



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA**  
**ELÉTRICA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**MODELO DE PREVISÃO SAZONAL DE CHUVA PARA O ESTADO DO**  
**CEARÁ BASEADO EM REDES NEURAS ARTIFICIAIS**

**THIAGO NOGUEIRA DE CASTRO**

**FORTALEZA**  
**SETEMBRO 2011**



**THIAGO NOGUEIRA DE CASTRO**

**MODELO DE PREVISÃO SAZONAL DE CHUVA PARA O  
ESTADO DO CEARÁ BASEADO EM REDES NEURAIAS  
ARTIFICIAIS**

Dissertação submetida à Coordenação do  
Curso de Pós-Graduação em Engenharia  
Elétrica, da Universidade Federal do Ceará,  
como requisito para obtenção do grau de  
Mestre em Engenharia Elétrica.

Orientador:

Prof. Dr. Ricardo Silva Thé Pontes

Fortaleza

**SETEMBRO 2011**

**THIAGO NOGUEIRA DE CASTRO**

**MODELO DE PREVISÃO SAZONAL DE CHUVA PARA O ESTADO DO CEARÁ  
BASEADO EM REDES NEURAS ARTIFICIAIS**

Este trabalho foi julgado adequado à obtenção do grau de Mestrado em Engenharia Elétrica – Área de Concentração em Automação da Universidade Federal do Ceará, e aprovado em sua forma final pelo Mestrado em Engenharia Elétrica – Área de Concentração em Automação da Universidade Federal do Ceará.

Fortaleza, 15 de setembro de 2011.

---

Prof. Dr. Ricardo Silva Thé Pontes  
Universidade Federal do Ceará

---

Prof. Dr. Aluizio Fausto Ribeiro Araújo  
Universidade Federal de Pernambuco

---

Prof. Dr. Eduardo Sávio Passos Rodrigues Martins  
Fundação Cearense de Meteorologia e Recursos Hídricos

---

Prof. Dr. Arthur Plínio de Souza Braga  
Universidade Federal do Ceará

## **DEDICATÓRIAS**

A DEUS essa força inabalável a qual recorreremos constantemente pelo dogma chamado FÉ.

Aos meus queridos e amados pais, José Alberto de Castro e Laurinda Lúcia Nogueira dos Reis; e minhas amadas irmãs (Lívia Maria Nogueira de Castro e Issis Maria Nogueira de Castro) fontes de amor, carinho e principalmente dedicação na árdua tarefa de educar pelos ensinamentos mais nobres que um ser humano pode ter: os de preceitos morais e de respeito ao seu semelhante.

A minha querida Aline pela compreensão, das minhas incompreensões, nos momentos difíceis, e por acreditar da minha importância em sua vida. Esta conquista é muito mais sua.

## **AGRADECIMENTOS**

Em especial, ao Prof. Dr. Ricardo Silva Thé Pontes, meu orientador, pelos ensinamentos, amizade e, sobretudo pela confiança em apostar no meu potencial de trabalho.

Aos meus amigos pelo constante incentivo na busca de completar meus estudos de Pós-graduação, em um período no qual já estava desmotivado para tal propósito.

Ao Dr. Eduardo Sávio R. P. Martins (Presidente da Fundação Cearense de Meteorologia e Recursos Hídricos - FUNCEME) pelo incentivo sem restrições aos seus funcionários para cursar programas de Mestrado e Doutorado.

Ao Departamento de Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, na pessoa de todos os seus Professores e colegas pela transmissão de conhecimentos e a oportunidade para cursar este Programa de Mestrado.

A todos os colegas dos Departamentos de Meteorologia e Hidrologia da FUNCEME pelas discussões profícuas (em especial ao Dr. José Maria Brabo Alves).

Finalmente, a todos que de alguma forma contribuíram para que este estudo se completasse.

“O processo de adquirir conhecimento e saber são intrínsecos à evolução do ser humano. O primeiro está ligado, principalmente, ao seu instinto investigativo, o segundo as suas experiências vividas. Porém, se estes não se mesclarem pelo menos na mesma proporção, e não forem usados no sentido de tentar melhorar e compreender a vida de seu semelhante, com certeza não terão sentido prático”.

A. J. M. B. (08/09/07)

CASTRO, T. N. **MODELO DE PREVISÃO SAZONAL DE CHUVA PARA O ESTADO DO CEARÁ BASEADO EM REDES NEURAS ARTIFICIAIS**. Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal do Ceará – UFC, 2011, 75 pgs.

## RESUMO

Sistemas climatológicos são caracterizados por apresentarem modelagem complexa e de baixa previsibilidade. Em regiões de clima semiárido, como o Nordeste Brasileiro, informações de previsão climatológicas são de interesse para um melhor aproveitamento dos recursos hídricos. O Estado do Ceará, localizado no norte do Nordeste Brasileiro, sofre periodicamente com os problemas de estiagem. Atualmente a Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME), órgão pertencente ao governo do Estado do Ceará, é responsável por gerar pesquisas voltadas a trazer um melhor entendimento fenomenológico do clima do Estado e com isso efetuar uma melhor previsão de como será o período de chuvas. Hoje a Fundação utiliza-se de modelagem numérica composta por dois modelos regionais, Modelo Regional Espectral 97 (MRE) e o *Regional Modeling Atmospheric System* (RAMS), aninhados por uma técnica de *downscaling* ao modelo dinâmico de grande escala ECHAM4.5, para efetuar suas previsões. Os modelos dinâmicos são caracterizados por apresentarem elevado custo computacional, grande quantidade de dados para sua entrada e alta complexidade na utilização. O desenvolvimento de modelos de previsão baseados em Redes Neurais Artificiais (RNA) abrange diversas áreas do conhecimento e tem apresentado resultados promissores. Modelos baseados em redes neurais são capazes de reproduzir diferentes tipos de sistemas através da sua capacidade de aprendizado. Nesta dissertação foi desenvolvido um modelo de previsão de chuvas para as oito regiões homogêneas do Estado do Ceará, que apresenta um baixo custo computacional e de fácil utilização. Para atingir este desenvolvimento foi utilizada uma RNA baseada na técnica *Neo-Fuzzy Neuron* (NFN). Apesar de ser proposto um novo modelo de previsão, não se deseja a substituição dos atuais modelos, o novo modelo proposto nesta dissertação tem por finalidade enriquecer as informações geradas através de modelos de previsão para que assim possa ser gerada uma melhor predição de como será o período de chuvas no Estado do Ceará. O modelo proposto foi comparado ao modelo MRE que é atualmente utilizado pela FUNCEME para suas previsões. Nesta comparação utilizou-se como indicadores de desempenho: tempo de execução, valor da raiz quadrada do erro médio quadrático (REMQ) e a correlação com os valores observados. Ao final pode-se concluir que o modelo desenvolvido apresentou um melhor desempenho com menor tempo de processamento em relação ao modelo dinâmico MRE para efetuar a previsão de chuvas.

**Palavras-chave:** semiárido, previsão de chuvas, modelos meteorológicos, RNA, NFN



**CASTRO, T. N. SEASONAL FORECASTING MODEL OF RAIN FOR THE STATE OF CEARA BASED ON ARTIFICIAL NEURAL NETWORKS.** Master Thesis in Electrical Engineering, Federal University of Ceará, 2011, 75 pgs.

## **ABSTRACT**

Climatological systems are characterized by complex modeling and having low predictability. In semi-arid regions, as the Brazilian Northeast, weather forecast information are necessary for the maintenance of life and a better use of water resources. The State of Ceará, located on the north of Brazilian Northeast, is a region that suffers with drought for a long time. The Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME), which belongs to the state government, is responsible for generating research to bring a better phenomenological understanding on the weather of the State of Ceará and thus make a better prediction on how the rainy season will be. Today the foundation makes use of numerical modeling consisting of two regional models, the Regional Spectral Model (RSM) and the *Regional Modeling Atmospheric System* (RAMS), nested by a downscaling technique to the large scale dynamic model ECHAM4.5, in order to do its predictions. Dynamic models are characterized by their high computational costs, large amounts of information on its input and high complexity usage. The development of forecasting models based on Artificial Neural Networks (ANN) covers various areas of knowledge showing promising results. Neural network based models are capable of reproducing different types of systems through its learning capability. In this thesis it was developed a model for predicting rain for the eight homogeneous regions of the state of Ceará that presents low computational cost and easy use. In order to achieve this development it was used an ANN base on a Neo-Fuzzy Neuron (NFN) technique. Despite being offered a new prediction model, this thesis aims to enrich the information generated by forecast models and do a better prediction on the rainy season of the State of Ceará. The proposed model was compared to the RSM model that is currently in use by FUNCEME in its predictions. In this comparison, as performance indicators, it was used: the execution time, value of the root mean square error (RMSE) and the correlation with the observed values. At the end, it is concluded that the proposed model had a better performance and was faster than the RSM dynamic model in its predictions.

**Keywords:** semi-arid, rainfall forecast, meteorological models, ANN, NFN

## SUMÁRIO

<b>DEDICATÓRIAS</b> .....	<b>V</b>
<b>AGRADECIMENTOS</b> .....	<b>VI</b>
<b>RESUMO</b> .....	<b>VIII</b>
<b>ABSTRACT</b> .....	<b>IX</b>
<b>SUMÁRIO</b> .....	<b>X</b>
<b>LISTA DE FIGURAS</b> .....	<b>XII</b>
<b>LISTA DE TABELAS</b> .....	<b>XIV</b>
<b>LISTA DE ABREVIACÕES</b> .....	<b>XV</b>
<b>1 INTRODUÇÃO</b> .....	<b>1</b>
1.1 PRINCIPAIS CARACTERÍSTICAS CLIMATOLÓGICAS DA PRECIPITAÇÃO NO ESTADO DO CEARÁ E OS PRINCIPAIS SISTEMAS ATMOSFÉRICOS ATUANTES .....	3
1.2 A FUNCEME E A MODELAGEM CLIMÁTICA E HIDROLÓGICA NO CEARÁ.....	6
1.3 COMPANHIA DE GESTÃO DOS RECURSOS HÍDRICOS .....	8
1.4 OBJETIVOS .....	8
1.5 METODOLOGIA EMPREGADA .....	9
1.6 PRODUÇÃO CIENTÍFICA .....	9
1.7 ESTRUTURA DA DISSERTAÇÃO .....	9
<b>2 MODELAGEM DO SISTEMA DE PREVISÃO DE CHUVAS PARA O CEARÁ</b>	<b>10</b>
2.1 MODELAGEM DINÂMICA ATMOSFÉRICA .....	10
2.2 A TÉCNICA DE <i>Downscaling</i> .....	12
2.3 MODELO DINÂMICO DE GRANDE ESCALA <i>ECHAM4.5</i> .....	13
2.4 MODELO REGIONAL ESPECTRAL 97 (MRE) .....	15
2.5 <i>REGIONAL MODELING ATMOSPHERIC SYSTEM</i> (RAMS) .....	16
2.6 A SISTEMÁTICA DA GERAÇÃO DO RELATÓRIO DE PREVISÃO .....	17
<b>3 MODELO INTELIGENTE DE PREVISÃO DE CHUVAS</b> .....	<b>19</b>
3.1 REDES NEURAIS ARTIFICIAIS NA PREVISÃO METEOROLÓGICA .....	19
3.2 NEO-FUZZY NEURON .....	27
3.3 TESTES PRELIMINARES .....	30
3.4 MODELO DESENVOLVIDO.....	34
3.5 FLUXOGRAMA DO MODELO.....	36
3.6 DEFINIÇÕES DO MODELO .....	38
<b>4 ANÁLISE DOS RESULTADOS DO MPSCI</b> .....	<b>40</b>
4.1 APRESENTAÇÃO E DISCURSÃO DOS RESULTADOS (VALIDAÇÃO) .....	40

4.2	ANÁLISE DOS RESULTADOS POR REGIÃO 2002 A 2010 (VALIDAÇÃO) .....	43
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS .....</b>	<b>49</b>
5.1	TRABALHOS FUTUROS .....	50
	<b>REFERÊNCIAS .....</b>	<b>51</b>
	<b>ANEXO I – HARMÔNICOS ESFÉRICOS E TRUNCAMENTOS TRIANGULAR E ROMBOIDAL.....</b>	<b>58</b>
	<b>ANEXO II – SCRIPTS DE EXECUÇÃO DO MPSCI .....</b>	<b>61</b>

## LISTA DE FIGURAS

FIGURA 1 - DISTRIBUIÇÃO ESPACIAL (MM) E CONTRIBUIÇÃO (%) EM RELAÇÃO AO TOTAL ANUAL DAS ESTAÇÕES DO ANO PARA O ESTADO DO CEARÁ. 1A) PRECIPITAÇÃO DE VERÃO; 1B) PRECIPITAÇÃO DE OUTONO, 1C) PRECIPITAÇÃO DE INVERNO; 1D) PRECIPITAÇÃO DE PRIMAVERA; 1E) (%) CONTRIBUIÇÃO. FONTE: [2].....	4
FIGURA 2 - SEPARAÇÃO DO ESTADO DO CEARÁ EM OITO REGIÕES HOMOGÊNEAS. FONTE: [4].....	5
FIGURA 3 - REPRESENTAÇÃO ESQUEMÁTICA DOS PROCESSOS INCLUÍDOS NO MCGA ECHAM. BASE PARA IMAGEM EM [20] .....	14
FIGURA 4 - ESTRUTURA DE UMA REDE NFN. ....	28
FIGURA 5 - EXEMPLO DE FUNÇÕES DE PERTINÊNCIA TRIANGULARES E HOMOGÊNEAS. ....	29
FIGURA 6 - GRÁFICO COM A DISPERSÃO ENTRE SAÍDA DO MODELO E VALORES OBSERVADOS PARA REDE PROTÓTIPO MLP PARA OS DADOS DE VALIDAÇÃO. ....	32
FIGURA 7 - GRÁFICO COM A DISPERSÃO ENTRE SAÍDA DO MODELO E VALORES OBSERVADOS PARA REDE PROTÓTIPO NFN PARA OS DADOS DE VALIDAÇÃO. ....	33
FIGURA 8 - DIAGRAMA DE FLUXO PARA GERAR O MODELO DE PREVISÃO SAZONAL DE CHUVAS SOBRE O ESTADO DO CEARÁ.....	37
FIGURA 9 - GRÁFICO COM OS DADOS DE REMQ PARA O MODELO NEURA E DINÂMICO PARA OS DADOS DE VALIDAÇÃO. EIXO Y APRESENTA OS VALORES DO REMQ E NO EIXO X TEM-SE A REGIÃO. ....	42
FIGURA 10 - GRÁFICO COM OS DADOS DE CORRELAÇÃO PARA O MODELO NEURA E DINÂMICO PARA OS DADOS DE VALIDAÇÃO. EIXO Y APRESENTA OS VALORES DA CORRELAÇÃO E NO EIXO X TEM-SE A REGIÃO.....	42
FIGURA 11 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO CARIRI. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010. ....	45
FIGURA 12 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DA IBIAPABA. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010. ....	45
FIGURA 13 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO JAGUARIBANA. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010. ....	46
FIGURA 14 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO LITORAL DE FORTALEZA. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010.....	46
FIGURA 15 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO LITORAL NORTE. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010.....	47

FIGURA 16 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO LITORAL DO PECÉM. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010.....	47
FIGURA 17 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO MACIÇO DE BATURITÉ. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010. ....	48
FIGURA 18 - DADOS DE PRECIPITAÇÃO ACUMULADA PARA A REGIÃO DO SERTÃO CENTRAL E INHAMUNS. NO EIXO Y ESTÃO OS VALORES DO ACUMULADO DE PRECIPITAÇÃO, EM MM, E NO EIXO X ESTÁ UMA REPRESENTAÇÃO DOS TRIMESTRES DE CADA ANO. 2002 A 2010.....	48
FIGURA 19 - REPRESENTAÇÃO ESQUEMÁTICA DE YNM NA ESFERA UNITÁRIA POR SUAS DENOMINAÇÕES. ....	59
FIGURA 20 - TIPOS DE TRUNCAMENTO UTILIZADOS EM EXPANSÕES POR HARMÔNICOS ESFÉRICOS. ....	60

## LISTA DE TABELAS

TABELA 1 - MELHOR CONFIGURAÇÃO DA RNA DE [37] .....	20
TABELA 2 - MENOR E MAIOR ERRO PARA OS DIAS DE VALIDAÇÃO NOS EXPERIMENTOS DE [37].	20
TABELA 3 - RESULTADOS DO MODELO BASEADO EM RNA DE [38].....	21
TABELA 4 - RESULTADOS OBTIDOS POR [41] .....	23
TABELA 5 - RESUMO DOS RESULTADOS DE [42] PARA AS TRÊS REDES TESTADAS E PARA A PREVISÃO DE UM, DOIS E TRÊS DIAS DE HORIZONTE. ....	24
TABELA 6 - TABELA COM RESULTADOS DA COMPARAÇÃO DOS RESULTADOS DE [46] ENTRE AS REDES RNA E RNAM. ....	27
TABELA 7 – DADOS DE DESEMPENHO PARA AS REDES DE PROTÓTIPO .....	33
TABELA 8 - DESCRIÇÃO DAS VARIÁVEIS DE ENTRADA .....	34
TABELA 9 - QUANTIDADE DE PARTIÇÕES PARA CADA VARIÁVEL.....	39
TABELA 10 - RESULTADOS DO VALOR DO REMQ PARA MODELO NEURAL MPSCI E DINÂMICO MRE PARA OS DADOS DE VALIDAÇÃO. ....	41
TABELA 11 - RESULTADOS DA CORRELAÇÃO PARA MODELO NEURAL MPSCI E DINÂMICO MRE PARA OS DADOS DE VALIDAÇÃO.....	41

## LISTA DE ABREVIACES

FUNCEME	Fundao Cearense de Meteorologia e Recursos Hdricos
MCGA	Modelo de Circulao Global Atmosfrica
NEB	Nordeste Brasileiro
ECMWF	<i>European Centre for Medium Range Weather Forecasts</i>
DKRZ	<i>Max Planck Institute for Meteorology and German Climate Computing Centre</i>
NCEP	<i>National Centers for Environmental Prediction</i>
NMC	<i>National Meteorological Center</i>
MRE	Modelo Regional Espectral 97
RAMS	<i>Regional Modeling Atmospheric System</i>
ZCIT	Zona de Convergncia Intertropical
VCAS	Vrtices Ciclnicos de Ar Superior
MPSCI	Modelo de Previso Sazonal de Chuvas Inteligente
RNA	Rede Neural Artificial
SIF	Sistema de Inferncia Fuzzy
NFN	Neo-Fuzzy Neuron
TSM	Temperatura da Superfcia do Mar
MEG	Modelo Espectral Global
ECHAM	<i>European Centre Hamburg Atmospheric Model</i>

# 1 INTRODUÇÃO

A água é um dos recursos naturais mais importantes, sendo usada nos mais diversos tipos de finalidades, como, por exemplo, abastecimento doméstico e industrial, geração de energia, manutenção da vida, entre outros. O Brasil apresenta uma posição privilegiada quanto à disponibilidade de recursos hídricos, possuindo cerca de 12% da água doce disponível no mundo segundo o site do Portal Brasil (<http://www.brasil.gov.br/>) na página de Recursos Hídricos. Entretanto, algumas de suas regiões sofrem com a escassez deste recurso devido a prolongados períodos de seca em alguns anos, e sofrem com danos devido a eventos extremos, como cheias, em outros anos. O Nordeste Brasileiro (NEB) é uma dessas regiões, sendo bem conhecida por apresentar uma variabilidade interanual da precipitação, sofrendo com problemas causados por anos de estiagem, como falta de abastecimento, e anos com excesso de chuva [1].

O gerenciamento dos recursos hídricos no NEB é feito todos os anos pelos órgãos públicos a fim de evitar ou mitigar os danos causados pelos eventos extremos. Em regiões semiáridas, como o NEB, a integração entre as ciências meteorológicas e hidrológicas é essencial para que o gerenciamento dos recursos hídricos seja feito de maneira adequada e com antecipação de dias ou até mesmo meses. Ao melhorar a operação de um reservatório hídrico, por exemplo, podem-se trazer benefícios sociais e econômicos para as comunidades dependentes deste. Com base nestas ações, podem-se evitar transtornos ocasionados por picos de cheias inesperadas ou por falta de água para suprir a demanda de abastecimento urbano ou rural [2]. Para realizar este gerenciamento conta-se, como principal ferramenta, com a modelagem meteorológica. Esta é operacionalmente utilizada em órgãos de meteorologia, fazendo: (i) previsões de tempo – previsões feitas para escala de tempo de algumas horas a frente e até dias – e de clima– com escala de tempo de meses a anos –, e (ii) gerando relatórios com indicativos para as regiões onde possa ocorrer falta ou o excesso de chuva. Nesta modelagem, para o caso do NEB, deve-se considerar de forma direta a influência da zona de convergência intertropical (ZCIT), pois quando qualquer evento climático anormal influencia essa zona, principalmente nos meses de fim ou início do ano, a distribuição das chuvas sobre o NEB ocorrem algumas semanas mais tarde, propiciando os eventos chamados de “veranicos”, que por sua vez irão influenciar as culturas agrícolas [3].

O objetivo deste trabalho é contribuir para o gerenciamento dos recursos hídricos de um dos estados do NEB, o Ceará, com a geração de modelos de previsão sazonal de chuva, a partir de dados obtidos junto à FUNCEME (Fundação Cearense de



Meteorologia e Recursos Hídricos), que demandem baixo esforço computacional, uma vez que os atuais modelos requerem que sejam executados em um cluster de dez máquinas, e consigam reproduzir a dinâmica de sistemas complexos. Para tal, os modelos tratados nesta dissertação são baseados em Redes Neurais Artificiais (RNAs) [33], [34].

O estado do Ceará é marcado por recorrentes secas, apresenta um período úmido curto, concentrado em quatro meses do ano, fevereiro a maio; rios intermitentes; elevada perda de água por evaporação e grande irregularidade na distribuição espacial e temporal da precipitação. Além dessas características, a configuração geológica do Estado do Ceará tem mais de 80% de seu território assentado em uma estrutura cristalina, dificultando a infiltração de água e favorecendo um elevado escoamento superficial [2]. Isso dificulta a renovação das reservas hídricas do estado. Nesse contexto é imprescindível o estudo de técnicas que permitam aprimorar o potencial da previsão de chuvas [2], [3] e, assim, melhorar a gestão de água no estado, trazendo melhorias como:

- Reduzir os impactos sobre os níveis de produção e produtividade agrícola das comunidades que sobrevivem a partir da agricultura de subsistência, que são as que mais se ressentem dos períodos de estiagem e da falta de condições hídricas no solo. A porção semiárida do interior do Estado do Ceará, mais conhecida como sertões, apresenta práticas de agricultura de subsistência rudimentares que colaboram para uma baixa produção agrícola, principalmente durante períodos de seca.
- Contribuir para um melhor direcionamento das verbas dos governos Estadual e Federal para a região, pois são estas instâncias de governo que precisam atuar para garantir as condições de sustentabilidade destas famílias nos anos de perda excessiva de safra [2].

Os modelos neurais estudados neste trabalho não visam substituir os modelos já utilizados pela FUNCEME (descritos no Capítulo 2), mas sim contribuir para, em conjunto com os modelos já existentes, melhorar as previsões de chuva. A FUNCEME utiliza o conjunto de simulações dos modelos de mesoescala RAMS (*Research Atmospheric Modeling System*), desenvolvido na Universidade do Colorado, e o Modelo Regional Espectral 97 (MRE), do *Nacional Centers for Atmospheric Prediction* – NCEP, alimentados pelo modelo global ECHAM 4 (*European Centre Hamburg Atmospheric Model*), com a TSM (Temperatura da Superfície do Mar) persistida e prevista, com 10 membros de inicialização para cada modelo regional para previsão de clima [4].

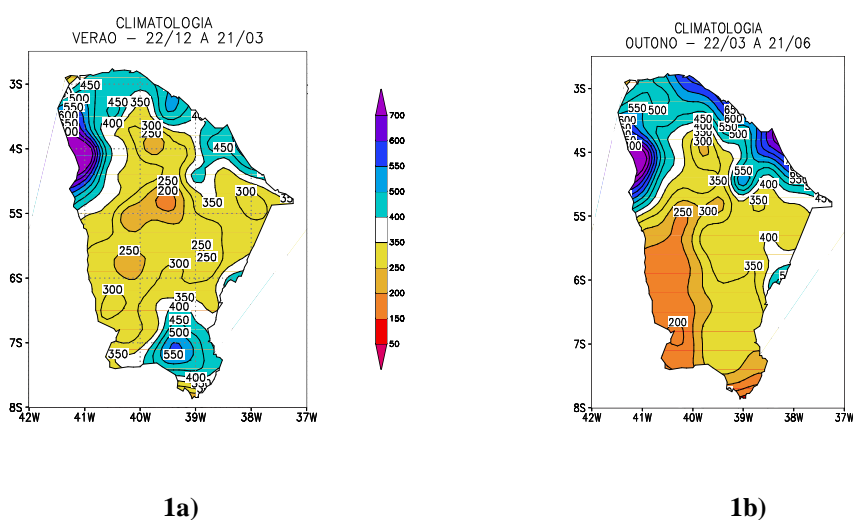
O restante deste Capítulo está organizado de forma a: (i) fornecer ao leitor uma melhor visão do problema de previsão de precipitações no estado do Ceará (Subseção 1.1), (ii) apresentar o órgão, parceiro desta pesquisa, que atua na modelagem

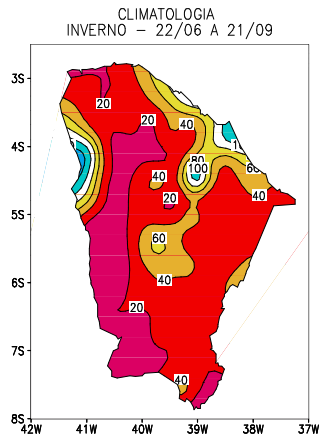
climática e hidrológica no CE (Subseção 1.2), (iii) apresentar o órgão que faz uso destes modelos (Subseção 1.3), (iv) resumir os objetivos deste trabalho (Subseção 1.4), (v) descrever a metodologia empregada (Subseção 1.5), (vi) relacionar a produção científica gerada (Subseção 1.6), e (vii) descrever a organização dos demais Capítulos que compõem esta dissertação (Subseção 1.7).

## 1.1 Principais Características Climatológicas da Precipitação no Estado do Ceará e os Principais Sistemas Atmosféricos Atuantes

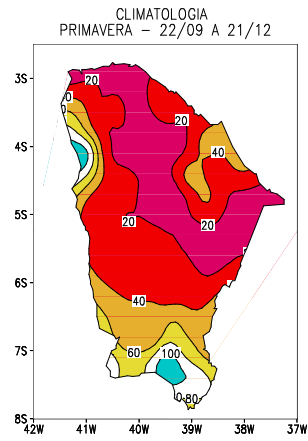
O Estado do Ceará, localizado aproximadamente entre as coordenadas de 2,5°S e 10°S e 34°W e 42°W, apresenta basicamente dois períodos distintos com característica pluviométrica ao longo do ano: chuvoso e seco. Durante o período chuvoso, não levando em consideração as variabilidades interanuais, ocorrem cerca de 60% do total das chuvas do ano, com cerca de 650 mm/ano em média, que se estendem principalmente de fevereiro a maio, o que acarreta em chuvas concentradas em pequenos períodos que acarreta na pouca variabilidade de culturas que possam ser cultivadas. Outra influencia dessa concentração é a presença de veranicos, períodos com mais de oito dias sem chuvas, que podem causar a perda de toda uma safra. O período seco, compreendendo os meses de junho a outubro, é marcado pela pouca ocorrência de precipitações sobre o estado. Este período pode apresentar um interstício de pré-estação chuvosa que se estende de novembro a janeiro [3].

Em seu trabalho, Alves [2] avaliou as imagens da Figura 1 que contém a distribuição espacial e a contribuição em termos de desvios da precipitação ao longo das estações do ano (verão, inverno, outono e primavera) para o Estado do Ceará. Concluindo que as estações de verão e outono austrais são as estações que apresentam os maiores totais de chuvas, assim como as maiores contribuições, em relação ao total anual.

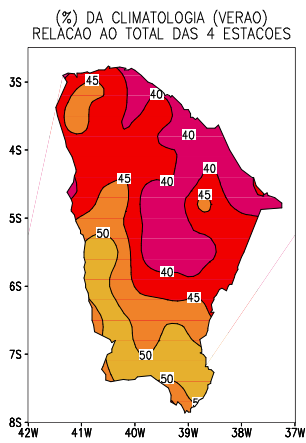




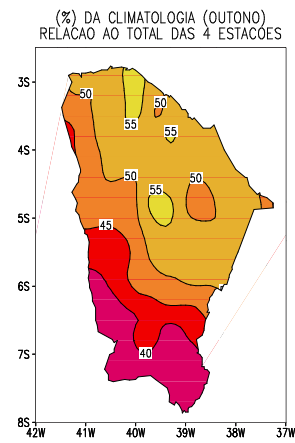
1c)



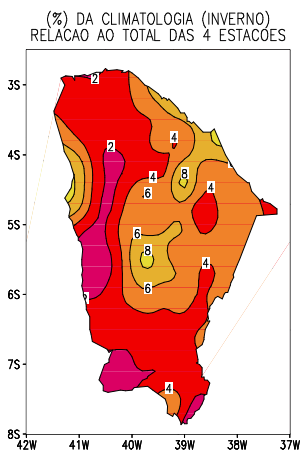
1d)



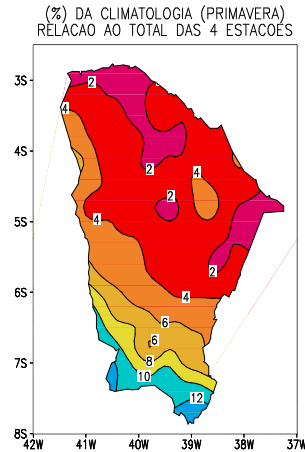
1e)



1f)



1g)



1h)

Figura 1 - Distribuição espacial (mm) e contribuição (%) em relação ao total anual das estações do ano para o Estado do Ceará. 1a) precipitação de verão; 1b) precipitação de outono, 1c) precipitação de inverno; 1d) precipitação de primavera; 1e) (%) contribuição. Fonte: [2]

A evolução da ocorrência das chuvas sobre o Estado se dá de forma gradativa como o mostra na Figura 1. Começando normalmente com chuvas centradas sobre sua região centro-sul no período da pré-estação. Isso ocorre devido à instabilidade atmosférica gerada pela presença de frentes frias localizadas no setor centro-sul do NEB, que favorecem a formação da atividade convectiva [2]. Entretanto, nas demais áreas do estado pode haver chuvas abundantes uma vez que haja a atuação dos Vórtices Ciclônicos de Ar Superior (VCAS) que acabam por induzir a formação de nuvens até nas áreas mais áridas do Estado. Em alguns casos, em janeiro as VCAS se aproximam da costa do Estado do Ceará, associando-se a ZCIT, que é o principal sistema causador de chuvas sobre o Estado no período de fevereiro a maio, causando precipitações abundantes na pré-estação [2] ,[5].

Levando em consideração a influência dos aspectos de grande escala da atmosfera e dos oceanos, que são responsáveis por modular a intensidade das chuvas no setor norte do NEB, a partir do mês de fevereiro, início da estação chuvosa, a distribuição das chuvas sobre o Estado ocorrem de forma mais homogêneas sobre todo ele. Na Figura 2 pode-se ver a divisão do Estado do Ceará em oito regiões que apresentam características homogêneas de precipitação. Durante esse período, a ZCIT atua de forma mais frequente sobre o Estado do Ceará, principalmente nos meses de março e abril. Assim, os principais fatores que passam a influenciar na intensidade da precipitação são, principalmente, os aspectos fisiográficos e a localização de cada região [2]. A topografia é outro aspecto físico que contribui significativamente para um aumento da quantidade de chuva em uma determinada região. Sendo assim, regiões mais elevadas, em geral, apresentam maior precipitação em comparação a áreas de topografia mais plana [2].



Figura 2 - Separação do estado do Ceará em oito regiões homogêneas. Fonte: [4]

A seguir é apresentado um breve histórico da FUNCEME que é o órgão responsável por gerar informações técnicas e científicas que são utilizadas pelos tomadores de decisão tanto da esfera governamental e quanto por usuários no geral. Também é apresentada a rede de monitoramento que foi instalada pela fundação.

## **1.2 A FUNCEME e a Modelagem Climática e Hidrológica no Ceará**

A Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) foi criada pela lei Nº 9.618 (D.O. 26/09/72), sob a denominação Fundação Cearense de Meteorologia e Chuvas Artificiais, em 18 de setembro de 1972 e apresentando personalidade jurídica de direito privado vinculada à Secretaria de Agricultura e Abastecimento. Inicialmente apresentava como objetivos a produção de chuvas artificiais e estudos de meteorologia aplicada no Estado do Ceará [4]. O órgão teve seu nome modificado para o atual em 15 de dezembro de 1987, através da lei Nº 11.380 (D.O. 17/12/87) passando a ser vinculada à Secretaria de Recursos Hídricos (SRH) do Estado do Ceará. A partir daí apresentava como finalidade básica a realização de pesquisas científicas e tecnológicas, a realização de estudos no campo dos recursos hídricos superficiais e subterrâneos e a prestação de serviços especializados nas áreas de Meteorologia e Recursos Hídricos [4].

Em 1988, a FUNCEME amplia seu campo de atuação, absorvendo parte das atividades da extinta Superintendência de Desenvolvimento do Ceará (SUDEC). Em 1993, passa a integrar a estrutura da nova Secretaria de Ciência e Tecnologia do Ceará (SECITECE) e suas atividades passaram a ter ênfase na área científica [4].

Em 1997, por força da Lei Nº 12.725 de 18 de Setembro de 1997, a FUNCEME volta a fazer parte da SRH, com os mesmos objetivos estabelecidos em 1987, acrescidos da elaboração de estudos geoambientais, visando cobrir de forma abrangente toda a geografia física do Estado. Esse retorno deveu-se à observância, por parte do Governo do Estado, de que a Fundação deveria destinar-se a subsidiar as demandas da SRH, consubstanciadas na implantação do SIGERH - Sistema Integrado de Gestão de Recursos Hídricos [4].

Em 2003, a FUNCEME retorna à Secretaria da Ciência e Tecnologia (SECITECE), adotando como prioridade o estudo e a pesquisa voltados para o melhor conhecimento da natureza do semiárido. Atualmente, os objetivos do órgão estão voltados para o desenvolvimento de tecnologias, pesquisas aplicadas e para a criação, manutenção e constante expansão de banco de dados, gerando todo um conjunto de informações meteorológicas, climatológicas, geográficas, ambientais, hidrográficas, e sobre a cobertura vegetal e solos do Estado do Ceará. Para tanto, desenvolve projetos e mantém convênios e acordos de cooperação técnica com diversos órgãos em nível Estadual, Nacional e Internacional [4].

Por fim, a FUNCEME tem como missão gerar informações técnicas e científicas para serem utilizadas pelos tomadores de decisão da esfera governamental e usuários em geral, e com isso contribuir para um melhor convívio da sociedade Cearense e nordestina. Atualmente a FUNCEME é reconhecida internacionalmente como centro de excelência regional nos estudos de meteorologia, hidrologia e meio ambiente [2]. A partir de 2002 deu-se início a uma cooperação com o *International Research Institute* (IRI) e foi possível consolidar um sistema operacional de previsão dinâmica sazonal de precipitação para todo o NEB. Através desse, foi possível refinar a previsão de MCGAs (*ECHAM4.5*) com o aninhamento (*downscaling*) do MRE. A FUNCEME foi pioneira no mundo quanto a implementar um sistema operacional que utiliza um método de *downscaling* a partir de 2002 [2].

Para efetuar a sintonia de seus modelos de previsão, a FUNCEME disponibiliza de uma rede de monitoramento composta por 70 postos de coletas de dados (PDCs). Estas estão distribuídas ao longo de todo Estado do Ceará. Cada estação é projetada para ser independente e autossuficiente: são alimentadas por baterias que são recarregadas através de painéis solares, efetuam armazenamento em memória estática e transmitem os dados utilizando satélites do sistema SCD/ARGOS e via telefonia celular. Através do canal de telefonia é possível também interagir remotamente com a estação de coleta de dados. Os dados são centralizados na FUNCEME, onde são armazenados em bancos de dados e disponibilizados para os usuários [6]. Todas as PDCs estão equipadas com sensores meteorológicos que medem temperatura e umidade relativa do ar, radiação solar global, pressão atmosférica, velocidade e direção do vento e pluviometria. De forma a efetuar um estudo mais completo, algumas destas também são equipadas com sensores que medem parâmetros no solo, importantes para a agricultura, e nas estações próximas a reservatórios, rios ou açudes são monitorados o nível e/ou vazão dos mesmos [6].

Com o intuito de cobrir as áreas do estado da forma mais convergente possível, levando em conta também as características climáticas, hidrológicas e de solo, as estações foram instaladas nos seguintes municípios: Acaraú, Acopiara, Aiuaba, Amontada, Aquiraz, Aracati, Aracoiaba, Araripe, Aratuba, Assaré, Banabuiú, Barroquinha, Beberibe, Boa Viagem, Camocim, Canindé, Cariré, Catarina, Caucaia, Cedro, Coreaú, Crateús, Crato, Fortaleza, Granja, Groaíras, Ibareta, Icapuí, Icó, Iguatu, Independência, Ipú, Ipueiras, Irauçuba, Itapipoca, Itatira, Jaguaruana, Jati, Jijoca de Jericoacara, Jucás, Lavras da Mangabeira, Limoeiro do Norte, Maranguape, Mauriti, Meruoca, Missão Velha, Mombaça, Morada Nova, Orós, Pacajus, Pedra Branca, Pentecoste, Pereiro, Quixadá, Quixeramobim, Quixeré, Santa Quitéria, Santana do Cariri, São Benedito, São Gonçalo do Amarante, Senador Pompeu, Sobral, Solonópole, Tabuleiro do Norte, Tamboril, Tejuçuoca, Ubajara, Várzea Alegre e Viçosa do Ceará. Apenas no município de Morada Nova foram instaladas duas estações, devido a sua extensão [6].

Cada estação armazena os dados dos sensores a cada hora, o que gera 24 informações por parâmetro medido no decorrer de um dia. Uma estação central efetua a

concentração de todos os dados de todas as estações a cada hora, porém em eventos predefinidos as PCDs poderão enviar os dados automaticamente. Por fim os dados coletados pela estação central são então transferidos para um banco de dados dentro da FUNCEME onde são disponibilizados para os usuários [6].

### **1.3 Companhia de Gestão dos Recursos Hídricos**

O estado do Ceará é uma das regiões do NEB que se apresenta com cerca de 90% de sua área influenciada por um clima semiárido com grande variação sazonal e interanual do regime de chuvas [3]. Devido a isso se faz necessária uma política de gestão dos recursos hídricos de forma presente. Atualmente o órgão que se faz presente no gerenciamento e disciplinamento de mais de 90% das águas acumuladas no Estado é a Companhia de Gestão de Recursos Hídricos (COGERH). Esse órgão é responsável por gerenciar os recursos hídricos de domínio do estado do Ceará e da União [7]. A COGERH efetua o monitoramento de 126 açudes estaduais e federais que apresentam uma capacidade de armazenamento superior a 90% de toda a capacidade do Estado do Ceará [8].

Apenas o monitoramento não é suficiente para efetuar um correto gerenciamento dos recursos hídricos. Sem uma perspectiva de como serão as chuvas, não há como efetuar o planejamento de distribuição das águas. Por exemplo, ao efetuar uma liberação despreocupada de águas poderá causar a escassez de água para aquela região em anos com poucas chuvas. Em uma situação oposta, pequenas liberações com excesso de chuvas, as perdas poderiam ocorrer tanto produção agrícola quanto na devastação causada por enchentes.

### **1.4 Objetivos**

O objetivo geral deste trabalho é desenvolver um sistema inteligente utilizando técnica baseada em RNA capaz de aprender e reproduzir um sistema físico complexo de maneira rápida e com baixos custos computacionais.

Mais especificamente, desenvolver um modelo de previsão sazonal de chuvas para as oito regiões do Estado do Ceará a fim de gerar uma outra previsão que é destinada a ser avaliada junto às demais previsões, já feitas pela FUNCEME. A partir desse enriquecimento de informações será possível melhorar a qualidade do relatório com o prognóstico para o período de chuvas da estação chuvosa do Estado do Ceará.

## 1.5 Metodologia Empregada

Este trabalho realizou um levantamento bibliográfico com os modelos tradicionais de previsão de chuvas utilizados pela FUNCEME, e modelos baseados em Redes Neurais Artificiais. A partir dos dados disponíveis foram treinados modelos que foram avaliados comparativamente com os modelos em uso na FUNCEME.

## 1.6 Produção Científica

Os seguintes artigos foram gerados no desenvolvimento desta dissertação:

- CASTRO, T. et al. Seasonal Rainfall Forecast using a Neo-Fuzzy Neuron Model. **IEEE International Conference on Industrial Informatics**, Lisbon, 2011.
- CASTRO, T.; ALVES, J.; FIRMINO, M. PREVISÃO SAZONAL DE PRECIPITAÇÃO NO CEARÁ: COMPARAÇÃO ENTRE MODELAGEM DINÂMICA E UM MODELO COM REDE NEURAL. **XVII Congresso Brasileiro de Agrometeorologia**, Guarapari, 2011.

## 1.7 Estrutura da Dissertação

Este trabalho apresenta um modelo de previsão sazonal de chuvas das oito regiões homogêneas do Ceará baseado em um sistema inteligente. A dissertação está organizada de acordo com os seguintes capítulos: um levantamento de outros modelos utilizados na modelagem do sistema de previsão de chuvas para o Ceará é apresentado no Capítulo 2; no Capítulo 3 é apresentado o estado da arte da utilização de técnicas inteligentes para previsão de chuvas, bem como o modelo proposto. A análise dos resultados do **Modelo de Previsão Sazonal de Chuvas Inteligente** (MPSCI) e a comparação com o modelo dinâmico MRE é feita no Capítulo 4. Finalmente, o Capítulo 5 apresenta as conclusões e propostas para trabalhos futuros.



## 2 MODELAGEM DO SISTEMA DE PREVISÃO DE CHUVAS PARA O CEARÁ

Os organismos mundiais voltados à previsão meteorológica utilizam, basicamente, dois tipos de modelos na modelagem atmosférica: um **Modelo de Circulação Global Atmosférica** (MCGA), que apresentam uma resolução igual ou superior a 250 km, e um outro modelo, de menor escala, denominado **Modelo Regional** (MR), com uma resolução variável da ordem de dezenas de quilômetros e área limitada. Os MRs possibilitam a incorporação de características mais específicas da região de interesse, enquanto que nos macro modelos, MCGA, essas características são parametrizadas. Devido à utilização de informações mais específicas da região, é esperado que os MRs apresentem melhor previsibilidade para uma região do que a que seria obtida com os MCGAs [2].

De forma alternativa apresentam-se os modelos estatístico-estocásticos que são modelos de fácil aplicação e, geralmente, apresentam menores custos computacionais. Em geral essas técnicas têm por meta a predição de uma ou mais variáveis atmosféricas específicas, tendo como base outras que apresentam alguma relação física [9]. Sendo assim, inicialmente será discutido o modelo dinâmico de grande escala *ECHAM4.5*, seguido da discussão de dois modelos regionais: Modelo Regional Espectral (MRE) e *Regional Atmospheric Model System* (RAMS). Estes dois modelos regionais são utilizados pela FUCNEME em suas previsões.

### 2.1 Modelagem Dinâmica Atmosférica

A modelagem atmosférica baseia-se em modelos dinâmicos a partir de equações diferenciais que regem o comportamento físico das principais propriedades atmosféricas responsáveis por influenciar na previsão meteorológica. Os modelos de grande escala e regionais utilizam esse tipo de modelagem. As primeiras tentativas de efetuar a previsão dinâmica do tempo, em uma escala de horas, foram registradas em 1979 por L. F. Richardson [10] que significou um grande avanço para a época. Richardson estimou que seria necessário cerca de 64.000 pessoas, cada uma com uma máquina de calcular, para efetuar a previsão de tempo de algumas horas à frente. Porém, devido a inter-relação de causa e efeito dos fenômenos atmosféricos, quando a previsão terminasse não mais seria útil [2].

Atualmente, com o aumento da capacidade e velocidade de processamento dos computadores, a modelagem numérica tem avançado a passos largos. Desta forma é possível utilizar algoritmos mais poderosos, capazes de processar mais e mais sistemas físicos. Assim, a previsão de tempo (no intervalo de algumas horas até 15 dias à frente) e a previsão de clima (para 3 a 6 meses à frente) obtiveram uma maior precisão nos seus resultados [11]. Isso se reflete na possibilidade de prevenção de calamidades e perdas

financeiras, como por exemplo, ao se prever eventos de seca ou cheia com certa antecedência é possível minimizar os impactos socioeconômicos dos mesmos.

Os modelos dinâmicos, quais sejam os de grande escala, MCGAs, e os de pequena escala, MRs, tem como base as equações diferenciais parciais que regem as principais propriedades físicas atmosféricas, dadas pelas seguintes equações [10]:

Conservação da massa de ar:

$$\frac{\partial \rho}{\partial t} = - \left[ \frac{\partial}{\partial x} \rho u + \frac{\partial}{\partial y} \rho v + \frac{\partial}{\partial z} \rho w \right] \quad (1)$$

Conservação do calor:

$$\frac{\partial \theta}{\partial t} = - \left[ u \frac{\partial \theta}{\partial x} + v \frac{\partial \theta}{\partial y} + w \frac{\partial \theta}{\partial z} \right] + S_{\theta} \quad (2)$$

Conservação do movimento:

$$\frac{\partial V}{\partial t} = -V \cdot \nabla V - \frac{1}{\rho} \nabla p - g - 2\Omega \times V \quad (3)$$

Conservação da água:

$$\frac{\partial q_n}{\partial t} = -V \cdot \nabla q_n + S_{q_n}, \quad n = 1, 2, 3 \quad (4)$$

Conservação de outros materiais gasosos e aerossóis:

$$\frac{\partial \chi_m}{\partial t} = -V \cdot \nabla \chi_m + S_{\chi_m}, \quad m = 1, 2, \dots, M \quad (5)$$

Equação geral dos gases:

$$P = \rho R^* T \quad (6)$$

Sendo:

$\rho$  – Densidade do ar;

$\theta$  – Temperatura potencial da massa de ar;

$u, v$  e  $w$  – Componentes da velocidade do vento (zonal, meridional e vertical);

$g$  – Constante gravitacional;

$p$  – Pressão atmosférica;

$\Omega$	– Velocidade angular de rotação da Terra;
$q$	– Umidade específica do ar;
$S$	– Área;
$X$	– Outros gases ou aerossóis;
$T$	– Temperatura;
$R^*$	– Constante específica dos gases;

A demonstração das Equações (1) a (6) pode ser encontrada em [10]. Uma das principais variáveis que influenciam os modelos dinâmicos de grande escala, MCGAs, e pequena escala, MRs, é a temperatura da superfície do mar (TSM) dos oceanos. Por exemplo, a variabilidade climática no NEB, principalmente a distribuição sazonal de chuvas (acumulados trimestrais), é primariamente controlada pelas anomalias de TSM dos oceanos Pacífico e Atlântico Tropicais [3,12,13].

## 2.2 A Técnica de *Downscaling*

O acelerado avanço computacional traz a oportunidade de se integrar os resultados de modelagem numérica de escala global com a modelagem de pequena escala, propiciando uma melhor previsão para uma área na região de interesse. Essa técnica consiste no chamado *downscaling*, ou aninhamento, de um modelo numérico global para um modelo numérico regional [2].

Essa técnica tem sido testada nos últimos anos, principalmente na África (com a Região das Monções Asiática) e na América do Sul (com o NEB, como exemplo), apresentado resultados promissores para reduzir a escala da informação climática. O *downscaling* dinâmico tem como base a utilização dos resultados de uma modelagem de grande escala, os quais servem de entrada em um modelo regional de área limitada, com uma resolução de apenas dezenas de quilômetros [2].

O método de perturbação aninhada utilizado no algoritmo de *downscaling* seguiu o utilizado no MCGA sobre todo o domínio do espaço o que o torna um método diferente do utilizado convencionalmente na modelagem numérica, em geral domínio apenas nas zonas de fronteira lateral. As variáveis dependentes no modelo regional são a soma da perturbação e o campo de base (campo que depende do ajuste entre o modelo global e regional). As demais variáveis que não são previstas no MCGA, mas podem ser resolvidas e previstas no modelo regional em um domínio regional, são definidas como perturbações. O aninhamento é feito de tal forma que as perturbações sejam zero fora do domínio regional e diferente de zero dentro do mesmo. A computação das perturbações no domínio regional inclui esquema de tempo semi-implícito, filtragem de tempo, inicialização, e difusão horizontal implícita [5,14].

Em [14] foram feitos diversos testes para poder escolher a melhor resolução horizontal e o tamanho do domínio computacional. Durante a seleção destes, [14] descobriu que a saída do modelo é sensível a resolução do modelo e a localização de sua fronteira lateral.

No trabalho de [14] foi feito o aninhamento do modelo regional espectral (MRE) desenvolvido no *National Centers for Environmental Prediction-National Centers Atmospheric Research* - NCEP/NCAR com um MCGA, ECHAM3.6 para o NBE. O modelo proposto em [14] propõe que as previsões sejam geradas em duas grades de pequena escala, uma grade de 80 km, MRE-80, e uma outra menor de 20 km, MRE-20. Porém, o aninhamento foi feito de forma diferente para cada grade. Para o modelo MRE-80, modelo com a grade de 80 km, foi feito o *downscaling* dele com a saída do ECHAM3.6, enquanto que o modelo MRE-20 foi aninhado diretamente com a saída do MRE-80. Como era esperado pelos autores, o modelo MRE-80 foi o modelo que apresentou os melhores resultados na previsão, enquanto que o MRE-20 apresentou um aumento do erro sistemático.

Para efetuar a previsão sobre o NEB, a FUNCEME desenvolveu um algoritmo de *downscaling* baseado em [14] que reduz a escala dos resultados do modelo global *ECHAM4.5* para uma grade de 60 x 60 km, o que implica em uma resolução de 25 vezes uma vez que a resolução do *ECHAM4.5*, originalmente de 300 x 300 km. A FUNCEME utilizou essa técnica para seus dois modelos regionais: MRE e *Regional Modeling Atmospheric System* (RAMS). Ao efetuar essa diminuição no tamanho da grade acaba-se por melhorar a definição dos processos físicos, pois o *downscaling* incorpora efeitos de topografia, vegetação, contrastes entre continentes e oceanos entre outros [2,5,15,16,4,17].

### 2.3 Modelo Dinâmico de Grande Escala *ECHAM4.5*

O modelo *ECHAM4.5* é baseado no modelo de previsão de tempo do *European Centre for Medium Range Weather Forecasts* (ECMWF [18]). No *Max Planck Institute for Meteorology and German Climate Computing Centre* (DKRZ) vem sendo feitas diversas modificações nesse modelo que atualmente se encontra na quarta geração. Uma detalhada descrição do modelo pode ser encontrada em [19]. Em sua versão padrão, o mesmo apresenta 19 níveis híbridos de altura, que são baseados em sistema de coordenadas de pressão-sigma (coordenadas que definem a altura de uma isóbara, mas acompanham o relevo para se ajustar a elevações – tomando-se pressão do nível dividida pela pressão à superfície no ponto considerado), e seu domínio vertical estende-se até o nível de pressão 10 hPa. As variáveis prognosticadas são: vortacidade e divergência da massa de ar atmosférico, logaritmo de pressão a superfície, temperatura, umidade específica, razão de mistura e total de água de nuvem. Com exceção das componentes de vapor, o prognóstico das variáveis é representado por modelagem

matemática a partir de harmônicos esféricos com truncamento triangular no número de onda zonal T42 - vide Anexo I [2,5,19].

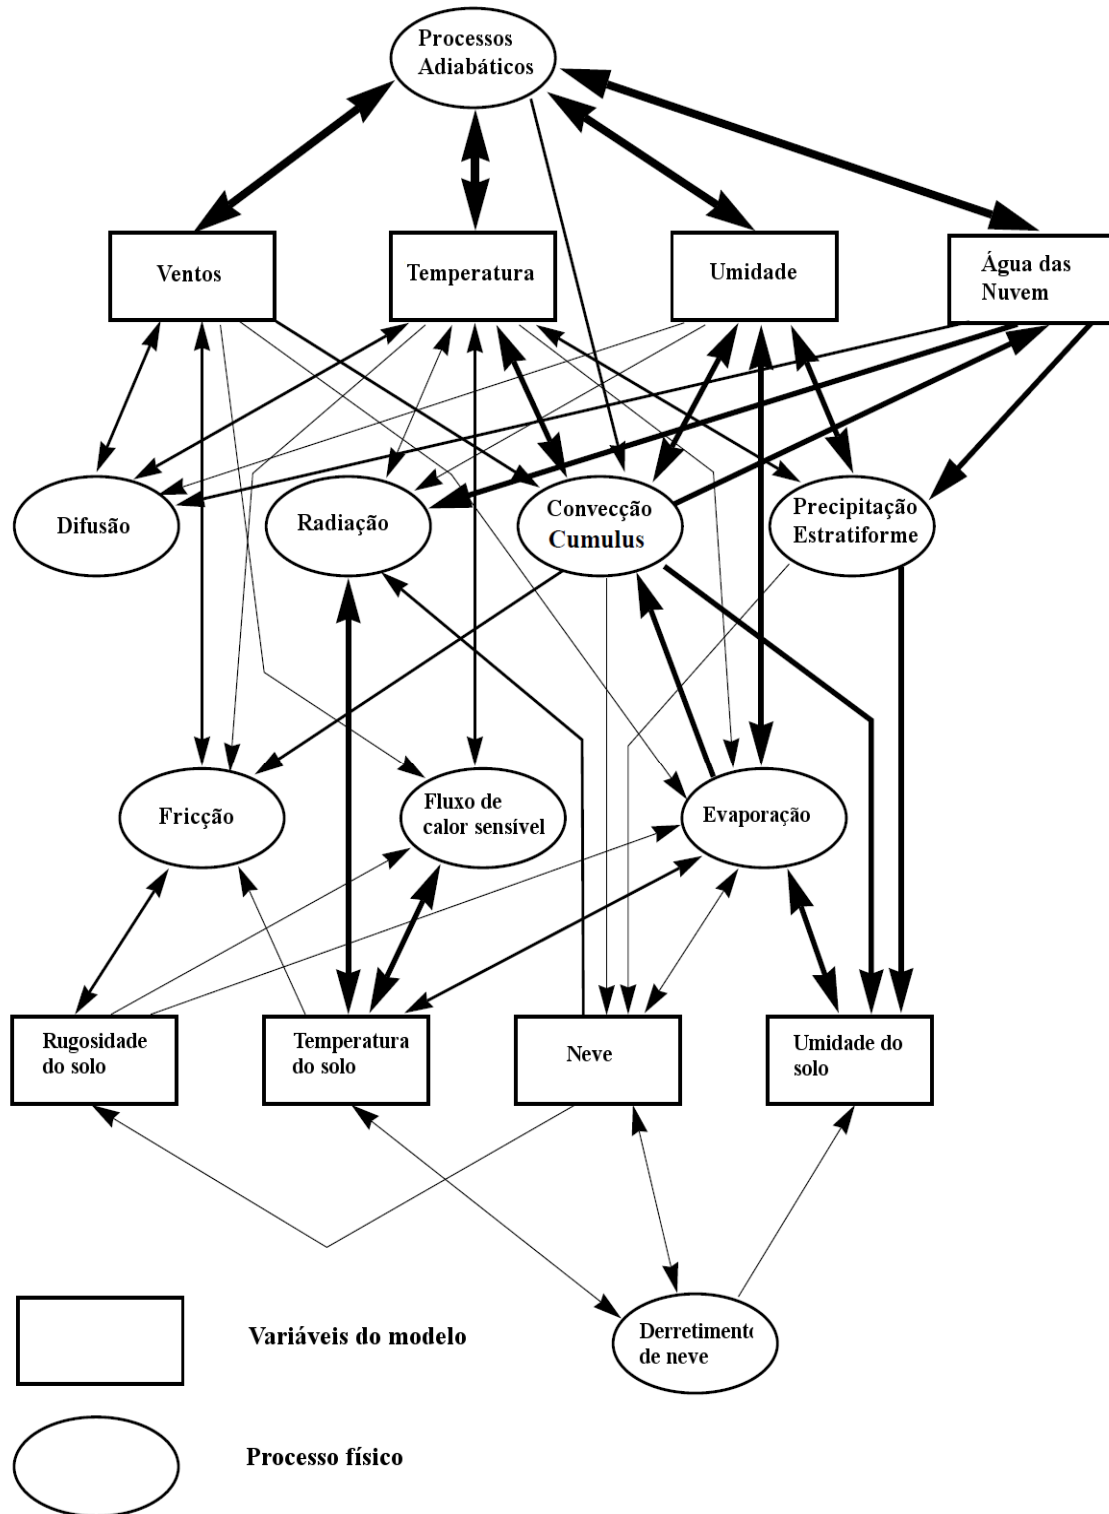


Figura 3 - Representação esquemática dos processos incluídos no MCGA ECHAM. Base para imagem em [20]

O modelo apresenta passo de tempo para a dinâmica e a física do problema de 24 minutos para a resolução horizontal T42. O passo de tempo para a radiação é de

duas horas. Os ciclos diurno e sazonal da forçante solar são simulados. Para o transporte de vapor d'água e água de nuvem um esquema semi-lagrangiano, que resolve as equações do modelo seguindo a trajetória do movimento, é usado. Os fluxos turbulentos de superfície são calculados através do Monin-Obukov bulk, usando teoria da similaridade como descrito por [2]. Um esquema fechado de alta ordem é usado para computar a transferência turbulenta de momento, calor, mistura e água de nuvem dentro e acima da camada limite atmosférica. Os coeficientes de difusão turbulenta são calculados como função da energia cinética turbulenta (E). O modelo de solo contempla os balanços de calor, água no solo, pacote de neve sobre o continente e balanço de calor de gelo sobre o continente [2]. A Figura 3 mostra como é a dependência de diferentes processos com as variáveis do modelo. A espessura da linha indica qualitativamente a importância da interação e, nos casos cíclicos (Temperatura – Fricção – Rugosidade do solo – Fluxo de calor – Temperatura), têm-se processos com retroalimentação [20].

Efeitos de vegetação, tais como interceptações de chuva na copa das árvores e controles de evapotranspiração pelos estômatos, são parametrizados. Os estômatos estão localizados geralmente na epiderme inferior (parte abaxial) e são o órgão responsável por realizar as trocas gasosas entre a planta e o meio ambiente [2].

Para a estimativa do escoamento superficial usa-se como base a área de captação da bacia hidrográfica e leva em consideração as variações de sub-grade da capacidade máxima de armazenamento de água no solo (capacidade de campo) sobre áreas continentais não homogêneas [2].

Os parâmetros de superfície, tais como albedo (medida relativa da quantidade de luz refletida), rugosidade, tipo de vegetação, índice de área foliar e parâmetros de solo (capacidade de armazenamento de água, capacidade e condutividade térmica), assim como as parametrizações de convecção cumulus (rasa, média e profunda) foram compilados segundo [21].

## **2.4 Modelo Regional Espectral 97 (MRE)**

O MRE utilizado é a versão 97 do modelo regional espectral desenvolvido no NCEP. Este apresenta a mesma física do Modelo Espectral Global (MEG) que é usado para previsão de médio prazo descrito em [22]. É um modelo numérico de área limitada que inicialmente teria seus resultados baseados em pontos de grade. Mas, ao perceber que computação espectral apresenta precisão melhor em termos de gradiente e interpolação espectral, os desenvolvedores decidiram-se utilizar o modelo espectral [23].

O modelo regional espectral desenvolvido no *National Centers for Environmental Prediction* (NCEP) tem como base o uso de dois componentes: um modelo espectral global de baixa resolução e um modelo espectral regional de alta

resolução. Uma versão de baixa resolução do modelo global espectral em operação do *National Meteorological Center* (NMC), que utiliza harmônicas esféricas (Anexo I) como funções de base horizontal, é o modelo global enquanto que um modelo primitivo de equação em uma projeção estereográfica, que utiliza series seno-cosseno como funções horizontais de base, é o modelo regional usado [24].

Duas importantes e únicas características desse modelo são o método de perturbação dependente do tempo e a precisão de alta ordem de computação espectral, que são suas principais diferenças entre os outros modelos regionais espectrais. O MRE utiliza transformação espectral para perturbação, sendo uma série de cosseno de duas dimensões para perturbações de pressão, divergência, temperatura e taxa de mistura e uma serie de seno de duas dimensões para perturbação de vorticidade [25].

Segundo [2] um importante avanço ocorreu na dinâmica do MRE para manter a sua estabilidade computacional. Esse consistia na utilização de uma opção de difusão local que está contida no MEG. Ao checar e difundir as áreas de ventos fortes, quando estiverem sendo utilizados passos de tempo longos, a instabilidade computacional pode ser evitada. Essa opção acaba por ser útil para estudos climáticos que requerem integrações mensais com MRE de alta resolução.

O MRE possui 18 níveis sigma na vertical de altura (segue o contorno da topografia), apresentando as seguintes características físicas: radiação de onda longa e curta (com variação diurna), interação com radiação de nuvem, uma camada na superfície com propriedades físicas da camada limite planetária, arrasto por onda de gravidade, convecção “cumulus” tipo Arakawa-Shubert simplificada [26,27]), convecção rasa e alguns processos hidrológicos [28]. Com exceção da rotina de radiação que é chamada a cada hora pelo MRE, as parametrizações físicas são computadas a cada passo de tempo desejado. Este utiliza o modelo de solo de duas camadas para descrever o papel da vegetação e sua interação com a umidade do solo em modificar as trocas de fluxo de momento, energia e vapor entre superfície-atmosfera [29].

Diferentemente dos métodos convencionais utilizados na modelagem numérica, foi utilizado uma técnica de *downscaling*/aninhamento entre o MCGA *ECHAM4.5* e o MRE descrita em [5]. Essa utilizou de forma unidirecional os resultados do MCGA de janeiro a maio dos anos de 1971-2000 como dados de entrada para o MRE de 6 em 6 horas. O método de perturbação aninhada seguiu o utilizado no MCGA sobre todo o domínio e não somente na zona de fronteira lateral. Por fim, as variáveis dependentes no MRE são definidas como a soma da perturbação e o campo base (campo que depende do ajuste do MCGA em relação ao MRE) [2].

## **2.5 Regional Modeling Atmospheric System (RAMS)**

Foi desenvolvido pelo Departamento de Ciências Atmosféricas da Universidade Estadual do Colorado, USA e é voltado primariamente para trabalhar como um modelo de área limitada, e muitas de suas parametrizações foram elaboradas para escala de grade de alta resolução ou de meso-escala [30]. O RAMS pode ser configurado para fazer simulações da circulação atmosférica em várias escalas de tempo e espaço, bem como diferentes resoluções horizontal e vertical, o que o torna um modelo muito flexível [9]. No primeiro esquema, a razão de mistura é prognosticada e a concentração ou tamanhos dos hidrometeoros (conjunto de partículas de água no estado líquido ou sólido que caem ou estão em suspensão na atmosfera, e são levantadas da superfície do globo pelo vento ou estão depositadas em objetos no solo ou na atmosfera livre) são especificados. No segundo caso, tanto a razão de mistura como a concentração e o tamanho dos hidrometeoros são prognosticados. O modelo é escrito em coordenado vertical sigma de altura, que segue o contorno da topografia [9].

A configuração utilizada para calibrar o modelo RAMS é descrita abaixo:

Algumas simulações em que diferentes esquemas de microfísica e radiação e/ou radiação foram testados, o modelo não permaneceu estável e não produziu resultados de precipitação realistas. A combinação de uma microfísica completa (incluindo a fase de gelo) e com o esquema de radiação de Harrington (acoplado a microfísica) teve melhores resultados e foi usada nas simulações dos 30 anos (1971-2000). No caso do teste do *nudging* central o modelo mostrou resultados coerentes, tanto quando o mesmo esteve ligado quanto este foi desligado reproduzindo as diferenças de precipitação no NEB nos anos de 1983 e 1985, apesar da precipitação ser bem mais real no caso em que o *nudging* central foi ligado sendo esse adotado no estudo [9].

Segundo [31], depois de escolhidos os esquemas numéricos e parametrizações físicas mais adequadas e constando-se que o RAMS apresentava sensibilidade significativa com respeito ao *nudging* central, foram realizadas simulações de climatologia (30 anos) com o uso de um membro do *ECHAM4.5*. Essas simulações objetivaram testar três configurações: sem *nudging* central, com *nudging* central fraco (assimilação em uma escala de tempo de 6 horas), e com *nudging* central forte (assimilação de 3 horas). De acordo com os resultados do Heidke Skill para três e cinco categorias de percentis de precipitação no NEB e os valores absolutos de precipitação mais reais, a configuração com *nudging* central fraco teve melhor desempenho sendo essa usada nas simulações dos 10 membros para os 30 anos (1971-2000) [9].

## 2.6 A Sistemática da Geração do Relatório de Previsão

A FUNCEME efetua a rodada de seus modelos de previsão, MRE e RAMS aninhados ao modelo global *ECHAM4.5*, em janeiro para efetuar a previsão para seis meses: janeiro, fevereiro, março, abril, maio e junho. Os resultados para esse período podem ser interpretados para definição do período de pré-estação (janeiro), período de



quadra ou estação chuvosa (fevereiro, março, abril e maio) e período de pós-estação (junho).

De posse da previsão, a FUNCEME então organiza dois eventos distintos. No primeiro evento é feita uma reunião entre os meteorologistas pertencentes à instituição para discutir os resultados dos modelos rodados e suas perspectivas. Durante esta primeira reunião não somente são analisados os dados dos modelos rodados, apesar de serem importantes, mas cada meteorologista traz consigo informações consideradas individualmente relevantes para efetuar a previsão, como por exemplo, avaliações sobre eventos oceano-atmosférico, como El Niño/La Niña, e a situação do dipolo do Oceano Atlântico. Após a perspectiva de cada membro ter sido apresentada é feito um debate final entre todos. Ao entrarem em um consenso único, é gerado um relatório com a previsão oficial da FUNCEME.

Somente após a primeira reunião ter ocorrido, e ter sido gerada a previsão oficial da fundação, é que é convocado o segundo evento, geralmente ocorrendo na forma de workshop. Nesse segundo evento, diversas instituições são convidadas a enviar seus membros para apresentarem suas perspectivas para o período. São apresentadas as previsões oficiais das diversas instituições, nacionais e internacionais, sendo finalizado com um debate quanto ao prognóstico de chuvas. Assim, o relatório final de previsão de chuvas é gerado e entregue aos órgãos públicos interessados nessa informação, como a Defesa Civil, e ao público em geral, através do site e da imprensa.

O ultimo Workshop que ocorreu se intitulou XIII Workshop Internacional de Avaliação Climática para o Semiárido Nordeste que ocorreu no dia 19 de janeiro de 2011 e contou com a participação de meteorologistas de institutos climáticos de nove estados do Nordeste, do INPE, INMET, além de órgãos da França e Reino Unido. Nesse foram apresentados os resultados esperados por todos os participantes. Ao final do evento ocorreu um debate final no qual foi definido qual seria a previsão para o nordeste. Em seguida um relatório foi apresentado aos representantes dos meios de comunicação para que a informação fosse passada ao público. O relatório final pode ser encontrado em [4].

As chuvas na Região Nordeste têm como característica principal a variabilidade espacial e temporal, ou seja, não há como definir em qual município vai chover exatamente ou quais são os dias de chuva. Além disso, a previsão de eventos da natureza, que são sistemas caóticos, não pode ser feita com uma certeza de 100%. Daí a previsão ser entregue em termos probabilísticos separada em três categorias (chuvas em torno da média, acima ou abaixo da média histórica) sobre toda a região.

A discussão entre os diversos órgãos que efetua a previsão sobre a região nordeste é baseada principalmente no processamento de modelos dinâmicos (modelos de larga escala, global, e os modelos de pequena escala, regionais) que requerem a utilização de um sistema computacional robusto e caro. Um modelo baseado em RNA, que apresenta baixo custo operacional, contribui através da adição de novas informações para a geração do relatório.

### 3 MODELO INTELIGENTE DE PREVISÃO DE CHUVAS

Apesar de toda a capacidade de processar informação que os computadores apresentam atualmente, ainda há uma grande dificuldade de realizar tarefas que são feitas no cotidiano humano [32]. O cérebro humano é capaz de processar tarefas que são consideradas de extrema complexidade como, por exemplo, reconhecer padrões de forma automática sem muito esforço. Isso é possível devido à capacidade de processamento em paralelo e de aprendizado que o cérebro humano possui [33]. Em muitas aplicações, como na modelagem de sistemas complexos, é desejável reproduzir essa capacidade humana. Desta forma, começaram a surgir os algoritmos baseados na fisiologia do cérebro, área de pesquisa que passou a ser denominada por Redes Neurais Artificiais (RNAs) [32].

A seguir será apresentado um breve histórico de RNA, seguido por um levantamento do estado-da-arte da aplicação destas aos estudos meteorológicos na Seção 3.1. Na seção seguinte é descrita a rede NFN. Na Seção 3.3 são apresentados os testes preliminares para a obtenção da estrutura do modelo proposto. Dando continuidade é apresentado o MPSCI. Por fim é mostrado o algoritmo do MPSCI.

#### 3.1 Redes Neurais Artificiais na Previsão Meteorológica

Segundo Kröse e Smagt [34], a primeira onda de interesse em RNAs ocorreu por volta de 1943 quando McCulloch e Pittis escreveram seu trabalho trazendo uma introdução a um modelo simplificado de neurônio: o perceptron [35]. Por volta de 1969, Minsky e Papert publicaram seu livro [36] que acabou por dar um golpe nas pesquisas envolvendo RNA, uma vez que mostrava as deficiências de modelos baseados no perceptron [34].

A recuperação das RNA ocorreu após a obtenção de importantes resultados teóricos na década de 80, mais notadamente a proposta do algoritmo de retropropagação do erro (*backpropagation*). Desde então, Redes Neurais formam uma linha de pesquisa em constante ascensão, e presente em diversos departamentos das universidades [34]. Modelos baseados em RNA são conhecidos por funcionarem como aproximadores universais capazes de aprender, e reproduzir, o comportamento dos mais diferentes sistemas. Devido a essa característica, a utilização destas na previsão de variáveis meteorológicas já vem sendo abordada em diversos trabalhos. A seguir serão apresentados alguns destes.

Em 2007, Hayati e Mohebi [37] utilizaram uma rede Perceptron de Múltiplas Camadas (MLP, do inglês *MultiLayer Perceptron*) para efetuar a previsão de curto prazo de temperatura para a cidade de Kermanshah, localizada no oeste do Irã. Utilizou-se dez anos (1996-2006) de dados meteorológicos para efetuar o treinamento e

a validação. Separou seus dados de forma aleatória em dois grupos: um grupo de treinamento contendo 67% dos dados e um de teste com os restantes 33% dos dados. Para verificar a generalização da rede separou-se, aleatoriamente, quatro dias que não passaram por treinamento nem teste. Para efetuar a medição do erro foi usado o erro médio absoluto (MAE, do inglês Mean Absolute Error). Foi utilizada uma RNA baseada em MLP com três camadas: uma de entrada, uma escondida e uma de saída. Na camada escondida utilizou função sigmoide e na de saída linear. A configuração que apresentou os melhores resultados está descrita na Tabela 1. A Tabela 2 mostra o menor e maior erro obtido ao longo dos experimentos realizados em [37] para os dias escolhidos para a validação. Em suas conclusões, Hayati e Mohebi [37] afirmam que o modelo teve bom desempenho, e precisão razoável para efetuar a previsão de um dia à frente.

Tabela 1 - Melhor configuração da RNA de [37]

Número de camadas escondidas	1
Número de neurônios da camada escondida	6
Número de apresentações do conjunto de treinamento	2000
Função de ativação da camada escondida	Tangente-sigmoide
Função de ativação da camada de saída	Pura linear

Tabela 2 - Menor e maior erro para os dias de validação nos experimentos de [37]

<b>Dia</b>	<b>Erro Mínimo</b>	<b>Erro Máximo</b>
02/01/1997	0,0079	0,6905
27/08/2000	0,1257	0,8005
09/06/2004	0,0809	1,0006
29/11/2006	0,0336	1,2916

O estudo de Huang e colegas em 2006 [38] buscou prever a formação de tempestades de areia no Nordeste da China com o uso de um modelo de RNA. Foram utilizados dados das médias mensais de variáveis meteorológicas (pressão, temperatura, umidade, velocidade do vento, temperatura da superfície do solo, precipitação e evaporação) e a ocorrências de tempestades de areia para efetuar a previsão. A ocorrência de tempestades é registrada da seguinte forma: se ocorre mais de uma tempestade de areia em um dia é registrada uma ocorrência de um “dia de tempestade de areia”; se um evento de areia persiste e passa da marca de 20:00h no horário de Beijing, “dois dias de tempestade de areia” são registrados. De forma a quantificar os

registros de tempestades de areia, os autores atribuíram o valor de 0,5 para dias com registro de tempestade de areia e -0,5 para dias sem registro. Foram desenvolvidos dois modelos de previsão: um baseado em regressão linear múltipla e outro em RNA. Para o método baseado em regressão linear utilizou o software Statistical Package for the Social Science (SPSS) para Windows. A estrutura do modelo neural selecionado foi a *Neural Network ARX* (NNARX) com o algoritmo de treinamento pelo método básico de Levenberg-Marquardt. O algoritmo foi desenvolvido no software Matlab na sua versão 5.3 utilizando o toolbox chamado de Neural Network Based System Identification Toolbox [33]. Os autores utilizaram o coeficiente de correlação de Pearson como parâmetro para avaliar o desempenho de ambos os modelos. O modelo baseado em regressão linear apresentou os seguintes coeficientes 0,133, 0,196, 0,266 e 0,223 enquanto que o modelo baseado em RNA obteve 0,333, 0,315, 0,364 e 0,347 para as regiões de Minqin, Keping, Mingfeng e Qiemo, respectivamente. A Tabela 3 resume os resultados obtidos para a RNA com relação a taxa de sucesso de previsão (PSR, do inglês Prediction Success Rate) que corresponde a divisão do número de tempestades previstas pelo total de tempestades registradas mais o número de declarações incorretas. Em suas considerações finais, Huang [38] diz que o modelo neural apresentou bons resultados para previsão de curto prazo.

Tabela 3 - Resultados do modelo baseado em RNA de [38]

	<b>Tempestades de areia registradas</b>	<b>Previstas</b>	<b>Não- previstas</b>	<b>Declarações incorretas</b>	<b>PSR(%)</b>
<b>Ano 2000</b>					71,6
<b>Minqin</b>	7	5	2	1	62,5
<b>Keping</b>	7	4	3	0	57,1
<b>Mingfeng</b>	3	2	1	0	66,7
<b>Qiemo</b>	2	2	0	0	100
<b>Ano 2001</b>					68,2
<b>Minqin</b>	7	4	3	0	57,1
<b>Keping</b>	13	8	5	1	57,1
<b>Mingfeng</b>	15	10	5	2	58,8
<b>Qiemo</b>	2	2	0	0	100

Evsukoff, Lima e Ebecken em 2011 [39] desenvolveu um modelo de chuva-vazão para a bacia do Rio Iguaçu localizada no sul do Brasil. Esse foi desenvolvido para dar suporte a operação de usinas hidroelétricas e prever a vazão natural na bacia. Como entrada foi utilizada a resposta de previsão de precipitação fornecidas pelo modelo meteorológico Eta de [40]. Os dados correspondem ao acumulado de 24 h em uma grade de 40 km x 40 km para os anos de 1996 a 2001. Os dados apresentam a previsão para toda a América do Sul, porém foram utilizados apenas 15 pontos no sentido Leste-Oeste, entre as longitudes  $-49^\circ$  e  $-54,6^\circ$ , e 6 pontos no sentido Norte-Sul, entre as latitudes  $-25^\circ$  e  $-27^\circ$ , que englobam apenas a bacia desejada. O modelo deve funcionar de forma semanal, estimando a vazão da bacia baseada na vazão anterior observada, que é utilizada apenas na inicialização do modelo e passando a usar a estimativa feita a partir da próxima execução, e a precipitação prevista pelo modelo Eta. Durante o treinamento os autores utilizaram dados de precipitação observados, pois devido aos grandes erros contidos na previsão meteorológica que poderia corromper os dados. Foi utilizado um modelo fuzzy recorrente para efetuar a previsão da vazão na bacia. Como entrada foi utilizado os dados meteorológicos previstos pelo modelo Eta e as observações do dia atual e do dia anterior de vazão para prever a vazão do próximo dia. Utilizou-se algoritmo genético para efetuar a estimação dos parâmetros da rede.

Para a previsão do total de vazão natural utilizando a precipitação observada o modelo proposto por [39] não apresentou coeficiente de eficiência Nash-Sutcliffe e Nash-Sutcliffe com valores logaritmos menor que 0,9; o valor do rms não foi maior que 300 m<sup>3</sup>/s que representa cerca de 6% enquanto que o porcentagem média absoluta (MAPE, do inglês Mean Absolute Percentage) do erro ao final do horizonte de previsão foi de cerca de 17%. Com isso os autores puderam concluir que o modelo alimentado com os valores observados de precipitação tem performance adequada de acordo com todas as métricas. Quando utilizado a previsão de chuva o desempenho decaiu ao longo do horizonte de previsão. No quinto dia de previsão o rms é cerca de 450 m<sup>3</sup>/s que representa 9% do máximo valor da vazão, o MAPE do erro é cerca de 25% e os coeficientes Nash-Sutcliffe sem e com valores logaritmos são respectivamente 0,7 e 0,8. Apesar disso os autores de [39] afirmam que para a previsão com um horizonte não superior a cinco dias ambos os modelos desenvolvidos apresentaram melhores resultados que o modelo anteriormente para efetuar a mesma previsão.

Uma técnica neuro-fuzzy foi utilizada em 2010 por Talei, Chua e Quek [41] para gerar um modelo chuva-vazão baseado em evento para a região da bacia de Kranji em Singapura. Os resultados do modelo neuro-fuzzy, sistema de inferência fuzzy baseado em rede adaptativa (ANFIS, de inglês adaptative network-based fuzzy inference system) foram comparados aos resultados obtidos pelo modelo físico chamado *Storm Water Management Model* (SWMM). Foram feitas duas calibrações para ambos os modelos, SWMM1, SWMM2, ANFIS1 e ANFIS2. Como forma de avaliar o resultado de todos os modelos desenvolvidos foram calculados o coeficiente de eficiência e o erro de pico relativo. Esses valores são mostrados na Tabela 4. Em suas conclusões, os autores afirmam que ambos os modelos, físico e neuro-fuzzy,

apresentaram resultados semelhantes, porém o modelo neuro-fuzzy obteve melhores resultados na previsão quando ocorreram picos de vazão.

Tabela 4 - Resultados obtidos por [41]

<b>Modelo</b>	<b>Coefficiente de Eficiência</b>	<b>Erro de Pico Relativo</b>
SWMM1	0,6342	0,313
ANFIS1	0,2878	0,342
SWMM2	0,6275	0,372
ANFIS2	0,5137	0,262

O desenvolvimento de modelos voltados para previsão de chuva pode ser encontrado em [42,43,44,45,46,47], e tem apresentado resultados promissores, inclusive ao se comparar aos resultados de modelos clássicos de previsão.

Chau e Wu em 2010 [42] desenvolveram um modelo que se utilizou de um conjunto de técnicas para efetuar a previsão de precipitação. Inicialmente foi utilizada uma técnica de análise espectral singular para decompor a serie de precipitação em componentes aditivos que geralmente podem ser interpretados como “tendências” (que podem vir a não existir), vários componentes “oscilatórios” e componentes de ruído. Em seguida os dados passam por um filtro e então são distribuídos em três grupos através de um algoritmo de Fuzzy C-Means (FCM) que representam precipitação de baixa intensidade (ou zero), precipitação de média intensidade e precipitação de alta intensidade (eventos de tempestade). Em seguida os dois primeiros grupos (baixa e média intensidade) são associados a uma RNA cada enquanto que o terceiro é associado a uma modelo de regressão de vetor de suporte e a saída é representada pela resposta de um desses modelos para cada amostra, referenciado como ANN-SVR-SSA. O modelo proposto foi comparado com dois outros modelos baseados em RNA: um que usa como entrada os dados de precipitação sem terem passado pela análise espectral singular nem o filtro, referenciado como ANN, e outra que usa como entrada os dados após esses dois procedimentos, referenciado como ANN-SSA. Como parâmetros de desempenho foram utilizados o valor do rms e o coeficiente de eficiência Nash-Sutcliffe (CE). Um resumo dos resultados encontrados em [42] pode ser visto na Tabela 5. Segundos os autores o uso de um filtro de análise espectral singular acarreta em uma melhoria da previsão para uma RNA e com o uso de um modelo SVR para efetuar a previsão em casos de alta intensidade de precipitação gerou uma melhoria considerável na previsão dos picos de chuvas.

Tabela 5 - Resumo dos resultados de [42] para as três redes testadas e para a previsão de um, dois e três dias de horizonte.

Bacia	Model	RMS			CE		
		1	2	3	1	2	3
<b>Wuxi</b>							
	ANN	10,59	11,50	11,59	0,17	0,02	0,00
	ANN-SSA	4,66	5,41	6,35	0,84	0,78	0,70
	ANN-SVR-SSA	4,18	3,48	4,14	0,87	0,91	0,87
<b>Zhenwan</b>							
	ANN	10,68	11,05	11,12	0,09	0,03	0,02
	ANN-SSA	4,94	5,60	5,89	0,81	0,75	0,71
	ANN-SVR-SSA	3,18	3,20	3,31	0,92	0,92	0,91

Weerasinche, Premaratne e Sonnadara em 2010 [43] desenvolveram um modelo de previsão de chuva para a cidade de Sri Lanka baseado em RNA. Seu trabalho apresentou dois tipos de previsão: um para determinar a ocorrência de precipitação como “choveu” e “não choveu” e um outro para prever a quantidade de precipitação em vários sub níveis utilizando técnicas fuzzy. Para efetuar o treinamento e validação dos modelos desenvolvidos foram usados os dados de dez estações vizinhas contendo 30 anos de dados (1970 – 1999), sendo 20 anos para treinamento (1970 – 1989) e 10 para validação (1990 – 1999). Os dados de precipitação utilizados no modelo que efetua a previsão de ocorrência de chuva foram caracterizados da seguinte forma: dias em o registro de precipitação for menor que 0,3 mm é considerado um dia seco e para valores maiores ou iguais é um dia molhado. Nesse modelo utilizou-se uma RNA alimentada a frente com algoritmo de retro-propagação com uma camada escondida, com 11 neurônios, e com a entrada consistindo do registro de precipitação dos três últimos dias das três estações mais próximas ao ponto de previsão. O segundo modelo foi desenvolvido para classificar, quanto a intensidade, a ocorrência de chuva em dias molhados através de um classificador fuzzy. No modelo fuzzy a intensidade de precipitação é classificada em branda, pouca, moderada e pesada. Ao final de [43] os autores tiraram as seguintes conclusões: o modelo de previsão de ocorrência de precipitação obteve sucesso ao prever a precipitação do dia seguinte, com uma taxa de sucesso de  $79\pm 3\%$ , com uma melhor previsão para os dias sem chuva (taxa de sucesso de  $90\pm 2\%$ ); quando treinada somente para o período chuvoso a rede apresentou uma taxa de sucesso de  $72\pm 2\%$ ; a previsão para dias molhado aumentou em quase 100%

quando a rede foi treinada com dados sazonais; o modelo fuzzy apresentou uma taxa de sucesso de  $80\pm 5\%$  para efetuar a previsão para o dia seguinte.

Em 1999, Brooks e Doswell [44] desenvolveram duas RNAs para efetuar a previsão: (i) da probabilidade de chuva (PdP) e (ii) da quantidade de chuva (QPF) para as próximas 24h na área do Dallas-Fort Worth, Texas. Ambas utilizaram como entrada a saída em grade do Modelo Eta do NCEP e sondagem do ar superior do Fort Worth, assim, a entrada é composta por 19 variáveis meteorológicas e a precipitação observada. As redes apresentaram três características: ambas as redes foram treinadas separadamente para o período quente e frio; foram processadas em paralelo; as redes são interativas. Para ambas as redes foram usados os dados de 1994 a 1995 para efetuar o treinamento e de 1 de março de 1996 a 28 de fevereiro de 1998 para validar a rede. Apesar de não falar claramente que a rede foi utilizada essa apresenta a estrutura similar a de uma MLP. Para avaliar os resultados da rede que efetua a previsão PdP foi utilizado a pontuação Bier que avalia as diferenças ao quadrado da previsão e dos eventos e então comparar com a de um modelo de referencia, que no caso foi a amostra climatológica. A pontuação de habilidade da rede neural foi de 73,0% enquanto que para o modelo de referencia é de 34,2%. Para o modelo para prever QPF foi obtido uma correlação de 0,95. Os autores afirmam que suas redes mostraram ótimos resultados para ambos os tipos de previsão, probabilidade de chuva e quantidade de chuva, porém ainda se faz necessário fazer mais estudos para casos específicos para testar mais a rede.

Um modelo neural para previsão em tempo real de chuva, e para o controle de cheias, foi desenvolvido em 2009 por Hung e colegas [45]. A RNA adotada no trabalho foi uma MLP e utilizou como parâmetros de entrada uma combinação de variáveis meteorológicas (umidade relativa, pressão do ar, temperatura e nebulosidade), e medidas como a chuva no ponto de previsão e a precipitação nas regiões de entorno, para períodos chuvosos e não chuvosos. Foram utilizados os dados de 75 estações, localizadas na região de Bangkok, coletados de hora em hora no período de 1 de janeiro de 1991 a 31 de dezembro de 1999 para o treinamento da RNA, e os dados do ano de 2003 para a validação. Diferentes configurações foram usadas e foram comparados seus resultados com base no Índice de Eficiência (IE) no valor do rms e no coeficiente de correlação. O modelo que apresentou os melhores resultados utilizou uma RNA alimentada a frente generalizada com duas camadas escondidas, uma com 22 e outra com 11 neurônios, com 9 variáveis de entrada (precipitação, umidade relativa, temperatura, pressão do ar, nebulosidade, media horaria de precipitação, precipitação das três estações mais próximas). Os melhores resultados, para o período de teste, foram: 94,82% para IE; 1,24 mm/h para o rms; 0,95 de correlação. O modelo neural para a previsão de uma hora a frente mostrou-se eficiente tanto por apresentar rápida convergência quanto de tratar ruídos na entrada.

Srivastava e colegas [46], em 2010, desenvolveram um modelo de previsão de média mensal de chuva na Índia treinando um modelo neural-fuzzy com índices oceano-atmosféricos. Este modelo utiliza um *fuzzy-ranking algorithm* (FRA) para efetuar a seleção das melhores variáveis de entrada (melhores preditores) a fim de obter



a previsão desejada. Em [46] a base de dados foi dividida em três conjuntos: um para treinar, outro para testar e um para validar a rede. Essa divisão foi feita a partir de três métodos: escolha aleatória, aproximação por um mapa auto-organizado e aproximação por algoritmo *Fuzzy-C Means* (FCM). Ambos os métodos de aproximação separam os dados em agrupamentos menores e só então selecionar os elementos de cada conjunto. O modelo utilizado foi uma RNA com algoritmo de retropropagação. O sistema de previsão que apresentou os melhores resultados foi o que utilizou dois algoritmos fuzzy (FRA e FCM) em conjunto com uma RNA com 14 entradas (anomalia da SST para diferentes localizações, índice de oscilação sul e o índice decadal de oscilação do pacífico) e com os seguintes índices de desempenho: 0,5669 de coeficiente de determinação ( $R^2$ ); 29,92mm como valor do rms; 5,01% como valor do erro médio percentual absoluto. Em suas conclusões [46] afirma que a utilização da TSM ou dos índices oceano-atmosféricos sozinhos não conseguem efetuar uma adequada descrição do modelo de previsão de chuva, mas a combinação de ambos é capaz de produzir um modelo de previsão melhor.

Em 2010, Wu, Chau e Fan [47] propuseram o uso de um modelo baseado em uma rede neural artificial modular (RNAM) para efetuar a previsão da média diária de chuva sobre as bacias dos rios Daning e Zhenshui na China, e para a previsão da média mensal sobre a Índia e a cidade de Zhongxian da China. Foi utilizado um algoritmo FCM para separar as entradas em três agrupamentos. Em cada agrupamento é colocada uma RNA baseada em MLP que é treinada individualmente. Como forma de verificar o desempenho do método proposto é feita uma comparação entre os seus resultados com três modelos de referência: RNA baseada em MLP, *k-nearest-neighbors* (K-NN) e regressão linear (RL). Os dados de precipitação diários para a bacia do rio Daning correspondem ao período de 1 de janeiro de 1988 a 31 de dezembro de 2007, enquanto que para a bacia do rio Zhenshui ao período de 1 de janeiro de 1989 a 31 de dezembro de 1998. Os dados mensais de precipitação da Índia são pertencentes ao período de janeiro de 1871 a dezembro de 2007 enquanto que os dados de Zhongxian correspondem ao período de janeiro 1956 a dezembro de 2007. A Tabela 6 apresenta os resultados da comparação entre as saídas das redes RNA e RNAM obtidos por [47]. Novamente o uso de um sistema neural com um sistema fuzzy apresentou os melhores resultados dentre os modelos testados.

Desta forma pode-se verificar a larga aplicação de RNA na previsão de eventos meteorológicos. Seguindo a ideia desses artigos foi desenvolvido um sistema de previsão de chuvas baseado no modelo *Neo-Fuzzy Neuron* (NFN) [48], com o algoritmo de aprendizado que seleciona a taxa de aprendizado de forma ótima, proposto por [49] e assim complementar a literatura em previsão de chuvas ao verificar a performance deste tipo de modelo.

Tabela 6 - Tabela com resultados da comparação dos resultados de [46] entre as redes RNA e RNAM.

Bacia Hidrográfica	Modelo	RMS	Coefficiente de Eficiência	Índice de Persistência
WuXi	RNA	4,43	0,84	0,87
	RNAM	3,63	0,90	0,92
Zhenwan	RNA	5,02	0,81	0,88
	RNAM	3,18	0,92	0,95
Índia	RNA	164,7	0,97	0,95
	RNAM	144,2	0,98	0,95
Zhongxian	RNA	34,09	0,84	0,84
	RNAM	28,58	0,86	0,86

### 3.2 Neo-Fuzzy Neuron

Devido ao aumento do uso de RNAs e de Sistemas de Inferência Fuzzy (SIF), surgiram sistemas híbridos, neuro-fuzzy, como uma sinergia entre ambos. As redes *Neo-Fuzzy Neuron* (NFN) seguem nesse contexto. Esse tipo de sistema apresenta as capacidades de aprendizado de uma RNA e a facilidade de interpretação e transparência da aproximação fuzzy [49].

De maneira simplificada, pode-se descrever um modelo NFN como sendo uma rede neural em que os neurônios são unidos a funções fuzzy de pertinência/regras. Essa rede apresenta um rápido treinamento, convergindo para um erro mínimo com poucas apresentações dos dados de treinamento, e é capaz de convergir para um erro mínimo global, ver [50]. A estrutura de uma rede NFN é similar a de uma RNA com n-entradas. Porém no lugar dos usuais pesos sinápticos são colocadas sinapses não-lineares. A Figura 4 mostra um exemplo de uma rede NFN. Esta rede é composta por “n” neurônios-fuzzy, sendo “n” a dimensão da entrada [49].

De forma simplificada, dada a entrada  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ , pode-se assim descrever uma rede NFN da seguinte forma: apresenta “n” neurônios, sendo que cada neurônio possui  $h_i$  partições, com  $i=1,2,\dots,n$ . Cada partição possui uma função de pertinência  $\mu_{ji}$  e um peso sináptico ajustável  $w_{ji}$  associado a ela, sendo que “j” representa a partição, podendo assumir valores entre  $[1,2,\dots,h_i]$ , e “i” o neurônio a que pertence essa partição [48].

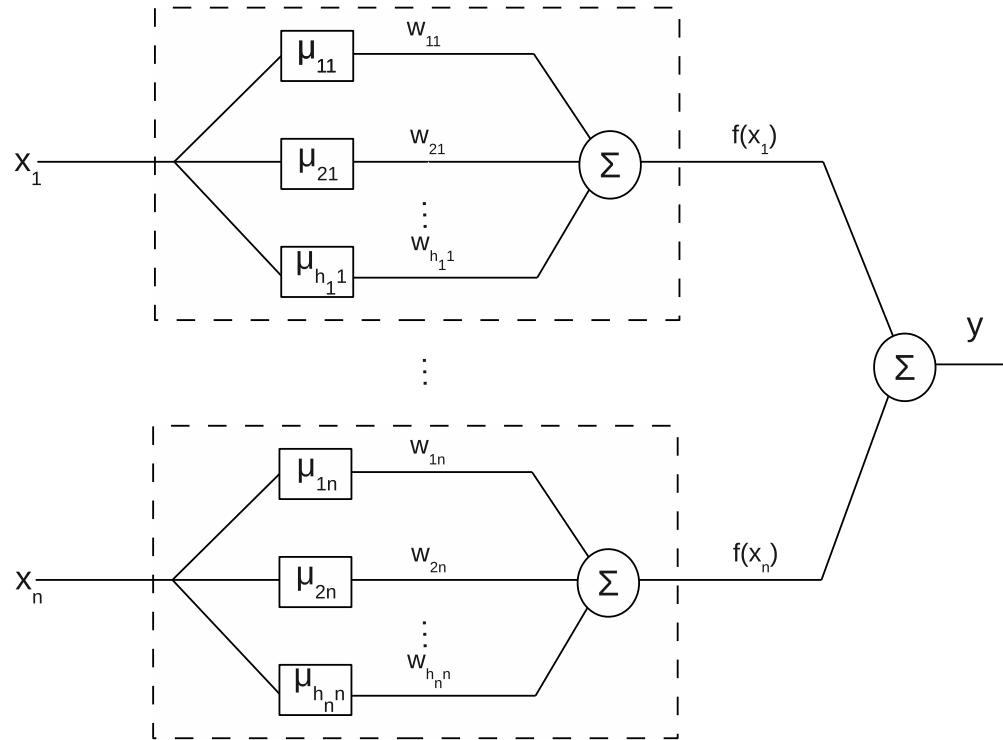


Figura 4 - Estrutura de uma rede NFN.

Uma entrada  $x_i$  passa por um processo de fuzificação ponderada pelo peso sináptico, e em seguida é feita a defuzzificação dessa resposta. Pode-se interpretar melhor segundo a Equação 7:

$$f(x_i) = \sum_{j=1}^{h_i} [\mu_{ji}(x_i) w_{ji}] \quad (7)$$

Sendo  $\mu_{ji}(x_i)$  a ativação da função de pertinência e  $w_{ji}$  é o peso sináptico da partição “j” do neurônio “i”;  $h_i$  e  $f(x_i)$  são, respectivamente, o número de partições e a saída do neurônio “i”.

Assim, a saída  $y$  do modelo pode ser descrita pela Equação 8:

$$y = \sum_{i=1}^n f(x_i) = \sum_{i=1}^n \sum_{j=1}^{h_i} [\mu_{ji}(x_i) w_{ji}] \quad (8)$$

Como função de pertinência foram utilizadas funções triangulares homogêneas [48], mostradas na Figura 5. Essa estrutura é utilizada para tentar garantir que no máximo apenas duas funções de pertinência estejam ativas ao mesmo tempo.




Figura 5 - Exemplo de funções de pertinência triangulares e homogêneas.  $C_{ji}$ , com  $j=1,2,\dots,h_i$ , são os centros das triangulares que compõem as partições de um determinado neurônio. Esses centros variam do valor mínimo ao máximo da variável de entrada associada ao neurônio.

A rede NFN passa por um processo de treinamento supervisionado no qual apenas os pesos sinápticos  $w_{ji}$  são ajustados. De forma semelhante a uma RNA convencional, um padrão de entrada é apresentado à rede que gera um sinal de saída. Esse sinal então é comparado com o valor desejado, gerando um sinal de erro, que é usado para ajustar os pesos da NFN [48]. O critério de aprendizado escolhido foi o erro médio quadrático padrão, conforme a Equação 9:

$$E_{\text{mse}}(k) = \frac{1}{2} (d(k) - y(k))^2 = \frac{1}{2} e(k)^2 \quad (9)$$

Sendo  $E_{\text{mse}}$  o erro médio quadrático,  $d$  o valor desejado,  $y$  a saída do modelo e “ $e$ ” o valor da diferença entre o valor desejado e obtido pelo modelo, todos com referência à interação  $k$ . A atualização dos pesos é feita a cada apresentação de uma amostra.

Para uma rede padrão pode-se utilizar o método do gradiente descendente [49] como função de minimização. Desta forma, a regra de atualização dos pesos é mostrada na Equação 10:

$$w_{ji}(k+1) = w_{ji}(k) + \eta e(k) \mu_{ji}(x_i(k)) \quad (10)$$

Sendo  $\eta$  o valor da taxa de aprendizado que determina a velocidade do aprendizado.

Na busca por melhorar a velocidade de convergência, nessa dissertação utilizou-se o algoritmo de atualização referenciado por [49] que seleciona a melhor taxa de aprendizado para cada amostra. Para cada neurônio  $i$ , e cada uma de suas partições  $h_i$ , são definidos os seguintes vetores:  $\boldsymbol{\mu}^{(i)} = [\mu_{1i}, \dots, \mu_{h_i}]^T$  e  $\boldsymbol{w}^{(i)} = [w_{1i}, \dots, w_{h_i}]^T$ . Assim, a saída  $y$  para a amostra  $k$  pode ser expressa na Equação 11:

$$y(k) = \sum_{i=1}^n \left[ \left( \boldsymbol{w}^{(i)}(k) \right)^T \cdot \boldsymbol{\mu}^{(i)}(k) \right] \quad (11)$$

Sem perda de generalização o vetor  $\boldsymbol{\mu}^{(i)}$  será definido em uma versão normalizada  $\tilde{\boldsymbol{\mu}}^{(i)}$  como mostrado na Equação 12:

$$\tilde{\boldsymbol{\mu}}^{(i)}(k) = \frac{\boldsymbol{\mu}^{(i)}(k)}{\sum_{j=1}^{h_i} \mu_{ji}(k)} \quad (12)$$

Assim, a saída  $y$  é reescrita na Equação 13:

$$y(k) = \sum_{i=1}^n \left[ \left( \boldsymbol{w}^{(i)}(k) \right)^T \cdot \tilde{\boldsymbol{\mu}}^{(i)}(k) \right] \quad (13)$$

Definindo-se os seguintes vetores:  $\tilde{\boldsymbol{\mu}}^T = [(\tilde{\boldsymbol{\mu}}^{(1)})^T, \dots, (\tilde{\boldsymbol{\mu}}^{(n)})^T]$  e  $\boldsymbol{w}^T = [(\boldsymbol{w}^{(1)})^T, \dots, (\boldsymbol{w}^{(n)})^T]$ , o algoritmo de aprendizado é expresso pelas Equações 14 e 15:

$$\begin{cases} \boldsymbol{w}(k+1) = \boldsymbol{w}(k) + e(k) \tilde{\boldsymbol{\mu}}(k) (\alpha^w)^{-1}(k), & (14) \\ \alpha^w(k+1) = \alpha \alpha^w(k) + \|\tilde{\boldsymbol{\mu}}(k+1)\|^2, & (15) \end{cases}$$

Sendo  $\alpha$  o fator de esquecimento, que indica a influencia de uma amostra sobre a outra e variando  $0 \leq \alpha \leq 1$ , e  $\alpha^w$  a taxa de aprendizado escolhido dinamicamente para ser utilizada na atualização dos pesos. No caso desta dissertação os valores de inicialização de  $\alpha$  e  $\alpha^w$  é 0,5. O vetor  $\boldsymbol{w}$  é inicializado de forma aleatória.

Desta forma para cada amostra uma nova taxa de aprendizado é selecionada com o objetivo de tornar o aprendizado das informações mais rápido.

### 3.3 Testes Preliminares

Como forma de avaliar se a utilização de um sistema neuro-fuzzy seria uma boa escolha para efetuar a previsão de clima para o estado do Ceará, foram montados dois protótipos de redes RNAs, um baseado em uma MLP e o outro baseado em uma NFN, objetivando verificar o desempenho de ambas as redes. Estes protótipos seriam

responsáveis por prever o acumulado de chuvas de um trimestre sobre uma determinada região utilizando como entrada informações do último trimestre.

Uma rede MLP é composta por uma camada de entrada com unidades de sensoriamento, uma ou mais camadas escondidas e uma camada de saída [33]. É uma rede alimentada à frente onde cada neurônio tem sua função de ativação. Cada conexão entre os neurônios possui pesos sinápticos que são ajustados por uma regra de aprendizado de retro-propagação como mostra a Equação 16 [34].

$$w_{ji}^c(k+1) = w_{ji}^c(k) + \alpha \delta_j^c(k) y_i(k) \quad (16)$$

Sendo,  $w_{ji}^c(k+1)$  o peso sináptico da camada “c” entre o neurônio da “i” e “j” para a interação  $k+1$ ,  $\alpha$  a taxa de aprendizado,  $\delta_j^c(k)$  o gradiente local da camada “c” e  $y_i(k)$  a saída da camada do neurônio “i” ambos para a interação “k”.

A configuração da rede MLP implementada possui duas camadas escondidas contendo 25 e 15 neurônios. Cada neurônio possui a seguinte função de ativação:

$$\varphi_j(v_j(k)) = \frac{1}{1 + e^{(-av_j(k))}} \quad (17)$$

Sendo,  $v_j(k)$  o campo de indução local do neurônio “j”.

A quantidade de neurônios da rede NFN foi igual a quantidade de variáveis de entrada, como o descrito na Seção 3.2.

O treinamento das RNAs é executado, quando se atinge um valor da raiz do erro médio quadrático (REMQ) inferior a 0,01, ou quando são apresentados todos os dados de treinamento 50.000 vezes.

Para esses experimentos decidiu-se efetuar a previsão sobre a bacia do Alto Jaguaribe localizada no Estado do Ceará. Os dados de entrada, para ambas as redes são as oito variáveis meteorológicas a seguir: pressão a superfície, temperatura do ar, umidade relativa, umidade específica e componente zonal e meridional do vento. De forma a trazer uma informação mais específica sobre a bacia, utilizou-se também a vazão da bacia do Alto Jaguaribe como entrada também. Com exceção da vazão, foram tomadas as médias sobre os pontos de grade entre 2°S-8°S e 45°W-38°W, que correspondem área aproximada de 4.200 km<sup>2</sup> sobre a bacia do Alto Jaguaribe.

O objetivo destes protótipos era efetuar a previsão do acumulado de precipitação sobre a área da bacia. Os dados observados de precipitação foram tirados de [4]. Como entrada da rede, foram utilizados os dados de um trimestre para efetuar a previsão do acumulado de chuvas para o trimestre seguinte (como por exemplo, utilizar na entrada os dados de janeiro, fevereiro e março para obter o acumulado de precipitação de abril, maio e junho).

Ao final, ambas as redes recebem como entrada um vetor com 24 posições que contém os dados do trimestre. Cada mês é composto pelos seguintes dados: mês de observação, umidade específica, umidade relativa, componente de vento zonal e meridional, pressão a superficial, temperatura do ar e vazão da bacia. A saída desejada é o valor da precipitação sobre a bacia.

A seguir são mostrados os gráficos para os dados de validação dos resultados obtidos com as duas redes. Primeiramente são mostrados os gráficos do tipo Q-Q, quantidade-quantidade, que trazem os dados observados no eixo x e os de saída do modelo no eixo y. Quanto mais próximos os pontos ficarem da reta de 45° mais próximos estão os valores calculados dos valores reais.




Figura 6 - Gráfico com a dispersão entre saída do modelo e valores observados para rede protótipo MLP para os dados de validação.




Figura 7 - Gráfico com a dispersão entre saída do modelo e valores observados para rede protótipo NFN para os dados de validação.

Como pode ser visto nos gráficos da Figura 6 e Figura 7, a rede MLP apresentou uma dispersão maior que a rede NFN, o que mostra que os resultados obtidos pelo modelo neuro-fuzzy apresentaram-se mais próximos dos valores reais.

A seguir são mostrados os gráficos, para a validação, com a saída calculada e os valores observados. As linhas tracejadas correspondem aos valores reais de precipitação enquanto que a outra corresponde à saída do modelo.

O desempenho de ambas as redes foi avaliado por três parâmetros: primeiro o tempo para finalizar o treinamento, ou seja, tempo, para atingir um valor da raiz do erro médio quadrático (REMQ) inferior a 0,01 e ambos os algoritmos foram executados sobe as mesmas condições; segundo a correlação entre a saída e o valor desejado; e o valor da raiz do erro médio quadrático normalizado (REMQN) para a validação. Esses podem ser encontrados na Tabela 7.

Tabela 7 – Dados de desempenho para as redes de protótipo

	<b>MLP</b>	<b>NFN</b>
<b>Tempo</b>	145,30min	3,80min
<b>Correlação</b>	0,59	0,75
<b>REMQN</b>	2,02	1,06

Quanto ao tempo para a rede MLP deve-se fazer uma observação, pois a mesma não foi capaz de atingir o valor do REMQ desejado no treinamento e parou devido ao excesso de repetição de apresentação dos dados de treinamento que foram reapresentados 50.000 vezes.



Novamente o modelo baseado em uma técnica neuro-fuzzy apresentou resultados com fatores de desempenho melhores que a técnica puramente neural. Após esses resultados optou-se por utilizar a rede NFN como rede base para o sistema a ser desenvolvido.

### 3.4 Modelo Desenvolvido

Nesta dissertação foi desenvolvido um modelo de previsão de chuvas sazonais para a o Estado do Ceará, baseado em RNA com o uso de NFN para gerar a previsão para as oito regiões homogêneas do Estado, no período de janeiro a junho. Essa escolha se deu para que possa ser feita uma comparação direta de desempenho e qualidade de resultados entre o modelo proposto nessa dissertação com os resultados obtidos pelos modelos utilizados na FUNCEME.

Em virtude da alta variabilidade espacial da precipitação sobre o Estado do Ceará, e das características típicas das regiões semiáridas, é que se fez a escolha pela previsão sobre essas oito regiões, Figura 2, uma vez que as características de chuvas sobre cada uma se apresentam de forma mais homogênea. Regiões litorâneas apresentam um total anual de precipitação geralmente maior que as regiões do interior do Estado. A seguir será descrito o modelo desenvolvido.

As variáveis de entrada utilizadas no modelo, com exceção das anomalias do Niño 3+4 e do dipolo da temperatura da superfície do mar (TSM), foram adquiridas a partir do Projeto Reanálise [51]. Estas se encontram descritas de forma mais completa na Tabela 8. Essas variáveis são as médias mensais das grandezas.

O Projeto do *National Centers for Environmental Prediction* [NCEP, conhecido antigamente como *National Meteorologic Center (NMC)*]/*National Center for Atmospheric Research (NCAR)* Reanálise, referenciado como Projeto Reanálise a partir de agora, teve sua origem no projeto de assimilação de dados do NMC conhecido como *Climate Data Assimilation System (CDAS)*. As motivações do projeto CDAS foram as aparentes “mudanças climáticas” observadas pelo projeto do NMC *Global Data Assimilation System (GDAS)*. O Projeto Reanálise utilizou um sistema de análise/previsão para efetuar a assimilação dos dados, usando as informações meteorológicas passadas de 1948 ate a atualidade [51,52].

Tabela 8 - Descrição das variáveis de entrada

Variável	Unidade	Descrição
Movimento Vertical	hPas <sup>-1</sup>	Indica o grau de massa de ar ascendente na atmosfera
Divergência	s <sup>-1</sup>	Indica quando há regiões de convergência ou

		divergência de massa atmosférica, que são favoráveis ou não a ocorrência de chuva
Vorticidade	$s^{-1}$	Indica a medida de rotação de um fluido. Vorticidade ciclônica (valores negativos) anticiclônica (valores positivos). No hemisfério sul estão associadas com áreas de maior (menor) instabilidade atmosférica e formação de maior (menor) quantidades de nuvens.
Temperatura do Ar	K	Variável atmosférica que indica áreas de maior ou menor aquecimento junto à superfície terrestre
Umidade Específica	$gkg^{-1}$	Variável atmosférica que indica o quanto o ar está mais ou menos úmido. Maiores (menores) valores destas variáveis mostram regiões com o ar mais úmido (seco)
Vento Zonal e Meridional	$ms^{-1}$	Indicam as componentes Leste-Oeste ou norte-sul do vento
Niño 3+4	$^{\circ}C$	Índice de anomalia de Temperatura da Superfície do Mar (TSM) na área entre $5^{\circ}N-5^{\circ}S$ e $170-120^{\circ}W$ representativa do fenômeno de aquecimento (El Niño) ou resfriamento (La Niña) nas águas superficiais do Oceano Pacífico Central Leste
Dipolo TSM	$^{\circ}C$	Índice representativo do dipolo de TSM no Atlântico Tropical dado pela diferença da anomalia de TSM entre a área ao Norte ( $5-20^{\circ}N$ , $60-30^{\circ}W$ ) e Sul ( $0-20^{\circ}S$ , $30^{\circ}W-10^{\circ}E$ ) da bacia.

Os dados do Projeto reanálise são distribuídos em pontos de grade, com um espaçamento de  $2,5^{\circ}$  de latitude e longitude, e níveis verticais de pressão que mudam de variável para variável [52]. Com o intuito de obter uma base de dados de entrada uniforme sobre o Estado do Ceará, optou-se por tomar a média dos valores das variáveis em dois níveis de pressão (altitude), de 925 hPa e 850 hPa, para uma grade entre as coordenadas  $3^{\circ}S - 8^{\circ}S$  e  $41^{\circ}W - 38^{\circ}W$ , que limitam o todo o Estado do Ceará [54,55].

Os dados de precipitação foram adquiridos no site da Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) para as oito regiões homogêneas do Ceará, Figura 2. A previsão do modelo foi gerada para cada uma destas regiões com a entrada padronizada como o descrito acima.

Foram utilizados dados dos anos de 1961 até 2010, divididos em dois grupos menores: um para treinamento, entre os anos de 1961 até 2000, e outro para validação, com o restante do período. O modelo tem como entrada os dados correspondente aos meses de outubro, novembro e dezembro para as nove variáveis de entrada, Tabela 8, formando um vetor de entrada com 27 valores. A utilização de três meses como entrada foi feita de forma que o modelo possa interpretar a dinâmica das variáveis e assim poder efetuar uma melhor previsão.

A saída do modelo corresponde ao acumulado de precipitação dos próximos quatro trimestres (janeiro a março, fevereiro a abril, março a maio e abril a junho). Assim, se a entrada corresponde aos meses de outubro, novembro e dezembro do ano de 2001 a saída corresponderá aos quatro próximos trimestres que pertencem ao ano de 2002.

A estrutura de uma rede NFN possui apenas uma saída, que neste modelo é o somatório da chuva para um dado trimestre. Como objetivo do modelo é efetuar a previsão de chuvas para o mesmo período que os modelos dinâmicos da FUNCEME, de janeiro a junho, foram montadas quatro redes independentes. A saída de cada rede corresponde ao somatório de um dos quatro trimestres (janeiro a março, fevereiro a abril, março a maio ou abril a junho), porém a entrada de cada uma das redes permanece a mesma.

Logo, para efetuar a previsão para uma determinada região são executadas quatro redes NFN, cada uma tendo como saída o valor do acúmulo da precipitação para um trimestre. Ao final, o modelo apresentou um total de 32 RNAs independentes que efetuam a previsão para cada uma as oito regiões homogêneas do Estado do Ceará para cada trimestre. Como será descrito posteriormente.

### **3.5 Fluxograma do Modelo**

A Figura 8 mostra o diagrama de fluxo para obtenção do modelo de previsão sazonal de chuvas inteligente (MPSCI) sobre o Estado do Ceará. Os dados do Projeto Reanálise foram adquiridos em [53] enquanto que a anomalia do Niño 3+4 e a anomalia do dipolo da TSM do oceano Atlântico em [54]. A totalização mensal da precipitação para as oito regiões homogêneas do Estado do Ceará foram adquiridos em [4]. Após a coleta de dados é montada uma matriz contendo os dados para cada mês com os valores de entrada: divergência e movimento vertical da massa de ar atmosférico, temperatura do ar, umidade específica, vorticidade e as componentes zonal e meridional do vento, anomalias do Niño3+4 e do dipolo da TSM do Oceano Atlântico. Cada linha da matriz contém o dado de um mês específico. Esta será chamada de matriz de parâmetros.

Para cada uma das oito regiões obtêm-se dados de precipitação que são somados para gerar os valores acumulados dos trimestres (janeiro a março, fevereiro a abril, março a maio e assim sucessivamente) e guardados em um vetor por região. Estes são chamados de vetores de precipitação. Após a ordenação dos dados, a separação dos mesmos é feita em dois grupos: treinamento e validação. Para evitar a repetição do armazenamento destes, foram gerados dois vetores contendo a posição do valor na matriz de parâmetros e no vetor de precipitação.

Cada região passa pelo processo de treinamento e validação individualmente. O processo de treinamento ocorre da seguinte forma: primeiramente inicializa-se uma rede NFN para o primeiro trimestre, janeiro a março, e então a treina; em seguida, inicializa-se uma nova rede para o próximo trimestre, fevereiro a abril, e também a treina; esse processo é repetido para os demais trimestres até o trimestre de abril a junho.

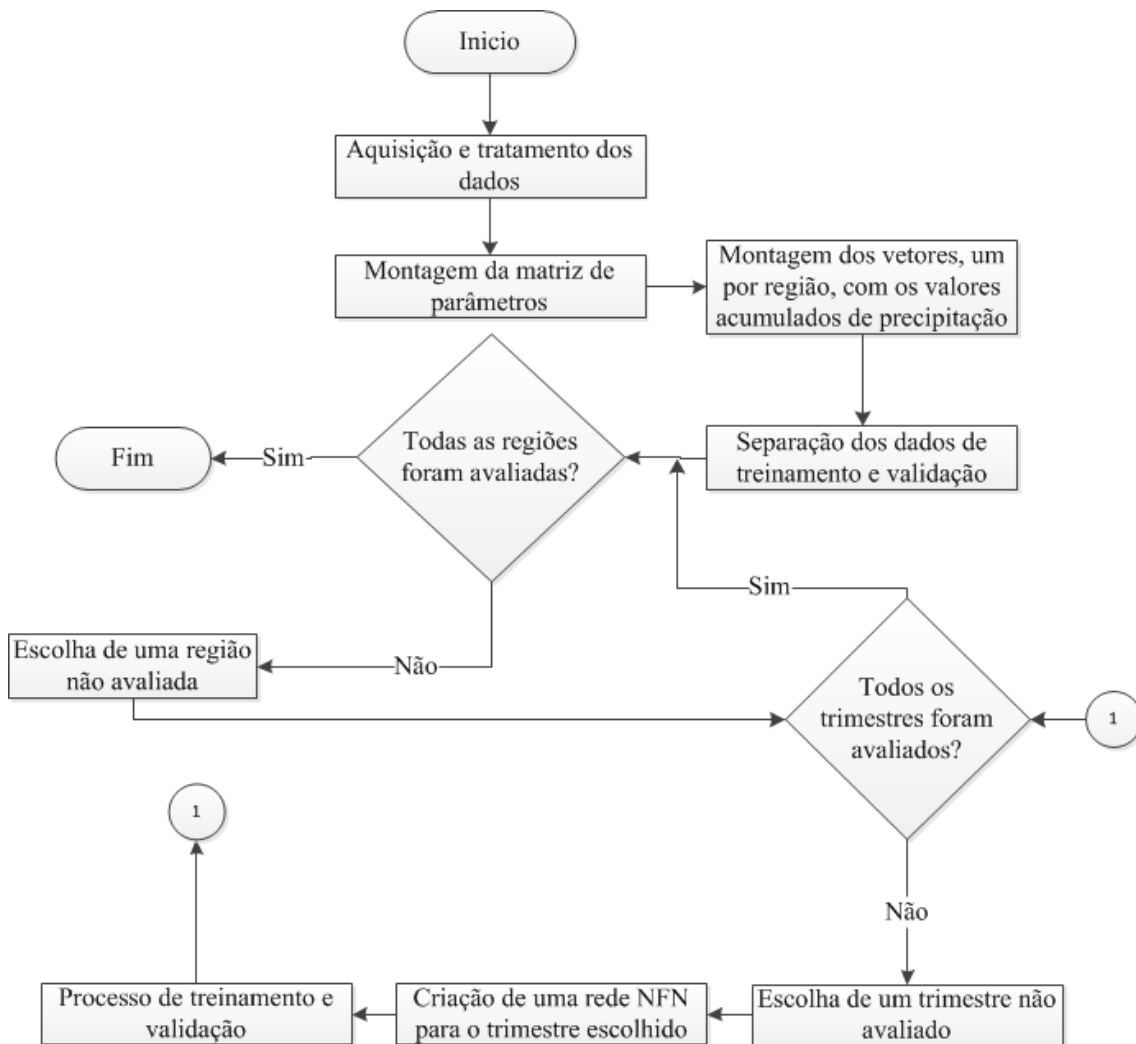


Figura 8 - Diagrama de Fluxo para gerar o modelo de previsão sazonal de chuvas sobre o Estado do Ceará

A configuração das redes NFN que compõe o MPSCI possuem a mesma base que é independente da região alvo, porém dependente do trimestre meta. Cada variável de entrada apresenta partições que possuem funções de pertinência do tipo triangular, distribuídas ao longo dos valores máximos e mínimos da mesma, e pesos sinápticos, inicializados aleatoriamente, que são atualizados ao longo de cada interação.

A entrada da RNA é um vetor composto pelas três linhas da matriz de parâmetros que correspondem aos meses de outubro, novembro e dezembro para um

dado ano, que é o vetor de entrada. Esse vetor é o mesmo independente da região selecionada e do trimestre a ser previsto, uma vez que se deseja utilizar apenas os dados anteriores a janeiro, mês em que é feita a previsão atualmente na FUNCEME.

Para cada entrada utilizada durante o treinamento, o valor da resposta do modelo é comparado com a saída desejada gerando um sinal de erro. A partir deste é feita a atualização da taxa de aprendizado e dos pesos sinápticos da rede.

Define-se que a apresentação de uma “época” corresponde à apresentação completa do conjunto de valores usados para treinamento. Após uma época é avaliado se o valor da REMQ chegou a um valor menor que 0,01, que foi definido como menor valor aceitável de erro. Obtido o valor de erro aceitável, o algoritmo de treinamento é interrompido e a configuração da rede é armazenada. Após o término do treinamento é feita a validação do modelo. De forma semelhante ao treinamento, efetua-se a validação, iniciando-se com o trimestre de janeiro a março e depois para os demais trimestres individualmente.

Ao final da validação é calculado mais uma vez o valor da REMQ e também é avaliada a correlação entre a saída do modelo e o valor real. Esses dois parâmetros foram selecionados como fatores de desempenho.

Somente após uma região ter passado por ambos os processos, treinamento e validação, para todos os trimestres, é selecionada uma nova região. Ao final, a configuração de cada rede criada foi armazenada individualmente.

### **3.6 Definições do Modelo**

As redes NFN presentes no MPSCI possuem como entrada as variáveis (9) para os meses de outubro, novembro e dezembro para efetuar a previsão do acumulado de precipitação para os trimestres: janeiro a março, fevereiro a abril, março a maio e abril a junho.

A configuração base das redes NFN que gerou o modelo MPSCI com os melhores resultados tem a configuração das partições como mostrado na Tabela 9.

No Anexo II é apresentado o código fonte para a obtenção do modelo MPSCI.

Tabela 9 - Quantidade de partições para cada variável.

Variável	Trimestre			
	Janeiro, Fevereiro e Março	Fevereiro, Março e Abril	Março, Abril e Maio	Abril, Maio e Junho
Movimento Vertical	7	2	2	2
Divergência	22	22	22	22
Vorticidade	5	5	4	2
Temperatura do Ar	8	5	3	2
Umidade Específica	3	5	3	2
Vento Meridional	5	5	7	7
Vento Zonal	5	2	2	6
Niño 3+4	4	5	3	3
Dipolo TSM	6	4	2	4

## 4 ANÁLISE DOS RESULTADOS DO MPSCI

O MPSCI usou dados dos meses de outubro, novembro e dezembro, pertencentes aos anos de 1961 a 2010, para efetuar a previsão de chuva nos próximos quatro trimestres (janeiro a março, fevereiro a abril, março a maio e abril a junho) pertencentes dos anos de 1962 a 2011.

Para o treinamento da rede foram usados os dados correspondentes aos anos de 1961 a 2000 e para a validação utilizou-se os anos de 2001 a 2009. Os dados gerados na validação do MPSCI foram comparados aos dados do modelo MRE da FUNCEME. Apesar do modelo RAMS também ser utilizado pela FUNCEME, não foi possível executar a comparação deste com o MPSCI. Em função de problemas no armazenamento dos dados, esses não se encontravam de forma completa. Tanto no modelo MRE quanto no MPSCI foram obtidos os resultados de previsão para as oito regiões do Estado do Ceará. Ao final foi efetuada a análise de desempenho entre os dois modelos.

### 4.1 Apresentação e Discursão dos Resultados (Validação)

Mesmo que tenham sido usadas quatro redes para efetuar a previsão total de apenas uma região, o algoritmo de treinamento converge rapidamente, menos de um minuto para cada região em um computador com um processador Intel® Core™ 2 Duo de 2,00 GHz. Para obter os valores da previsão para um trimestre demora menos de dez segundos. Quando comparado com modelo MRE que leva cerca de 24 horas, sendo executados em um *cluster* com 10 computadores com processadores Intel® Core™ 2 Quad 2,40 GHz para obter seus resultados, o custo computacional e a velocidade de processamento do modelo MPSCI tornam-se insignificantes.

Com base nos resultados obtidos foram montadas as Tabela 10 e Tabela 11. Na Tabela 10 são apresentados os valores da REMQ obtidos para o MPSCI e o MRE. Erros menores significam que o modelo teve saídas mais próximas dos valores reais. Na Tabela 11 são mostrados os valores da correlação para ambos os modelos, neural e dinâmico. Valores de correlação mais próximos de 1,00 indicam que a curva gerada pelo modelo acompanha melhor a curva real.

Os resultados do MPSCI são os valores da melhor configuração de rede desenvolvida e os valores do MRE correspondem à média de seus 10 membros, onde cada membro corresponde a uma perturbação nas variáveis de entrada.

A partir da Tabela 10 e Tabela 11 são construídos os gráficos apresentados nas Figura 9 e Figura 10.

Tabela 10 - Resultados do valor do REMQ para modelo neural MPSCI e dinâmico MRE para os dados de validação.

Região	REMQ (mm)	
	Modelo Neural MPSCI	Modelo Dinâmico MRE
Cariri	184,99	149,20
Ibiapaba	167,11	170,15
Jaguaribana	155,70	139,72
Maciço de Baturité	147,39	171,18
Litoral Fortaleza	218,93	229,44
Litoral Norte	192,73	194,19
Litoral Pecém	177,02	182,43
Sertão Central Inhamuns	130,05	124,04

Tabela 11 - Resultados da correlação para modelo neural MPSCI e dinâmico MRE para os dados de validação.

Região	Correlação	
	Modelo Neural MPSCI	Modelo Dinâmico MRE
Cariri	0,62	0,72
Ibiapaba	0,67	0,59
Jaguaribana	0,68	0,59
Maciço de Baturité	0,76	0,47
Litoral Fortaleza	0,59	0,47
Litoral Norte	0,72	0,64
Litoral Pecém	0,65	0,54
Sertão Central Inhamuns	0,65	0,55

Na Figura 9 são mostrados os resultados para a REMQ em ambos os modelos separados por região. Três regiões, Cariri, Jaguaribana e Sertão Central e Inhamuns, apresentaram REMQ maior para o modelo MPSCI do que para o MRE. No entanto, para as demais regiões o modelo neural apresentou o menor erro.

A Figura 10 apresenta os valores da correlação entre saída do modelo e o valor real da precipitação sobre a região. Neste caso apenas a região do Cariri apresentou resultado inferior para o modelo MPSCI, com valor de correlação menor que o obtido pelo modelo regional. Nas demais regiões a correlação se apresenta maior no modelo neural mostrando que o mesmo conseguiu acompanhar melhor os valores observados.



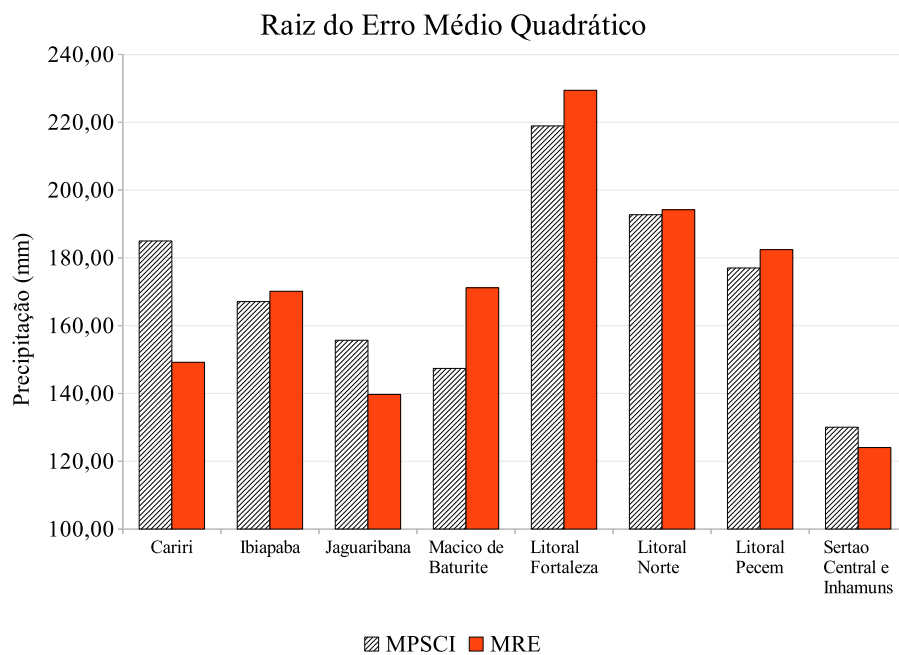


Figura 9 - Gráfico com os dados de REMQ para o modelo neural e dinâmico para os dados de validação. Eixo Y apresenta os valores do REMQ e no eixo X tem-se a região.

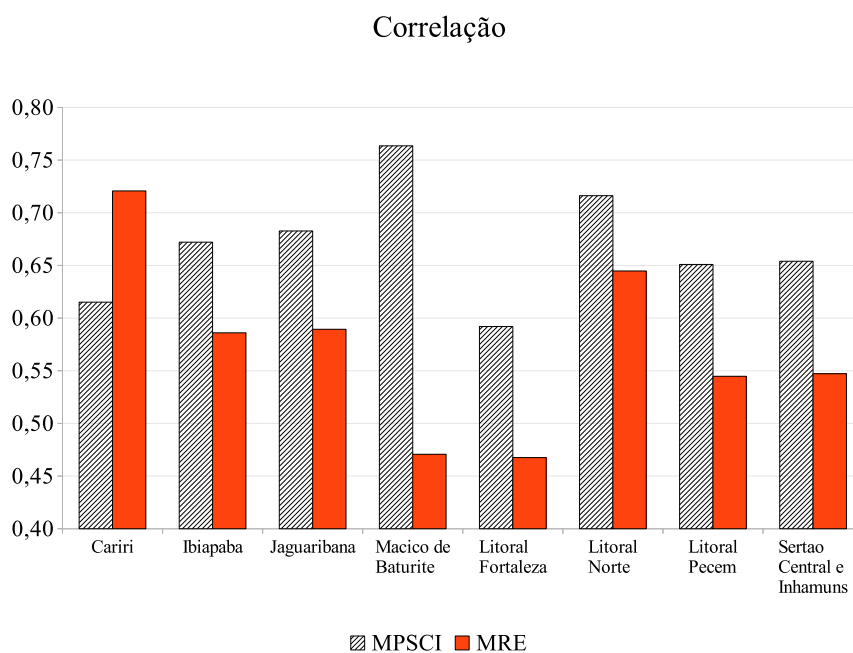


Figura 10 - Gráfico com os dados de correlação para o modelo neural e dinâmico para os dados de validação. Eixo Y apresenta os valores da correlação e no eixo X tem-se a região.

Apesar de nas regiões de Jaguaribana e Sertão Central e Inhamuns o REMQ ter se apresentado pior para o modelo neural (MPSCI) que para o modelo regional

(MRE) o índice de correlação foi mais alto. Esse resultado é devido a um pico de chuva que causou um sinal de erro alto e assim elevando o valor do REMQ.

## **4.2 Análise dos Resultados por Região 2002 a 2010 (Validação)**

O conjunto de valores de entrada selecionados para a validação do modelo MPSCI foram os pertencentes aos anos de 2001 a 2009. Estas entradas estão sempre relacionadas com os dados de outubro, novembro e dezembro. Os gráficos das Figura 11 a Figura 18 correspondem aos valores de previsão para os quatro trimestres (janeiro a março, fevereiro a abril, março a maio e abril a junho). Logo, os gráficos dos resultados de validação correspondem à previsão para os anos de 2002 a 2010.

Cada gráfico apresenta os dados observados em vermelho (linha contínua), previsão do MPSCI em azul (linha tracejada com losango) e a previsão do MRE em verde (linha pontilhada). Os valores do eixo X das figuras correspondem a cada um dos quatro trimestres para os anos de 2002 até o ano de 2010.

A região do Cariri apresentou um REMQ maior e uma correlação menor para o MPSCI. Na Figura 11 pode-se observar que apesar desta região ter se apresentado como a região com os piores resultados para o MPSCI, quando comparados com os do modelo MRE, a correlação mesmo assim apresentou um valor de 0,62 o que mostra que o modelo foi capaz de acompanhar os valores observados com certa precisão.

Diferentemente da região do Cariri a região de Ibiapaba mostrada no gráfico da Figura 12 apresenta melhores resultados para o MPSCI. Verifica-se que entre os anos de 2005 e 2006 o MPSCI não obteve bons resultados, o que influenciou no REMQ, embora tenha obtido um erro menor que o do MRE. Conforme pode ser visto na Figura 12 a curva de resposta do MPSCI acompanha melhor os valores reais o que torna o valor da correlação melhor que o do MRE.

De forma semelhante à região de Ibiapaba, a região Jaguaribana, Figura 13, apresentou resultados melhores para o MPSCI que para o MRE, particularmente com relação à correlação. Os piores valores de previsão ocorreram entre os anos de 2004 e 2005. Os demais anos apresentaram seus resultados próximos dos valores observados o que elevou o valor da correlação, embora o MPSCI tenha apresentado um valor da REMQ mais alto que o MRE.

Os resultados para a região do Litoral de Fortaleza, Figura 14, o modelo MPSCI apresentou resultados melhores que o MRE. Embora essa região tenha tido seus parâmetros de desempenho com os piores valores em comparação as demais regiões para ambos os modelos.

A região do Litoral Norte, Figura 15, seguiu o perfil das regiões de Ibiapaba e Jaguaribana, com REMQ um pouco maior para o MPSCI do que o do MRE. Os anos de 2002 e 2005 foram os anos com piores resultados para o modelo neural. Embora esses anos tenham apresentados valores diferentes dos observados, eles mostram a mesma tendência que a precipitação real. Nos demais anos, o modelo MPSCI apresentou resultados da previsão mais próximos dos valores reais, fazendo com que o valor da correlação fosse maior que o do MRE.

A região do Litoral do Pecém, Figura 16, apresentou os valores de REMQ e correlação melhores para o modelo MPSCI. Novamente, no ano de 2005 o modelo neural obteve seu pior desempenho, porém para os demais anos apresentou resultados bem próximos do valor real de precipitação.

A região do Maciço de Baturité, Figura 17, foi a região que apresentou o maior índice de correlação para o modelo neural. Observa-se que apenas no ano de 2002 e entre os anos 2005 e 2006 o MPSCI apresentou resultados ruins, enquanto que os demais anos os valores mantiveram-se bem próximos dos valores observados. Essa foi a região que apresentou os melhores resultados (REMQ e correlação) dentre as demais para o MPSCI.

A região do Sertão Central e Inhamuns, Figura 18, se comportou de forma semelhante à região de Jaguaribana, inclusive na comparação entre o MPSCI e MRE que obteve um valor de REMQ maior para o MPSCI com um valor de correlação menor para o modelo MRE. Os piores resultados foram para os anos de 2004 e 2005, o que elevou o valor do seu REMQ do MPSCI quando comparado ao do MRE. Apesar disso, para estes anos os valores de previsão acompanharam a tendência dos valores observados e, em conjunto com os demais anos, apresentaram uma correlação maior para o MPSCI em relação ao MRE.

Como pode o mostrado nas Figura 11, Figura 13 e Figura 18 verifica-se que o ano de 2004 apresentou-se atípico, com um alto índice de chuvas observado no início do ano, o que acarretou em uma grande diferença entre os valores observados e estimados para ambos os modelos, MRE e MPSCI.

Já nas regiões representadas pelas Figura 12, Figura 13, Figura 14, Figura 15, Figura 16, Figura 17 e Figura 18 no ano de 2005, que apresentou uma condição de alta precipitação no fim da estação de chuvas, verifica-se que o modelo MPSCI apresenta resultados piores que o modelo MRE quando comparado aos valores observados.

Considerando o valor da REMQ e da correlação, como índices de desempenho, a técnica neural é capaz de fornecer novas informações que podem contribuir para a geração do relatório de previsão para o período de chuvas no Estado do Ceará.

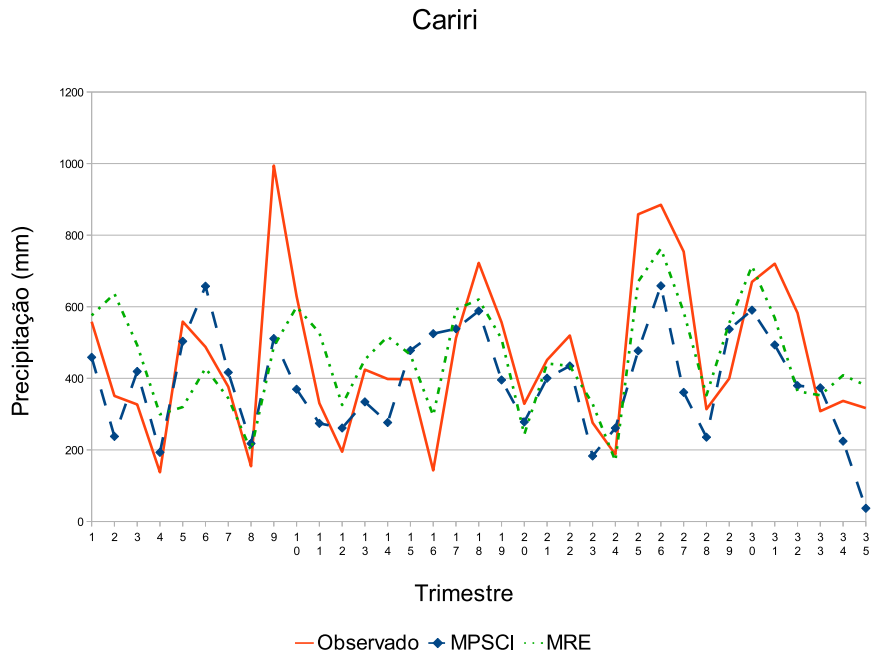


Figura 11 - Dados de precipitação acumulada para a região do Cariri. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

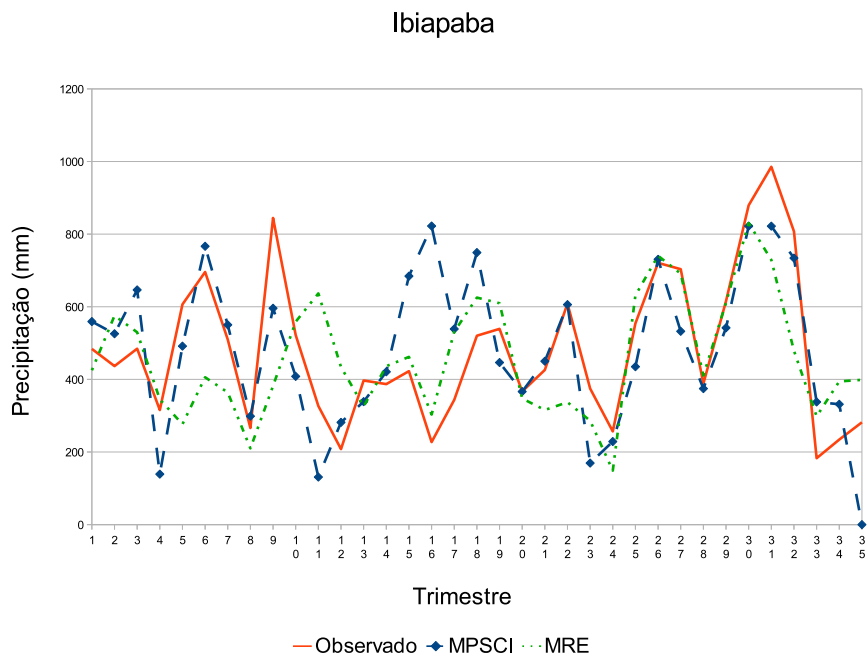


Figura 12 - Dados de precipitação acumulada para a região da Ibiapaba. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Jaguaribana




Figura 13 - Dados de precipitação acumulada para a região Jaguaribana. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Litoral de Fortaleza




Figura 14 - Dados de precipitação acumulada para a região do Litoral de Fortaleza. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Litoral Norte

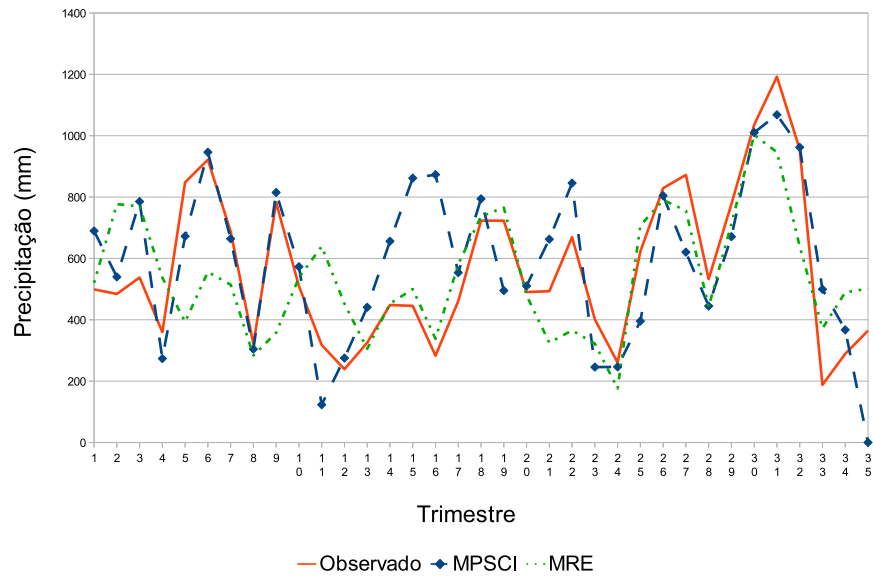


Figura 15 - Dados de precipitação acumulada para a região do Litoral Norte. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Litoral do Pecém




Figura 16 - Dados de precipitação acumulada para a região do Litoral do Pecém. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Maciço de Baturité

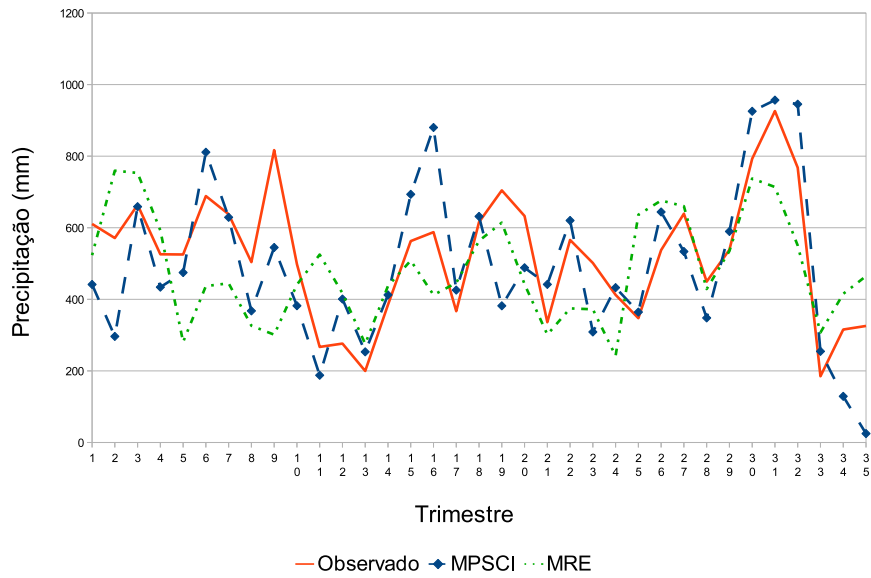


Figura 17 - Dados de precipitação acumulada para a região do Maciço de Baturité. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

### Sertão Central e inhamuns




Figura 18 - Dados de precipitação acumulada para a região do Sertão Central e Inhamuns. No eixo Y estão os valores do acumulado de precipitação, em mm, e no eixo X está uma representação dos trimestres de cada ano. 2002 a 2010.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

O modelo proposto nesta dissertação (MPSCI) baseado em RNA apresenta um grande potencial para a previsão do acumulado de chuvas para os quatro primeiros trimestres do ano para o Estado do Ceará. Apenas uma região, Cariri, apresentou os parâmetros de avaliação, REMQ e correlação, com resultados piores para o modelo neural em relação ao modelo dinâmico (MRE) o que pode ter ocorrido devido a essa região ter sido influenciada por fenômenos de curto prazo de duração e de grande intensidade que não foram levados em conta pelas entradas selecionadas.

O treinamento no modelo desenvolvido foi rápido, menos de um minuto para cada região em um computador com processador Intel® Core™ 2 Duo de 2,00 GHz, convergindo após a apresentação de poucas épocas (< 1000), enquanto que o modelo MRE, após ter sido sintonizado, leva cerca de um dia executando em um *cluster* composto por dez computadores, cada um com um processador Intel® Core™ 2 Quad de 2,40 GHz, para efetuar a previsão para o mesmo período. Sendo assim, mesmo que para todas as vezes que fosse necessário efetuar uma previsão pelo modelo neural, o mesmo tivesse que ser treinado novamente, ainda assim seria mais rápido e menos custoso que efetuar a previsão através do modelo dinâmico. Mostrando que o MPSCI é um modelo que tem baixo custo computacional e de rápido processamento.

A previsão de chuvas sobre o Estado do Ceará, assim como no NEB, é algo de fundamental importância, visto que essa região por longos anos vem convivendo com o flagelo da seca. Sabe-se que essa previsão é fruto de um sistema complexo e dependente de diversas variáveis inter-relacionadas o que a torna uma previsão bastante onerosa em termos de modelamento, processamento, aquisição de dados, entre outros. O modelo aqui desenvolvido procura ser uma ferramenta de auxílio a previsão de clima no Estado do Ceará que, embora de baixo custo, pode contribuir com informações adicionais para a previsão de chuvas.

Este trabalho não tem o objetivo de substituir os modelos global e regional, tradicionalmente utilizados para prognosticar as chuvas, mas sim trazer um novo modelo capaz de gerar mais informações para os meteorologistas, a um baixo custo operacional.

O desenvolvimento deste trabalho contribui para o início de uma nova área de pesquisa dentro da FUNCEME, levando em consideração modelos neurais em contrapartida aos modelos dinâmicos tradicionais.



## 5.1 Trabalhos Futuros

Os estudos realizados ao longo deste trabalho permitem vislumbrar desdobramentos além dos que foram apresentados. Com o objetivo de melhorar o desempenho do sistema desenvolvido e aprofundar o conhecimento no tema, algumas sugestões para futuros trabalhos são sugeridas:

1. Para efetuar a seleção dos parâmetros de entrada e seus atrasos sugere-se o acoplamento de um algoritmo para esta finalidade. Com esse pré-processamento será possível utilizar o mínimo de informação sem ter perdas na previsão.
2. Comparar os resultados do MPSCI com todos os modelos utilizados pela FUNCEME. Neste trabalho não foi possível efetuar a comparação devido à disponibilidade dos dados gerados pelo modelo, pois a fundação teve alguns problemas com seus backups.
3. Adaptação do modelo para efetuar a previsão de vazão sobre as bacias com o acoplamento de um modelo chuva-vazão. Com base nessa nova informação será possível efetuar, de forma mais precisa, a previsão de cheias.
4. Extrair regras do modelo neural-fuzzy que permitam interpretar as previsões geradas.
5. Visto que o trabalho foi desenvolvido objetivando efetuar a previsão para o período de chuvas sobre o Estado do Ceará, foram selecionado dados mensais. Ao se falar na previsão de fenômenos extremos que podem causar, por exemplo, a destruição de um reservatório, se faz necessário que a escala de tempo seja menor. Fica como sugestão a redução da escala de tempo do modelo, voltando-o para prever de eventos extremos.

## REFERÊNCIAS

- 1 MARENGO, J. A. O. Água e mudanças climáticas. **Estudos Avançados**, v. 22, p. 1-14, 2008.
- 2 ALVES, J. M. B. ESTUDO DO REGIME HIDROLÓGICO NO SEMI-ÁRIDO BRASILEIRO POR MODELAGEM DINÂMICA ACOPLADA: APLICAÇÃO EM GERENCIAMENTO DE RESERVATÓRIOS. **Tese de Doutorado**, Universidade Federal do Ceará, Departamento de Engenharia Hidráulica e Ambiental 2008.
- 3 ALVES, J. M. B.; SERVAIN, J.; CAMPOS, J. N. B. Relationship Between Ocean Climatic Variability and Rain-Fed Agriculture in Northeast Brazil. **Climate Research**, v. 38, n. 3, p. 225-236, 2009.
- 4 FUNCEME. FUNCEME, 2010. Disponível em: <<http://www.funceme.br>>. Acesso em: Junho 2010.
- 5 ALVES, J. M. B.; CAMPOS, J. N. B.; FILHO, F. A. S.; MONCUNNIL, D. F.; SILVA, E. M.; BARBOS, W. L.; FERREIRA, A. G.; SUN, L.; MOURA, A. D. Uma avaliação preliminar entre simulações climáticas de um modelo global (ECHAM4.5) e um downscaling dinâmico para o setor norte da Região Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 20, n. 2, p. 191-206, 2005.
- 6 MENDES, F. J.; FILHO, J. B. P. A.; SAKAMOTO, M. S. A REDE DE ESTAÇÕES METEOROLÓGICAS AUTOMÁTICAS DA FUNCEME. **Congresso Brasileiro de Meteorologia**, 2004.
- 7 COGERH. Cogerh - Companhia de Gestão dos Recursos Hídricos. Disponível em: <<http://portal.cogerh.com.br>>. Acesso em: Junho 2010.
- 8 COGERH. Anuário do Monitoramento Quantitativo dos Principais Açudes do Estado do Ceará., 2007.
- 9 ALVES, J. M. B.; COSTA, A. A.; SOMBRA, S. S.; CAMPOS, J. N. B.; SOUZA FILHO, F. A.; MARTINS, E. S. P. R.; SILVA, E. M.; SANTOS, A. C. S.; BARBOSA, H. A.; MELCIADES, W. L. B.; MONCUNNIL, D. F. Um Estudo Inter-Comparativo de Previsão Sazonal Estatística-Dinâmica de Precipitação no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 22, n. 3, p. 354-372, 2007.
- 10 HOLTON, J. R. An introduction to dynamic meteorology. **International Geophysics Series**, v. 23, n. sec. Ed. Academic Presss., 1979.

- 11 SHUKLA, J. S. et al. Dynamical seasonal prediction. **Bulletin of the American Meteorological Society**, v. 81, p. 2593-2505, 2000.
- 12 MOURA, A. D.; SHUKLA, J. On the dynamics of droughts in northeast brazil: observations, theory and numerical experiments with a general circulation model. **Journal of the Atmospheric Sciences**, v. 38, p. 2653–2675, 1981.
- 13 NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America. **Journal of Climate**, v. 9, p. 2464-2479, 1996.
- 14 NOBRE, P.; ANTONIO D. MOURA, L. S. Dynamical downscaling of seasonal climate prediction over Nordeste Brazil with ECHAM3 and NCEP'S Regional Spectral Model at IRI. **American Meteorological Society**, v. 82, p. 2787–2796, 2001.
- 15 ALVES, J. M. B.; SILVA, E. M.; MONCUNIL, D. F.; FILHO, V. P. S.; MELCIADES, W. L. B. Uma Avaliação Preliminar da Simulação de Precipitação Sobre o Nordeste do Brasil Usando um Aninhamento de um Modelo Numérico Regional em um Modelo Numérico Global. **Congresso Brasileiro de Meteorologia**, Foz do Iguaçu, p. 1273-1279, 2002.
- 16 ALVES, J. M. B.; BRISTOT, G.; COSTA, A. A.; MONCUNIL, D. F.; SILVA, E. M.; SANTOS, A. C. S.; BARBOSA, W. L.; NÓBREGA, D. S. B.; FILHO, V. P. S.; SOUZA, I. A. Uma Aplicação Da Técnica De “Downscaling” Dinâmico No Setor Norte Da Região Nordeste Do Brasil. **Revista Brasileira de Meteorologia**, v. 18, n. 2, p. 161-180, 2003.
- 17 SUN, L.; MONCUNIL, D. F.; LI, H.; MOURA, A. D.; FILHO, F. A. S. Climate Downscaling over Nordeste, Brazil, Using the NCEP RSM97. **American Meteorological Society**, v. 18, p. 551-567, 2005.
- 18 SIMMONS, A. J. et al. The ECMWF medium-range prediction models development of the numerical formulations and the impact of increased resolution. **Meteorology and Atmospheric Physics**, v. 40, p. 28-60, 1989. ISSN 0177-7971.
- 19 MAX-PLANCK-INSTITUT FÜR METEOROLOGIE. Max-Planck-Institut für Meteorologie: Model MPI ECHAM4 (T42 L19) 1996. **MPI ECHAM4 (T42 L19) 1995 Contents**. Disponível em: <[http://www-pcmdi.llnl.gov/projects/modeldoc/amip1/26mpi\\_ToC\\_b.html](http://www-pcmdi.llnl.gov/projects/modeldoc/amip1/26mpi_ToC_b.html)>. Acesso em: Junho 2011.

- 20 MAX-PLANCK-INSTITUT FÜR METEOROLOGIE. **The ECHAM3 Atmospheric General Circulation Model**. Max-Planck-Institut für Meteorologie. Hamburg. 1993. (DKRZ Report No. 6).
- 21 DOMMENGET, D.; LATIF, M.; **A global data set of land-surface parameters**. Max-Planck-Institut fuer Meteorologie. [S.l.], p. 35. 1994. (ISSN 0937-1060).
- 22 KANAMITSU, M.; ALPERT, J. C.; CAMPANA, K. A.; CAPLAN, P. M.; DEAVEN, D. G.; IREDELL, M.; KATZ, B.; PAN, H.-L.; SELA, J.; WHITE, G. H.; Recent changes implemented into the global forecast system at NMC. **Weather Forecast.**, v. 6, p. 455-435, 1991.
- 23 JUANG, H.-M. H. NCEP Regional Spectral Model. Disponivel em: <<http://www.emc.ncep.noaa.gov/mmb/RSM/>>. Acesso em: Janeiro 2011.
- 24 JUANG, H.-M. H.; KANAMITSU, M. The NMC nested regional spectral model. **Monthly Weather Review**, v. 122, p. 3-26, 1994.
- 25 JUANG, H.-M. H.; HONG, S.-Y.; KANAMITSU, M. The NCEP Regional Spectral Model: An Update. **American Meteorological Society**, v. 78, n. 10, p. 2125-2143, 1997.
- 26 PAN, H. L.; WU., W. S. Implementation a mass flux convective parameterization package for the NMC medium-range forecast model. **American Meteorological Society**, p. 96-98, 1994.
- 27 HONG, S. Y.; PAN, H. L. Nonlocal boundary layer vertical diffusion in a medium-range forecast model. **Monthly Weather Review**, v. 124, p. 2322-2339, 1996.
- 28 KANAMITSU, M. Description of the NMC global data assimilation and forecast system. **Weather. Forecast**, v. 6, p. 425-435, 1989.
- 29 PAN, H.-L.; MAHRT, L. Interaction between soil hydrology and boundary-layer development. **Boundary-Layer Meteorology**, v. 38, p. 185-202, 1987. ISSN ISSN 0006-8314.
- 30 TREMBACK, C. J.; WALKO, R. L. **RAMS version 6.0 User Guide - Introduction**. [S.l.]: ATMET, 2005.
- 31 COSTA, A. A. **Relatório de atividades do Projeto MONUMENT (Modelagem Numérica de Mesoescala Aplicada à Previsão Climática no Nordeste Brasileiro)**. Fundação Cearense de Meteorologia e Recursos Hídricos. Fortaleza, p. 24. 2006.
- 32 FREEMAN, J. A.; SKAPURA, D. M. **Neural Networks: Algorithms, Applications and Programming Techniques**. [S.l.]: Addison-Wesley, 1991.

- 33 HAYKIN, S. **Neural Networks - A Comprehensive Foundation**. [S.l.]: Prentice Hall, 1999.
- 34 KRÖSE, B.; SMAGT, P. V. D. **An Introduction to Neural Networks**. 8. ed. [S.l.]: [s.n.], 1996.
- 35 MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 8, p. 115-133, 1943.
- 36 MINSKY, M.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry**. [S.l.]: The MIT Press, 1969.
- 37 HAYATI, M.; MOHEBI, Z. Application of Artificial Neural Networks for Temperature Forecasting. **World Academy of Science, Engineering and Technology**, n. 28, 2007.
- 38 HUANG, M.; PENG, G.; ZHANG, J.; ZHANG, S.; Application of Artificial Neural Networks to the Prediction of Dust Storms in Northwest China. **Global and Planetary Change**, n. 52, p. 216-224, 2006.
- 39 EVSUKOFF, A.; LIMA, B.; EBECKEN, N.; Long-Term Runoff Modeling Using Rainfall Forecasts with Application to the Iguazu River Basin. **Water Resources Management**, v. 25, p. 963-985, 2011.
- 40 CHOU; S. C.; TANAJURA, C. A. S.; XUE, Y. K.; NOBRE, C. A.; alidation of the coupled Eta/SSiB model over South America. *Journal of Geophys Res* v. 20, 537–555, 2002
- 41 TALEI, A.; CHUA, L. H. C.; QUEK, C. A Novel Application of a Neuro-Fuzzy Computational Technique in Event-Based Rainfall-Runoff Modeling. **Expert Systems with Applications**, 2010.
- 42 CHAU, K. W.; WU, C. L.; A Hybrid Model Coupled with Singular Spectrum Analysis for Daily Rainfall Prediction. **Journal of Hydroinformatics**, n. 12, p. 458-473, 2010
- 43 WEERASINGHE, H.; PREMARATNE, H.; SONNADARA, D.; Performance of Neural Networks in Forecasting Daily Precipitation Using Multiple Sources. **Journal of the National Science Foundation of Sri Lanka**, n. 38, p. 163-170, 2010.
- 44 BROOKS, H.; DOSWELL III, C. A. Precipitation Forecasting Using a Neural Network. **Wethter and Forecast**, v. 14, p. 338-345, 1999.
- 45 HUNG, N. Q.; BABEL, M. S.; WEESAKUL, S.; TRIPATHI N. K.; An artificial neural network model for rainfall forecasting in Bangkok Thailand. **Hydrology and Earth System Sciences**, v. 13, p. 1413–1425, 2009.

- 46 SRIVASTAVA, G.; PANDA, S. N.; MONDAL, P.; LIU, J.; Forecasting of Rainfall Using Ocean-Atmospheric Indices with a Fuzzy Neural Technique. **Journal of Hydrology**, v. 395, n. 3-4, p. 190-198, 2010.
- 47 WU, C. L.; CHAU, K. W.; FAN, C. Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data-Preprocessing Techniques. **Journal of Hydrology**, p. 146-167, 2010.
- 48 YAMAKAWA, T.; Uchino, E.; Miki, T.; Kusabagi, H.; A Neo Fuzzy Neuron and its Applications to System Identification and Predictions to System Behavior. **In: Proceedings of the 2nd IIZUKA, Iizuka, Japan**, p. 477-483, 1992.
- 49 BODYANSKIY, Y.; KOKSHENEV, I.; KOLODYAZHNIY, V. An Adaptive Learning Algorithm for a Neo Fuzzy Neuron. **3rd Conference of the European Society for Fuzzy Logic and Technology**, 2003.
- 50 CHATURVEDI, K. T.; PANDIT, M.; SRIVASTAVA, L. Modified Neo-Fuzzy Neuron-Based Approach for Economic and Environmental Optimal Power Dispatch. **Applied Soft Computing**, v. 8, n. 4, p. 1428-1438, 2008.
- 51 KALNAY, E.; KANAMITSU, M.; KISTLER, R.; COLLINS, W.; DEAVEN, D.; GANDIN, L.; IREDELL, M.; SAHA, S.; WHITE, G.; WOOLEN, J.; ZHU, Y.; CHELLIAH, M.; EBISUZAKI, W.; HIGGINS, W.; JANOWIAK, J.; MO, K. C.; ROPELEWSKI, C.; WANG, J.; LEETMAA, A.; REYNOLDS, R.; JENNE, R.; JOSEPH, D. The NCEP/NCAR 40-Year Reanalysis Project. **Bulletin of the American Meteorological Society**, v. 77, n. 3, p. 437-471, 1996.
- 52 NCEP/NCAR. NCEP/NCAR Reanalysis 1, 2010. Disponível em: <<http://www.esrl.noaa.gov/psd/data/gridded/data.ncep.reanalysis.html>>. Acesso em: 2010.
- 53 IRI/LDEO CLIMATE DATA LIBRARY. dataset: NOAA NCEP-NCAR CDAS-1 MONTHLY Intrinsic PressureLevel, 2010. Disponível em: <<http://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCEP-NCAR/.CDAS-1/.MONTHLY/.Intrinsic/.PressureLevel/>>. Acesso em: 2010.
- 54 NATIONAL WEATHER SERVICE - CLIMATE PREDICTION CENTER. Climate Prediction Center - Monitoring & Data: Current Monthly Atmospheric and Sea Surface Temperatures Index Values, 2010. Disponível em: <<http://www.cpc.ncep.noaa.gov/data/indices/>>. Acesso em: 2010.
- 55 CASTRO, T.; SOUZA, F.; ALVES, J. M. B.; PONTES, R. S. T.; FIRMINO, M. B. M.; PEREIRA, T. M.; Seasonal Rainfall Forecast using a Neo-Fuzzy

Neuron Model. **IEEE International Conference on Industrial Informatics**, Lisbon, 2011.

- 56 CASTRO, T.; ALVES, J.; FIRMINO, M. PREVISÃO SAZONAL DE PRECIPITAÇÃO NO CEARÁ: COMPARAÇÃO ENTRE MODELAGEM DINÂMICA E UM MODELO COM REDE NEURAL. **XVII Congresso Brasileiro de Agrometeorologia**, Guarapari, 2011.
- 57 WU, C. L.; CHAU, K. W. Data-Driven Models for Monthly Streamflow Time Series Prediction. **Engineering Applications of Artificial Intelligence**, 2010.
- 58 MAGALHÃES, A. R.; GLANTZ, M. H. Socio-economic impacts of climate variations and policy response in Brazil. **Esquel Brazil Foundation**, Brasilia, 1992.
- 59 LEMOS, M. C.; FINAN, T. J.; FOX, R. W.; NELSON, D. R.; TUCKER, J. The Use of Seasonal Climate Forecasting in Policymaking: Lessons from Northeast Brazil. **Earth and Environmental Science**, v. 55, n. 4, p. 479-507, 2002.
- 60 KISTLER, R. et al. The NCEP-NCAR 50-Year Reanalysis: Monthly Means CD-ROM and Documentation. **Bulletin of the American Meteorological Society**, v. 82, n. 2, p. 247-268.
- 61 KNAMITSU, M.; Ebisuzaki, W.; Woollen, J.; Yang, S.-K.; Hnilo, J. J.; Fiorino, M.; Potter, G. L.; NCEP-DOE AMIP-II Reanalysis (R-2). **American Meteorological Society**, p. 1631-1643, 2002.
- 62 NCEP-DOE. NCEP-DOE Reanalysis 2. Disponível em: <<http://www.esrl.noaa.gov/psd/data/gridded/data.ncep.reanalysis2.html>>. Acesso em: 2010.
- 63 SILVA FILHO, V. P. Previsão de vazão no Semi-Árido Nordeste, utilizando modelos atmosféricos: Um estudo de Caso. **Tese de Doutorado**, Universidade Federal do Ceará, Departamento de Engenharia Hidráulica e Ambiental 2005.
- 64 UMA Aplicação da Técnica de Downscaling Dinâmico no Setor Norte da Região Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 18, n. 2, p. 161-180, 2003.
- 65 SOUZA, K.; CASTRO, T. N.; PEREIRA, T. M.; PONTES, R. S. T.; BRAGA, A. P. S.; Prediction of Core Losses on a Three-Phase Transformer Using Neural Networks. **IEEE International Symposium on Circuits and Systems**, Rio de Janeiro, 2011.
- 66 GIORGI, F.; BATES, G. T. The Climatological Skill of a Regional Model over Complex Terrain. **Monthly Weather Review**, v. 117, p. 2325-2347.

- 67 ROECKNER, E.; ARPE, K.; BENGTSSON, L.; CHRISTOPH, M.; CLAUSSEN, M.; DÜMENIL, L.; ESCH, M.; GIORGETTA, M.; SCHLESE, U.; SCHULZWEIDA, U.; **The atmospheric general circulation model ECHAM-4: model description and simulation of present-day climate.** Max-Planck-Institute für Meteorologie. [S.l.], p. 1-94. 1996.
- 68 ROECKNER, E.; ARPE, K.; BENGTSSON, L.; BRINKOP, S.; DÜMENIL, L.; ESCH, M.; KIRK, E.; LUNKEIT, F.; PONATER, M.; ROCKEL, B.; SAUSSEN, R.; SCHLESE, U.; SCHUBERT, S.; WINDELBAND, M. **Simulation of the present-day climate with the ECHAM model: Impact of model physics and resolution.** Max-Planck-Institut für Meteorologie. Hanburg. 1982. (ISSN 0937-1060).
- 69 WALKO, R. L.; COTTON, W. R.; MEYERS, M. P.; HARRINGTON, J. Y.; New RAMS cloud microphysics parameterization part I: the single-moment scheme. **Atmospheric Research**, 1995, v. 38, p. 29-62. ISSN ISSN 0169-8095.
- 70 CHEN, G.; PHAM, T. T. **Introduction to fuzzy sets, fuzzy logic, and fuzzy control systems.** [S.l.]: CRC Press, 2000.



## ANEXO I – HARMÔNICOS ESFÉRICOS E TRUNCAMENTOS TRIANGULAR E ROMBOIDAL

Aqui é abordada a técnica de harmônicos esféricos e truncamento que são utilizadas no modelo ECHAN4.5. No modelo global é utilizado harmônicos esféricos com truncamento triangular no número de onda zonal T42.

Os harmônicos são autofunções do Laplaciano na esfera de raio “a” e constituem um conjunto ortogonal completo. São dados pela expressão  $Y_n^m(\lambda, \theta) = e^{-im\lambda} P_n^m(\sin \theta)$  em coordenadas esféricas  $(\lambda, \theta) \in [-\pi, \pi] \times [-\pi/2, \pi/2]$ . Denotaremos  $\mu = \sin \theta$ .

Os polinômios de Legendre de ordem “m” e grau “n” podem ser expressos pela fórmula de Rodrigues:

$$P_n^m(\mu) = \frac{1}{\sqrt{2}} \frac{(1-\mu^2)^{|m|/2}}{2^n n!} \frac{d^{n+|m|}(1-\mu^2)}{d\mu^{n+|m|}} \quad (1)$$

Estes são solução do problema de Sturm-Liouville:

$$\frac{d}{d\mu} \left[ (1-\mu^2) \frac{dy}{d\mu} \right] + [n(n+1) - m^2 / (1-\mu^2)] y = 0, \quad \mu \in [-1, 1], \quad (2)$$

com a condição de serem limitados nos extremos do intervalo. Por constituírem um processo ortogonal completo em relação ao produto interno  $\langle f, g \rangle = \int_{-1}^1 fg$   $\Rightarrow \langle P_n^m, P_s^m \rangle = \delta_{ns}$ .

Os harmônicos esféricos obedecem à relação:

$$\frac{1}{2\pi} \int_{-1}^1 \int_{-\pi}^{\pi} Y_n^m(\lambda, \mu) \overline{Y_{n'}^{m'}(\lambda, \mu)} d\lambda d\mu = \begin{cases} 1, & \text{se } (m, n) = (m', n') \\ 0, & \text{se } (m, n) \neq (m', n') \end{cases} \quad (3)$$

Portanto são ortogonais em relação ao produto interno:

$$\langle f, g \rangle = \frac{1}{2\pi} \int_{-1}^1 \int_{-\pi}^{\pi} f \bar{g} d\lambda d\mu \quad (4)$$

Os polinômios de Legendre são normalmente calculados, e armazenados durante toda uma integração, através de relações de recorrência. Temos que:

$$P_{n+1}^m = \frac{1}{\epsilon_{n+1}^m} \mu P_n^m - \frac{\epsilon_n^m}{\epsilon_{n+1}^m} P_{n-1}^m, \quad (5)$$

Sendo  $\epsilon_n^m = \left( \frac{n^2 - m^2}{4n^2 - 1} \right)^{1/2}$ . Para a implementação do método em modelos espectrais globais, apresenta as seguintes propriedades:

$$P_n^m(\mu) = P_n^{-m}(\mu) \quad (6)$$

$$P_n^m(\mu) = 0, \quad n < |m| \quad (7)$$

Essas veem diretamente da fórmula de Rodrigues e como consequência tem-se:

$$Y_n^{-m} = (Y_n^m)^* \quad (8)$$

Outra relação importante é:

$$P_n^m(-\mu) = (-1)^{n+|m|} P_n^m(\mu), \quad (9)$$

Assim os polinômios passam a ser funções pares ou ímpares, dependendo de  $n+|m|$ .

Tem-se ainda as relações:

$$H_n^m(\mu) = (1-\mu^2) \frac{d}{d\mu} P_n^m(\mu) = -n\epsilon_{n+1}^m P_{n+1}^m + (n+1)\epsilon_n^m P_{n-1}^m \quad (10)$$

$$\frac{\partial}{\partial \lambda} Y_n^m = im Y_n^m \quad (11)$$

$$\nabla^2 Y_n^m = -\frac{(n+1)n}{a^2} Y_n^m \quad (12)$$

$$(1-\mu^2) \frac{\partial}{\partial \mu} Y_n^m = -n\epsilon_{n+1}^m Y_{n+1}^m + (n+1)\epsilon_n^m Y_{n-1}^m \quad (13)$$

Tem-se que  $Y_n^m$  será nulo nos “m” grandes círculos passando pelos polos e também nos “n-m” círculos de igual latitude. Toda vez que passa uma dessas linhas a função troca de sinal. Quando “m=0”, a função é independente da longitude e os harmônicos esféricos são denominados **Zonal**, quando “m=|n|” passam a ser denominados de **Sectorial** e para as demais escolhas são **Tesseral**. A Figura 19 mostra a representação das denominações de  $Y_n^m$ .




Figura 19 - Representação esquemática de  $Y_n^m$  na esfera unitária por suas denominações.

Quando se utiliza expansões por harmônicos esféricos os truncamentos mais comumente utilizados são o Romboidal e Triangular. A expansão que é geralmente utilizada é:

$$F(\lambda, \mu) \sum_{m=-M}^M \sum_{n=|m|}^{N(m)} F_{n,m} Y_n^m(\lambda, \mu) \quad (14)$$

Ao escolher  $N(m)=|m|+M$  tem-se um truncamento do tipo romboidal e para  $N(m)=M$  tem-se um triangular, Figura 20.

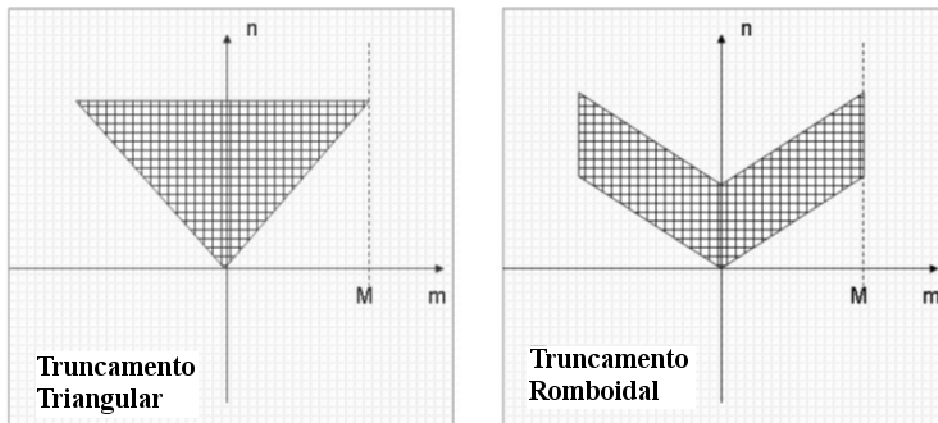


Figura 20 - Tipos de truncamento utilizados em expansões por harmônicos esféricos.

Quando a expansão é feita utilizando o truncamento triangular a esta não muda sob qualquer rotação do sistema de coordenadas na esfera. Essa característica faz com que o truncamento triangular seja o mais utilizado, pois fornece uma resolução uniforme na esfera.

## ANEXO II – SCRIPTS DE EXECUÇÃO DO MPSCI

O modelo executa o script “nfn\_executa\_funceme” que se utiliza dos scripts “nfn\_treinamento\_funceme” e “triangular”. A transcrição destes segue abaixo.

### **nfn\_executa\_funceme:**

```
close all

clear all

clc

% Programa para executar o arquivo mlp_tnc_funceme.m variando os
% parametros passados

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Leitura dos dados%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Leitura dos dados%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

div      =      load('../Dados/dados/divmrea1960201041375S38S.tsv');
% Divergencia

mver     =      load('../Dados/dados/mvermrea1960201041375S38S.tsv');
% Movimento vertical

temp     =      load  ('../Dados/dados/tempmrea1960201041375S38S.tsv');
% Temperatura do Ar
```

```

    uesp = load ('../Dados/dados/uespmrea1960201041375S38S.tsv');
%Umidade Especifica

    % ur = load('../Dados/dados/urmrea1960201041375S38S.tsv'); %Umidade
Relativa

    vor = load('../Dados/dados/vormrea1960201041375S38S.tsv');
%Vorticidade

    vm = load('../Dados/dados/vmmrea1960201041375S38S.tsv');
%Componente Meridional do Vento (Velocidade)

    vz = load('../Dados/dados/vzmrea1960201041375S38S.tsv'); %Componetne
Zonal do Vento (Velocidade)

    nino = load('../Dados/dados/nino3_34.dat');%Niño 3 e 3+4

    dipolo = load('../Dados/dados/dipolo.dat');%Dipolo do Atlantico

regiao1 = load('../Dados/dados/macico_baturite.dat');
regiao2 = load('../Dados/dados/cariri.dat');
regiao3 = load('../Dados/dados/litoral_fortaleza.dat');
regiao4 = load('../Dados/dados/ibiapaba.dat');
regiao5 = load('../Dados/dados/jaguaribana.dat');
regiao6 = load('../Dados/dados/litoral_norte.dat');
regiao7 = load('../Dados/dados/litoral_pecem.dat');
regiao8 = load('../Dados/dados/sertao_central_inhamuns.dat');

for i = 1 : 8
    strRegiao = ['regiao' num2str(i)];
    eval(['strRegiao ' strRegiao ' == -999.0) = nan;']);
end

trimestreNames = { 'Jan_Fev_Mar'; 'Fev_Mar_Abr'; 'Mar_Abr_Mai';
'Abr_Mai_Jun'};

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Vetor de dados %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

dados = [div(:,3) mver(:,3) temp(:,3) uesp(:,3) vor(:,3) vm(:,3) vz(:,3)
nino(:,4) dipolo(:,8)];

p = 3;%Define a quantidade de meses que serão usados na entrada
dP = 3;%Define a quantidade de meses para o somatorio do valor desejado
jP = 4;%Janela de previsão.

Ydesejos = nan*ones(size(dados,1), jP);% Valores desejados.

for i = 1 : size(Ydesejos, 1)
    for j = 1 : size(Ydesejos, 2)
        if (i + j) <= size(Ydesejos, 1) - (dP-1)
            tmp = regioa1(i + j : (i + j + dP - 1), 3);
            tmpNAN = sum(isnan(tmp));
            if tmpNAN == 0
                Ydesejos(i, j) = sum(tmp);
            end
        end
    end
end
end
end

```

```

% Seleção de dados de treinamento e validação

train = find(div(:,1) <= 2000 & div(:,1) >= 1961 & div(:,2) == 12);

train = train';% Os valores de treinamento selecionado para os anos de 1961
% ate 2000.

valida = find(div(:,1) >= 2001 & div(:,2) == 12);

valida = valida';

% Valores de validação para os anos a partir de 2002

dataTrain = [ div(train,1) div(train,2) ]; % Armazena as datas de treinamento
dataValida = [ div(valida,1) div(valida,2) ];% Armazena as datas de
validação

%-----

%%%%%%%%%%

% Execução      %

%%%%%%%%%%

erro_parada= 0.01;      % Meta da taxa de erro
int_parada=15000;      % Maximo de interacoes

%Quantidade de partições para cada un dos valores de validação
nUjiBase = [ 22 7 8 3 5 5 5 4 6 ];
nUjiBase = [ nUjiBase; 22 2 5 5 5 5 2 5 4 ];
nUjiBase = [ nUjiBase; 22 2 3 3 4 7 2 3 2 ];
nUjiBase = [ nUjiBase; 22 2 2 2 2 7 6 3 4 ];

resultsFolder = '../Results_FUNCEME/NFN/macico_baturite/';

```

```

eval(['!mkdir -p ' resultsFolder ';']);

for d = 1 : size(Ydesejos, 2)

    tic

    %Chama arquivo para treinar e validar o modelo

    [evoErro nUji distUji centerUji oldW validacao treinamento errV errT
    correlacao] = nfn_treinamento_funceme(dados, Ydesejos(:,d)', train, valida, p,
    erro_parada, int_parada, nUjiBase(d,:), resultsFolder);

    execTime = toc;

    display(execTime);

    pause(2)

    close all

    suffix = cell2mat(trimestreNames(d));

    pesosName = [ resultsFolder, 'pesos_' suffix '.dat'];
    salvaPesos(pesosName, oldW, distUji, centerUji, nUji);

    validaName = [ resultsFolder, 'valida_' suffix '.dat'];
    salvaValida(validaName, validacao);

    treinamentoName = [ resultsFolder, 'treinamento_' suffix '.dat'];
    salvaValida(treinamentoName, treinamento);

    analiseName = [ resultsFolder, 'analise_' suffix '.dat'];
    salvaAnalise(analiseName, errV, errT, correlacao, execTime);

```



```

    tmpP = ['save ' resultsFolder 'conf_' suffix ' distUji centerUji oldW
validacao treinamento correlacao'];

    eval(tmpP);

    clear evoErro nUji distUji centerUji oldW validacao treinamento errV
errT correlacao

end

close all

beep

```

### **nfn\_treinamento\_funceme:**

```

%
%
%           Dados Recebidos
%
% dados      = Dados para uso no treinamento representado as entradas
%            do sistema
%
% Ydesejos   = Dados para uso no treinamento e validação representando
%            o valor de saída desejado.
%
% train      = Posições, referente a matriz dados, das linhas a serem
%            usadas para treinamento.
%
% valida     = Posições, referente a matriz dados, das linhas a serem
%            usadas para validação.
%
% p          = Número de entradas a serem usadas.
%
% erro_parada = Critério de parada por erro. Se atingir esse valor para
%            execução.
%
% int_parada  = Critério de parada por número de épocas apresentadas. Se

```

```

%          atingir esse valor para a execução.
% nUjiBase    = Distribuição das funções de pertinencia
% resultsFolder = Pasta onde serão salvas as imagens.
%
%
%          Dados Retornados
%
%
% evoErro      = Evolução do erro durante o treinamento.
% distUji     = Distancias ao centro.
% centerUji   = Centros.
% oldW        = Pesos.
% validacao   = Valores estimados e desejados durante a validação
% treinamento = Valores estimados e desejados durante o ultimo
%             treinamento
% errV
% EQV        = Erro médio quadratico durante a validação
% REQV       = Root Mean Square Erro
% NREQV      = Normalized Root Mean Square Erro
% errT
% EQ         = Erro médio quadratico durante o ultimo treinamento
% REQ       = Root Mean Square Erro
% NREQ      = Normalized Root Mean Square Erro
% correlacao
% corrValida = Correlação entre valores desejados e obtidos
% corrTreinamento = Correlação entre valores desejados e obtidos

```

```
function [evoErro nUji distUji centerUji oldW validacao treinamento errV
errT correlacao] = nfn_treinamento_funceme(dados, Ydesejos, train, valida, p,
erro_parada, int_parada, nUjiBase, resultsFolder)
```

```
nValida = size(valida,2); % Quantidade de dados para validação
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
% Configuração da rede %
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
nE = size(dados,2); % Número de variáveis de entrada
```

```
NS = p*nE; % Número de neurônios
```

```
nUji = [];
```

```
for a = 1:p
```

```
    nUji = [ nUji nUjiBase ];
```

```
end
```

```
minXB = min(dados(:,1:nE)); % Mínimos das entradas
```

```
maxXB = max(dados(:,1:nE)); % Máximos das entradas
```

```
maxX = [];
```

```
minX = [];
```

```
for a = 1:p
```

```
    maxX = [ maxX maxXB ];
```

```
    minX = [ minX minXB ];
```

```
end
```

```
distUji = (maxX - minX)./(nUji - 1); % Distancias das funções de
pertinencia
```

```
centerUji = zeros(max(nUji),NS); % Centros das funções de pertinencia
```

```
wji = rand(max(nUji),NS); % Pesos
```

```

w = [];
for ii = 1:NS
    w = [w wji(:,ii)'];
end
w = w';
oldW = w;

for i = 1:NS
    for j = 1:nUji(i)
        centerUji(1:nUji(i),i) = (minX(i):distUji(i):maxX(i))';
    end
end

clear minXB minX maxXB maxX
clear wji

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Execução %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

flagS = 1; % Flag para para o algoritmo
int = 0;
evoErro = [];
erroIni = 1;
ekIni = 1;
alfa = 0.5;
alfaW = 0;

```

```

Eji = ones(max(nUji),NS);
minTrain = 99999;
maxTrain = -99999;
while( flagS )
    EQ=0;
    int=int+1;

    treinamento = [];
    errTrain = [];
    for ind=1:size(train,2)
        a = train(ind);
        % Seleccionando entradas
        xI=[];
        for kk = a : -1 : (a - p + 1)
            xI = [ xI; dados(kk, 1:nE) ' ];
        end

        yD=Ydesejos(a);    % Saida Desejada

        uji = zeros(max(nUji),NS);
        for ii = 1:NS
            for jj = 1:nUji(ii)
                uji(jj,ii) = triangular(xI(ii,1), distUji(ii), centerUji(jj,ii));
            end
        end
    end

    tilU = [];

```

```

for ii = 1:NS
    tmpDem = Eji(:,ii)*uji(:,ii);
    tmpUji = uji(:,ii)/tmpDem;
    tilU = [tilU tmpUji'];
end
tilU = tilU';

clear uji tmpDem tmpUji

yk = oldW'*tilU;

if(yk < 0)
    yk = 0;
end

if minTrain > yk
    minTrain = yk;
end

if maxTrain < yk
    maxTrain = yk;
end

ek = yD - yk;
treinamento = [treinamento; yD yk ];
errTrain = [errTrain; ek];

EQ = EQ + (ek*ek);    % RMS

```

```

    alfaW = alfa*alfaW + norm(tilU)*norm(tilU);

    oldW = w;

    deltaWji = ek*tilU/alfaW;

    w = w + deltaWji;

end

EQ = EQ/size(train,2);

REQ = sqrt(EQ);

NREQ = REQ/(maxTrain - minTrain);

errT = [EQ REQ NREQ];

clc; % apaga a tela

corrTrain = corr(treinamento(:,1), treinamento(:,2));

evoErro = [ evoErro; NREQ ];

disp(NREQ)    % Exibe RMS

disp(int)    % Exibe interacoes

disp(corrTrain) % Exibe a correlação do treinamento

if ((corrTrain == 1)||(NREQ<erro_parada)||(int==int_parada)) %
verifica se satisfaz o criterio de parada

    flagS = 0;

end

end

validacao = [];

errValida = [];

minValida = 99999;

maxValida = -99999;

EQV = 0;

```

```

for ind=1:nValida
    a = valida(ind);
    % Seleccionando entradas
    xI = [];
    for kk = a : -1 : (a - p + 1)
        xI = [ xI; dados(kk, 1:nE) ' ];
    end

    yD=Ydesejos(a);    % Saida Desejada

    uji = zeros(max(nUji),NS);
    for ii = 1:NS
        for jj = 1:nUji(ii)
            uji(jj,ii) = triangular(xI(ii,1), distUji(ii), centerUji(jj,ii));
        end
    end

    end

    tilU = [];
    for ii = 1:NS
        tmpDem = Eji(:,ii)*uji(:,ii);
        tmpUji = uji(:,ii)/tmpDem;
        tilU = [tilU tmpUji'];
    end

    end

    tilU = tilU';

    clear uji tmpDem tmpUji

```



```

ok = oldW'*tilU;

if(ok < 0)
    ok = 0;
end

if minValida > ok
    minValida = ok;
end

if maxValida < ok
    maxValida = ok;
end

if ~isnan(yD)
    ek = yD - ok;

    EQV = EQV + (ek*ek);    % RMS
    errValida = [errValida; ek];
    validacao = [ validacao; yD ok ];
else
    validacao = [ validacao; nan ok ];
end

end

EQV = EQV/(nValida);
REQV = EQV;
REQV = sqrt(REQV);

```

```

NREQV = REQV;

NREQV = NREQV/(maxValida - minValida);

errV = [EQV REQV NREQV];

corrValida = corr(validacao(:,1), validacao(:,2), 'rows', 'complete');

display(corrValida)

display(REQV)

% figure

% plot ((1:size(treinamento,1)),treinamento(:,1),'ob'); % Plota em azul os
dados originais.

% hold on;

% plot ((1:size(treinamento,1)),treinamento(:,2),'k'); % plota em preto os
dados encontrados pela rede.

% title({'Treinamento'}, 'fontsize', 15, 'fontweigh', 'bold');

% legend('Valor Real', 'Valor Estimado',0)

% xlabel("");

% ylabel('Precipitação Acumulada (mm)', 'fontsize', 15);

% tmpP = ['print -djpeg -r300 ' resultsFolder 'Treinamento_Pontos'];

% eval(tmpP);

% figure

% plot ((1:size(treinamento,1)),treinamento(:,1),'--b'); % Plota em azul os
dados originais.

% hold on;

% plot ((1:size(treinamento,1)),treinamento(:,2),'-k'); % plota em preto os
dados encontrados pela rede.

% title({'Treinamento'}, 'fontsize', 15, 'fontweigh', 'bold');

% legend('Valor Real', 'Valor Estimado',0)

```

```

% xlabel("");
% ylabel('Precipitação Acumulada (mm)', 'fontsize', 15);
% tmpP = ['print -djpeg -r300 ' resultsFolder 'Treinamento_Linhas'];
% eval(tmpP);

% figure

% plot (validacao(:,1),validacao(:,2),'.b',
min(min(validacao)):0.001:max(max(validacao)),
min(min(validacao)):0.001:max(max(validacao)),'-r');

% title({'Q - Q'}, 'fontsize', 12, 'fontweigh', 'bold');
% legend('Valor Real x Valor Estimado', '45i;½,0)
% xlabel('Valor Real', 'fontsize', 15);
% ylabel('Valor Estimado', 'fontsize', 15);
% tmpP = ['print -djpeg -r300 ' resultsFolder 'Q_Q'];
% eval(tmpP);

% figure

% plot ((1:size(validacao,1)),validacao(:,1),'ob'); % Plota em azul os
dados originais.

% hold on;

% plot ((1:size(validacao,1)),validacao(:,2),'.k'); % plota em preto os
dados encontrados pela rede.

% title({'Validação'}, 'fontsize', 15, 'fontweigh', 'bold');
% legend('Valor Real', 'Valor Estimado',0)
% xlabel("");
% ylabel('Precipitação Acumulada (mm)', 'fontsize', 15);
% tmpP = ['print -djpeg -r300 ' resultsFolder 'Validacao_Pontos'];
% eval(tmpP)

%

```

```

figure
plot ((1:size(validacao,1)),validacao(:,1),'-b'); % Plota em azul os dados
originais.

hold on;

plot ((1:size(validacao,1)),validacao(:,2),'-k'); % plota em preto os dados
encontrados pela rede.

title({'Validação'}, 'fontsize', 15, 'fontweigh', 'bold');

legend('Valor Real', 'Valor Estimado',0)

xlabel("");

ylabel('Precipitação Acumulada (mm)', 'fontsize', 15);

% tmpP = ['print -djpeg -r300 ' resultsFolder 'Validacao_Linhas'];
% eval(tmpP);

% close all

correlacao = [ corrValida corrTrain ];

end

```

### **triangular:**

```

function y = triangular(x, d, center)

a = center - d;

b = center;

c = center + d;

f1 = (x - a)/(b - a);

f2 = (c - x)/(c - b);

```

```
y = max(min(f1,f2),0);  
% y = trimf(x,[ a b c ]);  
end
```