

UNIVERSIDADE FEDERAL DE ALAGOAS  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS  
E SANEAMENTO

DENIS DUDA COSTA

**Previsão Hidrológica de Longo-Prazo baseada em Componentes  
Climáticas em Bacias Hidrográficas Semiáridas/Tropicais**

Maceió  
2014

DENIS DUDA COSTA

**Previsão Hidrológica de Longo-Prazo baseada em Componentes  
Climáticas em Bacias Hidrográficas Semiáridas/Tropicais**

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento, Centro de Tecnologia da Universidade Federal de Alagoas, como requisito para obtenção do título de Mestre em Recursos Hídricos e Saneamento.

Orientador: Prof. Dr. Carlos Ruberto  
Fragoso Junior

Co-Orientador: Prof. Dr. Adriano Rolim  
da Paz

Maceió  
2014

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**  
**Divisão de Tratamento Técnico**  
**Bibliotecária Responsável: Maria Auxiliadora G. da Cunha**

C837p Costa, Denis Duda.  
Previsão hidrológica de longo-prazo baseado em componentes climáticas em bacias hidrográficas semiáridas/tropicais / Denis Duda Costa. – 2014.  
44 f. : il. tabs., gráfs.

Orientador: Carlos Ruberto Frago Junior.  
Co-orientador: Adriano Rolim da Paz.  
Dissertação (Mestrado em Engenharia: Recursos Hídricos e Saneamento) – Universidade Federal de Alagoas. Centro de Tecnologia. Maceió, 2014.

Bibliografia: f. 40-44.

1. Índices climáticos. 2. Variabilidade climática e hidrologia . 3. Análise Wavelets. 4. Previsão hidrológica. I. Título.

CDU: 551.579



---

**FOLHA DE APROVAÇÃO**

**PREVISÃO HIDROLÓGICA DE LONGO-PRAZO BASEADA EM COMPONENTES  
CLIMÁTICOS EM BACIAS HIDROGRÁFICAS SEMIÁRIDAS/TROPICAIS**

**DENIS DUDA COSTA**

Dissertação submetida à banca examinadora do Programa de Pós-Graduação em Recursos Hídricos e Saneamento da Universidade Federal de Alagoas e aprovada no dia 09 de maio do ano de 2014.

Banca Examinadora:

**Prof. Dr. Carlos Ruberto Fragozo Júnior**  
(Orientador – PPGRHS/UFAL)

**Prof. Dr. Marllus Ferreira Passos das Neves**  
(PPGRHS /UFAL)

**Prof. Dr. Adriano Rolim da Paz**  
(Co-Orientador - UFPB)

**Profª. Drª. Djane Fonseca da Silva**  
(UFC - Campus Cariri)

## **AGRADECIMENTOS**

O término deste momento representa uma condição de satisfação ímpar em minha vida. Assim, não poderia deixar de agradecer aos que me motivaram ao longo do caminho.

A minha família, por tudo que me proporciona. Principalmente aos meus pais e irmão pelo apoio incondicional.

Ao meu orientador Carlos Ruberto, obrigado por todo o tempo a mim dispensado, pelos conhecimentos transmitidos, pela realização deste trabalho.

Ao meu co-orientador Adriano Rolim, pelo conhecimento a mim transmitido nessa linha de pesquisa, pelas discussões iniciais na proposta do trabalho, pela ajuda em Lund.

A Frede Carvalho, valiosa contribuição para obter parte dos resultados dessa pesquisa.

Aos professores do PPGRHS e CTEC, obrigado pela ajuda em minha formação e pelos bons momentos no futebol da quinta-feira.

A todos os amigos. Em especial aos do PPGRHS, os que mais estiveram comigo estes 2 últimos anos. A Bênicio, Carlos Alberto, Cledeilson, Erick Sebadelhe e Jeilson pelas ajudas nos trabalhos e os dias de estudos. A Mahelvson, Almir, Aline, Gláucia e Helen, pelo companheirismo, os bons momentos e apoio. A galera de POA/UFRGS/IPH, Rafael BB, Eugenio GG, Carlos Echeverria (Gordito) e novamente Almir, por toda boa festa, e acolhida na mansão dos Eugenhocas (A Republica dos Palmares). Um especial agradecimento a Gláucia e Helen.

A Thiago Alberto, pelo companheirismo, incentivo, trabalhos, resenhas; sou muito grato pela sua amizade. A LG (Luis Gustavo) o qual compartilho do mesmo sentimento acima, além de toda admiração que lhe tenho. A Regina, pelas conversas, conselhos e autenticidade.

A Universidade de Lund na Suécia, sobretudo a professora Cintia Uvo, por me receber tão bem lá e por sua incalculável contribuição nesse trabalho.

A Fábio Farias e Cláudia Rivera pela convivência em Lund. E aos meus flatmates (Pieterjan, Lorenzo, Marcos, Jasmine e Yingying Li) por todos os bons momentos.

A CAPES pela concessão de bolsa no mestrado. E ao órgão sueco (Vetenskapsradet) pela bolsa em meu período em Lund.

Prefiro os que me criticam, porque me  
corrigem, aos que me elogiam, porque me  
corrompem.

Santo Agostinho

## RESUMO

Em um atual cenário de discussões sobre mudanças climáticas e principalmente ambientais, as avaliações sobre a alteração em regimes hidrológicos em escalas globais e/ou locais associadas as condições de variações climáticas permitem ponderações sobre os impactos e riscos associados aos sistemas hídricos em uma sociedade cada vez mais dependente do uso da água, seja para as atividades básicas, irrigação na agricultura ou geração de energia. Nesse estudo o propósito foi avaliar a previsão da precipitação de longo prazo nas bacias do rio Mundaú e Paraíba, no Nordeste do Brasil, através de um modelo estocástico baseado em Redes Neurais Artificiais (RNA), utilizando índices climáticos como preditores. Para isso, dados de precipitação da região de estudo para o período chuvoso (Maio a Julho) entre 1938 a 2008 foram analisados e comparados com índices climáticos como Índice de Oscilação do Sul - SOI, Oscilação do Atlântico Norte - NAO, Oscilação Decenal do Pacífico - ODP e Oscilação Multidecenal do Atlântico - OMA, utilizando ferramentas como Análise de Componentes Principais (ACP), Análise de Agrupamentos e Wavelets. Os resultados destacaram que a variabilidade da precipitação local está associada aos distintos climas e biomas da região junto aos modos de variabilidade atmosférica que atuam naquela área. Os índices SOI e NAO se apresentaram como potenciais preditores da precipitação para a área de estudo, com influências na variabilidade de escalas temporais interanuais e decadais. A RNA destacou uma capacidade satisfatória na previsão da precipitação, com similaridade em ajustar os dados nas etapas de treinamento, validação e teste do modelo. Esses resultados podem ser uma ferramenta útil para avaliar eventos hidrológicos, melhorando a gestão dos recursos hídricos em bacias hidrográficas.

**Palavras-chave:** Índices Climáticos. Variabilidade Climática e Hidrológica. Análise Wavelets. Previsão Hidrológica.

## ABSTRACT

In a scenery of climate and environmental changes, assessments about hydrological regimes alterations in global and/or local scales coupled the climate variability conditions enable ponderations on the impacts and risks associated to water systems in a society increasingly dependent on the use of water, whether for basic activities, agriculture irrigation or hydropower generation. In this study we aimed to evaluate the Long-term Precipitation Forecast in the Mundaú and Paraíba do Meio river basin, Northeast Brazil, through a stochastic model based on Artificial Neural Network (ANN) using climate indices as predictors. For this, precipitation data for the rainy season (May to July) from 1938 to 2008 were analysed and compared with climate indices such as Southern Oscillation Index - SOI, Northern Oscillation Index - NAO, Pacific Decadal Oscillation - PDO and Atlantic Multidecadal Oscillation - AMO, using some tools such as Principal Component Analysis (PCA), Cluster and Wavelets. It was highlighted that the local precipitation variability is associated with distinct climates and biomes in the region with the variability atmospheric modes that acting in that area. The SOI and NAO indices presented as precipitation predictors potential for the study area, with influences on the timescales interannual and decadal variability. The ANN highlights a satisfactory ability in predicting precipitation, with similarity fitting the data in steps of training, validation and testing on the model. These results could be a useful tool for assessing hydrological events, improving the water resources management in river basins.

**Key-word:** Climate Indices. Climate and Hydrological Variability. Wavelets Analysis. Hydrological Forecast.

## LISTA DE FIGURAS

FIGURA 2.1 - FLUXOGRAMA COM UM RESUMO DA METODOLOGIA UTILIZADA. .....	14
FIGURA 2.2 - MAPA DE LOCALIZAÇÃO DA REGIÃO DE ESTUDO.....	15
FIGURA 2.3 - CARACTERIZAÇÃO DO REGIME HIDROLÓGICO DA REGIÃO.....	16
FIGURA 3.1 - A) AUTOVALORES PARA A 1ª CP, DESTACANDO OS MAIORES VALORES NAS EXTREMIDADES DA REGIÃO; B) AUTOVALORES DA 2ª CP, EVIDENCIANDO DE FORMA CLARA A SEPARAÇÃO DOS POSTOS. ....	20
FIGURA 3.2 - AGRUPAMENTO DAS ESTAÇÕES PLUVIOMÉTRICAS NA REGIÃO. .	21
FIGURA 3.3 - A) REGIÕES HOMOGÊNEAS NA REGIÃO; B) ÁREA DE INFLUÊNCIA DE CADA POSTO NA REGIÃO. ....	22
FIGURA 3.4 - A) REGIME PLUVIOMÉTRICO MÉDIO MENSAL PARA CADA RH; B) PRECIPITAÇÃO MÉDIA ANUAL PARA CADA RH. ....	23
FIGURA 3.5 - A) COEFICIENTE DE CORRELAÇÃO LINEAR MENSAL PARA RH 1; B) COEFICIENTE DE CORRELAÇÃO LINEAR MENSAL PARA RH 2; C) COEFICIENTE DE CORRELAÇÃO LINEAR MENSAL PARA RH3. A LINHA TRACEJADA EQUIVALE AO COEFICIENTE DE CORRELAÇÃO COM 95% DE CONFIANÇA DEFINIDO NA DISTRIBUIÇÃO T-STUDENT, PONTOS ACIMA E/OU ABAIXO DA LINHA APRESENTAM CORRELAÇÕES SIGNIFICATIVAS AO NÍVEL DE 5%.....	24
FIGURA 3.6 - A) ANÁLISE WTC ENTRE A SÉRIE TEMPORAL DO ÍNDICE IOS-NOVEMBRO E A PRECIPITAÇÃO DE MJJ, MOSTRANDO QUE OS DADOS SE ENCONTRAM EM FASE. B) ANÁLISE XWT ENTRE IOS-NOVEMBRO E PRECIPITAÇÃO DE MJJ, DADOS EM FASE. NÍVEL DE SIGNIFICÂNCIA A 5% DESTACADO NA ÁREA CIRCULADA. A RELAÇÃO É DITA EM FASE, SE OS VETORES ESTÃO NO SENTIDO PARA A DIREITA, CORRELAÇÃO POSITIVA. A RELAÇÃO É DITA EM NÃO-FASE SE OS VETORES ESTÃO NO SENTIDO PARA A ESQUERDA, CORRELAÇÃO NEGATIVA. ....	25
FIGURA 3.7 - A) ANÁLISE WTC ENTRE A SÉRIE TEMPORAL DO ÍNDICE OAN-DEZEMBRO E A PRECIPITAÇÃO DE MJJ, MOSTRANDO QUE OS DADOS SE	

ENCONTRAM EM NÃO-FASE. B) ANÁLISE XWT ENTRE OAN-DEZEMBRO E PRECIPITAÇÃO DE MJJ, DADOS EM NÃO-FASE. NÍVEL DE SIGNIFICÂNCIA A 5% DESTACADO NA ÁREA CIRCULADA. ....	27
FIGURA 3.8 - A) ANÁLISE WTC ENTRE A SÉRIE TEMPORAL DO ÍNDICE ODP-NOVEMBRO E A PRECIPITAÇÃO DE MJJ. B) ANÁLISE XWT ENTRE ODP-NOVEMBRO E PRECIPITAÇÃO DE MJJ, DADOS EM NÃO-FASE. NÍVEL DE SIGNIFICÂNCIA A 5% DESTACADO NA ÁREA CIRCULADA. ....	28
FIGURA 3.9 - A) ANÁLISE WTC ENTRE A SÉRIE TEMPORAL DO ÍNDICE OMA-MARÇO E A PRECIPITAÇÃO DE MJJ. B) ANÁLISE XWT ENTRE OMA-MARÇO E PRECIPITAÇÃO DE MJJ, DADOS EM NÃO-FASE. NÍVEL DE SIGNIFICÂNCIA A 5% DESTACADO NA ÁREA CIRCULADA. ....	29
FIGURA 3.10 - MELHOR AJUSTE PARA A PREVISÃO HIDROLÓGICA NA RH1 A PARTIR DA RNA. VARIÁVEIS PREDITORAS DE ENTRADA, IOS E OAN. ....	33
FIGURA 3.11 - MELHOR AJUSTE PARA A PREVISÃO HIDROLÓGICA NA RH2 A PARTIR DA RNA. VARIÁVEIS PREDITORAS DE ENTRADA, IOS E OAN. ....	33
FIGURA 3.12 - MELHOR AJUSTE PARA A PREVISÃO HIDROLÓGICA NA RH3 A PARTIR DA RNA. VARIÁVEIS PREDITORAS DE ENTRADA, IOS E OAN. ....	34

## LISTA DE TABELAS

TABELA 3.1 - VARIABILIDADE EXPLICADA PELA ACP. ....	19
TABELA 3.2 - RESUMO DOS ÍNDICES CLIMÁTICOS SELECIONADOS.....	30
TABELA 3.3 - COEFICIENTE DE CORRELAÇÃO PARA OS DIFERENTES MODELOS DE ENTRADA NA PREVISÃO DA RH1. ....	31
TABELA 3.4 - COEFICIENTE DE CORRELAÇÃO PARA OS DIFERENTES MODELOS DE ENTRADA NA PREVISÃO DA RH2. ....	31
TABELA 3.5 - COEFICIENTE DE CORRELAÇÃO PARA OS DIFERENTES MODELOS DE ENTRADA NA PREVISÃO DA RH3. ....	32

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>11</b>
<b>2</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>13</b>
<b>2.1</b>	<b>Área de Estudo .....</b>	<b>14</b>
<b>2.2</b>	<b>Dados para o estudo.....</b>	<b>16</b>
<b>2.3</b>	<b>Regiões Homogêneas.....</b>	<b>17</b>
<b>2.4</b>	<b>Teleconexões .....</b>	<b>18</b>
<b>2.5</b>	<b>Previsão.....</b>	<b>19</b>
<b>3</b>	<b>RESULTADOS .....</b>	<b>19</b>
<b>3.1</b>	<b>Regiões Homogêneas.....</b>	<b>19</b>
<b>3.2</b>	<b>Teleconexões .....</b>	<b>23</b>
<b>3.3</b>	<b>Previsão.....</b>	<b>30</b>
<b>4</b>	<b>DISCUSSÕES.....</b>	<b>34</b>
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES.....</b>	<b>37</b>
	<b>REFERÊNCIAS .....</b>	<b>39</b>

# 1 INTRODUÇÃO

Variações de grande escala no clima provocam mudanças nos padrões de precipitação em diversas regiões do globo (Rasanen & Kummu, 2013; Martin-Vide, 2004; Uvo, 2003), afetando as mais diferentes atividades que estão ligadas ao uso da água, tais como irrigação, condições de navegação nos rios, operação de reservatórios com usos múltiplos e os recursos hídricos, em geral (Bravo, 2010). Relações causa-e-efeito entre o clima e precipitação podem ser estabelecidas com a finalidade de prever eventos hidrológicos de longo prazo em bacias hidrográficas. Tal avaliação permite, com certa antecedência, mitigar os impactos mais relevantes no gerenciamento dos recursos hídricos.

A previsão ao longo-prazo se caracteriza por estimar eventos entre 1 a 9 meses de antecedência (Georgakakos e Krysztofowicz, 2001 apud Tucci et al, 2007), a partir de modelos determinísticos ou estocásticos (Frank e Pinheiro, 2003). Novos avanços têm possibilitado a previsão climática de longo prazo, através do acoplamento entre modelos determinísticos atmosféricos e hidrológicos conceituais, denominada hidroclimática (Silva et al, 2005). Porém estes modelos possuem custos computacionais elevados e ainda apresentam desempenho ineficiente quando aplicados à escalas locais com o aumento do horizonte de previsão (Koutsoyiannis et al, 2008). Desta forma, as previsões de longo prazo mais comuns são as baseadas em modelos estocásticos (Tucci et al, 2005), onde se procura estimar precipitação/vazão futura pelo comportamento das séries temporais observadas no passado. Uma das abordagens utilizadas na modelagem estocástica é a aplicação de Redes Neurais Artificiais (RNA), a qual tem demonstrado grande potencial para a previsão hidrológica local de longo prazo (e.g. Galambosi et al, 2009; Paz et al, 2011; M.Guégan et al, 2012; S.-P. Yu et al, 2013; Partal e Kisi, 2007; G.-F. Lin e M.-C. Wu, 2009; Kisi e Shiri, 2011; S.Wey et al, 2012), melhorando, desta maneira, o planejamento estratégico dos recursos hídricos (McIntosh et al., 2007; Dawson e Wilby, 2001).

Um importante passo na previsão hidrológica de longo prazo é a seleção dos melhores preditores que representam as relações físicas envolvidas no fenômeno. As oscilações de grande escala no sistema oceano-atmosfera naturalmente afetam às variações no clima, que por sua vez promovem mudanças nos padrões de precipitação e temperatura em diferentes regiões através das teleconexões (Paz et al, 2011). As teleconexões (i.e anomalias climáticas em parte do globo que podem levar a outras anomalias no clima em diferentes regiões)

(Silverman e Dracup, 2000) são comumente avaliadas por alguns indicadores climáticos como, por exemplo, a Temperatura da Superfície do Mar (TSM), a Pressão Atmosférica e índices climáticos (Wilby, 2004; Morid et al, 2007). Os índices climáticos, no entanto, têm sido mais utilizados, uma vez que eles possibilitam uma melhor compreensão das relações físicas envolvidas entre sistemas atmosféricos de grande escala e variáveis hidroclimatológicas (Paz et al, 2011). Alguns índices climáticos (e.g. OAN<sup>1</sup>, IOS<sup>2</sup>, ODP<sup>3</sup>, OMA<sup>4</sup>) vêm se destacando na predição de longo-prazo de eventos hidrológicos, considerando diferentes propósitos como, por exemplo, (a) no planejamento e operação de reservatórios para geração de energia (Bravo, 2010; M. Guégan et al, 2012); na variabilidade de vazões de rios de grande (Labat, 2010) e médio porte (Rasanen e Kummu, 2013); (c) nas variações interanuais da precipitação visando melhorar o horizonte de planejamento no setor agrícola (Paz et al, 2011); (d) na regionalização da precipitação (Uvo, 2003); (e) na detecção de eventos extremos em diferentes escalas temporais (Massei e Fournier, 2012; M.H-Alegria et al, 2012).

O Nordeste do Brasil é uma região caracterizada pela grande ocorrência de eventos hidrológicos extremos (secas e cheias), onde a previsão hidrológica de longo prazo se apresenta como uma ferramenta promissora para o gerenciamento dos recursos hídricos da região. Foi observado que a variabilidade interanual na precipitação local dessa região é influenciada, principalmente, (a) por anomalias de grande escala da circulação atmosférica global (Uvo e Berndtsson, 1996), (b) pela ocorrência de sistemas frontais (Uvo e Berndtsson, 1996; Molion e Bernardo, 2002)) e (c) pelo movimento da Zona de Convergência Intertropical - ZCIT (Uvo et al, 1998; Molion e Bernardo, 2002). Desta forma, as teleconexões vêm sendo utilizadas como preditores de longo prazo da variabilidade interanual da precipitação nessa região. Por exemplo, a fase negativa do índice IOS (El Niño) têm apresentado correlação positiva com períodos de estiagens, assim como as chuvas acima da média apresentaram relação com a fase positiva do índice (La Niña). Além disso, sugere-se

---

<sup>1</sup> OAN (Oscilação do Atlântico Norte) representa um fenômeno de redistribuição da massa atmosférica no atlântico medido pela diferença de pressão na superfície do mar entre Açores e a Islândia (Hurrell, 1995)

<sup>2</sup> IOS (Índice de Oscilação Sul) relaciona a variação da TSM e a diferença de pressão ao nível do mar no Pacífico central no Taiti e Pacífico oeste na Austrália (Galambosi et al, 2009; Singh, 2001; Li et al, 2000; M.H-Alegria et al, 2012)

<sup>3</sup> ODP (Oscilação Decenal do Pacífico) se baseia na variação dos padrões de temperatura e pressão na superfície do mar no Pacífico Norte (Mantua et al, 1997)

<sup>4</sup> OMA (Oscilação Multidecenal do Atlântico) é definido a partir dos padrões de variabilidade da TSM no Atlântico norte (Schlesinger, 1994).

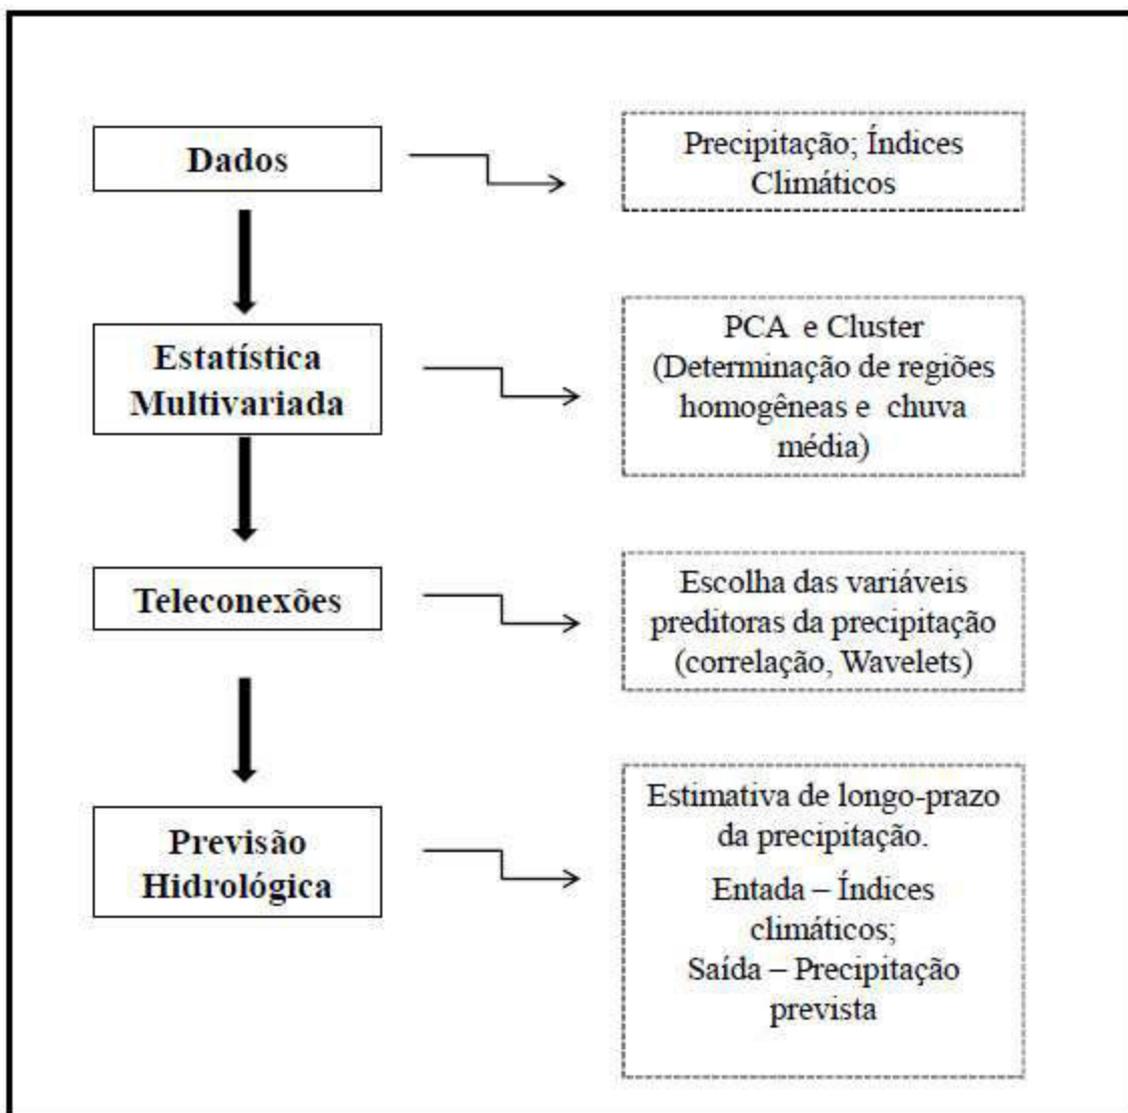
que heterogeneidade espacial das precipitações do nordeste está relacionado com índices climáticos como o IOS, o qual influencia secas severas na parte norte da região (Cirilo et al., 2007). Por outro lado, Kane (1993) mostrou não haver correlações significativas entre o IOS e as chuvas no nordeste, possivelmente devido as chuvas no nordeste estarem mais influenciadas pelas condições do Atlântico tropical quando comparados com o Pacífico tropical (Uvo et al, 1994; Kayano e Andreoli, 2006). As precipitações de algumas regiões do Nordeste do Brasil também apresentaram correlação com outros índices climáticos, tais como o ODP (Xavier e Xavier, 2004; Da Silva et al, 2010), OMA (Knight et al, 2006) e OAN (Costa e Fragoso Jr, 2012). Apesar dos avanços obtidos em relação ao entendimento dos efeitos dos sistemas climáticos na variabilidade interanual da chuva na região Nordeste do Brasil, ainda é necessário um aprofundamento dessas relações em escala de bacia hidrográfica visando avanços na previsão hidrológica de longo prazo.

Desta forma, este estudo pretende avaliar a previsão de precipitação de longo prazo nas bacias do rio Mundaú e Paraíba do Meio, ambas inseridas no Nordeste do Brasil compreendendo regiões semiárida e tropical úmida, através de um modelo estocástico baseado em Redes Neurais Artificiais, utilizando como preditores índices climáticos. Este trabalho também avaliou as principais teleconexões existentes nessas bacias hidrográficas, a partir das correlações entre índices climáticos (IOS, ODP, OMA e OAN) e o trimestre mais chuvoso. As explicações físicas existentes entre os índices climáticos e a precipitação foram investigadas através da aplicação de técnicas de decomposição de sinais, tais como Análise de Coerência e Cruzada de Wavelets, possibilitando a captura de características de periodicidades e averiguação do comportamento simultâneo das séries temporais por meio da co-variância entre os dados e do espectro de potência que mede o grau de associação entre as variáveis.

## **2 MATERIAIS E MÉTODOS**

Uma síntese da metodologia utilizada nesse trabalho é apresentada no fluxograma a seguir (**Figura 2.1**). Os detalhes de cada etapa são apresentados nos itens seguintes.

Figura 2.1 - Fluxograma com um resumo da metodologia utilizada.



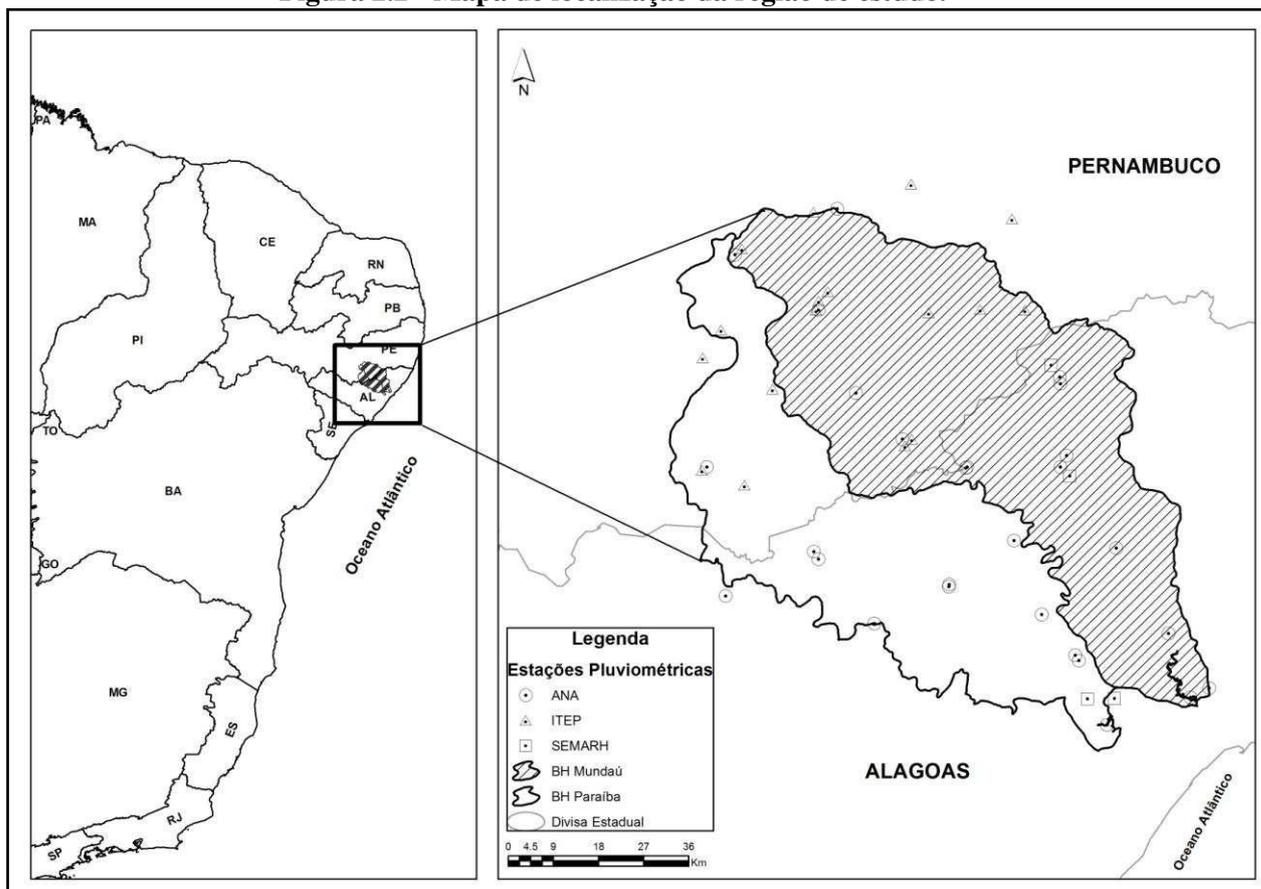
Fonte: Elaborado pelo autor (2014).

## 2.1 Área de Estudo

A área estudada compreende duas bacias hidrográficas, Bacia do rio Mundaú e Bacia do rio Paraíba, ambas localizadas no Nordeste do Brasil, limitadas pelas Latitudes  $8^{\circ}41'24''$  e  $9^{\circ}40'48''$  S e Longitudes  $35^{\circ}46'48''$  e  $36^{\circ}45'00''$  W (**Figura 2.2**). A área total compreende aproximadamente  $7,283 \text{ km}^2$ , sendo  $4,126 \text{ km}^2$  a Bacia do Mundaú e  $3,157 \text{ km}^2$  a Bacia do Paraíba, compartilhadas entre os estados de Pernambuco e Alagoas.

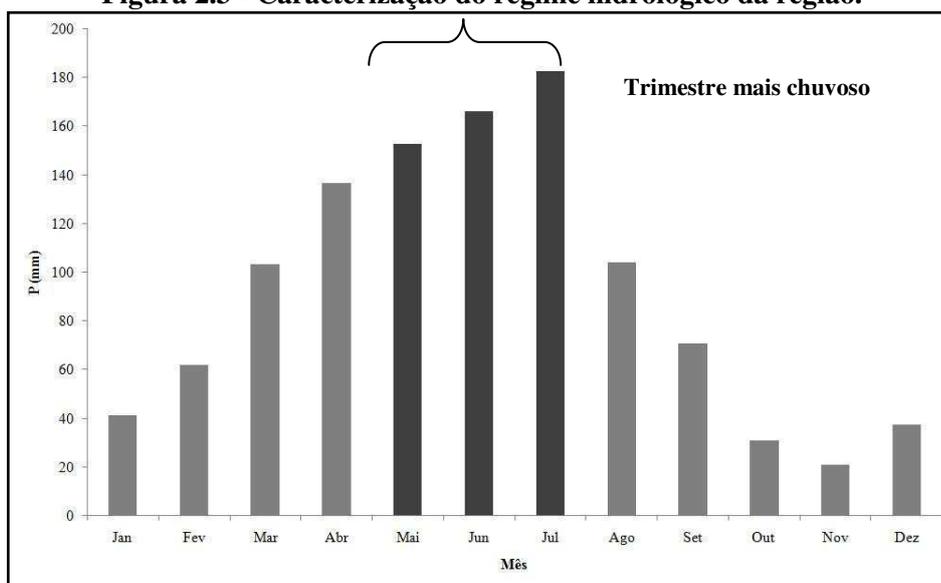
As bacias possuem características climato-fisiográficas semelhantes, com a presença do bioma Caatinga na parte alta da região, de aspecto climático semiárido, estando inclusive na região classificada de Polígono das Secas, e o bioma Mata Atlântica na parte baixa estendendo-se até a foz com clima tropical quente e úmido.

**Figura 2.2 - Mapa de localização da região de estudo.**



Fonte: Elaborado pelo autor (2014).

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 2,100 mm/ano (COTEC, 1999; COTEC, 2001). 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, sendo que 50% do total precipitado anual entre Maio e Julho (**Figura 2.3**).

**Figura 2.3 - Caracterização do regime hidrológico da região.**

Fonte: Elaborado pelo autor (2014).

Um total de 35 municípios estão inseridos na região, com população aproximada de 800 mil habitantes (IBGE, 2010), onde a principal atividade desenvolvida na área é a agricultura (plantio de cana-de-açúcar e agricultura familiar e/ou de subsistência), a qual é bastante susceptível às acentuadas variações do regime de precipitação, seja devido a grande cheia de 2010 que além da agricultura destruiu diversas cidades com perdas incalculáveis, ou uma forte estiagem que se estende desde 2012, resultado das próprias condições locais e/ou influência de fenômenos de grandes escalas como os descritos por Uvo et al (1998) e Molion & Bernardo (2002).

## 2.2 Dados para o estudo

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). No total foram utilizados 48 estações pluviométricas para um período entre 1938 a 2008 (**Figura 2.2**), sendo 27 ANA, 17 ITEP e 4 SEMARH. Os dados são correspondentes às séries de precipitações diárias. Testes de consistências foram realizados nas séries de precipitação através do software PrePlu (Collischonn, 2001). As séries mensais de precipitações foram obtidas a partir das séries diárias. Na sequência, um preenchimento de falhas pelo método da distância ao quadrado foi realizado nas séries mensais através do software INTERPLU (Collischonn, 2001). Dessa forma, foram obtidas as séries de precipitação do trimestre mais chuvoso da região, compreendido entre maio e julho (MJJ).

As séries históricas mensais referentes aos índices climáticos foram obtidas junto ao The National Center for Atmospheric Research (NCAR) e Natinal Oceanic and Atmospheric Administration (NOAA) para o mesmo período dos dados de precipitação. Os dados são apresentados na forma de anomalias em relação a média observada de um período. Para avaliar o efeito defasado de cada índice climático no trimestre mais chuvoso da região, as séries mensais dos índices climáticos foram tomadas de 2 a 8 meses em relação ao início da estação chuvosa.

### **2.3 Regiões Homogêneas**

Para a definição de regiões homogêneas (i.e sub-áreas dentro da área de estudo que possuem os mesmos padrões de variabilidade da precipitação) foram utilizados dois métodos de análise de estatística multivariada: uma Análise de Componentes Principais (ACP) e uma Análise de Agrupamento de Dados.

Inicialmente as estações pluviométricas foram separadas de acordo com o maior período de dados disponível, obtendo 25 postos entre o período de 1963 a 1992. Desse período de dados foi aplicado uma ACP para identificar os principais padrões de variabilidade de precipitação nas bacias. O primeiro e segundo eixo da ACP (autovalores) foram utilizados na reconstituição do sinal da precipitação, filtrando assim a variabilidade total da amostra de dados. Complementando a aplicação da ACP, foi utilizado uma Análise de Agrupamento (Cluster Analysis), a partir do sinal reconstituído, para identificação de grupos de postos pluviométricas que apresentam padrão de variabilidade similares. O método de agrupamento adotado foi o método Ward, com predefinição da quantidade de grupos, definido como 3 sub-grupos. As análises foram realizadas em MatLab® utilizando funções do toolbox de Análises Clusters.

Posteriormente, foi aplicada a técnica de Polígonos de Thiessen para obtenção da área de influência de cada estação pluviométrica na área de estudo, definindo pela Análise de Agrupamento as Regiões Homogêneas (RH) existentes nas bacias; em seguida foram calculadas as precipitações médias por RH para o trimestre mais chuvoso da região, considerando o período de 1963 a 1992. As séries anuais por RH foram estendidas para o período de 1938 a 2008, utilizando o passo anterior, a partir das demais estações pluviométricas presentes com dados entre 1938 e 1962 e de 1963 a 2008, para se ter um período maior de dados, com maior horizonte de avaliação para as Wavelets e RNA.

## 2.4 Teleconexões

Foram avaliadas possíveis teleconexões entre os índices climáticos IOS, OAN, ODP e OMA e a precipitação do trimestre mais chuvoso da região de estudo. Estes índices estão associados à potenciais variações em precipitação e vazão em diversas partes do globo (e.g Uvo (2003), Paz et al (2011), Massey e Fournier (2012), Rasanen e Kummu (2013)).

Uma abordagem preliminar simples, com base na análise de correlações, foi realizada inicialmente com o intuito de identificar potenciais variáveis preditoras. Os coeficientes de correlação de Pearson e Spearman foram calculados utilizando a precipitação acumulada MJJ para cada região e os valores mensais dos índices climáticos defasados de 2 a 8 meses em relação ao início do trimestre chuvoso. Foram considerados significativos os valores do coeficiente de correlação  $r$ , pertencentes ao intervalo de confiança ao nível de 95% pela aplicação da distribuição T-Student. A aplicação da técnica de Spearman serviu para verificar relações não-lineares entre a precipitação e os fenômenos climáticos (Paz et al, 2011).

Para uma compreensão física das relações entre sistemas climáticos e variações da precipitação na região de estudo, foram aplicadas técnicas de decomposição tempo-frequência para as séries temporais, visando a seleção dos melhores preditores da precipitação em MJJ, considerando sua influência em diferentes escalas temporais. Os sinais originais foram decompostos, considerando diferentes frequências temporais, através da técnica de Transformada Contínua de Wavelets (CWT), sugerida por Gristed et al (2004), utilizando e modificando rotinas em MatLab®, as quais são disponibilizadas no domínio <<http://noc.ac.uk/using-science/crosswavelet-wavelet-coherence>>. A função ondeleta de Morlet foi utilizada na aplicação da CWT, pois sugere melhores adaptações aos dados meteorológicos e/ou hidrológicos, ver detalhes em: Gristed et al (2004), Jevrejeva et al (2003), Labat (2010), Torrence & Compo (1998). Dois métodos de avaliação foram utilizados para avaliar o grau de associação entre duas CWT, são: (a) Coerência Wavelets (WTC) e (b) Wavelets Cruzada (XWT). A WTC é um método para análise da coerência (medida através da co-variância) e atraso de fase entre duas séries temporais como uma função do tempo e frequência (Chang and Glover 2010), a XWT mede a força de associação entre duas séries temporais através de um espectro de potência, onde é possível destacar os principais períodos de interferência de uma série em relação a outra para diferentes frequências temporais (Jevrejeva et al, 2003).

## 2.5 Previsão

Um modelo estocástico baseado em RNA foi utilizado para realizar a previsão de precipitação de longo prazo para o trimestre mais chuvoso das bacias, considerando as diferentes regiões homogêneas, tendo como variáveis preditoras os índices climáticos verificado no passo anterior e identificados como potenciais em previsibilidade.

O modelo RNA utilizado na previsão foi o multilayer feed-forward, recomendado na aplicação de previsão de variáveis hidro-meteorológicas (Dawson et al, 2002; Partal e Kisi, 2007; S.-P. Yu et al, 2013). O modelo fez uso de apenas um neurônio (unidade de aprendizado do modelo) com o número de camadas inferiores sempre igual a quantidade dos dados de entrada, evitando-se o overfitting<sup>5</sup>, mais detalhes ver em (Dawson e Wilby, 2001). A função de ativação aplicada na unidade de aprendizado foi a Sigmóide através do algoritmo de Levenberg-Marquardt backpropagation (Dawson e Wilby, 2001; Dawson et al, 2002; Wilby et al, 2004). O modelo RNA aplicado considerou as seguintes fases: treinamento, validação e teste (calibração) dos dados de saída, para uma melhor representação dos dados observados, seguindo os arranjos descritos em Paz et al (2011). Todos os testes foram conduzidos em ambiente MatLab®, através do toolbox de redes neurais.

## 3 RESULTADOS

### 3.1 Regiões Homogêneas

Pela aplicação da ACP, foi possível uma avaliação inicial dos padrões de variabilidade da precipitação na região. As 3 primeiras Componentes Principais (CP) representam cerca 69,5% da variabilidade da chuva acumulada entre maio e julho (**Tabela 3.1**).

**Tabela 3.1 - Variabilidade Explicada pela ACP.**

Componentes Principais	1º Eixo	2º Eixo	3º Eixo
Variância (%)	46,67%	14,68%	8,15%

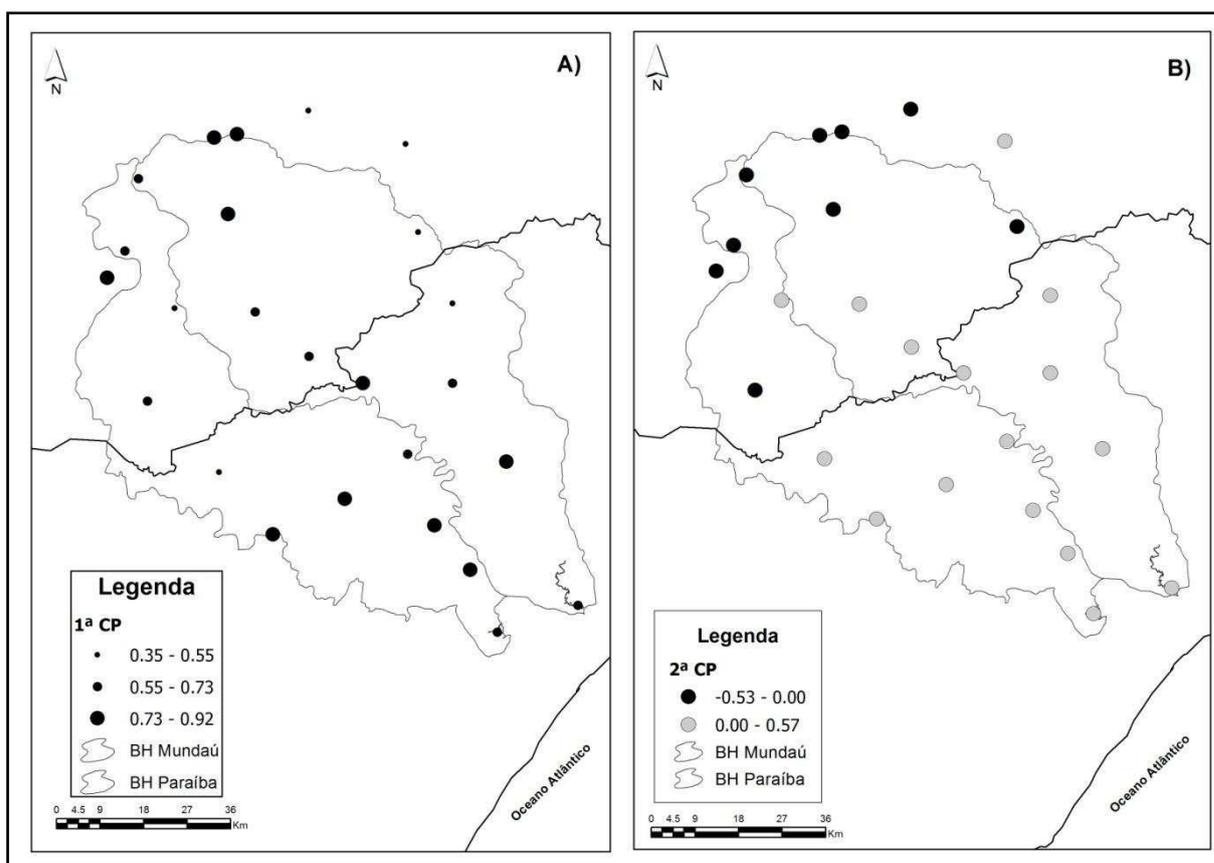
Fonte: Elaborado pelo autor (2013).

---

<sup>5</sup> Quando um modelo se ajusta em demasiado a um conjunto de dados, apresentando altas correlações, mas não terá capacidade de generalizar a informação fora da faixa observada da amostra (Dawson e Wilby, 2001).

A ACP identificou uma divisão clara de dois regimes distintos de variabilidade nas precipitações do trimestre mais chuvoso na região. Os autovalores da primeira componente apresentaram valores positivos para todas as estações pluviométricas (**Figura 3.1-a**), com valores mais elevados na parte baixa da bacia (região mais úmida) e na parte alta da bacia (região mais seca). Valores predominantemente mais baixos dos autovalores da primeira componente foram encontrados na porção central (região de transição climática) da região de estudo. Os autovalores da segunda componente apresentaram valores positivos e negativos (**Figura 3.1-b**), com uma separação clara de domínio ao longo da região, predominando os valores positivos na parte baixa e os valores negativos na parte alta, para a porção central da área de estudo houve uma variação entre valores positivos e negativos devido a existência de uma transição de clima e bioma nessa região, conhecida como Agreste.

**Figura 3.1 - a) Autovalores para a 1ª CP, destacando os maiores valores nas extremidades da região; b) Autovalores da 2ª CP, evidenciando de forma clara a separação dos postos.**

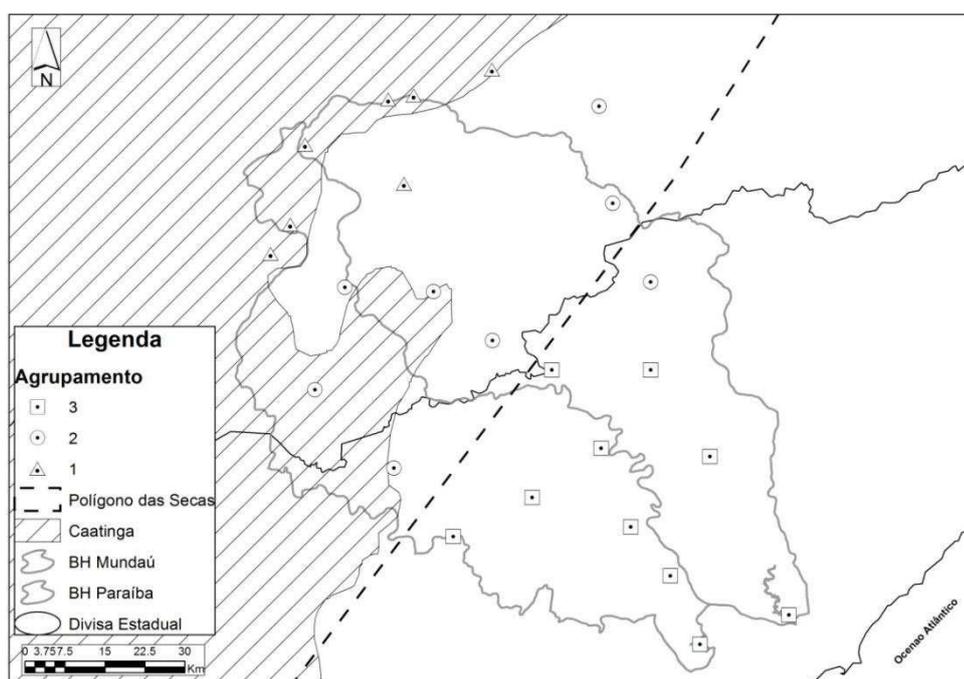


Fonte: Elaborado pelo autor (2013).

A Análise de Agrupamento, que foi elaborada a partir da reconstituição do sinal da precipitação para os 25 postos e utilizando as duas primeiras componentes da ACP, permitiu a

separação das estações pluviométricas em três grupos espaciais com padrões similares de variabilidade temporal em relação ao total acumulado precipitado em MJJ (**Figura 3.2**). O Grupo 1 é constituído por estações pluviométricas localizadas na parte alta da bacia, sendo a maioria dos postos inseridos no bioma Caatinga. Fazem parte do Grupo 2 estações localizadas na parte média da bacia, que apresenta um bioma de transição e está inserida no polígono das secas. O Grupo 3 inclui postos fora do polígono das secas que fazem parte do bioma mata atlântica.

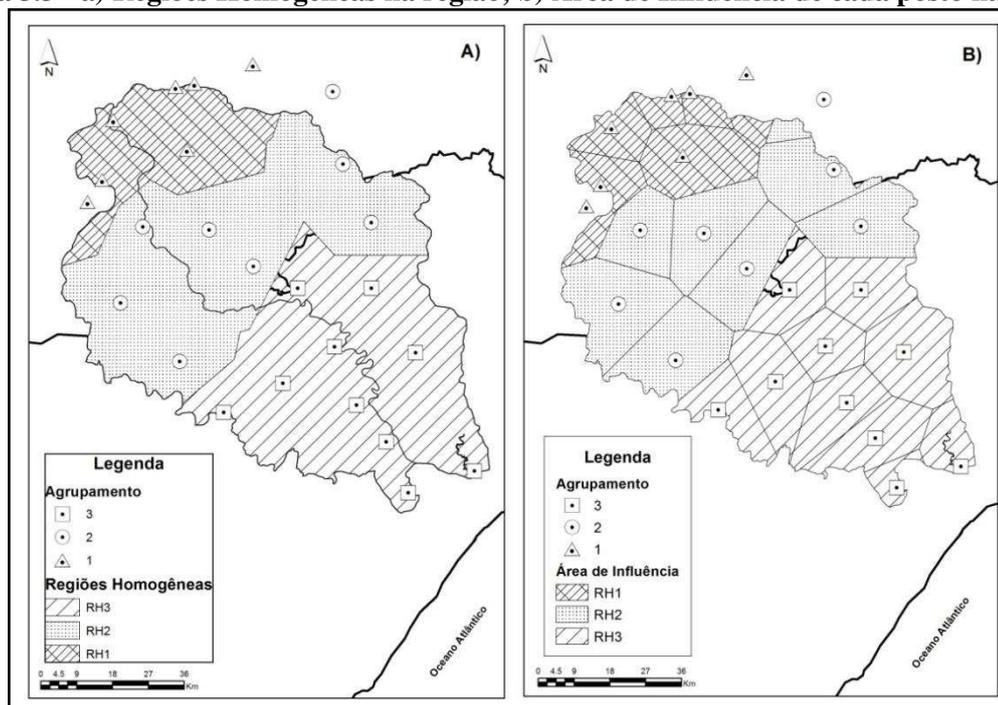
**Figura 3.2 - Agrupamento das estações pluviométricas na região.**



Fonte: Elaborado pelo autor (2013).

As regiões homogêneas (RH1, RH2 e RH3) de precipitação foram definidas a partir da Análise de Agrupamento (**Figura 3.3-a**). A **Figura 3.3-b** mostra a área de influência de cada posto contido em cada RH na área de estudo.

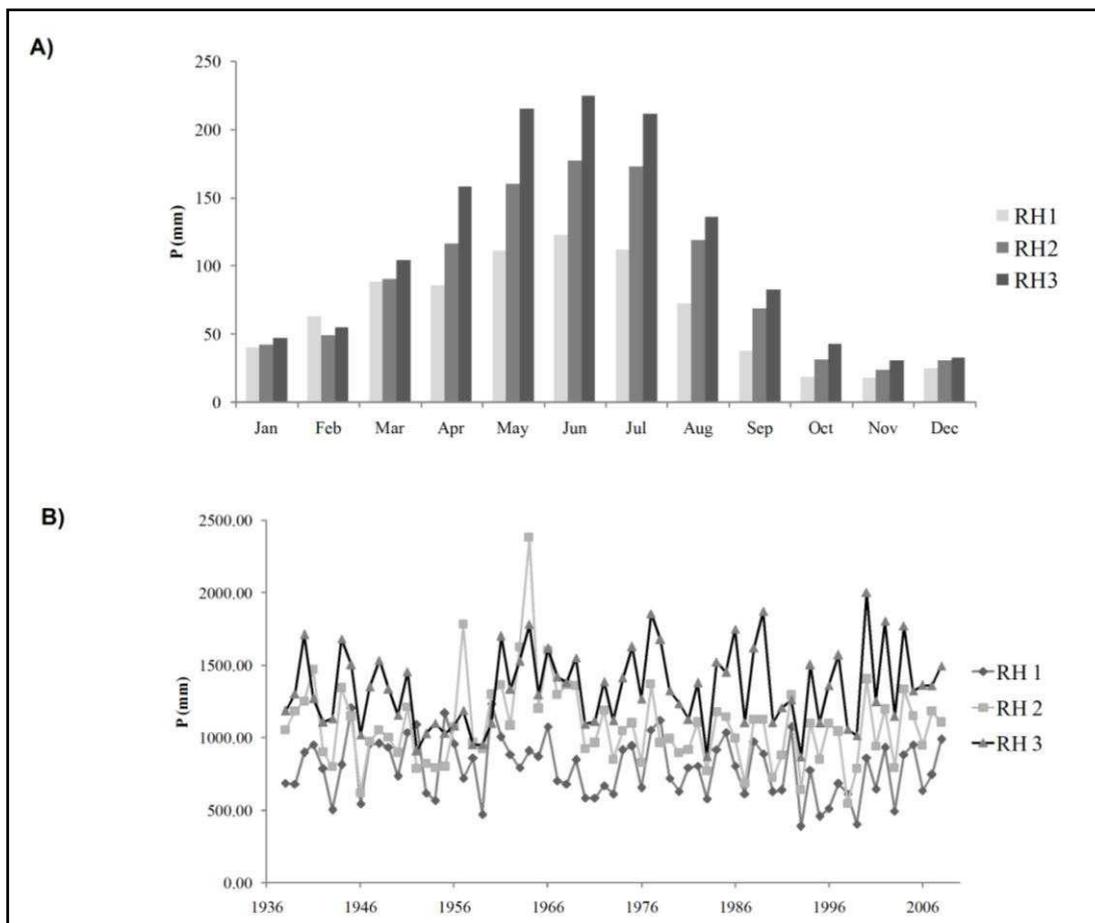
Figura 3.3 - a) Regiões Homogêneas na região; b) Área de Influência de cada posto na região.



Fonte: Elaborado pelo autor (2014).

A RH1 apresenta a menor precipitação anual média, com cerca de 793 mm/ano, seguido da RH2 com 1,079 mm/ano e RH3 com 1,339 mm/ano. A **Figura 3.4** mostra um resumo das precipitações médias obtidas por RH através da aplicação de Polígonos de Thiessen.

**Figura 3.4 - a) Regime pluviométrico médio mensal para cada RH; b) Precipitação média anual para cada RH.**



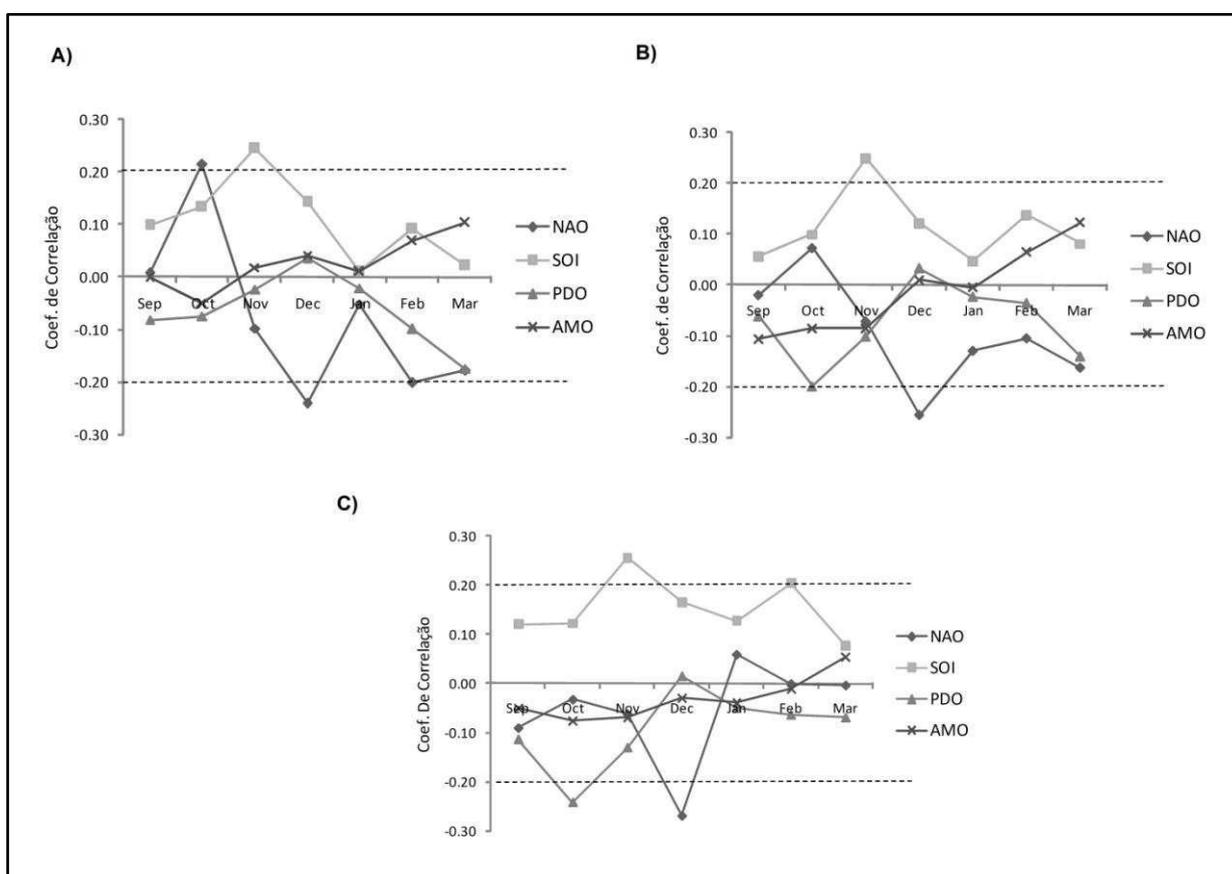
Fonte: Elaborado pelo autor (2014).

### 3.2 Teleconexões

Os valores de correlação de Pearson (linear) entre os índices climáticos e a precipitação de MJJ foram mais significativos do que os valores obtidos pela correlação de Spearman. Desta forma, a correlação de Pearson foi utilizada para uma avaliação preliminar do grau de correspondência entre as variáveis envolvidas. A **Figura 3.5** mostra as correlações lineares entre os índices climáticos e a precipitação acumulada em MJJ para cada RH. O índice IOS apresentou correlação positiva com a precipitação acumulada em MJJ para todas as RH, sendo novembro o mês de maior correlação em todas as RH. O índice OAN apresentou oscilação entre valores positivos e negativos da correlação com a precipitação de MJJ ao longo dos meses nas RH, sendo dezembro o mês de maior valor, em módulo, de correlação para todas as RH. O índice OMA também apresentou valores de correlações variando entre negativas e positivas nas RH. Porém tais correlações não foram significativas em nenhuma das regiões e em nenhum dos meses. O índice ODP não apresentou um padrão definido de

variabilidade das correlações ao longo dos meses. O mês de outubro apresentou correlações significativas para as RH2 e RH3, no entanto nenhuma correlação significativa foi encontrada para a RH1.

**Figura 3.5 - a) Coeficiente de correlação linear mensal para RH 1; b) Coeficiente de correlação linear mensal para RH 2; c) Coeficiente de correlação linear mensal para RH3. A linha tracejada equivale ao coeficiente de correlação com 95% de confiança definido na distribuição T-Student, pontos acima e/ou abaixo da linha apresentam correlações significativas ao nível de 5%.**

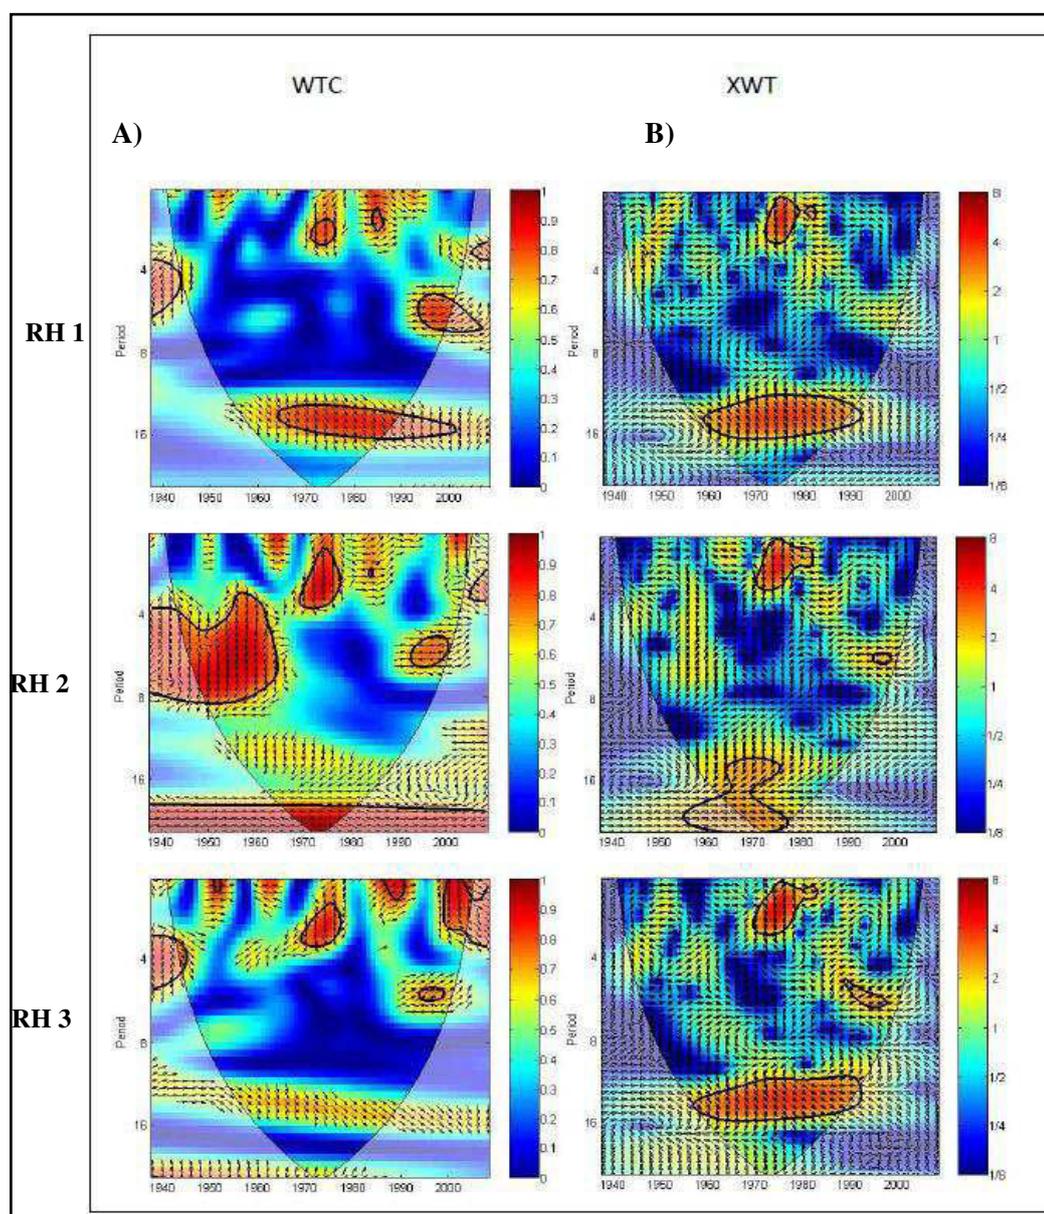


Fonte: Elaborado pelo autor (2013).

As análises de Wavelets (Coerência e Cruzada) indicaram uma relação de interferência mais intensa entre o índice IOS em novembro e a precipitação de MJJ para todas as regiões, assim como observado anteriormente na análise de correlação de Pearson (**Figura 3.6**). A Coerência Wavelets (WCT) destacou uma covariância positiva e significativa entre as séries temporais analisadas para as frequências temporais na faixa interanual de 1 a 3 anos, durante o período de 1970 a 1980 em todas as RH. Além disso, foi observado uma co-variância positiva e significativa para escalas temporais maiores (de 10 a 16 anos entre 1960 à 2000),

sobretudo na RH1. A análise de Wavelet Cruzada (XWT) mostrou altos valores de espectro de potência, em fase, para todas as regiões nas escalas temporais interanuais (1-3 anos) entre 1970 a 1980 e também nas escalas de 10 a 16 anos entre 1960 a 1990, indicando uma forte interferência do IOS de novembro sobre as precipitações de MJJ em todas as regiões.

**Figura 3.6 - a) Análise WTC entre a série temporal do índice IOS-novembro e a Precipitação de MJJ, mostrando que os dados se encontram em fase. b) Análise XWT entre IOS-novembro e Precipitação de MJJ, dados em fase. Nível de significância a 5% destacado na área circulada. A relação é dita em fase, se os vetores estão no sentido para a direita, correlação positiva. A relação é dita em não-fase se os vetores estão no sentido para a esquerda, correlação negativa.**

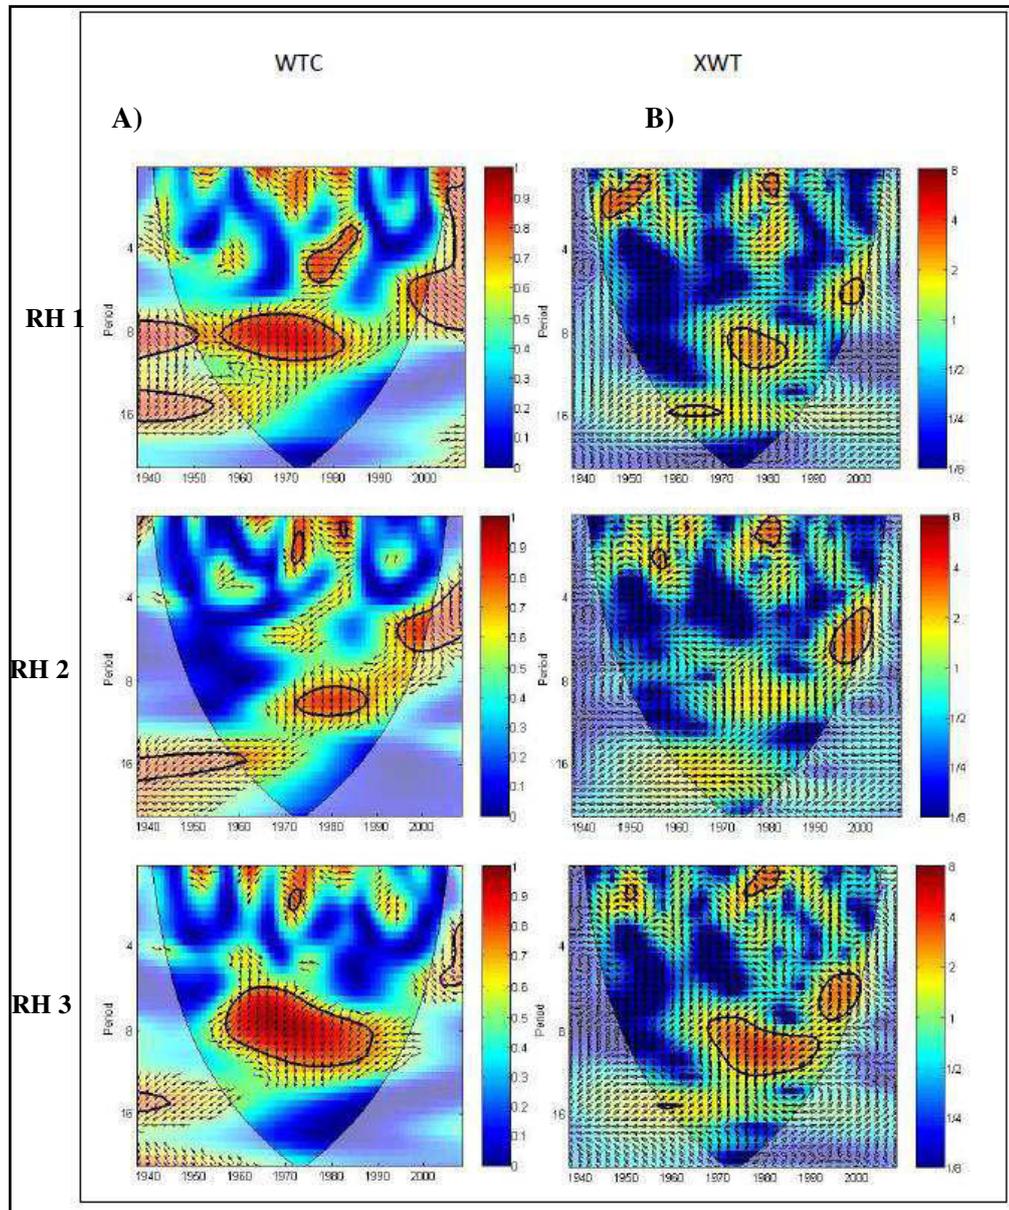


Fonte: Elaborado pelo autor (2013).

As análises de Wavelets indicaram uma relação de interferência mais intensa entre o índice OAN em dezembro e a precipitação de MJJ para todas as regiões, assim como observado anteriormente na análise de correlação de Pearson (**Figura 3.7**). A Coerência Wavelets (WCT) destacou uma covariância negativa e significativa entre as séries temporais analisadas para as frequências temporais na faixa de 6 a 10 anos, durante o período de 1960 a 1990 em todas as RH. Além disso, foi observado covariâncias significativas na faixa interanual de 1 a 2 anos entre 1970 a 1980 para RH2 e RH3. A análise de Wavelet Cruzada (XWT) mostrou altos valores de espectro de potência para todas as regiões nas escalas temporais interanuais (1-2 anos) entre 1950 a 1960 e 1980 a 1990 e também nas escalas de 6 a 10 anos entre 1970 a 1990 principalmente na RH1 e RH3, indicando uma forte interferência da OAN de dezembro sobre as precipitações de MJJ em todas as regiões e com diferentes períodos.

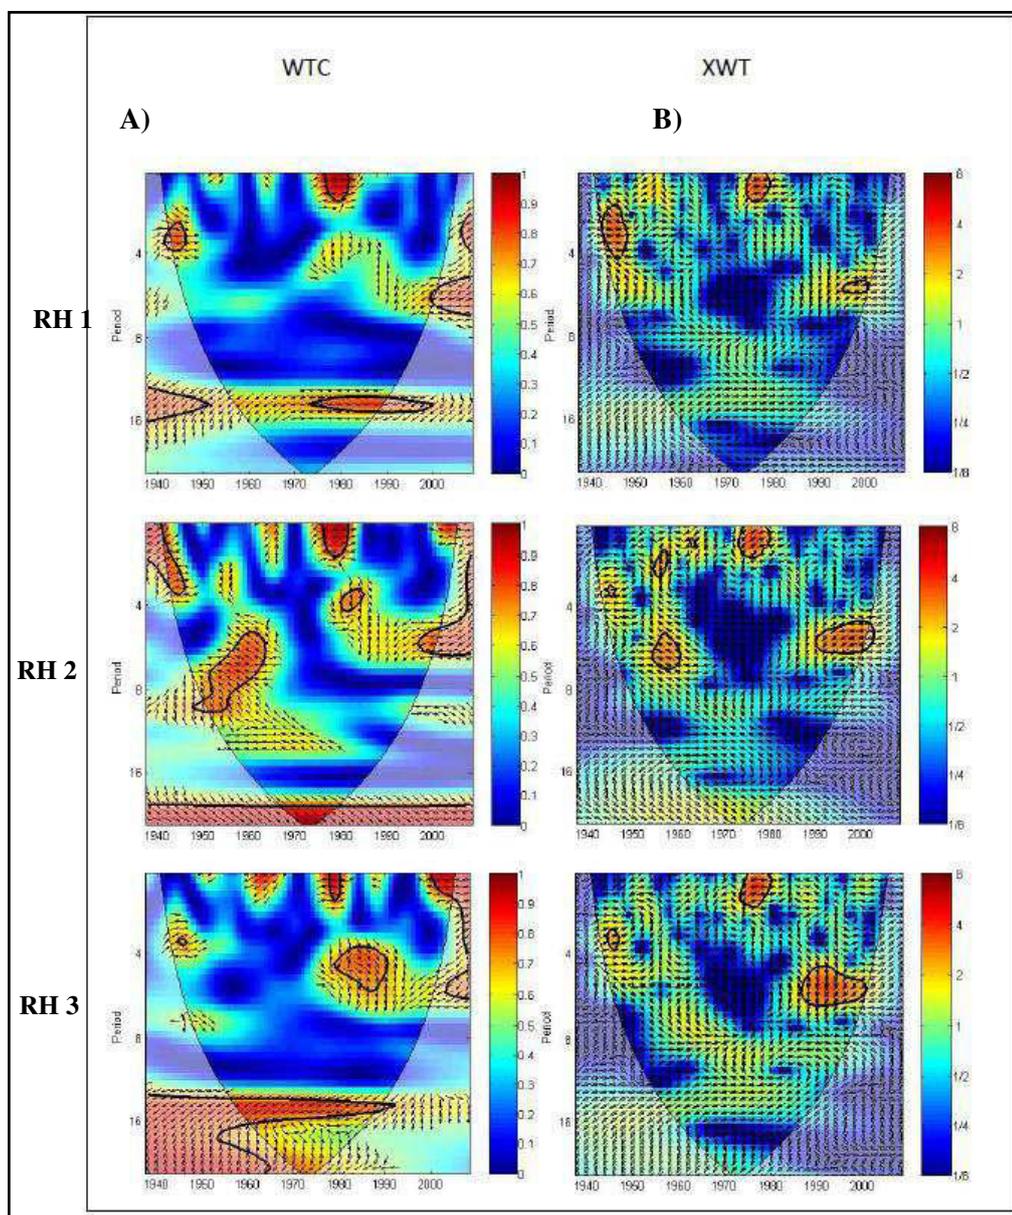
As análises de Wavelets indicaram uma relação de interferência mais intensa entre o índice ODP em novembro e a precipitação de MJJ para todas as regiões (**Figura 3.8**). A Coerência Wavelets (WCT) destacou uma covariância positiva e significativa e em fase entre as séries temporais analisadas para as frequências temporais na faixa de 1 a 2 anos, durante o período de 1960 a 1990 em todas as RH. Além disso, foi observado covariâncias significativas em não-fase para escalas temporais maiores, para RH1 entre 13 a 16 anos, para RH2 entre 5 a 9 anos e para a RH3 períodos acima de 14 anos. A análise de Wavelet Cruzada (XWT) mostrou altos valores de espectro de potência, em fase, para todas as regiões nas escalas temporais interanuais (1-2 anos) entre 1970 a 1980 e também similaridade em não-fase nas escalas de 5 a 7 anos entre 1970 a 1990 em todas as regiões, indicando uma interferência da ODP de novembro sobre as precipitações de MJJ em todas as regiões.

Figura 3.7 - a) Análise WTC entre a série temporal do índice OAN-dezembro e a Precipitação de MJJ, mostrando que os dados se encontram em não-fase. b) Análise XWT entre OAN-dezembro e Precipitação de MJJ, dados em não-fase. Nível de significância a 5% destacado na área circulada.



Fonte: Elaborado pelo autor (2013).

Figura 3.8 - a) Análise WTC entre a série temporal do índice ODP-novembro e a Precipitação de MJJ. b) Análise XWT entre ODP-novembro e Precipitação de MJJ, dados em não-fase. Nível de significância a 5% destacado na área circulada.

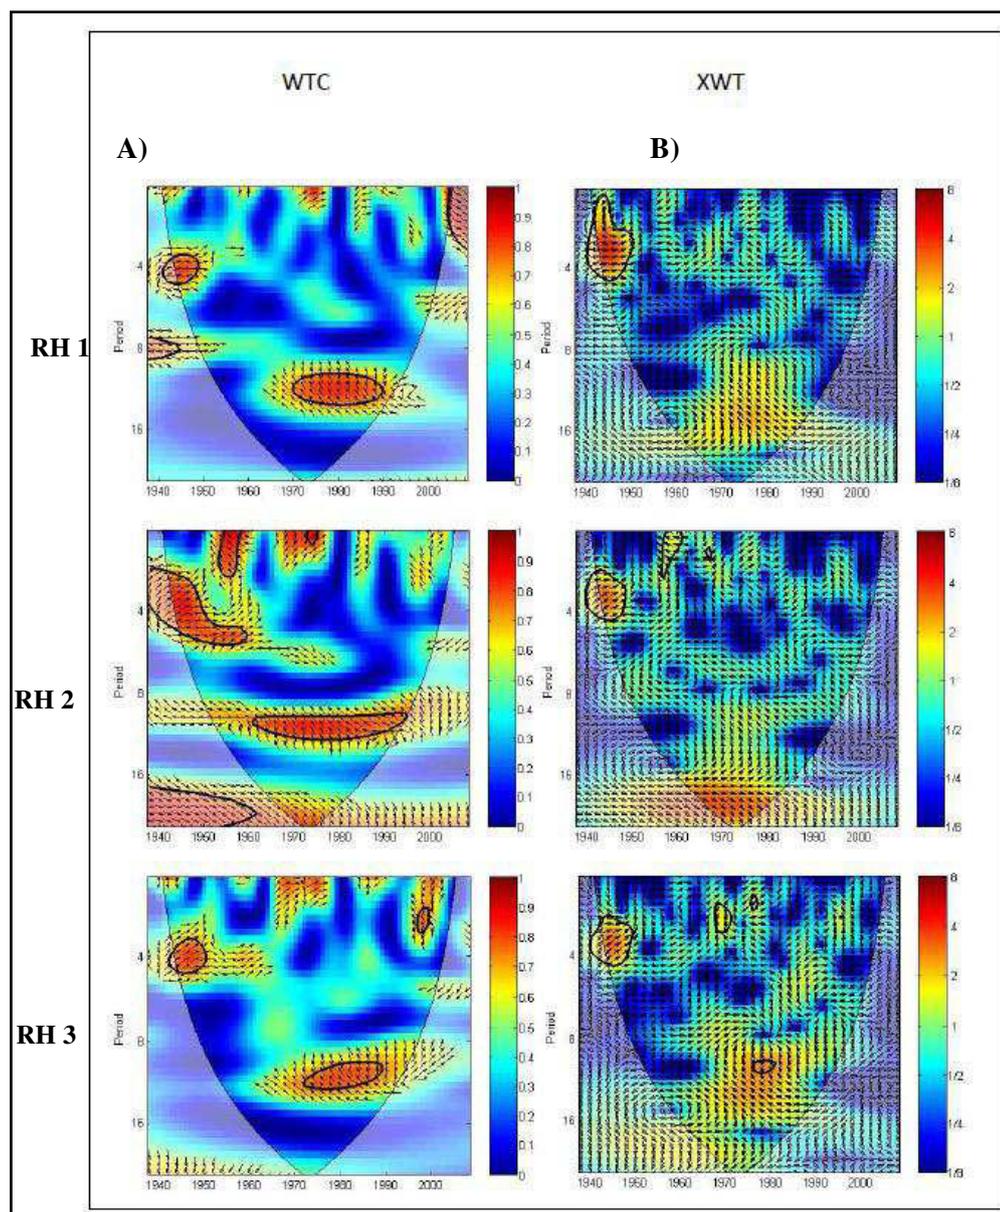


Fonte: Elaborado pelo autor (2013).

As análises de Wavelets indicaram uma relação de interferência mais intensa entre o índice OMA em março e a precipitação de MJJ para todas as regiões (**Figura 3.9**). A Coerência Wavelets (WCT) destacou uma covariância negativa significativa entre as séries temporais analisadas para as frequências temporais na faixa de 9 a 14 anos, durante o período de 1970 a 1990 em todas as RH. Além disso, foi observado uma co-variância positiva significativa para escalas temporais de até 4 anos após 1940 em todas as regiões. A análise de Wavelet Cruzada (XWT) mostrou altos valores de espectro de potência, em fase, para todas as

regiões nas escalas temporais de até 4 anos após 1940, como destacado na WTC; para escalas temporais maiores, entre 9 a 16 anos, de 1970 a 1990 as similaridades não foram significativas nas regiões, a interferência da OMA sobre as precipitações de MJJ em todas as regiões não foram significativas se comparados aos demais índices climáticos analisados.

**Figura 3.9 - a) Análise WTC entre a série temporal do índice OMA-março e a Precipitação de MJJ. b) Análise XWT entre OMA-março e Precipitação de MJJ, dados em não-fase. Nível de significância a 5% destacado na área circulada.**



Fonte: Elaborado pelo autor (2013).

A **Tabela 3.2** apresenta um resumo da seleção dos potenciais preditores da precipitação de MJJ para cada RH, os quais foram obtidos após as análises de correlação linear e de Wavelets. Observa-se que o tempo de resposta de alguns índices climáticos na

precipitação é de 5 a 6 meses antes do período chuvoso como, por exemplo, o IOS (novembro) e o OAN (dezembro), possibilitando uma razoável antecedência de previsão.

**Tabela 3.2 - Resumo dos índices climáticos selecionados**

Região	Índice Climático	Mês
RH1	IOS	Novembro
	OAN	Dezembro
	ODP	Novembro
	OMA	Março
RH2	IOS	Novembro
	OAN	Dezembro
	ODP	Novembro
	OMA	Março
RH3	IOS	Novembro
	OAN	Dezembro
	ODP	Novembro
	OMA	Março

Fonte: Elaborado pelo autor (2014).

### 3.3 Previsão

Para a avaliação de previsão da precipitação de MJJ na área de estudo por meio da aplicação de RNA, foi tomado como variáveis de entrada três diferentes combinações dos índices climáticos. A primeira utilizando todos os índices climáticos selecionados no item anterior (IOS, OAN, ODP e OMA). A segunda combinação utilizou os índices IOS, OAN e ODP, uma vez que o índice OMA não apresentou relação de interferência significativa na precipitação de MJJ quando comparados aos demais índices. E o terceiro arranjo foi composto por apenas os índices IOS e OAN, sendo esses os que apresentaram as melhores relações de interferências e maiores antecedências para a previsão da precipitação no período chuvoso. Para cada arranjo foram realizadas 10 simulações do modelo RNA, onde a média e o desvio padrão dos coeficientes de correlação foram calculados para avaliar a estabilidade do modelo RNA na previsão.

A **Tabela 3.3** apresenta os coeficientes de correlação encontrados na RH1. O terceiro e mais simples arranjo apresentou os melhores ajustes, principalmente na etapa de testes, onde em média foi obtido um  $R = 0,72$ . No geral o desvio-padrão foi baixo, o que caracteriza o

bom desempenho da RNA em encontrar padrões de relação entre índices climáticos e a precipitação de MJJ na RH1.

**Tabela 3.3 - Coeficiente de correlação para os diferentes modelos de entrada na previsão da RH1.**

RH1	Entrada	Tipo	R - médio	DV
	IOS, OAN, ODP e OMA		Treinamento	0,68
Validação			0,62	0,12
Teste			0,64	0,07
Global			0,65	0,04
IOS, OAN, ODP		Treinamento	0,64	0,04
		Validação	0,66	0,05
		Teste	0,65	0,07
		Global	0,64	0,03
IOS, OAN		Treinamento	0,66	0,08
		Validação	0,64	0,06
		Teste	0,72	0,04
		Global	0,66	0,05

Fonte: Elaborado pelo autor (2014).

A **Tabela 3.4** apresenta os coeficientes de correlação encontrados na RH2. O terceiro e mais simples arranjo apresentou os melhores ajustes, principalmente na etapa de testes, onde em média foi obtido um  $R = 0,68$ . No geral o desvio-padrão foi baixo, o que caracteriza o bom desempenho da RNA em encontrar padrões de relação entre índices climáticos e a precipitação de MJJ na RH2.

**Tabela 3.4 - Coeficiente de correlação para os diferentes modelos de entrada na previsão da RH2.**

RH2	Entrada	Tipo	R - médio	DV
	IOS, OAN, ODP e OMA		Treinamento	0,69
Validação			0,63	0,12
Teste			0,60	0,06
Global			0,66	0,05
IOS, OAN, ODP		Treinamento	0,64	0,04
		Validação	0,59	0,10
		Teste	0,62	0,10
		Global	0,62	0,02

IOS, OAN	Treinamento	0,76	0,08
	Validação	0,71	0,09
	Teste	0,68	0,04
	Global	0,73	0,06

Fonte: Elaborado pelo autor (2014).

A **Tabela 3.5** apresenta os coeficientes de correlação encontrados na RH3. O terceiro e mais simples arranjo apresentou os melhores ajustes, principalmente na etapa de testes, onde em média foi obtido um  $R = 0,76$ . No geral o desvio-padrão foi baixo, o que caracteriza o bom desempenho da RNA em encontrar padrões de relação entre índices climáticos e a precipitação de MJJ na RH3.

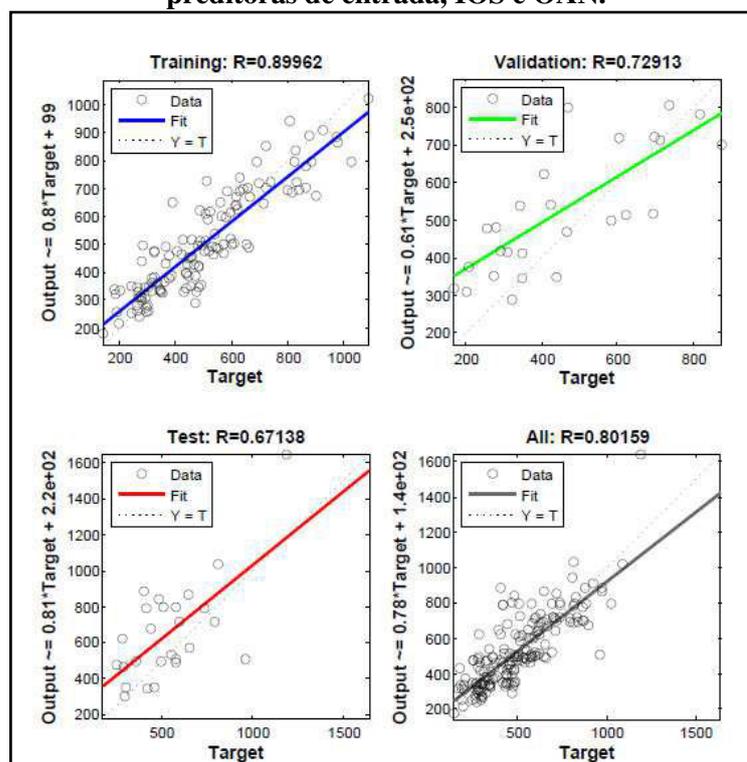
**Tabela 3.5 - Coeficiente de correlação para os diferentes modelos de entrada na previsão da RH3.**

RH3	Entrada	Tipo	R - médio	DV
	IOS, OAN, ODP e OMA		Treinamento	0,75
Validação			0,66	0,08
Teste			0,67	0,05
Global			0,71	0,06
IOS, OAN, ODP		Treinamento	0,66	0,05
		Validação	0,68	0,06
		Teste	0,68	0,07
		Global	0,66	0,04
IOS, OAN		Treinamento	0,75	0,08
		Validação	0,74	0,09
		Teste	0,76	0,05
		Global	0,74	0,06

Fonte: Elaborado pelo autor (2014).

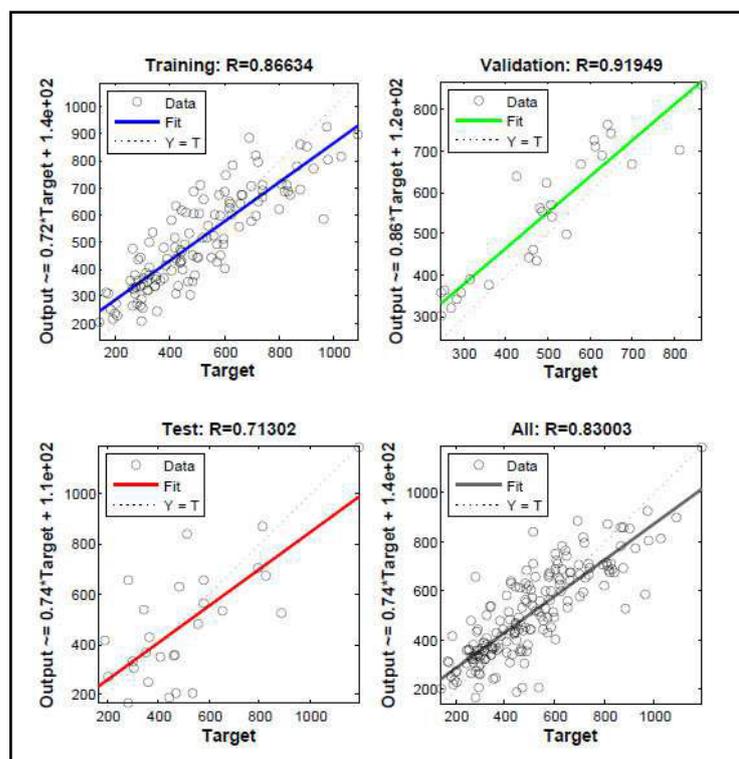
Para as três combinações analisadas, percebe-se que ao se utilizar uma configuração de predição com apenas o IOS e o OAN foram obtidos os melhores resultados. Os resultados ainda sugerem que a RH2 possui uma previsibilidade mais baixa se comparado à RH1 e RH3, o que pode está associado a região de transição onde RH2 se insere. A RH3, região sob influência litorânea, por sua vez, foi a região de maior previsibilidade. As **Figura 3.10** a **Figura 3.12** apresentam os melhores ajustes encontrados na RNA para cada região.

Figura 3.10 - Melhor ajuste para a previsão hidrológica na RH1 a partir da RNA. Variáveis predictoras de entrada, IOS e OAN.



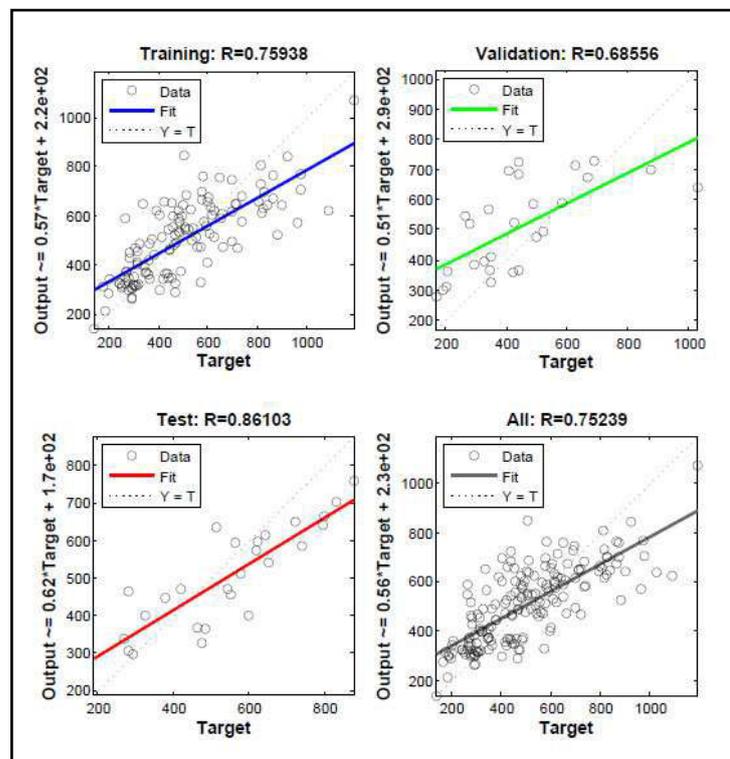
Fonte: Elaborado pelo autor (2014).

Figura 3.11 - Melhor ajuste para a previsão hidrológica na RH2 a partir da RNA. Variáveis predictoras de entrada, IOS e OAN.



Fonte: Elaborado pelo autor (2014).

**Figura 3.12 - Melhor ajuste para a previsão hidrológica na RH3 a partir da RNA. Variáveis predictoras de entrada, IOS e OAN.**



Fonte: Elaborado pelo autor (2014).

## 4 DISCUSSÕES

As regiões climáticas nas bacias dos rios Mundaú e Paraíba (clima de aspecto semiárido na parte alta e tropical úmido na parte baixa) explicam grande parte do gradiente nas precipitações encontrado da região de estudo, como destacou a primeira componente da ACP. A heterogeneidade de biomas e barreiras topográficas criadas pelo Planalto da Borborema são fatores que também influenciam a precipitação de MJJ da região de estudo, conforme destacado na segunda componente da ACP. Tais fatores também se mostraram importantes na descrição da variabilidade espaço-temporal da precipitação do nordeste e outras regiões (Uvo e Berndtsson, 1996; Uvo, 2003).

O agrupamento das estações pluviométricas em regiões homogêneas (RH) se mostrou diretamente associado aos biomas presentes na região de estudo. O grupo 1 está completamente inserido na área de caatinga, onde as estações pluviométricas dessa RH possuem os menores valores de precipitação anual acumulada. O grupo 2 está dentro da região denominada Polígono das Secas, onde as estações dessa região estão sob influência da

transição natural entre os dois biomas presentes, cuja área é fortemente influenciada pela formação do planalto da Borborema. As regiões altas deste planalto apresentam clima úmido e presença da mata atlântica, enquanto é encontrado um clima semiárido e formação caatinga nas áreas ao centro e oeste do planalto. O Grupo 3 está inserido quase que em totalidade na região da zona da mata, onde as estações apresentam os maiores índices pluviométricos.

A análise de correlações lineares destacou uma correlação significativa da precipitação de MJJ nas RH com os índices climáticos de variabilidade interanual como o IOS em novembro e o OAN em dezembro. Os valores negativos do IOS estão associados ao fenômenos El Niño, já os valores positivos ao La Niña, assim uma correlação positiva do índice IOS com a chuva nas RH era esperada, uma vez que o El Niño (La Niña) está associado a diminuições (acrécimos) nos regimes pluviométricos do nordeste brasileiro (Uvo et al, 1994; Cirilo et al, 2007; Molion e Bernardo,2002). Correlações negativas entre as anomalias do índice OAN e da precipitação no período chuvoso geralmente são esperadas no hemisfério norte, já que anomalias negativas (positivos) do OAN estão associados a um resfriamento (aquecimento) das águas no Atlântico, responsáveis por acréscimos (diminuição) nas chuvas do hemisfério norte (Trigo et al, 2002). Tal padrão também foi observado no Brasil, com relações de precipitação do sudeste (Allasia, 2007; Paz et al, 2011), e nordeste (Kayano e Andreoli, 2004). Os índices ODP e o OMA não apresentaram correlações significativas com a precipitação de MJJ, já que tais índices geralmente possuem efeitos em escalas temporais decadais e uma análise de correlação simples aplicada à séries temporais anuais não se mostra adequada para evidenciar fenômenos nessa escala de tempo.

A análise Wavelets entre o IOS em novembro e a precipitação de MJJ indicou uma forte influência de fenômenos El Niño e La Niña em todas as RH. A análise sugere que a chuva nessa região está associada as condições do Pacífico tropical, onde todas as regiões possuem uma relação de associação significativa do IOS com a precipitação de MJJ em multi-escalas temporais (Da Silva, 2009). Estudos anteriores também já destacaram o efeito de fenômenos de El Niño e La Niña na variabilidade interanual das precipitações no Nordeste do Brasil (Andreoli et al., 2004, apud Da Silva, 2009; Da Silva et al, 2010; Cirilo et al., 2007).

A análise Wavelets entre o índice OAN e a precipitação de MJJ indica que a chuva de MJJ nessa região também é influenciada pelas condições do Atlântico. Alguns estudos também indicaram a existência de uma forte correlação das chuvas do Nordeste do Brasil com o Atlântico (Uvo et al 1998, Andreoli e Kayano, 2006). As anomalias de temperaturas no

Oceano Atlântico (Andreoli e Kayano ,2007 apud Da Silva, 2009) e eventos La Niña em maior intensidade (Trigo et al., 2002) são fatores que podem favorecer a relação entre OAN e a precipitação nessa região.

O índice ODP apresentou uma relação de associação significativa em escalas temporais interanuais e em escalas maiores (de 5 a 7 anos) com a precipitação nas RH. Apesar de estudos apontarem que anomalias da ODP não possam modular significativamente condições de chuva no Nordeste do Brasil (Xavier e Xavier, 2004), foi observado que o índice ODP pode influenciar a variabilidade da chuva em escalas temporais maiores no hemisfério sul (Labat, 2010). Uma possível explicação da associação do ODP com a chuva de MJJ na área de estudo é que possivelmente existe uma relação indireta deste índice com fenômenos associados ao índice IOS. Por exemplo, Andreoli e Kayano (2005) apud Da Silva (2009) indicam que durante uma fase positiva do ODP, fenômenos El Niño são mais frequentes e intensos. Na fase negativa do ODP, fenômenos La Niña passam a serem mais frequentes e intensos.

O OMA de março apresentou uma menor força de associação com a precipitação de MJJ em todas as RH, em comparação com os outros índices climáticos. Knight et al (2006) encontraram evidências que a OMA interfere nos padrões de precipitação do Nordeste do Brasil, provocando mudanças nos padrões da Zona de Convergência Intertropical em escalas multidecenais e conseqüente diminuição nas precipitações médias da região, o que não foi observado na região de estudo. A covariância encontrada entre as séries temporais nessas escalas temporais não é significativa para evidenciar uma possível relação de associação. Tais relações foram observadas em escalas interanuais para todas as RH, sugerindo uma possível influência do OMA em fenômenos relacionados ao OAN no Atlântico, conforme visto em Walter e Graf (2002).

Apesar de modelos empíricos não terem compromisso de representar o comportamento físico dos processos envolvidos no fenômeno de interesse (Bravo (2010)), o modelo estocástico de previsão de precipitação de longo prazo na área de estudo baseado em RNA apresentou uma melhor performance ao utilizar como entrada índices climáticos que explicam mais adequadamente os mecanismos físicos envolvidos no problema. A qualidade dos ajustes encontrados pode ser considerada satisfatória para o propósito de previsão de precipitação de longo prazo, como observado em outros trabalhos (e.g. Bravo, 2010). Os melhores resultados para todas as RH foram obtidos com o uso do terceiro arranjo, que

considera apenas os índices climáticos IOS e OAN. Tais preditores demonstraram relações diretas com a precipitação de MJJ. Os arranjos que envolvem os índices ODP e OMA apresentaram perdas no desempenho do modelo de previsão, o que pode caracterizar uma interferência dessas variáveis na previsão da precipitação de MJJ. Os resultados também apresentaram desempenhos satisfatórios considerando a configuração da rede utilizada, onde a quantidade de neurônios não excedeu a quantidade de variáveis de entrada. Os valores médios dos ajustes encontrados não variaram significativamente em relação às fases de treinamento, validação e verificação do modelo, indicando uma satisfatória capacidade de previsão para diferentes períodos (Bravo, 2010; Paz et al, 2011).

## **5 CONCLUSÕES E RECOMENDAÇÕES**

Em bacias hidrográficas, diversas atividades estão condicionadas aos regimes de precipitação e conseqüentemente as variabilidades no clima. O conhecimento das condições hidrológicas em um dado período, seco ou úmido, é uma informação útil para a gestão da infraestrutura hídrica local, o que justifica a importância de desenvolver e aperfeiçoar técnicas de previsão hidrológica, com objetivo de traçar horizontes, diminuir riscos e aproveitar condições favoráveis.

Uma etapa chave para a previsão hidro-climática, e destacada nesse trabalho, foi a determinação e seleção das variáveis preditoras. Para previsões de períodos específicos como proposto, índices climáticos foram selecionados como candidatos potenciais, pois representam as principais condições em variabilidade climática, teleconexões e/ou interdependência com os eventos de precipitação na região do estudo.

A análise do período de maior concentração pluviométrica na região, de maio a julho, utilizando ACP e Análise de Agrupamento, destacou que as principais causas da variabilidade da precipitação nesses meses para a região de estudo estão associadas aos distintos climas presentes nas bacias, semiárido e tropical úmido, assim como seus biomas, caatinga e mata atlântica e as condições físicas e geográficas da região, com destaque a formação do Planalto da Borborema, juntamente aos modos de variabilidade atmosférica que atuam na região.

Os resultados obtidos na análise de Wavelets entre as séries temporais dos índices climáticos IOS e OAN e a precipitação de MJJ, destacaram que as condições dos oceanos

Pacífico e Atlântico influenciam nas variabilidades interanuais da precipitação de MJJ. Além disso variações atmosféricas em grande escala temporal promovem impactos significativos nos regimes hidrológicos das RH da área de estudo.

O modelo estocástico de previsão de precipitação de longo prazo se mostrou uma ferramenta promissora para a solução dos problemas hidro-meteorológicos na escala regional (bacia hidrológica), apresentando um coeficiente de determinação médio igual a 0,76. Este modelo possibilita o planejamento de ações mitigadoras no período chuvoso com 5 meses de antecedência em relação ao início do período chuvoso, podendo ser utilizado em uma avaliação prévia de futuras previsões de anomalias nas precipitação da região. Importante aplicação para as condições locais das bacias estudadas, que têm grande vocação à agricultura, seja familiar e/ou de subsistência e também ao setor sucroalcooleiro, possibilitando ao agricultor e empresas um planejamento prévio. Além de ser mais uma ferramenta somada aos aparatos governamentais em avaliar as possibilidades de eventos extremos de cheias, o qual têm causado danos irreparáveis às cidades inseridas nessa região.

Para trabalhos futuros, ficam as recomendações de se pesquisar outros candidatos a preditores hidro-climáticos na região, utilizar novas técnicas que avaliem as teleconexões como o método de decomposição de séries Transformada de Hilbert-Huang ou ainda outras funções Wavelets não aplicadas nesse estudo. Por fim, verificar novos métodos de previsão como lógica Fuzzy, além de outros arranjos em RNA, com entradas e/ou saídas diferentes, quantidade de neurônios e camadas inferiores, e principalmente outras equações para a função de ativação, na avaliação de treinamento, validação e calibração.

## REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Séries Históricas. HidroWeb - Sistema de Informações Hidrológicas**, 2005. Disponível em: <<http://hidroweb.ana.gov.br/>>. Acesso em: Junho de 2013.
- Allasia, DG. (2007). **Avaliação da previsão hidro-climática no Alto Paraguai**. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, Brasil, 208 p.
- BOWDEN, G. J., DANDY, G. C., & MAIER, H. R. (2005). **Input determination for neural network models in water resources applications. Part 1 - Background and methodology**. Journal of Hydrology (Amsterdam), 301, 75-92. doi:10.1016/j.jhydrol.2004.06.021
- BRAVO, J. M. **Subsídios à operação de reservatórios baseada na previsão de variáveis hidrológicas**. Universidade Federal do Rio Grande do Sul. Porto Alegre, p. 226. 2010. Tese submetida ao Programa de Pós Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental para obtenção do título de Doutor em Engenharia.
- CIRILO, J.A., CAMPELLO NETTO, M.S.C., MONTENEGRO, S.M.G.L., ASFORA, M.C. **Caracterização do Semi-Árido Brasileiro**. In: CIRILO, J.A., CABRAL, J.J.S.P., FERREIRA, J.P.C.L., OLIVEIRA, M.J.P.M., LEITÃO, T.E., MONTENEGRO, S.M.G.L., GÓES, V.C. O Uso Sustentável dos Recursos Hídricos em Regiões Semi-Áridas. Recife: Editora da Universidade - UFPE, 2007. Cap. 2, p. 48-52.
- 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.
- COSTA, D.D; FRAGOSO JR, C.R. **Variabilidade da Precipitação ocasainada por fatores climáticos - Influência de eventos El Niño e La Niña na bacia do rio Mundaú em PE/AL**. XI Simpósio de Recursos Hídricos do Nordeste. João Pessoa/PB, 2012.
- 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.

DA SILVA, D. F. **Análise de aspectos climatológicos, agroeconômicos, ambientais e de seus efeitos sobre a bacia hidrográfica do rio Mundaú (AL E PE)**, março de 2009, 212 p., Tese de Doutorado em Recursos Naturais, UFCG, Campina Grande (PB), 2009.

DA SILVA, D. F., SOUSA, F. A. S., KAYANO, M. T. **Escalas Temporais da Variabilidade Pluviométrica na bacia hidrográfica do rio Mundaú**. Revista Brasileira de Meteorologia, v.25, n.3, 324 - 332, 2010.

DAWSON, CW; WILBY, RL. (2001). **Hydrological modelling using artificial neural networks**. Progress in Physical Geography, v. 25(1), p. 80-108.

DAWSON, C. W., HARPHAM, C., WILBY, R. L., & CHEN, Y. (2002). **Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China**. Hydrology and Earth System Sciences, 6(4), 619–926. doi:10.5194/hess-6-619-2002.

DAWSON, C. W., & WILBY, R. L. (1998). **An artificial neural network approach to rainfall–runoff modelling**. Hydrological Sciences Journal, 43, 47–66. DOI:10.1080/02626669809492102.

FRENZEL, S., & POMPE, B. (2007). **Partial mutual information for coupling analysis of multivariate time series**. Physical Review Letters, 99(20), 204101. doi:10.1103/PhysRevLett.99.204101.

GALAMBOSI, A., OZELKAN, E. C., DUCKSTEIN, L. **The Impact of ENSO and macro-circulation patterns on precipitation under climate change**. Environmental Geology 58: 929-935 (2009), DOI 10.1007/s00254-008-1572-x.

GAMAGE, N., AND W. BLUMEN, 1993: **Comparative analysis of lowlevel cold fronts: Wavelet, Fourier, and empirical orthogonal function decompositions**. Mon. Wea. Rev., 121, 2867–2878.

GONG, D., WANG, S. 1998: **Antarctic Oscillation: concept and applications**. Chinese Science Bulletin, Vol. 43, No. 9, 734 - 738.

GRINSTAD, A., MOORE, J. C., AND 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.

GUÈGUAN, M., UVO, B.C., MADANI, K. **Developing a module for estimating climate warming effects on hydropower pricing in California.** Energy policy 42: 261-271 (2012), DOI:10.1016/j.enpol.2011.11.083.

HALLACK-ALEGRIA, M., RAMIREZ-HERNANDEZ, J., WATKINS, Jr. D. W. **ENSO - Conditioned rainfall drought frequency analysis in northwest Baja California, Mexico .** International Journal of Climatology 32: 831-842 (2012), DOI: 10.1002/joc.2310.

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.

INSTITUTO DE TECNOLOGIA DE PERNAMBUCO - ITEP. **Banco de dados pluviométrico.** Disponível em: <<http://www.itep.br/LAMEPE.asp>>. Acesso em: Dezembro de 2012.

JEVREJEVA, S., J. C. MOORE, AND A. GRINSTED, **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, 1993.

KAYANO, MT; ANDREOLI, RV. (2004). **Decadal variability of northern northeast Brazil rainfall and its relation to tropical sea surface temperature and global sea level pressure anomalies.** Journal Geophys. Res., v. 109, p. 21-32.

KAYANO, M. T; ANDREOLI R. V. **Relationships between rainfall anomalies over northeastern Brazil and the El Niño-Southern Oscillation.** Journal of Geophysical Research, v.111, D13102, doi:10.1029/2005JD006142, 2006.

KISI, O., SHIRI, J. **Precipitation Forecasting using Wavelets-Genetic Programming and Wavelet-Neuro-Fuzzy Conjunctions Models.** Water Resource Manage (2011) 25:3135–3152 DOI 10.1007/s11269-011-9849-3.

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

KOUTSOUYIANNIS, D., EFSTRATIADIS, A., NAMASSIS, N., & CHRISTOFIDES, A. (2008). **On the credibility of climate predictions.** Hydrological Sciences Journal, 53(4), 671-684. doi:10.1623/hysj.53.4.671.

- 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.
- LI, Z., KAFATOS, M. **Interannual Variability of Vegetation in the United States and its relation to El Niño/Southern Oscillation.** *Remote Sensing of Environment* 71: 239-247 (2000).
- LIN, G.-F., WU, M.-C. **A hybrid neural network model for typhoon-rainfall forecasting.** *Journal of Hydrology* 375 (2009) 450–458. Doi:10.1016/j.jhydrol.2009.06.047.
- MANTUA, N. J., HARE, S. R., ZHANG, Y., WALLACE, J. M., e FRANCIS, R. C. (1997). **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
- MARTIN-VIDE, J. **Spatial Distribution of a daily precipitation concentration index in Peninsular Spain.** *International Journal of Climatology* 24: 959-971 (2004), DOI: 10.1002/joc.1030.
- 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), <http://dx.doi.org/10.1016/j.jhydrol.2012.04.052>.
- MCINTOSH, PC; POOK, MJ; RISBEY, JS; LISSON, SN; REBBECK, M. (2007). **Seasonal climate forecasts for agriculture: towards better understanding and value.** *Field Crops Research*, v. 104, p. 130-138.
- MORID, S., SMAKHTIN, V., & BAGHERZADEH, K. (2007). **Drought forecasting using artificial neural networks and time series of drought indices.** *International Journal of Climatology*, 27, 2103-2111. doi:10.1002/joc.1498.
- MOLION, L. C. B.; BERNARDO, S.O. **Uma Revisão das chuvas no Nordeste brasileiro,** *Revista Brasileira de Meteorologia- SBMET*, v.17, nº01, 2002.
- PARTAL, T., KISI, O. **Wavelet and neuro-fuzzy conjunction model for precipitation forecasting.** *Journal of Hydrology* (2007) 342: 199-212, DOI:10.1016/j.jhydrol.2007.05.026.
- 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**. New York: Hershey, 2011. Cap. 16, p.326-354.
- PERRIER, V., T. PHILIPPOVITCH, AND C. BASDEVANT, 1995: **Wavelet spectra compared to Fourier spectra**. *J. Math. Phys.*, 36, 1506–1519.
- RASANEN, L.A., KUMMU, M. **Spatiotemporal influences of ENSO on precipitation and flood pulse in the Mekong River Basin**. *Journal of Hydrology* (2013), DOI: <http://dx.doi.org/10.1016/j.jhydrol.2012.10.028>.
- SCHLESINGER, M. E. (1994). An oscillation in the global climate system of period 65-70 years. *Nature* 367 (6465): 723–726. Bibcode:1994Natur.367..723S. doi:10.1038/367723a0
- SECRETARIA DE ESTADO DO MEIO AMBIENTE E DOS RECURSOS HÍDRICOS - SEMARH/AL. **Dados diários de chuva. Banco de Dados Hidrometeorológicos - BDHM Diretoria de Meteorologia – DMET**. Maceió. 2011.
- SILVA, B.C. ; COLLISCHONN, W. ; TUCCI, C. E.M. . **Previsão de Vazão com Modelos Hidroclimáticos**. *Revista Brasileira de Recursos Hídricos* (2005).
- SILVERMAN, D., & DRACUP, J. A. (2000). **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
- SINGH, O.P. **Multivariate ENSO index and Indian monsoon rainfall: Relationships on monthly and sub-divisional scales**. *Meteorology and Atmospheric Physics* 78: 1 - 9 (2001).
- THOMPSON, D. W. J., WALLACE, J. M. 2000: **Annular Modes in the Extratropical Circulation. Part I: Month - to - Month variability**. *Journal of Climate*, 13, p. 1000 - 1016.
- TORRENCE, C. AND COMPO, G. P.: **A practical guide to wavelet analysis**, *Bull. Am. Meteorol. Soc.*, 79, 61–78, 1998.
- TRIGO, R.M.; OSBORN. T.J.; CORTE-REAL, J. (2002) – **The North Atlantic Oscillation influence on Europe: climate impacts and associated physical mechanisms**. *Finisterra*, XXXVII, p. 5-31, 2002.
- TUCCI, C. E. M.; MARENGO J.; DIAS, P. L. S. et al. **Previsão de vazões na bacia do Rio São Francisco com base na previsão climática**. Relatório técnico ANEEL/OMM/98/00. Porto Alegre: IPHUFGRS. 385p. 2005.

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

UVO, C. R. B., REPELLI, C. A., S. ZEBIACK AND 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, B.C. **Analysis and regionalization of northern European winter precipitation based on its relationship with the North Atlantic Oscillation**. International Journal of Climatology 23: 1185-1194 (2003), DOI: 10.1002/joc.930.

YU, S.-P., YANG, J.-S., LIU, G.-M. **A novel discussion on two long-term forecast mechanism for hydro-meteorological signals using hybrid wavelet-NN model**. Journal of Hydrology 497 (2013) 189–197. <http://dx.doi.org/10.1016/j.jhydrol.2013.06.003>.

WEI, S.; SONG, J.; KHAN, N.I. **Simulation and predicting river discharge time series using a wavelet-neural network hybrid modelling approach**. Hydrological Process 26: 281-296 (2012), DOI: 10.1002/hyp.8227.

WILBY, R. L., WEDGBROW, C. S., & FOX, H. R. (2004). **Seasonal predictability of the summer hydrometeorology of the River Thames, UK**. Journal of Hydrology (Amsterdam), 295, 1-16. doi:10.1016/j.jhydrol.2004.02.015.