



**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL**

THIAGO ALBERTO DA SILVA PEREIRA

**ANÁLISE E PREVISÃO DE CHUVAS NA ESTAÇÃO SECA DO LESTE DO
NORDESTE DO BRASIL: APLICAÇÃO NAS BACIAS DOS RIOS MUNDAÚ E
PARAÍBA DO MEIO (AL/PE)**

Recife

2017

THIAGO ALBERTO DA SILVA PEREIRA

**ANÁLISE E PREVISÃO DE CHUVAS NA ESTAÇÃO SECA DO LESTE DO
NORDESTE DO BRASIL: APLICAÇÃO NAS BACIAS DOS RIOS MUNDAÚ E
PARAÍBA DO MEIO (AL/PE)**

Tese submetida ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como parte dos requisitos para a obtenção do título de Doutor.

Área de Concentração: Tecnologia Ambiental e Recursos Hídricos

Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro

Coorientador: Prof. Dr. Carlos Ruberto Fragoso Júnior

Recife

2017

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

P436a Pereira, Thiago Alberto da Silva.
Análise e previsão de chuvas na estação seca do leste do nordeste do Brasil:
aplicação nas Bacias dos rios Mundaú e Paraíba do Meio (AL/PE) / Thiago Alberto
da Silva Pereira. - 2017.
170 folhas, il., gráfs., tabs.

Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro.
Coorientador: Prof. Dr. Carlos Ruberto Fragoso Júnior.

Tese (Doutorado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia Civil, 2017.
Inclui Referências e Apêndices.

1. Engenharia Civil. 2. Secas. 3. Leste do Nordeste. 4. Modelo híbrido.
5. Previsão. I. Montenegro, Suzana Maria Gico Lima. (Orientadora). II. Fragoso
Júnior, Carlos Ruberto. (Coorientador). III. Título.

UFPE

624 CDD (22. ed.)

BCTG/2018-157



UNIVERSIDADE FEDERAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

A comissão examinadora da Defesa de Tese de Doutorado
**ANÁLISE E PREVISÃO DE CHUVAS NA ESTAÇÃO SECA DO LESTE NO
NORDESTE BRASILEIRO: APLICAÇÃO NAS BACIAS DOS RIOS MUNDAÚ E
PARAÍBA DO MEIO (AL/PE)**

defendida por
THIAGO ALBERTO DA SILVA PEREIRA
considera o candidato aprovado

Recife, 27 de Outubro de 2017.

Orientadores:

Professora Dra. Suzana Maria Gico Lima Montenegro - UFPE
(orientadora)

Professora Dr. Carlos Ruberto Fragoso Júnior – UFAL
(co-orientador)

Banca Examinadora:

Professora Dra. Suzana Maria Gico Lima Montenegro - UFPE
(orientadora)

Professora Dra. Josicleda Domiciano Galvêncio - UFPE
(examinador externo)

Professora Dra. Djane Fonseca da Silva - UFAL
(examinador externo)

Professor Dr. Mêuser Jorge Silva Valença - UPE
(examinador externo)

Professor Dr. Alfredo Ribeiro Neto - UFPE
(examinador interno)

Dr. Roni Valter de Souza Guedes - APAC
(examinador externo)

Dedico à pequena Maria Isis que me faz enxergar a vida com outros olhos e proporcionar sentimentos que nunca imaginei experimentar.

AGRADECIMENTOS

Uma tese jamais será feita em duas mãos, tampouco, quatro. Este espaço é reservado para agradecer a todos que fizeram parte direta ou indiretamente desta etapa da minha vida.

Primeiramente a Deus, o grande arquiteto que fez com que cada tijolo (pessoas) surgisse na hora certa para concretização deste sonho.

Aos meus pais, Luiz Alberto e Tânia Maria, pelo apoio incondicional.

À Roberta Freitas, minha esposa, namorada e companheira, por compreender todo o processo de doutoramento e me conceder a pequena Maria Isis neste período.

À Professora Suzana Maria Gico Lima Montenegro, primeiro, por me aceitar como orientando, e, posteriormente, por auxiliar em cada etapa deste trabalho sempre com paciência e presteza.

Ao professor e amigo Carlos Ruberto, por acreditar no meu potencial e proporcionar um intercâmbio de ideias na Universidade de Lund, na Suécia.

À professora Cintia Regina Bertacchi Uvo, por toda atenção e pelas dicas de como conduzir este trabalho para o bom termo.

Ao amigo Denis Duda, por diversos momentos, quer seja na disponibilização dos dados para esta tese e paciência para repassar alguns conhecimentos, quer seja pela acolhida na cidade de Lund, na Suécia.

A algumas pessoas que me ajudaram diretamente de alguma forma para a realização deste trabalho que talvez nem saibam que aqui estão citados, como: Ricardo Reis, Djane Fonseca, Mahelvson Chaves, Tainara Ramos, Rafael Pereira, Luis Gustavo. Ainda a Karleany Mendonça de Lima, pela formatação deste texto.

Aos amigos que cultivei no período de doutoramento, em especial: Cláudia Oliveira e Josiane Holz.

Aos amigos que me acolheram em Recife: Zé Roberto e Jane, Eduardo e Gabriela, Chica e Júnior e Cláudia e Marcílio.

Aos membros da banca de qualificação, que trouxeram contribuição importantíssima para realização do melhor nesta tese.

Aos docentes do Eixo de Tecnologia do Campus Sertão da Universidade Federal de Alagoas, em especial as coordenadoras do curso de engenharia Civil, professoras Viviane Costa e Rafaela Facíola, que foram bastante solícitas com a minha situação.

Aos companheiros de viagem, que proporcionaram momentos alegres durante este período: Dalgoberto, Márcio e Anderson.

A dois grandes amigos com os quais sei que posso contar sempre: Thiago Trindade e Chica.

A alguns discentes e ex-discentes que sempre me deram apoio: Ana Maria, Grazielly, Israel Lemos e Tássio Magassy.

A FINEP pelo Projeto REHIDRO, que proporcionou a integração entre diversas instituições.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento de projetos de pesquisa (Chamada Universal - MCTI/CNPq N° 14/2014 e MCTI/CNPq/ANA N.23/2015), Financiadora de Estudos e Projetos (FINEP), pelo financiamento do projeto REHIDRO 1830.

A *Swedish Foundation for International Cooperation in Research and Higher Education* (STINT) que financiou a Cooperação internacional entre a Universidade de Lund e a Universidade Federal de Alagoas.

A todos que contribuíram de alguma forma e não foram citados.

“Não perca tempo mentalizando o tamanho da escada, suba o primeiro degrau e saberá que é capaz”. (M.L.Pontes)

*“Se faltar o vento, a gente inventa
Vamos remar contra a corrente
Desafinar do coro dos contentes”
(Engenheiros do Hawaii)*

*“Se acredita, tenta”
(Lenine e Ivan Santos)*

RESUMO

A variabilidade climática provoca eventos extremos que impactam a população global. O entendimento desta variabilidade é ferramenta potente para mitigação dos seus efeitos deletérios. As condições anômalas da precipitação, decorrentes da variabilidade climática, trazem prejuízos diversos, sendo, portanto, necessário o estudo de seu comportamento e a construção de modelos de previsão com certo grau de antecedência. O nordeste do Brasil, em comparação com o país como todo, é a região mais vulnerável aos efeitos da variação da precipitação, por esta razão, torna-se importante a caracterização e estudos de recorrência destes eventos. No entanto, o nordeste do Brasil apresenta diferentes regimes de precipitação, em termos espaciais, podendo ser divididos em Norte do Nordeste do Brasil (NNEB) e Leste do Nordeste do Brasil (LNEB). Muitos esforços têm sido empreendidos para entender a variabilidade interanual da precipitação do NNEB, enquanto que no LNEB, o rol de trabalhos ainda se mostra incipiente, focando sua maioria na estação chuvosa. Diferentemente do NNEB, a estação seca do LNEB apresenta uma variabilidade interanual acima de 150 mm, que pode acarretar danos à população que ali reside. Logo, este trabalho visa entender a variabilidade pluviométrica da estação seca do LNEB e propor um modelo de previsão em longo prazo, utilizando como área de estudo as Bacias dos rios Mundaú e Paraíba do Meio, localizadas nos estados de Pernambuco e Alagoas. Para tal, os dados pluviométricos coletados foram compilados para o trimestre seco (outubro a dezembro) e submetidos à Análise de Componentes Principais e Análise Cluster, quando foi possível classificar a região em duas porções com características similares. A partir disso, foram calculados os índices de precipitação padronizada (SPI), então, buscou-se uma relação do SPI com índices climáticos globais (SOI, NAO, AMM, AMO, PDO e Niño 3.4), com defasagem de até 6 meses da estação seca, através de técnicas de correlação univariadas (Correlação de Spearman) e multivariadas (transformada *wavelets*, *wavelets* cruzada e *wavelets* coerência). Por fim, à luz dos resultados das etapas anteriores, foi construído um modelo híbrido (combinação de Rede neural e algoritmos genéticos) com dois objetivos: reconhecimento dos padrões dos dados e previsão dos índices baseados na precipitação. As correlações de Spearman não apresentaram resultados satisfatórios para análise interanual, no entanto, para análise decadal verificaram-se bons resultados para faixa espectral decadal com coeficientes de correlação acima de 0,3. Estes resultados foram corroborados pela análise de *wavelets* que encontrou escalas dominantes na faixa decadal. Ainda sobre os resultados, da aplicação do modelo híbrido tem-se uma maior previsibilidade para faixa decadal do SPI e resultados modestos para sua série interanual, retratando apenas alguns picos negativos após o ano de 1987. Este trabalho mostrou que a maior porção da variabilidade pluviométrica (interanual), na estação seca, decorre de fenômenos meteorológicos de pequena escala e as características físicas das bacias, enquanto que a menor porção (frequência decadal ou maior) pode ser explicada pelos fenômenos globais com destaque para as condições do oceano Atlântico, sobretudo na variabilidade da porção litorânea da área de estudo.

Palavras-chave: Secas. Leste do Nordeste. Modelo híbrido. Previsão.

ABSTRACT

Climatic variability causes extreme events that significantly impact the global population. Understanding this variability is a powerful tool to mitigate its deleterious effects. The anomalous precipitation conditions, due to climatic variability, bring different damages, so it is necessary to study their behavior and construct forecast models with a certain degree of advance. Northeastern Brazil, in comparison to the country as a whole, is the region most vulnerable to the effects of precipitation variation, and is therefore important to the characterization and recurrence studies of these events. However, northeastern Brazil presents different precipitation regimes in spatial terms, being able to be divided in Northeast of Brazil (NNEB) and East of Northeast of Brazil (LNEB). Many efforts have been undertaken to understand the interannual variability of the NNEB precipitation, while in the LNEB the role of studies to analyze the precipitation variation and its cause-effect relationships is still incipient, focusing mostly in the rainy season. Unlike the NNEB, the dry season of the LNEB shows an interannual variability above 150 mm, which can cause damage to the population living there. Therefore, this work aims to understand the rainfall variability of the LNEB dry season and to propose a long term forecasting model, using the Mundaú and Paraíba do Meio river basins located in the states of Pernambuco and Alagoas as the study area. For this, the rainfall data collected were compiled for the dry period (October to December) and submitted to Principal Component Analysis and Cluster Analysis when it was possible to classify the region into two parts with similar characteristics. (SPI), a SPI relationship with global climate indexes (SOI, NAO, AMO, AMO, PDO and Niño 3.4) was calculated, with a lag of up to 6 months of the dry season, using univariate correlation techniques (Transformed of wavelets, cross wavelets and coherence wavelets), finally the light of the results of the previous steps was constructed a hybrid model (combination of neural network and genetic algorithms) with two objectives: recognition of data patterns and prediction of precipitation indexes. Spearman correlations did not present satisfactory results for interannual analysis, however for decadal analysis, using the spectral range of 10 to 16 years, good results were observed for decadal spectral range with correlation coefficients above 0.3. These results were corroborated by the analysis of wavelets that found dominant scales in the decadal range for most of the climatic indexes, still on the results, of the application of the hybrid model, we have a greater predictability for SPI decadal range and modest results for its interannual series, portraying only a few negative peaks after 1987, reporting once more to the PDO. This work showed that the largest portion of rainfall variability (interannual) in the dry season is due to small-scale meteorological phenomena and the physical characteristics of the basins, and the smaller portion (decadal or greater) can be explained by global phenomena. Atlantic, especially in the variability of the coastal area of the study area.

Keywords: Droughts. East Northeast. Hybrid Model. Forecast.

LISTA DE ILUSTRAÇÕES

Figura 1 - Circulação do Pacífico Equatorial em Anos Normais.	26
Figura 2 - Circulação do Pacífico Equatorial em Condições de El Niño	26
Figura 3 - Circulação do Pacífico Equatorial em Condições de La Niña.....	27
Figura 4 - Regiões dos Niños	30
Figura 5 - Anomalias da Temperatura na Superfície do Mar (cores), da pressão do nível do mar (contornos) e da intensidade do vento na superfície, durante a fase (a) fria e (b) quente.	31
Figura 6 - Estrutura dinâmica da fase positiva e negativa do NAO.	33
Figura 7 - Mapa de regressão do modo da AMC correspondente a TSM normalizada e vetor de velocidade do vento. Os vetores do vento são plotados de forma que a soma geométrica dos coeficientes de correlação exceda 0.27 (95% de nível de confiança), e mapas de anomalia.	35
Figura 8- Diferentes Componentes da Previsão de Secas.	48
Figura 9- Transformada Wavelet: decomposição em tempo escala com tamanhos de janelas variáveis.....	52
Figura 10 - (a) Diferentes tipos de wavelets-mãe, (b) translações e (c) dilatações da base e (d) processo de correlação da transformada de Wavelets.	53
Figura 11 - A wavelet de Morlet (a) e a representação de sua formação através de um senoide (em verde) e um envelope gaussiano, em vermelho (b).	54
Figura 12 - Modelo de uma Rede Neural Artificial e detalhe do funcionamento de um dos neurônios. Fonte: Bravo (2010).	59
Figura 13 - Localização da Região de Estudo.	65
Figura 14 - Precipitação Média Mensal com o Grau de dispersão da Região de Estudo.	66
Figura 15 - Estações Pluviométricas Seleccionadas.	69
Figura 16 - Alternativas na geração do novo indivíduo num sub-complexo.....	79
Figura 17 - Cálculo do OCW_{x_1} de uma rede neural artificial progressiva com 4 neurônios na camada de entrada e 4 na camada intermediária.	80
Figura 18 - Topologia da Rede Neural Artificial Utilizada Para Reconhecimento do Padrão das Variáveis.....	81
Figura 19 - Topologia da Rede Neural Artificial Utilizada Para Previsão.....	82
Figura 20 - Autovetores do 1º e 2º Modo da Análise de Componente Principais da Precipitação de OND.	85

Figura 21 - Análise de Cluster da Similaridade Espacial da Precipitação OND E Classificação Climática.....	86
Figura 22 - Dendograma dos dados de Precipitação do Trimestre Seco nas Bacias do Rio Paraíba e Mundaú.	87
Figura 23 - Série de SPI3 das Regiões Homogêneas (RHs).....	89
Figura 24- Série de SPI3* para Regiões Homogêneas (RHs).	91
Figura 25 – Aplicação da Transformada de Ondaleta a Série de SPI3 nas Regiões Homogêneas.	92
Figura 26 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do NAO de maio e o SPI3 do RH1.	93
Figura 27 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de abril e o SPI3 do RH1.	94
Figura 28 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de abril e o SPI3 do RH2.	94
Figura 29 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de junho e o SPI3 do RH1	94
Figura 30 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de junho e o SPI3 do RH2	95
Figura 31 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_temp de abril e o SPI3 do RH2	95
Figura 32 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_temp de maio e o SPI3 do RH2	96
Figura 33 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do SOI de abril e o SPI3 do RH1.....	97
Figura 34 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do SOI de abril e o SPI3 do RH2.....	97
Figura 35 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de abril e o SPI3 do RH2.....	98
Figura 36 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de maio e o SPI3 do RH2.....	98
Figura 37 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de junho e o SPI3 do RH1.....	98
Figura 38 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de junho e o SPI3 do RH2.....	99

Figura 39 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de julho e o SPI3 do RH1	99
Figura 40 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de julho e o SPI3 do RH2	99
Figura 41 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 (50-25-25) de Junho e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	103
Figura 42 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de junho e Niño 3.4 de Maio (50-25-25) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	103
Figura 43 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_sst de abril e Niño 3.4 de junho (70-15-15) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	103
Figura 44 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 de Maio (60-20-20) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH2.	104
Figura 45 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 de junho (60-20-20) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH2.	104
Figura 46 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_sst de abril e Niño 3.4 de abril (70-15-15) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH2.	105
Figura 47 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de junho e PDO de Maio (70-15-15) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	105
Figura 48 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de junho e PDO de abril (70-15-15 e 60-20-20) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	106
Figura 49 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de julho e PDO de abril (70-15-15 e 60-20-20) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	106
Figura 50 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de julho e PDO de Maio (70-15-15) e os valores da contribuição relativa (ROCW _i) de cada Oceano analisado Aplicado a RH1.	107

Figura 51 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de Julho e PDO de Maio (50-25-25) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH2.	107
Figura 52 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH1	110
Figura 53 – Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH1.	111
Figura 54 – Série Temporal do SPI para o Melhor Ajuste no Agrupamento 1 para RH1.....	112
Figura 55 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 1 para RH1.....	113
Figura 56 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH2	114
Figura 57 – Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH2.	115
Figura 58 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 1 para RH2.	116
Figura 59 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 1 para RH2.....	117
Figura 60 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH1	118
Figura 61– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH1	119
Figura 62 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 2 para RH1.	120
Figura 63 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 2 para RH1.....	121
Figura 64 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH2	122
Figura 65– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH2	123
Figura 66 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 2 para RH2.	124
Figura 67- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 2 para RH2.....	125
Figura 68 - Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH1.	126

Figura 69– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH1	127
Figura 70- Série Temporal do SPI para o Melhor Ajuste no Agrupamento 3 para RH1	128
Figura 71- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 3 para RH1.....	129
Figura 72 - Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH2.	130
Figura 73 - Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH2.	131
Figura 74 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 3 para RH2.	132
Figura 75 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 3 para RH2.....	133
Figura 76- Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH1.	134
Figura 77 - Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH1	135
Figura 78 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 4 para RH1.	136
Figura 79 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 4 para RH1.....	137
Figura 80- Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH2	138
Figura 81- Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH2	139
Figura 82 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 4 para RH2.	140
Figura 83- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 4 para RH2.....	141

LISTA DE TABELAS

Tabela 1- Índices de Seca Utilizados: Categorias	43
Tabela 2 - Categorias de Seca de acordo com o valor do SPI.	44
Tabela 3 - Estudos de Análise de Agrupamento Realizados no Brasil.	50
Tabela 4 - Modelos Desenvolvidos para Previsão Hidrológica.	58
Tabela 5 - Estações Pluviométricas Seleccionadas para o Período de 1938 a 1961.	67
Tabela 6 - Estações Pluviométricas Seleccionadas para o Período de 1962 a 2008.	68
Tabela 7 - Explicação da Variabilidade da precipitação dos 3 primeiros modos da PCA.	84
Tabela 8 - Correlação de Spearman Entre os Dois Primeiros Modos do PCA e os Índices Climáticos.....	86
Tabela 9- Correlação de Spearman entre SPI e índices Climáticos.	90
Tabela 10 – Melhores Índices Climáticos Encontrados na Aplicação do Wavelets	100
Tabela 11 – Correlação de Spearman Entre os Índices Climáticos e as Faixa Espectral de 10 a 16 anos de SPI	101
Tabela 12 – Índices Climáticos Utilizados na Rede Neural para Reconhecimento de Padrões.	102
Tabela 13 – Combinações das Variáveis Predictoras para Construção do Modelo de Rede Neural.	109
Tabela 14 – Índices Climáticos Utilizados nos Modelos de Previsão com Melhores Resultados	142

LISTA DE ABREVIATURAS E SIGLAS

NEB	Nordeste do Brasil
NNEB	Norte do Nordeste do Brasil
LNEB	Leste do Nordeste Brasil
NOAA	<i>National Oceanic and Atmospheric Administration</i>
SOI	Índice de Oscilação Sul
PDO	Oscilação Decenal do Pacífico
NAO	Oscilação do Atlântico Norte
AMO	Oscilação Multidecenal do Atlântico
ENSO	El Niño/Oscilação Sul
SLP	Pressão do Nível do Mar
TSM	Temperatura da Superfície do Mar
AMM	Modo Meridional do Atlântico
AMC	Análise de Máxima Covariância
MEI	Índice multivariado do ENSO
SAM	Modo Anular do Hemisfério Sul
AAO	Oscilação Antártica
NAM	Modo Anular do Hemisfério Norte
AAO	Oscilação Antártica
OA	Oscilação Ártica
IOD	Dipolo do Oceano Índico
ScandO	Oscilação Escandinávia
EAWRO	Oscilação do Atlântico Leste/ Oeste da Rússia
PNAO	Oscilação do Pacífico/Norte América
PEO	Oscilação Eurásia/Polar
WPO	Oscilação do Pacífico Oeste
ZCIT	Zona de Convergência Intertropical
VCAN	Vórtices Ciclônicos de Ar Superior
ZCEN	Zona de Convergência do LNEB
POAS	Perturbações Ondulatórias Nos Ventos
IBGE	Instituto Brasileiro de Geografia e Estatística
PNUD	Programa das Nações Unidas para o Desenvolvimento

SPI	Índice Padronizado de Precipitação
SPEI	Índice De Precipitação e Evapotranspiração Padronizado
MSDI	Índice Padronizado de Seca Multivariado
ISDI	Índice Integrado de Seca De Superfície
PSDI	Índice de Severidade de Seca de Palmer
CMI	índice de umidade da cultura
SMDI	Índice de seca da umidade do solo
ACP	Análise de Componentes Principais
AC	Análise de Cluster
DVS	Decomposição do Valor Singular
WT	Transformada Ondeleta
WCT	Coerência Wavelet
XWT	Wavelet Cruzada
RNA	Rede Neural Artificial
SVR	<i>Support Vector Regression</i>
ANA	Agência Nacional de Águas
ITEP	Instituto Tecnológico de Pernambuco
SEMARH – AL	Secretaria Est. de Rec. Hídricos e Meio Ambiente de Alagoas
OND	Outubro, Novembro e Dezembro
NCAR	<i>The National Center for Atmospheric Research</i>
SCE-UA	<i>Shuffled Complex Evolution – University of Arizona</i>
OCW	<i>Overall Connection Weight</i>

SUMÁRIO

1	INTRODUÇÃO	20
1.1	JUSTIFICATIVA	20
1.2	RELEVÂNCIA.....	21
1.3	HIPÓTESE	22
1.4	OBJETIVOS	22
1.5	ESTRUTURA DA TESE	23
2	VARIABILIDADE CLIMÁTICA	24
2.1	ÍNDICES CLIMÁTICOS	25
2.1.1	Índice de Oscilação Sul - IOS	25
2.1.2	Niños	29
2.1.3	Oscilação Decenal do Pacífico - PDO	30
2.1.4	Índice Oscilação do Atlântico Norte - NAO	32
2.1.5	Oscilação Multidecenal do Atlântico – AMO	33
2.1.6	Modo Meridional do Atlântico – AMM	34
2.1.7	Outros índices	36
2.2	VARIABILIDADE CLIMÁTICA NO LESTE DO NORDESTE BRASILEIRO.....	37
2.3	RESUMO DO CAPÍTULO	39
3	OS FENÔMENOS DAS SECAS	40
3.1	ÍNDICES DE SECAS	42
3.1.1	Índice Padronizado de Precipitação – SPI	43
3.2	MODELOS DE PREVISÃO HIDROLÓGICA	47
3.2.1	Análise Multivariada	48
3.2.2	Correlação	51
3.2.3	Análise de Séries temporais	51
3.2.4	Métodos de Previsão	56
3.3	RESUMO DO CAPÍTULO	63
4	MATERIAIS E MÉTODOS	64
4.1	ÁREA DE ESTUDO	64
4.2	COLETA E SELEÇÃO DOS DADOS	67
4.3	ANÁLISE MULTIVARIADA	68
4.4	CÁLCULO DO SPI.....	72

4.5	CORRELAÇÃO DE SPEARMAN	74
4.6	TRANSFORMADA ONDELETA	74
4.7	REDE NEURAIAS ARTIFICIAIS	75
4.7.1	Divisão e Pré-processamento dos Dados.....	75
4.7.2	Treinamento e Validação	76
4.7.3	Avaliação do Desempenho	82
5	RESULTADOS	84
5.1	ANÁLISE MULTIVARIADA	84
5.2	ANÁLISE DOS EVENTOS DE CHUVA	88
5.3	TRANSFORMADA ONDELETA	90
5.3.1	Oceano Atlântico.....	93
5.3.2	Oceano Pacífico.....	96
5.3.3	Considerações sobre Aplicação da Wavelets.....	100
5.4	REDES NEURAIAS ARTIFICIAIS	102
5.4.1	Reconhecimento dos Padrões.....	102
5.4.2	Previsão.....	108
5.4.3	Considerações sobre Aplicação da RNA.....	141
6	CONCLUSÕES E RECOMENDAÇÕES.....	144
	REFERÊNCIAS.....	147
	APÊNDICE A – CÁLCULO DO SPI	160
	APÊNDICE B – CORRELAÇÕES DE SPEARMAN.....	163
	APÊNDICE C – DIVISÃO DOS DADOS	165
	APÊNDICE D – CATEGORIAS DE SECAS	169

1 INTRODUÇÃO

O conhecimento da variabilidade climática de uma região se constitui em uma informação estratégica, no que concerne ao entendimento do comportamento de eventos extremos, tais como a seca. A seca é um fenômeno climático que pode provocar prejuízos de diferentes maneiras, afetando diversos setores da sociedade, como a economia e o ecossistema (Krol *et al.*, 2006; Santos *et al.*, 2010; Garrison, 2010; Hastenrath, 2012; Golian *et al.*, 2015). Este fenômeno é considerado a catástrofe natural mais grave quanto ao número de pessoas afetadas e prejuízos econômicos (Hao e AghaKouchak, 2013), por apresentar características peculiares em relação a outros desastres naturais, como a ausência de uma definição clara e difícil identificação do início e fim da seca (Mishra e Singh, 2010). Este fenômeno é a categoria de desastres naturais com maior registro de ocorrências no país (MMA, 2017).

1.1 JUSTIFICATIVA

Neste contexto, surge a necessidade de compreender o regime de secas em um determinado local, para diversos fins, como: caracterização do comportamento temporal e espacial, análise de recorrência e predição. Isso não é diferente para o Nordeste do Brasil, que é mais vulnerável a estes eventos, em relação às outras regiões do país, sobretudo na sua porção semiárida (Uvo *et al.*, 1998).

O Nordeste brasileiro está exposto a diferentes regimes de precipitação em termos espaciais. O Norte do Nordeste do Brasil (NNEB) é caracterizado por um período chuvoso (entre fevereiro e maio) com a alta variabilidade interanual (Uvo e Berndtsson, 1996; Uvo *et al.*; 1998) e nenhuma precipitação durante maior parte do período seco (outubro – dezembro). Por outro lado, o Leste do Nordeste brasileiro (LNEB) pode receber mais de 1500mm da precipitação anual e, durante a estação seca, apresentar alta variabilidade podendo variar em 250mm.

Muitos trabalhos têm sido desenvolvidos para analisar e caracterizar a variabilidade da precipitação no NNEB, na estação chuvosa (Uvo *et al.*, 1994; Kane, 1997; Uvo *et al.*, 1998; Andreoli e Kayano, 2004; Andreoli *et al.* 2004; Giannini *et al.*, 2004; Andreoli e Kayano, 2006; Freitas, 2009; Santos e Manzi, 2011; Hastenrath, 2012). No entanto, há um interesse crescente no entendimento da dinâmica da precipitação no Leste do Nordeste do Brasil (LNEB), podendo citar os estudos desenvolvidos por Rao *et al.*, 1993; Moura *et al.*, 2009; Da

Silva, 2009; Sansigolo e Reis, 2014; Amorim et al, 2014a; Amorim *et al.*, 2014; Costa, 2014; Guedes, 2016; Costa *et al.*, 2016; Alves, 2016; Da Silva, 2017. Todavia, estes estudos realizados no Leste do Nordeste do Brasil focam na estação chuvosa e, quando focam na estação seca, restringem-se à caracterização espaço-temporal da precipitação (Costa *et al.*, 2016) e às relações com índices de disponibilidade hídrica (Alves, 2016), deixando ainda dúvidas sobre como fenômenos globais podem influenciar no regime de precipitação da estação seca.

Diante disso, há a necessidade de investigar as relações climáticas entre os fenômenos globais atmosféricos e oceânicos com a variabilidade da precipitação da estação seca no Leste do Nordeste do Brasil e, a partir disso, introduzir uma nova ferramenta de apoio para previsão no período chuvoso, o qual é determinante para associação a eventos de seca. Para tal, foram selecionadas, com a área de estudo, as bacias do Rio Paraíba do Meio e Mundaú por apresentarem diversos estudos voltados para entender a variabilidade das componentes hidrológicas (Da Silva, 2009; Costa, 2014; Costa *et al.*, 2016; Alves, 2016) e, também, por representarem todo o gradiente longitudinalmente das condições climato-fisiográficas marcantes do Leste do Nordeste.

1.2 RELEVÂNCIA

No cenário de alterações climáticas, o estabelecimento de uma ferramenta para previsão da precipitação, em qualquer época do ano, tem o intuito de auxiliar na redução dos efeitos deletérios da seca, mitigando os impactos na economia, ecossistemas aquáticos e na sociedade. Mais especificamente para a estação seca e aplicando as características da região de estudo, podem-se destacar os seguintes pontos:

- Maior planejamento da colheita da cana-de-açúcar, haja vista que o ideal é realizar a colheita com condições secas e, se nesse período houver chuvas acima de normal, o produtor poderá postergar a colheita, respeitando-se o funcionamento da indústria. Ou ainda, antecipar a colheita e aproveitar a chuva “não esperada” para o período seco e realizar o replantio. Com isso, o agricultor poderá aproveitar melhor os recursos naturais e incrementar sua produção;
- Em relação à cultura de subsistência (em especial feijão e milho), a informação da ocorrência de chuvas superiores à média na estação seca poderá adiantar ou retardar o

seu cultivo ou até mesmo agir como forma de planejar adequadamente para produzir duas safras anuais;

- Na pecuária, a possibilidade de chuva em maior período do ano aumenta a disponibilidade de pastagens, o que diminui a necessidade de aquisição de ração para os animais, que gera uma economia adicional;
- Os índices de disponibilidade hídrica em corpos d'águas sem barramentos são regidos pelo comportamento da precipitação na estação seca, logo a previsão da chuva neste período dará subsídios para o atendimento dos usos consuntivos e não-consuntivos. Por exemplo: condições mínimas para diluição de efluentes, a sustentabilidade dos ecossistemas, a irrigação e o abastecimento de água para diferentes usos.

Complementarmente, pretende-se aqui vislumbrar uma nova perspectiva na previsão de secas, utilizando-se o artifício de compreender como se dá a variabilidade da precipitação no período seco e, num próximo passo, buscar relações com o comportamento da precipitação na estação chuvosa.

1.3 HIPÓTESE

Este trabalho levanta a hipótese se é possível proceder com a previsão derivada da precipitação do período seco no Leste do Nordeste do Brasil baseado apenas em índices climáticos globais e uso de modelos estatísticos.

1.4 OBJETIVOS

Diante disso, o trabalho tem o objetivo de propor um modelo híbrido de previsão para índices de seca nas bacias do rio Paraíba do Meio e Mundaú, a partir de índices climáticos globais. Para alcançar o objetivo geral proposto nesta tese, fez-se necessário atingir os seguintes objetivos específicos:

- Entender os processos responsáveis pela variabilidade da precipitação da estação seca;
- Caracterizar e analisar espacialmente e temporalmente a variabilidade da precipitação da estação seca nas bacias do rio Paraíba do Meio e Mundaú;

- Procurar relações estatísticas entre os índices decorridos da precipitação (na estação seca) e os índices climáticos;
- Desenvolver um modelo de previsão de precipitação no período seco baseados em técnicas estatísticas multivariadas, para uma porção do Leste do Nordeste.

1.5 ESTRUTURA DA TESE

O Capítulo 2 traz os conceitos relacionados à variabilidade climática, como índices climáticos e uma breve explanação de como se dá esta variabilidade na área de estudo. O Capítulo 3, por sua vez, faz um levantamento dos termos relacionados aos fenômenos das secas, com destaque para os índices de seca e uma revisão literária dos estudos que objetivam a previsão hidrológica.

O Capítulo 4 expõe as metodologias (ferramentas) utilizadas, iniciando-se com a caracterização da área de estudo, incluindo: o clima, a hidrografia e a vegetação. O Capítulo 5 mostra os resultados e a discussão da metodologia proposta no capítulo anterior. O Capítulo 6, por fim, apresenta as considerações finais acerca dos resultados obtidos com a pesquisa, evidenciando a importância da realização do trabalho. Ainda são listadas as referências, que serviram de aporte para a elaboração desta tese e a apresentação dos apêndices.

2 VARIABILIDADE CLIMÁTICA

A história conta que o Planeta Terra tem experimentado variações climáticas de diversas escalas, podendo reportar às escalas de milhões de anos ou escalas anuais e decadais. A força destas variações está relacionada a diferentes fenômenos, como: atividade tectônica, atividade vulcânica, alterações na taxa de irradiação solar devido à variação estelar e à própria dinâmica interna da Terra. A variação da dinâmica interna do planeta pode desempenhar a maior função na determinação da variabilidade do clima, na ausência de qualquer outra força dos vários elementos do sistema (Goosse *et al.*, 2010).

Molion (2008) afirma que o clima é um fenômeno sistêmico, dinâmico e natural produzido pelo sistema Sol-Atmosfera-Terra, ou seja, os sistemas atmosféricos na escala de tempo que atuam sobre determinada região constituem as componentes que definem o padrão climático local. A variação das diferentes componentes climáticas nas escalas temporais e espaciais, quer seja na sua frequência e intensidade, definem a variabilidade climática local (Silva, 2013). Nesta linha, Goosse *et al.* (2010) postulam que a atmosfera e a superfície do oceano são componentes climáticos mais ligados aos modos de variabilidade do clima.

Registra-se, no início do século XX, um grande avanço para o entendimento da variabilidade climática, ao considerar o comportamento do Oceano e sua interação com a atmosfera como um importante fator nos padrões climáticos em diferentes regiões do globo (Silva, 2013). Assim, estudos têm sugerido a associação entre a ocorrência de fenômenos localizados e a variabilidade local em regiões remotas (Silverman e Dracup, 2000; Ganguli e Reddy, 2013; Giannini *et al.*, 2004; Da Silva, 2009; Reis, 2015; Costa *et al.*, 2016).

A influência entre as condições físicas localizadas em climas de regiões remotas dá-se o nome de teleconexão climática. Segundo Silverman e Dracup (2000), teleconexões climáticas referem-se a um padrão recorrente e persistente de anomalias de uma determinada variável, que podem persistir por várias semanas ou meses e, algumas vezes, podem se tornar dominantes por vários anos consecutivos. Elas explicam como as anomalias de uma determinada região da Terra podem levar a fenômenos climáticos que ocorrem em outra parte do globo.

Importante destacar que o conhecimento do período de persistência pode indicar a viabilidade de previsões nas diferentes escalas, neste sentido, Santos e Franco (2011) apontam que, de modo geral, nos trópicos as teleconexões costumam persistir por semanas ou meses e, portanto, a previsibilidade nas escalas sazonais e mensais é mais factível.

As anomalias (variações no padrão) são monitoradas através de diversos indicadores denominados índices climáticos, uma vez que eles possibilitam resumir a intensidade dos modos conhecidos da variabilidade climática, que são relativamente bem descritos e compreendidos, tornando mais plausível a explicação da relação física envolvida entre sistemas atmosféricos de grande escala e variáveis hidroclimatológicas (Paz *et al.*, 2011).

2.1 ÍNDICES CLIMÁTICOS

Um índice climático é um valor que pode ser usado para descrever o estado e as alterações no sistema climático, permite análises estatísticas, tais como comparar séries de tempo, meios de estimativas e a identificação de *outliers* e tendências. Estes relacionam diversas componentes climáticas como pressão, temperatura da superfície do mar, precipitação, velocidade dos ventos, radiação solar, temperatura do ar e cobertura de gelo, entre outros (Reis, 2015).

Há uma variedade de índices descritos conforme pode ser visto no site <http://www.esrl.noaa.gov/psd/data/climateindices/list> do NOAA (*National Oceanic and Atmospheric Administration*), que são representativos dos diferentes padrões de variabilidade climática divididos entre os diferentes oceanos e para o globo como o todo. Reis (2015), para analisar a teleconexão climática na bacia do Rio Piancó, no semiárido brasileiro, analisou 42 índices climáticos, no entanto, alguns índices vêm ganhando destaque em estudos climáticos nas diferentes partes do globo, como: Índice de Oscilação Sul (SOI), Oscilação Decadal do Pacífico (PDO), Oscilação do Atlântico Norte (NAO) e Oscilação Multidecenal do Atlântico (AMO).

2.1.1 Índice de Oscilação Sul - IOS

Os ventos superficiais ao longo da maior parte do Pacífico Tropical se movem, normalmente, de forma zonal (de leste para oeste), esse movimento ocorre normalmente de uma área de alta pressão sobre o Pacífico Leste (próximos a Américas do Sul e Central) em direção à área que é, em geral, estável e com baixa pressão sobre o Pacífico Oeste (Norte da Austrália) (Garrison, 2010). Estas ondas de vento são responsáveis pela temperatura da superfície do mar mais quente no Oeste do Pacífico e, conseqüentemente, a ressurgência equatorial transporta água fria profunda de forma mais eficiente para o Leste do Pacífico. Devido a essas diferenças nas temperaturas da superfície do mar, convecção atmosférica e

movimento de ar ascendente são observadas sobre o Pacífico Ocidental, enquanto a subsidência ocorre ao longo do leste do Pacífico (Figura 1).

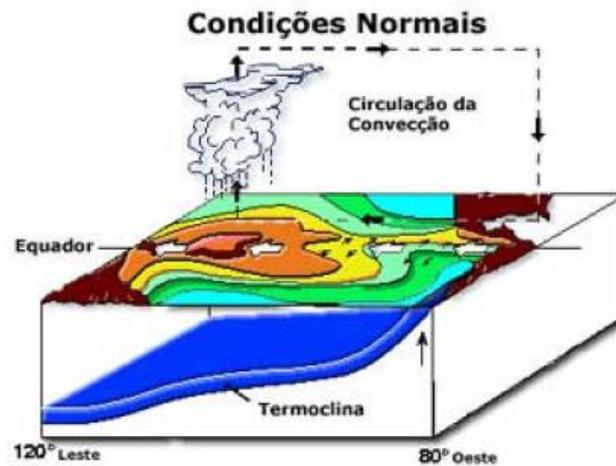


Figura 1 - Circulação do Pacífico Equatorial em Anos Normais.
(Fonte: Goosse *et al.*, 2010)

No entanto, por motivos ainda desconhecidos, segundo Goosse *et al.* (2010), as áreas de alta pressão mudam de lugar em intervalos irregulares que variam entre 3 a 8 anos. A alta pressão se desenvolve no Pacífico Oeste, e a baixa pressão passa a dominar no Pacífico Leste. Assim, os ventos através do Pacífico Tropical invertem sua direção e sopram de Oeste para Leste. Logo, a água quente que havia se acumulado no lado Oeste do Pacífico pode então se acumular no lado Leste (ou quase toda extensão do Pacífico Tropical), próximo à costa da América do Sul e Central, ocorrendo também a divisão, em duas, da célula de circulação sobre o oceano Pacífico (Figura 2).

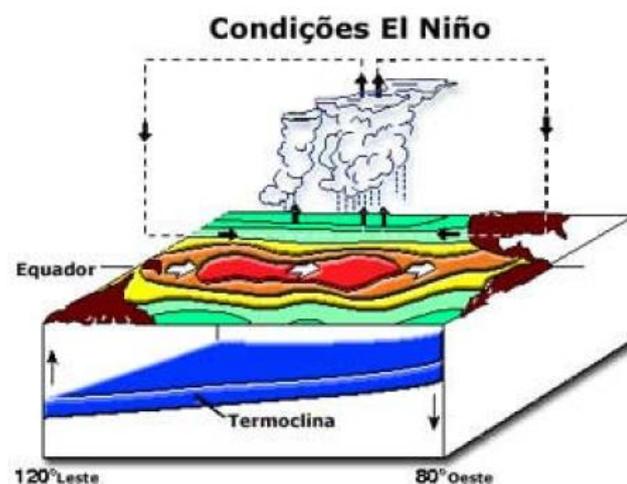


Figura 2 - Circulação do Pacífico Equatorial em Condições de El Niño
(Fonte: Goosse *et al.*, 2010)

Na verdade, o exposto, anteriormente, trata-se de dois fenômenos que são acoplados. O primeiro, relacionado às alterações dos campos de vento gerados pela mudança na pressão

atmosférica no Pacífico Tropical, denominado **Oscilação Sul**; e o segundo é relativo ao aquecimento das águas do leste do Pacífico Tropical, conhecido como **El Niño**¹. Portanto, estes fenômenos são, frequentemente, combinados para formar o acrônimo ENSO (El Niño/Oscilação Sul). Esta “gangorra”, na pressão do nível do mar (SLP) entre Leste e Oeste do Pacífico, que impulsiona os ventos, classicamente, pode ser mensurado pelo Índice de Oscilação Sul, dado pela equação 1.

$$SOI = \frac{SLP'_{Tahiti} - SLP'_{Darwin}}{\sigma_{ASLP}} \quad (1)$$

Em que: SLP'_{Tahiti} e SLP'_{Darwin} são, respectivamente, as anomalias da SPL no Taiti e em Darwin, Austrália (ou seja, a diferença entre valor corrente e a média de longo termo), e σ_{ASLP} é o desvio padrão da diferença entre essas duas anomalias na SLP. Quando o IOS é baixa, o gradiente médio de longo prazo entre o Leste e Oeste do Pacífico diminui, levando o vento do Leste mais fraco. Valores negativos prolongados do IOS são associados às correntes de vento no sentido oeste-leste e temperaturas da superfície anormalmente quentes, no Oriente Pacífico Equatorial. Quando as condições normais voltam com um vigor surpreendente, produzindo correntes fortes, ressurgências intensas e condições frias e tempestuosas ao longo da costa leste sul-americana, ou seja, ocorrendo as condições opostas ao El Niño, que por analogia, chama-se La Niña (Figura 3).

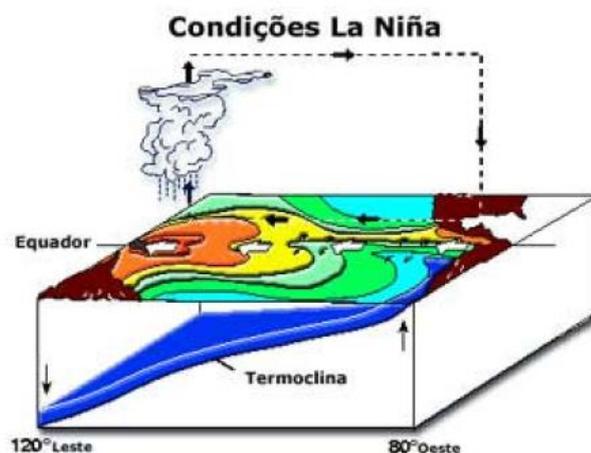


Figura 3 - Circulação do Pacífico Equatorial em Condições de La Niña
(Fonte: Goosse *et al.*, 2010)

Durante o evento de ENSO mais forte, a temperatura da água do mar no Pacífico Leste pode aumentar até 7°C. A água mais quente causa evaporação, e o ar úmido ascende, causando uma grande quantidade de precipitação em área que, normalmente, é seca,

¹ O fenômeno de aquecimento das águas ocorre normalmente à América do Sul na época de Natal, portanto os pescadores peruanos utilizavam a expressão *Corriente del Niño* (Corrente do Menino Jesus) para descrever este fluxo (Garrison, 2010).

intensificando as tempestades costeiras e a precipitação sobre a costa do Peru e Equador (Garrison, 2010). Os movimentos descendentes decorrentes da bipartição da célula de circulação (Figura 2) inibem a formação de nuvem e reduzem a precipitação (com secas em eventos de moderados à forte) no Nordeste e no Sul do Brasil, que devido ao bloqueio de frentes frias ocasionam episódios de enchentes moderadas a fortes (Aragão, 1998).

Picilli (2007) afirma que evento de El Niño e La Niña tem uma tendência a se alterar em um período da ordem de 3-7 anos. Já Da Silva (2009) assegura que o aquecimento e o subsequente resfriamento duram de 12 a 18 meses e que, no entanto, não existe um ciclo bem definido. Garrison (2010) verificou que onze ciclos do fenômeno de Oscilação Sul ocorreram desde 1950, sendo que os mais intensos ocorreram em 1982-1983 e 1997-1998. Os efeitos do ENSO não são sentidos apenas no Pacífico tropical (Costa Peruana, Indonésia e Nordeste da Austrália), mas são associados com perturbações em algumas partes do Oceano Atlântico e Índico, como Moçambique e Oeste dos Estados Unidos (Goosse *et al.*, 2010).

Segundo Goosse *et al.* (2010), ENSO é, provavelmente, o modo interno de variabilidade climática que mais provoca impacto nas atividades humanas. Como consequência, a previsão do seu desenvolvimento dentro de poucos meses é um avanço intenso na ciência, bem como suas relações nas componentes climáticas locais. Diante disso, nas últimas décadas, estudiosos têm procurado relacionar as alterações nos campos de ventos (e temperatura) do Pacífico tropical, mais especificamente utilizando o SOI, com as anomalias em diferentes partes do globo.

Deste modo, foram desenvolvidos modelos de previsão de seca utilizando, entre outros índices, o SOI, para a Califórnia (Silverman e Dracup, 2000) e a província de Teerã, Irã (Morid *et al.*, 2007). Labat (2010), ao realizar análises sobre as relações entre o clima e hidrologia nos diferentes continentes, utilizou SOI. Räsänen e Kummu (2013) buscaram encontrar a relação do ENOS nas características espaço-temporal da precipitação e vazão numa bacia do sudoeste da Ásia; Ganguli e Reddy (2013) usaram as teleconexões climáticas para desenvolver modelos de predição de seca numa bacia no Noroeste da Índia; e Yuan (2015) analisou os impactos da mudança do clima na hidrologia da Bacia *Yellow River*, na China. No sudeste da Europa, Briciu e Mihăilă (2014) verificaram a influência de oscilações climáticas, como o ENSO, nas vazões de rios de médio porte.

No Brasil, destacam-se estudos desenvolvidos no Sul-Sudeste do país (Picilli, 2007; Bravo, 2009; Santos e Franco, 2011; Paz *et al.*, 2011; Nascimento Jr, 2011); na Bacia do Rio São Francisco (Pinto, et al, 2006; Santos, 2011), na Amazônia (Yoon e Zeng, 2010) e no Nordeste (Da Silva, 2009; Costa, 2014; Reis, 2015; Costa *et al.*, 2016; Alves, 2016). Maiores

detalhes a respeito dos trabalhos desenvolvidos no Nordeste podem ser vistos no item 2.2 que trata da variabilidade climática na região de estudo.

2.1.2 Niños

Além do Índice de Oscilação Sul (SOI), existem índices que têm como base uma medida mais direta da anomalia da temperatura. Assim, o *The International Research Institute for Climate and Society* (IRI) definiu diversas regiões, conforme a Figura 4, no Oceano Pacífico Tropical, que são monitoradas para identificar mudanças nas variáveis como temperatura da superfície do mar (TSM), sendo mais comuns nas seguintes regiões (Kiem e Franks, 2001):

- Niño 1+2 (0° - 10° S; 80° - 90° W): A região que tipicamente aquece primeiro quando o El Niño se desenvolve;
- Niño 3 (5° S- 5° N; 150° W- 90° W): A região do Pacífico tropical, que tem a maior variabilidade na temperatura da superfície do mar sobre a escala temporal do El Niño;
- Niño 3.4 (5° S - 5° N; 170° W - 120° W): É a região que tem maior variabilidade às escalas de tempo do El Niño e é mais próxima (do que a do Niño 3) da região onde as mudanças na temperatura da superfície do mar locais são importantes para deslocar a região de precipitação localizada no Pacífico oeste;
- Niño 4 (5° S- 5° N; 160° E- 150° W): A região onde as mudanças na TSM conduzem a valores de aproximadamente $27,5^{\circ}$ C, o que é visto como um importante fator na produção de chuva.

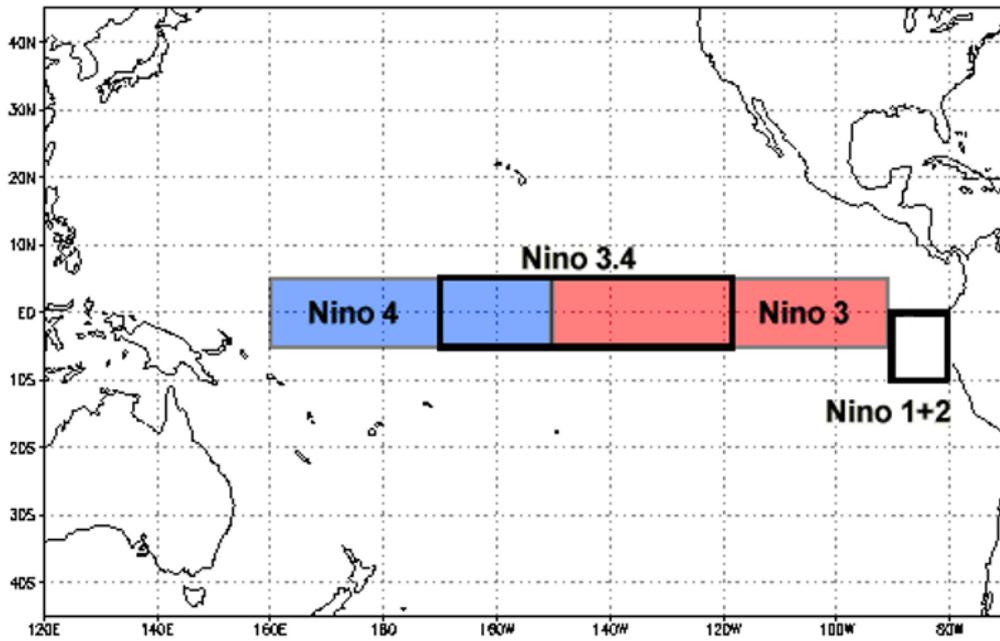


Figura 4 - Regiões dos Niños

(Fonte: http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/Niño_regions.shtml)

Assim, alguns autores têm procurado relacionar os comportamentos anômalos nas diferentes regiões dos Niños com a precipitação de diversos locais do Brasil, como o Rio Grande do Sul (Lopes, 2006), bacia do rio Pardo/Mogi-Guaçu (Paz *et al.*, 2011), na bacia do Alto do São Francisco (Pinto, 2005) e Pernambuco (Guedes, 2016). Entre as regiões do Niños, segundo Sansigolo e Reis (2014), o Niño 3.4 é, geralmente, escolhido por apresentar os principais centros de convecção do Pacífico Equatorial. Nesta linha, Labat (2010) utilizou este índice para entender o regime de vazão em todos continentes e, mais especificamente, Briciu e Mihăilă (2014), no sudeste da Europa. Quanto à precipitação no Brasil, procurou-se relacionar a variabilidade do Niño 3.4 com precipitações anômalas no Estado do Paraná (Teixeira e Martín-Vide, 2013) e Nordeste brasileiro (Sansigolo e Reis, 2014).

2.1.3 Oscilação Decenal do Pacífico - PDO

A oscilação decenal do Pacífico (PDO) é um fenômeno de interações oceano e atmosfera, caracterizado por anomalias da temperatura e pressão da superfície do nível do mar no Oceano Pacífico Norte e Central, próximo à costa oeste dos Estados Unidos (Mantua *et al.*, 1997). A PDO pode ser considerada como o padrão de variabilidade similar ao ENOS (Hare e Mantua, 2000) se constituindo como uma “gangorra” entre a Temperatura da Superfície do Mar (TSM) ao longo da costa oeste da América do Norte, em respeito ao restante da bacia do

Pacífico (Da Silva, 2009). Da mesma forma que o ENOS, a PDO apresenta fases frias e quentes, caracterizadas, respectivamente, por anomalias positivas e negativas da TSM, no Pacífico Extratropical, em ambos os hemisférios (Figura 5). No entanto, diferentemente do ENOS, os eventos de PDO persistem por 20 a 30 anos (Molion, 2005).

Com base na série de dados disponíveis, desde o início do século XX, Mantua et al (1997) encontrou evidências de que as fases frias da PDO ocorreram entre 1990 e 1924 e entre 1947 e 1976, e as fases quentes entre 1925 e 1946; e entre 1977 até meados da década de 1990. Portanto, a PDO parece ter entrado novamente em sua fase negativa, e o clima global poderá experimentar um resfriamento paulatino nos próximos 25 anos, com um consequente aumento (redução) da frequência de eventos La Niña (El Niño) (Da Silva, 2009), haja vista que, na fase positiva (negativa) da PDO, há a tendência de maiores números de intensos episódios de El Niño (La Niña) (Andreoli e Kayano, 2005).

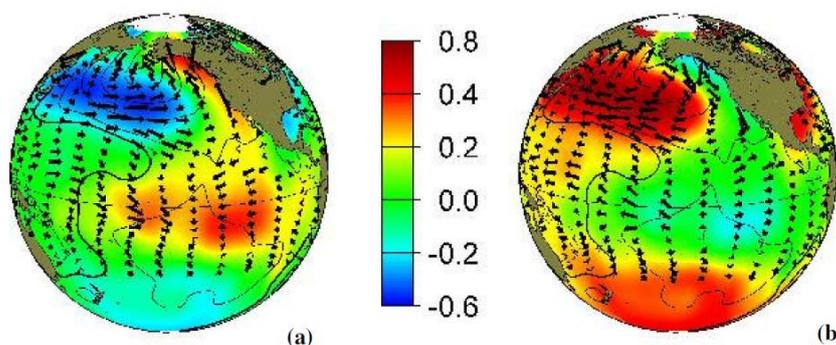


Figura 5 - Anomalias da Temperatura na Superfície do Mar (cores), da pressão do nível do mar (contornos) e da intensidade do vento na superfície, durante a fase (a) fria e (b) quente.

(Fonte: <http://research.jisao.washington.edu/pdo/graphics.html>)

Segundo Da Silva (2009), existem três tipos de índices que caracterizam o fenômeno PDO, sendo mais utilizado o índice proposto por Mantua *et al.* (1997) que deriva da primeira componente principal das anomalias da temperatura da superfície do mar, no Pacífico Norte, entre as latitudes 20° N e 90° N (pólo).

Segundo Mantua *et al.* (1997), os reflexos da PDO são mais claros durante a estação de inverno no Noroeste da América do Norte, no entanto, alguns pesquisadores buscaram correlação com o clima em outros locais do Planeta (Labat, 2010), sobretudo da América do Sul (Pezza e Ambrizzi, 2005; Kayano e Andreoli, 2005). Por isto, tem existido motivação para desenvolver trabalhos no intento de sugerir as teleconexões climáticas geradas pelo PDO no Brasil (Da Silva, 2009; Bravo, 2009; Prado, 2010; Silva, 2013; Nascimento Jr, 2011; Santos, 2011; Paz *et al.*, 2011; Alexandre, 2012; Costa *et al.*, 2016), Europa (Briciu e Mihăilă, 2014) e Ásia (Ganguli e Reddy, 2014).

2.1.4 Índice Oscilação do Atlântico Norte - NAO

O índice de Oscilação do Atlântico Norte (NAO) mensura o fenômeno homônimo que, segundo Greatbatch (2000), é considerado o mais importante modo de variabilidade atmosférica sobre o Oceano Atlântico Norte, desempenhando um enorme papel na variabilidade climática do Leste da América do norte e na Europa Continental.

O fenômeno foi identificado, primeiramente, por Gilbert Walker, na década de 1920, que o definiu como a diferença acentuada de pressão entre Açores e a Islândia, que está associada com a magnitude da corrente do Golfo, altas temperaturas no inverno e outono na Escandinávia e costa leste dos Estados Unidos, e com as baixas temperaturas na costa leste do Canadá e o oeste da Groelândia (Greatbatch, 2000), ocasionadas pelas mudanças no transporte de calor e umidade entre o Oceano e os continentes próximos (Hurrell, 1995). Em resumo, a Oscilação do Atlântico Norte é caracterizada pela circulação atmosférica de larga escala nas latitudes médias (40°N – 60° N) do Atlântico Norte, dado pela intensidade dos ventos de oeste que cruzam o Oceano Atlântico Norte (Goosse *et al.*, 2010).

A intensidade deste modo de variabilidade é dada pela diferença normalizada da pressão da superfície do mar entre duas estações meteorológicas que representam a faixa das latitudes médias boreais. A normalização, segundo Goosse *et al.* (2010), é feita para identificar as anomalias da pressão de cada estação a partir dos desvios padrão de longo termo. Deste modo, Hurrell (1995) definiu o índice para retratar este fenômeno como a diferença entre a média normalizada no inverno (dezembro a março) das anomalias de pressão do nível do mar (SLP) de Ponta Delgadas, Açores e Akureyri, Islândia, considerando o período para estatísticas médias (desvio padrão) no período de 1864 a 1994, podendo representá-lo pela equação 2.

$$NAO_{index} = \frac{SLP'_{Açores}}{\sigma_{Açores}} - \frac{SLP'_{Islândia}}{\sigma_{Islândia}} \quad (2)$$

Onde $SLP'_{Açores}$ e $SLP'_{Islândia}$ são as anomalias da SPL em Açores e na Islândia, enquanto que $\sigma_{Açores}$ e $\sigma_{Islândia}$, os desvios padrão destas anomalias.

Apesar deste fenômeno ser observado durante todo o ano, a sua amplitude e seus efeitos são maiores no inverno do Hemisfério Norte (Uvo, 2003) quando a atmosfera é mais dinamicamente ativa, portanto, tem-se dado mais atenção ao período de inverno. Altas taxas (positivas) do NAO no inverno estão associadas a ventos de Oeste mais fortes e condições mais secas nas regiões Central e Sul da Europa, e úmidas sobre a Islândia e Escandinávia,

(Goosse *et al.*, 2010; Greatbatch, 2000) conforme Figura 6. Portanto, observa-se que o entendimento da variabilidade do NAO constitui informação considerável nas condições socioeconômicas do continente europeu.

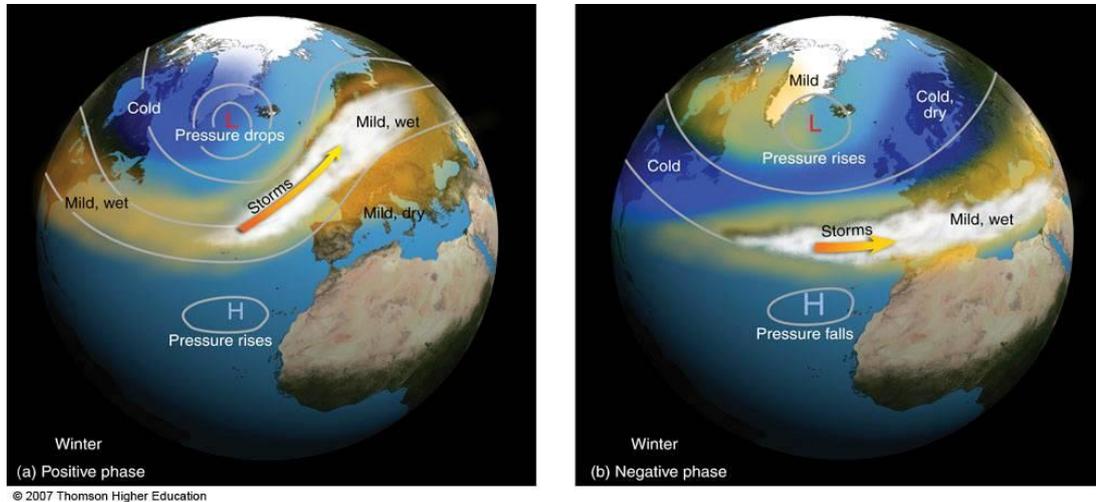


Figura 6 - Estrutura dinâmica da fase positiva e negativa do NAO.
(Fonte: <http://apollo.lsc.vsc.edu/classes/met130/notes/chapter10/nao.html>)

Diante disso, diversos estudos têm sido desenvolvidos para compreender o comportamento do fenômeno e seus reflexos nas componentes climáticas no Atlântico Norte (Czaja e Frankignoul, 1999; Czaja e Frankignoul, 2002; Czaja *et al.*, 2002), na precipitação do Sul da Europa (Rodó *et al.*, 1997), Norte da Europa (Uvo, 2003) e vazões em rios europeus (Massei e Fournier, 2012). Ainda assim, alguns estudos têm-se desenvolvidos na busca de uma relação entre a Oscilação do Atlântico Norte e variáveis hidrológicas em outros continentes (Morid *et al.*, 2007; Labat, 2010; Sun *et al.*, 2015) e, mais especificamente, no Brasil, podendo destacar locais como a bacia do Alto Paraguai (Piccilli, 2007), do Rio Grande, com objetivo de subsidiar o planejamento e operação de reservatórios para geração de energia (Bravo, 2010), bacia do rio Pardo/Mogi-Guaçu, para planejamento agrícola (Paz *et al.*, 2011), e mais recentemente nas bacias dos Rios Paraíba e Mundaú (Costa *et al.*, 2016; Alves; 2016).

2.1.5 Oscilação Multidecenal do Atlântico – AMO

A oscilação multidecadal do Atlântico (AMO) é um modo de escala quase global da variabilidade multidecadal observada, alternando fases (anomalias de temperaturas) quentes e frias em grandes partes do hemisfério Norte (Knight *et al.*, 2006), que provoca interações entre a circulação termohalina e a atmosfera no Atlântico Norte e interações entre o oceano e

atmosfera no Pacífico Norte (Dima e Lohmann, 2007). Estudos espectrais (Minobe, 1997) sugerem que as mudanças destes regimes prevalecem com oscilações entre 50 e 70 anos sobre o oceano Pacífico e Atlântico Norte, no século XVIII até o presente (Enfield *et al.*, 2001). O índice que retrata este fenômeno pode ser definido como o primeiro eixo rotacionado das componentes principais do campo de temperatura da superfície do mar nas condições neutras (não-ENOS) (Dima e Lohmann, 2007).

Este fenômeno está associado às variações multidecadais na temperatura da superfície do oceano Atlântico, em particular, precipitação no Nordeste brasileiro e Sahel africano, furacões do Atlântico e no verão da Europa e América do Norte, haja vista que fases quentes (frias) da OMA coincidiram a diminuição (aumento) da precipitação no NEB e de vazões nos Estados Unidos, como também o aumento (diminuição) da precipitação do Sahel africano e das formações de furacões (Knight *et al.*, 2006). A teleconexão no nordeste brasileiro pode ser explicada pela posição anômala da Zona de Convergência Inter-Tropical (ZCIT) influenciada pela fase da AMO, dado que a ZCIT mais ao norte (fase quente) diminui a precipitação durante a estação chuvosa do norte do Nordeste do Brasil, enquanto que na fase fria a ZCIT está mais ao sul, e isto implica índices pluviométricos maiores (Uvo, 1989).

Alguns estudos têm procurado entender como este fenômeno pode influenciar a precipitação e vazões nos Estados Unidos (Mo *et al.*, 2009, Enfield *et al.*, 2001) e diversos locais do Brasil, como a Bacia Amazônica (Santos *et al.*, 2013), Estado de São Paulo (Prado, 2010) e Nordeste brasileiro (Costa *et al.*, 2016; Alves, 2016); além de subsidiar a previsão climática em diferentes regiões do Planeta (Ganguli e Reddy, 2014; Alexandre, 2012; Costa, 2014).

2.1.6 Modo Meridional do Atlântico – AMM

O modo dominante na variabilidade interanual e decadal do Atlântico tropical é caracterizado pela anomalia meridional da temperatura da superfície do mar nas latitudes próximas ao Equador, que leva a superfície dos ventos para as águas mais quentes e desloca a precipitação (Nobre e Shukla, 1996), conforme pode ser visto na Figura 7. Este índice está relacionado a um fenômeno oceano-atmosfera conhecido como Dipolo do Atlântico, definido, segundo Aragão (1998), como uma mudança anômala na temperatura da água do mar no Oceano Atlântico Tropical (20°N-5°N e 5°S-20°S), que muda a circulação meridional da atmosfera (célula de Hadley) e inibe a formação de nuvens sobre o Nordeste do Brasil e alguns países da África, podendo apresentar variabilidade nas escalas sazonal, interanual e

decadal (Moura *et al.*, 2009). Quando as águas do Atlântico Norte estão mais quentes (frias) que as águas do Atlântico Equatorial e Tropical Sul existem movimentos descendentes (ascendentes) anômalos sobre o Nordeste do Brasil e a África Oriental, inibindo (possibilitando) a formação de nuvens e diminuindo (aumentando) a precipitação.

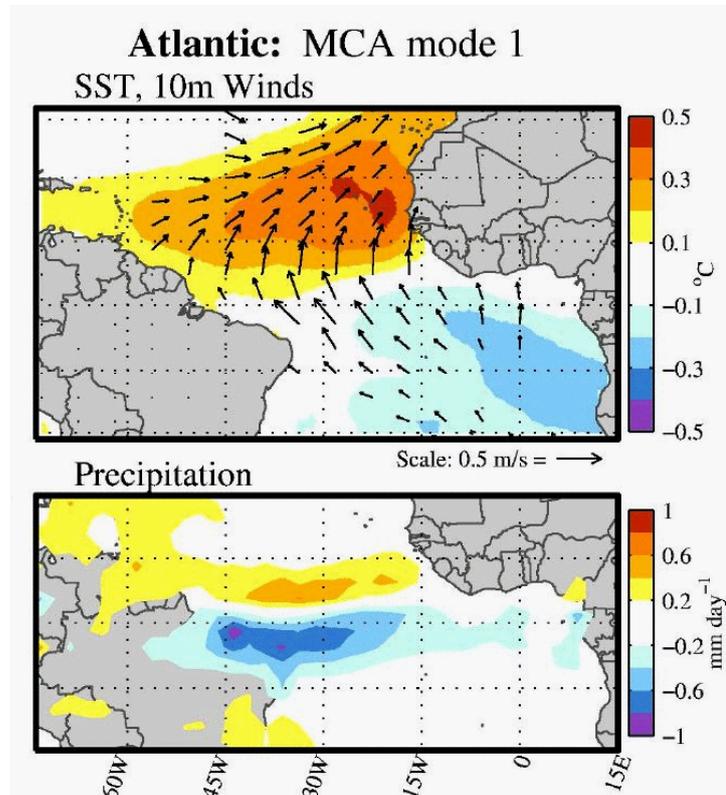


Figura 7 - Mapa de regressão do modo da AMC correspondente a TSM normalizada e vetor de velocidade do vento. Os vetores do vento são plotados de forma que a soma geométrica dos coeficientes de correlação exceda 0.27 (95% de nível de confiança), e mapas de anomalia. (Fonte: Chiang e Vimont, 2004)

Assim, o índice Modo Meridional do Atlântico, visando retratar este fenômeno, é caracterizado pela aplicação da Análise de Máxima Covariância (AMC) ao campo de temperatura da superfície do mar (AMM_sst) e à componente zonal e meridional dos campos de ventos a 10 metros (AMM_wind), no período de 1950-2005, a partir de dados de reanálise do NCEP/NCAR localizados na faixa de latitudes 21S-32N e longitudes 74W-15E (Chiang e Vimont, 2004).

Durante a fase positiva do AMM, quando as águas estão mais quentes que o normal e os ventos mais fracos, a ZCIT é deslocada para o norte, causando secas no Nordeste do Brasil (Chiang e Vimont, 2004). Condições opostas são encontradas na fase negativa do AMM. Além da precipitação, AMM afeta o desenvolvimento de ciclones tropicais no Atlântico Norte (Kossin e Vimont, 2007). Desta forma, estudos do comportamento deste modo meridional e seus efeitos têm sido desenvolvidos, podendo destacar o de Foltz *et al.* (2012), que analisaram

o evento (MMA) de 2009 e relacionou com as enchentes no Nordeste do Brasil. Alguns autores têm mostrado, ainda, a interação entre o AMM e o ENOS na variabilidade climática (Foltz e McPhaden, 2010; Patricola *et al.*, 2014).

2.1.7 Outros índices

Kiem e Franks (2001) afirmam que alguns índices que carregam medida mais direta da temperatura de área do Pacífico Tropical indica um grau de incerteza onde o ENSO deve ser mensurado, surgindo, então, outro indicador do ENSO, denominado Índice Multivariado do ENSO (MEI), que é calculado usando seis variáveis principais observadas no Pacífico tropical: pressão ao nível médio do mar, componente zonal e meridional do vento em superfície, Temperatura da Superfície do Mar, temperatura do ar em superfície e uma fração de nebulosidade. No Brasil, o MEI foi utilizado para buscar a relação com a precipitação no Rio Grande do Sul (Lopes, 2006) e na Bacia do Rio Mundaú (Da Silva, 2009).

Todos índices climáticos citados levam em consideração a anomalia das diversas componentes climáticas, geralmente, em regiões tropicais. No entanto, alguns índices representam a variabilidade destas componentes nas regiões de latitudes maiores, como o Modo Anular do Hemisfério Sul (SAM) ou Oscilação Antártica (AAO), que se refere à alternância de massa atmosférica em grande escala, entre as latitudes médias e altas do hemisfério sul (Gong e Wang, 1999) e tem sua intensidade calculada pela diferença no valor médio zonal normalizado da pressão do nível do mar entre as latitudes 40°S e 70°S (Nan e Li, 2003); e o seu equivalente no Hemisfério Norte, denominado Modo Anular do Hemisfério Norte (NAM) ou Oscilação Ártica (OA) (Goosse *et al.*, 2010). Estes índices anulares têm sido investigados no intuito de encontrar teleconexões climáticas, sobretudo com regiões de altas latitudes (Bravo, 2010; Labat, 2010; Santos e Franco, 2011; Briciu e Mihăilă, 2014).

Existe ainda uma gama de índices climáticos que visa representar oscilações em diferentes locais do Planeta, como o Dipolo do Oceano Índico (IOD) (Ganguli e Reddy, 2013), Oscilação Escandinávia (ScandO) (Olsson *et al.*, 2011), Oscilação do Atlântico Leste/Oeste da Rússia (EAWRO), Oscilação do Pacífico/ Norte América (PNAO), Oscilação Eurásia/Polar (PEO) e Oscilação do Pacífico Oeste (WPO) (Briciu e Mihăilă, 2014).

2.2 VARIABILIDADE CLIMÁTICA NO LESTE DO NORDESTE BRASILEIRO

O Nordeste brasileiro (NEB) experimenta altas intensidades de eventos hidrológicos extremos e uma grande variabilidade interanual da precipitação (Giannini *et al.*, 2004). De modo geral, a variabilidade da precipitação no NEB pode ser explicada pela combinação dos fenômenos ENSO e dipolo do Atlântico (Aragão, 1998; Ferreira e Melo, 2005) que modificam a frequência, distribuição espacial e intensidade de sistemas atmosféricos como: Zona de Convergência Intertropical (ZCIT), os Vórtices Ciclônicos de Ar Superior (VCAN), os Sistemas Frontais, Brisas Marítimas e Terrestre e os Distúrbios de Leste (Molion e Bernardo, 2002; Ferreira e Melo, 2005; Da Silva, 2009; Hastenrath, 2012; Amorim *et al.*, 2014).

Diferentes regimes de precipitação podem ser encontrados no NEB. Em termos espaciais, os valores acumulados anuais de precipitação podem totalizar apenas 300mm na porção semiárida e 2000mm na zona litorânea (Amorim *et al.*, 2014; Campos, 2015; Cunha *et al.*, 2015). Na escala temporal, o Norte do Nordeste do Brasil (NNEB) é caracterizado por um período chuvoso (entre fevereiro e maio), com a alta variabilidade interanual (Uvo e Berndtsson, 1996; Uvo *et al.*; 1998) e nenhuma precipitação durante maior parte do período seco (outubro – dezembro), por outro lado, o Leste do Nordeste brasileiro (LNEB) pode receber mais de 250mm da precipitação durante a estação seca.

Muitos estudos têm destacado a relação do ENSO e do Dipolo do Atlântico nos sistemas climáticos que determinam a variabilidade da precipitação no NNEB, na estação chuvosa (Uvo *et al.*, 1994; Kane, 1997; Uvo *et al.*, 1998; Andreoli e Kayano, 2004; Andreoli et al. 2004; Giannini *et al.*, 2004; Andreoli e Kayano, 2006; Freitas, 2009; Santos e Manzi, 2011; Hastenrath, 2012). No entanto, há um interesse crescente no entendimento da dinâmica da precipitação no Leste do Nordeste do Brasil (LNEB).

O principal produtor de chuvas no LNEB estaria ligado à maior atividade de circulação de brisa que carrega bandas de nebulosidade para o continente; à ação das frentes frias, ou seus remanescentes, que se propagam ao longo da costa; à máxima convergência dos Alísios com a brisa terrestre; à Zona de Convergência do LNEB (ZCEN) alimentada pela convergência de umidade dos Alísios e às Perturbações Ondulatórias Nos Ventos (POAS) que, por sua vez, associam-se à topografia e à convergência de umidade (Molion e Bernardo, 2002; Reboita *et al.*, 2010).

Em busca de uma relação entre os fenômenos anormais de precipitação do Leste do Nordeste com fenômenos globais, Rao *et al.* (1993) verificou correlações positivas entre a

anomalias da SST do sudeste do Atlântico, entre janeiro e abril, com as anomalias de precipitação desta região. Observa-se, então, que tanto o Outono (Sansigolo e Reis, 2014) ou Inverno Austral (Amorim *et al.*, 2014a; Costa, 2014) podem ser afetados por anomalias da temperatura da superfície do mar (TSM) dos oceanos Pacífico e Atlântico Tropicais. No entanto, pode-se encontrar uma correlação maior da precipitação da estação chuvosa do LNEB com TSM do Atlântico, do que com a TSM do Pacífico (Moura *et al.*, 2009; Guedes, 2016). Moura *et al.* (2009) mostraram que anomalias positivas de TSM no Atlântico Tropical sul produzem precipitação sobre LNEB, enquanto anomalias positivas de TSM no Pacífico inibem e que a TSM do Atlântico Norte possui correlação negativa com a precipitação indicando estar relacionada com atividades de bloqueio que induzem secas.

Amorim *et al.* (2014), analisando o período de abril a junho, verificaram que quando o Oceano Atlântico Sul é mais quente, as condições oceânicas e atmosféricas são favoráveis a uma maior precipitação mensal perto do LNEB, além disso, esses autores sugerem que os fenômenos climáticos remotos contribuem mais na distribuição espacial do que na intensidade da precipitação.

Na bacia do rio Mundaú, Da Silva (2009) encontrou escalas dominantes de oscilação na precipitação da quadra chuvosa, na ordem de 22 a 11 anos, o que sugere escalas temporais maiores de mecanismos meteorológicos dominam sobre fenômenos de escalas menores. Além disso, esta mesma autora observou mais eventos de anomalia positiva de precipitação na porção litorânea desta bacia, no período antes de 1974 (fase fria do PDO). Guedes (2016) mostrou a ocorrência de eventos mais prolongados de secas ao analisar os déficits hídricos acumulados na ordem de 24 a 60 meses, o que indica a influência de mecanismos mais duradouros (ex.: PDO) sobre a precipitação daquele estado.

Alves (2016) constatou que as teleconexões climáticas atuantes nos oceanos Atlântico e Pacífico influenciam a variabilidade da disponibilidade hídrica (Q_{90} , Q_{95} e Q_7) na Bacia do Rio Mundaú. Costa *et al.* (2016) observaram que as condições climáticas têm papel secundário na variabilidade da precipitação na estação seca (outubro a dezembro) do LNEB, no entanto, os eventos anômalos neste período podem ser governados pelas condições do Oceano Atlântico e Pacífico Tropical. Diante disso, Rao *et al.* (1993) e Sansigolo e Reis (2014) afirmam que a alta previsibilidade do ENSO e seu significativo impacto nas precipitações da região provêm uma fonte de previsibilidade da variabilidade sazonal das suas anomalias em relação à climatologia.

2.3 RESUMO DO CAPÍTULO

É fato que o clima do Planeta sofre variações de diferentes escalas (anuais, decadais, multidecadais) e esta variação pode provocar impactos na hidrologia em diversas regiões, sendo importante investigar mecanismos de associação destes fenômenos em regiões remotas. Diversas estratégias são adotadas, entre elas, o uso de índices climáticos que são indicadores de anomalias de componentes climáticas dos Oceanos para diferentes escalas temporais. Assim, diversos modelos têm sido desenvolvidos para associar esses índices com fenômenos anômalos no clima em diversas partes do mundo, não sendo diferente para LNEB. No entanto, os estudos realizados no Leste do Nordeste do Brasil focam na estação chuvosa, deixando ainda dúvidas sobre como fenômenos globais podem influenciar no regime de precipitação da estação seca.

3 OS FENÔMENOS DAS SECAS

Segundo Freitas (2009), não existe uma definição geral e universal para o fenômeno da seca. Mishra e Singh (2010) relatam 7 diferentes definições que, basicamente, trazem à tona questão de um nível limiar de uma determinada variável (precipitação, vazão ou umidade do solo) ou combinação dessas variáveis utilizadas na descrição da seca. De modo geral, as secas estão relacionadas à redução da quantidade de precipitação recebida durante um período de tempo, que pode ter curta, média ou longa duração; possui recorrência e é inevitável (Mishra e Desai, 2005).

Mishra e Singh (2010) enfatizam ainda que temperaturas, ventos fortes, baixa umidade relativa, características de chuvas incluindo a sua distribuição em dias durante cultura em desenvolvimento, intensidade e duração da chuva, e início e término desempenham um papel significativo na ocorrência de secas. Deste modo, a definição de seca pode ser classificada sob diferentes categorias, as quais seguem:

- Seca meteorológica: baseada em condições atmosféricas regionais, caracteriza-se pela falta de água induzida pelo desequilíbrio entre a precipitação e evaporação;
- Seca agrícola: caracterizada pela falta de umidade que afeta o desenvolvimento e/ou sobrevivência de culturas agrícolas, pastoris e florestais. A variação do grau de umidade do solo depende não apenas da precipitação, mas também da demanda por água das culturas;
- Seca hidrológica: referente às deficiências no suprimento de água superficial ou subterrânea; ocorrem quando há existência de secas meteorológicas de longa duração, acrescido de uma redução dos níveis de água subterrânea e consequente deplecionamento dos reservatórios, lagos e poços;
- Seca socioeconômica: ocorre quando o déficit de água induz a falta de bens ou serviços (energia elétrica, alimentos, etc). Pode ser vista não como um tipo de seca, mas simplesmente como consequência dos outros tipos de seca definidos anteriormente.

As secas são um fenômeno natural que se diferem nitidamente das demais catástrofes naturais, devido aos seguintes fatores (Freitas, 2009; Mishra e Singh, 2010):

- O início e o fim de uma seca são difíceis de determinar. Os impactos de uma seca aumentam lentamente, muitas vezes se acumulam ao longo de um período

considerável e podem durar anos, muitas vezes espalhando-se por uma extensa área;

- A própria ausência de uma definição, precisa e universalmente aceita de seca, leva à confusão da existência ou não dela e, em caso afirmativo, da sua gravidade;
- As atividades humanas podem acionar diretamente uma seca, como irrigação excessiva, o desmatamento, a sobre-exploração da água disponível, e erosão, impactando negativamente a capacidade da terra para capturar e reter a água.

As secas tem potencial impacto na sociedade, meio ambiente e economia (Krol *et al.*, 2006; Santos *et al.*, 2010; Garrison, 2010; Hastenrath, 2012; Golian *et al.*, 2015), sendo considerada como a catástrofe natural mais grave quanto a número de pessoas afetadas e prejuízo econômico (Hao e AghaKouchak, 2013). Recentemente, as secas parecem ter ocorrido com uma frequência e intensidade cada vez maior, em grande parte os países e consideráveis extensões de terra da Europa, África, Ásia, as América e a Austrália foram atingidas por secas extremas provocando prejuízos diversos (Freitas, 2009; Mishra e Singh, 2010).

No Brasil, o Nordeste é a região conhecida como a mais exposta aos maiores eventos de seca (Uvo *et al.*, 1998), notadamente na sua porção semiárida, com sérias implicações sociais e econômicas sobre 20 milhões de pessoas (IBGE, 2010). Os piores indicadores econômicos e sociais do Brasil podem ser encontrados nesta parte do país (PNUD, 2013; Sena *et al.*, 2014; Cunha *et al.*, 2015) devido, entre outros fatores, à ausência de políticas de planejamento e gestão de secas nas instituições brasileiras. Os últimos episódios de secas ocorridos no NEB foram em 1981 a 1983, 1992 a 1993, de 2002 a 2003 (Freitas, 2009) e mais recentemente em 2012, até os dias atuais (Campos, 2015; Cunha *et al.*, 2015).

Para uma análise detalhada da problemática da seca, faz-se necessário abordar, entre outros aspectos, sua distribuição espacial e política de mitigação nos seus efeitos. Posto que o fenômeno das secas não se restringe a uma pequena área ou região, o conhecimento da sua distribuição espacial e seus efeitos torna-se de grande importância (Freitas, 2009). Numa análise da seca regional, os padrões espaço-temporal devem ser investigados em diferentes escalas com base em diferentes limiares. Informações sobre as características de seca regionais são críticas e devem ser incorporadas em suma estratégicas, bem como a gestão dos recursos hídricos, em longo prazo (Muñoz-Díaz e Rodrigo, 2004; Santos *et al.* 2010; Costa *et al.*, 2016).

AghaKouchak (2015) afirma que existe um consenso da importância dos planos de mitigação dos efeitos da seca para reduzir os impactos decorrentes deste fenômeno, no entanto, segundo Mishra e Singh (2011), diversos países mostram-se inabilitados a implementar medidas para o efetivo plano de mitigação, como: desenvolvimento de um modelo de previsão de secas preciso, eficientes instrumentos de monitoramento do início, duração e fim do período das secas, adequado modelos de geração de vazão para rios intermitentes e implementação de sistema de alerta de secas com contínuo monitoramento.

Verifica-se a complexidade em reconhecer um período de seca e, conseqüentemente, acionar as medidas mitigadoras. Uma boa solução seria o emprego de indicadores de seca, que tem o objetivo de avaliar o efeito de uma seca e definir diferentes parâmetros, que incluem intensidade, duração, gravidade e extensão espacial.

3.1 ÍNDICES DE SECAS

Os índices de seca são indicadores capazes de quantificar (magnitude, severidade e extensão espacial) a seca em diferentes escalas, consiste em equações que incluem variáveis meteorológicas e hidrológicas que, em conjunto com procedimentos estatísticos, expressam numericamente a seca (Barra *et al.*, 2002), são capazes de avaliar o efeito de uma seca e definir diferentes parâmetros. O elemento mais básico para a determinação deste parâmetro é a identificação do seu nível limiar, que pode ser constante e ou em função do tempo (Mishra e Singh, 2010).

Albuquerque (2010) afirma que os índices de seca podem ser classificados de acordo com a categoria de secas que o definem, a saber: a) índices de secas meteorológicas associados às variáveis climatológicas como precipitação, temperatura e evaporação. Estes índices têm relação direta com as anormalidades da precipitação e seus quantis; b) índices de secas hidrológicas: representam variações nos níveis de água subterrânea, vazão e armazenamento de reservatórios; c) índices de secas agrícolas: no seu cálculo são considerados fatores relacionados a cultivo e propriedades dos solos, como umidade e evapotranspiração refletindo os impactos na agricultura; d) índices de seca socioeconômica: que inferem os impactos socioeconômicos decorrentes do déficit de água.

Inúmeros índices têm sido desenvolvidos para quantificar uma seca, nesta linha, Mishra e Singh (2010) citaram 17 diferentes indicadores de secas. Neste mesmo ano, Vicente-Serrano *et al.* (2010) apresentaram um índice de seca multiescalar (SPEI), e em 2013 foi a vez de Hao e AghaKouchak (2013) que propuseram um índice multivariado de seca (MSDI).

Mais recentemente, Wu *et al.* (2015) apresentou o índice integrado de seca de superfície (ISDI) que integra índice de vegetação com temperatura da superfície do Planeta. A compilação de todos estes índices e a classificação dos mesmos se encontram na Tabela 1.

Tabela 1- Índices de Seca Utilizados: Categorias

Categorias	Índices de Seca
Meteorológica	índice de anomalia da chuva (IAC), Decilis, o índice de precipitação nacional (NRI), índice de precipitação padronizada (SPI), índice de seca de Bhalme e Mooly (BMDI), índice de precipitação e evapotranspiração padronizado (SPEI), Precipitação Efetiva (EP), monitor de Secas (DM), índice de severidade Herbst (HSI), índice de precipitação Lamb (LRDI).
Hidrológica	índice de recuperação de seca (IDI), índice de precipitação padronizada (SPI) e índice de escoamento padronizado (SRI)
Agrícola	índice de umidade da cultura (CMI), índice de seca da umidade do solo (SMDI ou SSI), índice de seca de cultura específica (CSDI), índice de severidade de seca de Palmer (PDSI), índice do déficit de evapotranspiração (ETDI), índice da diferença de água normalizada (NDWI), índice de precipitação padronizada (SPI), índice padronizado de seca multivariado (MSDI), índice integrado de seca de superfície (ISDI).
Socioeconômica	Índice de suprimento de água superficial (SWSI)

Fonte: Adaptado de Mishra e Singh (2010); Vicente-Serrano et al (2010); Hao e AghaKouchak (2013)

No Brasil, mais recentemente, foi criado um índice de vulnerabilidade contra as secas, composto por variáveis e subíndices que fazem sua representação em três dimensões: climática; socioeconômica e físico-ambiental (BRASIL, 2017). Rossato *et al.* (2017) utilizaram o índice de severidade de seca de Palmer (PSDI) para avaliar os impactos da seca no Brasil e concluíram que este índice constitui uma ferramenta importante para associar com informações econômicas e sociais para gerar mapas de riscos para subsídios aos tomadores de decisão.

Como o foco deste trabalho não é descrever os inúmeros índices de secas, os mesmos não serão detalhados. Aqui, foi selecionado o Índice de Precipitação Padronizada (SPI) para a caracterização das secas na região de estudo. Esta preferência decorre de diversas características deste índice que serão explicitadas no próximo item.

3.1.1 Índice Padronizado de Precipitação – SPI

O SPI foi proposto McKee *et al.* (1993), é um índice de seca que quantifica o excesso ou déficit de precipitações acumulados para qualquer escala de tempo, a partir da precipitação

padronizada². Seu cálculo é baseado em quantis da distribuição Normal Padrão (distribuição normal com média igual a zero e desvio padrão igual a um) e nas probabilidades associadas a esses quantis, para tal, tradicionalmente, é ajustada a função de distribuição de probabilidades Gama. A descrição do procedimento de cálculo do SPI está contida no item 4.4, da metodologia utilizada neste trabalho.

McKee *et al.* (1993) apresentaram, arbitrariamente, a categorização das intensidades da seca, no entanto, Agnew (2000) afirma que o SPI não tinha sido largamente aplicado e testado para as classes sugeridas por McKee *et al.* (1993), então propôs uma classificação alternativa com valores limiares mais racionais, que se mostraram com maior sensibilidade na demarcação de secas leves e moderadas. Desta forma, a Tabela 2 traz as diferentes classificações da intensidade da seca, baseado no SPI, para McKee *et al.* (1993) e Agnew (2000).

Tabela 2 - Categorias de Seca de acordo com o valor do SPI.

Classificação de Seca	SPI (McKee et al, 1993)	SPI (Agnew, 2000)
Extremamente Úmido	> 2,00	> 1,65
Severamente Úmido	< 2,00 e > 1,50	< 1,65 e > 1,28
Moderadamente Úmido	< 1,50 e > 1,00	< 1,65 e > 0,84
Normal	>-1,00 e <1,00	>-0,84 e <0,84
Moderadamente Seco	>-1,50 e <-1,00	>-1,28 e <-0,84
Severamente Seco	>-2,00 e <-1,50	>-1,65 e <-1,28
Extremamente Seco	<-2,00	<-1,65

Fonte: Adaptado de McKee et al (1993) e Agnew (2000).

A característica fundamental do SPI é que pode ser calculada para uma variedade de escalas de tempo (versatilidade), que reflete os diversos usos da água e, conseqüentemente, a categoria, as quais são descritas a seguir:

- SPI de 1 mês: resultados bastante similares aos da percentagem da precipitação normal mensal, reflete circunstâncias de curto prazo, considerando o índice meteorológico;
- SPI de 3 meses: fornece uma comparação entre a precipitação ao longo de três meses consecutivos de um determinado ano. Os valores do SPI de três meses refletem condições de curto em médio prazo de água no solo, tendo grande aplicação na análise de umidade disponível no solo que é importante para a produção agrícola;

² Calculado pela simplesmente a diferença de precipitação a partir da média durante um período de tempo especificado dividido por o desvio padrão, onde a média e o padrão desvio são determinados a partir dos registros do passado (McKee *et al.*, 1993).

- SPI de 6 meses: faz uma comparação entre a precipitação para um período específico de seis meses com o mesmo período na série histórica em análise, pode ser muito eficaz na detecção do excesso de precipitação ao longo das diferentes estações do ano que podem refletir nas vazões e os níveis dos lagos e reservatórios (índice hidrológico);
- SPI de 12 meses: o SPI nesta escala de tempo reflete testes padrões de precipitação em longo prazo, que provocam consequências diretas na vazão, volumes de reservatórios e fontes de águas subterrâneas, podendo ser entendido como índice hidrológico.

Além da vantagem incorrida da versatilidade do SPI, Hayes *et al.* 1999 *apud* Guedes 2016 apresentam outras, a saber:

- Índice baseado apenas na precipitação. Desse modo, a avaliação de seca é possível, mesmo que outras informações hidrometeorológicas não estejam disponíveis;
- O SPI não é afetado negativamente pela topografia, uma vez que faz comparações pontuais;
- Por ser um índice padronizado, as frequências de eventos críticos em qualquer local e em qualquer escala temporal são consistentes;
- Índice eficiente na detecção das intensidades e durações dos eventos para regiões de diferentes características climáticas, inclusive em áreas do Nordeste brasileiro;
- Capacidade do SPI em se associar com outras metodologias.

Guttman (1998), ao comparar o SPI e o PDSI, conclui que existe uma grande coerência entre estes índices, o que indica que pouca informação é acrescida à caracterização das secas com o uso de dados de evapotranspiração, ao passo que grandes incertezas são introduzidas no cálculo, ou seja, pouca informação é agregada pelo uso de diversos parâmetros do PSDI. Além disso, este mesmo autor verificou que o SPI tem interpretação menos complexa. O SPI pode detectar o início da seca mais rapidamente do que o PDSI (Hayes *et al.*, 1999 *apud* Guedes 2016) e SSI (Hao e AghaKouchak, 2013) e a apresentar uma variação espaço-temporal da seca de forma consistente (Mishra e Singh, 2010).

Mishra e Singh (2010) verificaram duas limitações no uso do SPI: necessidade de longos registros históricos para seu cálculo consistente e a distribuição de probabilidades a ser utilizada para o cálculo das probabilidades, pois nem sempre a distribuição Gama poderá ser

adequadamente ajustada à amostra de dados. Diante disso, Santos (2011), à luz das limitações supracitadas, utilizou a análise regional com momentos-L e utilizou outras funções de distribuição de probabilidades para o cálculo das probabilidades dos quantis (SPI) na parcela mineira da Bacia do Rio São Francisco. Desta maneira, Santos (2011) conclui que a análise regional de frequências com momentos-L supriu a carência de dados hidrológicos e fez boas estimativas dos valores de SPI, em especial, dos valores mais extremos e mostrou que a flexibilidade necessária para a modelagem estatística (diferente da distribuição Gama) de chuvas e secas é bastante recomendável.

Não obstante, as limitações apresentadas acima, o SPI tem sido utilizado para estudar os diferentes aspectos de secas, por exemplo, caracterização espaço-temporal em diversos países como: Espanha (Muñoz-Díaz e Rodrigo, 2004), Portugal (Santos *et al.*, 2010), China (Xu *et al.*, 2015) e Irã (Golian *et al.*, 2015) e em diferentes regiões do Brasil, no Estado do Rio Grande do Sul (Albuquerque, 2010), na Bacia do Rio São Francisco (Santos *et al.*, 2013), Amazônia Oriental (Santos *et al.*, 2017) e Leste do Nordeste brasileiro (Costa *et al.*, 2016). Importante destacar que o estudo de Costa *et al.* (2016) mostrou que a porção semiárida das bacias estudadas é mais suscetível a ocorrência de secas com pequena extensão territorial, enquanto que eventos de extensões maiores afetam as bacias de forma homogênea o que sugere que os fenômenos climáticos globais podem governar eventos mais secos na área de estudo.

Alguns autores têm utilizado também o SPI para diferentes modelos de previsão no mais diversos locais do Planeta (Mishra e Desai, 2005; Mishra *et al.*, 2007; Cancelliere *et al.*, 2007; Morid *et al.*, 2007; Santos *et al.*, 2009; Guedes, 2016; Ganguli e Reddy, 2013; Belayneh *et al.*, 2014; Choubin *et al.*, 2014), que serão melhor detalhados nos itens subsequentes. Aqui cabe uma descrição mais detalhada do trabalho de Guedes (2016), que utilizou um modelo para a previsão de SPI a partir das anomalias de TSMs no Pacífico e Atlântico Tropical para o estado de Pernambuco, localizado no Leste do Nordeste brasileiro. O autor encontrou um desempenho que classificou como satisfatório na associação entre as variáveis oceânicas e os valores de SPI sobre o estado de Pernambuco, mas de modo geral, a previsão foi melhor na porção litorânea daquele estado e para a escala trimestral do SPI. Pereira *et al.* (2014) analisaram a correlação do SPI1, SPI3, SPI6 e SPI12 com os índices climáticos nas bacias do rio Mundaú e Paraíba e observaram que o SPI3 apresentavam melhores resultados. Verificasse, portanto, que a compreensão das secas e modelagem das suas componentes é de grande importância no planejamento e de gestão de recursos hídricos (Mishra e Singh, 2011).

3.2 MODELOS DE PREVISÃO HIDROLÓGICA

A previsão de variáveis hidrológicas é a estimativa de uma ou mais variáveis para um (ou mais) intervalo(s) de tempo específico(s) no futuro. Com base no horizonte de previsão, pode-se classificar em: previsão de curto prazo, quando o horizonte for de poucas horas até alguns dias; previsão de longo prazo, para horizontes de até nove meses (Georgakakos e Krysztofowicz, 2001 *apud* Bravo, 2010).

Segundo Frank e Pinheiro (2003), a previsão de longo prazo pode ser realizada por dois tipos de modelos: os conceituais e empíricos (ou estocásticos). O modelo empírico utiliza dados observados para identificar uma relação entre as variáveis dependentes (saída) e independentes (entrada). Esse tipo de previsão, comumente, é realizada por estatísticas sazonais estabelecidas por condições pretéritas. Já os modelos conceituais há uma necessidade de se conhecer os processos físicos, ou seja, identificação de causa-efeito dos processos climáticos.

Tucci *et al.* (2005) afirmam que com o melhor conhecimento das conexões climáticas e com os avanços na simulação numérica, ampliaram-se, largamente, as possibilidades de uso da previsão climática dinâmica de longo prazo através do acoplamento entre modelos atmosféricos e hidrológicos (hidroclimáticos) e também o desenvolvimento de modelos hidrológicos de grandes bacias. No entanto, segundo Paz *et al.* (2011), estes modelos ainda não têm capacidade de produzir previsão de precipitação confiável para locais específicos e exigem grande esforço computacional e conhecimento específico do modelo.

A previsão de secas, uma componente da previsão de longo prazo, se constitui um elemento crucial na tomada de decisão das ações a serem executadas na gestão de riscos de secas e na mitigação dos seus efeitos (Freitas, 2009). Dessa forma, tem crescido, consideravelmente, o número de trabalhos feitos em modelagem de vários aspectos de seca, como identificação e previsão de sua duração e gravidade. No entanto, um grande desafio é desenvolver técnicas adequadas para a previsão do início e término dos pontos de secas e com capacidade de prever condições de seca com precisão para meses de antecedência, devido, segundo Mishra e Singh (2011), à variabilidade espaço-temporal das variáveis hidrometeorológicas associadas à intensificação do ciclo hidrológico global.

Como o foco do trabalho são as previsões estocásticas, são apresentados, na Figura 8, os diversos procedimentos e elementos que compõe este sistema de previsão segundo Mishra e Singh (2011).

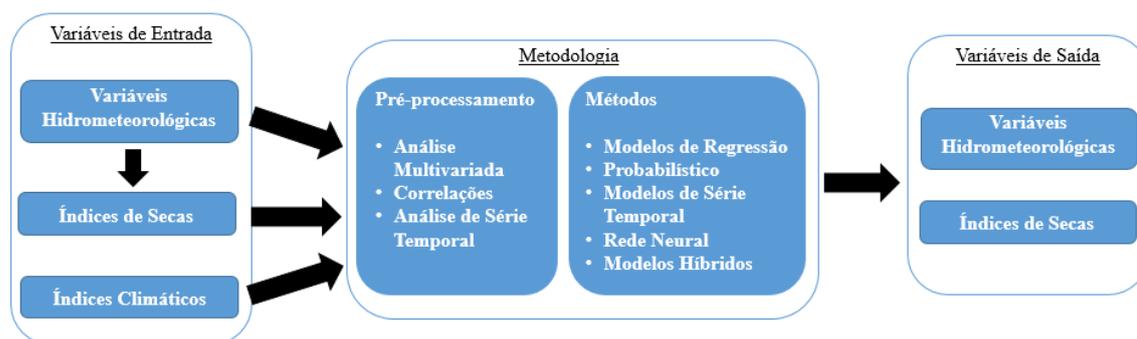


Figura 8- Diferentes Componentes da Previsão de Secas.
(Fonte: Adaptado de Mishra e Singh, 2011)

As variáveis de entrada (predictandos) para a previsão de seca dependerá de diferentes tipos de secas e da variável a ser prevista, podendo ser divididas em três categorias: hidrológicas (precipitação, vazão, umidade do solo e níveis de águas subterrâneas); os próprios índices de secas, como: PSDI, CMI, SPI e SMDI (Mishra e Singh, 2011); e, por fim, os índices climáticos (SOI, NAO, PDO, AMO, PDO, além de anomalias da TSM dos diferentes oceanos).

A definição das variáveis de entrada de um modelo de previsão não é uma tarefa fácil e requer muitas vezes um tratamento (pré-processamento) de todas as variáveis que influenciam na ocorrência, intensidade e duração da secas. Assim, os itens a seguir trazem as principais ferramentas utilizadas para auxiliar a seleção dos predictandos dos modelos de previsão de secas.

3.2.1 Análise Multivariada

As secas dependem dos sistemas meteorológicos que atuam na região, do relevo e dos fenômenos climáticos de grande escala que influenciam as variáveis que definem o comportamento e a circulação da atmosfera (Guedes *et al.*, 2012). Assim, o processo de identificação das secas faz uso de uma gama de variáveis, sendo necessário recorrer-se à análise multivariada. Esta técnica estatística é usada para reduzir ao máximo o número de variáveis envolvidas em um problema com uma pequena perda de informações. Os principais objetivos desta técnica são (Bouroche e Saporta, 1982): reduzir a dimensão de interpretação de uma matriz de dados; investigar o comportamento espacial e temporal das variáveis consideradas e obter grupos homogêneos das variáveis. Dentro da análise multivariada, existem várias técnicas de manejo de dados muito úteis para trabalhos em climatologia,

destacando-se a Análise de Componentes Principais (ACP), Análise de Cluster ou de Agrupamento (AC) e a Decomposição do Valor Singular (DVS).

A ACP consiste essencialmente em reescrever as coordenadas das amostras em outro sistema de eixo mais conveniente para a análise. Em outras palavras, as n variáveis originais geram, através de suas combinações lineares, n componentes principais, cuja principal característica, além da ortogonalidade, é que são obtidos em ordem decrescente de máxima variância, ou seja, a primeira componente principal detém mais informação estatística que a segunda componente principal, que por sua vez tem mais informação estatística que a terceira componente principal e assim por diante. Esse método permite identificar os principais padrões de variabilidade da precipitação de uma região, filtrando as informações, reduzindo a quantidade de variáveis envolvida em função da máxima variância, que pode ser explicada por cada variável (Muñoz-Díaz e Rodrigo, 2004).

Essa técnica tem sido utilizada em diversos locais do Planeta (Uvo, 2003; Muñoz-Díaz e Rodrigo, 2004; Santos *et al.*, 2010; Choubin *et al.*, 2014; Yuan, 2015), não sendo diferente no Brasil que apresenta estudos nas diferentes regiões (Souza *et al.*, 1992; Lopes, 2006; Silva *et al.*, 2009; Guedes *et al.*, 2010; Lima *et al.*, 2010; Costa, 2014). Analisando o Estado de Alagoas como o todo, Souza *et al.* (1992) verificaram que as duas primeiras componentes explicam 93,64% da covariância da precipitação média, sendo que 89,70% está contida na primeira, e então concluíram que esta componente pode ser entendida como índice de precipitação ao longo do ano. Costa (2014), ao analisar o período chuvoso das bacias do Rio Paraíba e Mundaú, verificou que a primeira componente da ACP explica grande parte do gradiente espacial das precipitações, e a segunda é explicada pela heterogeneidade de biomas e barreiras topográficas.

Por sua vez, a Análise de Cluster tem o objetivo principal de classificar os indivíduos de uma população que são conhecidos por suas características, em grupos que sejam homogêneos intragrupos e heterogêneos intergrupos. As técnicas objetivas de agrupamento diminuem a subjetividade, pois quantificam a (dis)similaridade entre indivíduos. As técnicas da Análise de Agrupamento podem ser hierárquicas e não-hierárquicas. Na primeira, são produzidas partições em um número de classes não definido inicialmente, e nas não-hierárquicas efetua-se uma partição em um número de classes pré-fixado. A classificação dos indivíduos em grupos distintos é feita a partir de uma função de agrupamento denominada distância ou similaridade e de um critério matemático de agrupamento (Bouroche e Saporta, 1982).

Em diversos locais do mundo, a Análise de Agrupamento tem sido utilizada (Uvo, 2003; Muñoz-Díaz e Rodrigo, 2004; Santos *et al.*, 2010; Yuan, 2015). No Brasil, inúmeros estudiosos aplicaram esta técnica em diferentes regiões do país, conforme a Tabela 3.

Tabela 3 - Estudos de Análise de Agrupamento Realizados no Brasil.

Autores	Local	Variável Utilizada
Souza <i>et al.</i> (1992)	Alagoas	Precipitação
Sansigolo e Nery (1998)	Sul e Sudeste	Precipitação
Silva <i>et al.</i> (2009)	Sul e Sudeste	Precipitação
Guedes <i>et al.</i> (2010)	Piauí	Precipitação
Lima <i>et al.</i> (2010)	Nordeste	Vento
Macedo <i>et al.</i> (2010)	Paraíba	SPI
Souza <i>et al.</i> (2011)	Mato Grosso do Sul	Precipitação
Jácomo <i>et al.</i> (2012)	Oeste de São Paulo	Precipitação
Guedes <i>et al.</i> (2012)	Piauí	SPI
Fetter <i>et al.</i> (2012)	Piauí	Precipitação
Gomes <i>et al.</i> (2013)	Pará	Vazão
Costa (2014)	Leste do Nordeste	Precipitação
Guedes (2016)	Pernambuco	SPI
Da Silva (2016)	BH São Francisco	Precipitação
Santos <i>et al.</i> (2017)	Amazônia Oriental	SPI

Costa (2014), ao utilizar o sinal reconstituído da precipitação da estação chuvosa, a partir das duas primeiras componentes principais, verificou nas bacias do Rio Paraíba e Mundaú uma predefinição a 3 grupos homogêneos utilizando um método hierárquico. Esse agrupamento se mostrou diretamente ligado aos biomas (caatinga, zona da mata e área de transição) presentes na região de estudo. Guedes (2016), por sua vez, verificou que a Análise de Agrupamento delimitou o estado de Pernambuco em dois grupos climáticos: O Grupo 1 (Agreste e Litoral) e o Grupo 2 (Sertão), para todas as escalas do SPI estudadas.

Por fim, destaca-se ainda a Decomposição do Valor Singular (DVS) ou Análise de Máxima Covariância (AMC). Essa técnica é uma análise multivariada baseada na matriz de variância cruzada entre pares de conjunto de dados que permite o isolamento de um conjunto de dados mutualmente ortogonal aos padrões espaciais que maximizam a covariância temporal entre duas variáveis físicas. A AMC tem sido largamente utilizada em variáveis climáticas (Uvo *et al.*, 1994; Uvo *et al.*, 1998; Yuan, 2015; Costa *et al.*, 2016). Os resultados encontrados por Costa *et al.* (2016) apontam que apenas os padrões de temperatura (do Oceano Pacífico Tropical, a leste Atlântico Tropical e do Oceano Índico) do segundo modo de covariância (28,1%) estão relacionados, com significância estatística, a precipitações no período seco das Bacias do rio Paraíba e Mundaú.

3.2.2 Correlação

Para escolha das potenciais variáveis preditoras e/ou os preditandos, realiza-se uma análise preliminar com base em correlações estatísticas. A análise de correlação (Pearson e Spearman) é amplamente utilizada para a seleção de variáveis de entrada para modelos apresentando bons resultados (Dawson e Wilby, 2001). A vantagem da segunda (Spearman) em relação à primeira (Pearson) é a capacidade de mensurar relações lineares e não-lineares entre variáveis (crescente e decrescente), enquanto que a correlação de Pearson captura apenas relações lineares (Paz *et al.*, 2011). As correlações são submetidas a testes para verificar o nível de significância da estatística encontrada (Naghetini e Pinto, 2007), podendo ser teste de hipótese (por ex. *t-student*) ou baseados no método de Monte Carlo. Normalmente, adota-se um nível de significância de 0,05, ou seja, intervalo de confiança de 95%.

Mishra e Singh (2011) enfatizam que na existência de modelo de previsão baseado em índices climáticos é de vital importância os valores de correlação de seca e índices climáticos, com alguns meses de defasagem. Deste modo, diversos autores têm utilizado as correlações para selecionar as variáveis nos modelos de previsão (Billib e Freitas, 1996; Pinto *et al.*, 2006; Silverman e Dracup, 2000; Cordery e McCall, 2000; Bravo, 2010; Paz *et al.*, 2011; Ganguli e Reddy, 2013; Pereira *et al.*, 2014; Costa, 2014; Choubin *et al.*, 2014; Reis, 2015; Yuan, 2015; Guedes, 2016).

3.2.3 Análise de Séries temporais

Muitas vezes as variáveis hidroclimáticas são de natureza periódica e essa característica pode ser mais explorada para a previsão da seca. A periodicidade pode variar entre anos ou até dezenas de anos, com diferentes proporções das diferentes amplitudes, por diferentes regiões (Mishra e Singh, 2011). Nesse contexto, surge a necessidade de aplicação de ferramentas que identifiquem a variação na escala tempo-frequência dos componentes climáticos.

Assim, a transformada de Fourier tem sido amplamente utilizada. Essa ferramenta matemática consiste na superposição linear e independente com periodicidade constante, há, então, a repetição infinita das funções seno e cosseno (base clássica de Fourier), sendo bem adequadas ao tratamento de dados envolvendo processos periódicos estacionários (Labat, 2005). No entanto, a maioria das séries de variáveis climáticas envolve processos transitórios,

de caráter não estacionário, que operam frequentemente sob uma grande variedade de escalas, tanto para taxas de precipitação, como vazão (Oliveira, 2007; Santos *et al.*, 2013).

Então, a análise de Transformada Onduleta ou Wavelet (WT) foi desenvolvida a fim de fornecer uma ferramenta de análise de desempenho para o sinal não estacionário. Essa ferramenta é capaz de capturar componentes de alta e baixa frequência, funcionando como uma janela que aumenta e diminui com esse intuito, decompõe uma série temporal em diferentes níveis de resolução tempo-frequência e então determina as componentes da variabilidade dominante. Na Wavelet, é permitido que os seus parâmetros de análise (temporal – b e escalar – a) sofram variações de acordo com as características de cada trecho do sinal com que se trabalha. Assim a área de processamento de sinais tem a sua disposição uma ferramenta capaz de capturar informações globais e locais de um processo (Morettin, 1999 *apud* Santos, 2011). A Figura 9 mostra que os tamanhos de janelas para localização de frequências são ajustáveis a cada trecho do sinal de forma que ela consegue localizar altas e baixas frequências, simultaneamente, em um mesmo trecho temporal.

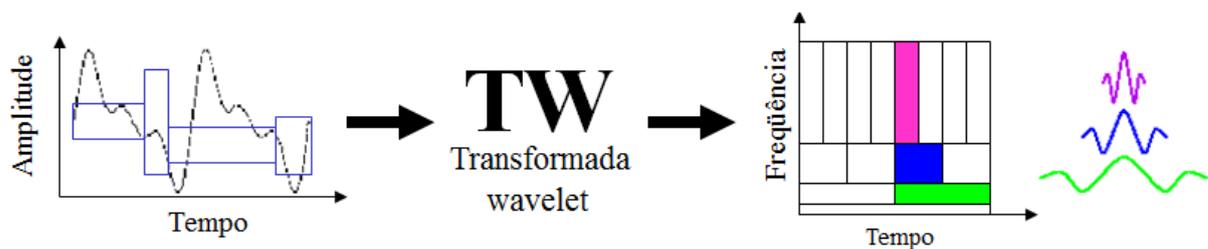


Figura 9- Transformada Wavelet: decomposição em tempo escala com tamanhos de janelas variáveis. (Fonte: Gurgel, 2013)

A transformada Wavelet contínua de uma função $f(t) \in L^2(\mathbb{R})$ é formalizada pela decomposição da função $f(t)$ em uma base formada por funções Wavelets $\Psi(t)$. Em sua formulação matemática, a transformada Wavelet contínua é dada pela equação 3.

$$W_f(a, b) = \int f(t) \cdot \Psi_{a,b}^*(t) dt \quad (3)$$

Sendo,

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right), \quad a > 0 \quad (4)$$

A equação 4 representa uma “família” de funções Wavelets usada para a transformação e que, na literatura é denominada “wavelet-mãe” e $\Psi_{a,b}^*(t)$ com o asterisco (*), simboliza seu conjugado complexo. O parâmetro a está relacionado à dilatação/contração da função e refere-se à escala usada. O parâmetro b está relacionado à translação temporal ou localização da função da “wavelet-mãe”. O termo $\frac{1}{\sqrt{a}}$ corresponde a um fator de normalização

para a energia da wavelet $\Psi_{a,b}(t)$. Assim, a equação 1 mede as flutuações da função (ou sinal) $f(t) \in L^2(\mathbb{R})$ na vizinhança de b , cujo tamanho é proporcional ao parâmetro de escala a .

A Wavelets procura por correlações entre o sinal (por exemplo, a função $f(t)$) e a função Wavelet, ou seja, ela busca onde melhor se encaixa a wavelet-mãe cumprindo-a ou dilatando-a em vários intervalos de tempo (Figura 10d). Este cálculo é feito em diferentes escalas de a (Figura 10c) e localmente em torno do tempo b (Figura 10b). O resultado é um coeficiente de Wavelet dentro de um mapa de contorno conhecido como escalograma ou periodograma da Wavelet (Reis, 2015). Esses coeficientes são submetidos a métodos de Monte Carlo para destacar estatísticas com níveis significantes, normalmente em 5%.

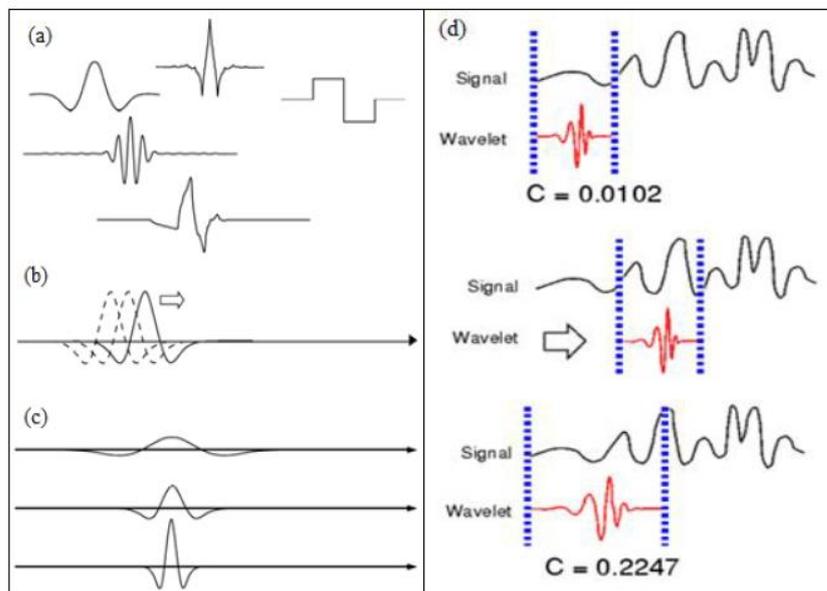


Figura 10 - (a) Diferentes tipos de wavelets-mãe, (b) translações e (c) dilatações da base e (d) processo de correlação da transformada de Wavelets.

(Fonte: Reis, 2015)

Cada tipo de “wavelet-mãe” possui uma melhor ou pior localização no domínio da frequência e/ou tempo. É necessária a escolha de uma wavelet para a base de maneira conveniente, de forma que o sinal seja adequadamente caracterizado e se evitem distorções no resultado. Existem vários tipos de “wavelet-mãe” podendo destacar o Morlet, DOG (Chapéu Mexicano) e Paul (Torrence e Compo, 1998), sendo que a transformada de Morlet é a mais usada em dados meteorológicos e/ou hidrológicos por possuir características semelhantes a estes sinais, tais como simetria ou assimetria e variação temporal brusca e suave (Torrence e Compo, 1998; Gristed *et al.*, 2004; Da Silva, 2013).

Na prática, a Wavelet de Morlet, mostrada na Figura 11, é definida como um produto de uma onda exponencial complexa ($e^{i\omega_o\eta}$) e um envelope gaussiano ($\pi^{-0,25}e^{-0,5\eta^2}$), conforme observado na equação 5.

$$\Psi_0(\eta) = e^{i\omega_0\eta} \cdot \pi^{-0,25} \cdot e^{-0,5\eta^2} \quad (5)$$

Onde $\Psi_0(\eta)$ é o valor da wavelet no tempo adimensional, η , e ω_0 é a frequência adimensional, igual a um valor que satisfaça a condição de admissibilidade, ou seja, a função deve ter média zero e ser localizada no espaço do tempo e frequência para se “admissível” como uma Wavelet.

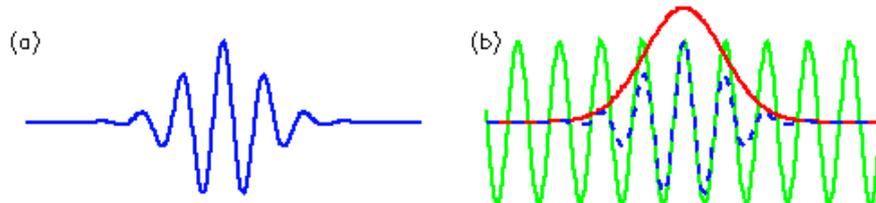


Figura 11 - A wavelet de Morlet (a) e a representação de sua formação através de um senoide (em verde) e um envelope gaussiano, em vermelho (b).

(Fonte: Reis, 2015)

Pode-se então variar a “escala” da Wavelets mudando sua largura, que é a grande vantagem do uso desta ferramenta. As ondas exponenciais complexas apresentam alta frequência, enquanto gaussianas apresentam baixa frequência. Para determinação de ciclos curtos ou longos, modifica-se o tipo da onda. A maneira de mudar o tamanho das ondeletas em relação ao tempo é chamada de “ondeletas escaladas” (Da Silva, 2013).

Na ocorrência de fenômenos climáticos, muitas vezes é necessário investigar as grandezas que deram origem ao processo que envolve muitas variáveis. Nesse contexto, para medir a força de associação entre as duas séries através de um espectro de potência, sendo possível destacar os principais períodos de interferência de uma série em relação à outra para diferentes frequências temporais (Labat, 2005). Torrence e Compo (1998) definem o espectro da Wavelet Cruzada (XWT) de duas séries temporais ($f(t)$ e $g(t)$) como:

$$XW_{f,g}(a,b) = W_f^*(a,b)W_g(a,b) \quad (6)$$

Onde $W_f(a,b)$ e $W_g(a,b)$ são os coeficientes das transformadas wavelets contínuas individual (conforme equação 3) para cada sinal $f(t)$ e $g(t)$, respectivamente. O sobrescrito * simboliza o complexo conjugado. Desta forma, o termo $XW_{f,g}(a,b)$ da equação X expressa o produto dos coeficientes da transformada wavelet em uma dada escala a , na vizinhança temporal de b .

Outra ferramenta útil é a coerência wavelet (WCT), definida por Jevrejeva *et al.*, (2003) através da equação 7. WCT é uma medida da intensidade da covariância de duas séries no espaço tempo-frequência, ao contrário do espectro Wavelet Cruzada identifica regiões de significativa coerência (não necessariamente com alta potência),

$$WC_{f,g}(a,b) = \frac{|S(s^{-1}XW_{f,g}(a,b))|^2}{S(s^{-1}|W_f(a,b)|^2)S(s^{-1}|W_g(a,b)|^2)} \quad (7)$$

Na equação 7, o fator s^{-1} é introduzido para normalizar a densidade de energia, e S representa um operador de suavização em tempo e escala para wavelet usada. A equação 7 possibilita representar a correlação entre dois sinais por meio de um diagrama (mapa de cores ou escalograma) em função do tempo-frequência no qual é possível a visualização de eventos coincidentes sobre as escalas e frequências, em cada instante de tempo dos sinais. A Coerência Wavelet apresenta valores entre 0 (zero) e 1 (um). Para valores de próximos de 1(um) a correlação é alta. Para valores de próximos de 0 (zero) a correlação é baixa.

Labat *et al.* (2005) enfatizam que a abordagem de Wavelets pode sugerir explicações físicas para relações dependentes da escala de tempo. Grinstead *et al.* (2004), ao explorarem as relações de fase entre duas séries temporais, verificaram que relações em fase relativa é indicada pela posição das setas no escalograma (em fase seta apontando para direita, enquanto que anti-fase apontando para esquerda). Esses mesmos autores afirmam que a XWT revela informações sobre a fase. Se duas séries são fisicamente relacionadas, espera-se uma consistente ou uma variação lenta do atraso de fase. No entanto, Maraun e Kurths (2004) verificaram que XWT pode mostrar picos enganosos para realizações de processos independentes, apenas porque o WT de uma das séries temporal exibe picos fortes. Assim, XWT não é adequado para testar a significância inter-relação entre dois processos e deve-se analisar simultaneamente (sobreposição), WCT e XWT.

Da Silva (2009) enfatiza que a transformada ondeleta traz metodologia eficaz na localização de fenômenos transientes e que atuam, simultaneamente, em várias escalas de tempo, proporcionando novas perspectivas e abordagens de análises, sendo útil para detectar, analisar e caracterizar as escalas de tempo que afetam os sistemas atmosféricos sobre a América do Sul e oceanos adjacentes.

Nesse sentido, muitos estudos têm sido desenvolvidos para procurar relações de tempo-frequência de diversas variáveis climáticas (ou índices climáticos), no intuito de correlacionar com componentes hidrológicas em diferentes locais do Planeta. Buscou-se, então, investigar o impacto das flutuações de escala global nas vazões médias mensais (Labat *et al.*, 2005) e anuais (Labat, 2010) dos diferentes continentes e, mais especificamente, nas vazões mensais no Sudeste da Europa (Briciu e Mihăilă, 2014). Em relação à precipitação, destacam-se os estudos de diferentes partes do Brasil (Harter e Chapa, 2004; Da Silva, 2009;

Da Silva, 2010; Santos, 2011; Reis, 2015; Costa, 2014; Da Silva, 2013; Santos *et al.*; 2013; Barreto *et al.*, 2014, Da Silva, 2017).

Em relação à aplicação destas ferramentas na área de estudo, Da Silva (2009) verificou escala temporal dominante na ordem de 22 a 11 anos entre cada evento de chuva extrema. Já Costa (2014) destacou a influência de padrões de temperatura na superfície dos oceanos Pacífico e Atlântico nas variabilidades interanuais da precipitação no trimestre chuvoso. Por fim, Alves (2016), ao analisar os índices de disponibilidade hídrica, verificou que a atuação combinada dos fenômenos nos dois oceanos pode ocasionar uma variabilidade mais acentuada na disponibilidade hídrica.

3.2.4 Métodos de Previsão

Uma vez definidas as variáveis de entradas, parte-se para a discussão das diferentes metodologias para a previsão. Mishra e Singh (2011) tipificam 5 modelos de previsão, a saber:

- Análise de Regressão: modelo de regressão múltipla que prevê uma variável a partir de duas ou mais independentes variáveis;
- Modelos de Séries Temporais: Acoplamento de modelos autorregressivos com modelos de média móvel; realizam uma busca sistemática nos diferentes estágios da modelagem (identificação, avaliação e verificação de diagnóstico); podem ser classificados como não-sazonal (ARIMA) e sazonal (SARIMA) (Mishra e Desai, 2005).
- Modelos Probabilísticos: são modelos derivados de funções de distribuição de probabilidade;
- Modelos de Rede Neural Artificial: são modelos não-lineares flexíveis que podem, adaptativamente, descobrir padrões a partir dos dados;
- Modelos Híbridos: tratam-se da combinação de modelos de previsão de secas para unir as potencialidades de cada modelo, separadamente (Mishra *et al.*, 2007);

Nessa linha, Valença (2015) afirma que a agregação de múltiplas ferramentas de inteligência computacional (modelos híbridos) permite a obtenção de solução de forma mais eficiente para problemas complexos, podendo destacar Algoritmos Genéticos e Sistema Baseado em Conhecimento, e Freitas (2010) destaca o emprego de lógica difusa (*fuzzy*) combinada com Rede Neural Artificial. Além dos 5 tipos de métodos citados acima, Belayneh

et al. (2014) destacaram o uso do vetor suporte de regressão ou *support vector regression* para previsão de secas, que é técnica de aprendizagem supervisionada. A Tabela 4 apresenta a metodologia utilizada para previsão na ótica de diferentes autores, além das variáveis de entrada utilizadas a área de aplicação do modelo.

Em seguida, será melhor detalhado o modelo de redes neurais artificiais (RNA) e os modelos híbridos decorrentes do acoplamento da RNA com outros métodos, pois foram as metodologias selecionadas. A seleção deste modelo justifica-se por apresentar ferramentas robustas para modelar muitos dos processos hidrológicos não lineares como chuva-vazão, água subterrânea, a simulação da qualidade da água, e precipitação; bem como reconhecer os padrões das variáveis analisadas (ASCE, 2000; Paz *et al.*, 2011).

Tabela 4 - Modelos Desenvolvidos Para Previsão Hidrológica.

Autores	Local	Preditandos	Modelo Utilizado	Preditores
Billib e Freitas (1996)	Ceará, Brasil	TSM do Pacífico	Neural-fuzzy	Precipitação
Silverman e Dracup (2000)	Califórnia, EUA	SOI, NAO, MEI, Niño 3.4 e outros	RNA	Precipitação
Pinto <i>et al.</i> (2006)	Bacia do São Francisco, Brasil	SOI e ATSM	Probabilística	Precipitação
Cancelliere <i>et al.</i> (2006)	Sicília	SPI	Probabilística (Cadeia de Markov)	SPI
Kim <i>et al.</i> (2006)	México	PDSI	Híbridos (WA-RNA)	PDSI
Mishra <i>et al.</i> (2007)	Índia	SPI	Híbrido (ARIMA-RNA)	SPI
McIntosh <i>et al.</i> (2007)	Austrália	IOD e SOI	RNA	Precipitação
Morid <i>et al.</i> (2007)	Irã	SOI, NAO, Precipitação e EP	RNA	EP e SPI
Santos <i>et al.</i> (2009)	Bacia do São Francisco, Brasil	SPI	RNA	SPI
Bravo (2010)	Bacia do Rio Grande, Brasil	SOI, PDO, NAO e SAM	RNA – Algoritmos Genéticos	Precipitação
Gomes <i>et al.</i> (2010)	Bacia do São Francisco, Brasil	Precipitação	RNA	Vazões
Paz <i>et al.</i> (2011)	Bacia do Pardo/ Mogi-Guaçu, Brasil	PDO, SAM, NAO e Niño 3.4	RNA	Precipitação
Alexandre (2012)	Grandes Bacias brasileiras	SOI, NAO, MEI, Niño 3, Niño 3.4 e outros	Modelos Autorregressivo	Vazão
Ganguli e Reddy (2013)	Índia	SOI, IOD e AMO	SVR	SPI
Belayneh <i>et al.</i> (2014)	Etiópia	SPI	ARIMA, RNA, SVR e Híbridos (WA-RNA e WA-SVR)	SPI
Costa (2014)	Bacia dos Rios Mundaú e Paraíba, Brasil	SOI, NAO, AMO e PDO	RNA	Precipitação
Choubin <i>et al.</i> (2014)	Irã	AMO, AMM, Niño 3.4, Niño 4, SOI e outros	Neural-fuzzy	SPI
Reis (2015)	Bacia do Rio Piencó, Brasil	NAO, SOI, PDO, AMO, AMM e outros	RNA	Precipitação
Guedes (2016)	Estado de Pernambuco	ATSM Pacífico e Atlântico	RNA	SPI

Notas - WA-RNA: Wavelets e Redes Neurais Artificiais; WA-SVR: Wavelets e *Support Vector Regression*

As redes neurais artificiais são modelos matemáticos que reproduzem o sistema nervoso biológico e do próprio cérebro humano que tem, como principal propriedade, a habilidade de aprender a partir de seu ambiente e, com isso, extrair conhecimento (Maier e Dandy, 2000). Os modelos de RNA's se utilizam de elementos intrínsecos denominados neurônios artificiais, que imitam o funcionamento do neurônio biológico. Essas pequenas células estão conectadas através de sinapses e juntas formam uma grande rede chamada rede neural. Essa grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação (CORRAR *et al.*, 2007). O neurônio artificial (matemático), por sua vez, funciona de acordo com a equação 8:

$$S = F\left(\sum_{i=1}^n w_i \cdot E_i + b\right) \quad (8)$$

Onde S é o valor da resposta do neurônio; F é a função de ativação; w, são os pesos sinápticos; E_i são os valores das entradas que são processadas no neurônio; b é a tendência ou bias do valor de saída. Observa-se, então, na equação 8, que a resposta de um neurônio é calculada através da aplicação de uma função de ativação a uma soma ponderada das entradas ao neurônio, e as RNA's são compostas por um determinado número de neurônios, dispostos em camadas de processamento, conforme a Figura 12.

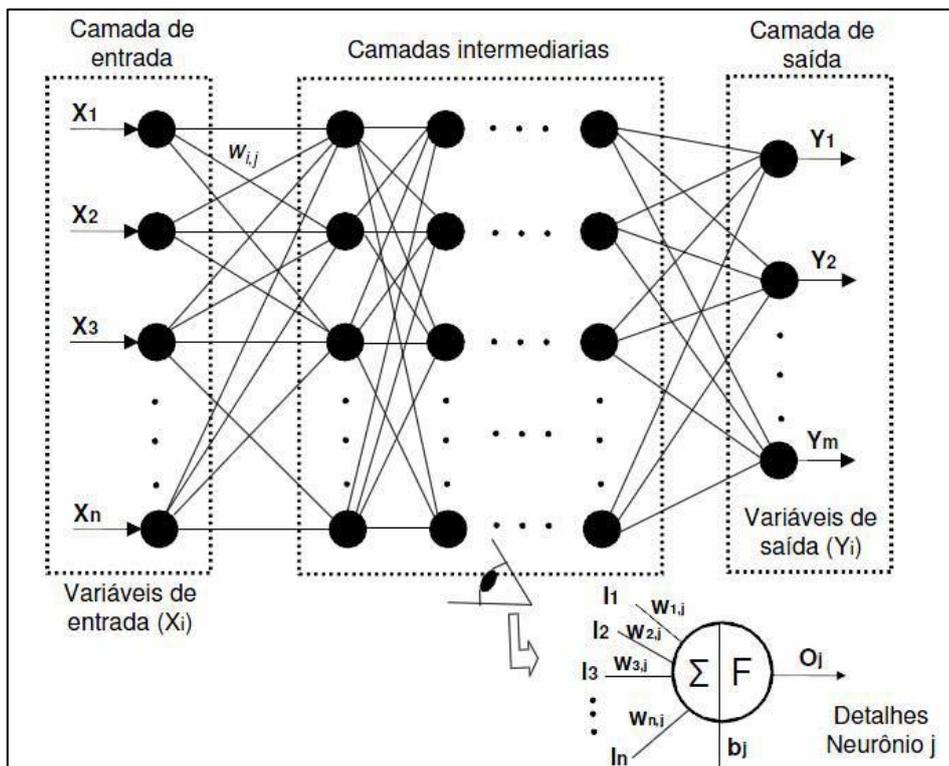


Figura 12 - Modelo de uma Rede Neural Artificial e detalhe do funcionamento de um dos neurônios.
Fonte: Bravo (2010).

Como visto na Figura 12, tipicamente a topologia de um modelo de RNA tem uma camada de entrada, uma ou mais camadas escondidas (intermediárias) e uma camada de saída. Na maioria dos modelos de RNA, a camada de entrada recebe as variáveis de entrada, por exemplo, as variáveis de previsão, fornecendo a base de informações do modelo. Através da camada(s) oculta(s), essa informação é processada e passada para a camada de saída, onde os produtos finais da RNA, por exemplo, os valores preditos, são gerados (Reis, 2015).

Na escolha da topologia, são selecionadas as funções de ativação entre as camadas da RNA. Existe um grande número de funções de ativação, sendo as mais utilizadas nos modelos de previsão (Bravo, 2010): a sigmoide logística, a tangente hiperbólica e a linear, apresentadas a seguir pelas equações 9, 10 e 11, respectivamente.

$$\log sig(n) = \frac{1}{1 + e^{-n}} \quad (9)$$

$$\tan sig(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (10)$$

$$linear(n) = n \quad (11)$$

Essas funções de ativação são aplicadas a todos os neurônios de uma camada da RNA. As camadas intermediárias recebem as funções de ativação não lineares, onde a mesma função de ativação é geralmente adotada para todos os neurônios de uma determinada camada e assim por diante, até atingir a camada de saída.

A força da ligação entre cada dois neurônios é medida pelo peso sináptico, e os pesos de todas as ligações constituem os parâmetros a serem definidos por meio de um processo de otimização denominado de treinamento (Paz et al., 2011). No treinamento, os valores dos pesos e “bias” são ajustados com o objetivo de minimizar alguma medida de desempenho, baseada, comumente, nos erros entre a saída da rede e o valor observado (Bravo, 2010).

O treinamento das RNAs é, normalmente, feito com base em métodos de busca local. Os métodos de busca local podem ser divididos em duas classes: (1) de primeira ordem e (2) de segunda ordem. Os métodos de primeira ordem são baseados em modelos lineares (gradiente descendente). Por sua vez, os métodos de segunda ordem são baseados em modelos quadráticos, como o método de Newton. Em ambos os casos, diferentes técnicas iterativas são utilizadas durante o treinamento para minimizar/maximizar a medida de desempenho utilizada. O algoritmo mais utilizado no treinamento das RNA's aplicadas na área de recursos hídricos é o retropropagativo (*backpropagation*), que consiste em duas fases:

- a) Fase forward (propagação adiante) – um padrão de atividade (vetor de entrada) se propaga pela rede da camada de entrada até a camada de saída e, finalmente, um conjunto de saídas é produzido como resposta real da rede; Durante esse passo, os pesos sinápticos da rede não são alterados;
- b) Fase backward (propagação reversa) – a resposta real é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. O erro se propaga na direção contrária ao fluxo de dados, indo da camada de saída até a primeira camada intermediária, ajustando os pesos sinápticos de cada neurônio de cada camada.

É importante ressaltar novamente que o uso de um método de busca local em processo de treinamento da RNA não garante encontrar o ótimo global do problema de otimização se a superfície de erro tiver muitos mínimos locais (rugosa). A tendência de convergência para o ótimo global fica condicionada à posição inicial (valores) dos pesos sinápticos, pois esse treinamento é baseado somente em informações de gradiente. Porém, teoricamente, de acordo com Shukla *et al.* (2011), esse problema pode ser resolvido repetindo o treinamento da RNA várias vezes, com diferentes condições iniciais. Se os mesmos pesos são obtidos, pode ser evidência suficiente para considerar ter encontrado o verdadeiro ótimo global.

Além dos métodos de busca local, como os previamente apresentados, outros procedimentos podem ser utilizados em processos de otimização, como, por exemplo, os métodos de busca global. Desses métodos, os mais utilizados no treinamento de modelos de redes neurais artificiais são os algoritmos evolucionários. Os algoritmos evolucionários são métodos de otimização e busca baseados em analogias com a natureza. Uma das principais características desses métodos é que utilizam uma população de soluções candidatas para explorar o espaço de busca, ao invés de uma única solução, como geralmente ocorre nos métodos numéricos clássicos. Dessa forma, é possível explorar, simultaneamente, múltiplos pontos do espaço de busca, aumentando as possibilidades de se encontrar o ótimo global em problemas que possuem diversos ótimos locais (Bravo, 2010).

Em relação, as medidas de desempenho mais utilizadas na avaliação dos resultados do funcionamento de modelos de redes neurais para previsão de variáveis hidrológicas são: o erro quadrático médio (RMSE - Equação 12), o erro médio absoluto (MAE - Equação 13), o erro médio relativo (MRE - Equação 14), o índice de eficiência de Nash-Sutcliffe (NS - Equação 15) e o coeficiente de correlação de Pearson (R- Equação 16) (Dawson e Wilby, 2001; Paz *et al.*, 2010), além do coeficiente de correlação de Spearman (ρ - Equação 17).

$$RMSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad (12)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_i - O_i}{O_i} \right| \quad (14)$$

$$Nash = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (15)$$

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}} \quad (16)$$

$$\rho = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{(n^3 - n)} \quad (17)$$

Sendo que P_i e O_i são os valores previstos e observados dos preditandos na amostra i , respectivamente; \bar{P} e \bar{O} são o valor médio do preditando e do observado e N é o número total de amostras.

Na busca de uma melhor precisão da previsão dos modelos de rede neural, Aussem e Murtagh (1997) utilizaram a combinação de previsão de diferentes níveis de resolução da série de manchas solares, através da transformada Wavelets para decompor a série temporal em diferentes escalas de resolução temporal e conseguiram encontrar as leis que regem a dinâmica de cada nível de resolução através de sistemas não lineares. Posteriormente, Kim *et al.* (2006) se utilizaram dos mesmos artifícios para a previsão de secas na bacia do rio Conchos, no México, e os resultados indicaram que o modelo de conjunção (wavelets e rede neural) melhorou, significativamente, a capacidade das redes neurais para prever a seca regional.

Mais recentemente, Belayneh *et al.* (2014) utilizaram diversos modelos (RNA, SVR e ARIMA) combinados ou não com Waveletes para previsão do SPI 12 e SPI24 e verificaram que os modelos de redes neurais com wavelet acopladas (WA-ANN) foram melhores do que todos os outros modelos no estudo.

3.3 RESUMO DO CAPÍTULO

Os fenômenos das secas são as catástrofes naturais mais devastadoras e a sua identificação é bastante complexa, devido ao fato de não existir uma definição clara. Decorrente disso, muitos estudos têm voltado os olhos para caracterização e previsão destes eventos, muitas vezes fazendo uso de índices de seca que são indexadores capazes de quantificar a magnitude e severidade das secas. Existem diversos índices de secas, podendo citar o SPI por apresentar versatilidade e facilidade no seu cálculo. Para a previsão, há os modelos desenvolvidos em todo o mundo, esses modelos têm o objetivo de indicar com certo tempo de antecedência os valores de uma variável hidrológica. Dentre os modelos utilizados, destaca-se o modelo de Redes Neurais Artificiais, isoladamente ou combinado com outros modelos (Wavelets e Algoritmos Genéticos), que tem sido bastante aplicado na previsão hidrológica ao redor do mundo.

4 MATERIAIS E MÉTODOS

4.1 ÁREA DE ESTUDO

A região estudada compreende duas bacias hidrográficas (rios Mundaú e Paraíba), que estão localizadas no Leste do Nordeste do Brasil e são limitados pelas seguintes coordenadas: Latitudes 8°41'24" e 9°40'48" S e Longitudes 35°46'48" e 36°45'00" W (Figura 13). A área total compreende aproximadamente 7.283 km², sendo 4.126 km² a bacia do Mundaú e 3.157 km² a bacia do Paraíba, compartilhadas entre os estados de Pernambuco e Alagoas.

O rio Paraíba Meio, principal canal da bacia do Paraíba, possui 171,98 km com regime intermitente e perene, é alimentado, principalmente, pelos riachos Bálsamo e o Seco na margem direita, no estado de Pernambuco, e no território alagoano, o rio Quebrangulinho, riacho Lunga, riacho do Canto, riacho Itapicuru, riacho Isabel, riacho do Carapa e Rio Porongaba (Cunha, 1995). O rio Mundaú é perene, tem vazão média anual de 30,6 m³/s (Da Silva, 2009), as maiores contribuições vêm dos rios Canhoto e Inhaúmas, próximo à fronteira dos estados de Alagoas e Pernambuco, e mais próximo a sua foz do rio Satuba.

Na região, estão inseridos, total ou parcialmente, 45 municípios (inclusive Maceió), que perfazem quase 2 milhões de habitantes (IBGE, 2010). A importância para os municípios deve-se, principalmente, segundo Souza *et al.* (2004): ao abastecimento de diversos reservatórios e pequenos açudes localizados na cabeceira (Vide Figura 13); ao abastecimento de água para irrigação de diversos cultivos (cana-de-açúcar e agricultura de subsistência) e preservação de um dos complexos lagunares mais produtivos do Brasil.

As bacias têm propriedades clima-fisiográficas semelhantes que variam muito desde a zona costeira para as cabeceiras. A parte inferior das bacias é caracterizada por um clima úmido de floresta tropical, e na parte superior das bacias, é semiárida. A parte central das bacias é caracterizada pelo clima de transição e vegetação entre semiárido e clima tropical (Costa *et al.*, 2016). Em relação ao relevo, as bacias apresentam uma forma ondulada, a fortemente ondulada em sua parte alta, com serras de altitudes inferiores a 1000 m. Na parte média, o relevo se apresenta ondulado a suavemente ondulado e, por fim, na parte baixa da bacia o relevo é suavemente ondulado com presença de tabuleiros nas proximidades da costa (Gama, 2011; Nascimento, 2016).



Figura 13 - Localização da Região de Estudo.

A região é caracterizada por uma forte variação no total da precipitação média anual, onde a parte alta da bacia tem uma média de 870 mm/ano, e a parte baixa tem uma média de 2100mm/ano (COTEC, 1999). A área é marcada também por dois períodos distintos no regime pluviométrico: um período seco de setembro a fevereiro e um período úmido de março a agosto, com concentração de 70% do regime pluviométrico anual. O período entre outubro e dezembro, em média, precipitam cerca de 90 mm (8% do total anual), no entanto, é marcado por uma variabilidade interanual de até 150mm, considerando o acumulado deste trimestre, conforme pode ser visto pela Figura 14, que traz as médias mensais das precipitações na região e o seu grau de dispersão.

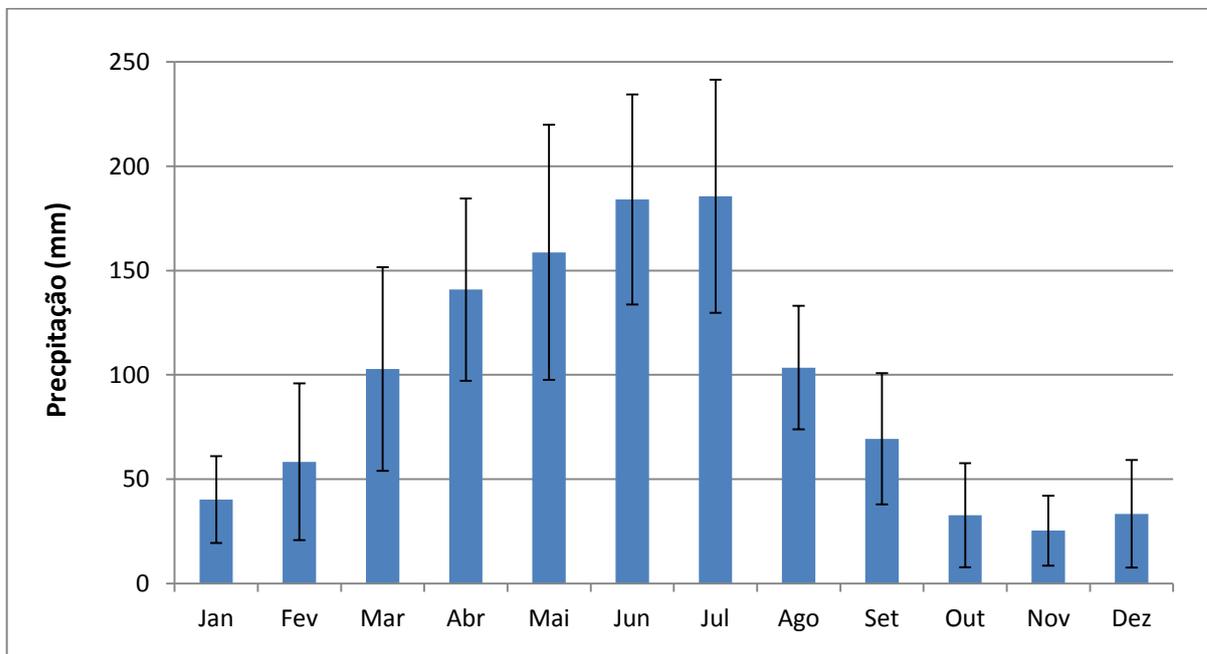


Figura 14 - Precipitação Média Mensal com o Grau de dispersão da Região de Estudo.

Como os meios de subsistência e atividades econômicas são, principalmente, pecuária e agricultura de sequeiro, a área de estudo é altamente sensível às variações do regime pluviométrico. Nesta linha, Fragoso Jr, *et al.* (2010) enfatizam que a região é bastante susceptível às acentuadas variações do regime de precipitação, citando como exemplo a grande cheia de 2010 que, além da agricultura, destruiu diversas cidades com perdas incalculáveis. Ou uma forte estiagem, como a que se iniciou em 2012, e se estendeu até os dias atuais, resultado das próprias condições locais e/ou influência de sistemas sinóticos e fenômenos de grandes escalas como os descritos no item 2.2.

4.2 COLETA E SELEÇÃO DOS DADOS

Os dados de precipitação utilizados foram obtidos de três diferentes fontes: Agência Nacional de Águas (ANA), Instituto Tecnológico de Pernambuco (ITEP) e Secretaria Estadual de Recursos Hídricos e Meio Ambiente de Alagoas (SEMARH - AL). Para seleção dos dados pluviométricos coletados, testes de consistências, foram realizados através do software PrePlu (Collischonn, 2001). As séries mensais de precipitações foram obtidas a partir das séries diárias. Na sequência, um preenchimento de falhas foi realizado nas séries mensais através do software INTERPLU (Collischonn, 2001), onde foram identificados postos com mais de 5% falha da amostra total e estes intervalos foram preenchidas usando estações próximas de até 30 km por meio inversa método do quadrado da distância (Costa, 2014). Buscou-se selecionar os postos pluviométricos que possuíam dados no mesmo período, considerando o maior período possível de análise. Por fim, foram obtidas as séries do trimestre mais seco da região, compreendido entre outubro e dezembro (OND).

As séries históricas mensais referentes aos índices climáticos foram obtidas junto ao *The National Center for Atmospheric Research (NCAR)* e *National Oceanic and Atmospheric Administration (NOAA)* para o mesmo período dos dados de precipitação. Os dados são apresentados na forma de anomalias em relação à média observada de um período. Para avaliar o efeito defasado de cada índice climático no período seco, as séries mensais dos índices foram tomadas de até 6 meses antes do início da trimestre OND.

Após a coleta e análise dos dados pluviométricos, foram selecionados dois conjuntos de dados com o objetivo de estender a série histórica analisada de tal forma que o primeiro possui 8 estações com série histórica de 1938 a 1961, e o segundo é composto por 18 estações para o período de 1962 a 2008 (47 anos), os postos selecionados podem ser visto nas Tabela 5 e 6, e sua distribuição espacial na Figura 15.

Tabela 5 - Estações Pluviométricas Selecionadas para o Período de 1938 a 1961.

Código	Nome	Longitude(°)	Latitude(°)	Cidade	Estado	Fonte
836015	Garanhuns	-36,488	-8,888	Garanhuns	PE	ANA
935005	Maceió	-35,788	-9,567	Maceió	AL	ANA
936004	Correntes	-36,333	-9,111	Correntes	PE	ANA
936010	Atalaia	-36,017	-9,511	Atalaia	AL	ANA
936034	Palmeira dos Índios	-36,655	-9,400	Palmeira dos Índios	AL	ANA
936041	Quebrangulo	-36,488	-9,333	Quebrangulo	AL	ANA
936053	U. dos Palmares	-36,055	-9,167	U. dos Palmares	AL	ANA
936057	Viçosa	-36,256	-9,383	Viçosa	AL	ANA

FONTE: Autoria Própria

Tabela 6 - Estações Pluviométricas Seleccionadas para o Período de 1962 a 2008.

Código	Nome	Longitude(°)	Latitude(°)	Cidade	Estado	Fonte
836008	Caetés	-36,633	-8,783	Caetés	PE	ANA
935012	Murici-Ponte	-35,950	-9,314	Murici	AL	ANA
936010	Atalaia	-36,017	-9,517	Atalaia	AL	ANA
936031	Mar Vermelho	-36,383	-9,450	Mar Vermelho	AL	ANA
936041	Quebrangulo	-36,483	-9,333	Quebrangulo	AL	ANA
936045	Sant. do Mundaú	-36,217	-9,167	Sant. do Mundaú	AL	ANA
936047	São José da Laje	-36,050	-9,017	São José da Laje	AL	ANA
936049	Santa Efigênia	-36,133	-9,300	Capela	AL	ANA
936053	U. dos Palmares	-36,050	-9,167	U. dos Palmares	AL	ANA
936057	Viçosa	-36,250	-9,383	Viçosa	AL	ANA
10000002	Brejão	-9,026	-36,566	Brejão	PE	ITEP
10000007	Canhotinho	-36,114	-8,883	Canhotinho	PE	ITEP
10000010	Correntes	-36,317	-9,117	Correntes	PE	ITEP
10000012	Garanhuns	-36,4667	-8,850	Garanhuns	PE	ITEP
10000017	Jucati	-36,493	-8,707	Jucati	PE	ITEP
10000020	Jurema	-36,137	-8,718	Jurema	PE	ITEP
10000035	Paranatama	-36,658	-8,919	Paranatama	PE	ITEP
10000036	Saloá	-36,692	-8,969	Saloá	PE	ITEP

FONTE: Autoria Própria

4.3 ANÁLISE MULTIVARIADA

Dentre as técnicas de estatística multivariada, foi utilizada a Análise de Componentes Principais (ACP), utilizando precipitação total OND. Esta técnica é útil para reduzir a informação em um grande número de variáveis num menor conjunto e identificar a maior parte da variância global (Muñoz-Díaz e Rodrigo, 2004; Neto *et al.*, 2014). A fundamentação estatística para a PCA descrita abaixo foi utilizada por Guedes *et al.* (2010).

A partir da matriz de dados X (n postos \times p precipitação), cujas variáveis possuem média $E(x_j) = m(j)$ e variância $V(x) = s(j)$, $j = 1...p$, pode-se obter a matriz de variância e covariância S, pela equação 18.

$$S = \frac{1}{n} X \cdot X^t \quad (18)$$

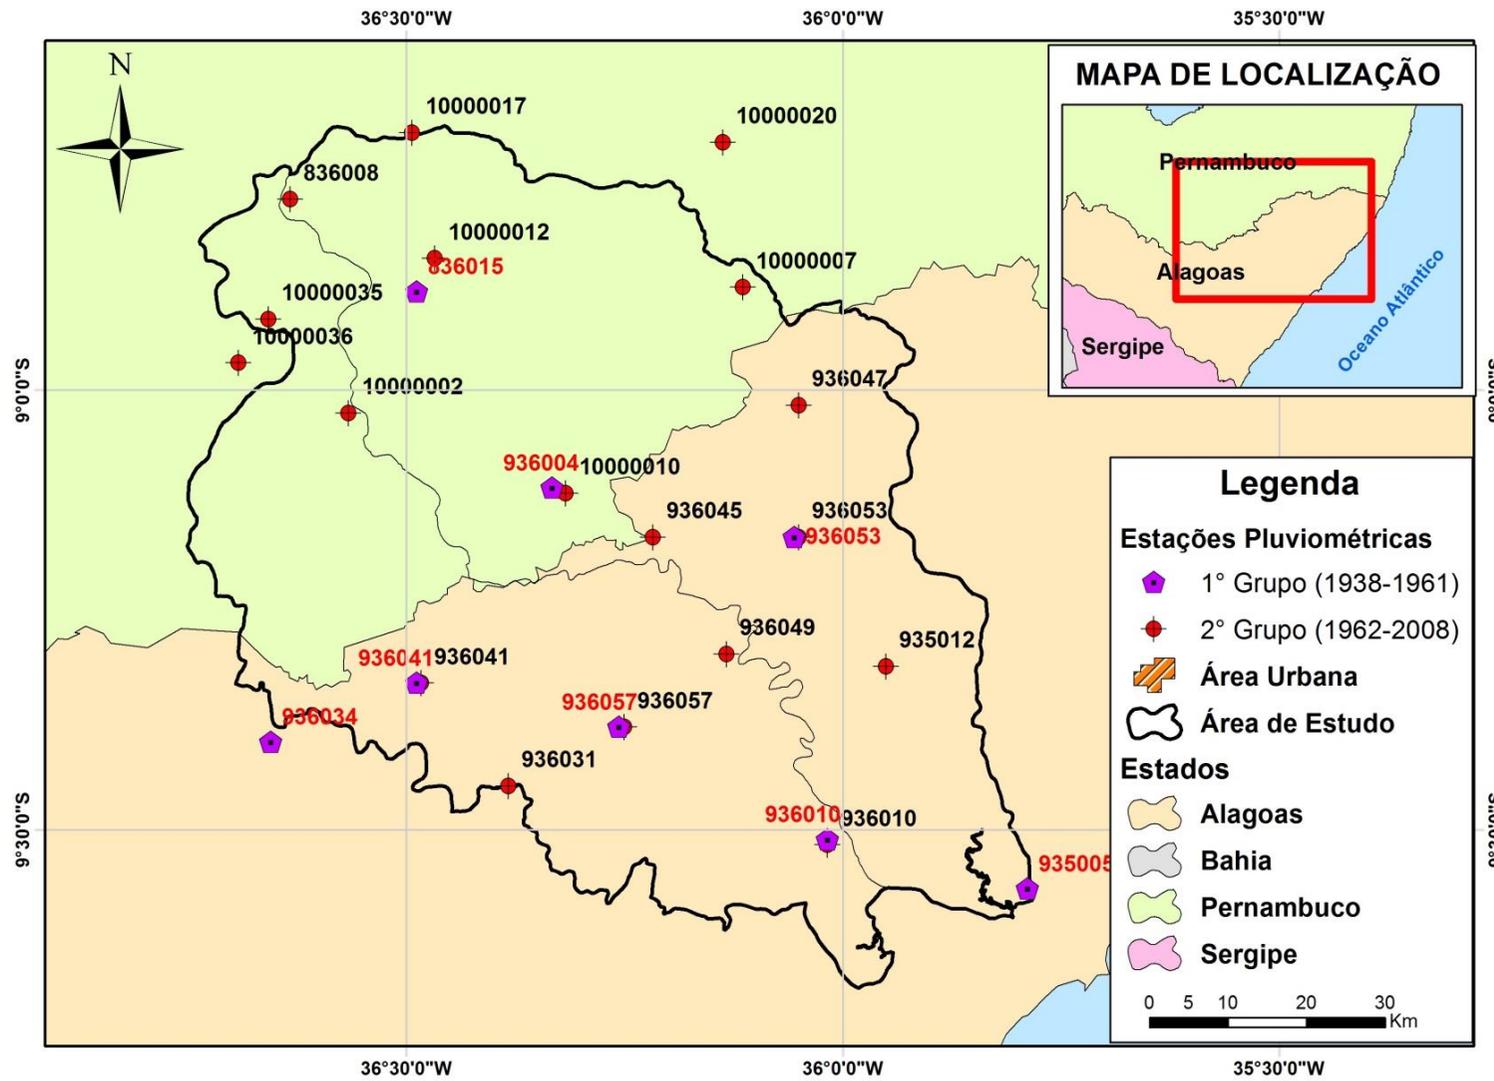


Figura 15 - Estações Pluviométricas Seleccionadas.

Considerando a matriz X com valores centrados, X^t sua matriz transposta e n é o número de estações. Normalizando a matriz das variáveis $x_1, x_2, x_3, \dots, x_p$ normalizadas (média zero e variância um) através da média e do desvio padrão, a matriz variância e covariância será igual à matriz de correlação R , dada pela equação 19.

$$R = \frac{1}{n} Z \cdot Z^t \quad (19)$$

Sendo a matriz R uma matriz de correlação simétrica e positiva de dimensão $(p \times p)$, será diagonalizável por uma matriz ortogonal A , de mudança de base denominada de matriz dos autovetores. Com isso, a matriz diagonal D , cujos elementos diagonais são os autovalores de R , é obtida pela equação 20.

$$D = A^{-1} \cdot R \cdot A \quad (20)$$

Onde A^{-1} é a inversa da matriz A .

As CP's U_1, U_2, \dots, U_p , são obtidas por combinações lineares entre a transposta dos autovetores de A^t e a matriz de observações X , conforme equação 21.

$$U = A^{-1} \cdot X \quad (21)$$

Os valores X_i do n -ésimo local podem ser estimados pela equação 22.

$$X_i = A_{j1} \cdot U_1 + A_{j2} \cdot U_2 + \dots + A_{jk} \cdot U_k + \dots + A_{jp} \cdot U_p \quad (22)$$

Onde as variáveis de U_p é o conjunto dos autovetores de X ordenados por ordem decrescente dos autovalores mais significativos de a em a_k , dado pela equação 23.

$$U_k = \sum_{j=1}^n a_{jk} \cdot X_k \quad (23)$$

O melhor ajuste das componentes é feito através da explicação da variância, pela ordem crescente dos autovalores. A soma dos valores próprios é a soma das variâncias centradas e normalizadas. Assim, a porcentagem da variância dos autovalores em ordem decrescente que é dada pela equação 24.

$$\%Var(X) = \frac{\sum_{i=1}^q \lambda_i}{\sum_{j=1}^p \lambda_j} \quad (24)$$

O método de rotação ortogonal usado foi o VARIMAX, que maximiza a variância em cada componente. A correlação entre a i -ésima variável original e a i -ésima componente principal é dada pela equação 25.

$$Coor(X_i \cdot Z_j) = a_{ij} \cdot \sqrt{\lambda_i} \quad (25)$$

Sendo a_{ij} é o j -ésimo elemento do i -ésimo autovetor e λ_i o i -ésimo autovalor.

Complementando a aplicação da ACP, a Análise de Agrupamento ou Análise *Cluster* foi utilizada com o intuito de identificar áreas homogêneas de impactos dos eventos de secas de forma simultânea e apontar padrões similares relativos aos efeitos das teleconexões climáticas sobre a região (Guedes, 2016).

A análise de cluster foi realizada utilizando o número suficiente de modos das componentes principais para explicar, pelo menos, 75% da variância total (Uvo, 2003), com o intuito de identificar de grupos de postos pluviométricos que apresentam similares padrões de variabilidade. Para esta análise, o método hierárquico (Ward) com predefinição da quantidade de grupos, definido como 2 sub-grupos de estações pluviométricas com semelhante variabilidade da precipitação nas bacias do rio Paraíba e Mundaú. O uso desse método, segundo Guedes (2016), permite fazer associações entre variáveis e identificar o grau de aproximação entre elas, além de propiciar ao pesquisador a escolha da quantidade e o tamanho dos grupos que deseja formar de acordo com seu objetivo e área de estudo.

Na análise de agrupamento, todos os processos de hierarquização são similares, iniciando-se pela determinação da função de agrupamento. Esta função descrita por Guedes (2016) de acordo com Wilks (2006) é usada como critério para medir a distância entre dois pontos x_i e x_j ou para estabelecer o quanto eles são parecidos. Aqui, para medir a dissimilaridade entre dois postos x_i e x_j utilizou-se a distância euclidiana, expressada por:

$$d(x_i, x_j) = |x_i - x_j| = \left[\sum_{k=1}^n P_i \cdot (x_{i,k} - x_{j,k})^2 \right]^{1/2} \quad (26)$$

Sendo, $x_{j,k}$ representa os valores mensais dos locais x_i e x_j , e P_i é o peso associado a cada indivíduo. O método de Ward (1963) procura por partições que minimizem a perda associada a cada agrupamento. Essa perda é quantificada pela diferença entre a soma dos erros quadráticos de cada padrão e a média da partição em que está contido. A soma dos quadrados dos desvios de p indivíduos organizados em k grupos, é definida pela equação 27.

$$SQD = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \quad (27)$$

Onde n é o número total de elementos do agrupamento, e x_i é o n -ésimo elemento do agrupamento. Nos métodos hierárquicos, o dendrograma, que é a representação gráfica de uma árvore de classificação, representa a ordem em que os dados foram agrupados. A obtenção dos grupos pode ser feita pelo dendrograma a partir do critério da inércia e

conhecimento prévio da região em estudo. As análises (Componentes Principais e Cluster) foram realizadas em MatLab® utilizando funções do *toolbox* de Análises Clusters.

4.4 CÁLCULO DO SPI

Após o agrupamento das estações, foi construído o polígono de Thiessen de cada subgrupo para encontrar um valor único para cada ano, do acumulado da precipitação nos meses de outubro e dezembro. Essa série temporal foi utilizada para calcular o índice de precipitação padronizada (SPI).

O cálculo do índice SPI para cada localidade é baseado em uma série longa de dados de precipitação, com no mínimo 30 anos de observações. Inicia-se com a determinação da distribuição de probabilidades de precipitação, a qual é modelada por meio da distribuição Gama. A função inversa é obtida por aproximação pela distribuição Normal, resultando no SPI (Albuquerque, 2010). A distribuição Gama é definida pela função de densidade de probabilidade apresentada na equação 28 a seguir:

$$g(x) = \frac{x^{\alpha-1} \cdot e^{-x/\beta}}{\beta^{\alpha} \cdot \Gamma(\alpha)} \quad (28)$$

Onde $\alpha > 0$ é o parâmetro de forma, $\beta > 0$ é o parâmetro de escala, $X > 0$ é a precipitação acumulada e $\Gamma(\alpha)$ é a função gama completa definida pela equação 29:

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} \cdot e^{-y} dy \quad (29)$$

Os parâmetros α e β da função densidade de probabilidade Gama são estimados para cada estação, para cada escala de tempo e para cada mês do ano. Utilizam-se as seguintes equações de máxima verossimilhança para estimar α e β , conforme equações 30 e 31, respectivamente.

$$\hat{\alpha} = \frac{1}{4 \cdot A} \cdot \left(1 + \sqrt{1 + \frac{4 \cdot A}{3}} \right) \quad (30)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (31)$$

Sendo A, uma estatística calculada a partir da equação 32.

$$A = \ln \bar{x} - \frac{\sum_{i=1}^n \ln x_i}{n} \quad (32)$$

Onde n é o número de precipitações observadas e \bar{x} , a precipitação média. Os parâmetros calculados, anteriormente, são utilizados para o cálculo da probabilidade da precipitação não superar certo valor associado a um evento, para o mês dado e escala de tempo da estação em questão, por meio da equação 33.

$$G(x) = \frac{1}{\Gamma(\hat{\alpha})} \int_0^x t^{\alpha-1} \cdot e^{-t} dt \quad (33)$$

Sendo $t = x/\hat{\beta}$ a variável reduzida da distribuição de Gama.

Devido ao fato da função gama completa $\Gamma(\hat{\alpha})$ ser indefinida para $x = 0$, bem como a possibilidade da distribuição de precipitação poder conter zeros, a distribuição de probabilidade acumulada, denotada por $H(x)$, é calculada através da equação 34.

$$H(x) = q + (1 - q) \cdot G(x) \quad (34)$$

Sendo q a probabilidade de ocorrência de valores nulos. Se m for o número de zeros numa série temporal de precipitação de tamanho n , logo q pode ser estimado por m/n . Para facilitar o cálculo do valor de Z ou SPI, em todas as escalas temporais possíveis e para cada mês do ano, utiliza-se equação 35 que converte a probabilidade acumulada na variável aleatória normalizada (Z):

$$Z = SPI = - \left(t - \frac{c_0 + c_1 \cdot t + c_2 \cdot t^2}{1 + d_1 \cdot t + d_2 \cdot t^2 + d_3 \cdot t^3} \right), \text{ para } 0 < H(x) \leq 0,5$$

$$Z = SPI = + \left(t - \frac{c_0 + c_1 \cdot t + c_2 \cdot t^2}{1 + d_1 \cdot t + d_2 \cdot t^2 + d_3 \cdot t^3} \right), \text{ para } 0,5 < H(x) \leq 1,0 \quad (35)$$

Sendo:

$$t = \sqrt{\ln \left(\frac{1}{(H(x))^2} \right)}, \text{ para } 0 < H(x) \leq 0,5$$

$$t = \sqrt{\ln \left(\frac{1}{(1 - H(x))^2} \right)}, \text{ para } 0,5 < H(x) \leq 1,0 \quad (36)$$

$$c_0 = 2,515517; c_1 = 0,802853; c_2 = 0,010328$$

$$d_1 = 1,432788; d_2 = 0,189269; d_3 = 0,001308.$$

Para o cálculo do SPI, foi escrita uma rotina em Matlab®, a mesma pode ser vista no Apêndice A.

4.5 CORRELAÇÃO DE SPEARMAN

Para a seleção dos preditandos, foi utilizada a correlação de Spearman, que visa identificar uma relação crescente ou decrescente em formato de curva das séries analisadas, que é dada pela equação 37.

$$\rho = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{(n^3 - n)} \quad (37)$$

Sendo: $d_i = x_i - y_i$ a diferença de postos dos escores da duas séries e n , o número de dados das séries. Para esta correlação, consideraram-se significativos os limites correspondentes ao nível de significância de 95% calculado pelo teste de Monte Carlo, que consiste:

1. Inicialmente calcula-se a correlação da série completa e ordenada pela equação 20;
2. São geradas várias vezes (iterações) amostras, a partir da amostra inicial, com os valores aleatoriamente ordenados. Tipicamente, utilizam-se mais de 1000 iterações;
3. Calculam-se os valores de correlações (equação 27) das diferentes amostras desordenadas;
4. Os valores das correlações (normalmente 1000) são colocados na ordem crescente;
5. Calculam-se os quantis superiores e inferiores (geralmente com 95% e 99%) da série encontrada no item anterior;
6. Comparam-se os valores dos coeficientes de correlação calculados no item 1 com os valores correspondentes aos seus quantis, para verificar o nível de significância estatística;

Para este procedimento, foi escrito uma rotina em Matlab® e pode ser acessado no Apêndice B.

4.6 TRANSFORMADA ONDELETA

Após a seleção dos preditandos, a Transformada Wavelet Contínua (TW) foi aplicada às séries de preditores (SPI) e preditandos (índice climáticos) para extração de suas

características. Ainda assim, foram extraído sinais de diferentes níveis de decomposição da wavelets original da série de SPI. Para identificação de correlações significativas entre as séries, foi necessária a aplicação em conjunto da Transformada Cruzada Wavelet (XWT) e da Transformada Coerência Wavelet (WTC). Para a aplicação desse item da metodologia, foi utilizado um pacote de rotinas computacionais, elaboradas na linguagem de programação Matlab®, disponibilizadas no *link*: <http://noc.ac.uk/using-science/crosswavelet-wavelet-coherence>.

4.7 REDE NEURAS ARTIFICIAIS

Esta parte da metodologia leva em consideração os procedimentos de aplicação de Rede Neural Artificial (RNA) utilizada por Bravo (2010), com algumas variações para melhor se adequar ao foco deste trabalho.

4.7.1 Divisão e Pré-processamento dos Dados

A divisão dos dados foi feita em três conjuntos de dados: treinamento, validação e verificação, sendo utilizado o método da validação cruzada. Desse modo, foram feitas 3 tipos de divisão, na ordem: treinamento-verificação-validação, os quais são: 70-15-15, 60-20-20 e 50-25-25. Geralmente, algumas estatísticas de ambos os conjuntos dos dados são estimadas para verificar as similaridades entre eles (por exemplo, a média e o desvio padrão). Assim, foi desenvolvido um algoritmo, em linguagem Matlab®, que divide os dados e garante a similaridades destes conjuntos (Ver Apêndice C). Além disto, este algoritmo foi escrito para garantir que o maior e menor valor da série fosse inserido no conjunto de treinamento, e o segundo maior e menor no conjunto de validação.

Posteriormente, é feito o pré-processamento das variáveis de saída. Os valores das variáveis foram padronizados utilizando-se a equação 38.

$$x_{novo} = -0.9 + \left(\frac{x_{orig} - x_{min}}{x_{max} - x_{min}} \right) \cdot 1.8 \quad (38)$$

Em que x_{novo} é o valor da variável padronizada no intervalo [-0.90; 0,90]; x_{orig} é o valor original da variável na sua respectiva unidade; x_{min} é o valor mínimo da variável original na sua respectiva unidade; x_{max} é o valor máximo da variável original na sua respectiva unidade.

A padronização dos dados é importante para que seja obtida uma melhora na eficiência das técnicas utilizadas no treinamento da RNA, fugindo da região de saturação das soluções, portanto a utilização desta técnica visa melhorar o desempenho quando da utilização de variáveis que incluem grandes magnitudes ou quando existem grandes diferenças entre os valores das mesmas, devido às diferentes unidades.

4.7.2 Treinamento e Validação

Foi utilizado um método de busca global para o treinamento da RNA, baseado em algoritmos evolucionários, denominado SCE-UA (*Shuffled Complex Evolution – University of Arizona*). Trata-se de um algoritmo evolucionário de otimização global mono-objetivo, inicialmente desenvolvido para a calibração de modelos hidrológicos (Bravo, 2010).

Nesse algoritmo, o processo de busca começa a partir de uma população de soluções candidatas, selecionadas, aleatoriamente, a partir do espaço factível, inicialmente estabelecido de acordo com a definição dos limites superior e inferior dos parâmetros. A população inicial é então dividida em grupos, denominados "complexos", cada um constituído por $2n+1$ soluções candidatas, onde n é o número de parâmetros do modelo (número de pesos e bias, no caso dos modelos de redes neurais artificiais). Cada complexo evolui para um ótimo em forma independente, através de gerações, usando um procedimento baseado no método simplex. No entanto, em um número pré-definido de gerações, os complexos são embaralhados para promover o compartilhamento das informações encontradas por cada grupo.

As etapas do algoritmo são apresentadas a seguir, conforme Duan *et al.* (1992):

1. Início do processo: são selecionados os valores dos parâmetros do algoritmo, $p \geq 1$ e $m \geq 2n+1$, onde p representa o número de complexos, m o número de pontos em cada complexo e n o número de parâmetros do problema de otimização (variáveis de decisão). O tamanho da população (s) é igual ao produto de p e m ;
2. Geração da população: são gerados s conjuntos de parâmetros do modelo de simulação, entre os limites máximo e mínimo definidos para cada parâmetro. Esses conjuntos são escolhidos de forma aleatória, utilizando uma distribuição de probabilidades uniforme;
3. Hierarquização dos pontos: os pontos da população são avaliados com a função objetivo e reorganizados, em ordem crescente de função-objetivo, formando o conjunto D . O primeiro ponto de D apresenta o menor (melhor) valor da função objetivo;

4. Divisão em complexos: a população D de s pontos é dividida em p complexos, cada um com m pontos. A divisão de complexos segue a regra $A^k = \{x_j^k, f_j^k\}$ onde $x_j^k = x_{k+p(j-1)}$ e $f_j^k = f_{k+p(j-1)}$, para $j = 1, \dots, m$. Onde k é o número de complexo, que varia de 1 a p, j é o número do ponto dentro do complexo, que varia de 1 a m; x é o grupo de parâmetros e f é o valor da função-objetivo. Esta regra obriga a que cada complexo esteja integrado a um certo número de soluções “boas” (baixo valor da função objetivo) e de soluções “ruins” (altos valores da função-objetivo);
5. Evolução dos complexos: a cada complexo é dada a oportunidade de evoluir com base no método de Evolução Competitiva de Complexos, explicado mais adiante.
6. Mistura dos complexos: os complexos A^k são novamente agrupados na população D, e os pontos reorganizados, em ordem crescente de função-objetivo;
7. Teste de convergência: se o critério de convergência é satisfeito, o algoritmo se encerra. Caso contrário, o procedimento retorna ao passo 3;

O algoritmo de Evolução Competitiva de Complexos, usado no passo 5 para a evolução de cada complexo do algoritmo SCE-UA, foi descrito por Duan *et al.* (1992) como segue:

1. Início: são selecionados os valores de q, α' e β , que são parâmetros do SCE-UA. Os valores são escolhidos de forma que $2 \leq q \leq m$, $\alpha' \geq 1$, e $\beta \geq 1$;
2. Atribuição de pesos: cada um dos pontos do complexo recebe um peso, proporcional à sua posição na warrquia do complexo. Os pesos são atribuídos em função de uma distribuição de probabilidades trapezoidal, considerada em cada um dos complexos através da equação 39:

$$p_i = \frac{2 \cdot (m + 1 - i)}{m \cdot (m + 1)} \quad (39)$$

Sendo p_i é o peso do ponto i; i é a posição do ponto no complexo. Os valores dos pesos variam de forma linear entre o valor máximo, atribuído ao ponto $i=1$, até o valor mínimo, superior a zero, atribuído ao ponto $i=m$.

1. Seleção dos pais: um sub-complexo de q pontos (u_j onde $j=1, \dots, q$) é escolhido de forma aleatória de cada complexo. A probabilidade de cada ponto do complexo ser parte do sub-complexo é dada pelo peso definido em 2;

2. Geração dos filhotes: os pontos do sub-complexo são organizados de forma crescente de função-objetivo e calculado o centroide dos $q-1$ melhores pontos do sub-complexo, segundo a equação 40.

$$g = \frac{1}{q-1} \cdot \sum_1^{q-1} u_j \quad (40)$$

A continuação, as coordenadas de um novo ponto são calculadas como segue:

- a) O ponto X_R é chamado de “ponto de reflexão” e suas coordenadas são calculadas de acordo com a equação $X_R=2g-u_q$.
- b) Se X_R estiver contido no espaço factível dos parâmetros, é calculado o valor da função-objetivo F_R , e o procedimento continua no passo c. Caso contrário, é definido o menor hipercubo que contém todos os pontos do complexo e gerado um ponto X_A , de forma aleatória, no interior deste hipercubo. Posteriormente, é calculada F_A e feito $X_R=X_A$ e $F_R=F_A$ (passo de mutação).
- c) Se $F_R < F_q$, u_q é substituído por X_R e o procedimento continua no passo e. Caso contrário, as coordenadas de um novo ponto (X_C), chamado de “ponto de contração”, são calculadas com a equação $X_C=(g+u_q)/2$. Posteriormente, é calculada F_C .
- d) Se $F_C < F_q$, u_q é substituído por X_C e o procedimento continua no passo e. Caso contrário é definido o menor hipercubo que contém todos os pontos do complexo e gerado um ponto X_A , de forma aleatória, no interior deste hipercubo. Posteriormente é calculada F_A e substituído u_q por X_A .
- e) Repetir os passos a-d um número α' de vezes.
 1. Os pontos de cada um dos sub-complexos são devolvidos, modificados a cada complexo;
 2. Os passos 1 a 5 são repetidos um número β de vezes;

A Figura 16 apresenta as alternativas na geração do novo ponto num sub-complexo considerando um problema hipotético de otimização com duas variáveis de decisão. Os pontos pretos pertencem a um complexo. Os pontos X_i ($i=1, 2, 3$) foram selecionados para formar um sub-complexo onde o ponto X_3 apresenta o maior valor de função-objetivo e, em consequência, é o pior indivíduo do sub-complexo.

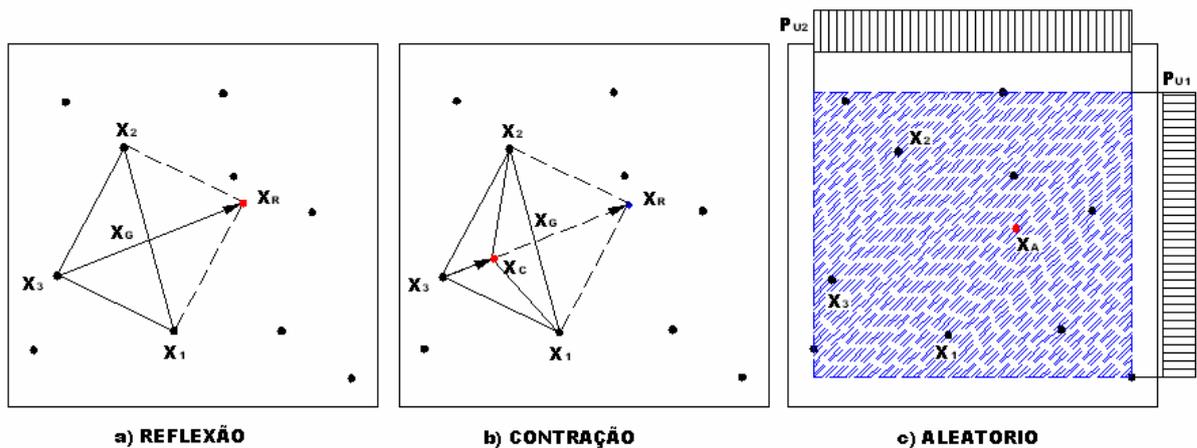


Figura 16 - Alternativas na geração do novo indivíduo num sub-complexo.
(Fonte: Bravo, 2010)

A rotina do algoritmo explicitado anteriormente foi obtida no site www.yarpiz.com em linguagem Matlab®.

O algoritmo SCE-UA foi desenvolvido para resolver problemas de otimização sem restrições. No entanto, adicionando um termo de penalidade na função-objetivo, que dependa da verificação de restrições, permite trabalhar com problema de otimização com restrições. Dessa forma, a função-objetivo durante o processo de treinamento se baseia na teoria de estabelecimento dos valores dos pesos com sustento físico, estabelecido por Olden e Jackson (2002), conforme pode ser visto na equação 41.

$$\begin{aligned} \text{Min } \therefore FO &= 1 - CE + Pen \\ \text{s.t } ROCWX_i &> 0 \text{ ou } < 0 \end{aligned} \quad (41)$$

Se FO é a função-objetivo; CE é o coeficiente de eficiência ou de Nash-Sutcliffe; Pen é uma penalidade, cujo valor depende da verificação de restrições, o valor da penalidade é igual a zero quando as restrições são atendidas. No caso contrário, a penalidade apresenta um valor maior que zero. $ROCWX_i$ é a contribuição relativa da variável de entrada X_i , advém da técnica *overall connection weight approach* (Olden et al., 2004; Kingston et al., 2005), que introduzem restrições na contribuição de cada variável de entrada na estimativa da variável de saída, permite que seja verificada a plausibilidade física da relação entre variáveis de entrada e saída do modelo, que será explicitado em seguida.

A relação entre as variáveis de entrada e a variável de saída do modelo de rede neural artificial pode ser avaliada, e a busca durante o processo de treinamento orientado a uma região fisicamente factível do espaço de busca. Isso resulta de vital importância quando poucos dados existem e onde a função-objetivo resulta complexa, com um grande número de

ótimos locais que dificulta a obtenção do ótimo global. O OCW de uma variável de entrada, por exemplo X_1 , na Figura 17, é calculado utilizando a equação 42.

$$OCW_{x_1} = w_{1,1} \cdot Wh_1 + w_{1,2} \cdot Wh_2 + w_{1,3} \cdot Wh_3 + w_{1,4} \cdot Wh_4 \quad (42)$$

Sendo OCW_{X_1} é o *Overall Connection Weight* da variável de entrada X_1 ; $w_{1,i}$, é o peso de conexão entre os primeiro neurônio da camada de entrada e o i -ésimo neurônio da camada intermediária ($i = 1$ a 4, na Figura 17); Wh_i é o peso de conexão entre o h_i neurônio da camada intermediária e o neurônio da camada de saída.

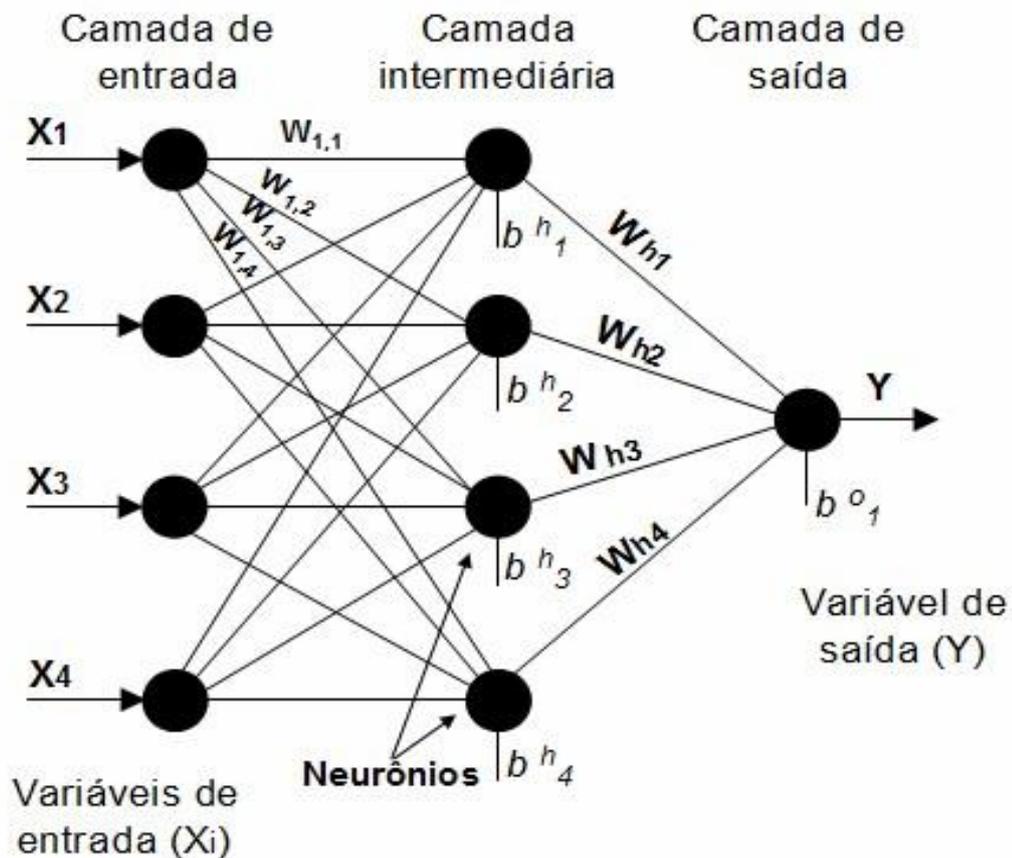


Figura 17 - Cálculo do OCW_{x_1} de uma rede neural artificial progressiva com 4 neurônios na camada de entrada e 4 na camada intermediária.
(Fonte: Adaptado de Bravo 2010)

Kingston *et al.* (2005) propôs o uso de um valor relativo, chamado ROCWs, ao invés do OCWs, para determinar a contribuição relativa de cada entrada, conforme apresentado a seguir na equação 43, para a rede neural apresentada na Figura 17.

$$ROCW_{x_1} = \frac{OCW_{x_1}}{|OCW_{x_1}| + |OCW_{x_2}| + |OCW_{x_3}| + |OCW_{x_4}|} \quad (43)$$

Os OCWs e os ROCWs são aproximações da contribuição real de uma variável de entrada. No entanto, este procedimento proporciona os melhores resultados em termos de quantificação da importância de cada variável de entrada ao modelo de rede neural artificial,

em comparação com outros métodos comumente utilizados (Olden *et al.*, 2004). O algoritmo do Modelo de Rede Neural com sustento físico, proposta por Kingston *et al.* (2005), foi desenvolvido no ambiente Matlab® e acoplado ao algoritmo SCE-UA. Assim, o uso do modelo de Rede Neural apresentado aqui foi utilizado com dois intuitos, conforme pode ser descrito em seguida.

a) Reconhecimento dos padrões (comportamento) das variáveis de entrada

Para este objetivo foi empregado uma rede neural com três camadas, com dois neurônios na camada de entrada preenchida por dois índices climáticos (ver item 2.1) selecionados à luz das etapas anteriores, tendo o cuidado de utilizar sempre a combinação de um índice que descreva as condições do oceano Atlântico e outro do Pacífico, com intuito de verificar qual o Oceano possui maior influência na variabilidade de precipitação na estação seca do LNEB. A camada intermediária e de saída é dada com apenas um neurônio, como pode ser visto na Figura 18. A função de ativação entre as camadas é a tangente hiperbólica sigmoide.

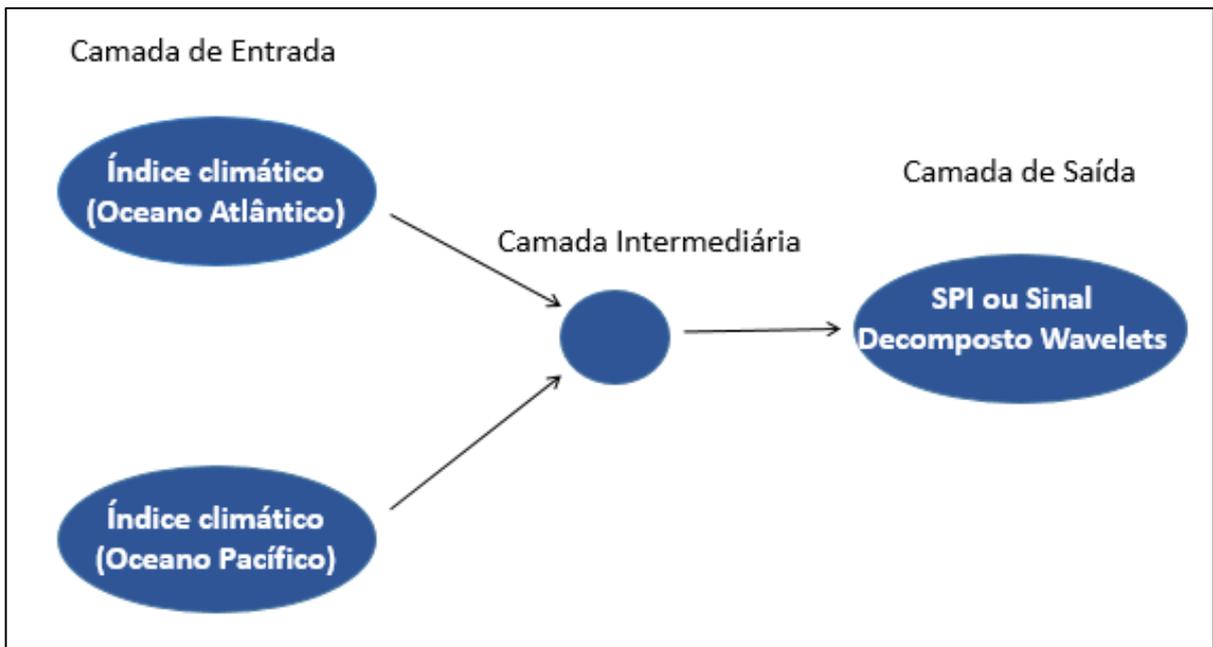


Figura 18 - Topologia da Rede Neural Artificial Utilizada Para Reconhecimento do Padrão das Variáveis.

Nesta etapa, foi analisada a influência dos oceanos na variação interanual e decadal da precipitação, para tal, no primeiro caso, a camada de saída será dada pela série do SPI e de entrada com índices climáticos que representam anomalias interanuais, enquanto que o segundo é dado pelo sinal decomposto da wavelets para resolução temporal decadal e na entrada índices climáticos da ordem decadal ou multidecadal. Foram realizadas 10 simulações

para cada cenário e para cada configuração de divisão dos dados, com 1000 iterações cada ou menos a depender dos critérios da validação cruzada, buscando sempre a configuração que apresenta maior estabilidade nos resultados encontrados.

b) Previsão

Neste item, também foi utilizada um RNA com três camadas. No entanto, a camada de entrada foi preenchida por dois ou mais índices climáticos - IC (neurônios), testando diversas combinações para encontrar a melhora na previsão do SPI. A camada intermediária terá o número de neurônios igual à da camada de entrada, por fim, a camada de saída terá apenas um neurônio correspondente ao SPI, conforme pode ser visto na Figura 19. A função de ativação entre as camadas também foi a tangente hiperbólica sigmoide, sendo realizadas 10 simulações para cada combinação e para cada configuração de divisão dos dados, com 1000 iterações cada, buscando sempre a configuração que apresenta maior estabilidade nos resultados encontrados.

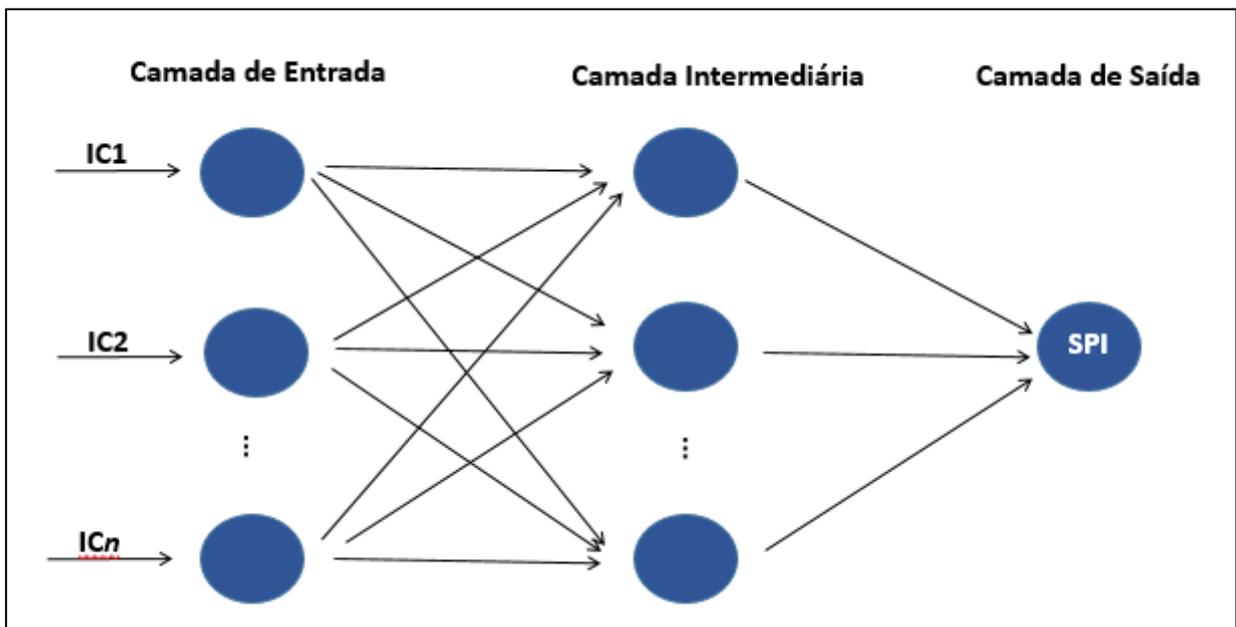


Figura 19 - Topologia da Rede Neural Artificial Utilizada Para Previsão.

4.7.3 Avaliação do Desempenho

Como medidas de desempenho para avaliação, os resultados da RNA são utilizados na etapa do reconhecimento dos padrões dos valores do coeficiente de correlação de Pearson, coeficiente de correlação de Spearman e o erro médio quadrático - RMSE aplicados ao conjunto de dados de verificação. Enquanto que para a previsão são estudadas as medidas de desempenho citadas além do coeficiente de Nash para universo do treinamento, validação e

verificação. Para a busca da estabilidade da rede, serão calculados a média e desvio padrão dos resultados das 10 simulações realizadas para cada configuração a fim de observar a oscilação da mesma. Além disso, foram analisados se os valores previstos se enquadram na categoria de seca dos valores observados. Para isto foi escrita uma rotina na linguagem Matlab®, conforme o Apêndice D.

5 RESULTADOS

5.1 ANÁLISE MULTIVARIADA

Com a aplicação da análise de componentes principais nos postos selecionados do segundo conjunto (18 estações com série histórica de 47 anos), observou-se que os três primeiros modos explicam mais de 75% da variância total da precipitação para o trimestre OND, conforme pode ser visto na Tabela 7.

Tabela 7 - Explicação da Variabilidade da precipitação dos 3 primeiros modos da PCA.

Modos	1°	2°	3°
Explicação (%)	62,59	8,62	5,16

Em relação aos autovetores, a primeira componente principal consiste em valores positivos para todo o domínio (Figura 20), com maiores valores para o centro da área de estudo, notando-se uma pequena redução dos valores na parte superior das bacias, principalmente, após uma barreira topográfica significativa localizada na porção oriental central do rio Paraíba do Meio e Mundaú. Os valores dos autovetores da segunda componente principal indicam uma clara separação entre as partes superior e inferior das bacias, consistindo de valores positivos e negativos, respectivamente (Figura 20), com uma região de transição na parte central das bacias.

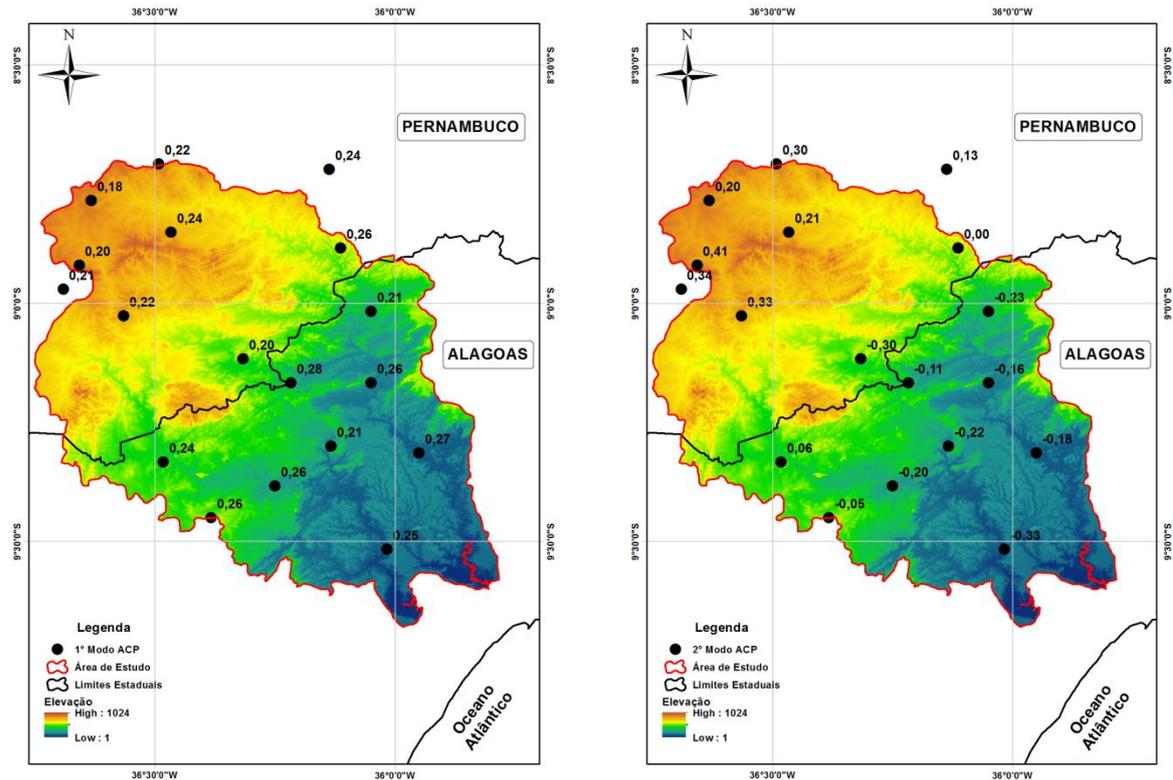


Figura 20 - Autovetores do 1º e 2º Modo da Análise de Componente Principal da Precipitação de OND.

A análise de cluster (Figura 21) indicou dois grupos homogêneos (regiões) bem definidos (RH1 e RH2) de precipitação OND, seguindo, principalmente, o padrão espacial encontrado na segunda componente principal. Verifica-se que a primeira componente corresponde ao desvio da precipitação no período seco, a qual é influenciada pelas características fisiográficas da região (barreiras topográficas) aliado a pequenas e sinóticas escalas meteorológicas, sugerindo a distribuição não homogênea dos padrões de precipitação no trimestre seco na região de estudo. Já para a segunda componente, parece ser mais influenciada pelas condições climáticas, uma vez que a estrutura espacial dos autovetores se mostraram em acordo com os climas de cada RH, que pode ser corroborado pela análise de correlação de Spearman dos dois primeiros modos da ACP com as médias dos índices climáticos do trimestre OND (Tabela 8), mostrando-se que apenas o NAO apresentou correlação significativamente (negativa) estatística.

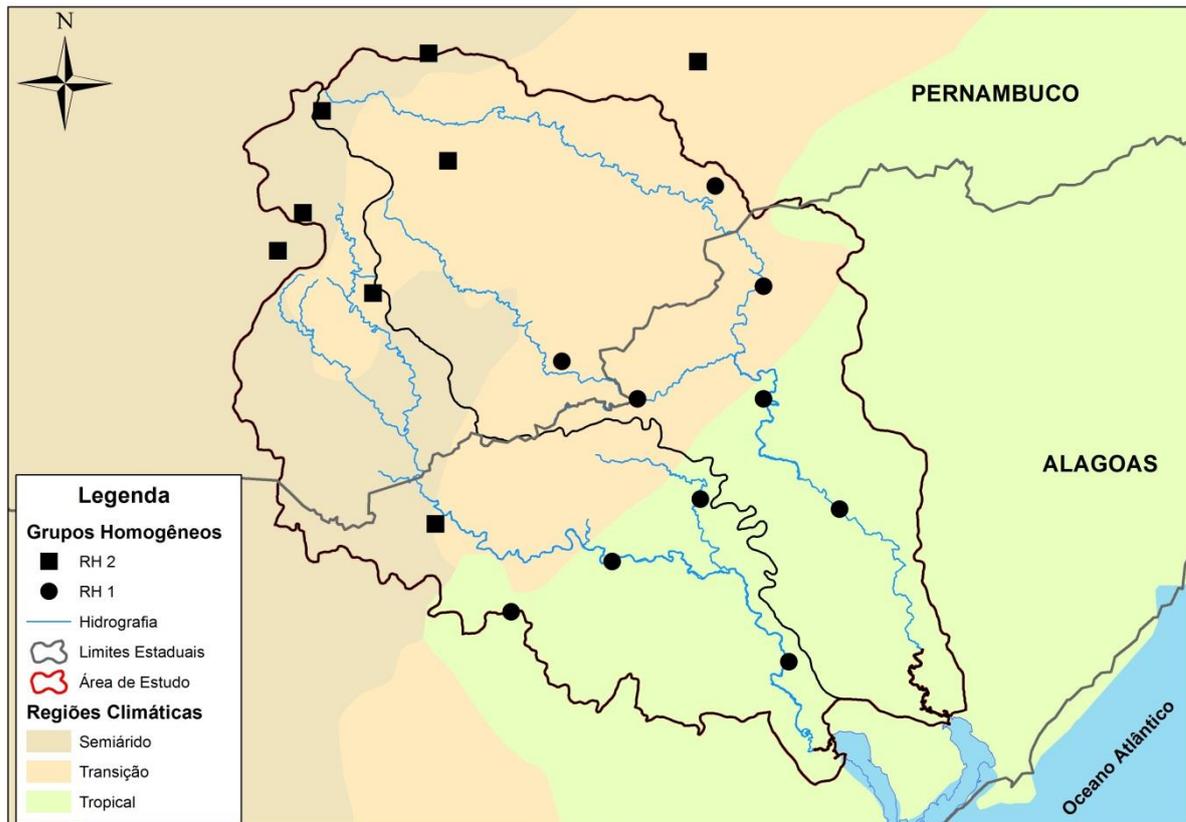


Figura 21 - Análise de Cluster da Similaridade Espacial da Precipitação OND E Classificação Climática.

A Figura 22, por sua vez, traz o dendograma dos dados de precipitação para o trimestre seco das bacias estudadas, verifica-se uma subdivisão bem definida, que está espacializada na Figura 21.

Tabela 8 - Correlação de Spearman Entre os Dois Primeiros Modos do PCA e os Índices Climáticos.

Modos	Índices Climáticos						
	NAO	PDO	AMO	SOI	Niño 3.4	AMM_wind	AMM_sst
1°	-0,1864	-0,0378	-0,1858	0,0944	-0,0165	-0,2143	-0,1995
2°	-0,4393*	-0,1217	-0,1190	-0,0616	-0,0070	0,0113	-0,1651

* correlação com 95% de significância realizado pelo teste de Monte Carlo.

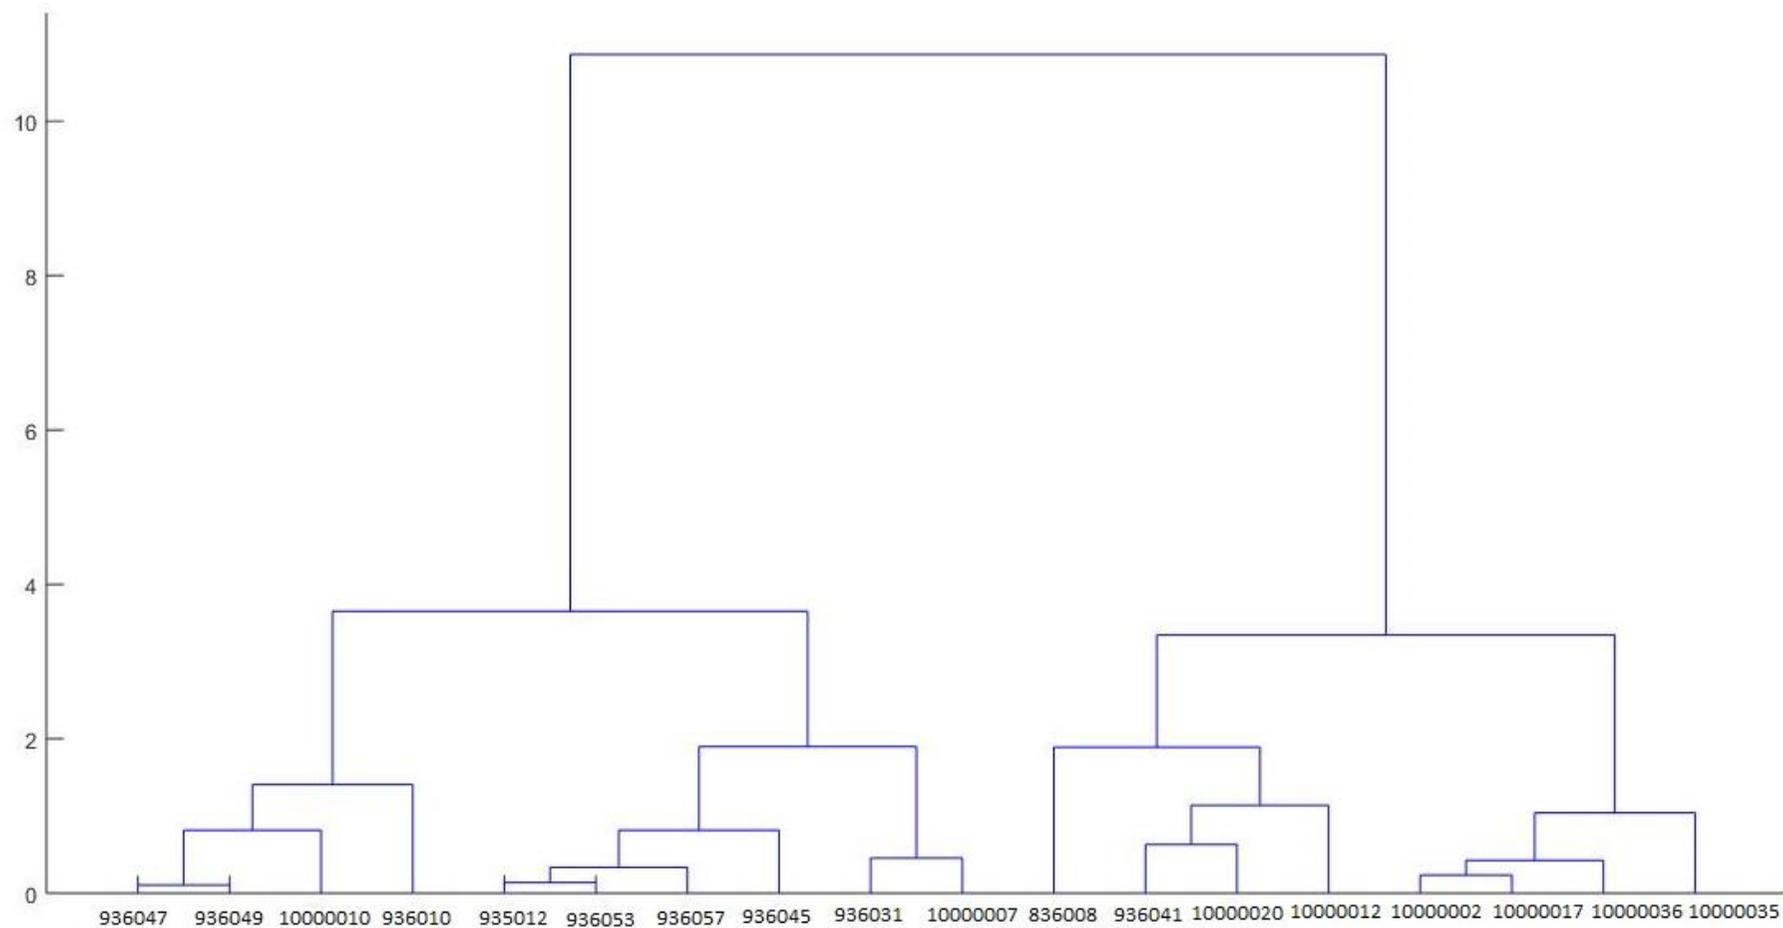


Figura 22 - Dendrograma dos dados de Precipitação do Trimestre Seco nas Bacias do Rio Paraíba e Mundaú.

Esses resultados sugerem que a maior parcela da variância da precipitação (62,59%), dos meses de outubro a dezembro, não pode ser explicado por fenômenos climáticos globais, como ENOS e Dípolo do Atlântico e vão a conformidade com Costa *et al.* (2016) que utilizaram o AMC encontrando apenas 28,1% da variabilidade da precipitação (de OND) relacionada com os padrões de temperatura dos Oceanos Pacífico Tropical, a leste Atlântico Tropical e do Oceano Índico.

5.2 ANÁLISE DOS EVENTOS DE CHUVA

Nesta etapa, a subdivisão decorrente da análise de agrupamento, do item anterior, serviu para estender a série de precipitação de cada região homogênea. Assim, o primeiro conjunto de postos selecionados (1938 - 1961) foi utilizado sendo identificadas suas localizações dentro das áreas homogêneas e calculada a precipitação média através do polígono de Thiessen. O mesmo tratamento foi dado ao segundo conjunto de estações (1962 - 2008), obtendo uma série ininterrupta com dados mensais de janeiro de 1938 a dezembro de 2008, e essa série temporal foi utilizada para calcular o índice de precipitação padronizada (SPI) com a escala de tempo de três meses (de acordo com o Apêndice A) para o trimestre OND das estações selecionadas, doravante chamada SPI3.

Dessa forma, a Figura 23 traz a série anual do SPI3 para as duas sub-regiões (RH) da área de estudo, com os valores limiares das categorias de seca de acordo com Agnew (2000). É importante destacar que a Figura 23 não traz a classificação dos eventos de seca em relação aos anos estudados. Na verdade, o que se tem é o comportamento da variabilidade anual (déficit/acrécimo) da precipitação da estação seca.

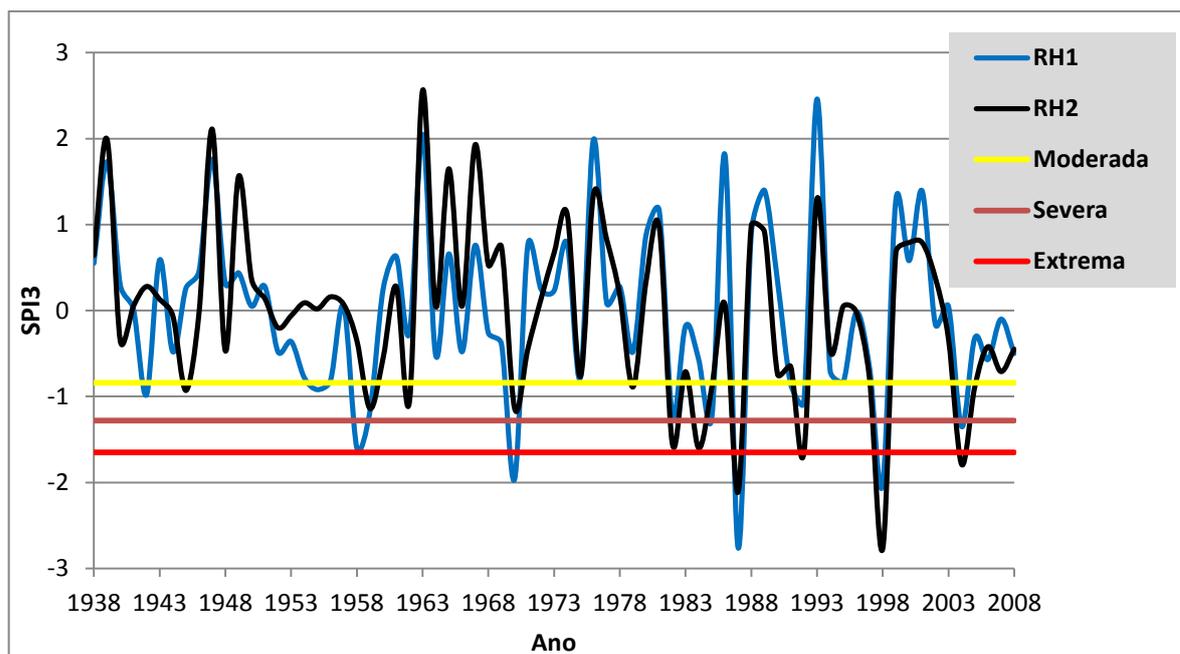


Figura 23 - Série de SPI3 das Regiões Homogêneas (RHs).

Em relação ao regime pluviométrico nas sub-regiões, observa-se que antes de 1978 há um comportamento diferente, enquanto que após 1978 as séries são bastante similares, com exceções apenas nas magnitudes. Verificou-se também que após o ano de 1978 os eventos de déficit hídrico se tornaram mais intensos e frequentes, destacando-se os anos de 1987, 1998 e 2004 que apresentaram valores extremos. Nesse sentido, Costa *et al.* (2016), ao analisarem padrões espaço-temporal das secas nas Bacias do Rio Mundaú e Paraíba, verificaram que após a década de 1990 tem aumentado notadamente a frequência destes eventos. Isso mostra que a tendência apresentada em muitos países para o período chuvoso, citada por Mishra e Singh (2010), que as secas têm se tornado, recentemente, cada vez mais frequentes também é vista na região de estudo. Isso também sugere que a região tem relação com a PDO também para estação seca, pois, após 1977, apresentou fase quente, e Da Silva (2009) encontrou a diminuição da precipitação, da quadra chuvosa, na Bacia do Rio Mundaú.

Com o intuito de verificar as relações entre a ocorrência dos eventos de diminuição de precipitação da estação seca e os fenômenos globais, foram calculados os coeficientes de correlação de Spearman entre as séries de SPI3 e as séries temporal de índices climáticos (SOI, Niño 3.4, PDO, NAO, AMO, AMM_sst e AMM_wind) com defasagem de até seis em relação à estação seca. Os resultados das correlações podem ser vistos na Tabela 9.

Tabela 9- Correlação de Spearman entre SPI e índices Climáticos.

Índice Climático	RH	MÊS					
		ABRIL	MAIO	JUNHO	JULHO	AGOSTO	SETEMBRO
AMO	1	-0,187	-0,206	-0,180	-0,171	-0,112	-0,137
	2	-0,112	-0,169	-0,147	-0,141	-0,094	-0,138
SOI	1	0,261*	0,081	0,047	0,100	-0,056	-0,002
	2	0,240*	0,053	0,121	0,139	0,033	0,016
AMM_wind	1	-0,121	-0,209	-0,211	-0,063	-0,101	-0,036
	2	-0,126	-0,293*	-0,153	0,019	0,041	-0,046
AMM_sst	1	-0,196	-0,235	-0,247	-0,176	-0,149	-0,139
	2	-0,158	-0,212	-0,258*	-0,191	-0,159	-0,152
NAO	1	-0,020	0,024	0,185	-0,170	0,103	-0,037
	2	0,006	-0,025	0,201	-0,086	-0,082	-0,017
Niño 3.4	1	-0,360*	-0,250*	-0,130	-0,038	0,012	0,020
	2	-0,329*	-0,264*	-0,180	-0,102	-0,054	-0,046
PDO	1	-0,004	-0,046	-0,047	-0,119	-0,092	-0,009
	2	-0,159	-0,228	-0,109	-0,213	-0,190	-0,070

* correlação com 95% de significância realizado pelo teste de Monte Carlo.

À luz da análise de correlação realizada, verifica-se que a região o SPI da área de estudo possui baixa correlação com os índices climáticos, destacando-se apenas o Niño 3.4 (abril e maio) e o SOI (abril), em relação ao oceano Atlântico, os resultados são piores, podendo citar isoladamente o AMM_sst de junho para RH2 e AMM_wind de maio para RH1. Vê-se então a necessidade de analisar a correlação dos índices climáticos com a precipitação em diferentes escalas temporais e frequências que a correlação de Spearman não consegue captar, logo se faz o uso da análise de Wavelets que será apresentada a seguir.

5.3 TRANSFORMADA ONDELETA

A Transformada Ondeleta ou Wavelet (WT) foi utilizada para determinar as escalas dominantes da série temporal do SPI3, antes disso, porém, foi realizada uma análise da SPI3 filtrando dos seus valores normais (Ver Tabela 2), ou seja, apresentando apenas os valores de SPI que seu módulo é maior do que 0,85, para tal foi calculado uma variável denominada SPI3*, onde para valores que seu módulo é menor 0,85 foi atribuído o valor zero, para

módulos maiores foi feita a subtração do mesmo por 0,85. O resultado desta variável para a região de estudo pode ser visto na Figura 24.

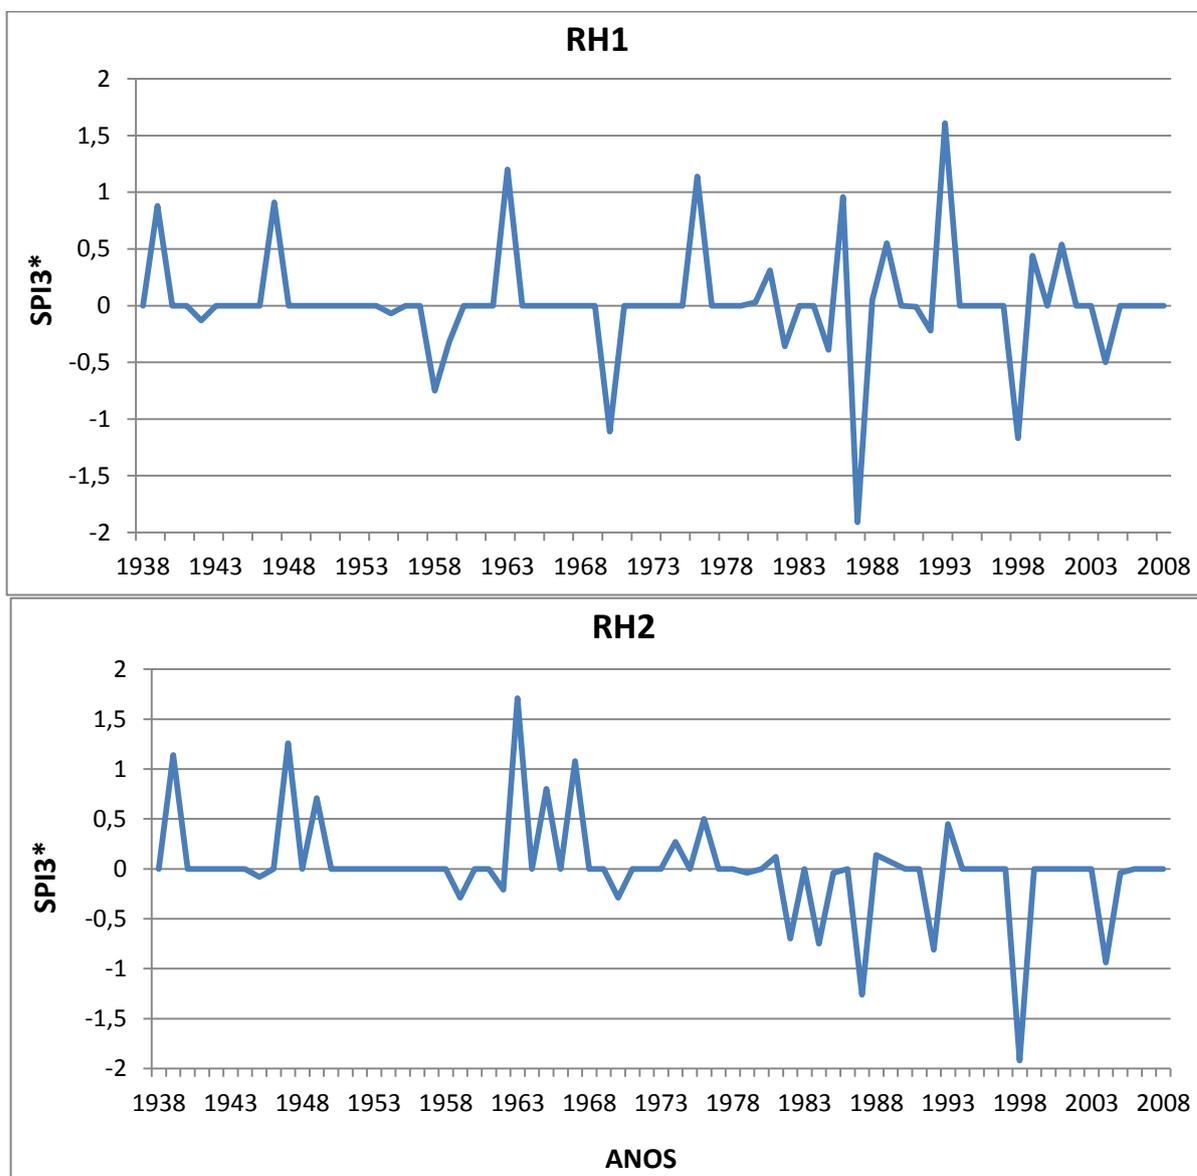


Figura 24- Série de SPI3* para Regiões Homogêneas (RHs).

Observando-se a imagem superior da Figura 24, verifica-se que a série de SPI do RH1, entre 1947 a 1976, possui um ciclo de aproximadamente 10 anos, e a partir de 1986 tem-se um ciclo menores (da ordem de 4 anos), no entanto com amplitude maiores, mostrando mais uma vez que os eventos abaixo da média se tornaram mais frequentes a partir de década de 1980. Para o RH2, não é possível identificar nenhum escala dominante, no entanto, é bem nítida a predominância da ocorrência de eventos úmidos antes de 1976 e comportamento contrário após 1976, corroborando a ideia que a região é influenciada pelo fenômeno PDO,

encontrada também por Da Silva (2009), no entanto para região litorânea da área de estudo (baixo Mundaú) analisando-se a quadra chuvosa.

Prosseguindo, a Figura 25 traz a Transformada Wavelet Contínua (TW) das séries de SPI3 das duas sub-regiões da área de estudo.

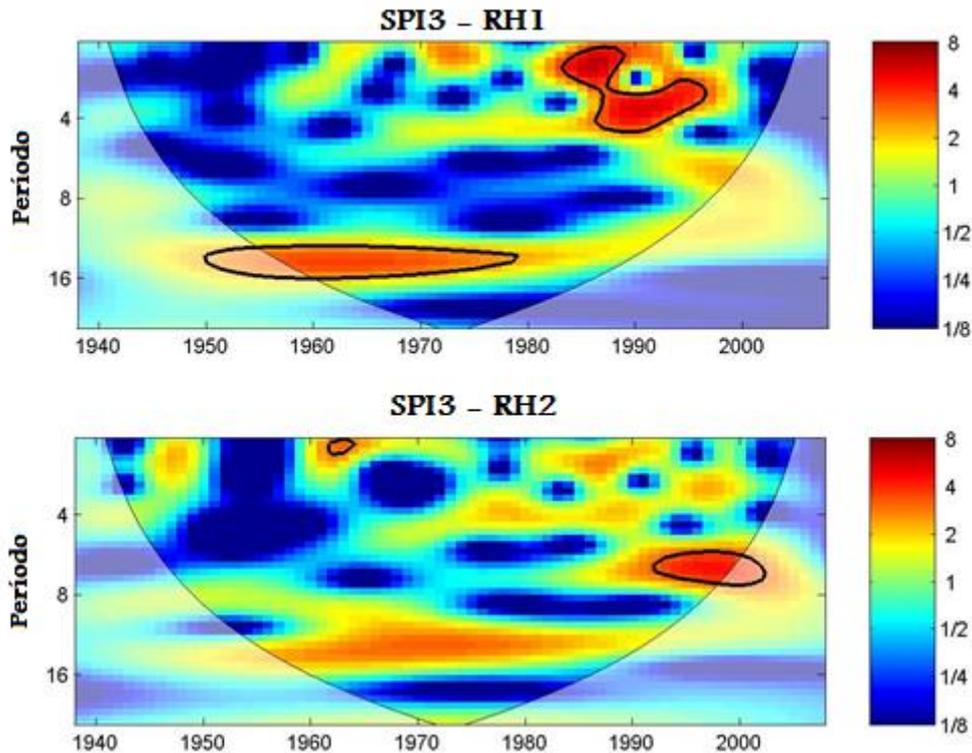


Figura 25 – Aplicação da Transformada de Ondaleta a Série de SPI3 nas Regiões Homogêneas.

A Figura 25 traz informações mais completas sobre as escalas dominantes na série de SPI3, pois a Figura 24 “desprezou” as variações consideradas normais. As escalas dominantes encontradas no RH1 são: uma escala da ordem de 12 - 16 anos no período de 1950 a 1980; escala de 1 – 2 anos na segunda metade da década de 1980 e escala de 3-4 anos entre os anos de 1985 a 1995. Esses valores apontam que a região pode sofrer influência também do ENOS e Dipolo do Atlântico, além de uma possível interferência do ciclo de mancha solares, e resultados semelhantes foram encontrados por Da Silva (2016), que analisou índices mensais de precipitação das capitais do Leste do Nordeste. Na RH2, por sua vez, apresentou apenas uma escala dominante localizada na década de 1990 para um ciclo de 6 a 8 anos.

Salienta-se, ainda, a escala dominante na ordem decadal (12 – 16 anos) encontrada para a estação seca enquanto que para a quadra chuvosa Da Silva (2009) observou escala de 22 anos (baixo Mundaú) e 18 anos para o médio Mundaú, o que pode sugerir que os ciclos maiores são encontrados na estação chuvosa das regiões litorânea e média das bacias.

Em busca de informações mais apuradas sobre o efeito de causa-efeito dos fenômenos climáticos e de precipitação nas bacias do rio Mundaú e Paraíba, foi utilizado em conjunto a Transformada Cruzada Wavelet (XWT) e a Transformada Coerência Wavelet (WT) para os índices climáticos (SOI, Niño 3.4, PDO, NAO, AMO, AMM_sst e AMM_wind) e os meses de abril a setembro que antecedem o período seco. Assim, foi utilizada a proposição de Maraun e Kurths (2004), que sugerem a análise em conjunta (superposição) da Transformada Cruzada Wavelet e a Transformada Coerência Wavelet. A seguir são apresentados os melhores resultados encontrados para esta etapa, de acordo com Oceano estudado.

5.3.1 Oceano Atlântico

Para o Oceano Atlântico, destacaram-se as correlações encontradas com Oscilação do Atlântico Norte e Modo Meridional do Atlântico. Desse modo, em seguida, serão descritos, nas Figuras 26 a 32, os principais resultados encontrados.

a) Oscilação do Atlântico Norte

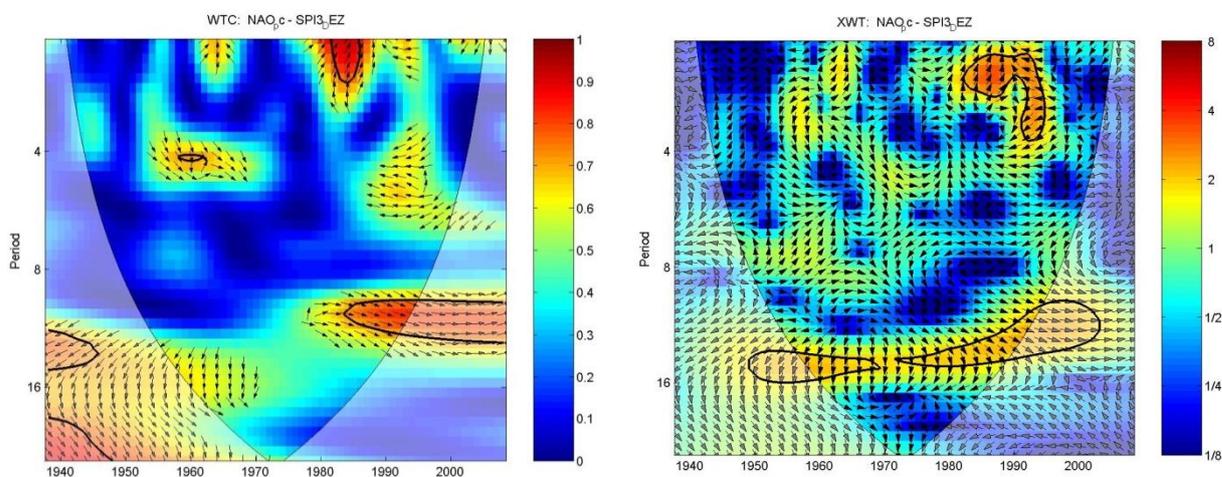


Figura 26 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do NAO de maio e o SPI3 do RH1.

Analisando a superposição das imagens da Figura 26, observa-se uma correlação (em fase) da precipitação da RH1 com NAO de maio na década de 1990 para uma escala decadal, verifica-se também uma leve diminuição do ciclo nesta década o que pode indicar que os eventos extremos podem ser tornar mais comuns.

b) Modo Meridional do Atlântico

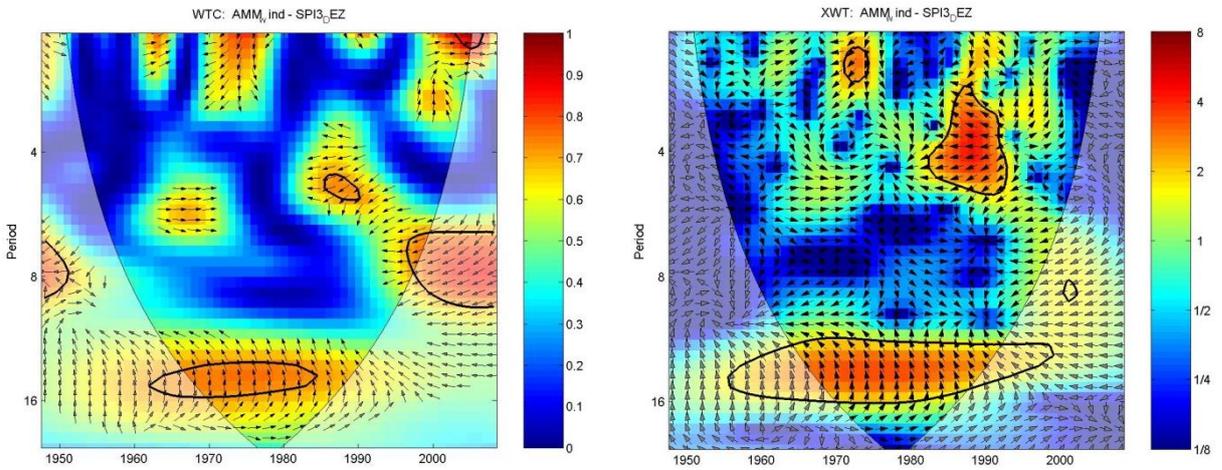


Figura 27 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de abril e o SPI3 do RH1.

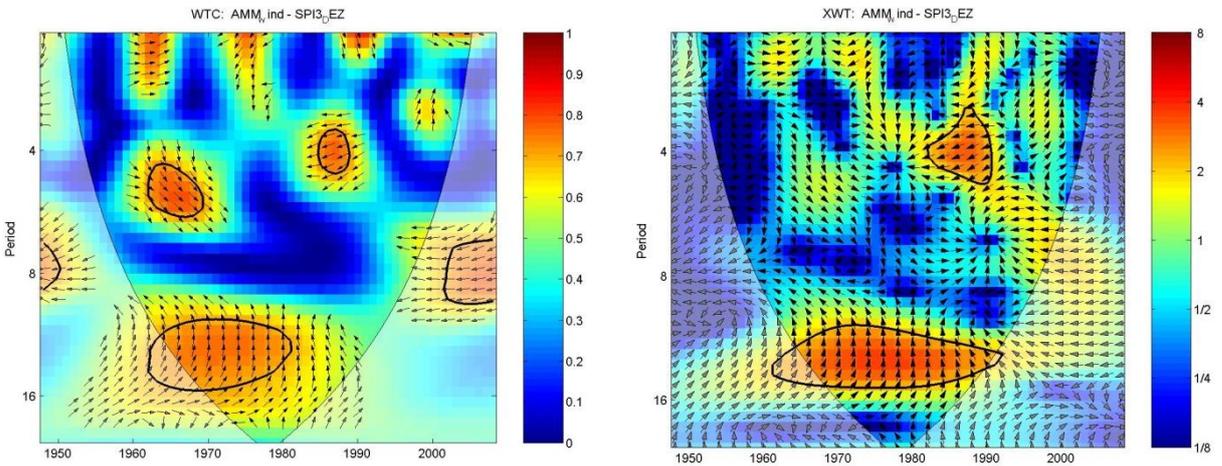


Figura 28 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de abril e o SPI3 do RH2.

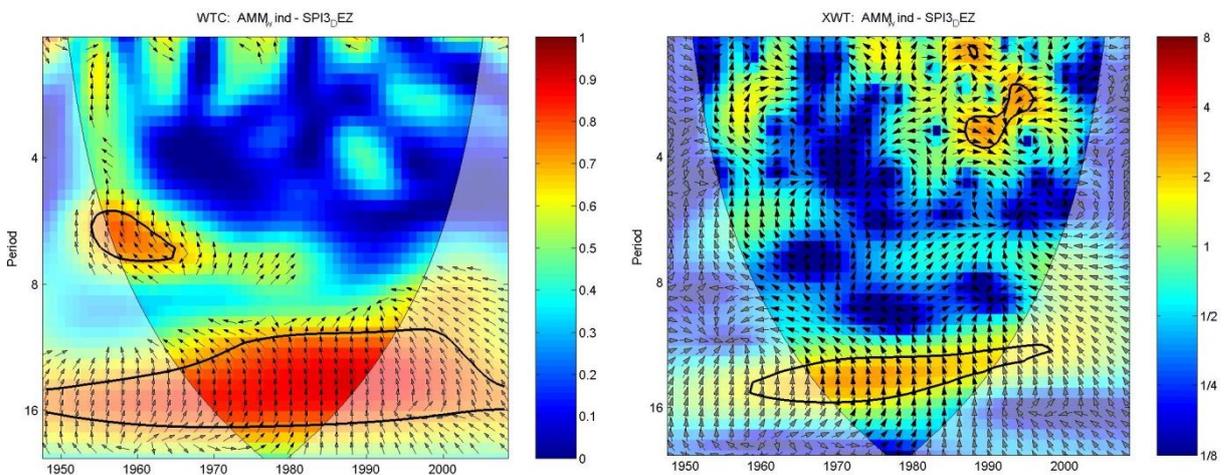


Figura 29 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de junho e o SPI3 do RH1

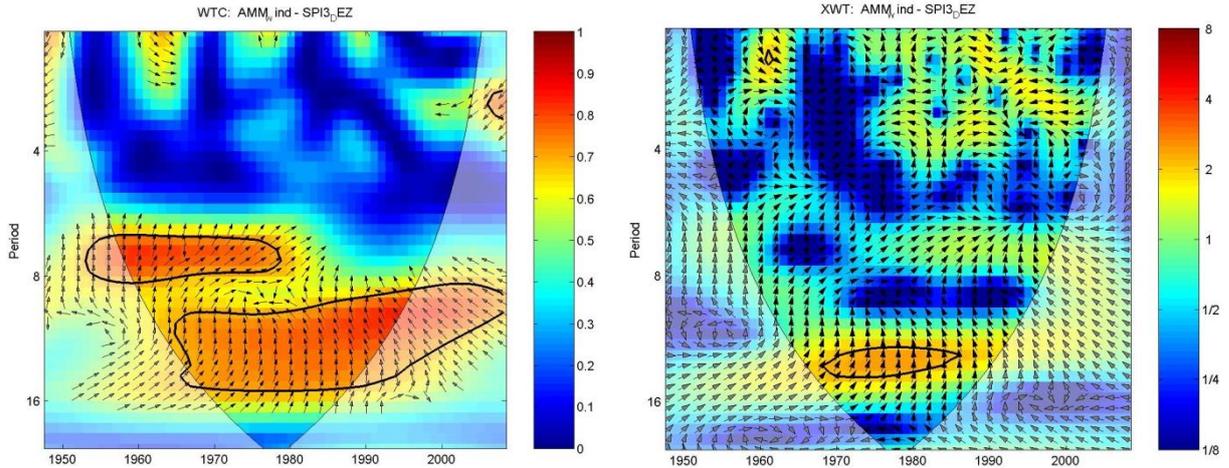


Figura 30 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_wind de junho e o SPI3 do RH2

A componente meridional do modo de variabilidade dos ventos do Atlântico (Figuras 27 e 30) apresentou melhores resultados (não fase) nos meses de abril e junho, foi observado, tanto para RH1 como RH2, uma correlação significativa para escala de 10 a 16 anos entre anos de 1960 e 1985 (abril) e para praticamente toda a série, sobretudo para RH1, analisando-se o mês de junho. Destaca-se, ainda, que RH2 apresentou uma escala bem definida de 4 anos, na segunda metade da década de 1980 ao relacionar com as anomalias de ventos do mês de abril.

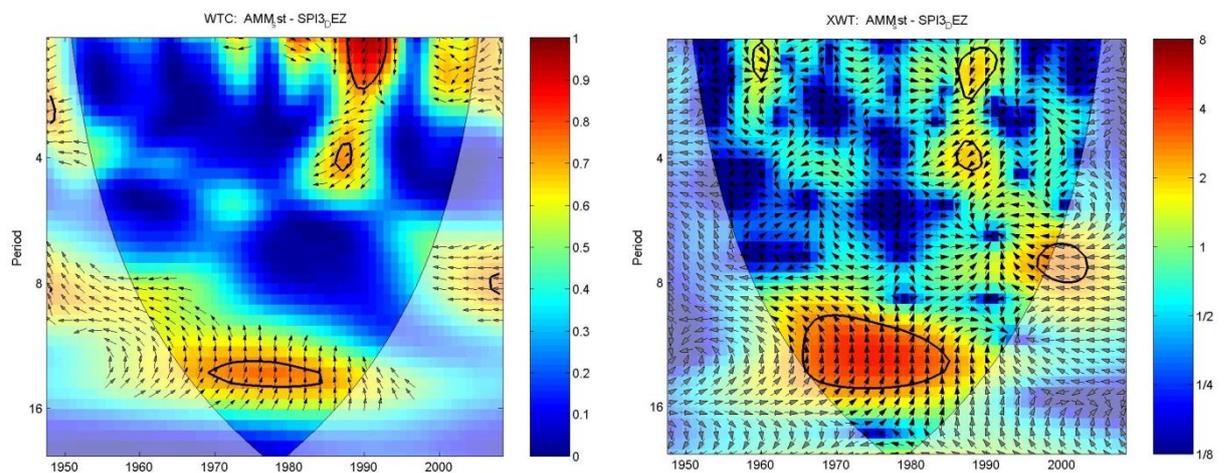


Figura 31 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_temp de abril e o SPI3 do RH2

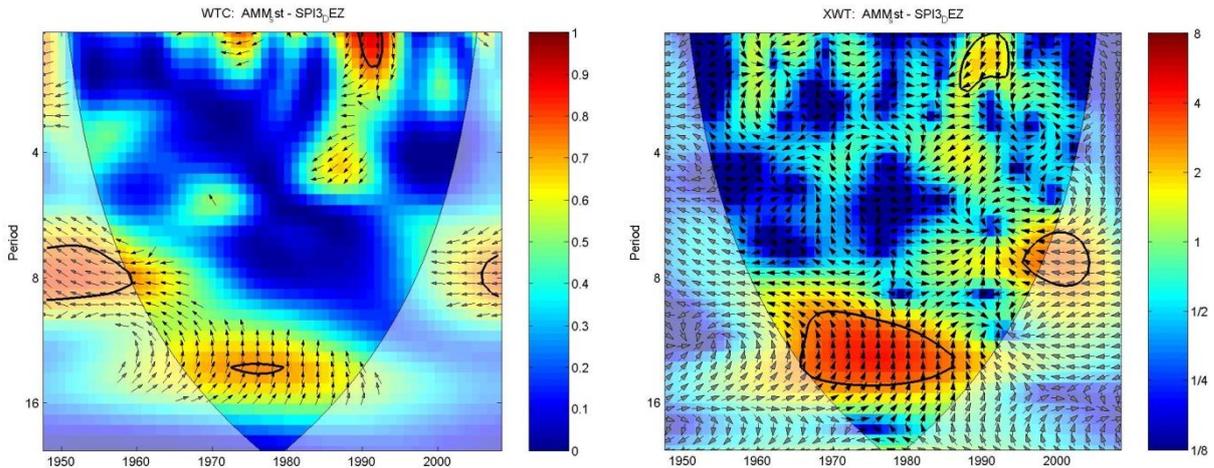


Figura 32 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do AMM_temp de maio e o SPI3 do RH2

A componente meridional do modo de variabilidade da temperatura da superfície do Atlântico (Figuras 31 e 32) se correlacionou bem (não fase) apenas com a precipitação do RH2, apresentando relação significativa para o ciclo de 12 a 14 anos nas décadas de 1970 e 1980 e em um ponto isolado com ciclo de 4 anos para o ano de 1990. Apenas a série temporal dos meses abril e maio deste índice climático foi destacada. Recordando Andreoli *et al.* (2004), observaram-se resultados semelhantes, haja vista que estes autores encontraram a dominância da escala de 11-14 anos para os índices de precipitação do município de Fortaleza (localizado no NNE) e para o gradiente inter-hemisférico da anomalia da temperatura da superfície do Atlântico.

5.3.2 Oceano Pacífico

No Oceano Atlântico, destacaram-se as correlações encontradas com o Índice de Oscilação Sul e Niño 3.4, conforme pode ser visto na Figura 33 a 40.

a) Índice de Oscilação Sul

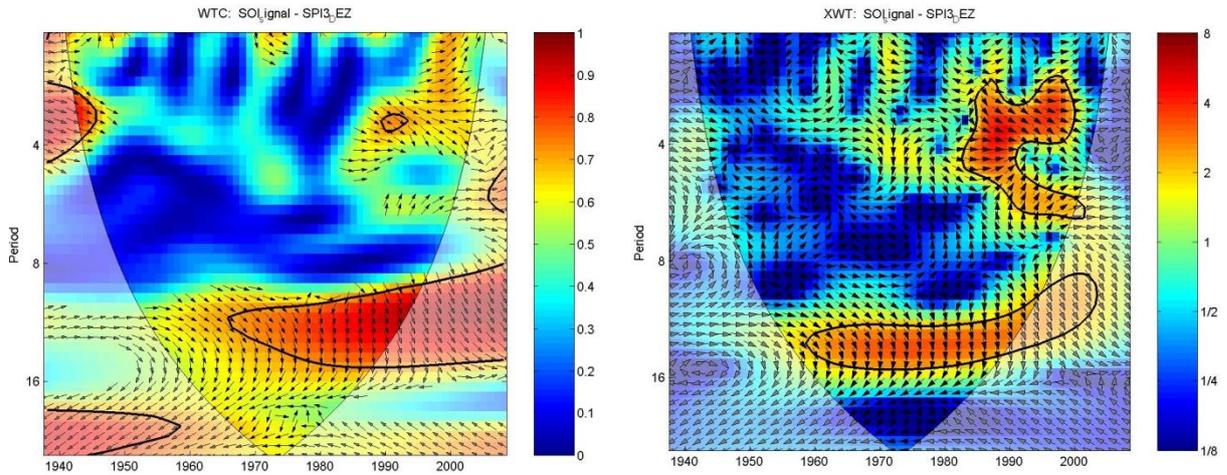


Figura 33 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do SOI de abril e o SPI3 do RH1

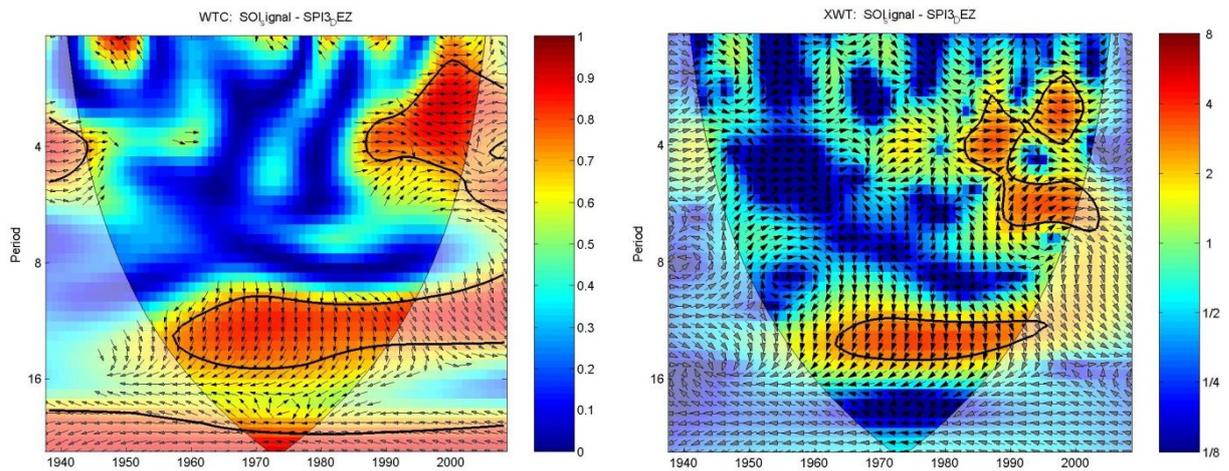


Figura 34 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do SOI de abril e o SPI3 do RH2

O SOI de abril apresentou bons resultados com ambas as regiões da área de estudo, com correlação significativa na ordem decadal para um período que se estende dos anos de 1960 a 2000. Observa-se que a correlação é fora de fase e que a região litorânea (RH1) apresentou tendência de diminuição do ciclo dominante. Por sua vez, a região semiárida exibiu uma forte relação (em fase) em ciclos curtos (2 – 5 anos) para período de 1985 a 2000.

b) Niño 3.4

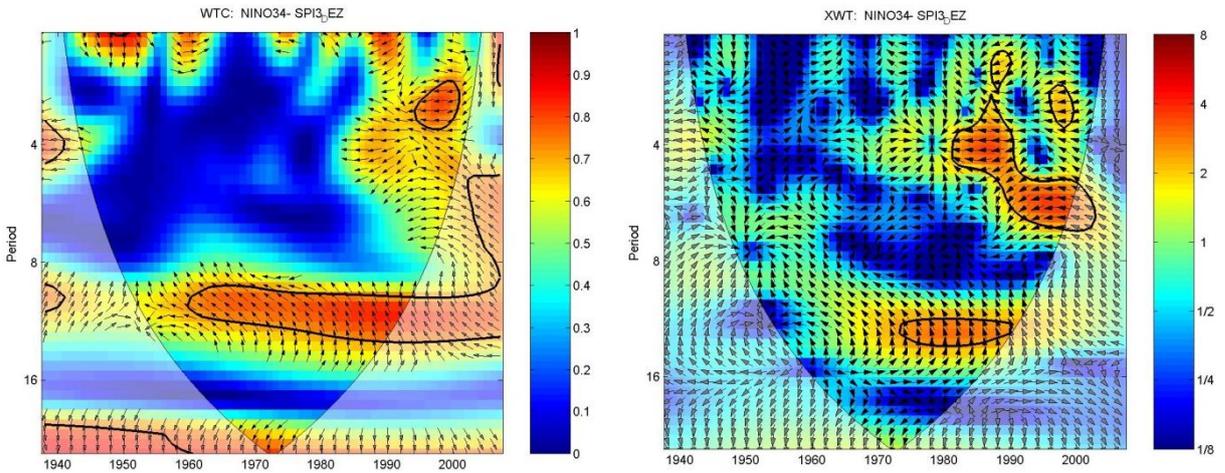


Figura 35 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de abril e o SPI3 do RH2

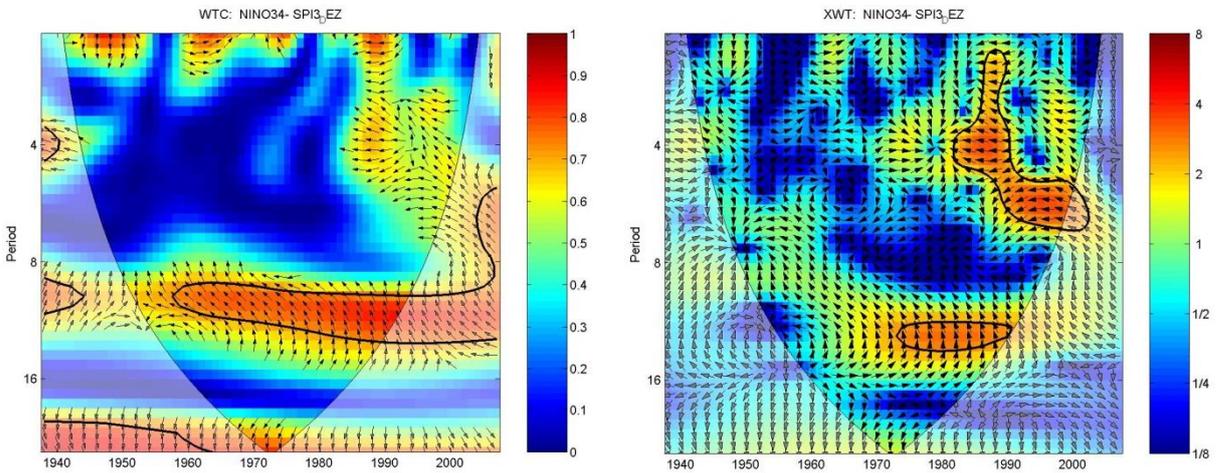


Figura 36 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de maio e o SPI3 do RH2

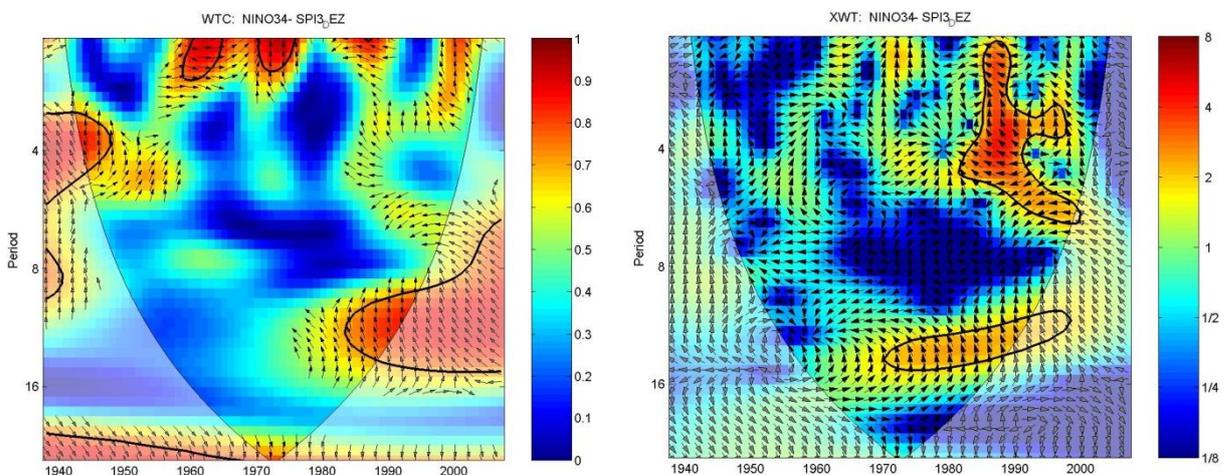


Figura 37 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de junho e o SPI3 do RH1

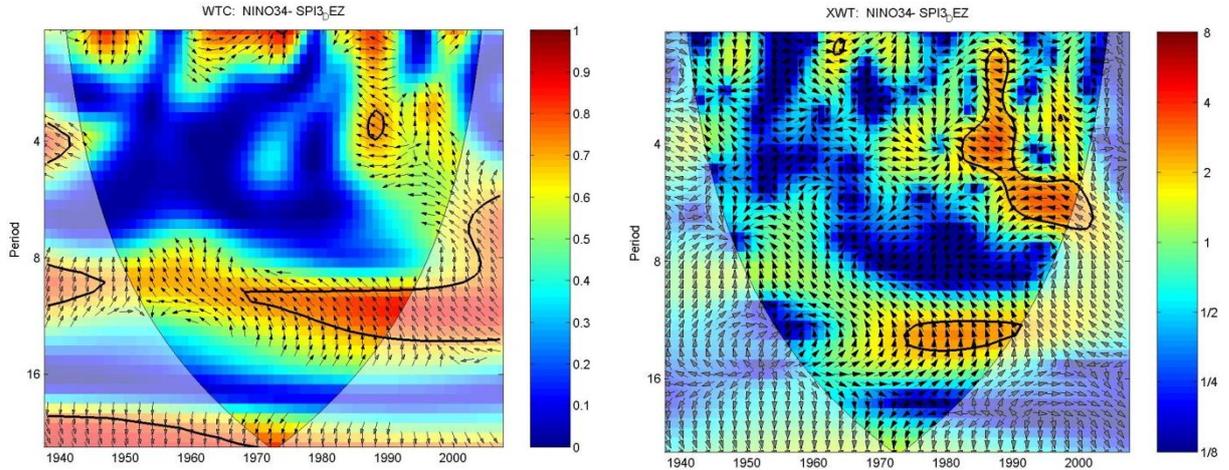


Figura 38 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de junho e o SPI3 do RH2

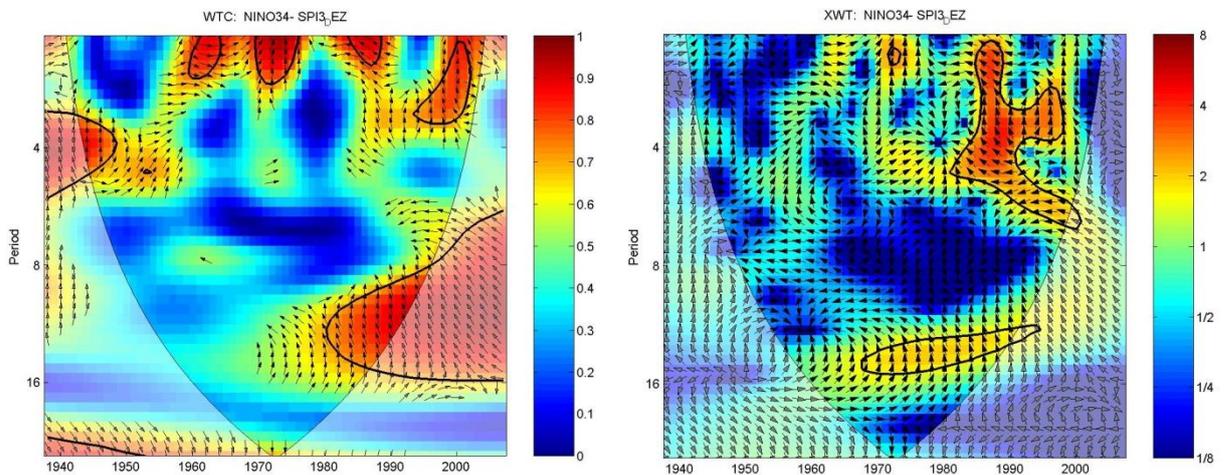


Figura 39 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de julho e o SPI3 do RH1

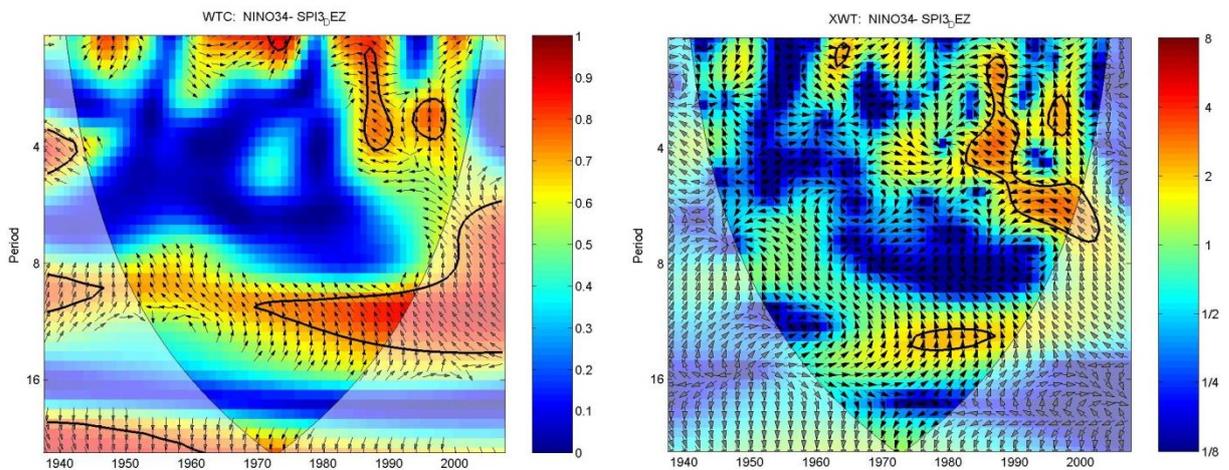


Figura 40 - Transformada Coerência Wavelet (WTC) e Cruzada Wavelet (XWT) do Niño 3.4 de julho e o SPI3 do RH2

O Niño 3.4 de abril e de maio (Figura 35 e 36) apresentou bons resultados (fora de fase) apenas para o RH2 para um período que se estende entre os anos de 1975 a 1990, na escala decadal. O Niño 3.4 de junho apresentou correlações significativas para as duas sub-regiões, sempre na escala decadal (~ 12 anos) e fora de fase, para o período de 1985 a 1995 para a RH1 e de 1975 a 1990 para RH2. Por fim, a série temporal do Niño 3.4 de julho apresentou correlações destacáveis no RH1 para os anos compreendidos entre 1980 a 1995, numa escala dominante decadal, enquanto para o RH2 tem-se uma leve predominância na escala decenal na década de 1980, e foi observada também uma boa correlação para escalas menores, de 1-4 anos na segunda metade da década de 1980, e de 3 anos para a metade da década de 1990, todas fora de fase. Observa-se também que tanto para os meses de junho e julho, para a porção litorânea, existe uma tendência de diminuição do ciclo predominante entre as décadas de 1970 e de 1990.

5.3.3 Considerações sobre Aplicação da Wavelets

Para melhor visualização dos resultados encontrados com a aplicação da Wavelets, a Tabela 10 traz os índices climáticos encontrados melhor correlacionados com o comportamento da secas na região de estudo.

Tabela 10 – Melhores Índices Climáticos Encontrados na Aplicação do Wavelets

RH	Oceano Pacífico		Oceano Atlântico		
	SOI	Niño 3.4	NÃO	AMM_wind	AMM_sst
1	Abril	Junho e Julho	-	Abril e Junho	-
2	Abril	Abril, Maio, Junho e Julho	Maio	Abril e Junho	Abril e Maio

Observa-se que tanto as condições do oceano Atlântico como a do Pacífico apresentaram correlação com significância de 95%, sob a metodologia da Wavelets utilizada, com o regime de chuvas de ambas as sub-regiões da área de estudo. De modo geral, o mês de abril se destacou, sobretudo na porção semiárida, sugerindo que as condições (pressão, temperatura e ventos) dos oceanos, neste mês, podem influenciar no regime de chuva na estação seca. Os resultados com os índices do Pacífico foram similares para as duas sub-regiões, por outro lado, no Atlântico, houve uma dissimilaridade, haja vista que a parcela costeira da região de estudo apresentou bons resultados apenas com as condições de vento enquanto que o semiárido com as variações de pressão do Atlântico Norte, temperatura e vento do Atlântico Tropical.

Destaca-se também que a região litorânea da área de estudo apresentou uma tendência de diminuição dos ciclos de precipitação a partir da década de 1990, conforme observado com os índices de NAO, Niño 3.4 e SOI; o que pode significar o aumento da frequência de ocorrência de secas.

Salienta-se ainda, analisando-se as figuras 26 a 40, que os índices climáticos com escala maiores que decadal (PDO e AMO) não apresentaram bons resultados sob o enfoque da Wavelets, em compensação é observada, quase que em todas situações, uma escala dominante na ordem de 10 a 16 anos, o que pode indicar uma correlação com fenômenos que possuem ciclo deste tamanho. Assim, foi realizada a correlação de Spearman entre a série composta pelo sinal 10 a 16 anos do SPI e as séries temporal de índices climáticos (SOI, Niño 3.4, PDO, NAO, AMO, AMM_sst e AMM_wind) com defasagem de até seis em relação à estação seca. Os resultados das correlações podem ser vistos na Tabela 11.

Tabela 11 – Correlação de Spearman Entre os Índices Climáticos e as Faixas Espectral de 10 a 16 anos de SPI

Índice Climático	RH	MÊS					
		ABRIL	MAIO	JUNHO	JULHO	AGOSTO	SETEMBRO
AMO	1	-0,1596	-0,2287	-0,3218*	-0,3718*	-0,4019*	-0,4310*
	2	-0,4732*	-0,5171*	-0,5650*	-0,6004*	-0,6574*	-0,7063*
SOI	1	0,1875	0,2070	0,1837	0,0932	0,2117	0,0293
	2	0,0895	0,2392*	0,1742	0,0382	0,1509	0,0442
AMM_wind	1	-0,0503	-0,2068	-0,2656*	-0,1088	-0,1895	-0,2672*
	2	-0,0395	-0,3879*	-0,3901*	-0,3362*	-0,4271*	-0,3866*
AMM_sst	1	0,1934	0,1919	0,0205	0,0189	-0,1652	-0,3396
	2	0,0638	0,0381	-0,1166	-0,1492	-0,3291	-0,4796
NAO	1	0,0135	-0,0874	0,1066	-0,0162	-0,1152	0,0829
	2	-0,0790	-0,0212	0,1702	0,0296	-0,0406	0,0355
Niño 3.4	1	-0,1018	-0,1235	-0,1192	-0,1226	-0,0925	-0,0743
	2	-0,0805	-0,1069	-0,0876	-0,0764	-0,0308	-0,0166
PDO	1	-0,4499*	-0,4420*	-0,3361*	-0,3449*	-0,2843*	-0,1769
	2	-0,2794*	-0,3326*	-0,2818*	-0,1890	-0,0962	0,0213

* correlação com 95% de significância realizado pelo teste de Monte Carlo.

Observa-se então correlação significativa (negativa), com defasagem de até seis meses, da série decomposta do SPI com os índices climáticos PDO e AMO, além do

AMM_wind para ambas regiões da área de estudo. Isso comprova que o regime de precipitação da estação seca da região pode sofrer influência de fenômenos de escala decadal, quer seja no Oceano Atlântico ou Pacífico. Verifica-se ainda que as maiores correlações com PDO foram encontradas para a região litorânea, enquanto que o AMO e AMM_wind para a região semiárida, o que sugere que as condições do Atlântico têm maiores conexões com a escala decadal da série de precipitação na porção semiárida e o Pacífico com a parcela das bacias localizada na costa. Essas informações podem ser estratégicas para definição de variáveis para entender o regime pluviométrico, bem como na definição de modelos de previsão de chuvas na estação seca da área de estudo.

5.4 REDES NEURAIAS ARTIFICIAIS

Em seguida, serão apresentados os resultados obtidos oriundos da aplicação da rede neural artificial de acordo com os objetivos desejados.

5.4.1 Reconhecimento dos Padrões

Para o reconhecimento de padrões da variabilidade temporal da precipitação da estação seca da área de estudo, foram realizados diversos arranjos no modelo de Rede Neural descritos na metodologia. Para a análise interanual, foram utilizando os seguintes índices climáticos: NAO, Niño 3.4, SOI, AMM_wind e AMM_sst, enquanto que a análise da variabilidade decadal foram empregados PDO, AMO e, novamente, AMM_wind e AMM_sst. A Tabela 12 traz os índices utilizados nos diferentes arranjos realizadas, tanto para RH1 como RH2.

Tabela 12 – Índices Climáticos Utilizados na Rede Neural Para Reconhecimento de Padrões.

Análise	Índice Climático						
	Oceano Atlântico				Oceano Pacífico		
	NAO	AMM_wind	AMM_sst	AMO	SOI	Niño 3.4	PDO
Interanual	Maio	Junho e Julho	Abril	-	Abril	Abril, Maio, Junho e Julho	-
Decadal	-	Junho	-	Junho e Julho	-	-	Abril e Maio

Importante destacar mais uma vez que a análise interanual foi estudada com o sinal bruto do SPI, enquanto que a decadal com o sinal decomposto pela Wavelets admitindo-se uma faixa de 10 a 16 anos. Prosseguindo, fazendo a combinação para que as simulações sempre ocorram com um índice de cada oceano resultou-se em 20 arranjos para o estudo

interanual e 6 para análise decadal. Os melhores resultados da etapa de verificação estão descritos nas Figuras que seguem. As Figuras 41 a 43 trazem as configurações encontradas para análise interanual no RH1.

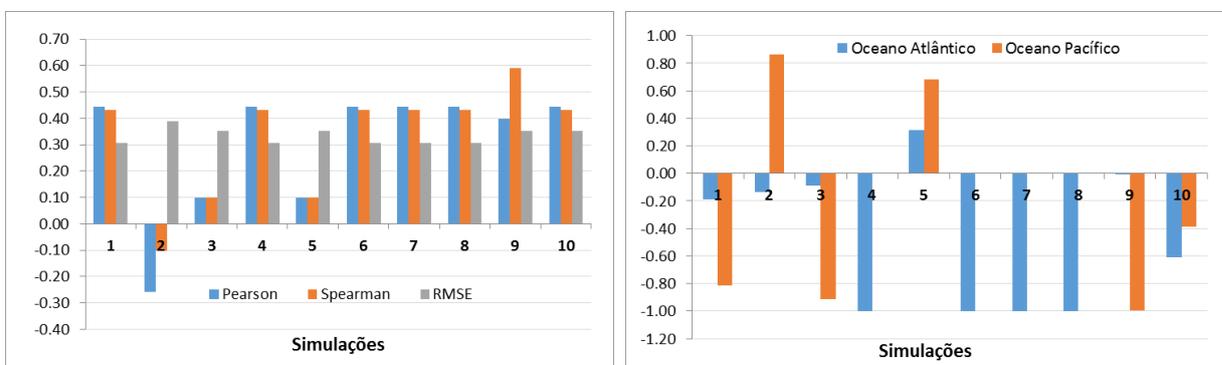


Figura 41 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 (50-25-25) de Junho e os valores da contribuição relativa (ROCW_i) de cada Oceano analisado Aplicado a RH1.

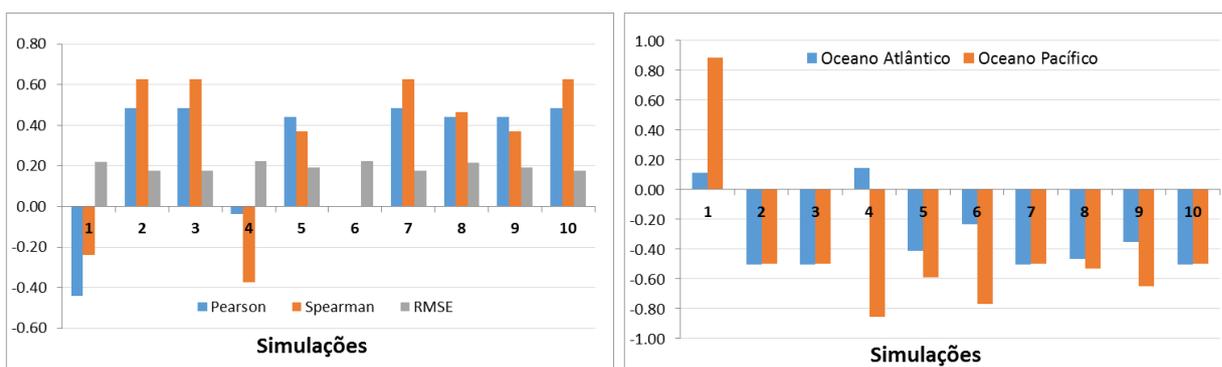


Figura 42 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de junho e Niño 3.4 de Maio (50-25-25) e os valores da contribuição relativa (ROCW_i) de cada Oceano analisado Aplicado a RH1.

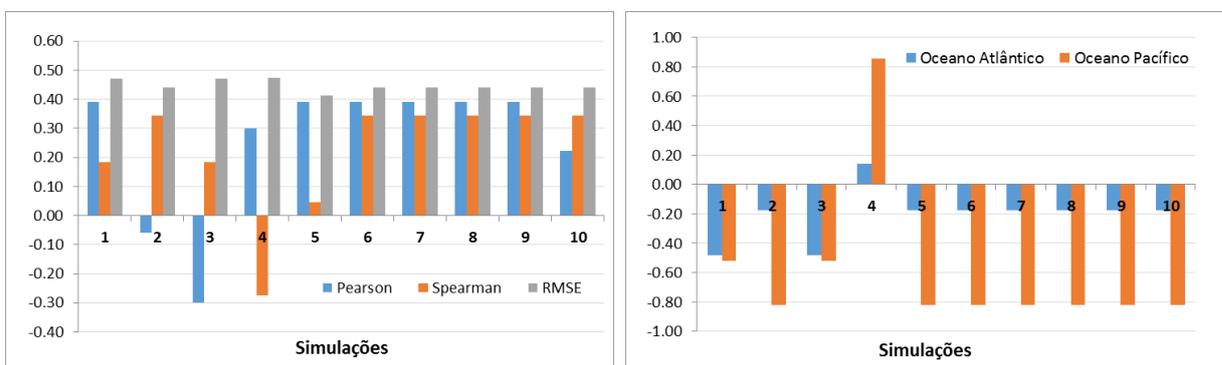


Figura 43 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_sst de abril e Niño 3.4 de junho (70-15-15) e os valores da contribuição relativa (ROCW_i) de cada Oceano analisado Aplicado a RH1.

Observa-se que dos 20 arranjos testados apenas 3 mostraram resultados satisfatórios e considerados estáveis, destacando-se para o Oceano Atlântico os índices de AMM e para o

Pacífico o Niño 3.4. Ainda sim, a configuração composta por AMM_wind de abril e Niño 3.4 de junho, mesmo apresentando índices de desempenho estáveis, tem pesos relativos do índices climáticos instáveis o que pode prejudicar a definição de padrão com esta configuração. Verificou-se também na configuração AMM_wind de junho e Niño 3.4 de Maio uma equivalência na influência de ambos Oceanos analisados, sendo diferente para a situação com AMM_sst de abril e Niño 3.4 de junho que se destacou o Oceano Pacífico. As Figuras 44 a 46 trazem os melhores resultados para análise interanual para região semiárida da área de estudo.

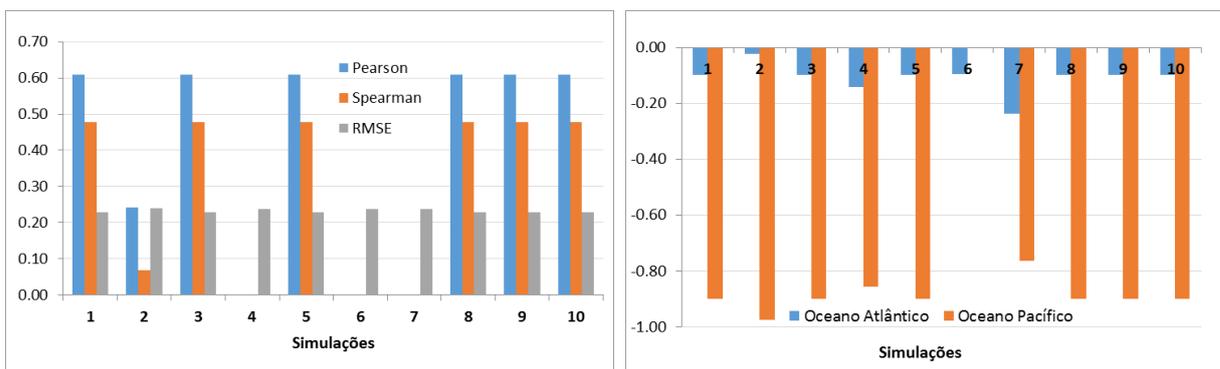


Figura 44 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 de Maio (60-20-20) e os valores da contribuição relativa (ROCW_i) de cada Oceano analisado Aplicado a RH2.

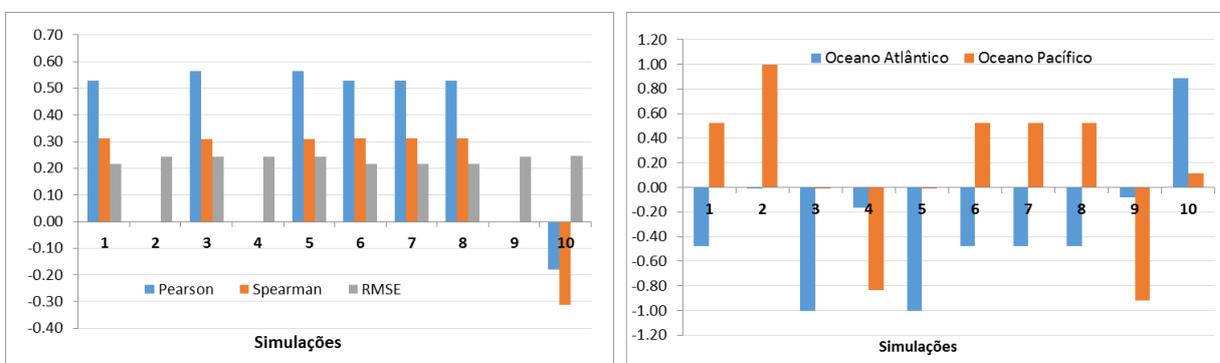


Figura 45 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_wind de abril e Niño 3.4 de junho (60-20-20) e os valores da contribuição relativa (ROCW_i) de cada Oceano analisado Aplicado a RH2.

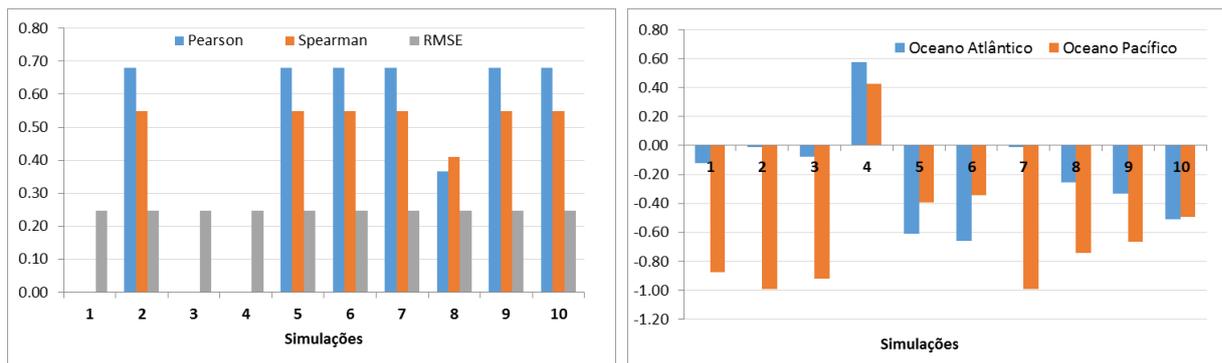


Figura 46 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMM_sst de abril e Niño 3.4 de abril (70-15-15) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH2.

Destaca-se mais uma vez que índices climáticos do mês de abril, o que pode sugerir que condições oceânicas (temperatura e ventos), neste mês, podem determinar o regime de chuvas no período seco. Verificou-se que a configuração formado por com AMM_wind de abril e Niño 3.4 de junho apresentou estabilidade em relação aos coeficientes de desempenho, no entanto, verificou-se que os valores do pesos relativos não se estabilizaram o que indica que existe mais de uma configuração para a solução ótima de rede neural aplicada. De modo geral, o Oceano Pacífico mostra ter maior influência na variação precipitação na estação da porção semiárida da região de estudo.

Em relação à análise decadal, os resultados se mostraram mais promissores para a região litorânea da área de estudo, conforme pode ser visto nas Figuras 47 a 50.

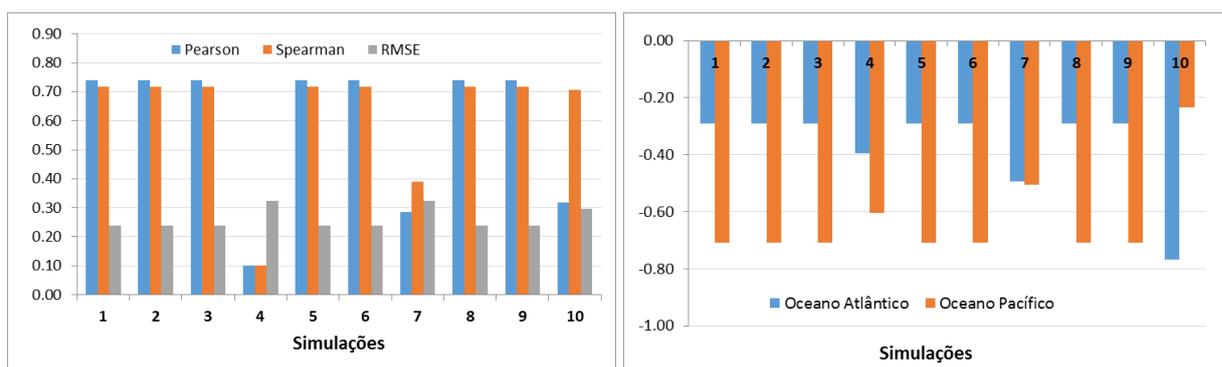


Figura 47 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de junho e PDO de Maio (70-15-15) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH1.

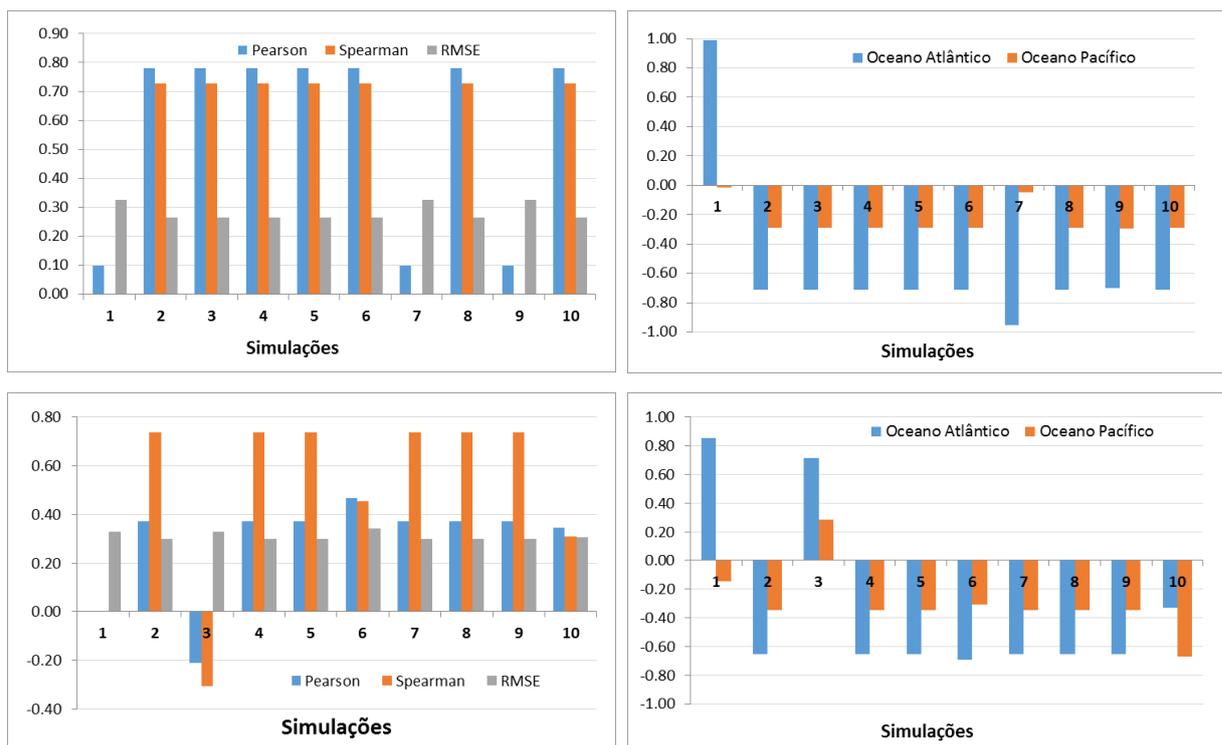


Figura 48 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de junho e PDO de abril (70-15-15 e 60-20-20) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH1.

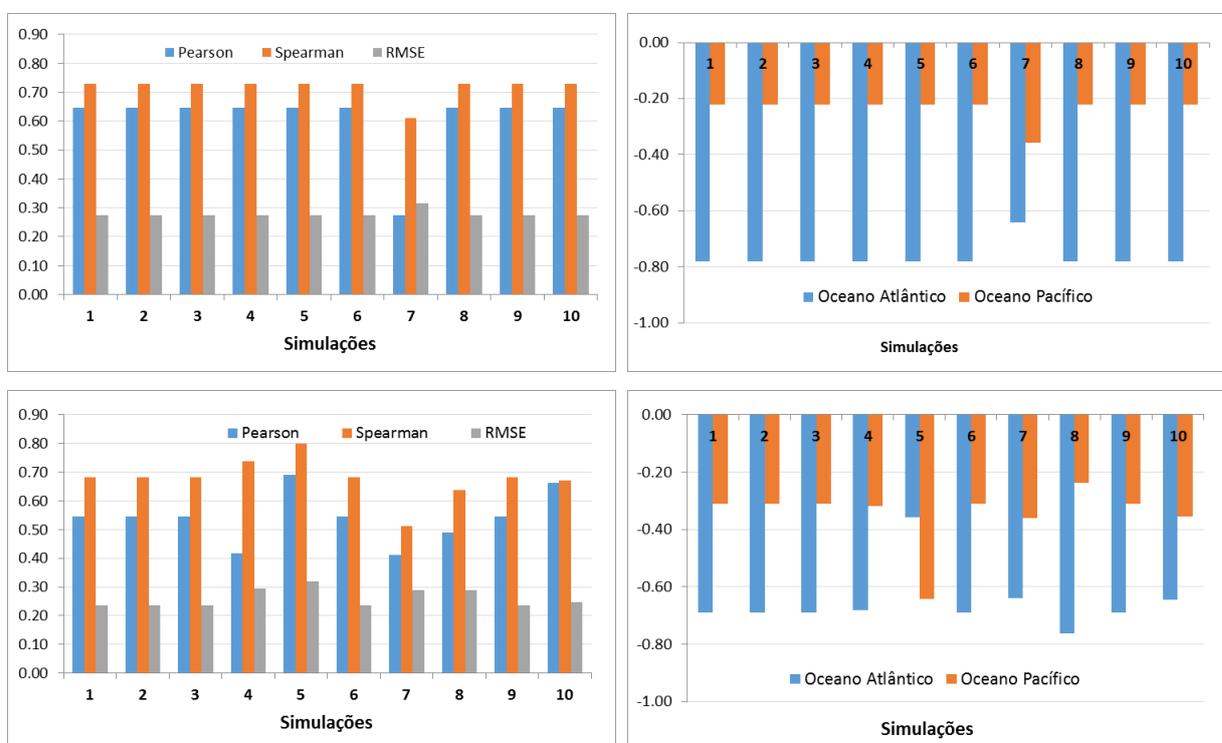


Figura 49 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de julho e PDO de abril (70-15-15 e 60-20-20) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH1.

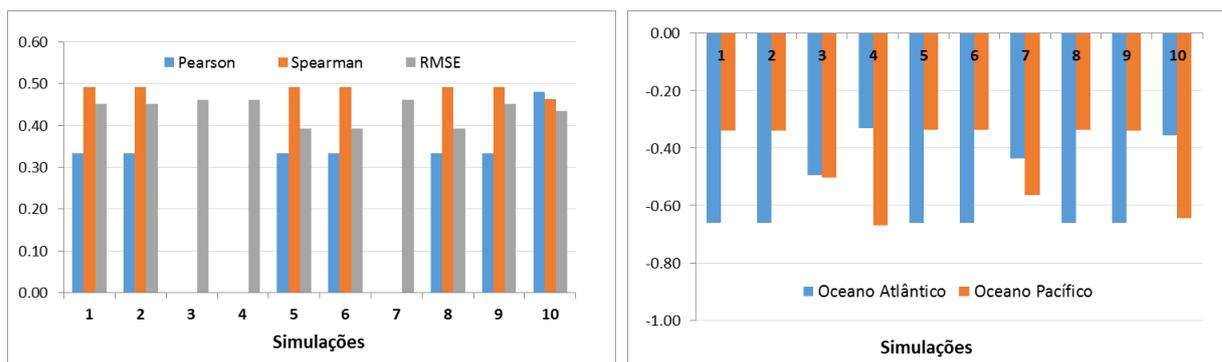


Figura 50 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de julho e PDO de Maio (70-15-15) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH1.

Nesta análise, apenas o AMM_wind não apresentou resultados satisfatórios, logo 4 arranjos dos 6 analisados destacaram-se, o que mostra variabilidade decadal desta região pode ser explicada por fenômenos climáticos globais. Verificou-se que a configuração com o PDO de abril apresentou bons resultados para mais de uma divisão adotada e estes apresentaram os melhores resultados com coeficientes de correlação (linear ou não-linear) próximos de 0,8. Salienta-se ainda que para análise decadal, de forma geral, o Oceano Atlântico mostra ter maior influência no regime de precipitações desta porção da área de estudo.

Diferentemente, da porção litorânea, a região semiárida apresentou apenas um arranjo com resultados estáveis, o qual pode ser vista na Figura 51.

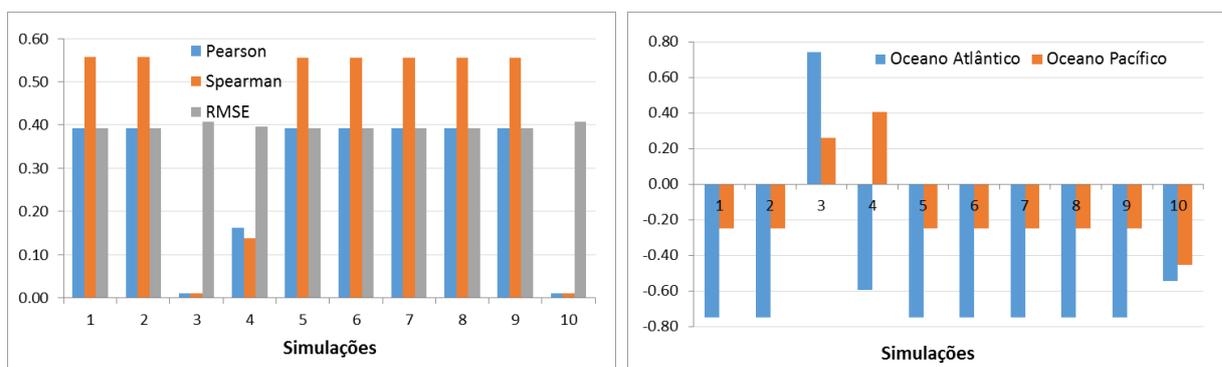


Figura 51 – Medidas de Desempenho da Etapa de Verificação do Modelo de RNA para a configuração com AMO de Julho e PDO de Maio (50-25-25) e os valores da contribuição relativa ($ROCW_i$) de cada Oceano analisado Aplicado a RH2.

Pode-se observar que apenas o arranjo com AMO de julho e PDO de Maio apresentou uma rede neural estável, isso pode ser explicado pelo fato da região está localizada numa zona de transição, onde fenômenos globais isoladamente não possam responder pela variabilidade decadal da chuva na estação seca. Ademais, para configuração selecionada, a maior influência no Oceano Pacífico foi notada apresentando comportamento semelhante com o da região litorânea.

5.4.2 Previsão

Diante dos resultados das etapas anteriores, foram selecionados os melhores índices climáticos (variáveis preditoras) e desta forma foram construídos 44 arranjos diferentes, divididos em 4 agrupamentos, para o modelo de previsão dos índices de seca. A Tabela 13 traz os arranjos utilizados nesta etapa, bem como sua codificação.

Os arranjos foram definidos utilizando-se de três ou quatro índices climáticos, onde foram priorizados os índices de variações decadal (PDO e AMO) de melhor correlação com o SPI da região de estudo. A topologia das redes são constituídas de 3 camadas, onde a camada intermediária foi composta com 3 ou 4 neurônios (a depender do número de entradas), além disso os dados foram divididos em 3 tipos em relação a treinamento-verificação-validação, os quais são: 70-15-15, 60-20-20 e 50-25-25. Então foram realizadas 10 simulações para cada arranjo onde a média e o desvio-padrão das medidas de desempenho foram calculados para análise da oscilação desses resultados.

As Figuras 52 e 53 trazem as medidas de desempenho dos arranjos do Agrupamento 01 para RH1.

Tabela 13 – Combinações das Variáveis Predictoras Para Construção do Modelo de Rede Neural.

Agrupamento 01		Agrupamento 02		Agrupamento 03		Agrupamento 04	
1° Arranjo (1-I)		1° Arranjo (2-I)		1° Arranjo (3-I)		1° Arranjo (4-I)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril
2° Arranjo (1-II)		2° Arranjo (2-II)		2° Arranjo (3-II)		2° Arranjo (4-II)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril
Niño 3.4	Abril						
3° Arranjo (1-III)		3° Arranjo (2-III)		3° Arranjo (3-III)		3° Arranjo (4-III)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril
Niño 3.4	Maio						
4° Arranjo (1-IV)		4° Arranjo (2-IV)		4° Arranjo (3-IV)		4° Arranjo (4-IV)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril	AMM_wind	Abril
Niño 3.4	Junho						
5° Arranjo (1-V)		5° Arranjo (2-V)		5° Arranjo (3-V)		5° Arranjo (4-V)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril
6° Arranjo (1-VI)		6° Arranjo (2-VI)		6° Arranjo (3-VI)		6° Arranjo (4-VI)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril
Niño 3.4	Abril						
7° Arranjo (1-VII)		7° Arranjo (2-VII)		7° Arranjo (3-VII)		7° Arranjo (4-VII)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril
Niño 3.4	Maio						
8° Arranjo (1-VIII)		8° Arranjo (2-VIII)		8° Arranjo (3-VIII)		8° Arranjo (4-VIII)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril	AMM_sst	Abril
Niño 3.4	Junho						
9° Arranjo (1-IX)		9° Arranjo (2-IX)		9° Arranjo (3-IX)		9° Arranjo (4-IX)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
Niño 3.4	Abril						
10° Arranjo (1-X)		10° Arranjo (2-X)		10° Arranjo (3-X)		10° Arranjo (4-X)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
Niño 3.4	Maio						
11° Arranjo (1-XI)		11° Arranjo (2-XI)		11° Arranjo (3-XI)		11° Arranjo (4-XI)	
PDO	Maio	PDO	Junho	PDO	Maio	PDO	Junho
AMO	Junho	AMO	Junho	AMO	Julho	AMO	Julho
Niño 3.4	Junho						

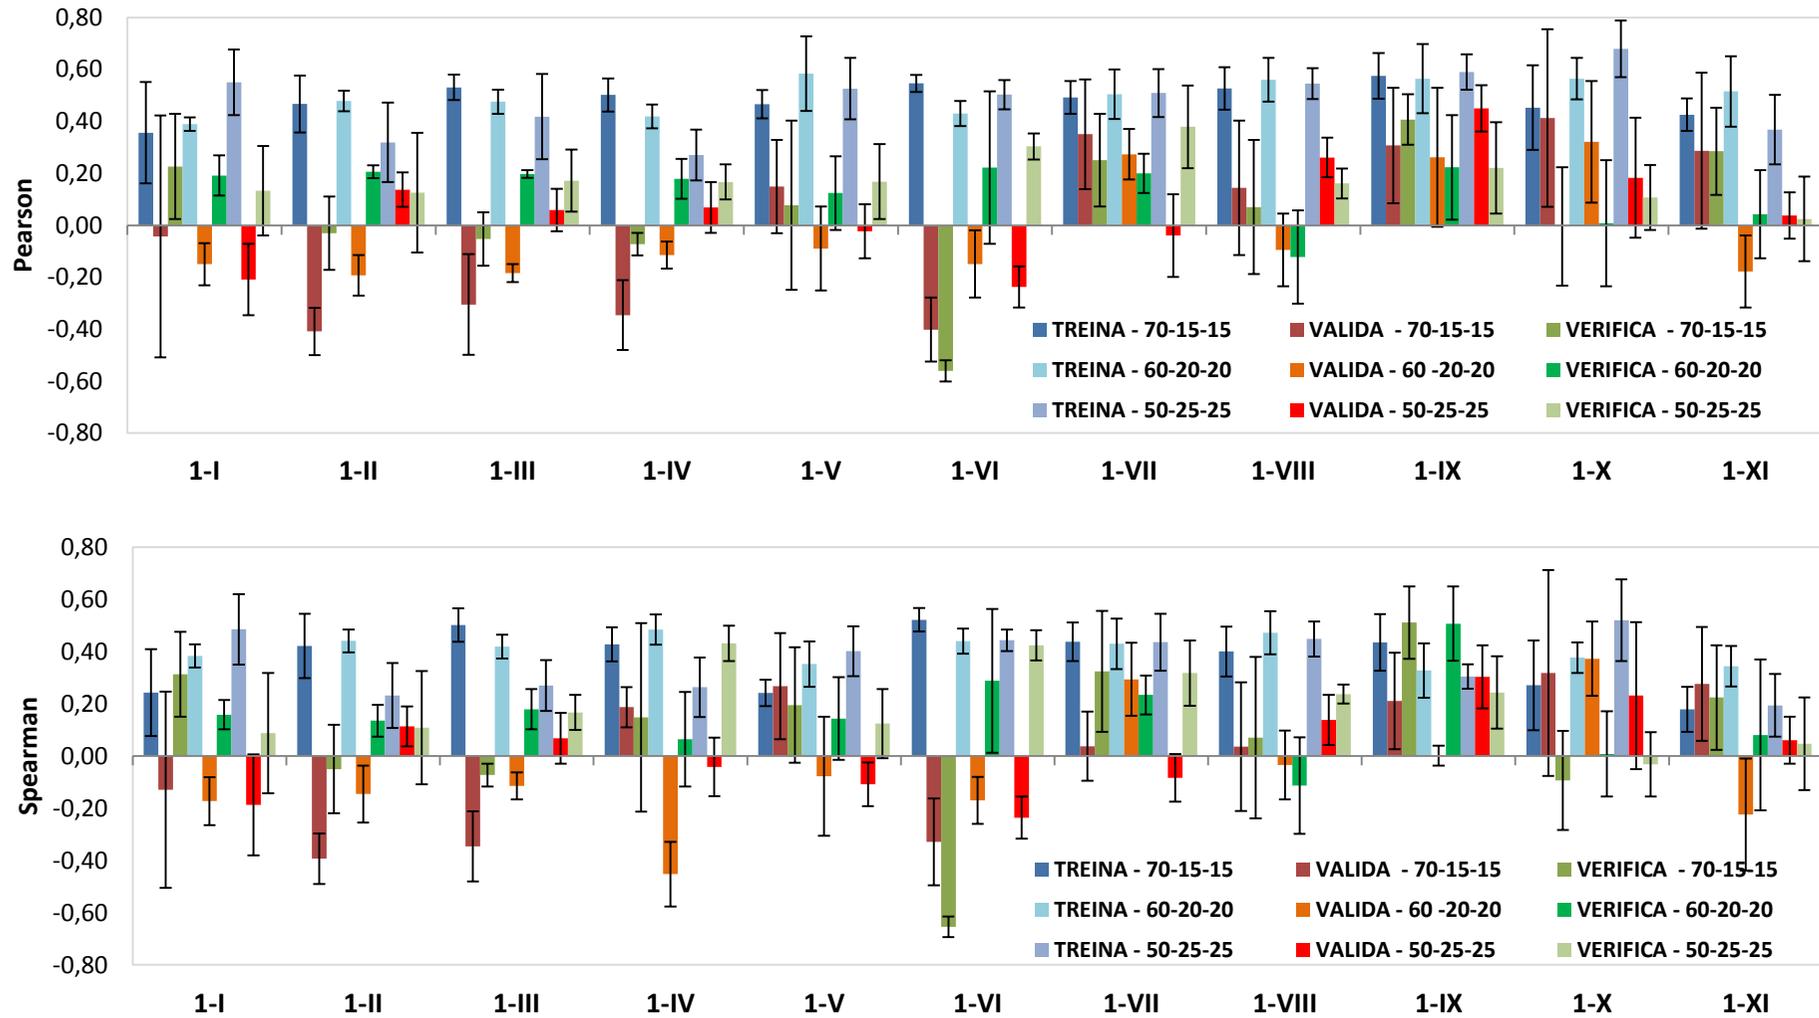


Figura 52 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH1

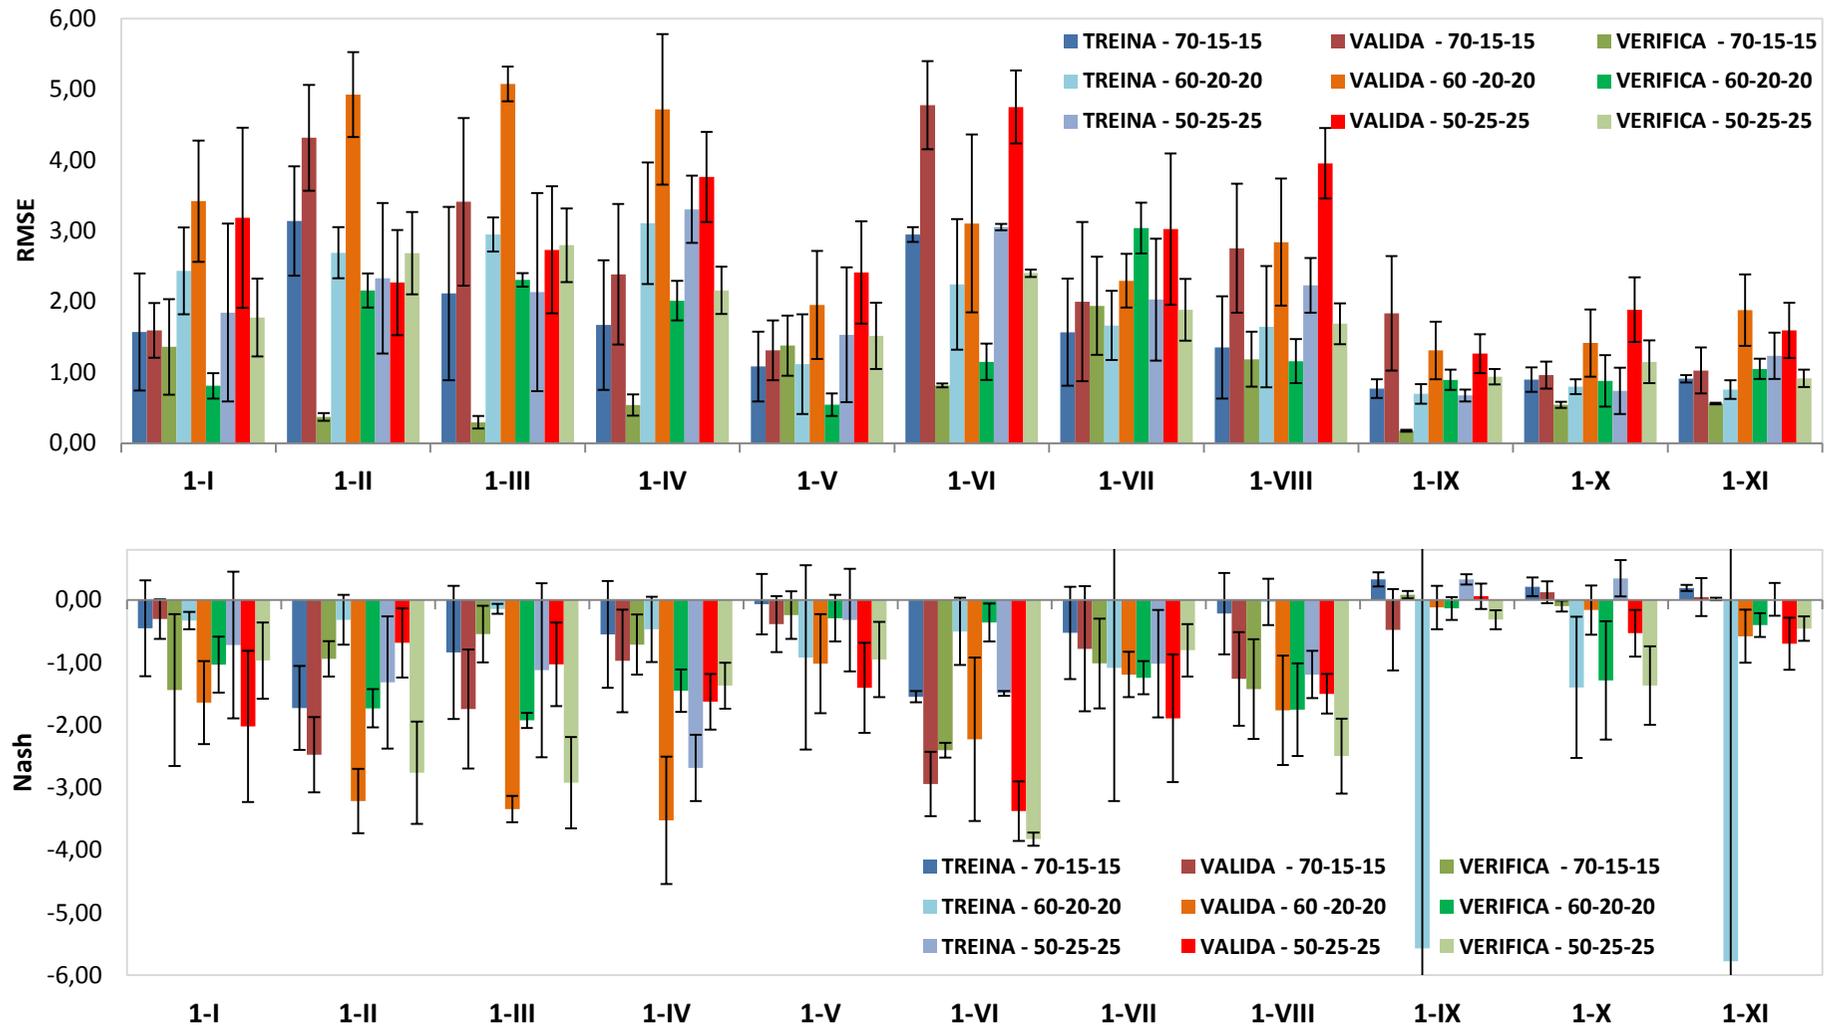


Figura 53 – Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH1.

Em relação ao agrupamento 01, aplicado a RH1, verifica-se, analisando os coeficientes de correlação, que os arranjos mais homogêneos são 1-IX, 1-X e 1-XI, corroborado quando se observam os valores de RMSE que apresentam os melhores (menores) valores e mais estáveis, além disso, destaca-se também o 1-V. No entanto, quando se atenta ao coeficiente de Nash, tem-se que o arranjo 1-IX e 1-XI possui uma grande instabilidade, sobretudo para o treinamento da divisão 60-20-20. Faz-se aqui uma ressalva para a configuração 1-I que apresentou bons valores para RMSE e NASH. Dessa forma, a Figura 54 traz os melhores resultados dos arranjos considerando a média das 10 simulações realizadas.

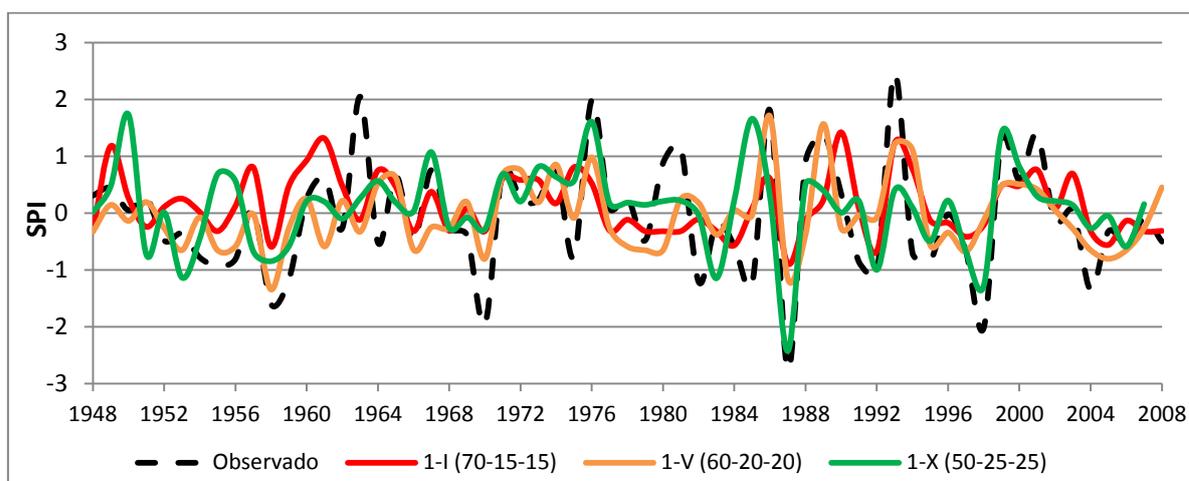


Figura 54 – Série Temporal do SPI para o Melhor Ajuste no Agrupamento 1 para RH1.

Observando-se a Figura 54, tem-se de maneira geral que os arranjos selecionados acompanham a tendência da mudança no comportamento pluviométrico na região. O arranjo 1-I apresentou uma pequena distorção no período anterior a 1964. A partir desse ano, os arranjos apresentaram um desempenho melhor, com destaque ao 1-X que conseguiu representar bem o déficit de chuva no ano 1987. Importante destacar que os arranjos selecionados apresentam apenas 3 índices climáticos como entrada no modelo. Ainda sobre a investigação do desempenho deste modelo, verificou-se o índice de acerto dos modelos de previsão construídos em relação à categorização de secas proposta por Agnew (2000), contidos na Tabela 2. Estes podem ser acessados na Figura 55.

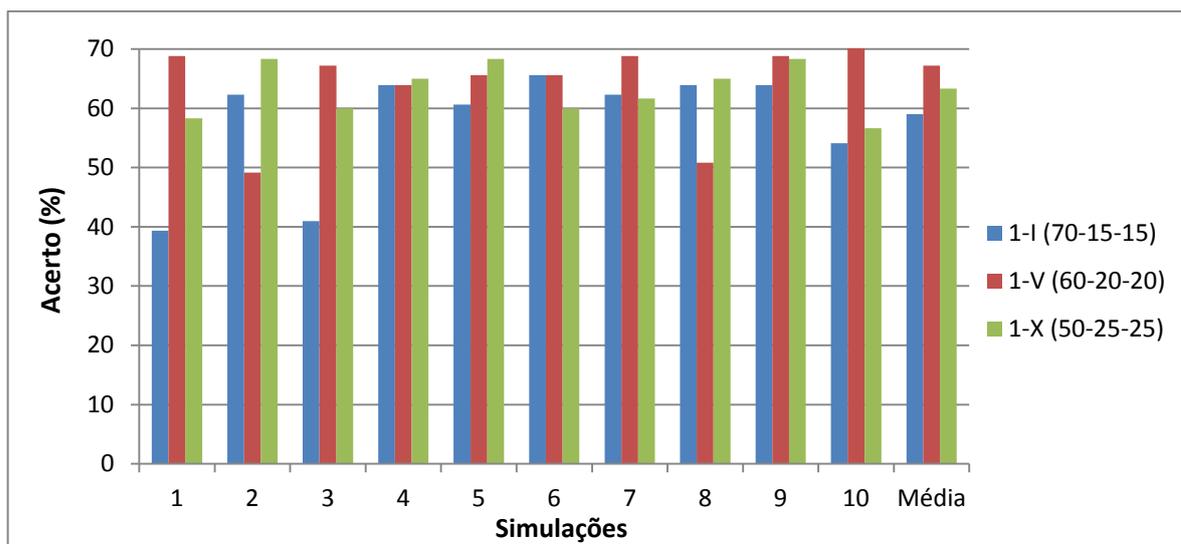


Figura 55 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 1 para RH1.

A partir da Figura 55, observa-se que o arranjo 1-I foi o que apresentou o pior desempenho em relação ao acerto da categoria de déficit de chuva, em contrapartida os arranjos 1-V e 1-X apresentaram uma homogeneidade nos resultados com nível de acerto próximo a 70%.

Prosseguindo, as Figuras 56 e 57 trazem as medidas de desempenho dos arranjos do Agrupamento 01 para RH2.

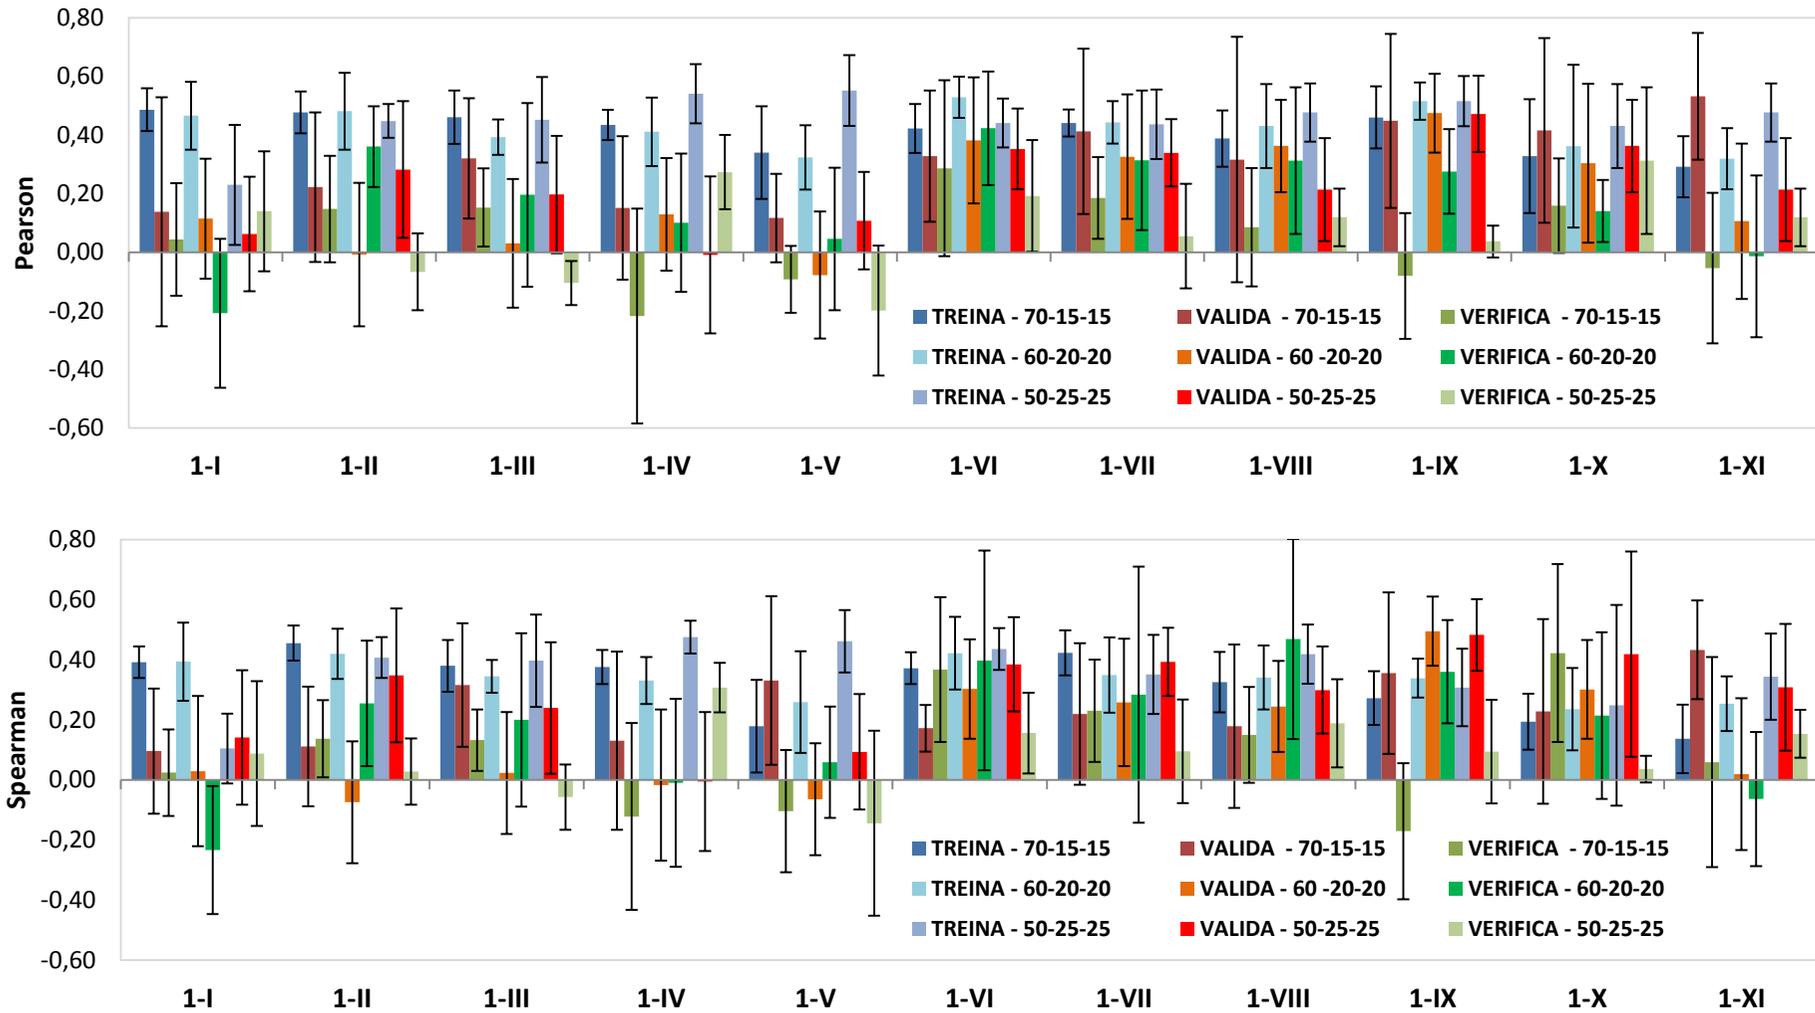


Figura 56 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH2

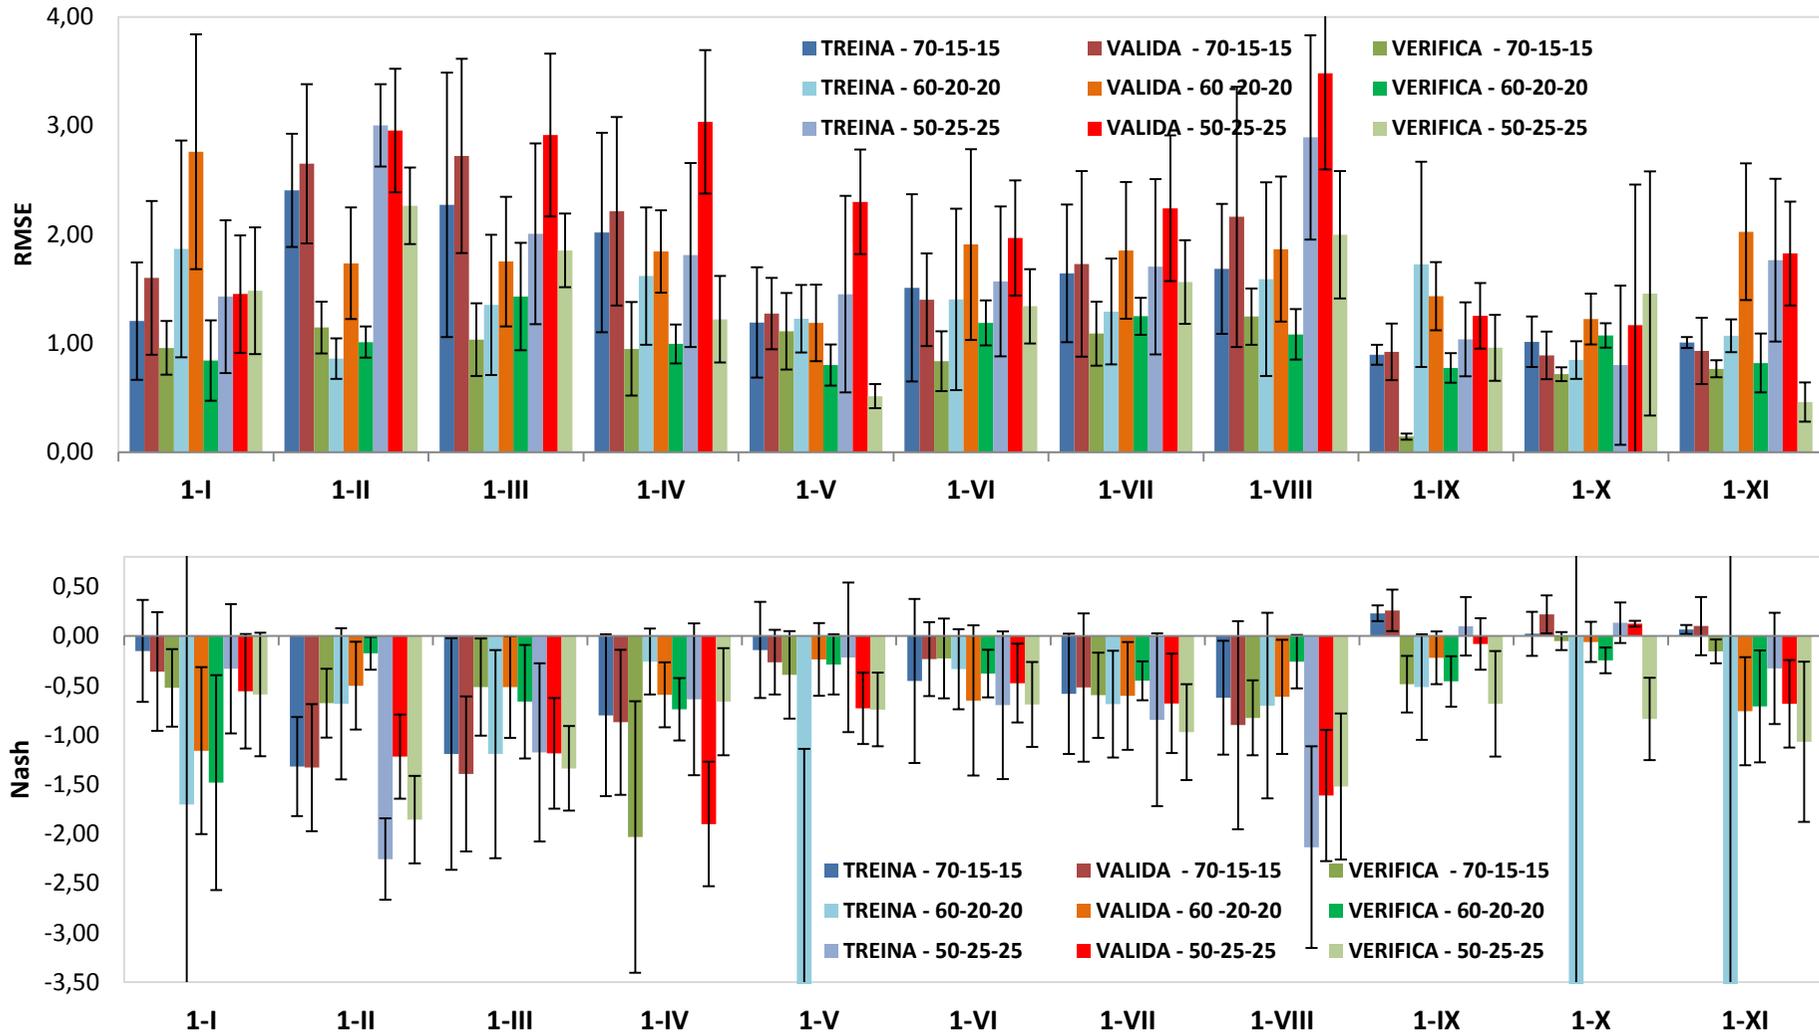


Figura 57 – Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 01 na RH2.

Na aplicação do agrupamento 01 a RH2, os coeficientes de correlação a partir do arranjo 1-VI se mostraram mais homogêneos em relação ao conjunto de treinamento, verificação e validação. No que concerne aos resultados do RMSE, destacam-se os arranjos 1-V, 1-IX, 1-X e 1-XI, por sua vez os melhores valores de Nash são de 1-VI, 1-VII e 1-IX. Assim, foram selecionados os melhores resultados dos arranjos para a média das 10 simulações, que são mostrados na Figura 58.

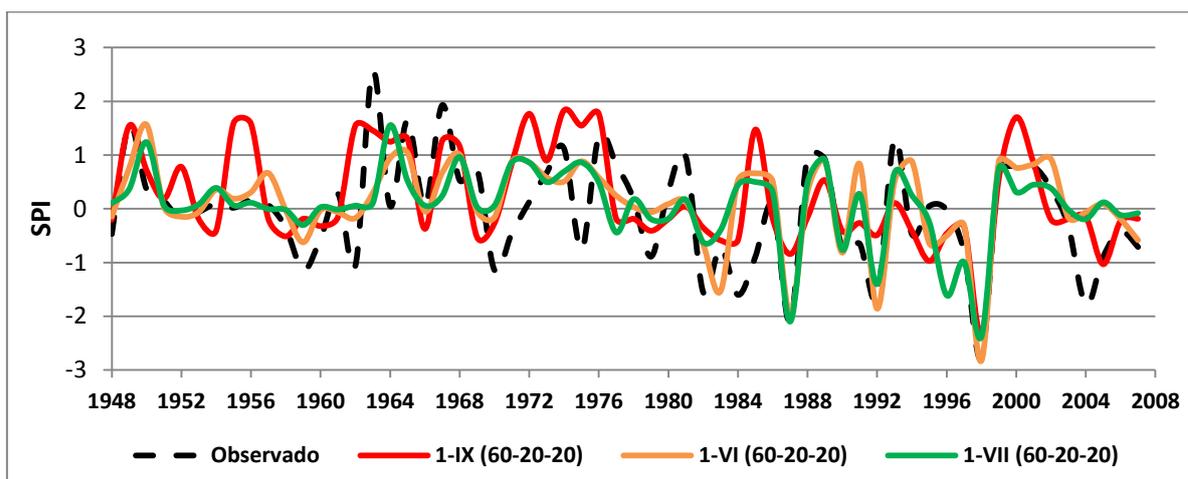


Figura 58 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 1 para RH2.

A Figura 58 mostra que os arranjos selecionados não conseguiram representar bem os índices de chuva no período de 1961 a 1981, no entanto captou o excesso de precipitação nesse período. Ademais, os três arranjos retrataram os picos negativos nos anos de 1987, 1992 e 1998. A Figura 59, por sua vez, traz os valores dos índices de acerto das categorias de secas, como subsídio para identificar os desempenhos dos arranjos selecionados.

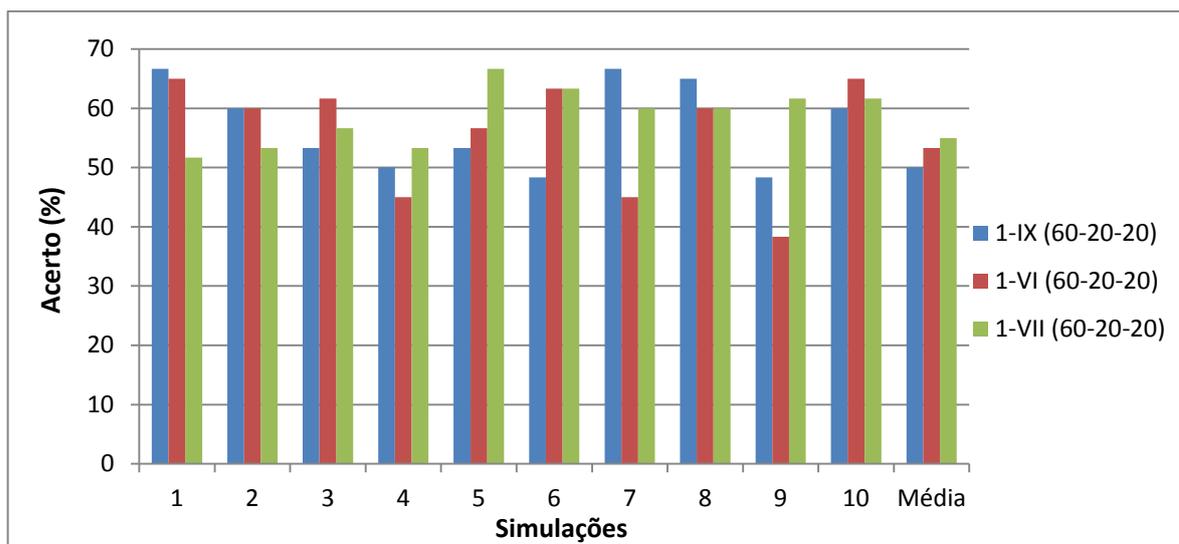


Figura 59 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 1 para RH2.

A Figura 59 indica que, de modo geral, os arranjos do agrupamento 1 apresentam índices de acerto das categorias de secas para RH2 inferiores a RH1, apresentando simulações com valores menores que 40% e média dos valores das simulações pouco ultrapassa o valor de 50%. Em relação ao agrupamento 02, as Figuras 59 e 60 trazem as medidas de desempenho para RH1.

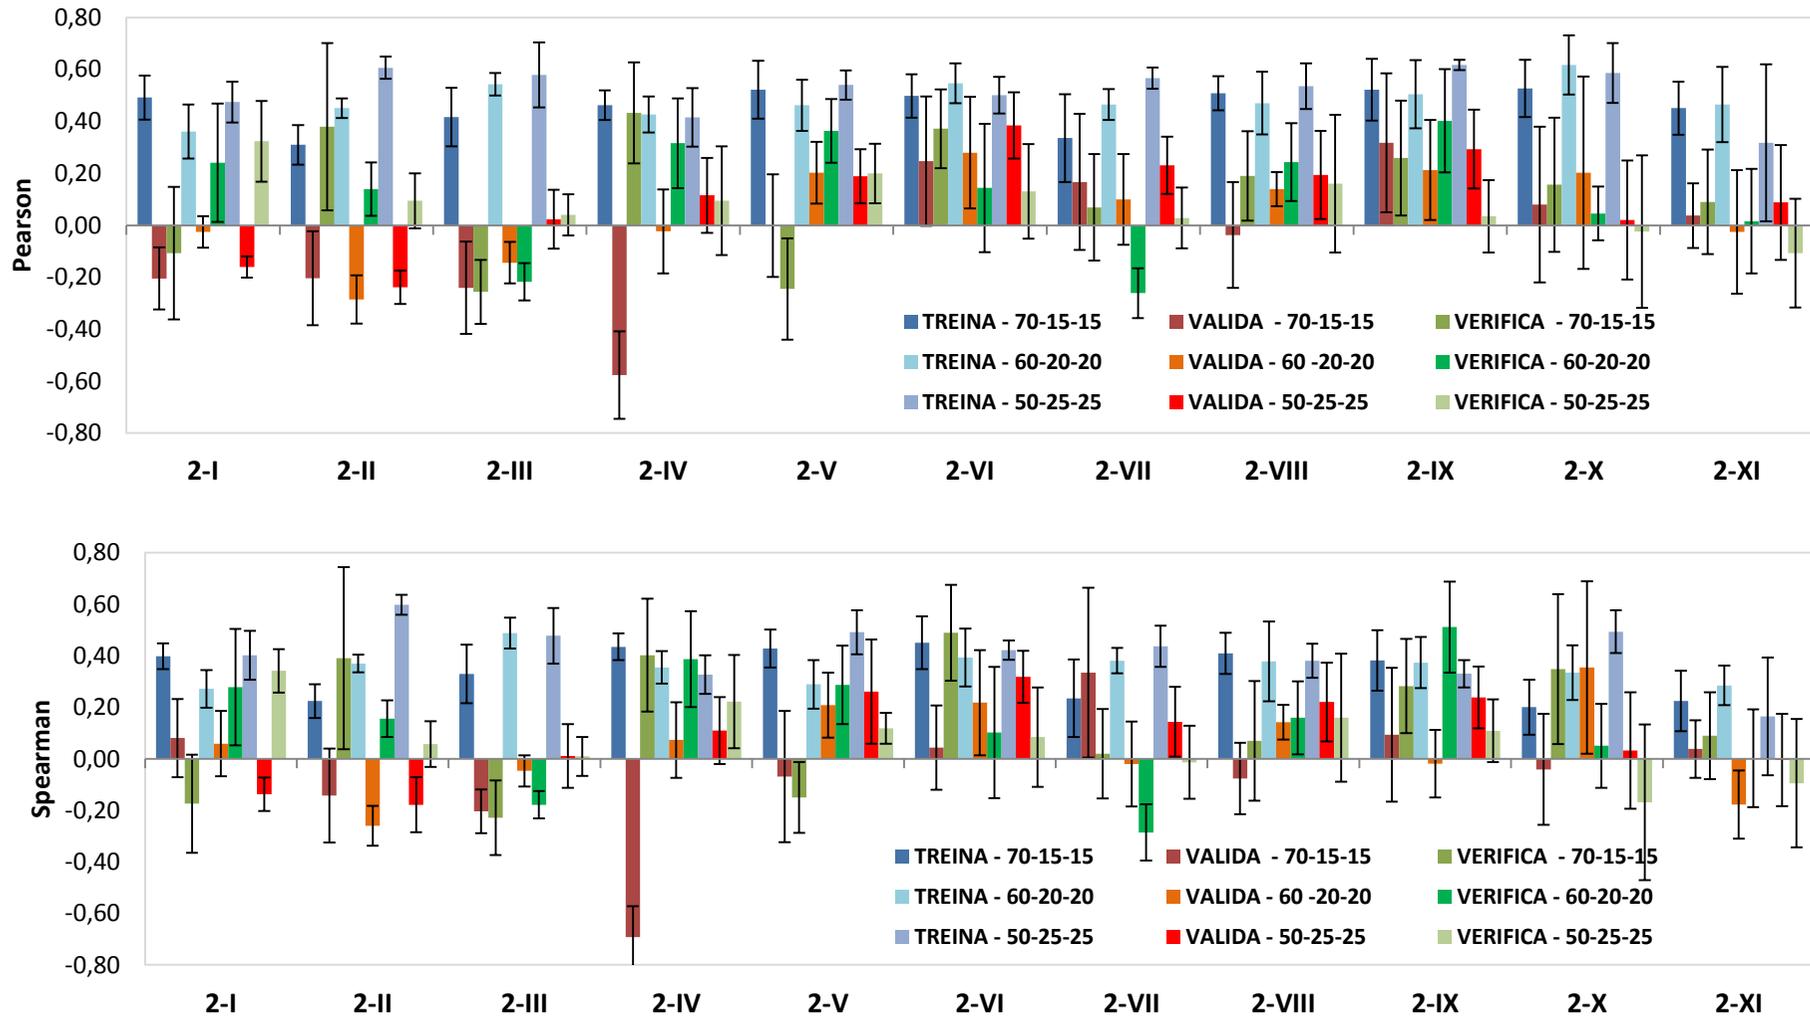


Figura 60 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH1

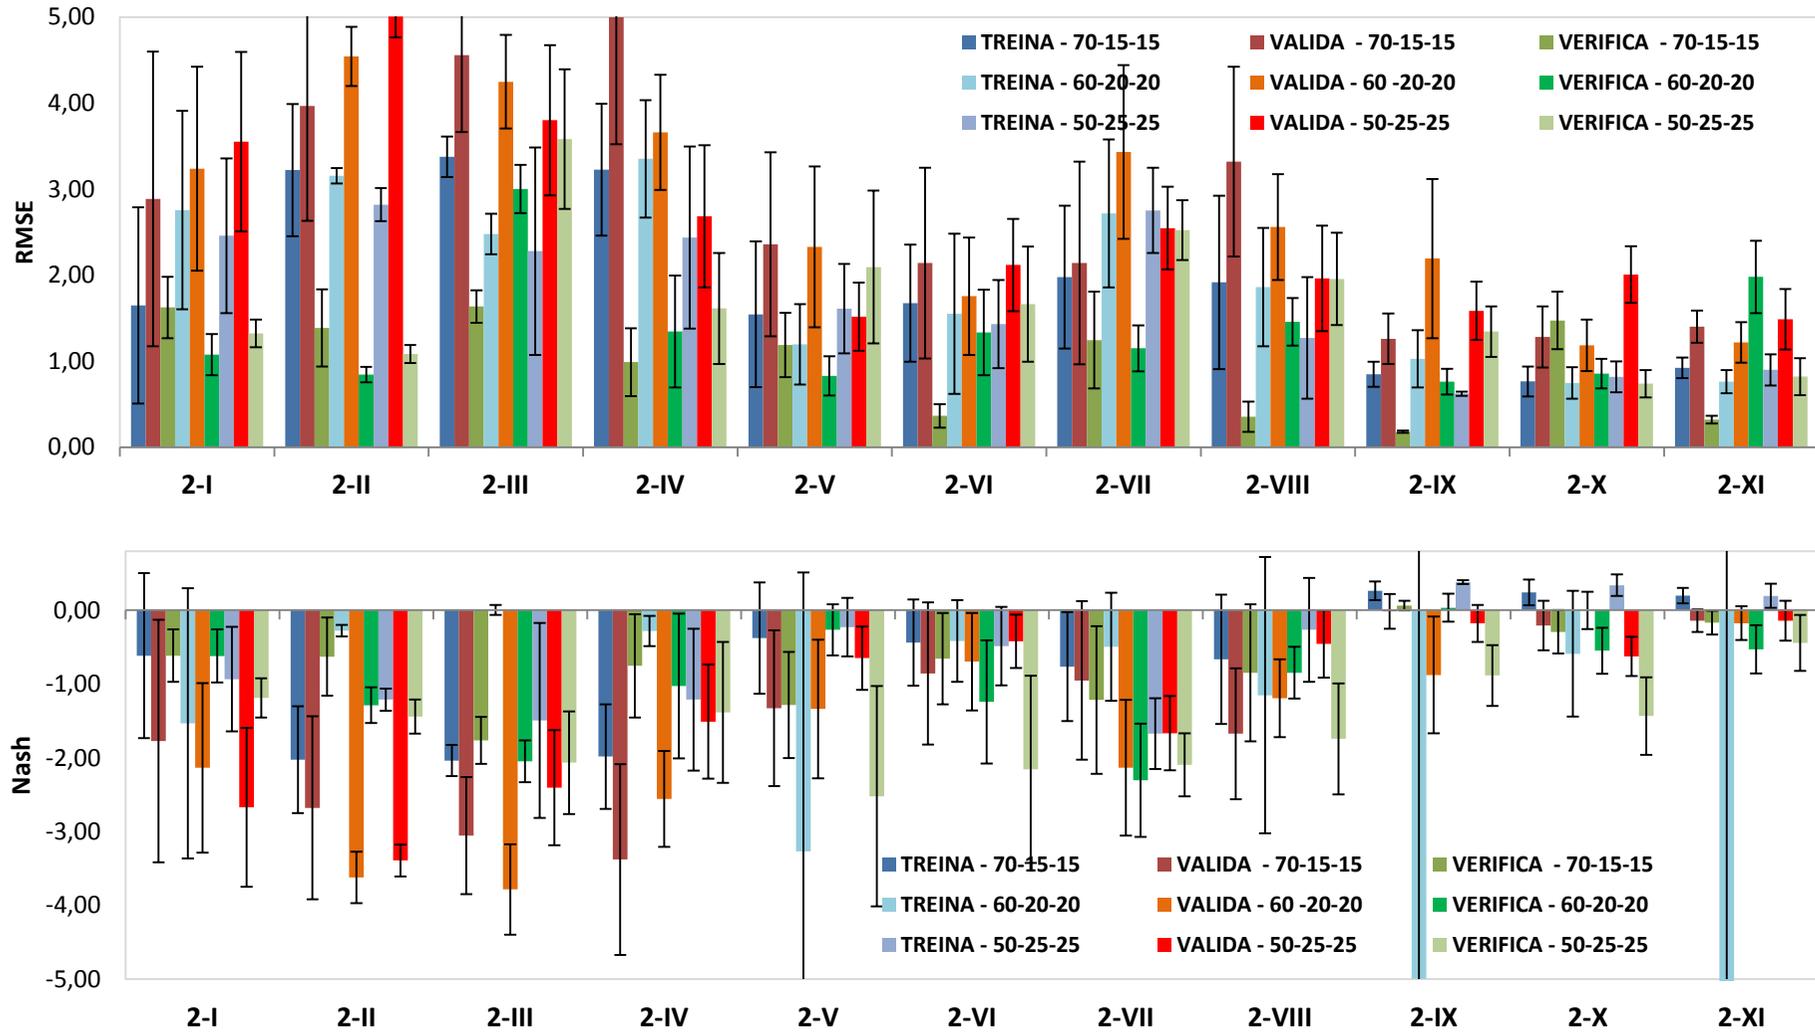


Figura 61– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH1

Em relação à Figura 60, que traz as correlações para o agrupamento 02 na RH1, destacam-se, timidamente, os resultados dos arranjos 2-V, 2-VIII e 2-IX. Na Figura 61, por sua vez, se sobressaem as configurações 2-IX, 2-X e 2-XI, sobretudo a 2-X, para o RMSE, que mostrou uma boa estabilidade. Em relação ao coeficiente de Nash, estes arranjos (2-IX, 2-X e 2-XI) foram os melhores com exceção para o arranjo 2-IX e 2-XI, que possui uma grande dispersão para o treinamento da divisão 60-20-20. Em seguida, na Figura 62, há as séries de SPI para a média das 10 simulações para o melhor arranjo e sua respectiva divisão do conjunto de dados.

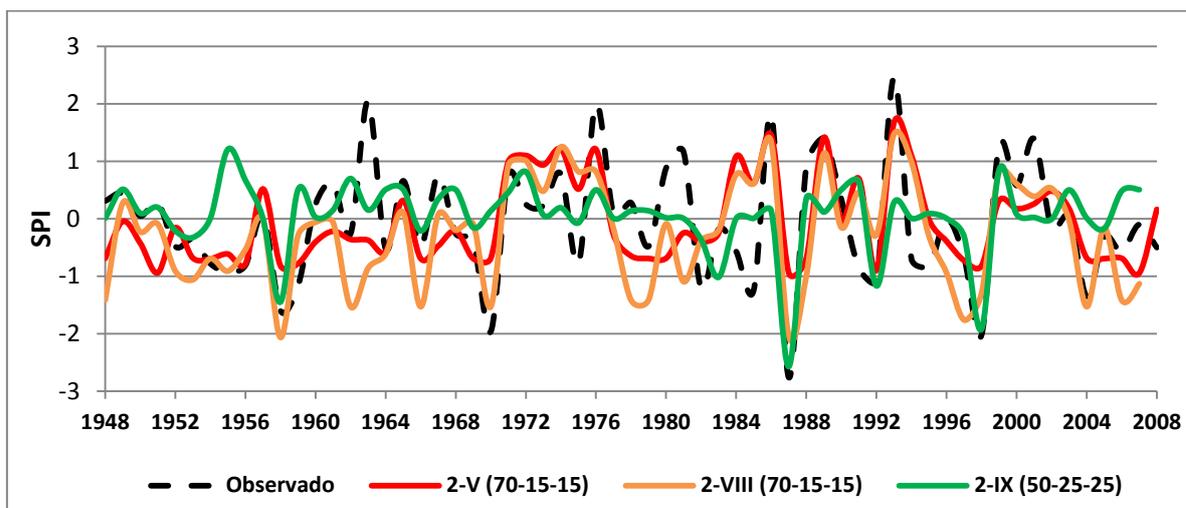


Figura 62 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 2 para RH1.

A partir da Figura 62, verifica-se que os arranjos selecionados reproduziram os eventos de déficit hídrico, sobretudo os arranjos 2-VIII e 2-IX, o arranjo 2-V por sua vez apresentou melhor ajuste para os valores médios de SPI. Desse modo, para verificar qual arranjo se comportou melhor em relação à classificação dos déficit/excesso de precipitação, foi necessário estudar o nível de acerto das categorias os quais podem ser vistos na Figura 63.

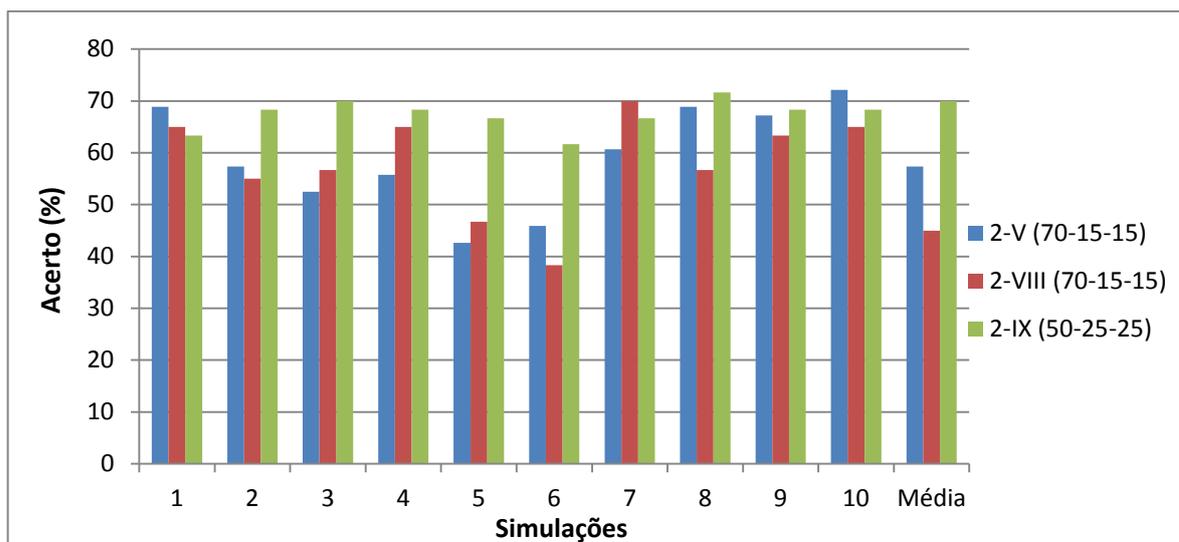


Figura 63 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 2 para RH1.

As configurações selecionadas para o Agrupamento 02, na RH2, mostraram o índice de acerto das classes de seca relativamente elevado com simulações superiores a 70%, um destaque para o arranjo 2-IX que, nas médias dos valores das 10 simulações, apresentou um acerto de 70%. Ainda em relação ao agrupamento 02, as Figuras 64 e 65 trazem os valores de desempenho para aplicação na RH2.

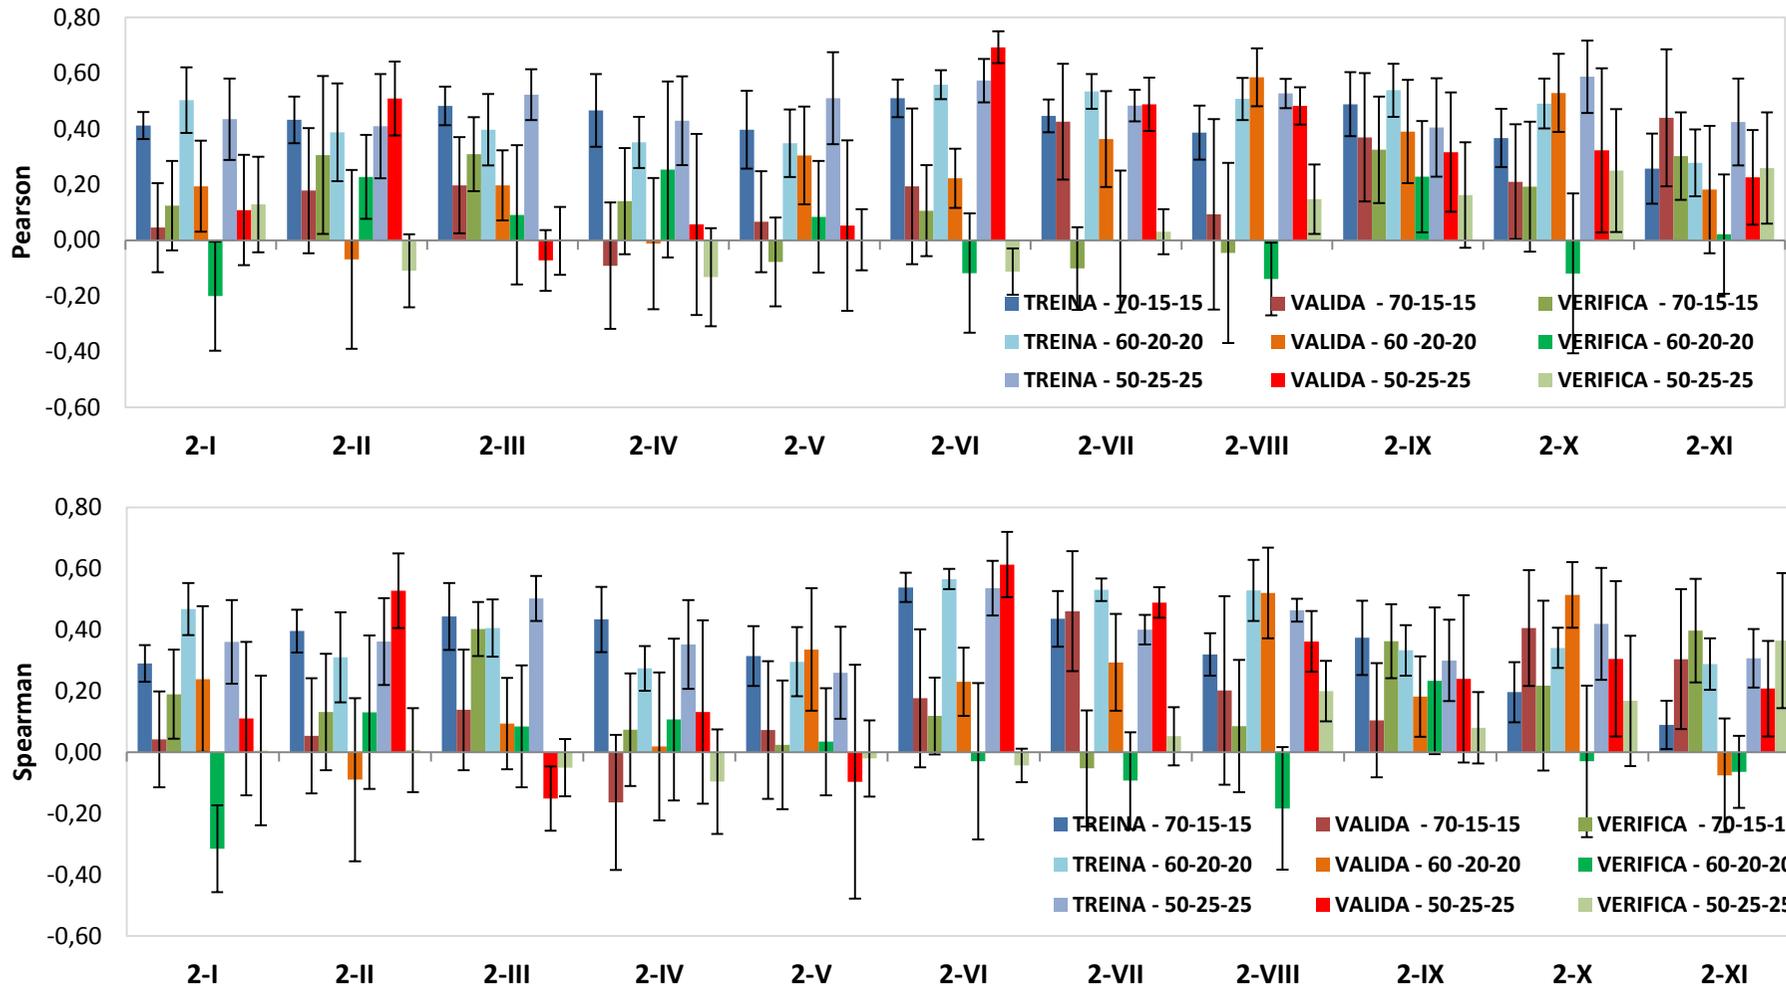


Figura 64 – Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH2

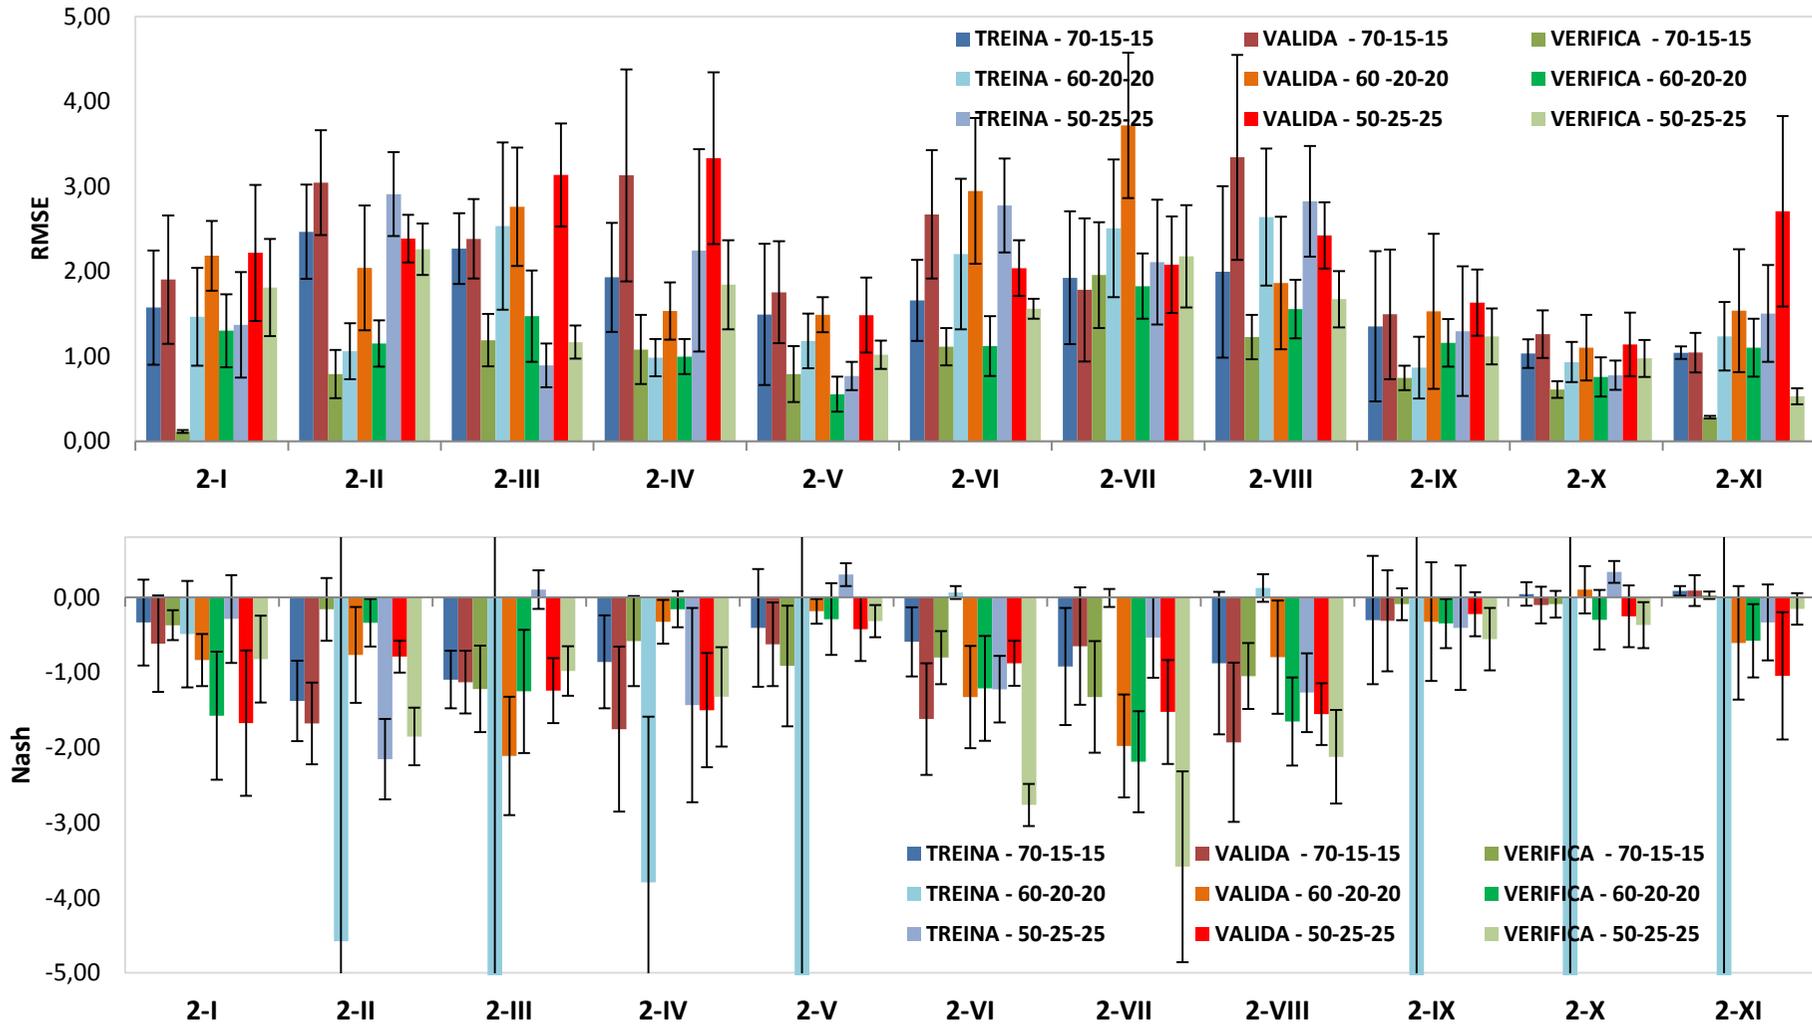


Figura 65– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 02 na RH2

A Figura 64 mostra que as correlações de Pearson e Spearman apresentam uma certa homogeneidade para algumas divisões do conjunto de dados para os arranjos 2-III, 2-V, 2-IX, 2-X e 2-XI. Em relação ao RMSE (Figura 65), destacam-se os arranjos 2-IV, 2-V, 2-IX e 2-X, sobretudo o arranjo 2-X, que pelo seu elevado grau de estabilidade da rede construído a partir desta configuração. Na análise do coeficiente de Nash, têm-se os melhores resultados para 2-IV, 2-V, 2-IX, 2-X e 2-XI, com uma ressalva para o desempenho do treinamento da divisão 60-20-20 que em praticamente todos arranjos apresentou alto grau de dispersão. Analisando os arranjos destacados pelos coeficientes de desempenho, selecionaram-se os melhores para verificar o comportamento temporal frente à série de SPI observada, assim foram adotadas as configurações 2-III, 2-IX e 2-X, conforme pode ser acessada na Figura 66.

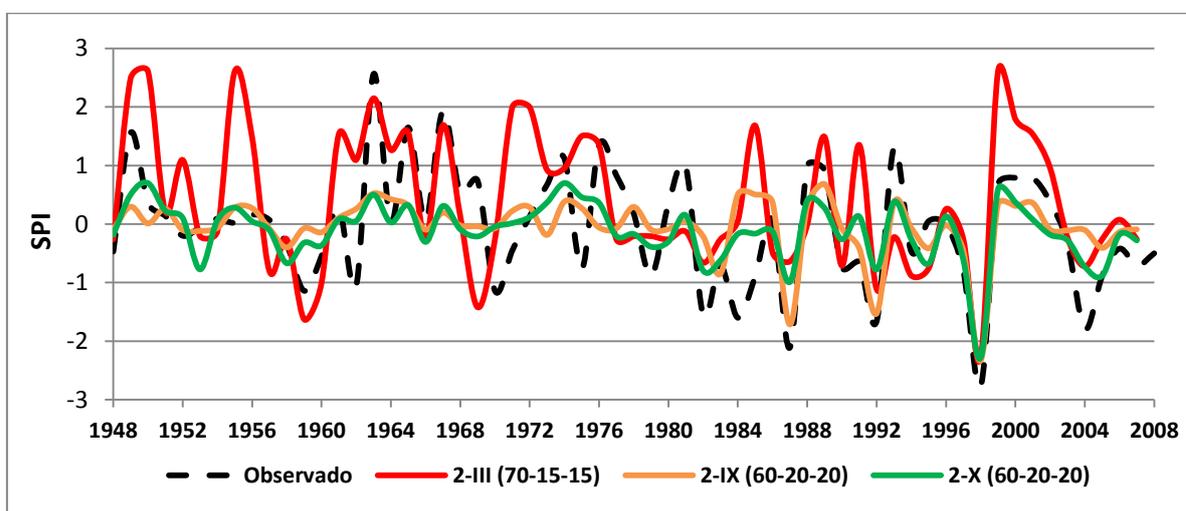


Figura 66 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 2 para RH2.

A Figura 66 mostra que o arranjo 2-III, de modo geral, acompanha a tendência de acréscimo/decrécimo de precipitação por toda a série, diferentemente das configurações 2-IX e 2-X que se ajustam melhor ao evento de déficit, sobretudo a partir de 1984, antes disso, esses arranjos apresentam sempre valores medianos (próximo de zero), o que pode até justificar o alto grau de dispersão do coeficiente de Nash apresentado na Figura 65. Para analisar o grau de acerto das classes de seca destes arranjos, observa-se a Figura 67.

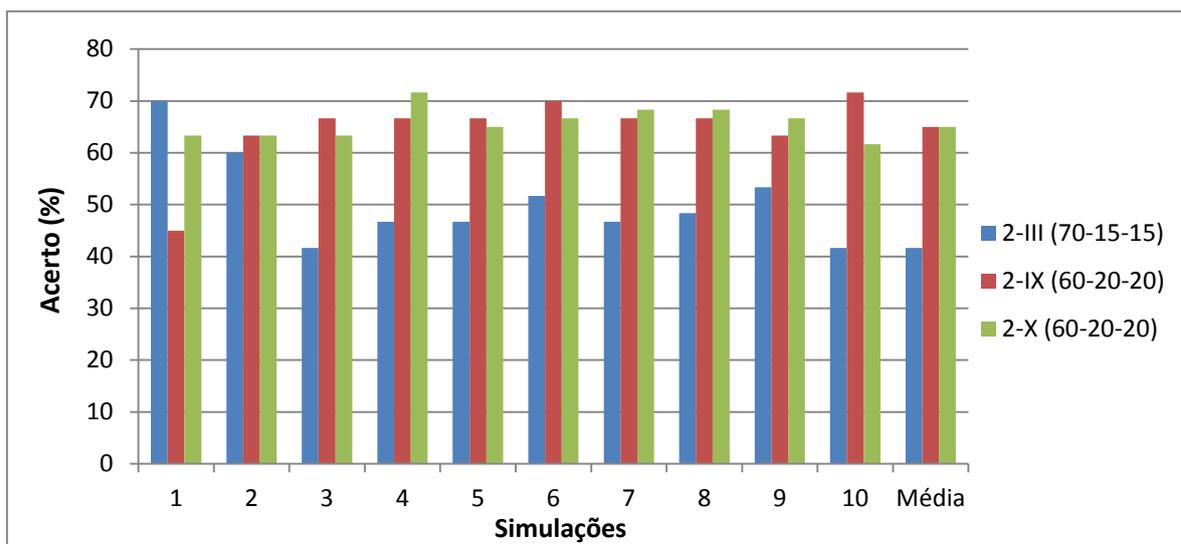


Figura 67- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 2 para RH2.

Da Figura 67, observa-se que o arranjo 2-III foi que apresentou o menor índice de acerto, podendo apresentar valores próximos de 40%, por outro lado os arranjos 2-IX e 2-X apresentaram, em uma simulação, mais de 70% de acerto e nas médias das simulações ambos apresentaram nível de acerto de 65%. Essas configurações podem se mostrar como potenciais modelos para previsão de déficit de precipitação, haja vista que melhores ajustes foram para estes eventos. Em busca de melhores modelos, analisou-se o desempenho do agrupamento 3 para RH1 que pode ser visto nas Figuras 68 e 69.

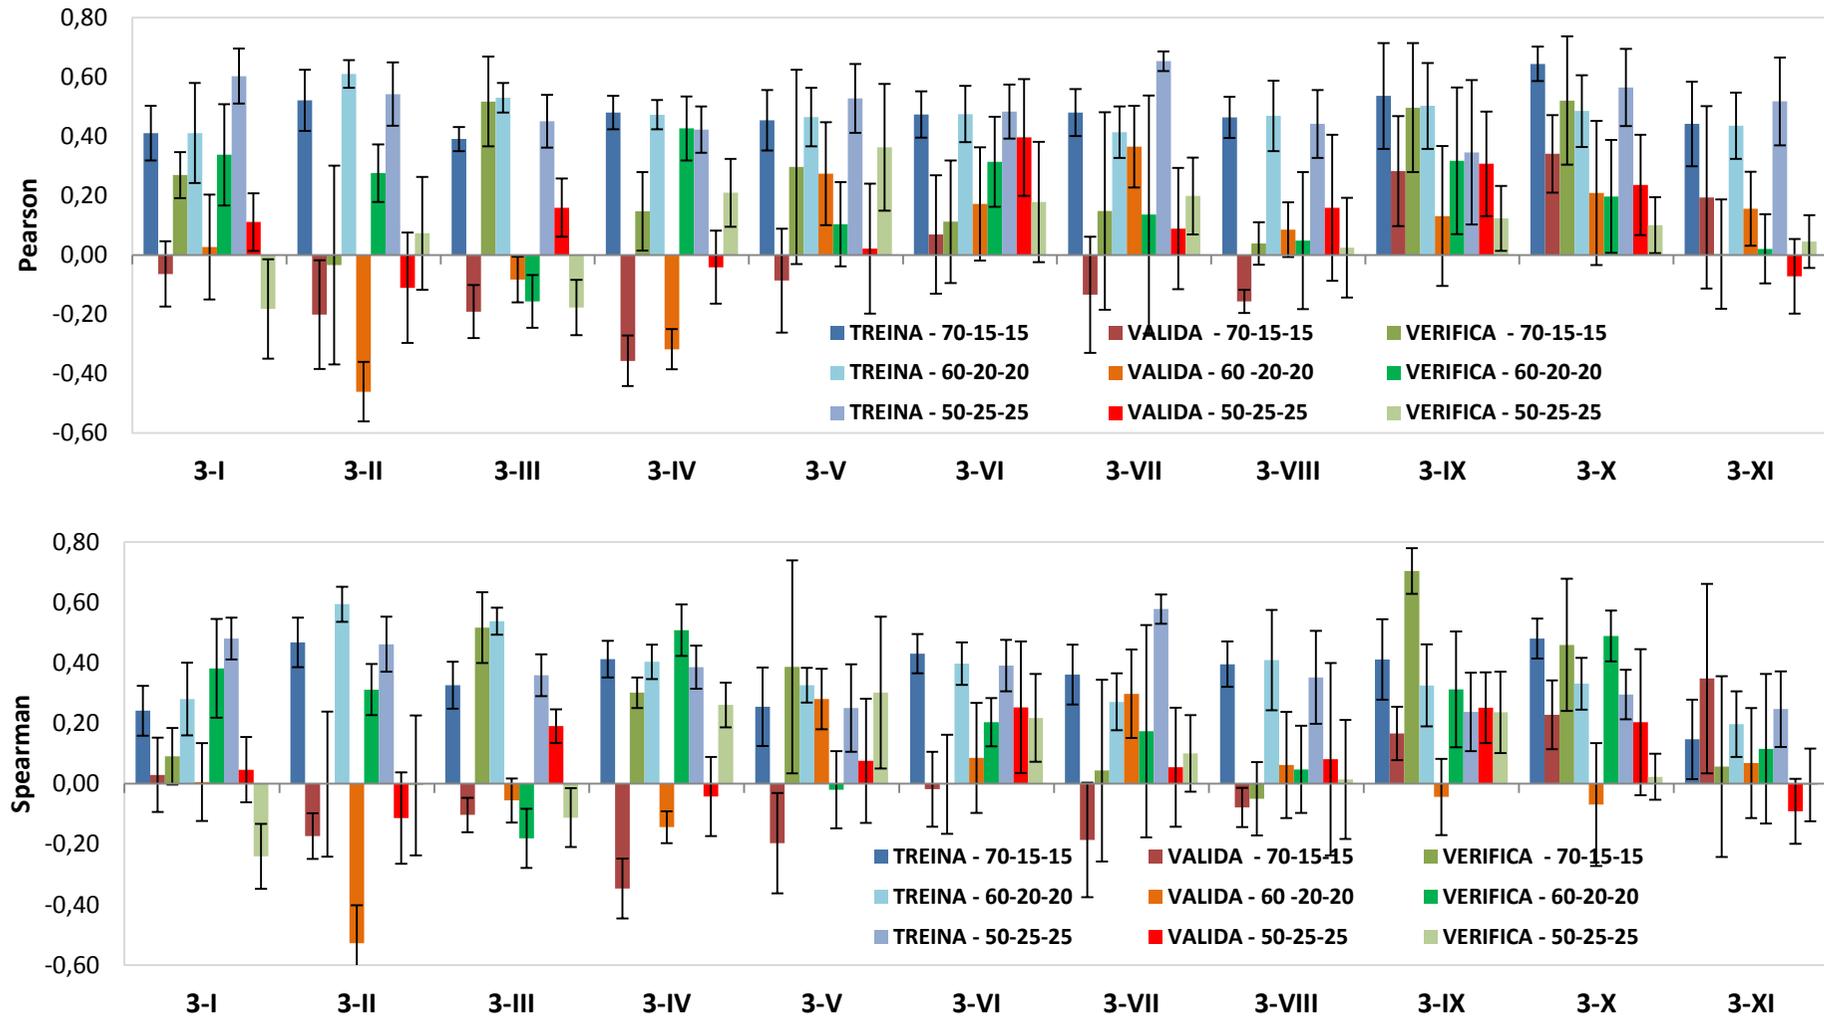


Figura 68 - Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH1.

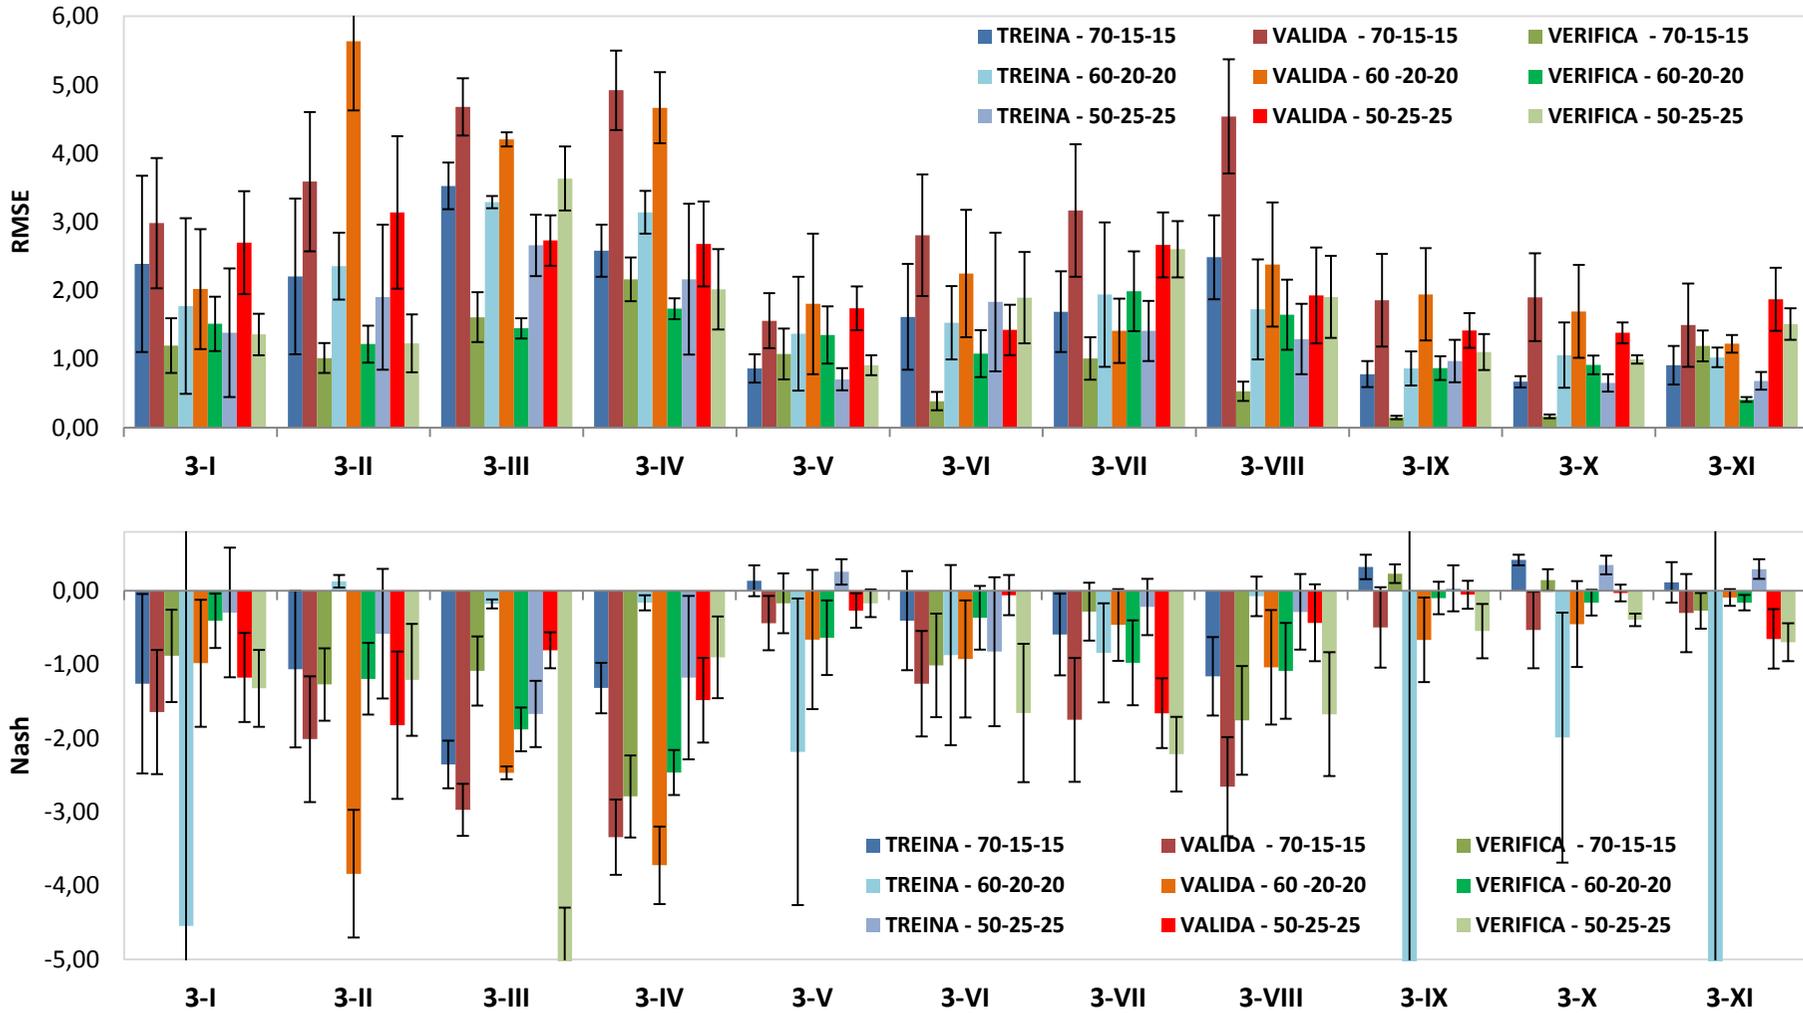


Figura 69– Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH1

As correlações de Spearman e Pearson mostraram que os arranjos 3-VI, 3-IX e 3-X são levemente mais homogêneos em relação aos seus valores no conjunto de treinamento, validação e verificação. Quando se observam o valores de RMSE, tem-se que 3-V, 3-VI, 3-IX, 3-X e 3-XI possuem os menores valores de erro e possuem um considerável grau de estabilidade nos resultados. O coeficiente de Nash, por sua vez, exhibe os melhores valores para 3-V, 3-IX, 3-X e 3-XI; inclusive apresentando valores da ordem de 0,4. Dessa forma, analisando as séries geradas por estes arranjos, selecionam-se as melhores para visualização do comportamento temporal em relação a série de SPI, conforme pode ser visto na Figura 70.

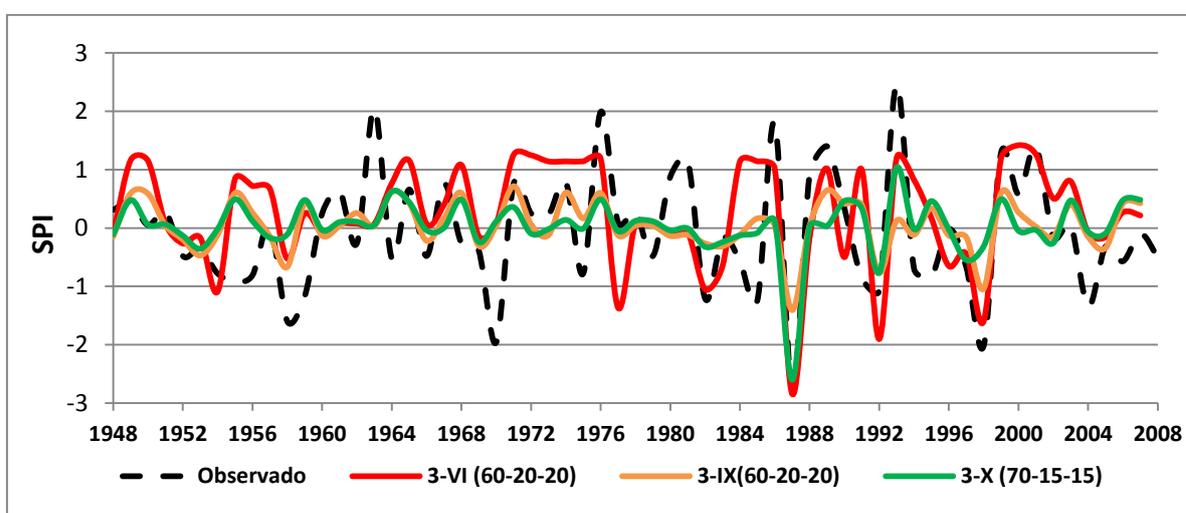


Figura 70- Série Temporal do SPI para o Melhor Ajuste no Agrupamento 3 para RH1

Analisando-se a Figura 70, verifica-se que o período a partir de 1987 possui maior poder de previsibilidade, dado que os arranjos selecionados se ajustam bem à série de SPI observada. Antes de 1987, as respostas dos modelos são valores medianos não retratando bem os picos. Esses resultados sugerem alguma alteração do regime pluviométrico (pico mais frequentes e mais agudos) a partir de 1987 que pode ser retratada pelo comportamento das variáveis climáticas globais (pressão atmosférica e temperatura do mar) traduzidas nos índices climáticos, em especial o Niño 3.4, que aparece em todas as configurações selecionadas. Para verificar o nível de acerto das categorias de secas e sua dispersão, a Figura 71 traz os valores de acerto, em porcentagem, para os arranjos supracitados.

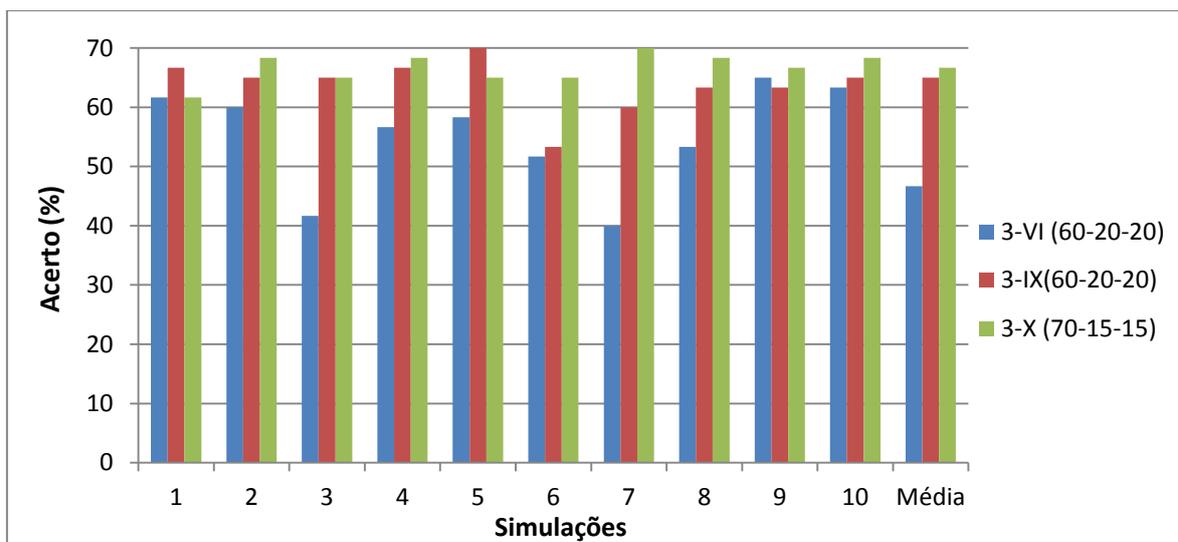


Figura 71- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 3 para RH1

A Figura 71 mostra que a configuração 3-VI possui os piores resultados em relação ao nível de acerto das classes de seca, enquanto que as 3-IX e 3-X apresentaram valores em sua maioria superiores a 60%. Isso mostra mais uma vez a importância dos fenômenos nos Oceanos Pacífico, no regime de precipitação da região de estudo, haja vista que estas configurações possuem um peso maior do Niño 3.4.

Prosseguindo a análise do agrupamento 3, desta vez na RH2, as Figuras 72 e 73 trazem os coeficientes de desempenho dos modelos simulados.

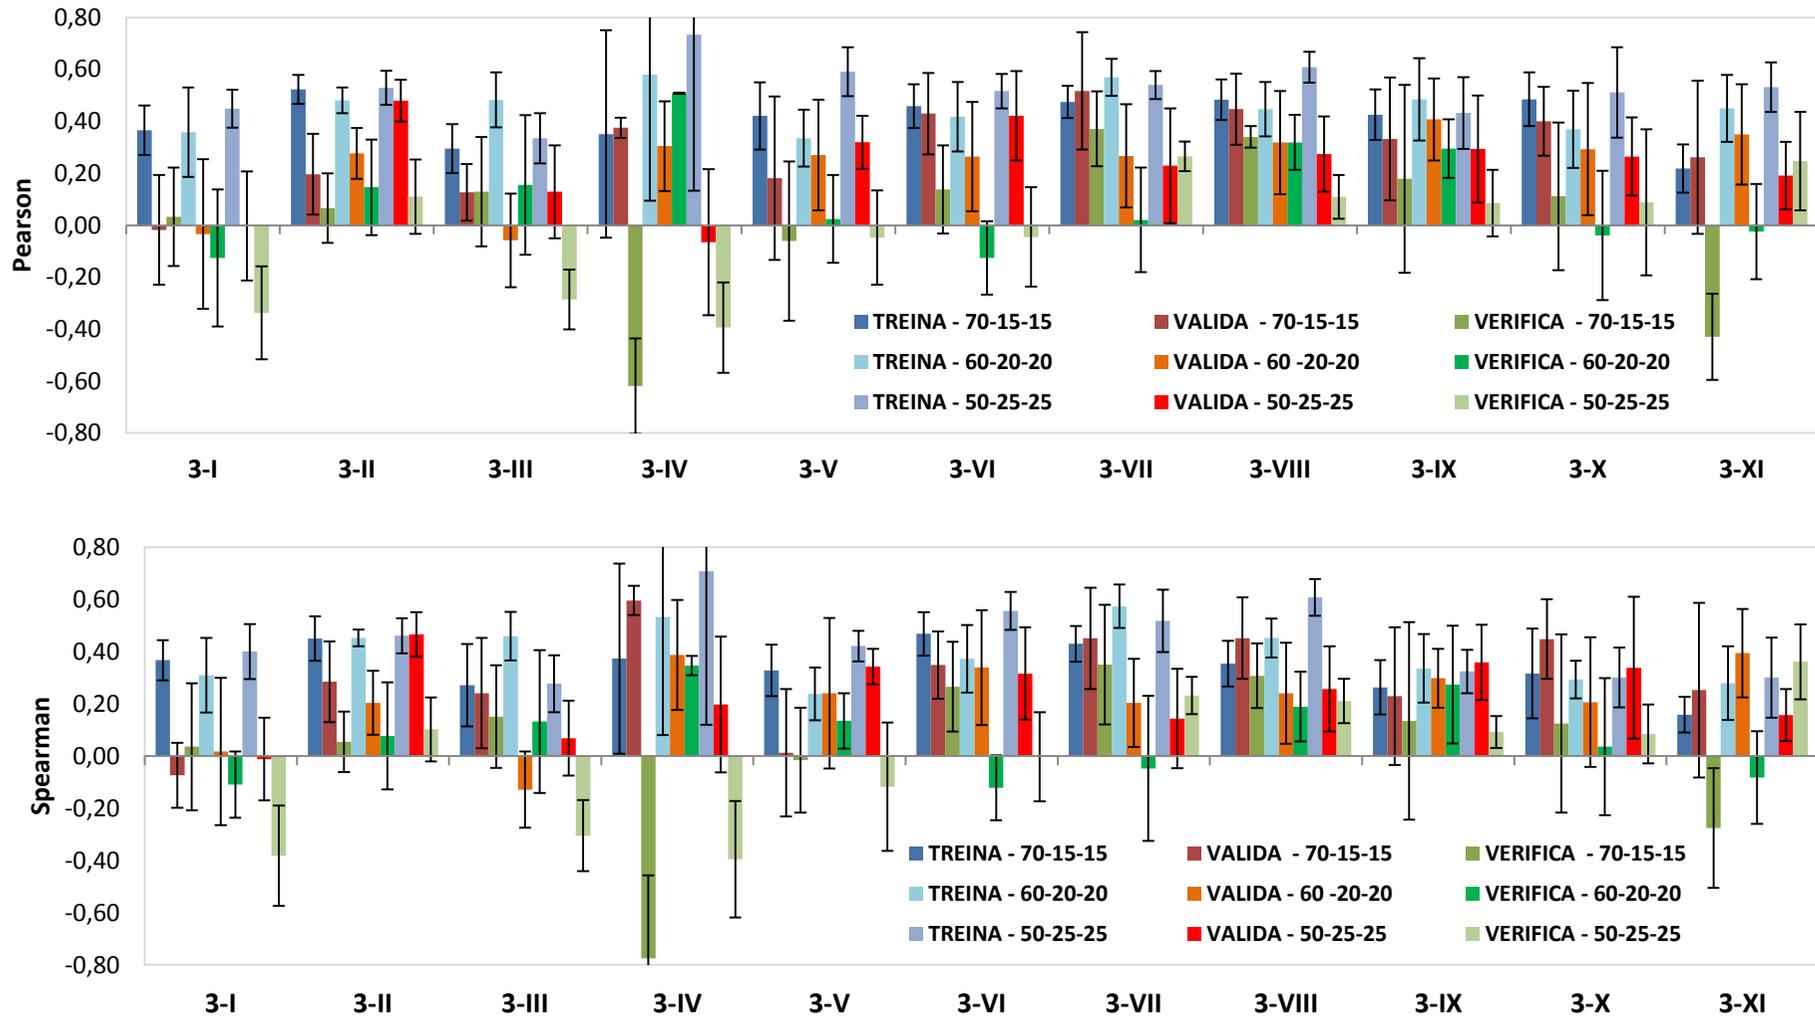


Figura 72 - Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH2.

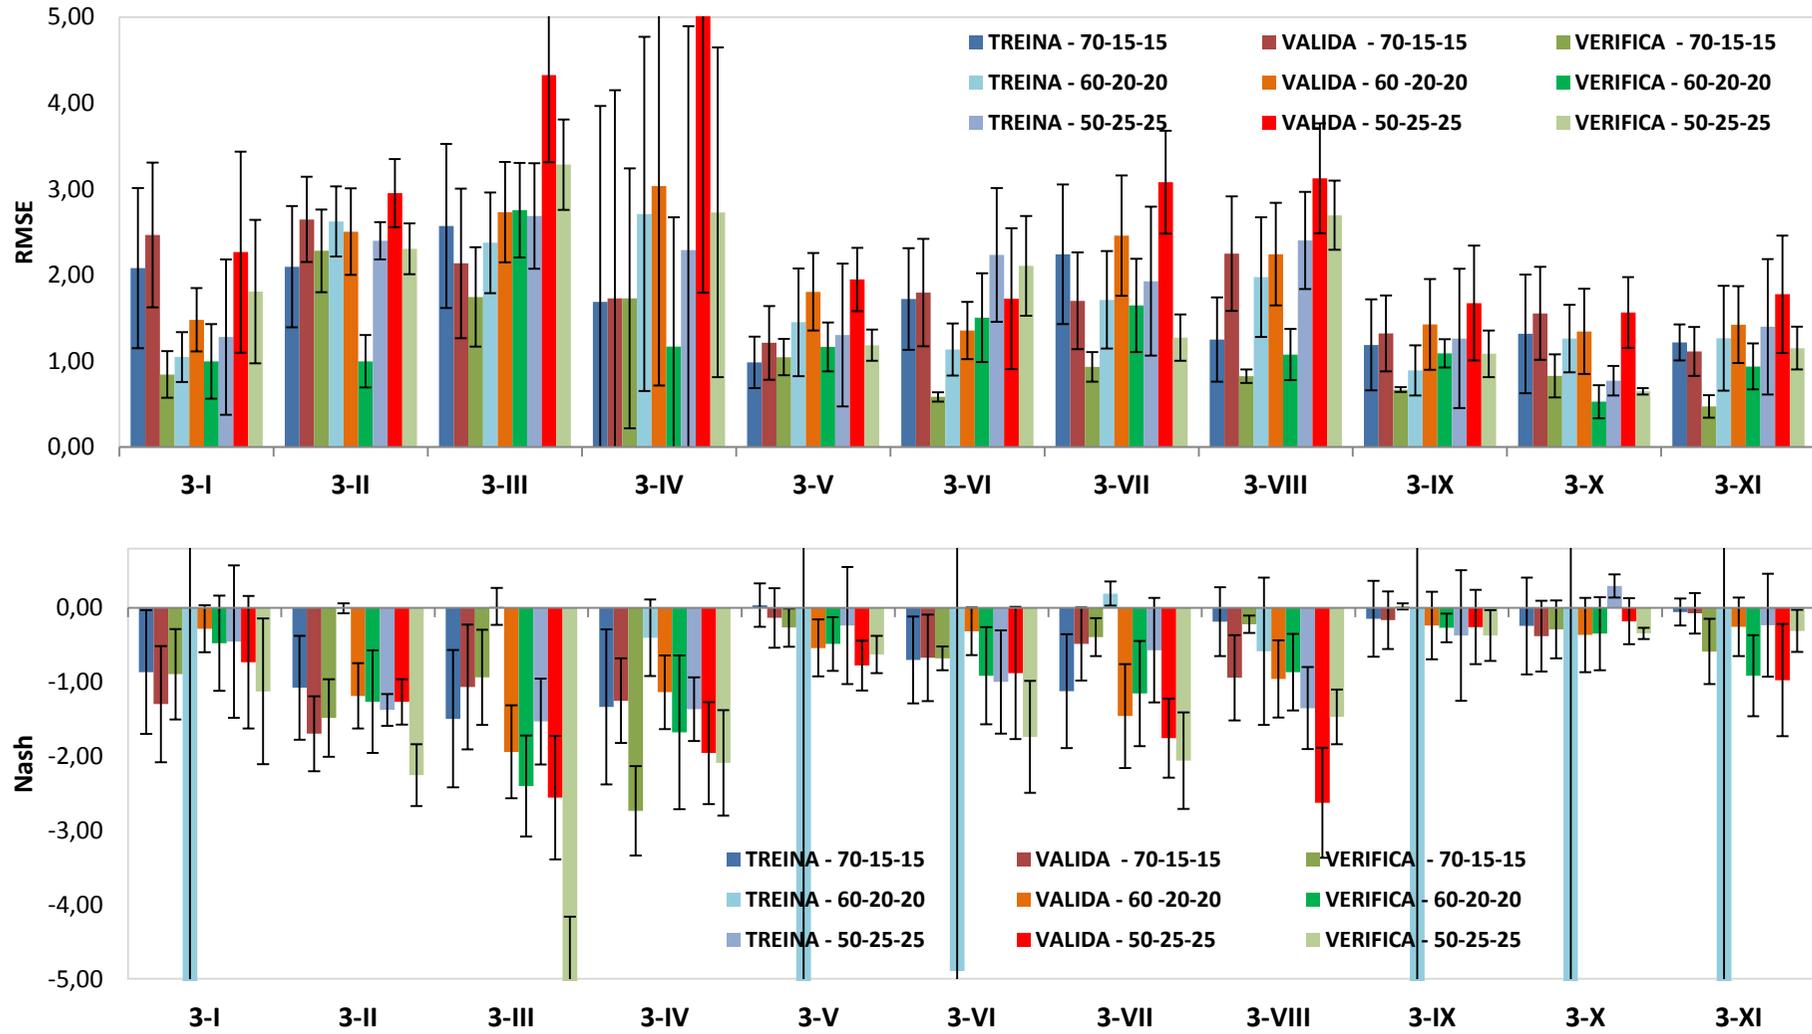


Figura 73 - Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 03 na RH2.

A Figura 72 evidencia que os arranjos 3-II, 3-VII, 3-VIII, 3-IX e 3-X apresentam comportamentos semelhantes para as amostra de treinamento, validação e verificação. Por sua vez, na Figura 73, o RMSE possui melhores resultados no arranjo 3-V, 3-IX, 3-X e 3-XI; por fim o coeficiente de Nash corrobora os resultados do RMSE, com exceção para o conjunto de dados de treinamento da divisão 60-20-20. A Figura 74 traz a série anual do SPI e dos valores gerados pelos melhores arranjos considerando a média das 10 simulações.

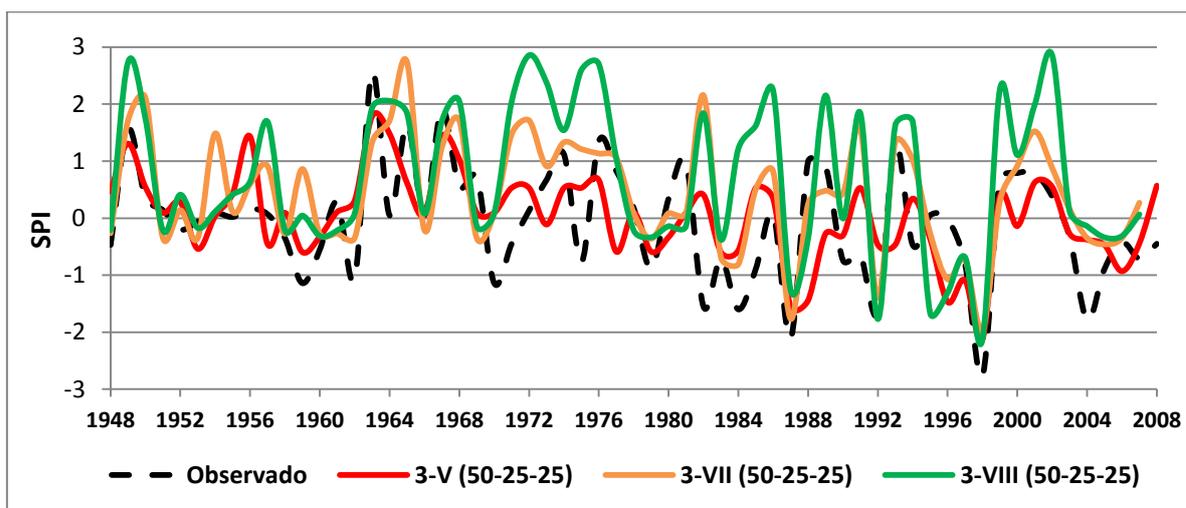


Figura 74 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 3 para RH2.

Verifica-se, analisando a Figura 74, que os modelos propostos seguem, de modo geral, a tendência da série de SPI da RH2 fazendo inflexões em pontos similares e, além disso, retratam bem os maiores eventos de déficit de chuva. Ainda sim, foi investigado o nível de acerto das classes destes modelos, os quais podem ser acessados na Figura 75.

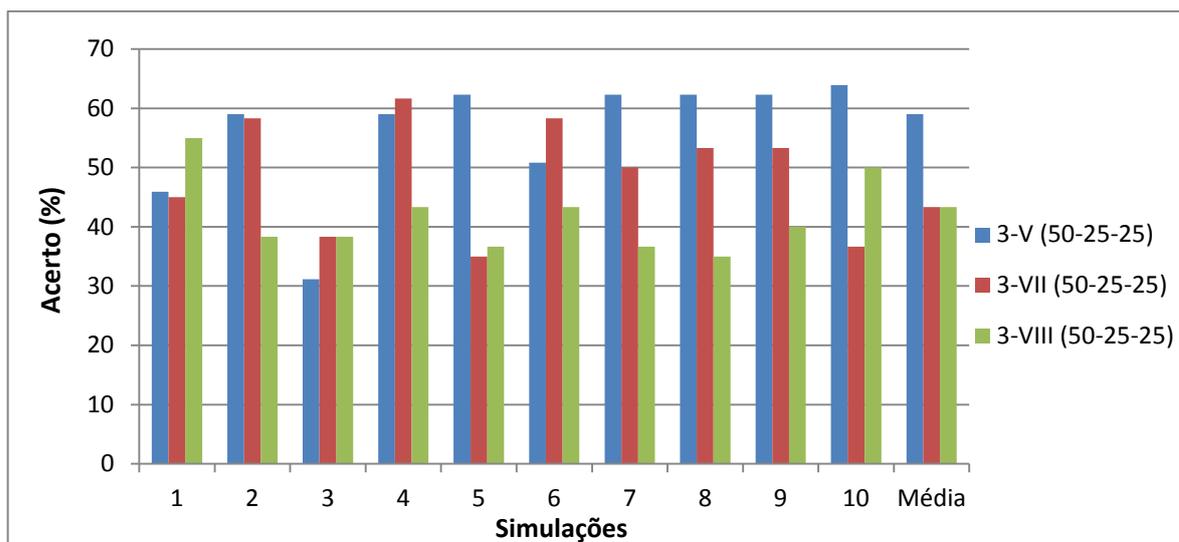


Figura 75 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 3 para RH2.

Apesar dos modelos selecionados para previsão do SPI, no RH2, acompanhar a tendência de déficit/superávit de precipitação, estes não conseguem incidir sobre as classes de secas inseridas, conforme pode ser visto na Figura 75, que apresenta uma redução do número de acerto, podendo encontrar valores menores que 40%. A melhor configuração se dá com o arranjo 3-V que ultrapassa levemente 60% de acerto.

Em seguida, têm-se os valores que aferem o desempenho do agrupamento 4 para RH1 nas Figuras 76 e 77.

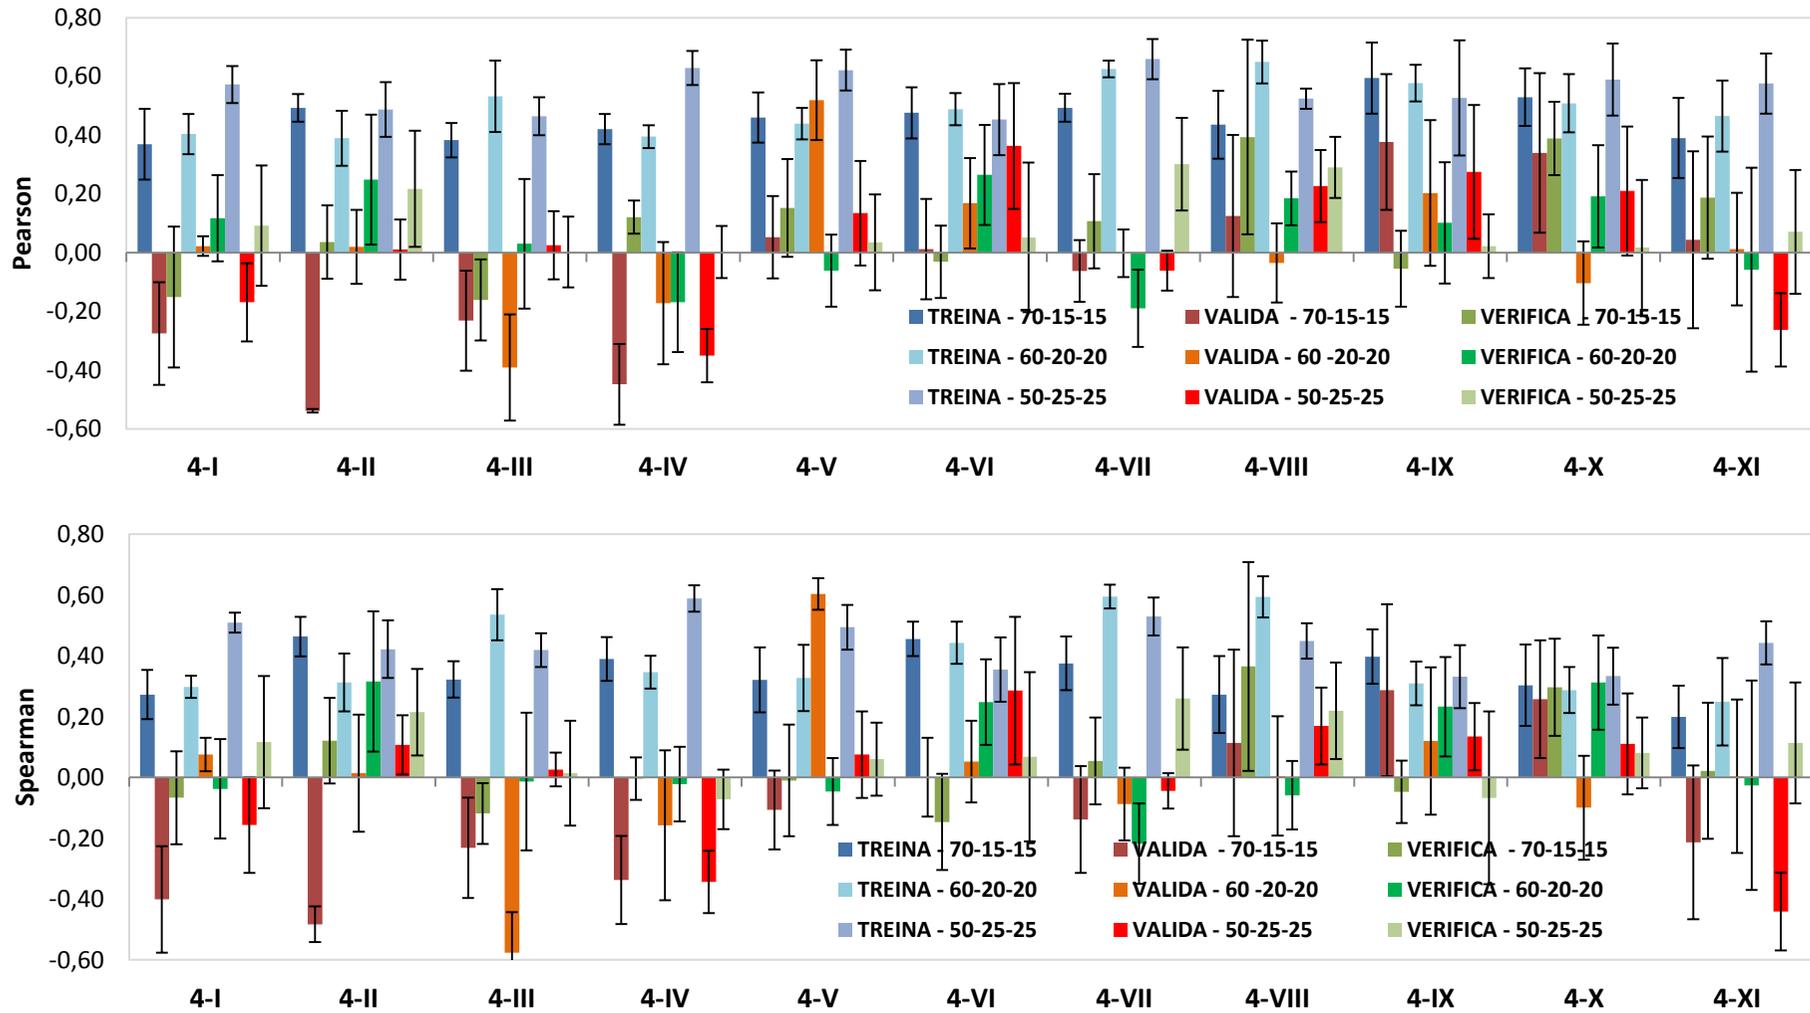


Figura 76- Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH1.

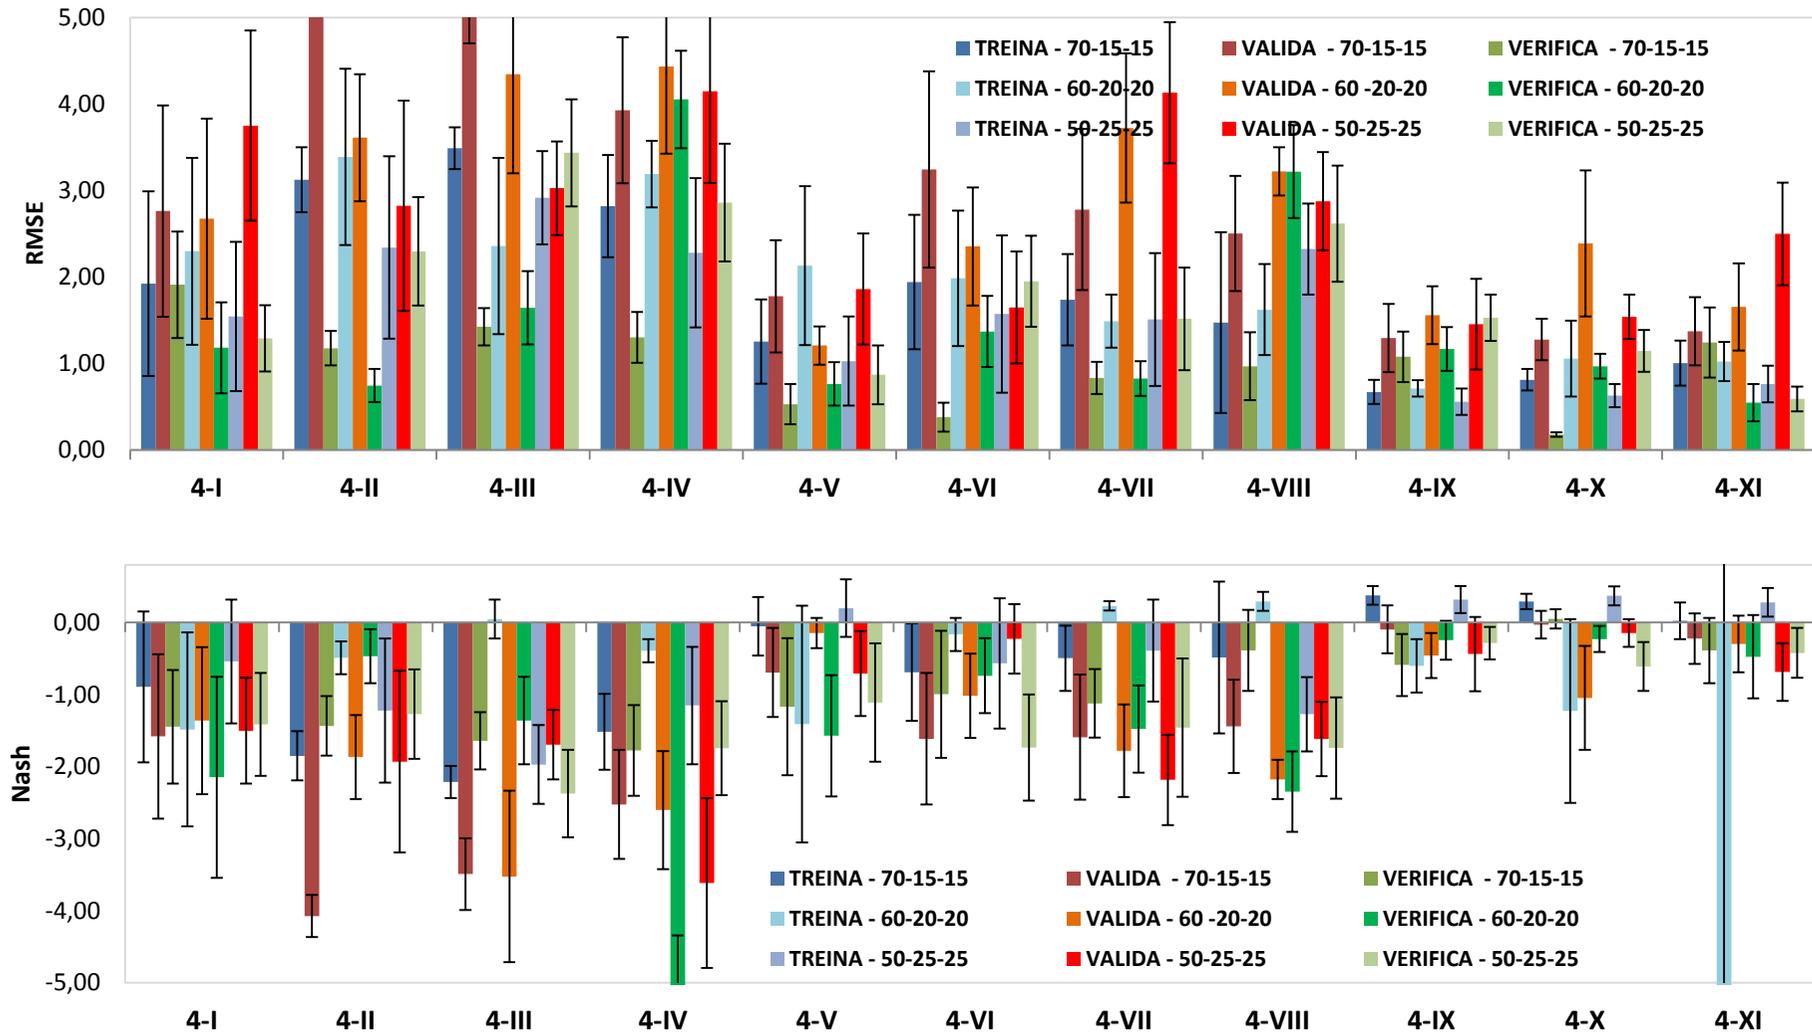


Figura 77 - Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH1

Os valores de correlação dos resultados oriundos da aplicação do agrupamento 04 a RH1 são bastante heterogêneo com certa dificuldade de encontrar arranjos estáveis. É possível destacar apenas o arranjo 4-VIII e 4-X, para as divisões de conjunto de dados, 50-25-25 e 70-15-15, respectivamente. Já para os valores de RMSE (Figura 77), destacam-se as configurações 4-V, 4-VI, 4-IX, 4-X e 4-XI; resultado bem semelhante para aplicação dos coeficientes de Nash. Ainda sim, para verificar o comportamento das séries geradas via rede neural artificial, serão selecionados os melhores arranjos e mostrados na Figura 78.

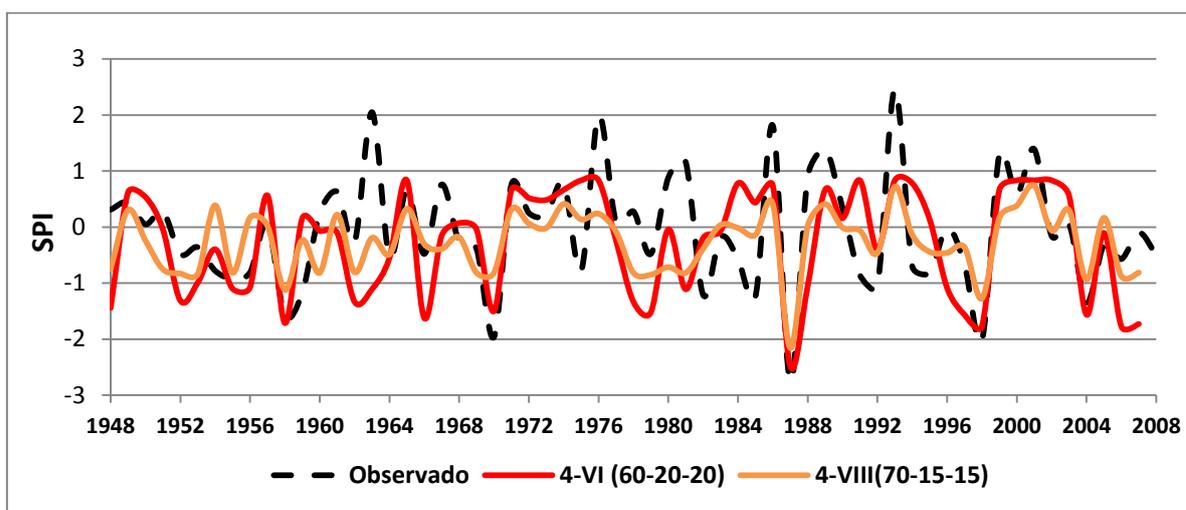


Figura 78 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 4 para RH1.

Só foi possível selecionar apenas 2 configurações dentro do agrupamento 4, aplicado a RH1. Estes arranjos mostraram resultados satisfatórios com representação da série temporal de SPI, principalmente, para evento com déficits de precipitação. A Figura 79 traz os índices de acerto das categorias de secas para os arranjos selecionados.

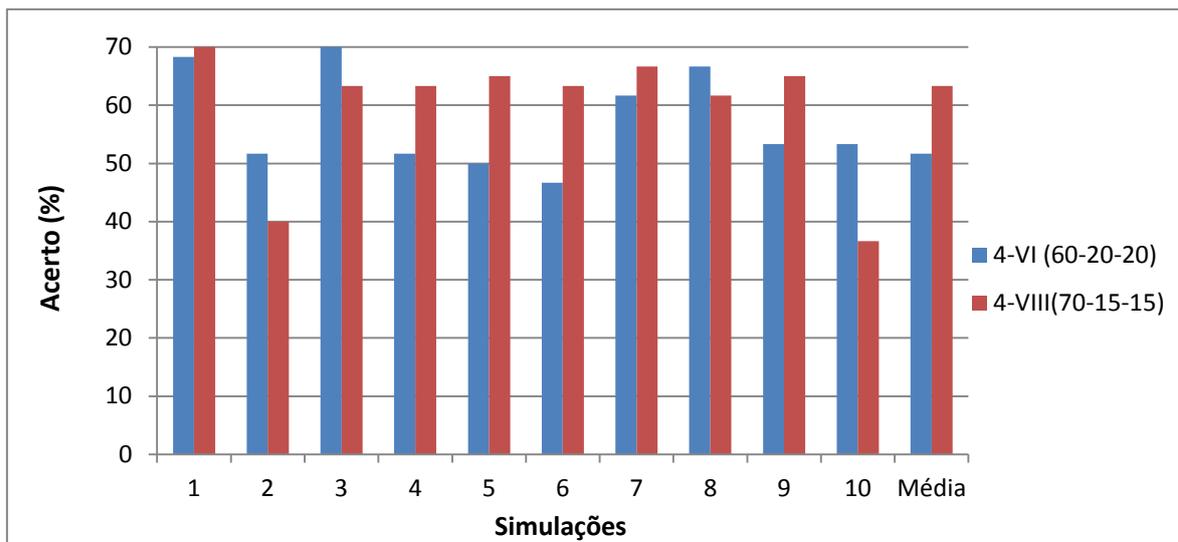


Figura 79 – Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 4 para RH1.

Analisando os arranjos selecionados, verifica-se que o arranjo 4-VIII apresenta resultados melhores podendo chegar a 70% de acerto e média das simulações acima de 60%, enquanto que o arranjo 4-VI tem valores abaixo de 40%.

Por fim, será analisado o desempenho das simulações realizadas com agrupamento 04 na RH2, cujas medidas de desempenho podem ser vistas nas Figuras 80 e 81.

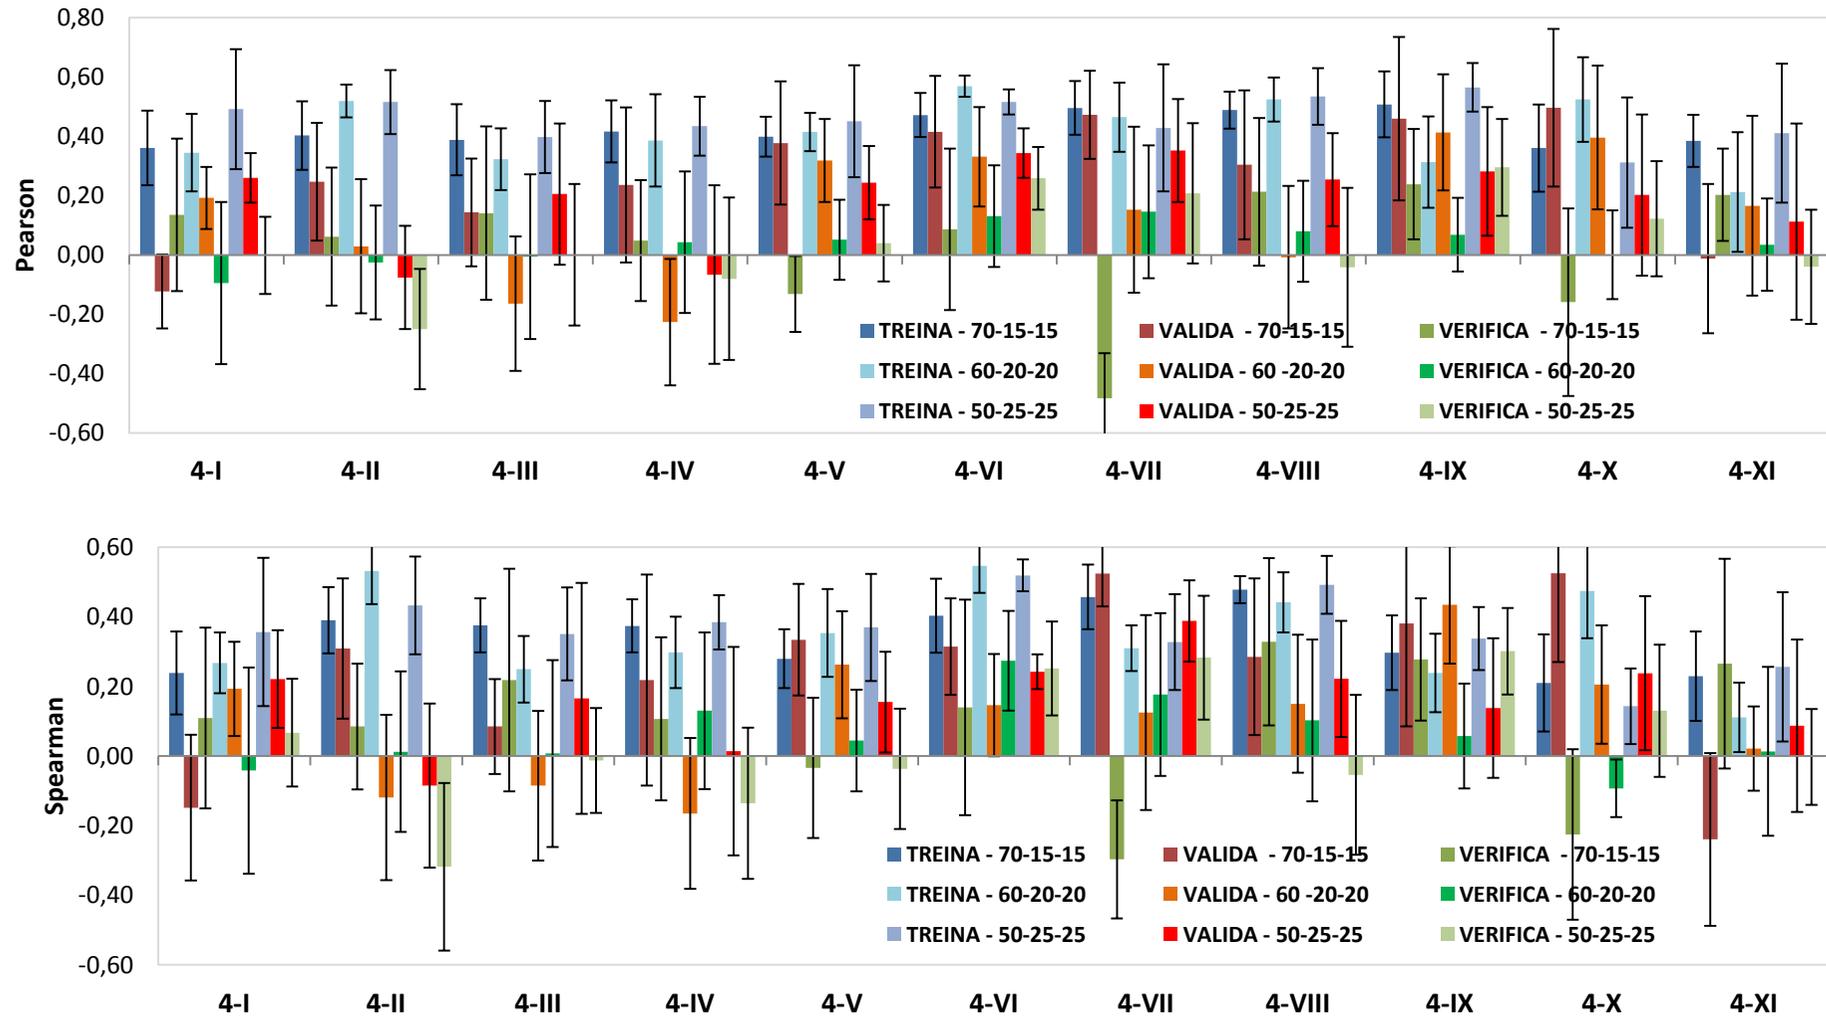


Figura 80- Medidas de Desempenho (Pearson e Spearman) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH2

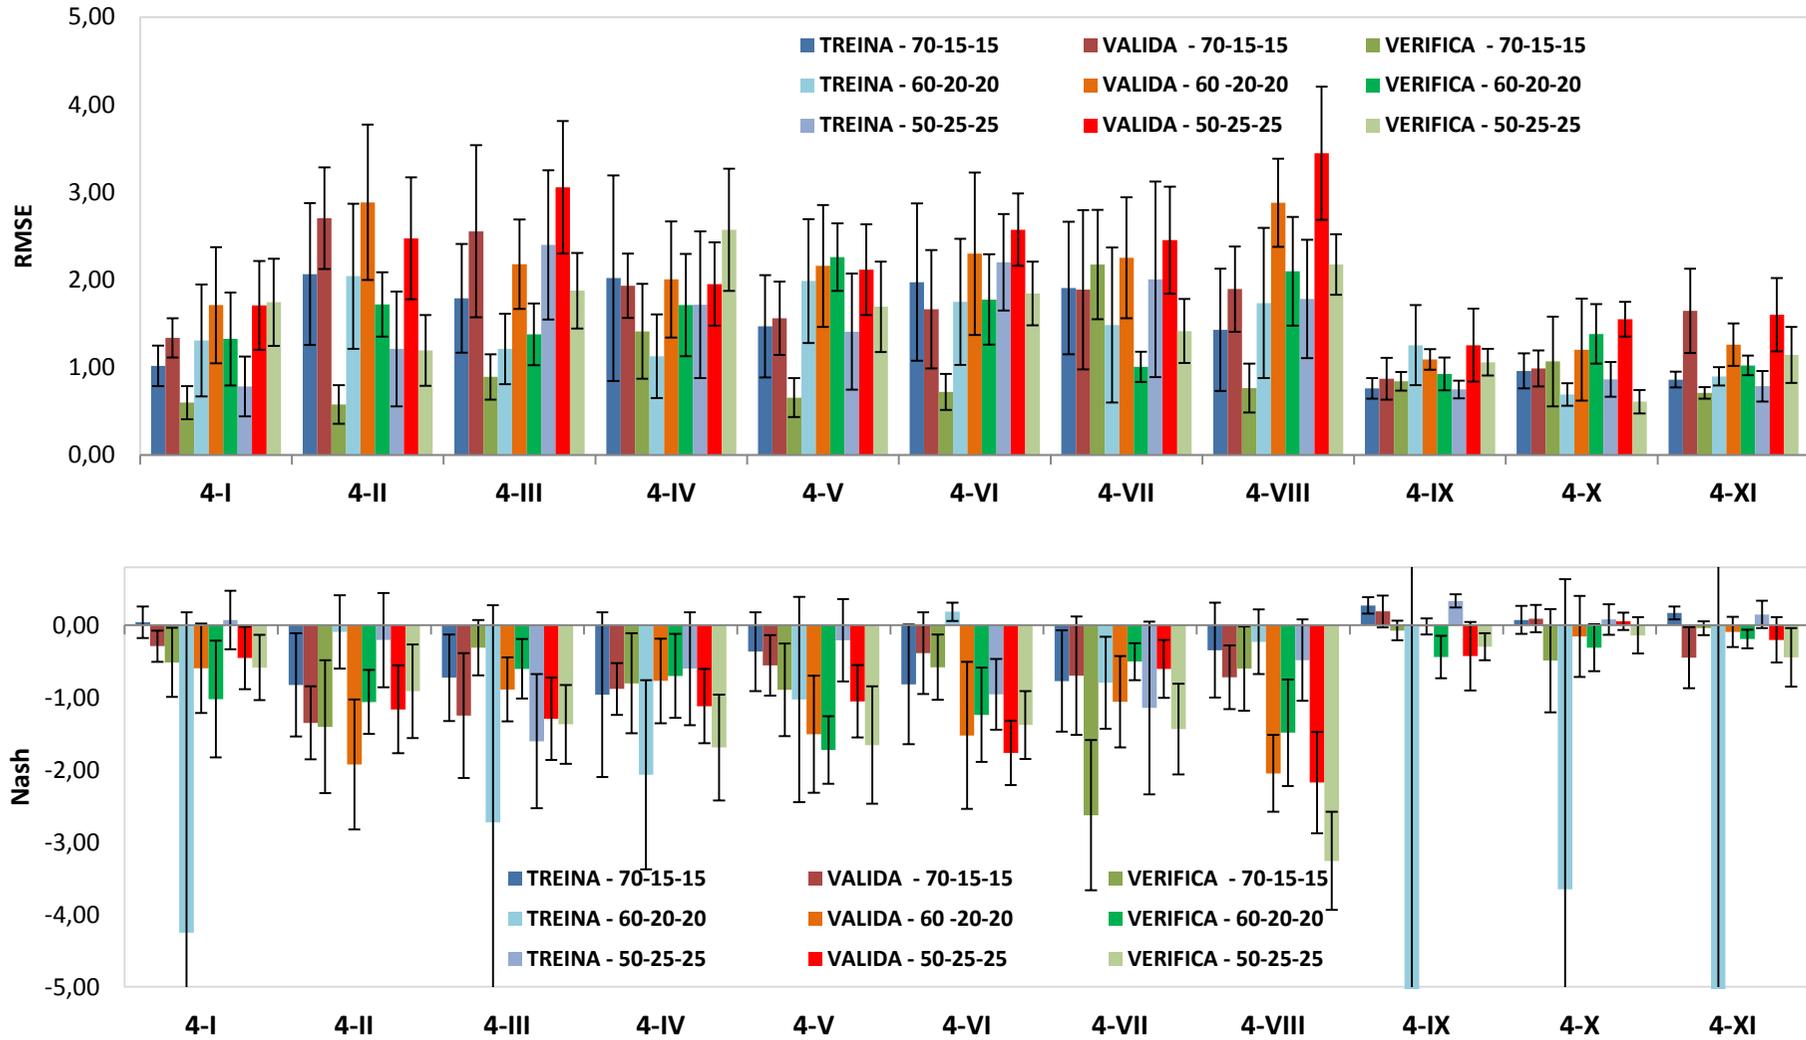


Figura 81- Medidas de Desempenho (RMSE e Nash) nos Conjuntos de Treinamento, Validação e Verificação Para o Agrupamento 04 na RH2

A Figura 81 mostra que os resultados das correlações de Pearson e Spearman aplicados à série gerados pelo agrupamento 04 a RH2 não são bons, estes apresentam alto grau de dispersão e de heterogeneidade em relação aos conjuntos de dados de treinamento, verificação e validação. Destaca-se apenas o arranjo 4-VI, que apresentou sempre valores positivos e um leve grau de estabilidade. Em compensação, os resultados do RMSE e coeficiente de Nash se coadunam no sentido de mostrar que os melhores resultados encontram-se no arranjo 4-IX, 4-X e 4-XI. Desse modo, procuraram-se, dentro dos arranjos citados, os melhores quando se analisa a série temporal de SPI gerada em relação a observada, os quais podem ser vistas na Figura 82.

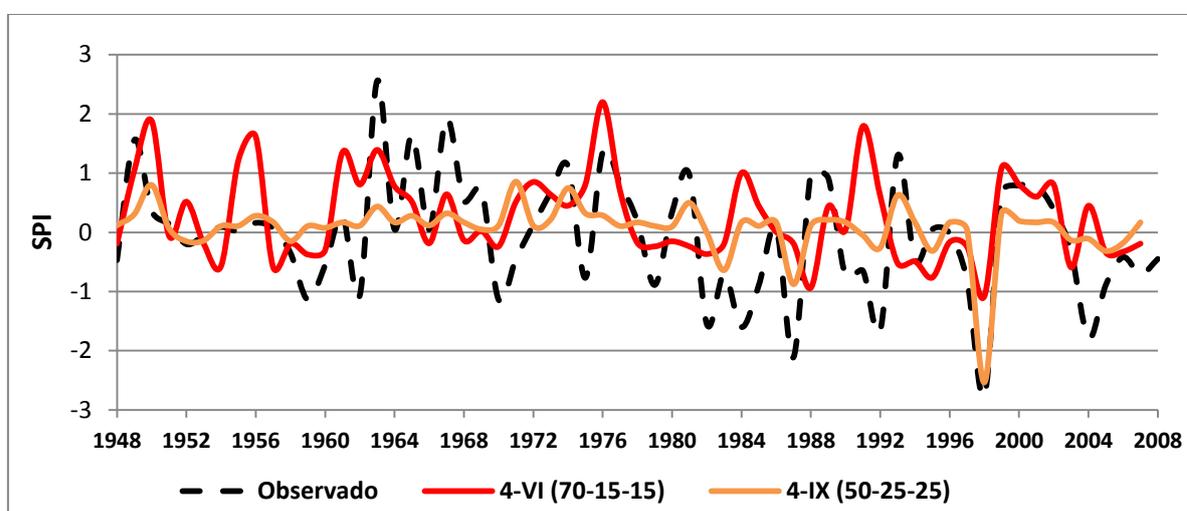


Figura 82 - Série Temporal do SPI para o Melhor Ajuste no Agrupamento 4 para RH2.

Analisando-se a Figura 82, tem-se que o arranjo 4-VI reproduziu as tendências de déficit/superávit de precipitação sem captar bem os picos; o arranjo 4-IX, por sua vez, conseguiu captar bem apenas o pico de 1998 além de retratar bem a série de 1948 a 1960 e a tendência geral de toda a série. Complementarmente, apresenta-se, na Figura 83, o nível de acerto dos arranjos 4-VI e 4-IX.

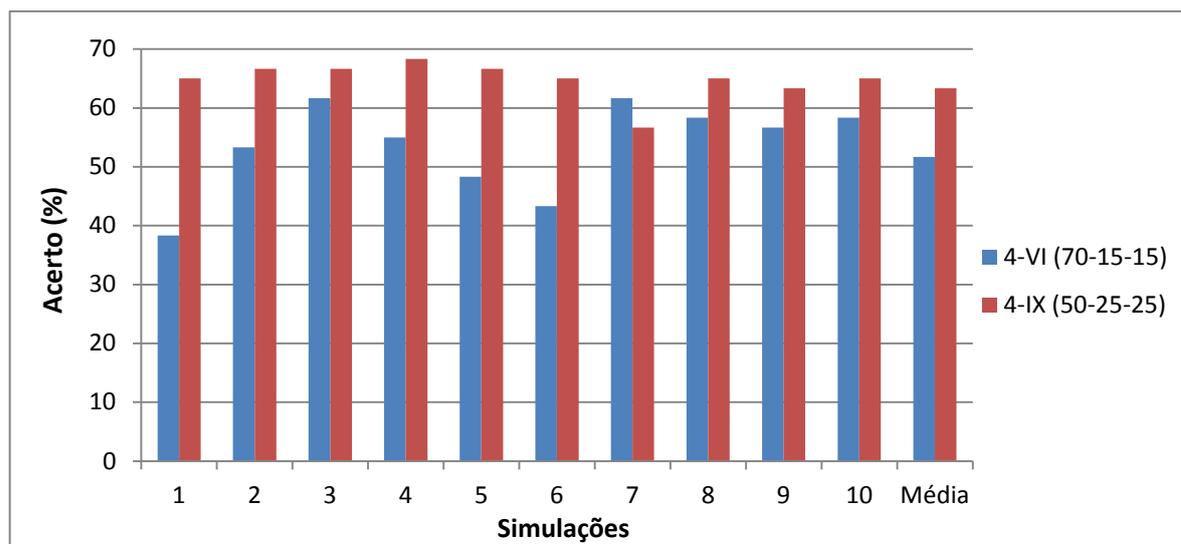


Figura 83- Índice de Acerto das Categorias de Secas para o Melhor Ajuste no Agrupamento 4 para RH2.

Analisando os arranjos selecionados, verifica-se que o arranjo 4-IX apresenta resultados melhores podendo ultrapassar a 60% de acerto, enquanto que o arranjo 4-VI tem valores abaixo de 40%.

5.4.3 Considerações sobre Aplicação da RNA

Reconhecimento dos Padrões

A variabilidade decadal mostrou uma maior potencialidade de predição, haja vista que os resultados das simulações realizadas para os diferentes arranjos foram mais estáveis. Para análise interanual, destacaram-se os índices Niño 3.4 (Pacífico) e variações do AMM com valores de correlações máximos próximos de 0,7. Destaca-se também que os resultados entre as duas porções da área de estudo são similares. Em relação à variação decadal, na região litorânea, apresentou maior capacidade para reconhecimento dos padrões de precipitação, apresentando 4 arranjos satisfatórios, enquanto na região semiárida, apenas uma configuração. De modo geral, os valores de correlação para esta análise são maiores do que a análise interanual, superando o valor de 0,7. Por fim, os resultados sugerem que a variabilidade decadal é regida com maior influência pelo Oceano Atlântico, enquanto que a variabilidade interanual de maneira mais tímida é governada pelo Oceano Pacífico.

Previsão

Para melhor visualização dos resultados encontrados na etapa da previsão, a Tabela 14 traz os melhores arranjos selecionados à luz das medidas de desempenhos utilizadas e a partir da análise do comportamento temporal da série.

Tabela 14 – Índices Climáticos Utilizados nos Modelos de Previsão com Melhores Resultados

	Arranjo	PDO	AMO	AMM_wind	AMM_sst	Niño 3.4
RH1	1-I	Maio	Junho	Abril		
	1-V	Maio	Junho		Abril	
	1-X	Maio	Junho			Maio
	2-V	Junho	Junho		Abril	
	2-VIII	Junho	Junho		Abril	Junho
	2-IX	Junho	Junho			Abril
	3-VI	Maio	Julho		Abril	Abril
	3-IX	Maio	Julho			Abril
	3-X	Maio	Julho			Maio
	4-VI	Junho	Julho		Abril	Abril
4-VIII	Junho	Julho		Abril	Junho	
RH2	1-VI	Maio	Junho		Abril	Abril
	1-VII	Maio	Junho		Abril	Maio
	1-IX	Maio	Junho			Abril
	2-III	Junho	Junho	Abril		Maio
	2-IX	Junho	Junho			Abril
	2-X	Junho	Junho			Maio
	3-V	Maio	Julho		Abril	
	3-VII	Maio	Julho		Abril	Maio
	3-VIII	Maio	Julho		Abril	Junho
	4-VI	Junho	Julho		Abril	Abril
4-IX	Junho	Julho			Abril	

Verifica-se, então, que a componente meridional dos campos de vento no Atlântico não se mostrou com grande potencialidade para ambas as sub-regiões da área de estudo. Destacam-se, mais uma vez, as condições oceânicas e atmosféricas do mês abril, tanto para o Atlântico como o Pacífico. Por fim, observa-se ainda que a utilização de AMO de julho (Agrupamento 03 e 04) apresentou os piores resultados dentro dos arranjos selecionados, sobretudo na identificação da classe de seca que obteve valores menores que 40%.

De modo geral, os modelos propostos conseguiram retratar os picos negativos no comportamento pluvial da região para o período seco, principalmente após ano de 1987. Os

resultados apontam que após esta data os eventos anormais se tornaram cada vez mais comuns e com maior magnitude, certamente decorrente da teleconexão criada pela fase do PDO, alterando os regimes de Niños. A combinação desses fenômenos (a partir dos índices climáticos), nos modelos propostos, creditou melhores respostas a partir da segunda metade da década de 1980. Analisando-se a série como todo, observa-se que os valores gerados seguiram tendência de aumento/diminuição da precipitação no período seco, apesar de não ser possível atingir as classes observadas, haja vista que melhores modelos possuem um nível de acerto pouco maior que 70%. Esta tendência possui caráter decadal ou superior e foi representada graças ao uso dos índices PDO e AMO.

6 CONCLUSÕES E RECOMENDAÇÕES

Este estudo trouxe uma gama de ferramentas com intuito de subsidiar a previsão do índice de seca (SPI) no trimestre seco das Bacias do rio Paraíba do Meio e Mundaú. A análise multivariada mostrou que a maior porção da variabilidade de precipitação no período seco pode ser explicada pelas características fisiográficas da região e fenômenos de pequenas escalas meteorológicas. Além disso, espacialmente, foi possível encontrar dois comportamentos distintos do regime de precipitação na estação seca que corrobora as características climáticas da área de estudo.

A utilização do SPI para análise dos eventos de chuva mostrou que nas últimas décadas os eventos com déficit de precipitação, no trimestre seco, se tornaram cada vez mais frequentes e intensos, sobretudo após o ano de 1978, para a porção semiárida das bacias, o que pode indicar uma teleconexão climática com a Oscilação Decenal do Pacífico que apresentou sua fase quente marcada por maiores episódios de El Niño.

As correlações não-lineares (Spearman) não conseguiram captar a relação dos índices climáticos com o SPI, sendo necessário utilizar método mais robusto de correlação (wavelets) entre séries. Assim, foi possível encontrar escalas dominantes da ordem decadal e interanual para a porção litorânea da região de estudo o que sugere a influência de fenômenos globais com ENSO, Dipolo do Atlântico e Manchas solares. Enquanto que a região semiárida apresentou apenas um ciclo dominante na ordem de 6 a 8 anos. Informações que podem ser incorporadas no dimensionamento ótimo de estruturas de armazenamento e aproveitamento das águas de chuva, pois dependem da variabilidade intranual da precipitação, haja vista que foi notado que o ciclo de eventos extremos, nos períodos secos, é menor.

Ainda na busca pelas relações de causa-efeito dos fenômenos globais com anomalias na precipitação, a WTC e XWT foram utilizadas e destacando-se:

- Que tanto as condições do Oceano Pacífico quanto Atlântico apresentam correlações significativas com a precipitação no trimestre seco;
- Os índices climáticos de abril apresentaram-se como potencial preditor para precipitação, sobretudo na região semiárida;
- A tendência de diminuição dos ciclos de extremos, entre as décadas de 1970 a 1990, sugerindo a ocorrência mais frequentes secas e enchentes, neste período.
- A ocorrência de escalas dominantes na ordem de 10 a 16 anos, corroborando com fenômenos decadal, como a própria PDO.

Nessa linha, encontraram-se correlações de Spearman mais significativas da componente decadal do SPI com índices climáticos.

A aplicação do modelo de RNA para reconhecimento de padrões mostrou que há uma maior potencialidade na predição das componentes decadal da precipitação da estação seca, com redes estáveis e coeficientes de desempenho próximos de 0,8. Os resultados para análise interanual se mostraram tímidos e mais uniformes para toda área. Por outro lado, na análise decadal, a região litorânea se destacou em relação à porção semiárida. Ainda sim, foi possível observar que a variabilidade decadal é governada, predominantemente, pelo Oceano Atlântico, e a variabilidade interanual, pelo Pacífico. Destaca-se mais uma vez o mês de abril com grande potencial para explicar a variação da chuva no trimestre de outubro a dezembro.

Em relação aos modelos de previsão, encontraram-se dificuldades para construir um arranjo estável e com resultados satisfatórios, certamente devido à precipitação na época do ano estudado ser governada por fenômenos globais locais. No entanto, foi possível extrair algumas informações, como:

- A importância do mês de abril para a previsão;
- Maior influência do gradiente meridional de temperatura do Atlântico em relação aos campos de vento;
- Maior previsibilidade dos eventos de déficit hídrico após o ano de 1987, certamente devido o grau de associação do PDO (fase quente) com a variabilidade decadal da precipitação na região de estudo;
- Níveis de acerto de classes de seca próximo a 70% com defasagem de 4 meses o que pode subsidiar a gestão dos recursos hídricos.

Os resultados das ferramentas utilizadas coadunam para a proposição que a variabilidade decadal ou maior da precipitação na estação seca é regida por fenômenos globais, conforme pode ser visto nas diferentes etapas:

- Sabendo que a maior parcela de variabilidade da série de SPI é interanual, a Análise Componente Principal mostrou que a maior explicação da precipitação é oriunda de fenômenos locais meteorológicos e devido às características físicas locais;
- Correlação de Spearman com as séries históricas da precipitação não foram captadas enquanto que com a sua componente decadal houve relações significativas;

- Melhores resultados do modelo RNA que se apresentaram para análise decadal, sobretudo para região litorânea, apesar de ficar claro que a PDO tem influência na região semiárida.

Assim, acredita-se que o objetivo foi atingido e que este trabalho pode criar uma nova perspectiva em relação ao entendimento/previsão de secas a partir da investigação da estação seca, haja vista que os resultados são semelhantes para os períodos distintos do ano. Ademais, alguns caminhos ainda podem ser investigados no intuito de encontrar resultados melhores, os quais:

- Procurar relações da precipitação na estação seca com a estação chuvosa da região de estudo.
- Avaliar os efeitos do ENOS sob diferentes padrões como ENOS canônicos e Modoki;
- Investigar o efeito combinado ENOS e PDO, na variabilidade da precipitação da estação seca da área de estudo;
- Realizar regressões múltiplas com índices climáticos analisados e outros que não utilizados neste trabalho;
- Utilizar diferentes arquiteturas e topologias de Rede Neural Artificial na procura de modelo mais eficaz, ou ainda, inserir variáveis que representem os fenômenos locais;
- Testar outros métodos de inteligência artificial ou *machine learning*, como: lógica fuzzy, suporte vetor regional, *Reservoir computing* entre outros.

REFERÊNCIAS

- AGHAKOUCHAK, A. A multivariate approach for persistence-based drought prediction: Application to the 2010–2011 East Africa drought, Center for Hydrometeorology and Remote Sensing, Department of Civil and Environmental Engineering, University of California, Irvine, E4130 Engineering Gateway, Irvine, CA 92697-2175, USA *Journal of Hydrology* 526 27–135, 2015.
- AGNEW, C. T. Using the SPI to identify drought. *Q13 Drought Netw. News* 12, 6–12, 2000.
- ALBURQUERQUE, T. M. A. Estudos do Processo de Gestão de Secas: Aplicação no Estado do Rio Grande do Sul. Tese de Doutorado submetido ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul - UFRGS, 2010.
- ALEXANDRE, A. M. B. Previsão de vazões mensais para o sistema interligado Nacional utilizando informações climáticas, Universidade federal do Ceará. Centro de Tecnologia Departamento De Engenharia Hidráulica e Ambiental - Programa de pós-graduação em engenharia civil, Fortaleza-CE, 2012.
- ALVES, A. L. Efeito de Teleconexões Climáticas na Variabilidade Espaço-Temporal dos Índices de Disponibilidade Hídrica em Uma Bacia Hidrográfica sob Transição Climática (Tropical/Semiárido). Dissertação Apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento – PPGRHS da Universidade Federal de Alagoas – UFAL. 2016.
- AMORIM, A. C. B.; CHAVES, R. R.; SILVA, C. M. S. Influence of the tropical Atlantic Ocean's sea surface temperature in the eastern northeast Brazil precipitation. *Atmos. Clim. Sci.* 4,874 –883. doi:10.4236/acs.2014.45077, 2014.
- AMORIM, A. C. B.; Temperatura da superfície do mar do atlântico tropical e a precipitação do leste do nordeste do Brasil. XII Simpósio de Recursos Hídricos do Nordeste, 2014a.
- ANDREOLI, R.V.; KAYANO, M. T.; GUEDES, R. L.; OYAMA, M. D.; ALVES, M. A. S. A Influência da temperatura da superfície do mar dos Oceanos Pacífico e Atlântico na variabilidade de precipitação em Fortaleza, *Revista Brasileira de Meteorologia*, v.19, n.3, 337-344, 2004.
- ANDREOLI, R.V.; KAYANO, M.T. Multi-scale variability of the sea surface temperature in the Tropical Atlantic, *Journal of Geophysical Research*, 109, C05009, 2004.
- ANDREOLI, R.V.; KAYANO, M. T. Enso-Related Rainfall Anomalies in South America and Associated Circulation Features During Warm and Cold Pacific Decadal Oscillation Regimes, *International Journal of Climatology*. *Internacional Journal Climatology*, 25: 2017–2030, 2005.
- ANDREOLI, R.V.; KAYANO, M.T. Tropical Pacific and South Atlantic effects on rainfall variability over northeast Brazil, *International Journal of Climatology*, 26: 1895-1912, 2006.
- ARAGÃO, J. O. R. O impacto do ENSO e do dipolo do Atlântico no nordeste do Brasil. *Bulletin Institut Français Études Andines*, v.27 n.3, p.839-844, 1998.

ASCE. Artificial neural networks in hydrology I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115–123. doi:10.1061/(ASCE)1084-0699(2000)5:2(115), 2000.

AUSSEM, A.; MURTAGH F. Combining Neural Network Forecasts on Wavelet-transformed Time Series, *Connection Science*, 9:1, 113-122, DOI: 10.1080/095400997116766, 1997.

BARRA, T. S.; COSTA, J. M.; RAO, T. V. R.; SEDIYAMA, G. C.; FERREIRA, W. P. M.; DANTAS NETO, F. S. Caracterização Climatológica da Severidade das Secas do Estado do Ceará – Brasil. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.6, n.2, p.266-272. Campina Grande, PB, 2002.

BARRETO, A. B.; ARAGÃO, M. R. da S.; CORREIA, M. de F. Análise de ondeletas para precipitação de Salvador – BA, XII Simpósio De Recursos Hídricos Do Nordeste. Natal-RN, 2014.

BARROUCHE, J-M; SAPORTA G. Análise de Dados. Rio de Janeiro: Zahar, 117p. 1982.

BELAYNEH A.; ADAMOWSKI. J.; KHALIL, B.; OZGA-ZIELINSKI, B. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *J. Mt. Sci.* (6): 1593-1605. doi: 10.1007/s11629-014-3020-6. 2014

BILLIB, M. H. A.; FREITAS, M. A. S. Drought Forecasting and Management for Northeast-Brazil by Statistics, Neuro-fuzzy Systems Analysis and Stochastic Simulation. In: *Conference on Water Resources & Environment Research: towards the 21st Century*, 1996. Kyoto: IAHS Publication, v. 1. p. 1-1, 1996.

BRASIL. Ministério do Meio Ambiente, Ministério da Integração Nacional. Índice de vulnerabilidade aos desastres naturais relacionados às secas no contexto da mudança do clima, WWF-Brasil. Brasília – DF, 2017. ISBN: 978-85-7738-312-2. 2017.

BRAVO, J. M. Subsídios à operação de reservatórios baseada na previsão de variáveis hidrológicas. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) - Universidade Federal do Rio Grande do Sul. Instituto de Pesquisas Hidráulicas, Porto Alegre, 2009. Disponível em: <<http://hdl.handle.net/10183/26916>>. Acesso em: 12 jan. 2015.

BRICIU, A.; MIHĂILĂ, D. Wavelet analysis of some rivers in SE Europe and selected climate indices. *Environ Monit Assess* DOI 10.1007/s10661-014-3853-z, 2014.

CAMPOS, J. N. B. Paradigms and public policies on drought in northeast Brazil: a historical perspective. *Environ. Manage.* 55, 1052–1063. doi: 10.1007/s00267-015-0444-x, 2015.

CANCELLIERE, A.; DI MAURO, G.; BONACCORSO, B; ROSSI, G. et al. Drought forecasting using the Standardized Precipitation Index. *Water Resour Manage.* 21:801–819. doi: 10.1007/s11269-006-9062-y. 2007.

CHIANG, J. C. H.; VIMONT, D. J. Analogous Pacific and Atlantic meridional modes of tropical atmosphere - ocean variability. *J. Clim.* 17, 4143–4158. doi:10.1175/JCLI4953.1, 2004.

CHOUBIN B.; KHALIGHI-SIGAROODI, S.; AHMAD, S.; ATTAROD, P. Drought Forecasting in a Semi-arid Watershed Using Climate Signals: a Neuro-fuzzy Modeling Approach Mt. Sci. (2014) 11(6): 1593-1605. DOI: 10.1007/s11629-014-3020-6

COLLISCHONN, W. Simulação hidrológica de grandes bacias. Instituto de Pesquisas Hidráulicas - Universidade Federal do Rio Grande do Sul. Porto Alegre, p. 270. 2001. Tese submetida ao Programa de Pós Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental para obtenção do título de Doutor em Engenharia.

CORRAR, L. J.; PAULO, E.; FILHO, J. M. D. Análise Multivariada: para os cursos de administração, ciências contábeis e economia. São Paulo: Atlas, 2007.

CORDERY, I., MCCALL, M. A model for forecasting drought from teleconnections. Water Resources Research, Vol. 36, No. 3, Pages 763-768, March 2000

COSTA, D. D. Previsão Hidrológica De Longo Prazo Na Bacia Do Rio Mundaú Baseada Em Componentes Climáticas E Hidrológicas. Dissertação Apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento – PPGRHS da Universidade Federal de Alagoas – UFAL. 2014.

COSTA, D. D.; PEREIRA, T. A. S.; FRAGOSO JR, C. R.; MADANI, K.; UVO, C. B. Understanding Drought Dynamics during Dry Season in Eastern Northeast Brazil. *Frontiers Earth in Science*. published: June 2016 doi: 10.3389/feart.2016.00069

COTEC CONSULTORIA TÉCNICA LTDA. Plano Diretor de Recursos Hídricos da Bacia do Rio Mundaú. Governo do Estado de Pernambuco - Secretaria de Recursos Hídricos. [S.l.]. 1999.

CUNHA, S. B. da. Geomorfologia fluvial. In: GUERRA, A, J, T.; _____. (Org.). Geomorfologia: uma atualização de bases e conceitos 2. ed. Rio de Janeiro: Bertrand Brasil, 1995. p. 45-50.

CUNHA, A. P. M.; ALVALÁ, R. C.; NOBRE, C. A.; CARVALHO, M. A. Monitoring vegetative drought dynamics in the Brazilian semiarid region, *Agric. For. Meteorol.* 214-215, 494–505. doi: 10.1016/j.agrformet.2015.09.010, 2015.

CZAJA, A.; FRANKIGNOUL, C. Influence of the North Atlantic SST on the atmospheric circulation. *Geophysical Research Letters*, Laboratoire d'oceanographie Dynamique et de Climatologie (LODYC), Paris, France, VOL. 26, NO. 19, Pages 2969-2972, October 1, 1999

CZAJA, A.; FRANKIGNOUL, C. Observed Impact of Atlantic SST Anomalies on the North Atlantic Oscillation. *Journal of climate American Meteorological Society Department of Earth, Atmospheric, and Planetary Sciences, Massachusetts Institute of Technology, Cambridge, Massachusetts, Volume 15q*, 2002.

CZAJA, ARNAUD; VAN DER VAART, P.; MARSHALL, J. A Diagnostic Study of the Role of Remote Forcing in Tropical Atlantic Variability. 3280 *Journal of climate American Meteorological Society, VOLUME 15q*, 2002.

DA SILVA, D. F. Análise De Aspectos Climatológicos, Agroeconômicos, Ambientais e de Seus Efeitos Sobre a Bacia Hidrográfica Do Rio Mundaú (AL e PE). Tese de Doutorado

(Programa de Doutorado Temático em Recursos Naturais - PDRN) – Universidade Federal de Campina Grande, Paraíba - Brasil, 2009.

DA SILVA, D. F.; SOUSA, F. de A. S. de; Kayano, M. T. Escalas Temporais Da Variabilidade Pluviométrica Na Bacia Hidrográfica Do Rio Mundaú. *Revista Brasileira de Meteorologia (Impresso)*, v. 25, p. 147-155, 2010.

DA SILVA, D. F. Aplicação das análises de ondeletas para previsão climática e na prevenção de risco climático no Estado do Ceará. ISBN 9789899681019. In: Luciano Lourenço e Manuel Mateus. (Org.). Riscos naturais, antrópicos e mistos: Homenagem ao Prof Dr Fernando Rebelo. 1ed.Coimbra-Portugal: universidade de Coimbra, 2013, v. 1, p. 235-250

DA SILVA, D. F. Detecção de Áreas Hidroclimáticas Homogêneas Na Bacia Hidrográfica do Rio São Francisco. In: XIX Congresso Brasileiro de Meteorologia. João Pessoa- PB, 2016.

DA SILVA, D. F. Aplicação de Análises de Ondaletas para Detecção de Ciclos e Extremos Pluviométricos no Leste do Nordeste do Brasil. *Revista Brasileira de Meteorologia (Impresso)*, v. 32, p. 187-198. *Revista Brasileira de Meteorologia*, v. 32, n. 2, 187-198, 2017. DOI: <http://dx.doi.org/10.1590/0102-77863220002>

DAWSON, C. W.; WILBY, R. L. Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, 25(1), 80–108, 2001.

DIMA, M.; LOHMANN, G. 2007. A hemispheric mechanism for the Atlantic Multidecadal Oscillation. *Journal of Climate*, v. 20, p. 2706-2719.

DUAN, Q.; SOROOSHIAN, S; GUPTA, V. Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*. v. 28(4), p. 1015-1031.

ENFIELD, D. B; MESTAS-NUFIEZ, A. M.; TRIMBLE, P. J. The Atlantic multidecadal oscillation and its relation to rainfall and river flows in the continental US, *Geophys. Res. Lett.*, 28, 2077– 2080, 2001.

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*, Vol. 1, No 1, 2005.

FETTER, R.; OLIVEIRA, C. H. de. A identificação de áreas homogêneas para caracterização das chuvas no semiárido brasileiro. *Revista Geonorte, Edição Especial 2, V.1, N.5*, p.271 – 282, 2012

FRAGOSO JR., C. R.; PEDROSA, V. D. A.; SOUZA, V. C. B. D. Reflexões sobre a cheia de junho de 2010 nas bacias do rio Mundaú e Paraíba. X Simpósio Regional Brasileiro de Recursos Hídricos. Fortaleza/CE. 2010.

FOLTZ, G. R.; MCPHADEN, M. J.; LUMPKIN, R. A Strong Atlantic Meridional Mode Event in 2009: The Role of Mixed, Layer Dynamics, *Journal of Climate*, DOI: 10.1175/JCLI-D-11-00150.1. 2012

FOLTZ, G. R.; MCPHADEN, M. J. Interaction between the Atlantic meridional and Niño modes, *Geophysical Research Letters*, VOL. 37, L18604, doi:10.1029/2010GL044001, 2010

FREITAS, M. A. de S. Que Venha a Seca: modelos para gestão de recursos hídricos em regiões semiáridas. ISBN: 8578106601 ISBN-13: 9788578106607 Brochura, 1ª Edição – 2010.

GAMA, W. M. Impactos das mudanças climáticas na resposta hidrológica da bacia hidrográfica do rio Paraíba do Meio (AL/PE). Dissertação Apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento – PPGRHS da Universidade Federal de Alagoas – UFAL. 2011

GANGULI, P.; REDDY, M. J. Ensemble prediction of regional droughts using climate inputs and the SVM–copula approach. *Hydrol. Process.* 28, 4989–5009 (2014)

GARRISON, T. Fundamentos da Oceanografia. São Paulo- Cengage Learning Tradução da quarta edição de "Essentials of oceanography". ISBN 978-85-221-0677-6 2010.

GIANNINI, A.; SARAVANAN, R.; CHANG, P. The preconditioning role of Tropical Atlantic Variability in the Development of the ENSO teleconnection. *Climate Dynamics* (2004) 22: 839–855. doi: 10.1007/s00382-004-0420-2

GOLIAN, S. Trends in meteorological and agricultural droughts in Iran, *Theor Appl Climatol* 119:679–688 doi: 10.1007/s00704-014-1139-6, 2015.

GOMES, E. P; BLANCO, C. J. C.; PESSOA, F. C. Análise de agrupamento para identificação de regiões hidrológicamente homogêneas na Amazônia, XX Simpósio Brasileiro de Recursos Hídricos, 2013.

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

GONG, D.; WANG, S. Definition of Antarctic Oscillation index. *Geophysical Research Letters*, v. 26, p. 459-462, 1999.

GOOSSE H.; BARRIAT, P.Y.; LEFEBVRE, W.; LOUTRE, M.F.; ZUNZ, V. Introduction to climate dynamics and climate modelling - <http://www.climate.be/textbook> 109 Chapter 5. Brief history of climate: causes and mechanisms, 2010

GREATBATCH, R. J. The North Atlantic Oscillation, *Stochastic Environmental Research and Risk Assessment* 14, 213-242, 2000.

GRINSTAD, A.; MOORE, J. C.; JEVREJEVA, S. Application of the cross wavelets transform and wavelet coherence to geophysical time series. *Non Linear Process in Geophysics. Nonlinear Processes in Geophysics* (2004) 11: 561–566. SRef-ID: 1607-7946/npg/2004-11-561.

GUEDES, R. V. de S.; LIMA, F. J. L.; AMANAJAS, J. C.; BRAGA, C. C. Análise em componentes principais da precipitação pluvial no estado do Piauí e agrupamento pelo Método de ward, *Revista de Geografia. Recife: UFPE – DCG/NAPA*, v. 27, n. 1, jan/mar. 2010.

GUEDES, R. V. de S.; MACEDO, M. J. H. ; SOUZA, F. A. S. Análise espacial de eventos de secas com base no índice padronizado de precipitação e análise de agrupamento *Revista*

Brasileira de Ciências Ambientais – Número 23 – Março de 2012 ISSN Impresso 1808-4524 / ISSN Eletrônico: 2176-9478 55

GUEDES, R. V. de S. Análise e previsão de eventos críticos de precipitação com base no SPI e em redes neurais artificiais para o estado de Pernambuco. Tese de Doutorado (Programa de Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Paraíba - Brasil, 2016.

GURGEL, V. C. Aplicação de técnicas wavelets em análise de séries temporais para detecção de correlações, Universidade Federal Rural do Semiárido departamento de ciências exatas, tecnológica e humanas – campus Angicos-RN, 2013.

GUTTMAN, N. B., 1998. Comparing the palmer drought index and the standardized precipitation index. *J. Am. Water Resour. Assoc.* 34 (1), 113–121.

HAO, Z.; AGHAKOUCHAK, A. Multivariate Standardized Drought Index: Aparametric multi-index model, Department of Civil and Environmental Engineering, University of California, Irvine, CA, USA, *Advances in Water Resources* 57 12–18, 2013.

HARTER, I. B.; CHAPA, S.R. Análise de Precipitação em Pelotas Utilizando Transformada de Wavelet Morlet. In: XIII Congresso brasileiro de Meteorologia, 2004, Fortaleza. *Meteorologia e o Desenvolvimento Sustentável*, p. 97, 2004.

HASTENRATH, S. Exploring the climate problems of Brazil's Nordeste: a review. *Climatic Change*, v. 112, pp 243–251, 2011.

HARE, S. R.; MANTUA, N. J. Empirical evidence for North Pacific regime shifts in 1977 and 1989, *Prog. Oceanogr.* 47, 103-145, 2000.

HURRELL, J. W. (1995). Decadal trends in the North Atlantic Oscillation: regional temperatures and precipitation. *Science*, 269, 676–679. DOI: 10.1126/ science.269.5224.676.

IBGE. Instituto Brasileiro de Geografia e Estatística. Características Gerais da População, Religião e Pessoas Com Deficiência. Rio de Janeiro: IBGE, Censo demográfico 2010.

JÁCOMO, C. A. Análise de agrupamento nos dados pluviométricos do oeste do estado de São Paulo. *Anais do III Simpósio Brasileiro de Geomática, Presidente Prudente - SP, 25-27, v.2.* p. 346-347, ISSN 1981-6251, 2012.

JEVREJEVA, S., MOORE, J. C.; GRINSTED, A. Influence of the Arctic Oscillation and El Niño-Southern Oscillation (ENSO) on ice conditions in the Baltic Sea: The wavelet approach, *J. Geophys. Res.*, 108(D21), 4677, doi:10.1029/2003JD003417, 2003.

KANE, R. P. Rainfall characteristics in different parts of Northeast Brazil. *Revista Brasileira de Geofísica.*, vol 11(1): 7-22, 1997.

KAYANO, M. T; RAO, V.B.; ANDREOLI, R. V. A review of short-term climate variability mechanisms. *Science direct*, v.35, p.843-851, 2005.

KIEM, A. S.; FRANKS, S. W. On the identification of ENSO-induced rainfall and runoff variability: a comparison of methods and indices. *Hydrological Sciences Journal*, 46:5, 715-727, DOI: 10.1080/02626660109492866. 2001

KIM, T.; VALDÉS, J. B. Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural. *Journal Of Hydrologic Engineering* November/December 2003 / 319. 2006.

KINGSTON, G. B.; MAIER, H.R.; LAMBERT, M. F. Calibration and validation of neural networks to ensure physically plausible hydrological modeling. *Journal of Hydrology*, v. 314, p.158-176. (2005).

KNIGHT, J. R.; FOLLAND, C. K.; SCAIFE, A. A. Climate impacts of the Atlantic Multidecadal Oscillation. *Geophys. Res. Lett.* 33:L17706. Bibcode: 2006 Geo RL.. 3317706K. doi:10.1029/2006GL026242. 2006.

KOSSIN, J. P.; VIMONT, D. J. A more general framework for understanding atlantic hurricane variability and trends. *Bull. Am. Meteorol. Soc.* 88,1767–1781.doi:10.1175/BAMS-88-11-17672004. 2007.

KROL, M., JAEGER, A.; BRONSTERT, A.; GÜNTNER, A. Integrated modelling of climate, water, soil, agricultural and socio-economic processes: a general introduction of the methodology and some exemplary results from the semi-arid north-east of Brazil. *J. Hydrol.* 328, 417–431. doi: :10.1016/j.jhydrol.2005.12.021

LABAT, D. Cross wavelet analysis of annual continental freshwater discharge and selected climate indices. *Journal of Hydrology.* 385 (2010) 269-278. doi:10.1016/j.jhydrol.2010.02.029

LABAT, D. Recent advances in wavelet analyses: Part 1.A review of concepts. *Journal of Hydrology* 314 (2005) 275–288

LIMA, F. J. L. de; AMANAJÁS, J. C.; GUEDES, R. V. de S.; DA SILVA, E. M. Análise de componente principal e de agrupamento para estudo de ventos para a geração de energia eólica na região do Ceará, Paraíba, Pernambuco e Rio Grande do Norte, Brasil, *Revista ambiente & água – Na Interdisciplinary Journal of Applied Science*: v. 5, n.2. doi: 10.4136/1980-993x, Issn = 1980-993x – 2010.

LOPES, F. Z. Relação entre o MEI (Multivariate Enso Index) e a precipitação pluvial no Estado do Rio Grande do Sul. *Dissertação de Mestrado. Universidade Federal de Pelotas – UFPel, 2006.*

MACEDO, M. J. H.; GUEDES, R. V. de S.; SOUSA, F. de A. S. de; DANTAS, F. R da C. Análise do índice padronizado de precipitação para o estado da paraíba, brasil. *Revista ambiente & água – Na Interdisciplinary Journal of Applied Science*: v. 1, n.1, DOI: 10.4136/AMBI-AGUA.130, Issn = 1980-993x – DOI: 10.4136/1980-993x, 2010.

MAIER, H.R.; DANDY, G. C. Neural networks for the predictions and forecasting of water resources variables: a review of modeling issues and applications. *Environm. Model. and Software*, v. 15, p. 101-124. (2000)

MANTUA, N. J.; HARE, S. R.; ZHANG, Y.; WALLACE, J. M.; FRANCIS, R. C.. A pacific decadal climate oscillation with impacts on salmon. *Bulletin of the American Meteorological Society*, 78, 1069–1079. doi:10.1175/1520-0477(1997)078<1069: APICO W>2.0.CO;2. 1997.

- MARAUN D., KURTHS J.. Cross wavelet analysis: significance testing and pitfalls. *Nonlinear Processes in Geophysics* 11: 505–514. SRef-ID: 1607-7946/npg/2004-11-505. 2004
- MASSEI, N., FOURNIER, M. Assessing the expression of large-scale climatic fluctuations in the hydrological variability of daily Seine river flow (France) between 1950 and 2008 using Hilbert–Huang Transform. *Journal of Hydrology*, 2012.
- MCINTOSH, P. C.; POOK, M. J.; RISBEY, J. S.; LISSON, S. N.; REBBECK, M. Seasonal climate forecasts for agriculture: Towards better understanding and value. *Field Crops Research* 104 (2007) 130–138.
- MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales, in *AMS 8th Conference of Applied, Climatology*, 179–184, 1993.
- MINOBE, S. A 50-70 year climatic oscillation over the North Pacific and North America. *Geophysical Research Letters*, v. 24, n. 6, p. 683-686, 1997.
- MISHRA, A.K.; DESAI, V. R. Drought forecasting using stochastic models. *J. Stoch. Environ. Res. Risk Assess.* 19, 326–339, 2005.
- MISHRA, A. K.; DESAI, V. R.; SINGH, V.P. Drought forecasting using a hybrid stochastic and neural network model. *J. Hydrologic Eng. ASCE* 12 (6), 626–638., 2007.
- MISHRA, A.K.; SINGH, V.P. A review of drought concepts. *J. Hydrol.* 391 (1–2), 202–216, 2010.
- MISHRA, A. K.; SINGH, V. P. Drought modeling – A review. Department of Biological and Agricultural Engineering, Department of Civil and Environmental Engineering, Texas A&M University, 2117 College Station, TX 77843, USA, *Journal of Hydrology* 403, 157–175, 2011.
- MO, KINGTSE C.; SCHEMM, J-K. E.; YOO, S-H. Influence of ENSO and the Atlantic Multidecadal Oscillation on Drought over the United States, *JOURNAL OF CLIMATE*, 2009
- MOLION, L. C. B. Aquecimento Global, El Niños, Manchas Solares, Vulcões e Oscilação Decadal do Pacífico. *Revista Climanálise*, 2005.
- MOLION, L. C. B. Aquecimento global: uma visão crítica. *Revista Brasileira de Climatologia*. agosto, p.08-24. 2008.
- MOLION, L. C. B.; BERNARDO, S. O. Uma revisão da dinâmica das chuvas no Nordeste Brasileiro. *Revista Brasileira Meteorologia*, 17(1), pp 1-10, 2002.
- MORID, S.; SMAKHTIN, V.; BAGHERZADEH, K. Drought forecasting using artificial neural networks and time series of drought indices. *International Journal of Climatology*, 27, 2103–2111. doi:10.1002/joc.1498. 2007.
- MOURA, G. B. de A. Relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos. *Revista Brasileira de Engenharia Agrícola e Ambiental*. Campina Grande, PB, UAEA/UFCG, v.13, n.4, p.462–469, 2009.

- MUÑOZ-DÍAZ, D.; RODRIGO, F. S. Spatio-temporal patterns of seasonal rainfall in Spain (1912-2000) using cluster and principal component analysis: comparison. *Ann. Geophys.* 22, 1435–1448. doi: 10.5194/angeo-22-14 35, 2004
- NAGHETTINI, M.; PINTO, É. J. de A. *Hidrologia estatística*, ISBN 978-85-7499-023-1, Belo Horizonte: CPRM, 552 p., 2007.
- NAN, S; LI, J. The relationship between summer precipitation in the Yangtze River valley and the previous Southern Hemisphere Annular Mode. *Geophysical Research Letters*, v. 30(24), 2266, 2003.
- NASCIMENTO JR, L. *As Chuvas no Paraná: Variabilidade interanual e decadal*. Trabalho de Conclusão de Curso de Geografia apresentado ao Departamento de Geociências da Universidade Estadual de Londrina, 2011.
- NASCIMENTO, F. A. de B. *Uso do sistema de apoio ao gerenciamento de recursos hídricos para análise da segurança hídrica na bacia do Rio Mundáu (AL/PE)*. Dissertação Apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento – PPGRHS da Universidade Federal de Alagoas – UFAL. 2016
- NETO, J. R., FRAGOSO, C. R. JR.; MALHADO, A.C.M.; LADLE, R. J. Spatiotemporal variability of chlorophyll-a in the coastal zone of northeastern Brazil. *Estuaries Coasts* 72–83. doi: 10.1007/s12237-014-9809-2. 2014.
- NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America. *J. Climate*, 9, 2464–2479, 1996.
- OLDEN, J. D; JACKSON, D. A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, v. 154, p 135-150.(2002).
- OLDEN, J.D.; JOY, M. K.; DEATH, R.G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling*, v. 178, p. 389–397.
- OLIVEIRA H. M. 2007. *Análise de Sinais para Engenheiros: Uma abordagem via Wavelets* Editora Brasport, RJ. Série SBrT/Brasport. 238p.
- OLSSON, J.; UVO, C.B.; FOSTER, K.; YANG, W.; SÖDLING, J.; GERMAN, J.; JOHANSSO, B. A multimodel system for spring flood forecasts, *Elforsk Rapport* 11:72, The Swedish Electrical Utilities R&D Company, Stockholm, 29 pp. 2011.
- PATRICOLA, C. M.; SARAVANAN, R. The Impact of the El Niño–Southern Oscillation and Atlantic Meridional Mode on Seasonal Atlantic Tropical Cyclone Activity, *Journal Of Climate*, DOI: 10.1175/JCLI-D-13-00687.1. (2014)
- PAZ, A.R., UVO, B.C., BRAVO, J.M., COLLISCHONN, W., DA ROCHA, H.R. Seasonal Precipitation Forecast Based on Artificial Neural Networks. In: PRADO, H.A., CHAIB FILHO, H., LUIZ, A.J.B. *Computation Methods for Agricultural Research: Advances and Applications*. Cap. 16, p.326-354, New York: Hershey, 2011.

PEREIRA, T. A. da S.; COSTA, D. D.; FRAGOSO JR, C. R.; MONTENEGRO, S. M. G. L. Correlações Entre O Índice Padronizado de Precipitação e Índices Climáticos Nas Bacias Do Rio Mundaú e Paraíba. In: XII Simpósio de Recursos Hídricos do Nordeste. Natal-RN, 2014.

PEZZA, A. B.; AMBRIZZI, T. Dynamical Conditions and Synoptic Tracks Associated with Different Types of Cold surge over Tropical South América. *International Journal of Climatology*, v. 25, p. 215-241, 2005.

PICCILLI, D. G. A. Avaliação da Previsão Hidroclimático no Alto Paraguai. Tese de Doutorado submetido ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul - UFRGS, 2007.

PINTO, E. J. de A.; DE ABREU, M. L.; NAGHETTINI, M da C. Utilização de Indicadores Climáticos na Previsão Probabilística de Precipitações e Vazões na Bacia do Alto São Francisco. *RBRH – Revista Brasileira de Recursos Hídricos* Volume 11 n.4, 137-151 137, Out/Dez 2006.

PINTO, E. J. de A. Estudo de Indicadores climáticos para a previsão de longo termo de vazões na bacia do alto São Francisco. Tese UFMG, Saneamento, Meio Ambiente e Recursos Hídricos, 2005.

PNUD. Programa das Nações Unidas para o Desenvolvimento. Índice de Desenvolvimento Humano Municipal Brasileiro. Atlas do Desenvolvimento Humano no Brasil. Brasília: PNUD, 2013.

PRADO, L. F. 2010. Pacific interdecadal Oscillation and its impacts on São Paulo State rainfall regime. Dissertação (Mestrado) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, 132 p., São Paulo, 2010.

RÄSÄNEN, T. A.; KUMMU, M. Spatiotemporal influences of ENSO on precipitation and flood pulse in the Mekong River Basin *Journal of Hydrology* 476 (2013) 154-168

RAO, V. B.; LIMA, M. C. de; Franchito, S. H. Seasonal and Interannual Variations of Rainfall over Eastern Northeast Brazil. *Journal of Climate*. v.6, 1993.

REBOITA, M. S. Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, v.25, n.2, 185 - 204, 2010.

REIS, R. L. B. de S. Estudo De Teleconexões Climáticas Para a Previsão Hidrológica De Longo Prazo Da Bacia Do Rio Piancó No Semiárido Paraibano. Dissertação Apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento – PPGRHS da Universidade Federal de Alagoas – UFAL. 2015.

RODÓ, X.; BAERT, E.; COMIN, F. A. Variations in seasonal rainfall in Southern Europe during the present century: relationships with the North Atlantic Oscillation and the El Niño-Southern Oscillation. *Climate Dynamics* (1977) 13: 275-284.

ROSSATO, L.; Marengo, J. A.; ANGELIS, C. F. de; PIRES, L. B. M.; MEDIONDO, E. M. Avaliação da umidade do solo e do Índice de Severidade de Seca de Palmer no Brasil e suas projeções futuras. *Revista Brasileira de Recursos Hídricos - RBRH*, Porto Alegre, v. 22, e36, 2017. ISSN 2318-0331

SANSIGOLO, C. A.; NERY, J. T. Análise de fatores comuns e agrupamentos das precipitações nas regiões sudeste e sul do Brasil. In: X Congresso Brasileiro de Meteorologia, 1998, Brasília, DF. Anais do X Congresso Brasileiro de Meteorologia. Brasília, DF: Sociedade Brasileira de Meteorologia, 1998.

SANSIGOLO, C. A.; REIS, T. G. Probabilidades de precipitações sazonais no NE do Brasil associadas a eventos extremos de Enos. XII Simpósio de Recursos Hídricos do Nordeste, Natal, 2014

SANTOS, M. S. Caracterização espaço-temporal de secas utilizando ondaletas e o standardized precipitation index: Uma aplicação para a parcela mineira da bacia do rio são Francisco. Dissertação apresentada ao Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, Minas Gerais, 2011.

SANTOS, I. A.; FRANCO, N. J. N. Anomalias Da Precipitação No Sul Do Brasil E As Teleconexões. XVII Congresso Brasileiro de Agrometeorologia. Guarapari – ES. 2011.

SANTOS, C. A. C. dos.; MANZI, A. O. Eventos extremos de precipitação no estado do ceará e suas relações com a temperatura dos oceanos tropicais, Revista brasileira de meteorologia, v.26, n.1, 157 - 165, 2011.

SANTOS, C. A. G.; MORAIS. B. S.; SILVA, G. B. L. Drought forecast using an artificial neural network for three hydrological zones in San Francisco River basin, IAHS Publ. 333 – 302. 2013.

SANTOS, D. C. dos; MEDEIROS, R. M. de; BRITO, J. I. B. de. Análise de índices de precipitação na Amazônia Ocidental, Revista Brasileira de Geografia Física v.6 n.5, p.1336-1355, 2013.

SANTOS, C. A. G.; FREIRE, P. K. de M.; TORRENCE, C. A Transformada Wavelet e sua Aplicação na Análise de Séries Hidrológicas. Revista Brasileira de Recursos Hídricos Volume 18 n.3 – Jul/Set 2013,271-280. 2013.

SANTOS, J. F.; PULIDO-CALVO, I.; PORTELA, M. M.. Spatial and temporal variability of droughts in Portugal. Water Resour. Res. 46, 1–13. doi: 10.1029/2009WR008071, 2010.

SANTOS, M. S. Caracterização espaço-temporal de secas utilizando ondaletas e o standardized precipitation index: Uma aplicação para a parcela mineira da bacia do rio são francisco , universidade federal de minas gerais Programa de pós-graduação em saneamento, Meio ambiente e recursos hídricos, Belo Horizonte, 2011.

SANTOS, S. R. Q.; BRAGA, C. C.; SANSIGOLO, C. A.; SANTOS, A. P. P. Determinação de Regiões Homogêneas do Índice de Precipitação Normalizada (SPI) na Amazônia Oriental, Revista Brasileira de Meteorologia, v. 32, n. 1, 111-122. doi: <http://dx.doi.org/10.1590/0102-778632120160013>, 2017.

SENA, A.; BARCELLOS, C.; FREITAS, C.; CORVALAN, C. Managing the health impacts of drought in Brazil. Int. J. Environ. Res. Public Health 11, 10737–10751. doi: 10.3390/ijerph111010737, 2014.

- SHUKLA, R.P.; TRIPATHI, K. C.; PANDEY, A. C.; DAS, I. M.L. Prediction of Indian summer monsoon rainfall using Niño indices: a neural network approach *Atmos. Res.*, 102 1-2, pp. 99–109. 2011.
- SILVA, E. R. L. G. Associação da variabilidade climática dos oceanos com a vazão de rios da Região Norte do Brasil. Dissertação (Mestrado) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, 182 p., São Paulo, 2013.
- SILVA, E. S.; TRINCA, L. A.; NERY, J. T. Áreas espacialmente homogêneas de níveis de precipitação nas regiões sudeste e sul do Brasil. *Revista Energia na Agricultura*, ISSN 1808-8759, Botucatu, vol. 24, n.3, p. 34-59, 2009.
- SILVERMAN, D.; DRACUP, J. A. Artificial Neural Networks and long-range precipitation prediction in California. *Journal of Applied Meteorology*, 39, 57–66. doi:10.1175/1520-0450(2000)039<0057:annalr>2.0.co;2
- SOUZA, J. L. de.; AMORIM, R. F. C. de; CARVALHO, S. M. R. de; PEREIRA, J. O.; CURI, P. R. Agrupamento de estações pluviométricas do estado de alagoas, utilizando-se análise multivariada, *Revista Brasileira de Meteorologia*; Vol. 7(2), 603-612. Universidade Estadual Paulista, SP, 1992.
- SOUZA, R. C. de; REIS, R. S.; FRAGOSO JR, C. R.; SOUZA, C. F. Uma análise na dragagem do Complexo Estuarino-Lagunas Mundaú/Manguaba em Alagoas através de um modelo numérico hidrodinâmico bidimensional- resultados preliminares. *Revista Brasileira de Recursos Hídricos*, v. 9, n. 4, 2004. ISSN 2318-0331
- SOUZA, A. de.; FERNANDES, W. A.; PAVÃO, H. G.; LASTORIA, G.; GABAS, S. G.; PARANHOS FILHO, A. C.; SOUZA, R. S. DE; KOFANOVSKI, A. Z. Análise de agrupamento para a precipitação para a gestão de águas pluviais no Mato Grosso do Sul. XIX Simpósio Brasileiro de Recursos Hídricos. 2011.
- SUN, C; LI, J.; FENG, J.; XIE, F. A decadal-Scale Teleconnection between the NAO and Subtropical Eastern Australian Rainfall, *Journal of Climate*, v 28, 2015 doi: 10.1175/JCLI-D-14-00372.1
- TEIXEIRA, N. F.; MARTÍN-VIDE, J. Influência do ENOS na distribuição das precipitações no estado do Paraná, Brasil. *Revista Brasileira de Climatologia*. ISSN: 1980-055x (Impressa) 2237-8642 (Eletrônica).
- TORRENCE, C.; COMPO, G. P. A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, v. 79, n. 1, p. 61-78, doi: 10.1175/1520-0477(1998)079<0061. 1998.
- TUCCI, C. E. M. Previsão de vazões na bacia do Rio São Francisco com base na previsão climática. Relatório técnico ANEEL/OMM/98/00. Porto Alegre: IPH-UFRGS. 385p. 2005.
- UVO, C. R. B. A zona de Convergência Inter-Tropical (ZCIT) e sua Relação com a Precipitação da Região Norte do Nordeste Brasileiro. Dissertação de Mestrado. Programa de Pós-Graduação em Meteorologia do Instituto Espacial de Pesquisas Espaciais – INPE. 1989.

UVO, C. R. B.; REPELLI, C. A.; S. ZEBIACK; KUSHINIR, Y., 1994. A Study on the influence of the Pacific and Atlantic on the Northeast Brazil Monthly Precipitation Using Singular Value Decomposition (SVD). To be submitted to Journal of Climate.

UVO, C. B.; REPELLI, A.; ZEBIAK, S.E.; KUSHNIR, Y. The relationships between Tropical Pacific and Atlantic SST and Northeast Brazil monthly precipitation. *J. Climate*, v.11, p.551-562, 1998.

UVO, C.R. B.; BERNDTSSON, R. Regionalization and Spatial Properties of Ceará State Rainfall in Northeast Brazil. *J. Geoph. Res.*, vol. 101, no. D2, 4221-4233, 1996.

UVO, C. B. Analysis and regionalization of northern european winter precipitation based on its relationship with the North Atlantic oscillation. *International journal of climatology Int. J. Climatol.* 23: 1185–1194 (2003) Published online 9 July 2003 in Wiley InterScience (www.interscience.wiley.com). DOI: 10.1002/joc.930

VALENÇA, M. J. S. Fundamentos das redes neurais: exemplos em Java. 2 ed. rev. Ampli.- Olinda – PE: Livro Rápido, 2015. 386p. ISBN: 978-85-7716-342-7.

VICENTE-SERRANO, SERGIO M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I. et al. A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. Instituto Pirenaico de Ecología, Zaragoza, Spain, Instituto Pirenaico de Ecología, Zaragoza, Spain (Manuscript received 28 October 2008, in final form 6 October 2009 1696 *Journal Of Climate*, Volume 23, 2010.

WU, J.; ZHOU, L.; MO, X.; ZHOU, H.; ZHANG, J.; JIA, R. Drought monitoring and analysis in China based on the Integrated Surface Drought Index (ISDI), *Journal of Applied Earth Observation and Geoinformation* 41 (2015) 23–33

XU, K.; Yang, D.; Yang, H.; LI, Z.; QIN, Y.; SHEN, Y. Spatio-temporal variation of drought in China during 1961–2012: A climatic perspective, *China Journal of Hydrology* 526 (2015) 253–264, 2015.

YOON, J.; ZENG, N. An Atlantic influence on Amazon rainfall. *Clim Dyn* (2010) 34: 249 – 264. DOI 10.1007/s00382-009-0551-6

YUAN, F. Impacts of climate change on surface hydrology in the source region of the Yellow River. Water Resources Engineering Department Of Building And Environmental Technology Faculty of Engineering Lund University, June 2015.

APÊNDICE A – CÁLCULO DO SPI

```

% Programa que retorna o valor do SPI para diferentes
intervalos de
% análise(meses)
% Desenvolvido por Thiago Pereira em 26 de abril de 2016 p a
disciplina de
% Clima e Recursos Hídricos da UFPE
% Utilizou a metodologia proposta por Mckee el al., 1993 e
Abramowitz e Stegun(1965)
% Descrita por Albuquerque(2009) in Avaliação do processo de
gestão de seca:
% estudo de caso no Rio Grande do Sul

function [SPI] = SPIIn(X,Z)

% Matriz X - Matriz com valores de precipitação
% Z - intervalo de análise, em meses

% Tamanho da amostra
n = size(X,1);

% Número de anos
anos = n/12;

% Calculo do P acumulado
for i = Z:n
    Y(i-Z+1) = sum(X(i-Z+1:i));
end

ny = size(Y',1); % n-Z-1
Yr = Y(14-Z:ny);% Excluir 1a Linha

% Criar Matriz de Imagem
Iy = reshape(1:ny-13+Z, 12, []);
Ty = Iy';

% Criar Matriz sem a primeira linha
for j = 1:12
    Yc(:,j) = Yr(Ty(:,j));
end

%% Inserir "zeros" a primeira linha

% Gerar zeros
W = zeros(Z-1,1)';

% Juntar com os valores

```

```

L = [W Y(1:13-Z)];

%% Inserir Primeira Linha

M = [L; Yc];

%% Retirar os zeros no calculo do SPI

for k = 1:12
    if k < Z % Celulas que possuem zero
        % Ajustar Distribuição de Gamma
        pd = fitdist(M(2:anos,k), 'Gamma');
        % Retorna o valor da propabilidade acumulada
        N(2:anos,k) = cdf(pd,M(2:anos,k));
        % Devolve o zero
        N(1,k) = 0;
    else
        % Ajustar Distribuição de Gamma
        pd = fitdist(M(:,k), 'Gamma');
        % Retorna o valor da propabilidade acumulada
        N(:,k) = cdf(pd,M(:,k));
    end
    % Calculo do m
    m(k) = 0;
    for l = 1:anos
        if M(l,k) == 0;
            m(k) = m(k) + 1;
        else
            m(k) = m(k);
        end
    end
    % Retirar os "zeros" no cálculo do m
    if k < Z
        m(k) = m(k)-1;
    else
        m(k) = m(k);
    end

    % Cálculos do valores corrigidos
    q(k) = m(k)/anos;
    H(:,k) = q(k) + (1-q(k))*N(:,k);
end

co = 2.515517;
c1 = 0.802853;
c2 = 0.010328;
d1 = 1.432788;
d2 = 0.189269;
d3 = 0.001308;

```

```

for o = 1:12
    for p = 1:anos
        if H(p,o) > 0.5
            Aux(p,o) = 1/(1-H(p,o))^2;
            t(p,o) = sqrt(log(Aux(p,o)));
            Aux1(p,o) = co + c1*t(p,o)+c2*t(p,o)^2;
            Aux2(p,o) = 1+d1*t(p,o)+d2*t(p,o)^2+ d3*t(p,o)^3;
            SPI(p,o) = t(p,o) - (Aux1(p,o)) / (Aux2(p,o));
        else
            Aux(p,o) = 1/(H(p,o))^2;
            t(p,o) = sqrt(log(Aux(p,o)));
            Aux1(p,o) = co + c1*t(p,o)+c2*t(p,o)^2;
            Aux2(p,o) = 1+d1*t(p,o)+d2*t(p,o)^2+ d3*t(p,o)^3;
            SPI(p,o) = -t(p,o) + (Aux1(p,o)) / (Aux2(p,o));
        end
    end
end

% Os Z-1 elementos devem ser iguais a -99
R = -99*ones(Z-1,1);

SPI = reshape(SPI',n,1);

SPI = [R; SPI(Z:n)];

% Plotar gráfico
A = 1:n;

plot(A, SPI,'b')
xlabel('Tempo');
ylabel('SPI');
title(['SPI']);
legend('SPI');
end

```

APÊNDICE B – CORRELAÇÕES DE SPEARMAN

```

% Function modified of Cintia Bertacchi Uvo -- April 2009
% calculates the Spearman correlation among time series
% time series and checks its significance using bootstrap and
% indicate if these are significant 99% and 95%

function [sup95, inf95, sup99, inf99, S, R] =
corr_boot_sig_meu(nboot,x,y)
% x - times series (ex. rainfall);
% y - times series (ex. climate indices)
% nboot = number of bootstrap interactions

%sup95 - matrix upper values with 95% significance
%inf95 - matrix lower values with 95% significance
%sup99 - matrix upper values with 99% significance
%inf99 - matrix lower values with 99% significance
% S - significance matrix, if 99 (99% significance), 95(95%
significance)
% and 0 (significance below 95%)
% R - matrix with value correlation spearman size mz x nz

% Size times series
[nt,nz] = size(x);
[mt,mz] = size(y);

i = 1;
h = 1;
z = 1;

%calculate correlation
while h <= mz;
    while i <= nz;
        R(h,i)=corr(x(:,i),y(:,h),'type','Spearman');
        while z <= nboot
            onesample = ceil(nt*rand(nt,1));
            twosample = ceil(nt*rand(nt,1));
            if h == 1
                tmp(z,i) =
corr(x(onesample(:),i),y(twosample(:),h),'type','Spearman');
                z=z+1;
            % Calcule limits with significance 95% and 99%
            sup95(h,i) = quantile(tmp(:,i),0.975);
            inf95(h,i) = quantile(tmp(:,i),0.025);
            sup99(h,i) = quantile(tmp(:,i),0.995);
            inf99(h,i) = quantile(tmp(:,i),0.005);
            else
                tmp(z,i+nz*(h-1)) =
corr(x(onesample(:),i),y(twosample(:),h),'type','Spearman');

```

```

        z=z+1;
    % Calculate limits with significance 95% and 99%
        sup95(h,i) = quantile(tmp(:,i+nz*(h-1)),0.975);
        inf95(h,i) = quantile(tmp(:,i+nz*(h-1)),0.025);
        sup99(h,i) = quantile(tmp(:,i+nz*(h-1)),0.995);
        inf99(h,i) = quantile(tmp(:,i+nz*(h-1)),0.005);
    end
    end
    i=i+1;
    z=1;
    end
    h = h+1;
    i = 1;
end

% Significance test
for aa = 1:mz
    for ab = 1:nz
        if R(aa,ab)> sup99(aa,ab) || R(aa,ab)< inf99(aa,ab)
            S(aa,ab) = 99;
        elseif R(aa,ab)> sup95(aa,ab) || R(aa,ab)<
inf95(aa,ab)
            S(aa,ab) = 95;
        else
            S(aa,ab) = 0;
        end
    end
end
end
return

```

APÊNDICE C – DIVISÃO DOS DADOS

```

Algoritmo que divide os dados de entradas e os targets do
treinamento e
% validação da ANN com critérios de similaridades da media e
desvio
% padrao dos conjuntos de treinamento e validação dos target
% Divide em tres configurações (70 - 15 - 15, 60 - 20 - 20 e
% 50 - 25 - 25)

function
[X,Y,Xval,Yval,Xver,Yver,X2,Y2,Xval2,Yval2,Xver2,Yver2,X3,Y3,X
val3,Yval3,Xver3,Yver3,M] = divid_dados(A,B)
% X - matriz de entradas
% Y - matriz de targets
% Z - Matriz que indica a divisão dos dados

% Formar matriz de dados;

[nt,M] = size(A);
T = [1:nt]; % Jogar a ordem cronologica (anos)
T = T';
D = [T A B];

% Maior valor de target para o Treinamento
[a b] = max(B);
Mtrain1(1,:) = D(b,:);
Mtrain2(1,:) = D(b,:);
Mtrain3(1,:) = D(b,:);
Aux = D;
Aux(b,:) = [];

% Menor valor de target para o Treinamento
[c d] = min(Aux(:,end));
Mtrain1(2,:) = Aux(d,:);
Mtrain2(2,:) = Aux(d,:);
Mtrain3(2,:) = Aux(d,:);
Aux1 = Aux;
Aux1(d,:) = [];

% 2o. maior valor de target para a validação
[e f] = max(Aux1(:,end));
Mvalida1(1,:) = Aux1(f,:);
Mvalida2(1,:) = Aux1(f,:);
Mvalida3(1,:) = Aux1(f,:);
Aux2 = Aux1;
Aux2(f,:) = [];

% 2o. menor valor de target para a validação
[g h] = min(Aux2(:,end));

```

```

Mvalida1(2,:) = Aux2(h,:);
Mvalida2(2,:) = Aux2(h,:);
Mvalida3(2,:) = Aux2(h,:);
Aux3 = Aux2;
Aux3(h,:) = [];

% Tamanho da matriz de Validação e Verificação;

nvalida(1) = ceil(0.15*nt);
nvalida(2) = ceil(0.20*nt);
nvalida(3) = ceil(0.25*nt);

for i = 1:3
    nverif(i) = nvalida(i);
    ntrain(i) = nt - 2*nverif(i);
end

Dif1 = ones(1,2);
Dif2 = ones(1,2);
Dif3 = ones(1,2);

%% 70 - 15 - 15
while Dif1(1) > 0.10 || Dif1(2) > 0.10

    Aleat1 = randperm(nt-4);
    Conjtrain1 = Aleat1(1:ntrain(1)-2);
    Mtrain1(3:ntrain(1),:) = Aux3(Conjtrain1,:);
    Conjvalida1 = Aleat1(ntrain(1)-1:ntrain(1)+nvalida(1)-4);
    Mvalida1(3:nvalida(1),:) = Aux3(Conjvalida1,:);
    Conjverif1 = Aleat1(ntrain(1)+nvalida(1)-3:nt-4);
    Mverif1 = Aux3(Conjverif1,:);

    Mdt1 = mean(Mtrain1(:,end)); % Media do treino
    Mdv1 = mean(Mvalida1(:,end)); % Media da Validação
    dt1 = std(Mtrain1(:,end)); % Desvio padrao do treino;
    dv1 = std(Mvalida1(:,end)); % Desvio padrão da validação;
    Estat1 = [Mdt1 Mdv1; dt1 dv1]; % Matriz das Estatísticas;

    for i = 1:2
        Dif1(i) = abs(Estat1(i,1) - Estat1(i,2))/abs(Estat1(i,2));
    end
end

%% 60 - 20 - 20

while Dif2(1) > 0.10 || Dif2(2) > 0.10

    Aleat2 = randperm(nt-4);
    Conjtrain2 = Aleat2(1:ntrain(2)-2);
    Mtrain2(3:ntrain(2),:) = Aux3(Conjtrain2,:);

```

```

Conjvalida2 = Aleat2(ntrain(2)-1:ntrain(2)+nvalida(2)-4);
Mvalida2(3:nvalida(2),:) = Aux3(Conjvalida2,:);
Conjverif2 = Aleat2(ntrain(2)+nvalida(2)-3:nt-4);
Mverif2 = Aux3(Conjverif2,:);

Mdt2 = mean(Mtrain2(:,end)); % Media do treino
Mdv2 = mean(Mvalida2(:,end)); % Media da Validação
dt2 = std(Mtrain2(:,end)); % Desvio padrao do treino;
dv2 = std(Mvalida2(:,end)); % Desvio padrão da validação;
Estat2 = [Mdt2 Mdv2; dt2 dv2]; % Matriz das Estatísticas;

for i = 1:2
Dif2(i) = abs(Estat2(i,1)- Estat2(i,2))/abs(Estat2(i,2));
end
end

%% 50 - 25 - 25

while Dif3(1) > 0.10 || Dif3(2) > 0.10

Aleat3 = randperm(nt-4);
Conjtrain3 = Aleat3(1:ntrain(3)-2);
Mtrain3(3:ntrain(3),:) = Aux3(Conjtrain3,:);
Conjvalida3 = Aleat3(ntrain(3)-1:ntrain(3)+nvalida(3)-4);
Mvalida3(3:nvalida(3),:) = Aux3(Conjvalida3,:);
Conjverif3 = Aleat3(ntrain(3)+nvalida(3)-3:nt-4);
Mverif3 = Aux3(Conjverif3,:);

Mdt3 = mean(Mtrain3(:,end)); % Media do treino
Mdv3 = mean(Mvalida3(:,end)); % Media da Validação
dt3 = std(Mtrain3(:,end)); % Desvio padrao do treino;
dv3 = std(Mvalida3(:,end)); % Desvio padrão da validação;
Estat3 = [Mdt3 Mdv3; dt3 dv3]; % Matriz das Estatísticas;

for i = 1:2
Dif3(i) = abs(Estat2(i,1)- Estat2(i,2))/abs(Estat2(i,2));
end
end

%% Escrever as Matrizes

% 70-15-15
X = Mtrain1(:,2:M+1);
Y = [Mtrain1(:,1) Mtrain1(:,M+2)];

Xval = Mvalida1(:,2:M+1);
Yval = [Mvalida1(:,1) Mvalida1(:,M+2)];

Xver = Mverif1(:,2:M+1);

```

```
Yver = [Mverif1(:,1) Mverif1(:,M+2)];

% 60-20-20
X2 = Mtrain2(:,2:M+1);
Y2 = [Mtrain2(:,1) Mtrain2(:,M+2)];

Xval2 = Mvalida2(:,2:M+1);
Yval2 = [Mvalida2(:,1) Mvalida2(:,M+2)];

Xver2 = Mverif2(:,2:M+1);
Yver2 = [Mverif2(:,1) Mverif2(:,M+2)];

% 50-25-25
X3 = Mtrain3(:,2:M+1);
Y3 = [Mtrain3(:,1) Mtrain3(:,M+2)];

Xval3 = Mvalida3(:,2:M+1);
Yval3 = [Mvalida3(:,1) Mvalida3(:,M+2)];

Xver3 = Mverif3(:,2:M+1);
Yver3 = [Mverif3(:,1) Mverif3(:,M+2)];

end
```

APÊNDICE D – CATEGORIAS DE SECAS

Algoritmo que identifica as categorias de secas observadas e calculadas,

% além de retornar o número de acerto de categorias

```
function [NumAc] = Catego(X,T)
```

```
[nt nz] = size (X);
```

```
i = 1;
```

```
j = 1;
```

```
k = 1;
```

```
l = 1;
```

```
m = 1;
```

```
n = 1;
```

```
for j = 1:nt
```

```
    for i = 1: nz
```

```
        if X(j,i) >= 1.65
```

```
            Y(j,i) = 1;
```

```
        elseif (X(j,i) < 1.65) && (X(j,i) >= 1.28)
```

```
            Y(j,i) = 2;
```

```
        elseif (X(j,i) < 1.28) && (X(j,i) >= 0.84)
```

```
            Y(j,i) = 3;
```

```
        elseif (X(j,i) < 0.84) && (X(j,i) >= -0.84)
```

```
            Y(j,i) = 4 ;
```

```
        elseif (X(j,i) < - 0.84) && (X(j,i) >= -1.28)
```

```
            Y(j,i) = 5;
```

```
        elseif (X(j,i) < - 1.28) && (X(j,i) >= -1.65)
```

```
            Y(j,i) = 6;
```

```
        else
```

```
            Y(j,i) = 7;
```

```
        end
```

```
        i=i+1;
```

```
    end
```

```
    j=j+1;
```

```
end
```

```
for k = 1: nz
```

```
    if T(k) >= 1.65
```

```
        W(k) = 1;
```

```
    elseif (T(k) < 1.65) && (T(k) >= 1.28)
```

```
        W(k) = 2;
```

```
    elseif (T(k) < 1.28) && (T(k) >= 0.84)
```

```
        W(k) = 3 ;
```

```
    elseif (T(k) < 0.84) && (T(k) >= -0.84)
```

```
        W(k) = 4 ;
```

```
elseif (T(k) < - 0.84) && (T(k) >= -1.28)
    W(k) = 5 ;
elseif (T(k) < - 1.28) && (T(k) >= -1.65)
    W(k) = 6;
else
    W(k) = 7;
end
    k=k+1;
end

for l = 1:nt
    for m = 1:nz
        if W(m) == Y(l,m)
            Ac(l,m) = 1;
        else
            Ac(l,m) = 0;
        end
        m = m+1;
    end
    l = l+1;
end

for n = 1:nt
    NumAc(n) = sum(Ac(n, :)) * 100 / nz;
    n = n+1;
end

NumAc = NumAc';
end
```