-0,218	12	-0,136	11	-0,074	10

Fonte: Autoria própria (2019).

4.3 Previsão da precipitação para o trimestre de dezembro a fevereiro


Para a previsão da precipitação de dezembro a fevereiro (DJF), analisou-se como preditores índices climáticos de quatro trimestres imediatamente anteriores.

4.3.1 Análise dos preditores através do Random Forest

Para os índices analisados, foi realizado com 50 *sets* de treino/teste, além de que a mediana da medida de importância para cada variável foi tomada para classifica-las, possibilitando que sejam organizados por ordem de importância.


As Figuras 23, 24, 25 e 26 representam o *boxplot* obtido pelo modelo RF para a média das anomalias de TSM de setembro a novembro (SON), junho a agosto (JJA), março a maio (MAM) e de dezembro a fevereiro (DJF), respectivamente. Salienta-se que o símbolo \circ é referente aos *outliers*.

Figura 23 - *Boxplot* para os índices analisados no período de SON




Fonte: Autoria própria (2019).

Figura 24 - *Boxplot* para os índices analisados no período de JJA




Fonte: Autoria própria (2019).

Figura 25 - *Boxplot* para os índices analisados no período de MAM



Fonte: Autoria própria (2019).

Figura 26 - *Boxplot* para os índices analisados no período de DJF



Fonte: Autoria própria (2019).

Com base na Figura 23, tem-se que para o preditor SON o Atlântico Tropical Sul foi classificado como a variável mais importante, seguida do Dipolo do Atlântico Tropical e da Oscilação do Atlântico Norte. Apenas a Oscilação Decadal do Pacífico teve resultados negativos, sendo classificado assim como a variável menos importante.

A partir da Figura 24, nota-se que para o trimestre JJA o Atlântico Tropical Sul e o Dipolo do Atlântico Tropical novamente foram classificados como as variáveis de maior importância, seguido do ENSO Multivariado. O Atlântico Tropical Norte apresentou importância próxima a zero, tendo desempenho inferior apenas a Oscilação Multidecadal do Atlântico e Oscilação do Atlântico Norte, que obtiveram resultados negativos.


Verificando a Figura 25, percebe-se que com o preditor MAM o Atlântico Tropical Sul foi pela terceira vez seguida qualificada como uma das variáveis mais importantes, seguida do Niño 3.4 e do ENSO Multivariado. O único índice a apresentar valores negativos foi o Niño 1.2, sendo identificado como a variável de menor importância.

O Dipolo do Atlântico Tropical que esteve entre as variáveis menos importante nos casos anteriores, para o último preditor (DJF) foi identificado como o índice de maior importância, seguido do Niño 4 e do ENSO Multivariado (classificado pela terceira vez seguida entre as três variáveis mais importantes), sendo possível perceber na Figura 26. Este foi o caso do período preditivo de DJF que teve a maior ocorrência de índices com importância negativa, com destaque especial para o Atlântico Tropical Sul, que obteve mediana negativa, mesmo que nos casos anteriores tenha sido classificado como uma das variáveis mais importantes. Além disso, o Atlântico Tropical Norte, Dipolo do Atlântico Tropical, Oscilação do Atlântico Norte também obtiveram resultados negativos.

4.3.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais


Nas Figuras 27, 28, 29 e 30 é exposta a correlação e o NASH da precipitação observada de DJF com relação a precipitação obtida pelo modelo RNA, utilizando os índices climáticos dos períodos de SON, JJA, MAM e DJF.

Figura 27 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON




Fonte: Autoria própria (2019).

Figura 28 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA



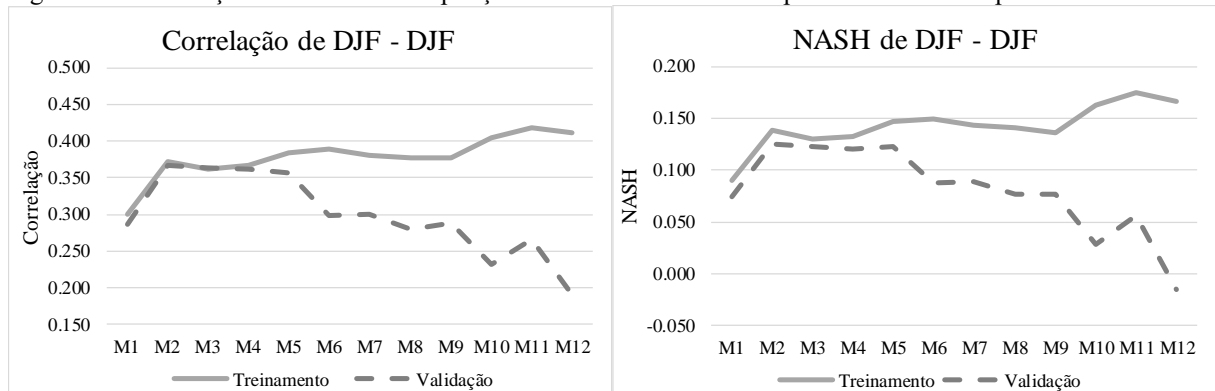
Fonte: Autoria própria (2019).

Figura 29 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM



Fonte: Autoria própria (2019).

Figura 30 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor DJF



Fonte: A autoria própria (2019).

Com base na Figura 27, tem-se que para o preditor SON, a etapa de treinamento apresentou os maiores valores de correlação nos Modelos 4 (M4) ao Modelo 9 (M9), onde o maior foi de 0,561 no Modelo 11 (M11), já a etapa de validação apresentou os maiores valores nos extremos, isto é, quando era utilizado poucos preditores ou todos os preditores, onde o máximo foi de 0,642 no Modelo 1 (M1). Além disso, na etapa de treinamento o gráfico foi predominantemente crescente, enquanto que na etapa de validação o gráfico se aproximou de uma curva côncava. Desta vez, percebe-se que tendo apenas a utilização do Atlântico Tropical Sul o modelo já apresentou o melhor valor de correlação.

Para o NASH deste mesmo período, tem-se que a etapa de treinamento exibiu os maiores valores de NASH no M3 ao M9, com o máximo de 0,312 no M11, já na validação o maior resultado foi de 0,360. Assim como no caso da correlação, o gráfico do NASH na etapa de treinamento foi majoritariamente crescente, enquanto na validação acercou a uma curva côncava.

Conforme a Figura 28, a validação teve os maiores valores de correlação e NASH para o preditor JJA, com máximo de 0,692 no M5 para a correlação e 0,420 no M5 para o NASH. No caso do treinamento, o maior valor da correlação foi de 0,448 no M12 e para o NASH foi de 0,200 no M12. Enquanto o gráfico do treinamento foi levemente crescente, o da validação foi crescente até o M5, tendo uma tendência decrescente nos modelos subsequentes.

A validação apresentou os maiores valores de correlação e NASH para o preditor MAM, com máximo de 0,652 no M2 para a correlação e 0,245 no M3, sendo possível observar na Figura 29. Com relação ao treinamento, o máximo foi de 0,341 e 0,115 no M12 para a correlação e NASH, respectivamente. O gráfico do treinamento foi predominantemente crescente, enquanto o da validação foi aproximadamente constante até o M5 e após isso, teve uma tendência mais decrescente. Além disso, percebe-se tendo a utilização do Atlântico Tropical Sul a validação possui melhores resultados que o treinamento.

Por último, o treinamento teve os melhores resultados de correlação e NASH para o período DJF, sendo o máximo da correlação e NASH de 0,419 no M11, respectivamente. Em relação ao treinamento, o máximo foi de 0,341 e 0,115 no M12 para a correlação e NASH, respectivamente. Em relação a validação, o maior valor da correlação 0,367 e 0,126 para o NASH, sendo ambos no M2. A etapa de treinamento sempre aumentou a correlação com o acréscimo de preditores, enquanto que na etapa de validação aumentou até o M2, após isso, variou constantemente com a inserção de um preditor, mas com linha de tendência negativa. Ademais, nota-se que não tendo a utilização do Atlântico Tropical Sul o treinamento teve melhores resultados que a validação, além de que para este período preditivo, o treinamento não apresentou um comportamento assintótico em nenhum dos casos analisados.

Por fim, no treinamento, a correlação da precipitação observada com a precipitação obtida pelas redes neurais artificiais foi maior utilizando o preditor de um trimestre de antecedência (SON), tendo ocorrido o mesmo caso com o NASH, sendo possível observar na Tabela 9 e 10, onde 1º, 2º e 3º significa os modelos com os maiores resultados. Vale salientar que para este período preditivo, o NASH não apresentou resultados negativos em nenhum dos quatro preditores.

Tabela 9 - Três maiores correlações da precipitação de DJF com os preditores analisados

Preditor	Treinamento						Validação					
	1º		2º		3º		1º		2º		3º	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,561	11	0,559	12	0,548	10	0,642	1	0,636	2	0,611	11
JJA	0,448	12	0,428	10	0,427	11	0,692	5	0,686	6	0,685	7
MAM	0,341	12	0,316	11	0,315	10	0,652	2	0,647	3	0,645	4
DJF	0,419	11	0,412	12	0,404	10	0,367	2	0,363	3	0,361	4

Fonte: Autoria própria (2019).

Tabela 10 - Três valores de NASH da precipitação de DJF com todos os preditores analisados

Preditor	Treinamento						Validação					
	1º		2º		3º		1º		2º		3º	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,312	11	0,312	12	0,299	10	0,360	1	0,336	10	0,334	12
JJA	0,200	12	0,182	10	0,181	11	0,420	5	0,411	7	0,409	6
MAM	0,115	12	0,100	11	0,099	10	0,245	3	0,239	2	0,231	4
DJF	0,175	11	0,166	12	0,163	10	0,126	2	0,123	3	0,123	5

Fonte: Autoria própria (2019).

A etapa de validação possui os maiores valores de correlação e NASH, onde o trimestre JJA como preditor obteve os melhores resultados. Apenas no último preditor que o treinamento teve resultados melhores que a validação. Ademais, a etapa de treinamento teve os

melhores resultados nos três últimos modelos, isto é, os modelos com maiores quantidade de índices agregados, enquanto a validação apresentou maior variação dos modelos que apresentavam melhor desempenho.


4.4 Previsão da precipitação para o trimestre de dezembro a fevereiro

Para a previsão da precipitação de dezembro a maio (MAM), examinou-se como preditores índices climáticos de quatro trimestres imediatamente anteriores.

4.4.1 Análise dos preditores através do Random Forest


As Figuras 31, 32, 33 e 34 representam o *boxplot* obtido pelo modelo RF para a média das anomalias de TSM de DJF, SON e MAM, respectivamente.

Figura 31 - *Boxplot* para os índices analisados no período de DJF




Fonte: Autoria própria (2019).

Figura 32 - *Boxplot* para os índices analisados no período de SON




Fonte: Autoria própria (2019).

Figura 33 - *Boxplot* para os índices analisados no período de JJA



Fonte: Autoria própria (2019).

Figura 34 - *Boxplot* para os índices analisados no período de MAM



Fonte: Autoria própria (2019).

Conforme a Figura 31, tem-se que para o preditor de DJF o Dipolo do Atlântico Tropical foi classificado como a variável mais importante, seguida do Niño 1+2 e ENSO Multivariado. A Oscilação do Atlântico Norte teve mediana negativa para este modelo, indicando que possui menor importância para a previsão da precipitação.

A partir da Figura 32, observa-se que para o preditor SON, o Dipolo do Atlântico Tropical novamente foi classificado como a variável de maior importância, seguido da Oscilação Multidecadal do Pacífico e Niño 3. O Niño 1+2 que foi classificado no caso anterior como uma das variáveis mais importantes, obteve resultados negativos para este preditor, tendo desempenho inferior apenas do Atlântico Tropical Sul.

O Atlântico Tropical Sul e o Niño 1+2 que no caso anterior foram identificados como as variáveis menos importantes, desta vez foram classificados como os índices mais


importantes com o preditor de JJA, conforme Figura 33. Ademais, essa foi a situação em que teve a maior ocorrência de índices TSM com importância negativa, sendo um total de 7 variáveis: Atlântico Tropical Norte, ENSO multivariado, Oscilação do Atlântico Norte, Niño 3.4, Niño Oceânico, Niño 4 e a Oscilação Decadal do Pacífico.

Com base na Figura 34, nota-se que para o preditor MAM, o Atlântico Tropical Sul e Niño 1+2 novamente foram classificados como as variáveis mais importantes, seguido do Niño 3. A Oscilação Decadal do Pacífico teve importância próxima de zero, tendo desempenho inferior apenas ao Niño Oceânico, Niño 4 e o Dipolo do Atlântico Tropical, que outra vez obtiveram mediana negativa.

4.4.2 Análise dos resultados obtidos pelas Redes Neurais Artificiais


Nas Figuras 35, 36, 37 e 38 é exposto a correlação e o NASH da precipitação observada de MAM com relação a precipitação obtida pelo modelo RNA, utilizando os índices climáticos dos períodos de DJF, SON, JJA e MAM.

Figura 35 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM



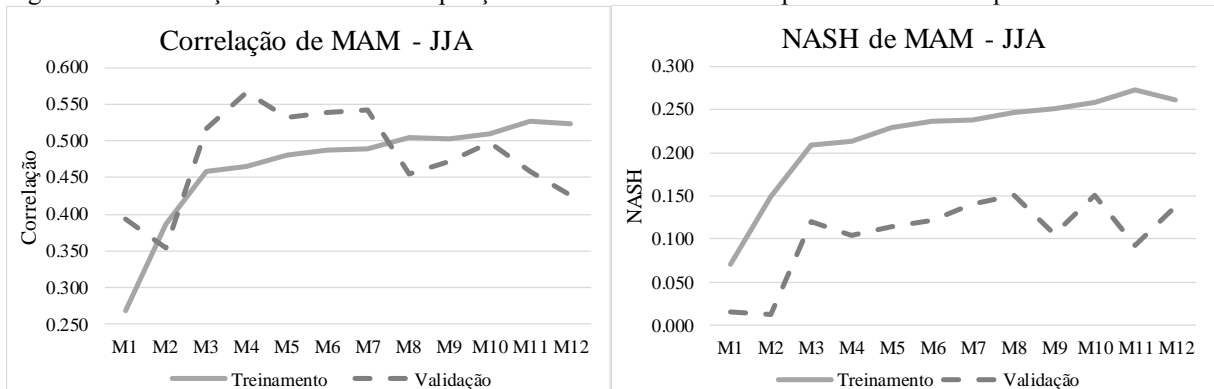
Fonte: Autoria própria (2019).

Figura 36 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor SON




Fonte: Autoria própria (2019).

Figura 37 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor JJA



Fonte: Autoria própria (2019).

Figura 38 - Correlação e NASH da Precipitação observada com a obtida pelo modelo com o preditor MAM



Fonte: Autoria própria (2019).

Conforme a Figura 35, a etapa de validação obteve os melhores resultados de correlação para o preditor DJF, com o máximo de 0,823 no Modelo 9 (M9), enquanto que no treinamento o maior foi de 0,740 no Modelo 12 (M12). Tanto no treinamento quanto na validação o gráfico foi crescente até o M2, tendo um comportamento assintótico nos modelos seguintes. O NASH para este mesmo caso foi negativo no primeiro modelo da etapa de validação, porém nos modelos subsequentes teve os maiores valores, com máximo de 0,663 no M9. O comportamento do gráfico do NASH e correlação é análogo ao caso da correlação.

A validação sempre teve os maiores de correlação, sendo o pico de 0,695 no M4, já no treinamento o máximo foi de 0,567 no M10, com relação ao NASH, o treinamento teve os maiores resultados, com o máximo de 0,319 no M10, enquanto na validação o maior valor foi de 0,310 no M10, sendo possível observar na Figura 36. O gráfico do treinamento é crescente até o M5, se assemelhando a uma assíntota nos modelos subsequentes, enquanto na validação apresenta grande variância nos valores até o M4, tendo um comportamento mais constante nos modelos seguintes. Além disso, percebe-se que tendo novamente a utilização do Dipolo do Atlântico Tropical como uma das variáveis mais importantes, o gráfico do treinamento não teve um comportamento assintótico.

Com base na Figura 37, tem-se que para o preditor JJA a etapa de treinamento teve os maiores valores de correlação no M2 e do M8 ao M12, com o máximo de 0,527 no M11, já para a validação, que teve os melhores resultados no geral, teve o ápice de 0,567 M4. Com relação ao NASH, os melhores resultados ocorreram no treinamento, com maior valor de 0,273 no M11, já no caso da validação, o máximo foi de 0,150 no M10. O gráfico do treinamento é crescente até o M3, tendo um comportamento assintótico após este modelo, não sendo observado o mesmo comportamento na validação.

Observando a Figura 38, tem-se que para o preditor MAM, o treinamento apresentou os maiores valores de correlação e NASH, com máximo de 0,609 e 0,368 no M11, respectivamente. No caso da validação, teve a correlação variou de 0,032 no M12 para -0,059 no M10, enquanto que na etapa de validação o NASH apresentou valores negativos, com mínimo de -0,424 no M10. A etapa de treinamento sempre aumentou a correlação com o acréscimo de preditores, com exceção do modelo 10 e 12; já na validação, teve poucas oscilações com valores próximos a zero para a correlação e para o NASH é aproximadamente constante até o M5 e decrescente nos modelos seguintes. Ademais, este foi o único caso com o período preditivo que o gráfico do treinamento não teve um comportamento assintótico.

Por fim, no treinamento e na validação a correlação da precipitação observada com a precipitação obtida pelo RNA foi maior utilizando o preditor de um trimestre de antecedência (DJF), tendo ocorrido o mesmo caso com o NASH, sendo possível observar na Tabela 11 e 12, onde 1º, 2º e 3º significa os modelos com os maiores resultados, com exceção do último preditor do NASH, visto que os valores são negativos, sendo organizados com os menores resultados.

Tabela 11 - Três maiores correlações da precipitação de MAM com todos os preditores analisados

Preditor	Treinamento						Validação					
	1º		2º		3º		1º		2º		3º	
	R	M	R	M	R	M	R	M	R	M	R	M
DJF	0,740	12	0,739	11	0,737	8	0,823	9	0,815	10	0,814	11
SON	0,567	10	0,567	12	0,563	11	0,695	4	0,663	10	0,654	9
JJA	0,527	11	0,523	12	0,509	10	0,567	4	0,542	7	0,539	6
MAM	0,609	11	0,608	12	0,554	9	-0,059	10	-0,051	9	-0,037	4

Fonte: Autoria própria (2019).

Tabela 12 - Três valores de NASH da precipitação de MAM com todos os preditores analisados

Preditores	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
DJF	0,545	12	0,543	10	0,540	8	0,663	9	0,656	10	0,654	11
SON	0,319	10	0,314	11	0,314	12	0,310	10	0,292	4	0,286	9
JJA	0,273	11	0,261	12	0,259	10	0,150	10	0,150	8	0,141	7
MAM	0,368	11	0,367	12	0,303	10	-0,424	10	-0,423	9	-0,401	11

Fonte: Autoria própria (2019).

A etapa de validação possui os maiores valores de correlação e NASH, apenas no último preditor que o treinamento teve resultados melhores que a validação, no caso do penúltimo preditor (JJA), a etapa de treinamento teve um melhor desempenho quando analisado pelo NASH. Ademais, a etapa de treinamento teve os melhores resultados nos três últimos modelos, isto é, o modelo 10, 11 e 12, enquanto a validação apresentou maior variação dos modelos que apresentavam melhor desempenho, porém o modelo 10 teve grande recorrência entre os modelos com melhor performance.

4.5 Síntese dos resultados

Na Tabela 13 é possível observar os maiores valores de correlação e NASH, com seu respectivo preditor, para cada período preditivo que foi analisado. Sendo possível o observar o período de MAM obteve os maiores resultados.


Tabela 13 - Maiores valores de correlação e NASH

Período preditivo	Correlação			NASH		
	Preditores	Valor	Etapa	Preditores	Valor	Etapa
DJFMAM	SON	0,738	Trein.	MAM	0,377	Trein.
FMAM	JJA	0,724	Valid.	MAM	0,393	Trein.
DJF	JJA	0,692	Valid.	JJA	0,420	Valid.
MAM	DJF	0,823	Valid.	DJF	0,663	Valid.

Fonte: Autoria própria (2019).

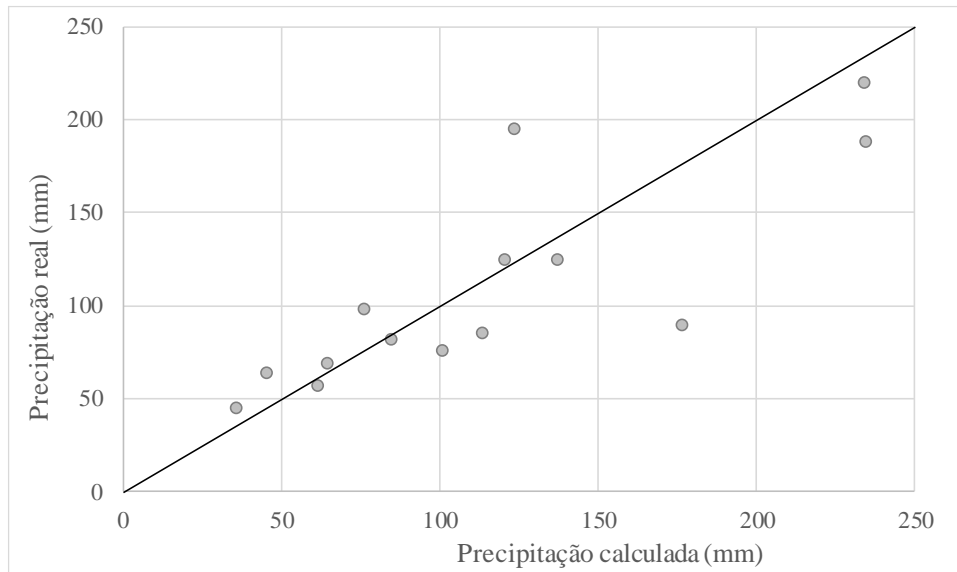
Como o período preditivo de MAM com o preditor de DJF obteve os melhores resultados, é exposto nas Figuras 39 e 40 uma comparação entre precipitação real e os resultados da precipitação neste período, para a etapa de treinamento e validação, respectivamente. Diante disso, é possível perceber que para a precipitação real no treinamento é em grande maioria maior que a precipitação calculada. Já para a precipitação calculada na validação, observa-se que além de apresentar, uma correlação satisfatória entre os valores calculados pela rede e os valores desejados, o modelo apresenta um bom desempenho, tendo apenas a presença de alguns *outliers*.

Figura 39 - Comparação entre a precipitação calculada no treinamento a precipitação observada



Fonte: Autoria própria (2019).

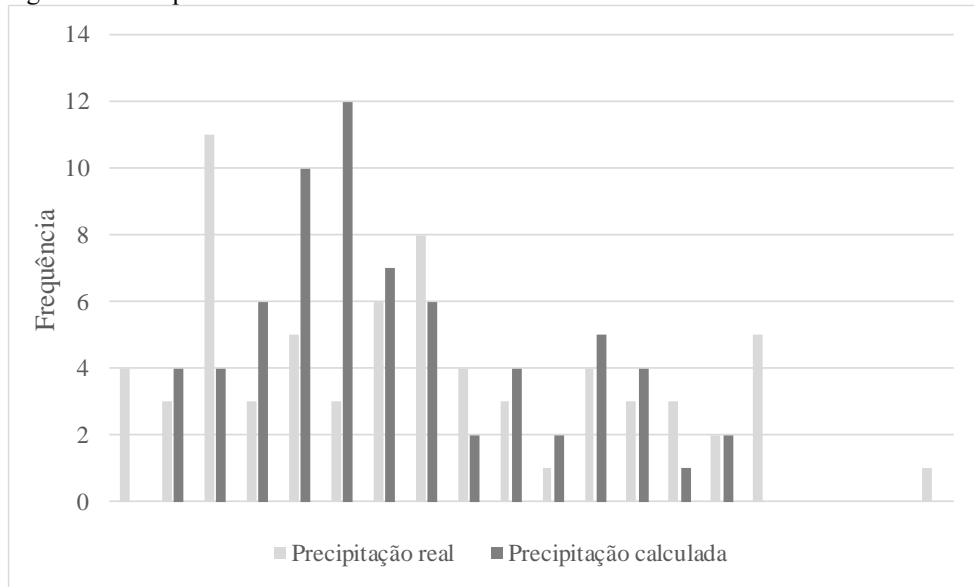
Figura 40 - Comparação entre a precipitação calculada na validação a precipitação observada



Fonte: Autoria própria (2019).

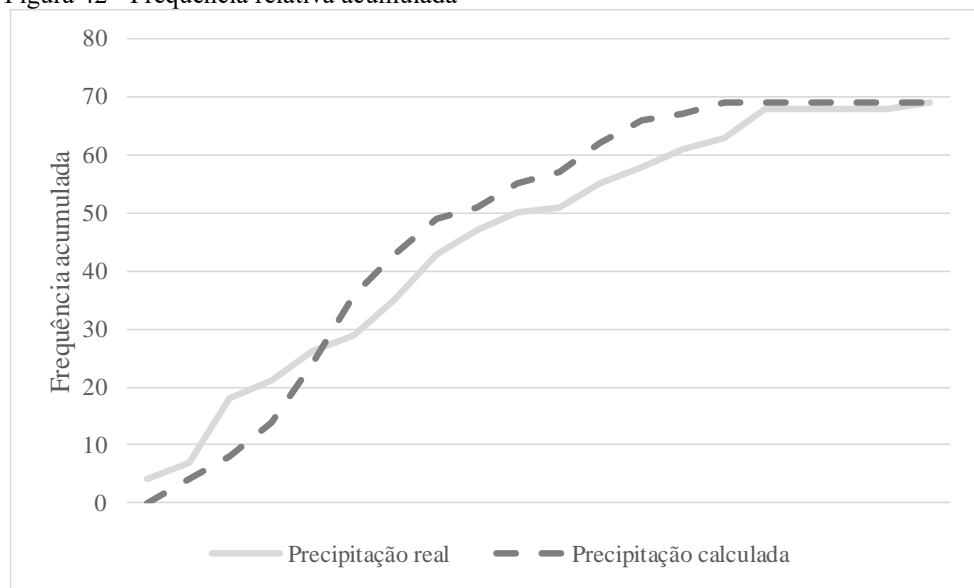
Por fim, tem-se que as Figuras 41 e 42 apresentam uma comparação entre a frequência relativa e frequência relativa acumulada da precipitação observada com a precipitação calculada do período preditivo de MAM com preditor DJF. Percebe-se que ambos os casos possuem frequências semelhantes, tendo maiores divergências entre a precipitação de 65 mm a 95 mm, onde teve uma maior recorrência da precipitação calculada.

Figura 41 - Frequência relativa



Fonte: Autoria própria (2019).

Figura 42 - Frequência relativa acumulada



Fonte: Autoria própria (2019).

5 CONCLUSÃO

Este trabalho apresentou uma metodologia para classificar os índices TSM (Temperatura de Superfície do Mar) que possuem maior influência no regime pluviométrico da região hidrográfica dos Sertões de Crateús, inicialmente a partir do *Random Forest* (RF) e em seguida, realizando a previsão do período de precipitação usando Redes Neurais Artificiais (RNA) a partir de uma série histórica de 67 de dados hidrometeorológicos.

O Atlântico Tropical Sul foi o índice classificado mais vezes como a variável mais importante pelo RF, tendo um total de 7 vezes das 16 possíveis, que corresponde a 43,75% dos casos. O Dipolo do Atlântico Tropical ficou em segundo lugar no critério de ser qualificado como a variável mais importante, com total de 5 vezes, equivalendo a 31,25% dos casos. Em vista disso, percebe-se que as anomalias de TSM que envolvem o dipolo do atlântico foram classificados como os mais importantes em 75% das situações analisadas e em apenas um dos casos (período preditivo de DJF e preditor DJF, com lag 1) não esteve entre as três variáveis mais importantes. Ademais, salienta-se que o Atlântico Tropical Norte foi a única variável que nunca esteve entre os três índices mais importantes.

A Oscilação do Atlântico Norte foi classificado mais vezes como a variável menos importante, com total de 6 vezes, correspondendo a 37,50%, além de estar entre os três índices menos importante em 56,25% dos casos. A Oscilação Decadal do Pacífico ficou em segundo lugar, ficando 4 vezes como a variável menos importante, totalizando 25,00%.

Com relação a previsão climática, tem-se que para o período preditivo de DJFMAM a maior correlação foi de 0,738 ocorrendo na etapa de treinamento onde SON foi utilizado como preditor e o maior valor de NASH foi 0,377, onde o preditor foi o período de MAM, tendo ocorrido na etapa de treinamento. Para a precipitação da quadra chuvosa (FMAM) a maior correlação foi de 0,724 (com preditor JJA) e NASH de 0,393 (com preditor MAM), tendo acontecido na etapa de validação e treinamento, respectivamente.

Já para a precipitação do período DJF a maior correlação foi de 0,692 e NASH de 0,420, em que o predito foi JJA, tendo ambos ocorrido na validação. Para o período preditivo de MAM o máximo valor de correlação e NASH foi de 0,823 e 0,663, onde DJF foi utilizado como preditor, além de que ambos aconteceram na etapa de validação.

Além disso, na etapa de validação foi observado que os modelos com maiores quantidades de índices agregados possuem maiores valores de correlação e NASH. Já para a etapa de validação, teve uma maior variabilidade dos modelos que apresentaram melhores resultados, porém os modelos com menos índices agregados tiveram uma maior recorrência.

Considerando o tamanho da série histórica, os resultados podem ser considerados satisfatórios com relação ao caso da correlação, todavia o modelo obteve baixos valores de NASH. Dessa forma, com a finalidade de aprimorar os estudos da previsão da precipitação da região hidrográfica dos Sertões de Crateús, recomenda-se como trabalhos futuros:

- Comparação dos resultados obtidos utilizando RNA com outros modelos correntes (métodos estatísticos ou dinâmicos), para averiguar a eficiência do método apresentado neste trabalho;
- Analisar diferentes tipos de período preditivo de precipitação adotado neste trabalho, como a precipitação mensal;
- Realizar a previsão climática utilizando uma maior quantidade de neurônios, ou seja, até que o RNA apresente um comportamento assintótico para os 12 modelos utilizados;
- Comparar com outros modelos RNA, como o *Extreme Learning Machine* (ELM).

REFERÊNCIAS

- ALVES, B. C. C.; SOUZA FILHO, F. A. S.; SILVEIRA, C. S. Análise de Tendências e Padrões de Variação das Séries Históricas de Vazões do Operador Nacional do Sistema (ONS). **RBRH: Revista Brasileira de Recursos Hídricos**, v.18, n.4, p.19-34, 2013.
- ANDREOLI, R. V.; KAYANO, M. T. *Multi-scale variability of the sea surface temperature in the Tropical Atlantic*. In: **Journal Of Geophysical Research**, v.109, p. 1-12, 2004.
- ANJOS, S. L. **Ondaletas aplicadas à análise de variabilidade de baixa frequência em séries de afluência aos reservatórios hidrelétricos brasileiros**. Dissertação (Mestre) em Tecnologia Ambiental e Recursos Hídricos, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2015.
- ARAGÃO, J. O. R. **O Impacto do ENSO e do Dipolo do Atlântico no Nordeste do Brasil**. In: *Bull Inst. Fr. Études Andines*, v.27, n.3, p.839-844, 1998.
- ARAÚJO, C. B. C. **Aplicação das redes neurais artificiais do tipo Perceptron na estimativa de recalques em estacas**. Dissertação (Mestre) em Geotecnia, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2015.
- ARAÚJO, C. B. C. *et al.* **Previsão de vazões: Utilização de RNA**. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.
- ARAÚJO, C. B. C.; DANTAS NETO S. A. D.; SOUZA FILHO, F. A. S. Previsão de vazões para o açude Orós/CE a partir de dados hidrometeorológicos utilizando Perceptrons. **Revista Brasileira de Meteorologia**, v. 30, n. 1, 37 - 46, 2015.
- ARAÚJO, W. S. **Estudo da variabilidade hidrometeorológica no Nordeste do Brasil utilizando análise multivariada e espectral**. Tese (Doutor) em Meteorologia, Departamento de Ciências Atmosféricas, Universidade Federal de Campina Grande, 2013.
- ARAÚJO JÚNIOR, L. M. A.; SOUZA FILHO; F. A. S.; BARRETO, G A. **Previsão de vazão: Multi modelos**. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.
- BARREIRO, M., Díaz, N., RENOM, M. *Role of the global oceans and land-atmosphere interaction on summertime interdecadal variability over northern Argentina*. **ClimDyn**, 42, 1733-1753, 2014.
- BIRIKUNDAVYI, S.; LABIB, R.; TRUNG, H.T.; ROUSSELLE, J. *Performance of neural networks in daily streamflow forecasting*. **Journal of Hydrology**, v 7, n 5, p 392-398, 2002.
- BOWDEN, G.J., DANDY, G.C., MAIER, H.R. *Input determination for neural network models in water resources applications: Part I – background and methodology*. **Journal of Hydrology**, 301, 75-92, 2005.
- BRAVO, J. M. *et al.* Avaliação dos Benefícios de Previsão de Vazão na Operação de Reservatórios. **RBRH: Revista Brasileira de Recursos Hídricos**, v.13 n.1, p.197-213, 2008.

BREIMAN, L. *Random Forests. Machine Learning*. In: *Kluwer Academic Publishers*, v. 45, n. 1, p. 5-32, 2001.

BUSSAB, W. O.; MORETTIN, W. O. *Estatística Básica*. São Paulo: Saraiva. p. 50. 548 páginas, 2012.

CABRAL, S. L. Um complexo convectivo de mesoescala (ccm) associado à precipitação intensa sobre o Crato-CE. In: **XI Simpósio De Recursos Hídricos do Nordeste**, [S.l.], 2012.

CABRAL, S. L.; CAMPOS, J. N. **Intervalo de tempo de máxima previsibilidade no acoplamento de modelos climáticos e hidrológico**. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.

CAGECE. Operação de guerra: A batalha da equipe da Cagece em Crateús para operar a maior e mais complexa adutora do Ceará e abastecer uma cidade com 52 mil habitantes. **Revista Cagece**, [S.l.], 2017.

CARTON, J.A., CAO, X., GIESE, B.S., SILVA, A.M. *Decadal and interannual SST variability in the Tropical Atlantic Ocean*. **J Phys Oceanogr**, v.26 p.1165-1175, 1996.

CARVALHO, T. M. N. *Water demand modelling using machine learning techniques*. Dissertação (Mestre) em Recursos Hídricos, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2019.

CHARLES A. C.; NAMEN, A. A.; RODRIGUES, P. P. G. W. Comparação de modelos de mineração de dados aplicados a uma estação meteorológica de superfície. **RBRH - Revista Brasileira de Recursos Hídricos**, v. 22, e58, 2017.

COHEN, J.C.P., M.A.F. SILVA DIAS e NOBRE C.A. **Aspectos Climatológicos das Linhas de Instabilidade na Amazônia**. In: Boletim de Monitoramento e Análise Climática, v. 4, INPE/CPTEC, p. 34-40., 1989.

COUTINHO, M. D. L.; SAKAMOTO, M. S. Análise sinótica da intensa precipitação observada no litoral do Ceará em 7 de abril de 2016. In: **Geosp – Espaço e Tempo**, v. 21, n. 3, p. 858-871, 2017.

COSTA, J. A.; DA SILVA, D. F. Distribuição espaço-temporal do Índice de anomalia de chuva para o Estado do Ceará. **Revista Brasileira de Geografia Física**, v. 10 n. 04 p. 1002 – 1013, 2017.

COUTINHO, M. D. L. *et al.* Estudo de caso: Evento extremo no estado do Ceará entre os dias 03 e 04 de janeiro de 2015. **Revista Brasileira de Climatologia**, v. 20 n.13, 2017.

CRUZ, M. F. M.; RODRIGUES, L. D; VERSIANI, B. R. Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais. **RBRH - Revista Brasileira de Recursos Hídricos**, vol. 15, n.1, p. 121-132, 2010.

DA SILVA, D. F *et al.* Previsão Climática e de Ciclos Climáticos para o Estado do Ceará. **Revista Brasileira de Geografia Física**, p. 959-970, 2013.

DAWSON, C.W. *et al.* Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China. **Hydrol. and Earth System Sci.**, v 6, n 4, p. 619- 926, 2002.

DAWSON, C. W.; WILBY, R. L. *Hydrological Modelling Using Artificial Neural Network.* In: **Progress in Physical Geography.** v.25, p. 80-108, 2001.

DEBASTIANI, A. B.; SILVA, R. D.; DANTAS NETO, S. L. F. Eficácia da arquitetura MLP em modo closed-loop para simulação de um Sistema Hidrológico. **RBRH - Revista Brasileira de Recursos Hídricos**, v. 21, n. 4, p. 821-831, 2016.

EARTH SYSTEM RESEARCH LABORATORY. *Climate Indices: Monthly Atmospheric and Ocean Time-Series.* Broadway: ESRL, 2018.

ESTÁCIO, A. B. S; SOUZA FILHO, F. A. S.; ROCHA, R. V. **Análise da incerteza de modelo hidrológico com uso de otimização multiobjetivo e impacto na incerteza de oferta hídrica: estudo de caso do reservatório Orós.** In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.

FARIAS, P.; COELHO, C. A. S., SOUZA, C. R. **A habilidade do modelo de previsão climática sazonal do CPTEC em prever o padrão de teleconexão de precipitação de verão associado ao fenômeno El Niño-Oscilação Sul.** In: Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) - Instituto Nacional de Pesquisas Espaciais (INPE), 2006.

FERNADES, W. S.; SILVEIRA, C. S. **Regularização de vazão a longo prazo para o Nordeste Brasileiro.** In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.

FERNÁNDEZ-DELGADO, M. *et al.* Do we need hundreds of classifiers to solve real world classification problems. In: **Journal of Machine Learning Research**, v.15, n. 1, p. 3133-3181, 2014.

FERREIRA, F. F.; ALVES, J. M. B.; COSTA, A. A. Um estudo dos impactos das Temperaturas da Superfície do Mar (TSM) em macrorregiões, pluviométricamente homogêneas, no Estado do Ceará. **Revista Brasileira de Agrometeorologia**, v. 12, n. 1, p. 193-204, 2004.

FERREIRA, N. J.; CHAN, C. S.; SATYAMURTI, P. **Análise dos distúrbios ondulatórios de leste sobre o Oceano Atlântico Equatorial Sul.** In: Anais do Congresso Brasileiro de Meteorologia, 6, Rio de Janeiro, p. 462-466, 1990.

FIGUEIREDO, K. *et al.* Modelo de Previsão de Vazão com Informação de Precipitação Utilizando Redes Neurais. **RBRH - Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 69-82, 2007.

FERREIRA, A.G.; MELLO, N.G.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. 01, n. 01, p. 15-28, 2005.

GALVÃO, C. O. **Sistemas Inteligentes: Aplicações a Recursos Hídricos e Ciências Ambientais**. 1ª edição, Editora da Universidade (Universidade Federal do Rio Grande do Sul), Rio Grande do Sul, 1999.

FUNDAÇÃO CEARENSE DE METEOROLOGIA E RECURSOS HÍDRICOS. **Portal Hidrológico**. Fortaleza: FUNCEME, 2019.

GAN, M. A.; KOUSKY, V. E. **Um Estudo Observacional sobre as Baixas Frias da Alta Troposfera nas Latitudes Subtropicais do Atlântico Sul e Leste do Brasil**. In: INPE, São José dos Campos, SP. 25 págs, 1982.

GARCIA, S. C. **O uso de Árvores de Decisão na Descoberta de Conhecimento na área de Saúde**. Dissertação (Mestre) em Ciência da Computação, Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Computação, Porto Alegre, 2003.

GENUER, R.; POGGI, J.; TULEAU-MALOT, C. *Variable selection using Random forests*. *Pattern Recognition Letters*, v. 31, n. 14, p. 2225-2236, 2010.

GOMES, L. F. C.; MONTENEGRO, S. M. G.; VALENÇA, M. J. S. **Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco**. RBRH - Revista Brasileira de Recursos Hídricos, v. 15, n.1, p. 05-15, 2010.

GUARNIERI, R. A. **Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA**. Dissertação (Mestre) do Curso de Pós-Graduação em Meteorologia. INPE, São José dos Campos, 2006.

HASTENRATH, S.; HELLER, L. *Dynamics of climatic hazards in Northeast Brazil*. *Quartely*. In: *Journal Royal Meteorological Society*, v.103, n.435, p.77-92, 1977.

HAYKIN, S. **Redes Neurais Artificiais: Princípios e práticas**. 2ª edição, Editora Bookman, Porto Alegre, 2001.

HSU, K. L.; GUPTA, H. V.; SOROOSHIAN, S. *Artificial neural network modeling of the rainfall-runoff process*. *Water Resources Research*, v. 31, n. 10, p. 2517- 2530, 1995.

HURRELL, J. W. *Decadal trends in the North Atlantic Oscillation: regional temperatures and precipitation*. *Science*, v. 269, n. 5224, p. 676-679, 1995.

INSTITUTO DE PESQUISA E ESTRATÉGIA ECONÔMICA DO CEARÁ – IPECE. **Perfil Municipal 2017 Crateús**. Fortaleza: IPECE, 2018.

JAIN, A. *et al*. *Identification of physical processes inherent in artificial neural network rainfall runoff models*. *Hydrological Processes*, v. 18, n. 3, p. 571-581, 2004.

JAIN, A.; KUMAR, A. M. *Hybrid neural network models for hydrologic time series forecasting*. *Applied Soft Computing*, v. 7, n. 2, p. 585-592, 2007.

LABAT, D. *Wavelet analysis of the annual discharge records of the world's largest rivers*. *Advances in Water Resources*, 31, p. 109–117, 2008.

- LIAW, A.; WIENER, M. *Classification and Regression by randomForest*. **Rnews**, v. 2/3, p. 18-22, 2002.
- MANTUA, N. J. *A Pacific Interdecadal Climate Oscillation with Impacts on Salmon Production*. **Bulletin of the American Meteorological Society**, v.78, n.6, p. 1069- 1080, 1997.
- MARENGO, J. A. *et al. Assessment of regional seasonal rainfall predictability using the CPTEC/COLA atmospheric GCM*. **Climate Dynamics**, v. 21, p. 459–475, 2003.
- MARENGO, J. A., VALVERDE M. C. Caracterização do clima no Século XX e Cenário de Mudanças de clima para o Brasil no Século XXI usando os modelos do IPCC-AR4. **Revista Multiciência**, Campinas, n.8, 2007.
- MATOS A. B.; PEDROLLO, O. C.; CASTRO, N. M. Efeito do Controle de Montante de Sub-bacias Embutidas na Previsão Hidrológica de Curto Prazo com Redes Neurais: Aplicação à Bacia de Ponte Mística. **RBRH: Revista Brasileira de Recursos Hídricos**, 2014. v. 19, n.1, p. 87-99, 2014.
- MOLION, L. C. B.; BERNARDO, S. O. Uma revisão da dinâmica das chuvas no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 17, n. 1, p. 1-4, 2002.
- MORAES, D.; COUTINHO, M. Evento de precipitação intensa ocorrido nos dias 15 e 16 de abril de 2018 em Fortaleza-CE: Estudo de caso. **Revista Brasileira de Climatologia**, v. 25 n. 15, 2019.
- MORIASI, D. N. *et al. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations*. **American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 885-900, 2007.
- MOURA, A. D., SHUKLA, J. *On the dynamics of droughts in the Northeast Brazil: Observations, theory and numerical experiments with a general circulation model.*, **Journal of Atmospheric Sciences**, v. 38, n.12, p. 2653 – 2675, 1981.
- MOURA, G. B. A. *et al.* Relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.4, p.462–469, 2009.
- NAMIAS, J. *Influence of northern hemisphere general circulation on drought in northeast Brazil*. **Institution of Oceanography**, La Jolla, Calif. p. 336-343, 1972.
- NOBRE, P. **As origens das águas no Nordeste: A questão da água no Nordeste**. In: Centro de Gestão e Estudos Estratégicos, Agência Nacional de Águas. – Brasília, DF: CGEE, 2012.
- NOBRE, P.; MOURA, A. D.; SUN, L. *Dynamical downscaling of seasonal climate prediction over Nordeste Brazil with ECHAM3 and NCEP's Region Spectral Models at IRI*. **Bulletin American Meteorological Society**, v. 82, p. 2787-2796, 2001.
- NOBRE, P.; SHUKLA, J. *Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America*. **Journal of Climate**, v. 9, n.10, p.2464–2479, 1996.

NÓBREGA, R. S. *et al.* O fenômeno El Niño e a influência conjunta do dipolo do Atlântico no Estado do Ceará. *In: Congresso Brasileiro de Meteorologia*, XI, p. 22, 2002.

OLIVEIRA, G. G. *et al.* Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 18, n.3, 2013.

OLIVEIRA, W.; CUNHA, L.; PAIVA, I. A influência da Oscilação do Atlântico Norte nos caudais dos rios Vouga e Mondego – relevância na manifestação de cheias e inundações. **Revista de Geografia e Ordenamento do Território**, n. 12, p. 255-279, 2017.

OLIVEIRA, G. G.; PEDROLLO O. C.; CASTRO, N. M. O Desempenho das Redes Neurais Artificiais (RNAs) para Simulação Hidrológica Mensal. **RBRH: Revista Brasileira de Recursos Hídricos**, v. 19, n.2, p. 251-265, 2014.

PAINEL INTERGOVERNAMENTAL DE MUDANÇAS CLIMÁTICAS. *Climate Change 2014*. Copenhagen: IPCC, 2015.

RAJAGOPALAN, B.; LALL U.; ZEBIAK S. E. *Categorical climate forecasts through regularization and optimal combination of multiple GCM ensembles*. *In: Monthly Weather Review*, v.130, n. 7, p. 1792 - 1811, 2002.

REPELLI, C. A.; ALVES, J. M. B. Uso de Análise de Correlações Canônicas para Prognosticar a Variabilidade Espacial da Precipitação Sazonal Sobre o Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 11, n. 1/2, 67-75, 1996.

RIQUETI, G. A.; RIBEIRO, C. E.; ZÁRATE, L. E. Classificando perfis de longevidade de bases de dados longitudinais usando Floresta Aleatória. *In: Symposium on Knowledge Discovery, Mining and Learning - KDMILE*, 2018;

ROA-GÁRCIA, M. C. *Equity, efficiency and sustainability in water allocation in the Andes: Trade-offs in a full world*. *In: Water Alternatives*, v. 7, n.2, p. 298-319, 2014.

ROCHA, R. V.; SOUZA FILHO, F. A. S.; SILVA, S. M. O. Análise da Relação entre a Precipitação Média do Reservatório Orós, Brasil - Ceará, e os Índices PDO e AMO Através da Análise de *Changepoints* e Transformada de Ondeletas. **Revista Brasileira de Meteorologia**, v. 34, n. 1, p. 139-149, 2019.

ROCHA, V. A. G. M. *et al.* Análise Comparativa Entre RNA, AG e Migha na Determinação de Rugosidades Através de Calibração de Redes Hidráulicas. **RBRH – Revista Brasileira de Recursos Hídricos**, v. 18, n. 1, p. 125-134, 2013.

ROLIM, L. Z. R.; SOUZA FILHO, F. A. S. **Análise dos modos de variação (sazonal, interanual e multidecadal) do clima atual através da análise de séries temporais de vazões**. *In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho et al.* Fortaleza: Expressão Gráfica e Editora, 2019.

ROSS, Sheldon. *Introduction to Probability and Statistics ofr Engineers and Scientists*. 3ª edição, Elsevier. p. 27, Berkeley, 2004.

SANTOS, J. M.; SOARES, L. P. A precipitação para o estado do ceará e sua relação com a dinâmica climática. *In: II Workshop Internacional sobre água no semiárido brasileiro*, 2015.

SILVA, D. F. *et al.* Efeitos da associação de eventos de ENOS e ODP sobre o Estado do Ceará. **Revista de Geografia (UFPE)**, v. 29, n. 2, p.114-135, 2012.

SECRETARIA DE RECURSOS HÍDRICOS. **Comitê de bacias hidrográficas**. Fortaleza: SRH, 2013.

SILVA; D. F.; GALVÍNCIO, J. D. Estudo da Influência da Oscilação Decadal do Pacífico no Nordeste do Brasil. **Revista Brasileira de Geografia Física**, v.4, n.4, p. 665-676, 2011.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia E Ciências Aplicadas: Curso Prático**. 1ª Edição. Editora Artliber, 2010.

SIQUEIRA A. H. B. **Variabilidade do clima da América do Sul e sua relação com os índices oceânicos e atmosféricos**. Dissertação (Mestre) em meteorologia, Universidade Federal de Alagoas, Instituto de Ciências Atmosféricas, Maceió, 2012.

SOUZA, E. B., ALVES J. M. B.; REPELLI C.A. Um Complexo Convectivo de Mesoescala Associado à Precipitação Intensa sobre Fortaleza-CE. **Revista Brasileira de Meteorologia**, v. 13, n. 2, 01-14, 1998.

SOUZA FILHO, F. A.; LALL, U. Modelo de Previsão de Vazões Sazonais e Interanuais. **RBRH – Revista Brasileira de Recursos Hídricos**, v. 9, n.2, p. 61-74, 2004.

STOKELJ, T.; PARAVAN, D.; GOLOB, R. 2002. *Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants*. *In: J. Water Resour. Plann. Manag.*, v 128, n 6, p 415-423.

TELLES, W. R. Simulação de uma Pluma de Contaminantes no Rio Macaé Utilizando Redes Neurais Artificiais. **RBRH – Revista Brasileira de Recursos Hídricos**, v. 18, n. 2, p. 165-174, 2013.

TRIGO, R.; OSBORN, T. J.; CORTE-REAL, J. Influência da Oscilação do Atlântico Norte no Clima do Continente Europeu e no Caudal dos Rios Ibéricos Atlânticos. **Revista Portuguesa de Geografia**, Lisboa, XXXVII, v. 73, p. 5-31, 2002.

UVO, C. R. B.; BERNDTSSON R. *Regionalization and Spatial Properties of Ceará State Rainfall in Northeast Brazil*. *In: J. Geophysic Research*, v. 101, n. D2, p. 4221-4233, 1996.

UVO, C. B. *et al.* *The relationships between Tropical Pacific and Atlantic SST and Northeast Brazil monthly precipitation*. **Journal of Climate**, v.11, n. 10, p. 551-562, 1998.

APÊNDICE A – DADOS DE PRECIPITAÇÃO

Tabela A.1 – Dados de precipitação obtidos pelo o Thiessen para a região hidrográfica dos Sertões de Crateús

Ano	Mês												Média anual
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	
1911	15,5	46,0	138,2	73,9	15,8	0,0	0,0	2,9	0,0	0,0	8,3	15,1	315,7
1912	79,1	215,9	155,5	163,4	74,2	26,8	8,2	0,1	2,9	0,0	12,9	1,9	740,9
1913	24,7	299,5	223,1	208,4	82,5	17,6	13,8	2,5	0,5	13,8	30,4	121,0	1037,8
1914	223,1	64,5	56,4	111,3	26,7	50,3	14,5	35,6	0,0	7,3	1,6	0,0	591,3
1915	10,0	33,6	17,9	62,5	18,6	7,2	1,0	0,0	0,0	0,0	0,6	141,1	292,5
1916	55,6	38,1	264,3	138,3	62,9	13,5	2,6	0,0	0,0	16,7	88,4	51,6	732,0
1917	161,2	275,4	294,4	131,3	121,9	22,9	1,7	0,6	0,0	0,0	19,6	37,5	1066,3
1918	113,0	40,4	174,2	101,9	63,4	38,5	0,0	8,1	1,5	5,8	3,6	59,4	609,7
1919	26,8	96,2	1,3	8,1	1,3	0,4	10,2	8,1	0,2	0,0	0,0	0,0	152,6
1920	12,2	38,4	308,1	204,3	93,0	5,3	9,5	3,5	5,7	8,6	6,6	44,1	739,2
1921	47,4	241,3	181,3	103,5	166,9	6,0	15,9	6,3	5,6	5,3	33,6	0,3	813,3
1922	3,9	109,3	214,6	378,6	55,7	62,5	11,4	9,3	0,2	0,6	69,5	1,5	917,2
1923	40,7	235,5	157,3	155,6	23,3	25,8	3,0	0,0	0,0	0,6	35,5	0,1	677,6
1924	155,4	292,4	307,9	353,5	144,2	73,7	0,1	0,0	1,3	31,6	0,4	33,5	1394,1
1925	207,6	79,8	132,9	150,0	55,1	4,7	2,8	0,3	3,6	8,8	1,6	21,8	668,8
1926	102,6	269,4	323,1	215,2	103,9	27,2	4,8	0,0	0,4	0,0	1,4	0,0	1047,9
1927	61,1	168,0	193,4	192,4	50,5	13,7	11,7	0,0	0,3	0,5	0,0	13,0	704,5
1928	89,7	44,7	333,0	82,3	28,3	6,4	1,6	0,0	0,0	0,0	14,2	16,7	616,9
1929	75,5	212,9	311,1	137,3	33,6	19,9	10,8	8,4	0,6	7,5	0,4	62,6	880,7
1930	65,3	74,8	223,6	111,0	8,2	15,0	1,8	0,0	0,0	14,9	0,7	6,6	521,8
1931	48,9	141,2	132,2	92,5	20,0	5,4	1,6	6,6	0,0	8,6	1,3	2,3	460,5
1932	34,3	120,1	44,0	23,9	8,4	4,5	20,4	0,0	4,2	0,0	0,7	0,2	260,6
1933	82,6	156,8	186,0	151,7	21,6	2,4	11,3	1,1	0,0	1,6	3,4	78,6	697,2
1934	98,6	244,7	224,0	123,7	94,6	11,5	0,0	0,2	0,5	1,2	12,4	52,6	863,8
1935	139,7	225,6	178,4	288,8	61,5	28,2	8,6	0,0	0,2	0,1	0,0	13,4	944,5
1936	15,8	295,4	35,9	10,8	25,5	11,4	0,1	0,0	0,0	0,0	4,0	4,1	402,7
1937	30,6	130,9	77,9	155,2	57,9	27,9	8,8	0,9	0,2	0,0	0,2	15,6	506,1
1938	62,3	52,4	235,5	135,5	12,8	3,4	0,0	0,6	0,0	0,0	0,6	0,7	503,8
1939	35,7	158,2	162,7	138,4	32,4	7,7	4,4	4,4	8,3	3,0	3,1	18,2	576,6
1940	124,4	116,7	327,7	219,1	99,6	26,4	10,0	4,5	1,5	0,6	0,0	1,0	931,7
1941	21,9	91,6	209,3	82,7	29,3	4,1	0,9	0,1	0,0	0,0	6,5	2,9	449,3
1942	13,5	86,8	81,5	55,4	2,5	0,1	0,0	3,8	0,1	2,3	26,4	53,8	326,1
1943	95,6	59,0	131,1	66,5	11,8	6,8	12,4	3,0	0,0	0,0	14,1	33,2	433,5
1944	130,4	26,4	147,7	130,4	38,2	1,9	7,1	0,0	0,0	0,0	2,1	164,9	649,1
1945	60,7	300,2	136,3	175,9	102,7	33,4	3,8	1,0	0,0	1,0	0,0	32,2	847,2
1946	140,1	119,1	111,8	180,2	29,4	35,6	1,6	0,0	0,0	0,6	22,6	84,8	725,9
1947	25,8	70,0	123,1	67,2	13,4	0,0	2,5	0,0	0,0	0,0	19,0	9,5	330,4
1948	68,6	110,1	335,8	81,2	52,9	10,5	4,7	0,3	0,2	2,3	0,0	22,4	688,9
1949	19,1	134,0	160,3	150,6	70,8	5,6	2,1	4,0	0,0	0,4	111,7	7,4	666,0
1950	64,8	103,5	283,5	240,9	53,4	0,4	1,6	0,0	0,0	0,0	3,5	5,3	757,0
1951	47,8	4,3	64,1	107,3	13,3	7,8	0,0	0,0	0,0	2,3	1,8	51,1	299,7
1952	17,0	33,7	106,1	87,7	35,6	5,6	0,0	0,0	0,0	1,4	2,0	45,0	334,1
1953	12,8	57,6	58,5	66,4	17,0	6,4	0,6	0,0	0,0	0,5	17,4	12,4	249,7

Tabela A.1 – Dados de precipitação obtidos pelo o Thiessen para a região hidrográfica dos Sertões de Crateús

Ano	Mês												Média anual
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	
1954	18,2	86,5	128,8	58,8	66,4	2,6	0,0	0,0	0,0	0,0	37,9	1,0	400,2
1955	111,5	48,7	98,7	162,2	71,4	7,9	3,1	0,3	0,0	8,1	0,6	3,1	515,6
1956	10,5	125,3	177,8	113,1	12,2	0,0	2,8	0,0	0,0	3,3	31,0	13,0	488,9
1957	66,8	45,9	213,4	438,8	5,6	4,2	0,0	0,0	0,0	0,8	0,0	6,3	781,9
1958	66,6	68,2	56,5	25,2	22,6	0,0	2,9	0,0	0,0	0,0	0,0	1,5	243,5
1959	55,6	154,3	104,7	27,1	54,1	8,0	0,0	5,4	0,0	0,5	0,4	0,4	410,5
1960	36,3	39,9	362,3	75,3	25,2	2,7	0,0	0,0	0,0	0,3	0,0	33,6	575,6
1961	136,4	182,0	252,6	130,8	76,1	9,2	18,4	0,0	0,0	0,0	0,9	7,2	813,6
1962	121,1	103,6	174,9	114,6	88,4	14,1	0,4	0,2	0,0	0,0	15,1	18,9	651,4
1963	102,6	196,5	369,4	140,2	20,6	4,9	1,2	0,0	0,0	0,9	22,7	96,5	955,5
1964	154,2	203,7	267,9	321,4	115,8	21,6	9,1	6,0	0,8	0,0	0,0	2,7	1103,1
1965	15,8	59,2	233,7	253,3	77,5	64,2	6,0	1,8	0,9	42,0	0,8	2,6	757,8
1966	15,0	173,0	53,1	173,4	31,2	10,4	5,4	0,0	6,1	0,0	18,3	11,7	497,7
1967	57,6	200,7	314,0	289,6	106,1	11,0	12,0	0,2	0,0	0,0	4,3	94,9	1090,5
1968	54,9	43,6	341,0	150,4	162,8	0,4	6,0	1,1	0,0	0,0	10,3	21,8	792,3
1969	88,0	117,1	207,0	141,8	43,8	26,6	29,3	0,5	0,0	0,0	0,0	0,4	654,5
1970	62,9	32,2	124,6	63,0	5,3	4,9	3,1	0,9	0,2	0,0	50,2	0,8	348,3
1971	74,2	104,7	141,7	193,3	76,4	14,3	18,1	1,5	0,0	8,9	2,0	0,7	635,9
1972	75,9	81,0	56,2	82,0	11,1	15,2	1,0	17,2	0,2	0,0	0,0	113,0	452,9
1973	61,9	92,1	168,8	287,2	91,0	41,6	18,5	4,5	26,1	15,7	2,9	14,5	824,8
1974	176,9	99,7	248,1	456,9	191,1	10,8	1,5	0,0	4,6	10,1	0,0	44,7	1244,4
1975	63,7	121,5	257,7	153,3	144,4	36,5	20,5	2,7	0,0	0,0	1,9	15,1	817,4
1976	19,6	223,0	125,3	107,4	21,1	4,4	0,4	0,4	10,5	9,6	15,9	6,8	544,5
1977	126,1	91,0	175,1	180,8	47,7	42,0	9,7	0,0	0,0	0,0	0,1	61,7	734,2
1978	66,3	91,3	168,9	114,0	75,3	5,7	10,7	0,1	0,9	0,0	5,2	10,5	549,0
1979	99,0	88,3	125,0	76,0	79,9	7,0	2,3	4,4	2,4	0,0	21,3	4,2	509,8
1980	105,6	233,8	108,8	25,9	1,3	9,3	0,4	0,0	0,1	1,1	6,0	13,4	505,7
1981	72,6	22,9	276,1	50,1	14,8	0,3	0,0	10,6	0,0	0,0	0,2	28,6	476,2
1982	51,6	77,1	135,4	75,6	18,3	1,9	1,7	1,2	0,1	3,8	3,9	2,5	373,0
1983	4,6	107,9	73,5	27,8	5,8	0,0	0,9	0,4	0,0	0,0	0,0	6,0	226,9
1984	36,3	66,5	251,1	287,9	56,0	7,2	13,3	0,3	2,2	30,1	13,2	3,7	767,9
1985	170,9	269,3	292,5	336,3	73,1	31,1	20,0	3,1	0,7	0,0	0,0	140,5	1337,7
1986	58,0	184,6	322,9	160,6	36,7	12,5	4,6	10,7	0,0	0,9	0,7	15,1	807,3
1987	17,4	70,1	281,4	29,7	12,2	25,1	5,0	1,7	0,0	0,0	0,0	2,3	444,7
1988	49,8	69,7	338,5	208,5	73,2	16,7	6,5	0,0	0,0	0,2	2,0	91,9	857,1
1989	45,1	27,5	204,2	351,8	148,3	15,6	4,9	5,9	0,0	18,4	0,4	150,4	972,4
1990	2,6	165,4	36,4	114,4	20,4	8,0	21,4	0,0	17,6	0,9	9,8	3,6	400,3
1991	130,3	127,5	248,4	100,3	59,4	7,7	0,6	0,8	0,0	0,0	1,2	0,0	676,3
1992	120,7	102,9	88,0	66,5	0,0	7,9	3,1	0,0	0,0	0,0	0,0	1,0	390,3
1993	10,9	47,0	67,4	48,5	71,5	5,0	3,1	0,0	0,6	0,5	0,0	24,5	279,0
1994	103,5	95,9	218,4	116,0	36,5	64,1	7,6	0,7	0,0	1,4	0,0	38,5	682,6
1995	39,2	163,7	123,7	324,4	142,0	13,9	15,3	0,0	0,0	20,4	33,8	5,1	881,6
1996	132,6	56,8	219,3	359,7	51,6	4,0	0,2	5,9	0,0	0,0	25,1	0,0	855,2
1997	144,7	19,3	266,1	125,4	72,6	0,0	3,8	0,0	0,0	0,7	0,8	28,0	661,4
1998	126,3	23,0	72,4	32,1	4,2	0,6	0,3	0,3	0,0	0,0	0,0	5,5	264,6

Tabela A.1 – Dados de precipitação obtidos pelo o Thiessen para a região hidrográfica dos Sertões de Crateús

Ano	Mês												Média anual
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	
1999	125,1	85,2	158,9	89,0	121,1	2,5	0,0	0,0	0,0	3,9	24,6	95,2	705,6
2000	95,2	172,7	174,5	164,7	22,2	5,2	6,4	7,6	10,1	0,1	11,3	45,3	715,3
2001	22,7	106,4	141,1	136,9	14,3	24,2	2,0	0,1	0,4	0,4	0,1	4,1	452,7
2002	244,3	33,8	149,9	142,0	27,3	15,1	1,1	0,0	0,0	0,5	0,0	7,8	621,8
2003	64,3	182,8	261,7	78,9	21,4	35,4	1,0	0,2	0,0	0,0	0,0	6,7	652,4
2004	488,2	169,1	82,5	51,8	19,8	30,3	3,6	0,4	0,3	0,0	3,4	9,9	859,5
2005	122,8	31,8	243,7	66,6	55,7	10,5	0,1	2,6	0,0	0,0	1,2	6,9	541,9
2006	34,1	105,7	145,9	161,8	75,5	31,8	0,8	0,6	0,1	0,4	0,9	7,1	564,8
2007	9,8	277,8	70,8	77,8	20,4	8,5	1,2	0,0	0,0	0,0	0,0	41,3	507,6
2008	57,9	119,4	394,6	181,3	43,3	1,1	5,6	9,2	0,0	0,0	0,0	2,9	815,2
2009	87,2	135,3	155,9	374,8	161,4	15,5	20,4	2,2	0,0	0,0	0,0	5,5	958,1
2010	85,2	6,2	55,4	106,2	10,0	4,4	0,0	0,0	0,0	20,8	0,0	115,8	404,0
2011	169,8	124,3	139,1	126,6	146,1	6,5	22,7	5,6	0,4	24,3	2,8	0,0	768,3
2012	36,3	55,2	35,9	29,6	3,8	0,4	0,0	0,0	0,0	0,0	0,9	0,0	162,1
2013	23,8	58,9	42,4	71,2	41,6	27,4	5,6	2,0	0,0	1,0	19,2	56,2	349,4
2014	46,1	50,5	130,1	81,6	50,0	0,3	0,0	0,0	0,0	3,5	38,4	4,2	404,6
2015	30,3	98,9	145,2	85,5	16,3	37,1	11,1	0,5	0,0	0,0	0,0	7,2	431,9
2016	234,4	43,2	105,5	64,5	23,2	7,2	0,0	0,0	0,0	0,0	0,0	38,1	516,2
2017	42,8	131,2	113,4	85,5	14,1	1,7	0,9	0,0	0,7	0,0	0,2	7,5	397,8
2018	46,8	192,3	147,1	180,6	13,9	3,8	10,8	0,3	0,0	8,9	1,1	107,5	713,0

Fonte: Autoria própria (2019).