



**UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA**

**APLICAÇÃO DE REDES NEURONAIS PARA A INTERPOLAÇÃO DA
PRECIPITAÇÃO NO ESTADO DE ALAGOAS**

HENDERSON SILVA WANDERLEY

**Maceió, AL
Janeiro de 2010**



**UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA**

Nº de ordem: MET-UFAL-MS-066.

**APLICAÇÃO DE REDES NEURONAIS PARA A INTERPOLAÇÃO DA
PRECIPITAÇÃO NO ESTADO DE ALAGOAS**

HENDERSON SILVA WANDERLEY

Dissertação de Mestrado orientado por Prof. Dr. Ricardo Ferreira Carlos de Amorim e pelo Prof. Dr. Frede de Oliveira Carvalho apresentada a Universidade Federal de Alagoas, para obtenção do título de Mestre em Meteorologia.

**Maceió, AL
Janeiro de 2010**

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária Responsável: Helena Cristina Pimentel do Vale

- W245a Wanderley, Henderson Silva.
Aplicação de redes neuronais para a interpolação da precipitação no Estado de Alagoas / Henderson Silva Wanderley, 2010.
xiii, 78 f. : il., grafs.
- Orientador: Ricardo Ferreira Carlos de Amorim.
Co-orientador: Frede de Oliveira Carvalho.
Dissertação (mestrado em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2010.
- Bibliografia: f. 68-75.
Anexo: f. 76-78.
1. Meteorologia. 2. Redes neurais. 3. Interpolação espacial e temporal.
4. Preenchimento de falhas. I. Título.

CDU: 551.508.7(813.5)



UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-066.

***“APLICAÇÃO DE REDES NEURONAIS PARA A INTERPOLAÇÃO DA
PRECIPITAÇÃO NO ESTADO DE ALAGOAS”***


Henderson Silva Wanderley

Dissertação submetida ao colegiado do Curso de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas - UFAL, como parte dos requisitos necessários à obtenção do grau de Mestre em Meteorologia.


Aprovado pela Banca Examinadora composta por:



Prof. Dr. Marcos Antônio Lima Moura
(Coordenador em exercício e membro interno)




Prof. Dr. Ricardo Ferreira Carlos de Amorim
(Orientador)



Prof. Dr. Frede de Oliveira Carvalho
(Co-orientador)



Prof. Dr. Brauliro Gonçalves Leal
(Membro Externo – UNIVASF)



Prof. Dr. Ranieri Carlos Ferreira de Amorim
(Membro Interno – IFAL)

Maceió – AL
Janeiro/2010

AGRADECIMENTO

A Deus pela sua graça e fidelidade em minha vida.

Ao Profº Dr. Ricardo Ferreira C. de Amorim e ao Profº Dr. Frede de Oliveira Carvalho pela orientação, a banca examinadora Profº Dr. Brauliro Gonçalves Carvalho, Profº Dr. Marcos Antônio de Lima Moura e ao Profº Dr. Ranieri Ferreira C. de Amorim pelas sugestões prestadas e incentivos até a conclusão deste trabalho.

A todo corpo docente do Instituto de Ciências Atmosféricas (ICAT/UFAL) e a todo corpo de professores que contribuíram para minha formação acadêmica pela Universidade Federal de Alagoas (UFAL).

A todo equipe do Laboratório de Sistemas Inteligentes Aplicados (LABSIA).

A minha turma de mestrado e a todos os amigos da universidade.

A Fundação de Amparo e pesquisa de Alagoas (FAPEAL) pelo auxílio financeira, bolsa de mestrado.

Aos meus pais que sempre lutaram pela minha educação com lição de amor, vida, fé, coragem, determinação, força e solidariedade me conduzindo á concretização dos meus objetivos.

A minha noiva pelo apoio e compreensão no período de estudo.

Aos meus avós, tios, primos.

A todos meu muito obrigado! Que Deus abençoe a todos.

HENDERSON SILVA WANDERLEY. Orientadores: Prof. Dr. Ricardo Ferreira Carlos de Amorim e Prof. Dr. Frede de Oliveira Carvalho. Aplicação de redes neurais para a interpolação da precipitação no estado de Alagoas. Dissertação (Programa de Pós-Graduação em Meteorologia). Instituto de Ciências Atmosféricas - ICAT. Universidade Federal de Alagoas – UFAL. Maceió, Alagoas, Brasil. (78p). 2010.

RESUMO

As regiões tropicais são marcadas por apresentarem uma grande variabilidade quanto à distribuição dos seus regimes pluviométricos, entretanto falta de informação quanto à distribuição espacial e temporal da precipitação é um sério obstáculo para se compreender e modelar sua variabilidade. Deste modo, o objetivo desta pesquisa foi utilizar Redes Neurais Artificiais para o estudo da variabilidade da precipitação, visando o preenchimento de falhas, utilizando-se de interpolação espacial e temporal da precipitação para o estado de Alagoas. Para a interpolação espacial foram utilizadas as médias mensais de 63 estações localizadas no estado de Alagoas e 182 estações localizadas no estado de Pernambuco entre os anos de 1965 a 1980, para os meses de maio e novembro. Para a interpolação temporal foram utilizados dados diários de 5 estações pluviométricas e 1 fluviométrica entre os anos de 1993 a 2002. Todas as estações utilizadas são provenientes do banco de dados da Agência Nacional de Águas (ANA). Para a interpolação foram adotados alguns cenários de entrada com diferentes configurações para o processo de treinamento das redes neurais, levando em consideração latitude, longitude, altitude, precipitações das estações dentro da região de dependência espacial e dados de precipitação de dias anteriores. A região de dependência espacial, bem como a distribuição espacial da precipitação para os meses em estudo foram obtidas através da utilização de técnicas geoestatísticas. As redes neurais mostraram ser uma ferramenta promissora para a simulação de dados de precipitação, demonstrando resultados satisfatórios para a interpolação espacial com Erro Absoluto Médio entre 0,04 a 51,40mm e Erro Percentual Médio Absoluto entre 0,03 a 30,48% para o mês de maio, e Erro Absoluto Médio entre 0,00 a 5,79mm e Erro Percentual Médio Absoluto entre 0,00 a 30,65% para o mês de novembro. A interpolação temporal obteve o melhor resultado para o cenários-1 com a utilização de cinco dados passados, com Erro Absoluto Médio de 0,067mm e Erro Percentual Médio Absoluto de 5,176%.

Palavras-Chave: Redes Neurais Artificiais, Interpolação Espacial e Temporal, Preenchimento de Falhas.

HENDERSON SILVA WANDERLEY. Advires: Prof. Dr. Ricardo Ferreira Carlos de Amorim is Prof. Dr. Frede de Oliveira Carvalho. Application of neural networks for interpolation of precipitation in the state of Alagoas. Dissertation (Post graduate Program in Meteorology). Atmospheric Science Institute - University Federal de Alagoas – UFAL. Maceió, Alagoas, Brasil. (78p). 2010.

ABSTRACT

Tropical regions are characterized by presenting a great variability in the distribution of its rainfall regimes, however lack of information about the spatial and temporal distribution of rainfall is a serious obstacle to understanding and modeling its variability. Thus, the purpose of this study was to use Artificial Neural Networks to study the variability of precipitation in order to infilling missing, using the temporal and spatial interpolation of precipitation for the state of Alagoas. For the spatial interpolation were used monthly averages of 63 stations located in the state of Alagoas and 182 stations in the state of Pernambuco between the years 1965 to 1980, for the months of May and November. For the temporal interpolation was used daily data of 5 pluviometric and 1 fluviometric stations between the years 1993 to 2002. All stations used are from the database of the Agência Nacional of Água (ANA). For the interpolation were adopted some entry scenarios with different settings for the training process of neural networks, taking into account latitude, longitude, altitude, rainfall stations within the region of spatial dependence and rainfall data from previous days. The region of spatial dependence and spatial distribution of precipitation for the months in the study were obtained through the use of geostatistics. Neural networks have proven to be a promising tool for the simulation of precipitation data, showing satisfactory results for the spatial interpolation with mean absolute error between 0,04 to 51,40mm and Mean Absolute Percentage Error from 0,03 to 30,48% for the month of May, and mean absolute error between 0,00 to 5,79mm and Mean Absolute Percentage Error between 0,00 to 30,65% for the month of November. Temporal interpolation obtained the best result for the scenario-1 with the use of five past data, with mean absolute error of 0,067mm and Mean Absolute Percentage Error of 5,176%.

Key Words: Artificial Neural Networks, Spatial and Temporal Interpolation, Infilling Missing.

SUMÁRIO

	Página
Agradecimento	v
Resumo	vi
Abstract	vii
Lista de Figuras	x
Lista de Tabelas	xii
1- INTRODUÇÃO	01
2- REVISÃO BIBLIOGRÁFICA	02
2.1- Precipitação Pluviométrica	02
2.1.1- Classificação da Precipitação 3	03
2.2- Sistemas Meteorológicos que Causam Chuvas na Região Nordeste do Brasil ..	04
2.3- Incertezas de Dados de Precipitação	07
2.4- Preenchimento de Falhas de Dados de Precipitação	08
2.5- Métodos de Interpolação	10
2.6- Utilização de Sistemas Inteligentes para a Interpolação de Dados de Precipitação	14
2.7- Redes Neurais Artificiais	20
2.7.1- Neurônios Biológicos e Artificiais	21
2.7.2 Processo de Aprendizado ou Treinamento da Rede Neural	23
2.8- Método Geoestatístico de Interpolação	24
2.8.1- Método de Krigagem	25
3- MATERIAIS E MÉTODOS	27
3.1- Caracterização da Área de Estudo	27
3.1.2- Dados Utilizados	28
3.1.3- Interpolação da Precipitação	32

4-	RESULTADOS E DISCUSSÕES	36
4.1-	Distribuição mensal da Precipitação no Estado de Alagoas	36
4.2-	Dependência Espacial da Precipitação	39
4.3-	Análise da Estimativa Espacial da Precipitação para o Mês de Maio	42
4.3.1-	Análise da Estimativa Espacial da Precipitação para o Mês de Novembro	44
4.4-	Interpolação Espacial da Precipitação com Redes Neurais Artificiais	46
4.4.1-	Interpolação Espacial da Precipitação para o Cenário-1	46
4.4.2-	Interpolação Espacial da Precipitação para o Cenário-2	49
4.4.3-	Interpolação Espacial da Precipitação para o cenário-3	52
4.4.4-	Interpolação Espacial da Precipitação para o Cenário-4	55
4.4.5-	Interpolação Espacial da Precipitação para o Cenário-5	58
4.5-	Interpolação Temporal da Precipitação com Redes Neurais Artificiais	61
5-	CONCLUSÕES	67
6-	REFERÊNCIAS BIBLIOGRÁFICAS	68
7-	ANEXOS	76

LISTA DE FIGURAS

	Página
FIGURA 01 Distribuição espacial dos regimes de chuva sobre o Nordeste Brasileiro	06
FIGURA 02 Neurônio Biológico	21
FIGURA 03 Neurônio Artificial	22
FIGURA 04 Modelo de Variograma Experimental com Patamar	24
FIGURA 05 Região Nordeste do Brasil, estado de Alagoas e suas microrregiões	27
FIGURA 06 Distribuição espacial das estações no Estado de Alagoas	29
FIGURA 07 Distribuição espacial das estações no Estado de Pernambuco	29
FIGURA 08 Região de dependência espacial da estação de Limueiro de Anadia	31
FIGURA 09 Localização espacial das estações na bacia do Rio Mundaú	32
FIGURA 10 Principais funções de transferência; a) sigmóide (logsig), b) tangente hiperbólica (tansig) e c) linear (purelin)	33
FIGURA 11 Média mensal da precipitação no Estado de Alagoas de 1965 a 1980	36
FIGURA 12 Região de dependência espacial para a estação de Limueiro de Anadia	41
FIGURA 13 Interpolação espacial da precipitação no estado de Alagoas para o mês de maio com 63 estações	42
FIGURA 14 Interpolação espacial da precipitação no estado de Alagoas para o mês de maio com 58 estações	43
FIGURA 15 Interpolação espacial da precipitação no estado de Alagoas para o mês de novembro com 63 estações	44
FIGURA 16 Interpolação espacial da precipitação no estado de Alagoas para o mês de novembro com 58 estações	45
FIGURA 17 Coeficiente de correlação para o mês de maio obtido pelo cenário-1	46
FIGURA 18 Coeficiente de correlação para o mês de maio obtido pelo cenário-1	47
FIGURA 19 Coeficiente de correlação para o mês de maio obtido pelo cenário-2	49
FIGURA 20 Coeficiente de correlação para o mês de novembro obtido pelo cenário-2	50
FIGURA 21 Coeficiente de correlação para o mês de maio obtido pelo cenário-3	52
FIGURA 22 Coeficiente de correlação para o mês de novembro obtido pelo cenário-3	53
FIGURA 23 Coeficiente de correlação para o mês de maio obtido pelo cenário-4	56

FIGURA 24	Coeficiente de correlação para o mês de novembro obtido pelo cenário-4	56
FIGURA 25	Coeficiente de correlação para o mês de maio obtido pelo cenário-5	58
FIGURA 26	Coeficiente de correlação para o mês de novembro obtido pelo cenário-5	59
FIGURA 27	Precipitação diária observada na Fazenda Boa Fortuna entre os anos de 1993 a 2002	61
FIGURA 28	Coeficiente de correlação para o cenário-1 com a utilização de cinco voltas	63
FIGURA 29	Coeficiente de correlação para o cenário-2 com a utilização de cinco voltas	64
FIGURA 30	Coeficiente de correlação para o cenário-3, sem voltas	65
FIGURA 31	Coeficiente de correlação para o cenário-4, sem voltas	66

LISTA DE TABELA

	Página
TABELA 01	Principais métodos de interpolação e sua classificação 11
TABELA 02	Informações das estações utilizadas para a interpolação espacial 30
TABELA 03	Informações das estações utilizadas para a interpolação temporal 31
TABELA 04	Cenários de utilizados para a interpolação espacial da precipitação 33
TABELA 05	Cenários de utilizados para a interpolação temporal da precipitação 35
TABELA 06	Resumo estatístico das precipitações pluviométricas para o estado de Alagoas, durante o período de 1965/1980 (DP = Desvio Padrão; CV = Coeficiente de Variação; PRP Mín = Precipitação Mínima; PRP Máx = Precipitação Máxima)... 37
TABELA 07	Parâmetros dos modelos teóricos ajustados ao variograma experimental para a precipitação média em Alagoas. (C_0 =Efeito Pepita, $C+C_0$ =Patamar, a =Alcance) . 39
TABELA 08	Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-1, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 48
TABELA 09	Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-1, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 48
TABELA 10	Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-2, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 51
TABELA 11	Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-2, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 51
TABELA 12	Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-3, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 54
TABELA 13	Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-3, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 54
TABELA 14	Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-4, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 57
TABELA 15	Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-4, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 57
TABELA 16	Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-5, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio 59

TABELA 17	Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-5, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio	60
TABELA 18	Cenários utilizados para a interpolação temporal da precipitação com seus respectivos número de voltas e dados observados e estimados	62
TABELA 19	Erro Médio Absoluto e Erro Percentual Médio Absoluto dos cenários utilizados para a interpolação temporal da precipitação com RNA ..	63
TABELA 20	Codificação, nome e localização das 63 estações pluviométricas selecionadas do banco de dados da ANA, distribuídas no estado de Alagoas	76

1. INTRODUÇÃO

As regiões tropicais são marcadas por apresentarem uma grande variabilidade quanto à distribuição dos seus regimes pluviométricos. Nestas localidades, a precipitação determina as chamadas estações secas e chuvosas, e o conhecimento de sua variabilidade espacial e temporal torna-se fundamental para obtenção dos padrões definidores dos regimes hidrológicos e climatológicos desta região. Sendo a precipitação, uma das variáveis meteorológica mais importante para as regiões entre os trópicos.

A falta de informação quanto à distribuição espacial e temporal da precipitação é um sério obstáculo para se compreender e modelar sua variabilidade. Problema esse que pode ser causador de grande incerteza nos processos de estimação dessa variável. Deste modo, surge a necessidade de se obter dados de precipitação para regiões que não apresentam estações de medições ou que apresente falhas em seu banco de dados.

A interpolação de dados surge como uma alternativa para se modelar a variabilidade da precipitação, onde em certas condições, torna-se praticamente impossível instalar uma estação de superfície ou fazer qualquer tipo de coleta de dados. O processo de estimativa de dados dessa variável permanece sendo uma tarefa complexa, principalmente para pequenas bacias hidrográficas ou para regiões que apresentem poucas estações de medições, onde essas lacunas dificultam a elaboração de estudos que buscam compreender a distribuição precipitação.

Deste modo a utilização de técnicas de interpolação, surge como alternativa eficaz para se estimar dados de precipitação e modelar as características não-lineares de distribuição desta variável, uma vez que a precipitação influencia diretamente nas ações de transformações sócio-ambiental de uma região.

A partir da década de 80 alguns estudos começaram a investigar o potencial dos Sistemas Inteligentes como ferramenta para simulação do comportamento de processos multi-variáveis não-lineares. Essa Ferramenta vem mostrando capacidade para representar os processos inerentes à precipitação como: sistemas de monitoramento, simulação, previsão e alerta de precipitação e/ou vazão.

Portanto o objetivo desta pesquisa é utilizar as redes neurais artificiais para o estudo da variabilidade da precipitação, visando o preenchimento de falhas, utilizando-se de interpolação espacial e temporal da precipitação para o estado de Alagoas.

2. REVISÃO DE LITERATURA

2.1. Precipitação pluviométrica

A precipitação é uma das variáveis meteorológica mais importante nas regiões tropicais. Sendo um dos elementos meteorológico indispensáveis para o estudo do regime hidrológico e climatológico de uma região. A distribuição espacial e temporal da precipitação é um dos fatores que condicionam o clima e que estabelece o tipo de vida em uma região.

Em meteorologia a precipitação é entendida com sendo toda a água na forma líquida e/ou sólida, proveniente do meio atmosférico que atinge a superfície da terra. A precipitação é classificada pelo estado em que se encontra na atmosfera e o tamanho de suas gotas como: chuva, chuveiro, sereno, virga, neve e granizo, como mostram Tubelis e Nascimento (1983). Embora contribuam com a transferência de umidade da atmosfera para a superfície da terra, nevoeiro, orvalho, e geada não são consideradas tipos de precipitação, pois elas não caem das nuvens, mas se desenvolvem sobre a superfície.

O mecanismo de formação da precipitação está ligado ao crescimento das gotículas de nuvens, onde o vapor d'água contido na atmosfera condensa-se formando gotículas. Os processos mais importantes para a formação de chuva são os de colisão seguido de coalescência e o de difusão de vapor seguido de movimentos turbulentos, movimento Browniano e forças elétricas (Triplet e Roche, 1977).

O processo de "colisão-coalescência", ou simplesmente "processo de captura", é o processo em que as gotículas de diferentes diâmetros se movem no interior das nuvens com diferentes velocidades, devido ao movimento turbulento do ar, que possibilita que umas colidam com as outras, produzindo assim, gotículas cada vez maiores. É importante salientar, que o processo de captura não apresenta uma eficiência de 100%, ou seja, a colisão de duas gotículas nem sempre resulta na sua coalescência, pode haver o espalhamento das gotículas após o choque. Como as gotículas maiores, assim formadas, terão também maior velocidade de queda, colisões adicionais ocorrerão, e um processo cada vez mais acelerado. Desse modo, uma gotícula poderá crescer até atingir o tamanho de uma gota de chuva. O processo de colisão-coalescência é essencial para a formação de nuvens, (Varejão, 2006).

Para que as gotas se precipitem são necessário que as mesmas tenham um volume tal que seu peso seja superior as forças que a mantém em suspensão, adquirindo então, uma velocidade de queda superior as componentes verticais ascendentes dos movimentos atmosféricos. Quando as gotas atingem um tamanho suficiente para vencer a resistência do ar,

elas se deslocam em direção a superfície, onde, nesse movimento de queda, as gotas maiores adquirem velocidade maior que as gotas menores, fazendo com que as gotas menores sejam alcançadas e incorporadas as maiores aumentando, por tanto, seu tamanho. (Vianello e Alves, 2006).

É notório que nem toda a condensação, até mesmo em ar ascendente, é seguida imediatamente de precipitação, pois em alguns casos, há formação de nuvens que não produzem chuvas; sendo necessários condições favoráveis e processo que desencadeiem a precipitação conforme Vianello e Alves (2006).

2.1.1 Classificação da Precipitação

A intensidade e a duração de um sistema de precipitação dependem extremamente dos movimentos verticais da massa de ar. Corrente essa, que dependendo de sua intensidade, determina o mecanismo dominante e o processo de formação dos movimentos verticais e uma posterior classificação, quanto ao tipo de precipitação como: ciclônica, convectiva e orográfica. Essa classificação é útil, porque nem sempre é possível estabelecer uma clara distribuição entre precipitações estratiformes e cumiformes conforme Ayoade (2007).

- *Precipitações Ciclônicas* - são associadas ao deslocamento de massas de ar das regiões de alta pressão para regiões de baixa pressão. A precipitação ciclônica pode ser classificada como frontal e não frontal. Qualquer baixa barométrica pode produzir precipitação não frontal com o ar sendo elevado devido uma convergência horizontal de grande escala em área de baixa pressão. A precipitação resulta da ascensão do ar quente sobre o ar frio da zona de encontro entre duas massas de características diferentes e classificadas como frontal.
- *Precipitações Convectivas* - são associadas a convecção em escala de cumulus em ar instável, são típicas de zonas equatoriais e ocorrem também durante o verão no centro-sul do Brasil. As Precipitações convectivas são de grande intensidade e de curta duração, concentrada em pequenas áreas.
- *Precipitações Orográficas ou de montanha* - ocorrem quando uma parcela de ar quente e úmido encontra uma barreira de montanha, onde o ar é forçado a subir. Ao ser elevado, encontra uma massa fria e seca, com pressão menor que a da parcela, a qual se resfria, ocasionando em condensação por ar úmido e conseqüente formação de nuvens orográficas, como é normal nas encostas voltadas para o mar.

2.2. Sistemas Meteorológicos que Causam Chuvas na Região Nordeste do Brasil

A variabilidade interanual da distribuição de precipitação sobre a Região do Nordeste Brasileiro é caracterizada por alguns mecanismos dinâmicos produtores de chuva nesta região. Estes mecanismos podem ser classificados em sistemas de grande escala ou de escala global, sistemas de mesoescala e sistemas locais. Os sistemas de grande escala influenciam o clima e as condições de tempo em diversas regiões do planeta. No Brasil, são responsáveis pela maior parte da precipitação observada no Nordeste, como a Zona de Convergência Intertropical (ZCIT), que no caso do Brasil, especialmente, produz chuva no setor norte e no setor semi-árido do nordeste brasileiro (Ferreira et al., 2005).

Os sistemas de mesoescala provocam chuvas fortes e de curta duração e são responsáveis por parte da precipitação nos trópicos e em várias regiões de latitudes médias durante a estação quente conforme Marcedo et al. (2005). Esses sistemas atuam no regime pluviométrico dessa área junto com sistemas locais típicos de regiões costeiras tropicais.

Molion e Bernado (2002) destacam a Zona de Convergência Intertropical (ZCIT), como sendo o principal mecanismo de grande escala que, associado à convergência de umidade, produz chuva no setor norte do Nordeste. As regiões leste e sul do Nordeste apresentam a penetração de Sistemas Frontais, associado à convergência de umidade dos Alísios e das Brisas Marítimas e Terrestres, seu principal produtor de grande escala. Segundo autores, nestas regiões são observadas também Perturbações Ondulatórias no campo dos Alísios (POA's), produzidas por penetração de Sistemas Frontais no Atlântico Tropical e África Equatorial. As POA's são mecanismos de mesoescala responsáveis por 30 a 40% dos totais pluviométricos nas regiões costeiras do norte e leste do Nordeste. Ainda segundo estes autores, eventos como El Niño (La Niña) intensos produzem anos secos (chuvosos) estando associados a anos com chuvas abaixo (acima) das normais.

Deste modo, podem-se identificar, no Nordeste do Brasil, regiões homogêneas quanto à distribuição de probabilidade de chuva. Filho et al. (2005) agruparam seis zonas pluviométricas homogêneas por medidas de posição, escala e forma da distribuição de frequência da quantidade da chuva no Nordeste, as quais são: Zona-1: litorânea, clima tropical e úmido, influenciado pelo ar litorâneo úmido do oceano; Zona-2: abrange parte do sertão nordestino, no qual predomina o clima tropical semi-árido; Zonas 3,4 e 5, que são zonas de transição entre o clima tropical semi-árido e o clima litorâneo úmido; Zona-6: que abrange principalmente o Maranhão, norte do Nordeste, onde predomina o clima tropical.

Essa classificação pode ser observada por estudos mais antigos como o de Nimer (1979) que havia identificado em seus estudos, quatro regiões distintas, em que a passagem de alguns sistemas principais de circulação atmosférica é acompanhada de instabilidade e chuvas: região norte, representado pela convergência intertropical; região sul, representada pelas frentes polares do Atlântico sul; região oeste, representado por linhas de instabilidades tropicais e sistemas leste, representados pelas ondas de leste. O autor define uma junção entre os sistemas norte e oeste em um único sistema de correntes perturbadas e denomina-o de sistema nordeste. Igualmente aos sistemas sul e de leste que podem ser agrupados em um único sistema e, denomina-o de sistema sudeste.

Xavier (2005) comenta que o norte no Nordeste Brasileiro sofre a influência de frentes fria ou de sistemas transientes como vórtice ciclônicos, principalmente nos meses de dezembro e janeiro. O autor comenta que em anos de atuação intensa desses sistemas, a zona de convergência intertropical é atraída para latitudes mais ao sul do equador.

Brito e Braga (2005) descrevem no Nordeste, a existência de três regiões distintas que apresentam diferentes períodos para a estação chuvosa (período dos quatro meses mais chuvosos): Um ao sul da região, com estação chuvosa de novembro a fevereiro; outra no norte, com chuvas mais significativas de fevereiro a maio, e a terceira ao leste, com época chuvosa de abril a julho. Deste modo, pode-se identificar, no nordeste brasileiro, três sub-regiões distintas conforme a distribuição espacial da precipitação, sua correlação com os principais períodos de ocorrência e os diversos sistemas que atuam sobre o regime de chuvas no Nordeste em: Região Norte, Sul e Leste, Figura 1.

- Norte do Nordeste Brasileiro (NNEB), região que abrange o estado do Ceará, parte do Rio Grande do Norte, Piauí, Maranhão e oeste da Paraíba e Pernambuco. Esta região tem o seu máximo de chuva nos meses de fevereiro a maio, com índices pluviométricos variando de 400mm/ano no interior e mais de 2000mm/ano no litoral. Os principais mecanismos de produção de chuva no NNEB são a Zona de Convergência Intertropical (ZCIT), a convergência de umidade (brisas e POA's), a convecção local, e raramente, a influência direta de Sistemas Frontais.
- Sul do Nordeste Brasileiro (SNEB), região que abrange todo o estado da Bahia, norte de Minas Gerais, noroeste do Espírito Santo, as partes sul do Maranhão e Piauí e extremo sudoeste de Pernambuco. Os máximos do total pluviométrico estão compreendidos entre os meses de novembro a fevereiro. Esta região demonstra

variação pluviométrica de 600mm/ano no interior a mais de 3000mm/ano no litoral. Os principais mecanismos produtores de chuvas estão definidos com a estacionalidade dos Sistemas Frontais alimentados pela umidade proveniente do Atlântico Sul, que definem a Zona de Convergência do Atlântico Sul (ZCAS), sistemas pre-frontais, convecção local e brisas de mar e terra no litoral.




Figura 1: Distribuição espacial dos regimes de chuva sobre o Nordeste Brasileiro.
 FONTE: Nimer (1979), adaptada por Wanderley (2007).

- Leste do Nordeste brasileiro (LNEB), faixa costeira compreendida pelo litoral e zona da mata, que se entende até 300Km da costa. Esta faixa está compreendida do sul da Bahia ao Rio Grande do Norte, região que apresenta clima quente e úmido com totais pluviométricos de 600mm/ano a 3.000mm/ano. O período mais chuvoso está compreendido entre o mês de abril a maio. Nesta região, os maiores totais de chuvas estão relacionados a circulação de brisas, que advecta bandas de nuvens para o continente e à ação de Frentes Frias e/ou a máxima convergência dos Alísios com a brisa terrestre, a qual é mais forte durante as estações de outono e inverno.

2.3. Incertezas de Dados de Precipitação

Renteria (2006) comenta que a incerteza decorrente de medições está presente em qualquer medida de uma grandeza física, a qual da origem a dados imprecisos, tradicionalmente modelados por conceitos probabilísticos. Entretanto, a Teoria Probabilística se aplica a análise de eventos aleatórios, mas não captura a imprecisão de um evento. A incerteza refere-se à diferença entre as estatísticas da amostra e da população, que pode ser devida a representatividade da amostra ou devido a erros de coletas e processamento dos dados da variável aleatória.

Sirois (1990) mostrou que a incertezas nos cálculos mensal, sazonal e anual de precipitação é um grave problema para a compreensão dos processos hidrológicos e meteorológicos devido à falta de dados. Mas, segundo o autor, existe uma necessidade crescente de se representar e estimar os efeitos da falta de dados de precipitação através da utilização de técnicas de simulação. Uma vez que, a utilização de dados que apresentaram falhas pode ser tendenciosa, se a porcentagem da amostra com falta for diferente do possível valor da precipitação. O valor absoluto do erro torna-se maior à medida que aumenta a diferença entre as amostra, e o desvio-padrão do estimador aumenta com valores crescentes. Estes resultados indicam que amostras com erros de estimação de 10%, o que não é incomum em redes de dados de precipitação, dá uma incerteza de cerca de 10, 5 e 2% para médias de precipitação mensal, sazonal e anual, respectivamente.

A precipitação geralmente apresenta-se como uma variável aleatória em sua distribuição. Suas características, tais como intensidade e duração, geralmente apresentam significativa variação espacial e temporal, acarretando assim imprecisão de sua medição e/ou estimação, até mesmo dentro de pequenas bacias hidrográficas. Segundo Luo et al. (2005) a incerteza da precipitação é decorrente de: (i) sua distribuição temporal, (ii) sua distribuição espacial e (iii) sua ordem de grandeza.

Coulibaly e Evora (2007) comentam que totais diários de precipitação são provavelmente os mais importantes dados para se modelar uma previsão, determinar a qualidade da água, bem como a simulação do impacto das alterações climáticas sobre sistemas de recursos hídricos, meteorológica e agrícola. No entanto, os registros de precipitação frequentemente sofrem de falta de dados devido à avaria dos equipamentos ou erros de coleta.

Esta é uma questão importante, especialmente para regiões situadas em áreas remotas. Por isso, a estimativa de valores faltosos de precipitação, é um assunto difícil tanto para a

hidrologia quanto para a meteorologia, devido à variabilidade espaço-temporal das chuvas e à complexidade dos processos físicos envolvidos, (Mello et al., 2003).

Por isso, descrever adequadamente a variação temporal e espacial da precipitação é essencial, pois a mesma influencia diretamente nas ações de transformações sócio-ambiental de uma região, e por esse motivo, tem sido alvo de vários estudos em ciências exatas e da terra como o de Wanderley et al. (2008).

Alves et al. (2008) cometam que a falta de informação quanto à distribuição espacial da precipitação é um sério obstáculo ao desenvolver técnicas para estimá-la e/ou interpolá-la. Sendo um causador de grande incerteza quanto aos dados estimados. Além disso, os registros de várias estações apresentam falhas, as quais dificultam o processo de estimação, aumentando o erro na interpolação da variável para essa localidade, Djurabekova et al. (2007). Teegavarapu e Chandramouli (2005) comentam que a estimativa de dados que apresentam faltas é uma das mais importantes tarefas exigidas em muitos estudos hidrológicos de modelagem.

Segundo Tercedeiro (2006) e Tucci (2001) as causas mais comuns de erros nas medições de dados de precipitação são:

- i) Erros humanos;
- ii) Erros instrumentais.

2.4. Preenchimento de Falhas de Dados de Precipitação

Alguns autores como Villela e Matos (1975), Gomes e Cruz (2002), Almeida (2007), Pinheiro et al. (2005) Pruski et al. (2004) e Tucci (2001), destacam alguns métodos de preenchimento de falhas como:

a) Método de Ponderação Regional

Método simplificado normalmente utilizado para o preenchimento de séries mensais ou anuais de precipitação. Para aplicação deste método selecionam-se pelo menos três estações, com as mesmas características climatológicas de distribuição da precipitação, que possuam no mínimo dez anos de dados. O cálculo para o preenchimento das falhas de precipitação do posto Y é feita através da Equação 1.

$$y = \frac{1}{3} \left[\frac{x_1}{x_{m1}} + \frac{x_2}{x_{m2}} + \frac{x_3}{x_{m3}} \right] \cdot y_m \quad (1)$$

onde, y é a precipitação do posto Y a se estimada; x_1 , x_2 e x_3 são as precipitações correspondentes ao mês ou ano que se deseja preencher, observadas em três estações vizinhas; y_m é a precipitação média do posto Y ; x_{m1} , x_{m2} e x_{m3} são as precipitações medias das três estações vizinhas.

b) Método de Regressão Linear apresentado na sua forma simples e múltipla

i) Método de Regressão Linear Simples

Neste método a precipitação do posto com falhas e de um posto vizinho são correlacionadas. As estimativas dos dois parâmetros da equação podem ser obtidas graficamente ou através do critério de mínimos quadrados.

ii) Método de Regressão Linear Múltipla

Neste método as informações pluviométricas do posto y são correlacionadas com as correspondentes observações de vários postos vizinhos, através das Equações 2 e 3.

$$y_c = x_{1l} + a_1 x_{2l} + \dots + a_{n-1} x_{nl} + a_n \quad (2)$$

$$y_{cl} = a_0 \cdot x_{1l}^{a1} \cdot x_{2l}^{a2} \cdot x_{3l}^{a3} \dots x_{nl}^{an} \quad (3)$$

Onde, n é o numero de postos considerados, a_0 , a_1 , $\dots$, a_n , são os coeficientes a serem estimados e x_{1l} , x_{2l} , $\dots$, x_{nl} são as observações correspondentes registradas nos postos vizinhos.

c) Método de Ponderação Regional com base em Ponderação Linear

Este método é uma combinação dos anteriores e consiste em estabelecer regressões lineares entres os postos com dados a serem preenchidos.

Em simulação realizada por Tucci (2001), o autor observou que os métodos usados para o preenchimento de falhas produziram valores inferiores àqueles registrados, com erros de 20,37%, 23,54% e 21,39% para os métodos de ponderação regional, regressão linear e

ponderação regional com base em ponderação linear. Segundo o autor, isso se deve ao comportamento da precipitação para o período testado, demonstrando um sensível aumento em seu registro. O autor ainda afirma que a aplicação desses métodos apresenta algumas limitações.

2.5. Métodos de Interpolação

O processo de interpolação pode ser entendido como o mecanismo que permite construir um novo conjunto de dados, para locais não amostrais, a partir de um conjunto discreto de dados pontuais conhecidos, dentro de uma área previamente delimitada. Como cada representação possui suas particularidades, técnicas diferentes são usadas na determinação dos valores de uma variável em todas as suas posições desejadas.

Segundo Kyriakidis et al. (2004), o raciocínio que está na base da interpolação é que, em média, os valores do atributo tendem a ser similares em locais mais próximos do que em locais mais afastados, podendo ser representada sua variação espacial. A interpolação espacial converte dados de observações pontuais em campos contínuos. Já a interpolação temporal busca o preenchimento de dados faltosos em sua série.

Segundo Coelho (2006) e Lourenço (1998) os métodos de interpolação mais comum do Sistema de Informação Geográfica (SIGs) em geral pertencem a duas categorias: globais e locais, que por sua vez, podem ser classificados como determinísticos e estocásticos, e dependendo da técnica utilizada podem ser exatos (técnica de interpolação que prevê valores idênticos aos medidos) e inexatos (técnicas de interpolação que prediz um valor diferente do medido), Tabela 1.

Os métodos de interpolação Global se baseiam no fato de que um atributo ocorre continuamente num espaço bi-dimensional, sendo possível modelá-lo segundo uma superfície matematicamente suavizada, a qual consiste em comparar os vários dados pontuais existentes e observados, que serão utilizados para estimar ou ajustar outro ponto, conforme Hingray e Haha (2005). A interpolação global considera toda população de pontos. Os métodos mais comuns de interpolação global são: o Método de Análise de Superfície de Tendência e o Método de Regressão Polinomial.

Os métodos de interpolação Locais usam um número limitado de pontos vizinhos, fornecendo valores interpolados. Esses métodos consideram uma zona próxima ao ponto que está sendo interpolado, não toda a população como os métodos globais. Os métodos

locais mais utilizados são: Polígonos de Thiessen, Inverso da Distância, Funções spline e Krigagem.

TABELA 1: Principais métodos de interpolação e sua classificação

Globais		Locais	
Determinísticos	Estocásticos	Determinísticos	Estocásticos
Superfície de Tendência (inexato)	Regressão (inexato)	Polígonos de Thiessen (exato)	Krigagem (exato)
		Inverso da Distância (exato)	
		Função Spline (exato)	

Segundo Peres et al. (2003) os algoritmos para inferência de atributos de dados espaciais, representados por amostras pontuais, podem ser classificados segundo três etapas de evolução distintas, a modelagem determinística, a modelagem estocástica linear e a modelagem estocástica, não linear “por indicação”.

Segundo Tucci (1998), o processo e o modelo são ditos estocásticos quando a chance de ocorrência das variáveis é levada em conta, e o conceito de probabilidade é introduzido na formulação. Por outro lado, se a chance de ocorrência das variáveis envolvidas no processo é ignorada, e o modelo segue uma lei definida que não é a lei das probabilidades, o modelo e os processos são ditos determinísticos.

Os algoritmos de interpolação determinísticos se caracterizam pela modelagem dos dados espaciais segundo o paradigma determinístico. Conforme Teegavarapu e Chandramouli (2005), neste tipo de modelagem os modelos de dados espaciais não contêm componente aleatória e são, portanto, considerados exatos. Em geral, o valor de ponderação é definido igual ao inverso simples ou ao quadrado da distância euclidiana da amostra. Estes interpoladores são denominados locais, pois utilizam um subconjunto das amostras na vizinhança de cada ponto a ser interpolado.

Os interpoladores estocásticos lineares se caracterizam pela modelagem dos atributos espaciais segundo o paradigma geoestatístico linear, na qual os atributos espaciais são considerados variáveis aleatórias e são tratados pela teoria das variáveis regionalizadas, segundo Sugimoto (2001). A geoestatística considera que a distribuição espacial do atributo

define uma função aleatória, dentro de uma região de interesse. Neste tipo de modelagem, os atributos são estimados pelo o método de krigagem linear, principalmente a krigagem ordinária.

A modelagem estocástica por indicação se caracteriza por utilizar os procedimentos não lineares da geoestatística. Li et al. (2009) afirmaram que este procedimento possibilita a inferência de uma aproximação discretizada do modelo de distribuição de probabilidade do atributo que é, então, utilizada para modelagem da incerteza sobre seus valores. Assim, tem-se uma modelagem espacial não paramétrica que pode, portanto, ser usada sem restrições ao tipo de distribuição do atributo. Segundo Imai et al. (2007) a krigagem por indicação é um estimador de krigagem não linear, ou seja, um estimador de krigagem linear aplicado a um conjunto de dados que foram modificados segundo uma transformação gaussiana, lognormal ou outra.

A krigagem é um conjunto de técnicas de regressão linear generalizada que permite minimizar a variância de estimação a partir de um modelo de covariância. Segundo Camargo (2004) a diferença entre a krigagem e outros métodos de interpolação é a maneira como os pesos são atribuídos às diferentes amostras. No caso de interpolação linear simples, por exemplo, os pesos são todos iguais a $1/N$ (N = número de amostras); na interpolação baseada no inverso do quadrado das distâncias, os pesos são definidos como o inverso do quadrado da distância que separa o valor interpolado dos valores observados. Na krigagem, o procedimento é semelhante ao de interpolação por média móvel ponderada, exceto que aqui os pesos são determinados a partir de uma análise espacial, baseada no variograma experimental. Além disso, a krigagem fornece em média, estimativas não tendenciosas (estimativas não tendenciosas significam que, em média, a diferença entre valores estimados e verdadeiros para o mesmo ponto deve ser nula) e variância mínima (significa que estes estimadores possuem a menor variância dentre todos os estimadores não tendenciosos).

A krigagem usa informações obtidas no variograma para encontrar os pesos a serem associados às amostras com valores desconhecidos. O variograma é a ferramenta básica para o procedimento de interpolação através do método de Krigagem, pois permite uma representação quantitativa da variação de um fenômeno regionalizado no espaço e no tempo, definindo a região de influência da variável, “região de dependência espacial ou alcance”. Segundo Bargaoui e Chebbi (2009) os principais métodos de krigagem são: krigagem simples, krigagem ordinária, krigagem universal, cokrigagem e krigagem por indicação.

Carvalho e Assad (2005) comentam que a região de dependência espacial possibilita que todas as estações vizinhas dentro desse raio, sejam usadas na estimativa de valores de

atributos de estações próximas. Vendrusculo et al. (2003) analisaram dados relativos à precipitação anual, através da utilização de variograma, encontraram dependência espacial da 48,5km, para o estado de São Paulo.

Baú et al. (2006) realizaram estudo da distribuição mensal da precipitação para o Paraná, encontraram alcance mensal para a precipitação variando de 44 a 101Km, para o mês de menor e maior dependência espacial. Zamboti e Melem (2002) modelaram a precipitação pluviométrica mensal total do mês de dezembro na região do interior e no litoral do estado do Paraná, encontrando alcance de 83,2 e 196,8Km, respectivamente para interior e litoral. Mello et al. (2003) trabalhando com dados de precipitação máxima, encontraram alcance próximos uns dos outros, na faixa de 90 a 100 km.

A krigagem quando comparada com outros métodos de interpolação vêm demonstrando resultados mais satisfatórios como nos trabalhos de: Bucene e Zimback (2003), Mello et al. (2003), que compararam a krigagem ao método do quadrado do inverso da distância para a interpolação de dados de chuva. E concluíram que a krigagem oferece uma melhor estimativa dos parâmetros nos locais onde esses não foram amostrados, com uma boa distribuição e continuidade. Alves et al. (2008) compararam os métodos de interpolação por krigagem ordinária e inverso da distância ponderada (IDP) para representar altitude, vazão, áreas de recarga e de vegetação. Observando o melhor desempenho da estimação por krigagem quando comparado ao método IPD.

Jakob e Young (2006) compararam alguns métodos de interpolação como: inverso do quadrado da distância, polinômio local e global, função de base radial e krigagem; concluído que entre os métodos testados, a krigagem ofereceu menores erros, sendo este o melhor método para se empregar a interpolação de variáveis.

Goovaerts (2000) avaliou o desempenho de três algoritmos geoestatísticos para a incorporação de um modelo digital de elevação territorial para a previsão de chuvas: krigagem simples com diferentes meios locais; krigagem com deriva externa e co-krigagem. As técnicas são ilustradas por meio de observações de precipitação anuais e mensais medidos em 36 estações climáticas em uma região de 5.000km² de Portugal.

O autor utilizou a validação cruzada para comparar os desempenhos da predição dos três algoritmos geoestatístico de interpolação com a regressão linear simples e três técnicas univariadas: o polígono de Thiessen; inverso do quadrado da distância e krigagem ordinária. Os erros de previsão maiores foram obtidos para os algoritmos do inverso do quadrado da distância e para o polígono de Thiessen, os quais ignoram tanto a elevação, quanto os registros de chuvas em torno das estações. Os três algoritmos geoestatísticos demonstraram

resultados satisfatórios, sendo a krigagem ordinária mais precisa do que a regressão linear quando a correlação entre a precipitação e a altitude é moderada.

Segundo Coulibaly e Evora (2007), Pokrovsky (2007), Verma et al. (2007) e Remesan et al. (2009) o comportamento dos padrões de distribuição da precipitação geram um conjunto de informações, cuja respostas, não são lineares, as quais não podem ser descritos corretamente por aplicação de regressão linear simples como método de interpolação. Para Ozelkan et al. (1998) é preciso ter em mente que a otimização de sistemas não-lineares, pode ser um desafio para sua resolução.

Deste modo, a literatura apresenta a utilização de ferramentas de sistemas inteligentes (Algoritmo Genético, Lógica Fuzzy e Redes Neurais Artificiais) como uma metodologia eficaz de interpolação para variáveis que apresentam distribuição não-linear, Shen et al. (2000), Mackey (2004), Lin e Chen (2004), Celikoglu (2006).

2.6. Utilização de Sistemas Inteligentes para a Interpolação de Dados de Precipitação

Sirois (1990) mostrou que a incertezas nos cálculos mensal, sazonal e anual de precipitação é um grave problema para a compreensão dos processos hidrológicos e meteorológicos devido à falta de dados. Mas, segundo o autor, existe uma necessidade crescente de se representar e estimar os efeitos da falta de dados de precipitação através da utilização de técnicas de interpolação.

A literatura apresenta vários estudos que investigam diferentes abordagens, incluindo redes neurais artificiais, para preencher falhas de dados de vazões, mas poucos estudos têm sido conduzidos sobre a reconstrução de registros de dados faltosos de precipitação, (Tucci, 1998), e (Coulibaly e Evora, 2007).

Valença (2005) discute que a modelagem do processo precipitação-vazão tem duas abordagens: a simulação física do sistema hidrológico com o uso de modelos conceituais e a simulação estatística ou estocástica que se baseia no conceito de caixa-preta. Segundo o autor, os modelos conceituais mais utilizados no mundo são o Stanford Watershed Model (SWM) e o HEC-1. Entretanto, a implementação e calibração deles podem apresentar algumas dificuldades, requerendo significativa quantidade de dados para calibração, bem como experiências com eles. Por outro lado, na aplicação estatística, destacam-se os modelos de séries temporais do tipo ARMAX (Auto-regressivo média móvel). Entretanto, tais modelos apresentam limitações, pois não são capazes de representar a não-linearidade e a variabilidade

espacial e temporal dos processos de precipitação-precipitação e precipitação-vazão. Os modelos ARMAX são capazes de representar muito bem o comportamento de um sistema cujas características de entrada e saída são aproximadamente lineares e, por outro lado, podem ser vistas como uma versão simplificada de uma rede neural com função de ativação linear e nenhuma camada escondida. O autor ressalta que com o uso de redes neurais se consiga uma melhor representação dos processos estocásticos. A rede neural é uma estrutura matemática flexível capaz de identificar as relações complexas não-lineares entre um conjunto de dados de entrada e saída.

Coulibaly e Evora (2007) comentam que totais diários de precipitação são provavelmente os mais importantes dados para se modelar uma previsão, determinar a qualidade da água, bem como a simulação do impacto das alterações climáticas sobre sistemas de recursos hídricos e agrícolas. Em hidrologia operacional, as características das enchentes como: época de ocorrência e forma são fortemente afetadas pela variabilidade espacial e temporal das chuvas. No entanto, na prática, os registros de precipitação frequentemente sofrem de falta de dados devido à avaria dos equipamentos. Esta é uma questão importante, especialmente para as bacias hidrográficas situadas em áreas remotas. Por isso, a estimativa de valores faltosos de precipitação é uma tarefa difícil em estudos hidrológicos devido à variabilidade espaço-temporal das chuvas e à complexidade dos processos físicos envolvidos.

Segundo os autores, poucos estudos têm investigado a utilização de redes neurais artificiais para preencher falhas de dados de precipitação. Deste modo, alguns métodos estatísticos têm sido propostos para preencher dados faltosos de precipitação, no entanto, nenhum destes estudos comparou plenamente diferentes tipos de redes neurais artificiais (RNA's) para preencher registros ausentes de precipitação diária e de temperaturas extremas diárias. Os autores investigaram seis diferentes tipos de redes neurais artificiais a saber: a rede perceptron multicamada (MLP) e suas variações (o tempo-desfasados feedforward rede (TDFW)), a função de base radial generalizada (RBFN), as redes neurais recorrentes (RNR) e suas variações (o tempo de redes neurais recorrentes (TRNR)), e as propagações fuzzy-neural network (FNN), juntamente com diferentes métodos de otimização para preencher a falta diária de registros de precipitação e temperaturas.

Para a realização do estudo, foram utilizadas 15 estações meteorológicas localizadas dentro da bacia hidrográfica Gatineau no nordeste do Canadá, com registros de precipitação e temperatura diários. Como conclusão do estudo, todas as RNAs foram aplicadas para preencher registros com falta de precipitação diária e temperatura máxima e mínima. As

RNAs foram treinadas com os mesmo dados, com o intuito de obter uma avaliação global do desempenho das diferentes RNAs para reconstruir os dados. Para avaliar o desempenho das RNAs para a reconstrução dos dados meteorológicos diários, alguns critérios básicos, tais como erro médio absoluto (EAM), o coeficiente de correlação (r) entre os dados observados e os reconstruído são utilizados. Surpreendentemente, em termos globais, o padrão MLP e suas variações (TDFW) forneceram os mais precisos registros de dados reconstruído de precipitação. Inversamente, as redes orientadas (isto é, a RNR e os TRNR), bem como a RBF, tiveram resultados insuficientes em comparação com a estática (MLP) e os modelos pseudo-dinâmicos (TDFW). O FNN mostrou resultados satisfatórios para duas estações, porém mostrou um baixo desempenho nas demais estações. Para cada estação, a média e o desvio padrão dos dados observados (ou histórico) e da precipitação reconstruída foram calculadas. Para três estações testadas, o FNN reproduziu muito bem os dados estatísticos observados (média e desvio padrão) - o que sugere que os dados reconstruídos preservem o padrão histórico, assim como as redes MLP e TLFN.

Yurdusev e Firat (2009) comentam que a simulação hidrológica, por vários anos, foi obtida por técnicas de regressão e modelos de séries temporais. E que hoje, diferentes abordagens para a simulação são utilizadas, incluindo várias técnicas matemáticas e estatísticas, tais como tempo de extrapolação, utilização de desagregação final, método do coeficiente único, método do coeficiente múltiplo, método probabilístico, técnica baseada na aprendizagem e modelos de séries temporais. Os autores destacaram ainda o uso de novas técnicas eficientes de modelagem de sistemas complexos de recursos hídricos, tais como redes neurais artificiais (RNA's), lógica fuzzy (LF) e inferência de sistema adaptativo neuro fuzzy (ANFIS). Essas ferramentas em sua maioria são utilizadas para a modelagem de processos de precipitação-vazão, modelagens hidrológicas de séries temporais, estimativa de concentração de sedimentos e escoamento superficial. Os autores comentaram que a previsão de longo prazo é fundamental quando se necessita de um melhor planejamento dos sistemas de distribuição e da concepção de uso dos recursos hídricos, uma vez que, a previsão de curto prazo, é importante para a exploração, gestão e distribuição de águas dos reservatórios. Uma vez que, o consumo de água é afetado por diversos fatores, tais como população, precipitação, umidade, temperatura, condições comerciais e industriais.

Ozgur et al. (2009) destacaram a eficácia do uso de sistemas inteligentes na simulação hidrológica. Dentre essas, os autores destacaram que a utilização de redes neurais artificiais e lógica fuzzy, as quais podem oferecer uma alternativa promissora para os processos hidrológicos, como: simulação precipitação-precipitação, precipitação-vazão, previsão de

enchentes, previsão de influxo do reservatório, e para corrigir a estimativa e o transporte de sedimentos. Em seu estudo os autores tinham como objetivo investigar a precisão e a adaptação técnica neuro-fuzzy (NF) para estimar o transporte de sedimentos suspensos.

Para a realização do estudo, foram utilizados dados mensais de sedimentos em suspensão de duas estações, Kuylus e Salur Koprusu, na Bacia Kizilirmak na Turquia. Os resultados obtidos usando a técnica neuro-fuzzy (NF) foram testados e comparados com os das redes neurais artificiais (RNA). O erro médio absoluto e o coeficiente de correlação estatística são utilizados para comparar e avaliar a performance dos modelos. Os autores concluíram na comparação dos resultados, que a técnica NF apresentou um melhor desempenho do que os outros modelos. A comparação dos resultados revelou que os modelos neuro-fuzzy podem ser empregados com sucesso na estimativa da taxa de transporte mensal de sedimentos em suspensão.

Teegavarapu e Chandramouli (2005) comentaram que a estimativa de registros de precipitação que apresentam faltas, é uma das mais importantes tarefas exigidas em modelagem hidrológica. Deste modo, os autores compararam alguns métodos de estimação de dados de precipitação para o preenchimento de falhas de precipitação como: Método de ponderação inversa da distância (MPID), a Integração das abordagens Polígono de Thiessen e método da distância inversa (PTDI), método de ponderação Coeficiente de Correlação (MPCC), Método de Ponderação Exponencial Inversa (MPEI), Método de Ponderação Vizinho mais Próximo (MPVMP), Método de estimativa Redes Neurais Artificiais (RNA) e Método de estimativa por Krigagem (MEK).

Os métodos foram avaliados através da análise da Raiz Quadrada do Erro Médio (RQEM), Erro Médio Relativo (EMR), Erro Absoluto Médio (EAM) e pelo Coeficiente de Determinação (r^2). Para o estudo, os autores utilizaram media anual de 1971 a 2003, para 20 estações no estado de Kentucky, EUA. A estimativa foi realizada em duas etapas, uma com 33% dos dados, e outra com 66%, para a estimação da precipitação em 6 e em 12 estações. Para a simulação com 6 estações o método de MPCC obteve os melhores resultados para RQEM, EMR e EAM. Para a simulação com 12 estações, todos os métodos apresentaram uma melhora significativa nos resultados, com RNA apresentando melhores valores para EMR, EAM e r^2 . Através do método de Thiessen, os autores definiram quatro estações mais próximas para a estimativa da precipitação na estação base, no centro dos polígonos. Nesta abordagem, a RNA apresentou o melhor r^2 . Para a simulação pelo método de krigagem, foram utilizados três modelos de variogramas (esférico, exponencial e gaussiano).

Os resultados montaram o modelo de variograma esférico com melhor desempenho em relação ao outro variograma. A krigagem também proporcionou melhor desempenho comparação com MPID e é ligeiramente inferior ao MPCC e a RNA. Foi evidenciado pelo os autores que o desempenho de todos os métodos, exceto MPEI, apresentaram melhoras quando o número de estações foi aumentado. Uma das principais razões para a melhoria do desempenho pode ser atribuída à existência de forte autocorrelação espacial entre as observações registradas em todas as estações. Os resultados deste experimento demonstraram que o desempenho de MPID falhou e os MPCC e RNA conseguiram proporcionar melhores estimativas de dados faltantes. Este experimento também prova que distância nem sempre é o parâmetro adequado para representar a força da correlação entre as amostras.

Teegavarapu (2007) enfatizou que métodos de interpolação determinísticos e estocásticos são frequentemente os métodos mais utilizados para estimar valores de precipitação que apresentam falhas. O autor comenta que a estimação por métodos tradicional, com o de Krigagem, apresenta uma grande limitação devido à necessidade de se definir uma função matemática que possa se ajustar a função do variograma, o qual expresse a superfície a ser interpolada. A utilização de funções universais (rede neural artificial), em substituição ao modelo de variograma, utilizados no método de krigagem é investigada neste estudo. A krigagem ordinária é usada para a estimativa de dados de precipitação com falhas. Para o estudo, foram utilizados dados de precipitação diária de 15 estações de medição em Kentucky, E.U.A.

Os resultados sugerem que o uso da função universal de aproximação rede neural em conjunto com krigagem tem várias vantagens sobre krigagem ordinária. No estudo, uma rede neural é usada como modelo de variograma, utilizando os dados brutos de krigagem ordinária para estimar dados ausente de precipitação. O uso da rede neural elimina a necessidade de se utilizar modelos pré-definidos de variograma para capturar a variação espacial de dados.

Os resultados sugerem que o desempenho da função de aproximação universal baseado no método de krigagem, para a estimativa de dados de precipitação com falhas, é satisfatório aos obtidos por krigagem ordinária tradicional. No entanto, o cuidado deve ser exercido através da abordagem de uma função universal como um substituto para um modelo de variograma. A forma funcional criado pela rede pode nem sempre resultar em um modelo de autorização que fornece a solução única e estável, que satisfaz as condições de krigagem ordinária.

Teegavarapu et al. (2009) propuseram um forma para se estimar dados de precipitação com falhas. O método utilizou, algoritmos genéticos (AG), formulação de otimização não-

linear para conseguir as melhores formas funcionais e coeficientes. Dados históricos de precipitação diária de 15 estações de medições localizadas no estado de Kentucky, E.U.A. são usados para testar a forma funcional e tirar conclusões sobre a eficácia do método proposto para estimativa dos dados de precipitação em falta. Os testes com AG em duas estações em Kentucky indicaram que as estimativas de precipitação podem ser comparadas com técnica de ponderação inversa tradicional. O AG é testado usando 6 estações mais próximo, das 14 disponíveis. A maior queda do erro absoluto foi obtida para o período de treinamento e testes com 14 e 6 estações. O uso de dados passados ajudaram a identificar a existência ou a falta de correlação entre observações separadas por locais diferentes. Os Resultados sugerem que o desempenho do AG na estimativa de falha de dados de precipitação é melhor do que outros métodos convencionais de ponderação. O método também proporcionou melhores resultados quando o número limitado de estações foi utilizada. O estudo também mostrou que tanto a distância quanto o coeficiente de correlação entre as estações ajuda a melhorar a precisão do método de estimativa.

Bodria e Cermák (2000) comentaram que a homogeneização dos dados de entrada, de uma rede neural, são um dos requisitos fundamentais para a previsão de confiança. Em outras palavras, os dados de entrada da rede são organizados como uma sequência temporal das precipitações mensais anteriores, que são mostrados à rede simultaneamente, onde a saída é a precipitação do mês seguinte. Este estudo indicou que a precipitação de um determinado mês foi dependente dos dois últimos meses do ano em curso (dois tempos passados), e da precipitação desse mesmo mês em dois anos anteriores. O uso de três ou mais tempos passados não melhorou significativamente o desempenho da rede. Os autores comentam que a estrutura de entrada da rede com a utilização de dados passados, é importante e deve ser feita. Geralmente, estas decisões são difíceis, uma vez que a precipitação é um processo estocástico complexo que envolve um número desconhecido de efeitos. Este estudo indicou que a precipitação de um determinado mês foi dependente dos dois últimos meses do ano em curso (dois tempos passados), e da precipitação desse mesmo mês em dois anos anteriores. O uso de três ou mais tempos passados não melhorou significativamente o desempenho da rede.

Kuo et al. (2006) desenvolveram um modelo hidrológico que visava combinar Redes Neurais Artificiais (RNA's) e Algoritmos Genéticos (AG), o qual foi desenvolvido para avaliar a gestão da qualidade da água no Reservatório de Feitsui em Taiwan. A Rede Neural foi utilizada para simular o comportamento da carga de nutrientes em um reservatório a través de dados de precipitação. O AG foi utilizado como uma estratégia na pesquisa para determinar a redução das taxas de cargas de nutrientes da bacia. Os resultados indicaram que

o modelo de RNA pode efetivamente simular a dinâmica da qualidade de água do reservatório. O AG foi capaz de identificar os sistemas de controle que reduziram as concentrações totais no reservatório em 60%, e o nível da carga de nutrientes foi reduzido de 10-80% na bacia hidrográfica.

Lobbrecht e Solomatine (2002) enfatizaram que em áreas densamente povoadas, tornasse necessário o controle da quantidade de água, uma vez que, esta medida pode prevenir inundações. O sistema de controle em tempo real (CTR) tornou-se uma metodologia avançada para a plena utilização das capacidades disponíveis de um sistema de abastecimento de água. O CTR quando aplicado para regular as estruturas urbanas e rurais de sistemas de água, pode eliminar a necessidade de grandes investimentos em sistemas de infra-estrutura de água. No entanto, desde os mais recentes desenvolvimentos nas tecnologias da informação e informática, CTR, passou a ser indispensável para a gestão global da água, e não apenas uma interessante relação “custo-benefício”. CTR fornece informações essenciais sobre o comportamento do sistema de água apoiando na gestão diária das operações e de médio e longo prazo. Os autores objetivaram investigar a possibilidade de utilizar redes neurais artificiais (RNA's) e sistemas adaptativos fuzzy (SAF), para reproduzir o comportamento de um modelo determinístico que controla um sistema de abastecimento de água. Os autores concluíram que a utilização das técnicas propostas para a aprendizagem de máquina com a utilização de RNA e FAS foram aplicados com sucesso para reproduzir o controle de ações centralizadas em um estudo de caso de serviços operacionais de gestão dos recursos hídricos. A precisão obtida por estes métodos foi satisfatória.

2.7. Redes Neurais Artificiais

As redes neurais foram desenvolvidas, originalmente, na década de 40, pelo neurofisiologista McCulloch e pelo matemático Walter Pitts. Onde seu trabalho consistia em uma analogia entre células nervosas vivas e um processo eletrônico binário. Mais o aumento do interesse pelas redes neurais, também conhecidas como connexionismo ou sistemas de processamento paralelo e distribuído só se deu no fim da década de 80. Segundo Braga et al. (2000) dois fatores foram responsáveis por essa retomada: o avanço da tecnologia, sobretudo da microeletrônica e o insucesso na resolução de alguns problemas simples para o ser humano.

As redes neurais hoje se apresentam como uma abordagem alternativa aos métodos estatísticos tradicionais na solução de problemas, cuja aplicação prática está se tornando cada

vez mais presente no nosso dia-a-dia. Müller e Fill (2003) destacam que em ciências ambientais como a meteorologia e a hidrologia, os sistemas computacionais inteligentes encontram aplicações, sobretudo em modelagem, previsão, otimização, operação e controle. Surgindo como alternativa ou complemento de técnicas consagradas da estatística, pesquisa operacional e modelagem numérica.

As Redes Neurais Artificiais se constituem em uma técnica de inteligência artificial definidas como sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas, normalmente não-lineares. Tais unidades são dispostas em um ou mais camadas (uma camada de entrada, uma ou várias intermediárias e uma de saída) e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões são associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

2.7.1. Neurônios Biológicos e Artificiais

O cérebro humano contém em torno de 10^{11} neurônios, suas células fundamentais. Os neurônios são divididos em três seções: corpo celular, dendritos e axônios, Figura 2. Do corpo celular saem ramificações chamadas dendritos e um prolongamento chamado axônios. A passagem de impulsos nervosos entre dois neurônios se dá na região de sinapse, geralmente formada pela união de dos axônios de um neurônio e os dendritos de outro.




Figura 2: Neurônio Biológico

É pela sinapse que os nodos se unem formando redes neurais. As sinapses funcionam como válvulas que controlam a transmissão de impulsos, entre os neurônios e a rede neural. Braga et al. (2000) comentaram que o efeito da sinapse é variável, dando ao neurônio a capacidade de adaptação. Se o sinal transmitido de um neurônio para o outro for suficiente

para excitá-lo, esse impulso é transmitido para as células seguintes. Mas, se o estímulo for inferior ao limiar excitatório, não ocorrerá nenhum estímulo nervoso. Esse sistema simples é responsável pela maioria das funções do nosso cérebro.

Os neurônios artificiais são simplificação do que se sabe a respeito do neurônio biológico, Figura 3. Valença (2005) comentou que o modelo proposto procura representar o neurônio biológico utilizando a regra de propagação e uma função de ativação. A emissão de sinais por esses neurônios estar baseada em um limiar excitatório, em analogia ao neurônio biológico.




Figura 3: Neurônio Artificial

O neurônio artificial é descrito como uma função matemática com n terminais de entrada $x_1, x_2, \dots, x_n$, (que representam os dentritos) de um neurônio y_k de saída (representando o axônio). Para emular o comportamento das sinápses, os terminais de entrada têm pesos acoplados $w_1, w_2, \dots, w_n$. Os pesos determinam em que grau o neurônio deve considerar os disparos que ocorrem naquela conexão, Equação-4.

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (4)$$

onde n é o número de neurônio, w_i é o peso associado à entrada x_i e θ é o limiar do neurônio.

A função de ativação na unidade de saída é a função sigmóide dada pela Equação-5. As funções sigmóides são vantajosas para essa aplicação por serem funções monotonamente crescentes, além de propiciarem um treinamento mais rápido e eficiente.

$$f(y) = \frac{1}{1 + e^{-y}} \quad (5)$$

2.7.2. Processo de Aprendizado ou Treinamento da Rede Neural

Segundo Carvalho (2000), o treinamento ou aprendizado de uma rede visa à obtenção de um erro mínimo, que mede a diferença entre saída calculada pela rede e o valor desejado. Dependendo do tipo da rede, são fornecidos os dados de saída desejada, com o objetivo de que esta consiga prever as saídas corretamente mediante a entrada de dados desconhecidos para ela. Este processo de aprendizado consiste em ajustes sucessivos dos pesos e, em alguns algoritmos, dos resíduos de ativação, de forma a se obter, os dados de saída da rede os mais próximos possíveis dos desejados. Esta é a etapa que exige maior demanda computacional na utilização de qualquer rede neural.

A propriedade mais importante das redes neurais é a habilidade de aprender com o seu ambiente e melhorar seu desempenho. Os mecanismos de aprendizado possibilitam a modificação de seu padrão de interconexão capacitando-a a resolver um determinado problema. Para treinar uma rede neural podem ser utilizados três mecanismos distintos de aprendizado, (Müller e Fill, 2003):

- **Aprendizado supervisionado** - São fornecidos, para a rede, o conjunto de dados de entrada e as respectivas respostas. A diferença entre a resposta desejada e a atual, fornecida pela rede, é então usada para calcular a correção dos pesos da rede neural. As redes Perceptron multicamadas MLP, GMDH e SSBN utilizam este tipo de treinamento.
- **Aprendizado não-supervisionado** - Neste tipo de aprendizado, a rede aprende com os seus próprios dados de entrada (somente os estímulos de entrada são mostrados à rede), ou seja, este algoritmo não requer o conhecimento das saídas. A rede se organiza internamente de tal forma que cada elemento de processamento de resposta, responda estrategicamente a um diferente conjunto de entradas.
- **Aprendizado por reforço** - quando apenas um parâmetro externo de comparação é fornecido com o objetivo de avaliar se a rede está agindo corretamente ou erroneamente. Normalmente é utilizado quando o problema envolve o tempo de sequencia de processos ou quando a resposta exata não está disponível, e somente sinais secundários são visíveis.

2.8. Método Geoestatístico de Interpolação

A geoestatística é definida como um conjunto de técnicas que estima valores regionalizados e espacializados de variáveis ou elementos de uma determinada área. A geoestatística é uma metodologia que permite uma análise espacial e/ou temporal de dados correlacionados. O traço marcante das características da geoestatística é o uso do variograma. O variograma permite através de técnicas simples definir um modelo estrutural de correlação espacial de uma variável. Além disso, inclui-se varias técnicas semelhantes de krigagem que utilizam modelos de correlação estrutural.

O variograma é a ferramenta básica para o procedimento de interpolação através do método de Krigagem, pois permite uma representação quantitativa da variação de um fenômeno regionalizado no espaço e no tempo. O mesmo expressa a dependência espacial através da medida da variância dos valores amostrais, separados por uma distância h . O nível de dependência entre duas variáveis regionalizadas, X e Y, é representado pelo variograma, $2\gamma(h)$, o qual é definido como a esperança matemática do quadrado da diferença entre os valores de pontos no espaço, separados pelo vetor distância h , definido pela Equação-6.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (6)$$

onde, $N(h)$ = número de pares de valores amostrados $[Z(x_i) - Z(x_i + h)]$ separados pelo vetor h .

Neste estudo foram utilizados os modelos isotrópicos experimental de variogramas, dos tipos Esférico, Exponencial e Gaussiano, ambos com patamar, os quais vêm demonstrando resultados satisfatórios em estudos sobre precipitação, Zamboti (2001).

Um exemplo ilustrativo do variograma e seus parâmetros: patamar, efeito pepita, alcance e Variância Estrutural, podem ser visto na Figura 4.




Figura 4: Modelo de Variograma Experimental com Patamar

- *Patamar* ($C + C_o$) - ponto o qual a função se estabiliza no variograma, é o valor do variograma correspondente a seu *alcance* (a). Deste ponto em diante, considera-se que não existe mais dependência espacial entre as amostras, porque a variância da diferença entre pares de amostras torna-se invariante com a distância;
- *Alcance* (a) - distância dentro da qual as amostras apresentam-se correlacionadas espacialmente;
- *Efeito Pepita* (C_o) - ponto onde o variograma toca o eixo das ordenadas, esse ponto revela a descontinuidade do variograma para distâncias menores do que a menor distância entre as amostras;
- *Variância Estrutural* (C) - é a diferença entre o patamar ($(C + C_o)$) e o Efeito Pepita (C_o).

Verificada a dependência espacial, é possível se estimar valores da variável para os locais não amostrados dentro do campo de análise através da técnica de Krigagem.

2.8.1. Método de Krigagem

A krigagem usa informações do variograma para encontrar os pesos ótimos a serem associados às amostras com valores conhecidos que irão estimar pontos desconhecidos. O termo krigagem é derivado do nome Daniel G. Krige, que foi o pioneiro a introduzir o uso de médias móveis para evitar a superestimação sistemática de reservas de mineração.

Inicialmente, o método de krigagem foi desenvolvido para solucionar problemas de mapeamentos geológicos, mas seu uso expandiu-se com sucesso para outras áreas. A krigagem pode ser entendida como uma série de técnicas de análise de regressão que procura minimizar a variância estimada a partir de um modelo prévio, que leva em conta a dependência estocástica entre os dados distribuídos no espaço.

Os três tipos de krigagem mais conhecidos são: Krigagem Simples, Krigagem Ordinária e Krigagem Universal. A Krigagem Ordinária foi escolhida para a interpolação neste estudo por apresentando resultados mais satisfatórios quando comparadas com os outros tipos de Krigagem, (Alsamamra et al., 2009).

As estimativas por Krigagem Ordinária assumem que a médias das amostras é constante, mais desconhecidas dos dados disponíveis. O método de Krigagem Ordinária pode ser escritos em notação matricial como mostra a Equação-7.

$$K \cdot \lambda = k \Rightarrow \lambda = K^{-1} \cdot k \quad (7)$$

onde, K e λ são matrizes das covariâncias (ou variogramas) e k o vetor dos pesos.

A vantagem principal da Krigagem Ordinária é que os dados usados descrevem o grau de influência e da dependência espacial usado atribuir pesos às observações. Llyud (2005) comenta que os pesos são atribuídos arbitrariamente pela Equação-8. E a correlação espacial entre os pontos de medida pode ser quantificada por meio da função de variância, pela Equação-9.

$$Z(x_i) = f(x_i) + e(x_i), \quad i = 1, 2, \dots, n \quad (8)$$

onde, $f(x_i)$ = função aleatória F num ponto x_i ; $e(x_i)$ são realizações médias de zero e erros.

$$\gamma(x, h) = \frac{1}{2} \text{var}[F(x) - F(x + h)] \quad (9)$$

onde, assumimos que h é a distância euclidiana entre dois pontos e que a tendência é constante, e $\gamma(x, h)$ são independente de x . Uma função paramétrica é usada para modelar a variância para valores diferentes de h .

O processo de validação cruzada permite através de um procedimento interpolativo, como o de krigagem, estimar valores de dados amostrais. Este procedimento retira de um ponto em um conjunto de dados, valores conhecidos $Z(x_i)$ e o estima $Z^*(x_i)$, repetindo o processo para todo o conjunto. Obtendo assim, dois valores para cada ponto, o real e o estimado, e a diferença entre os valores são definidos como erro na estimativa, ou cálculo da validação cruzada. A regressão linear dos valores é obtida pela Equação-10.

$$Z^*(x_i) = A + bZ(x_i) \quad (10)$$

onde, onde a é a intercessão e b é o coeficiente angular da reta.

3. MATERIAIS E MÉTODOS

3.1. Caracterização da Área de Estudo

O estado de Alagoas está localizado na região leste do nordeste brasileiro, fazendo limite ao norte com o estado de Pernambuco, ao sul com Sergipe, a oeste com Pernambuco e Bahia e a leste limita-se com o Oceano Atlântico. O Estado possui uma população de 3.015.912 habitantes (IBGE, 2005) e ocupa uma área de 27.793Km², correspondente a 0,33% do território nacional e a 1,8% da Região Nordeste, (Figura 5) (Assis et al., 2007). O Estado está dividido em 102 municípios, tendo sua localização geográfica entre as coordenadas:

Norte: 8° 48' Lat. Sul e 35° 30' Long. Oeste;

Sul: 10° 30' Lat. Sul e 36° 23' Long. Oeste;

Leste: 8° 54' Lat. Sul e 35° 09' Long. Oeste;

Oeste: 9° 19' Lat. Sul e 38° 13' Long. Oeste;




Figura 5: Região Nordeste do Brasil, estado de Alagoas e suas microrregiões

O Estado está dividido basicamente em seis regiões ambientais: Litoral, Zona da Mata, Agreste, Sertão, Sertão do São Francisco e Baixo São Francisco. Quanto à vegetação, o Estado possui uma vegetação típica de: floresta tropical, mangues litorâneos e caatinga. A principal forma de atividade agropecuária é a ocupação do solo pela cana-de-açúcar e pastagem.

O estado de Alagoas possui uma larga faixa costeira de aproximadamente 230Km ao longo do Oceano Atlântico. Seu relevo é caracterizado como planície litorânea, planalto na

região norte do Estado e depressão no centro. Cerca de 61% do território alagoano se encontra abaixo de 200m de altitude e 86% abaixo de 300m. Apenas 1% do território apresenta-se acima de 600m.

O clima do Estado, segundo Köpper, está dividido em:

AS': clima tropical quente e úmido, com chuvas de outono-inverno para o litoral, zona da mata e parte do agreste;

BShs': clima tropical quente e seco, com chuvas de outono-inverno, esta região ocupa cerca de 1/3 do Estado, estendendo-se pelo sertão em quase sua totalidade e parte do oeste do agreste;

3.1.2. Dados Utilizados

Para a interpolação espacial e temporal da precipitação no estado de Alagoas foram utilizados dados obtidos junto ao banco de dados da Agência Nacional de Águas (ANA), os quais estão disponíveis no site da HIDROWEB (<http://hidroweb.ana.gov.br>). Os dados estão disponíveis no formato "Access ou bloco de notas", com registros médios diários e mensais de precipitação, bem como outras informações quanto às próprias estações.

Para a interpolação espacial foram selecionadas 63 estações pluviométricas localizadas no estado de Alagoas (Figura 6), e 182 estações localizadas no Estado de Pernambuco (Figura 7). Os dados então compreendidos entre os anos de 1965 a 1980, com período hidrológico comum entre as mesmas. Essas estações foram escolhidas por não apresentarem falhas em seus registros de dados e estarem espacialmente bem distribuídas (anexo).

Das estações localizadas em Alagoas foram selecionadas 5 estações para a estimação espacial da precipitação com redes neurais e com técnicas geoestatísticas. As estações foram classificadas em A, B, C, D e E, A informação geográfica das estações e outras informações relevantes são apresentadas na Tabela 2. A localização espacial das estações pode ser vista na Figura 6.




Figura 6: Distribuição espacial das estações no Estado de Alagoas




Figura 7: Distribuição espacial das estações no Estado de Pernambuco

TABELA 2: Informações das estações utilizadas para a interpolação espacial

Estações	Nome das Estações	Latitude (°)	Longitude (°)	Altitude (m)	Precipitação maio (mm)	Precipitação novembro (mm)
A	Limoeiro de Anadia	-9.75	-36.5	150	168.6	18.79
B	Mar Vermelho	-9.45	-36.38	620	204.85	18.89
C	Sebastião Ferreira	-9.8	-36.06	0	104.05	3.92
D	Batalha	-9.66	-37.13	120	104.04	15.72
E	Colônia Pindorama	-10.11	-36.4	110	264.55	35.76

A utilização de técnicas geoestatísticas possibilitou determinar a região de dependência espacial da precipitação para o estado de Alagoas, a qual será utilizada em um dos cenários propostos com a utilização de redes neurais para a estimação da precipitação para as estações A, B, C, D e E, através da análise variográfica. O método geoestatístico de interpolação espacial “krigagem ordinária” propiciou compreender como se dá a distribuição espacial da precipitação para os meses de maio e novembro, meses de máxima e mínima distribuição da precipitação no estado, respectivamente. Para a estimativa dos dados de precipitação com a técnica de krigagem foram utilizados dois cenários: um com as 63 estações disponíveis para Alagoas, e outro com 58 estações, sem as estações A, B, C, D e E, onde será observada a eficácia da metodologia para a interpolação de dados pontuais para essas estações.

Foram utilizados para se obter a região de dependência variogramas isotrópicos do tipo esférico, exponencial e gaussiano, ambos com patamar. A região de dependência é observada através da análise de um dos parâmetros variográficos, o “*Alcance (a)*”, o qual define a região onde a precipitações das estações vizinhas, de uma estação base, podem ser utilizadas para estimar valores de precipitação dessa estação.

Através da análise variográfica definiu-se a região de dependência espacial para os meses de maio e novembro de 72 e 80Km, respectivamente. No entanto, optou-se em determinar uma distância “padrão” para todos os meses em estudo de 70Km. Esta distância foi adotada para facilitar o processo de seleção das estações dentro desta área. Um exemplo desta região de dependência adotada para a estação “A” *Limoeiro de Anadia-AL*, no centro do raio, pode ser observada na Figura 8, onde todas as estações dentro deste raio podem ser utilizadas para a interpolação da precipitação nesta estação.




Figura 8: Região de dependência espacial da estação de Limueiro de Anadia

Para a interpolação temporal da precipitação foram selecionados dados diários de precipitação de cinco estações pluviométricas e uma estação fluviométrica, ambas localizadas na Bacia do Rio Mundaú, localizada entre os estados de Alagoas e Pernambuco, correspondentes ao período de 1993 a 2002. Destas estações apenas três com dados de precipitação e uma com vazão foram utilizadas. A informação geográfica das estações e outras informações relevantes são apresentadas na Tabela 3. A estação Fazenda Boa Fortuna está localizada no município de Rio Largo, e dispõem de dados de precipitação e de vazão. As demais estações recebem o nome do município de sua localização. A localização das estações e sua distribuição espacial podem ser observadas na Figura 9.

TABELA 3: Informações das estações utilizadas para a interpolação temporal

Código	Nome das estações	Latitude (°)	Longitude (°)	Altitude (m)
3887092	São José da Laje	09° 01'	36° 03'	250
3887392	União dos Palmares	09° 10'	36° 03'	155
3887358	Santana do Mundaú	09° 10'	36° 13'	221
3888615	Murici	09° 19'	35° 56'	82
3888936	Fazenda Boa Fortuna	09° 29'	35° 50'	62




Figura 9: Localização espacial das estações na bacia do Rio Mundaú

3.1.3. Interpolação da Precipitação

Para a interpolação foram testadas redes neurais dos tipos MLP (Multilayer Perceptron), com a utilização dos algoritmos de treinamento Levenverg-Marquardt e a Regularização Automatizada “*Trainlm e Trainbr*”, juntamente com as funções de transferências de ativação “*sigmóide, linear, e tangente hiperbólica*” (Figura 10), ambas disponíveis em ambiente *MATLAB*® 7.0. Estes algoritmos foram utilizados por apresentar bons resultados e não necessitar de uma grande demanda computacional.




Figura 10: Principais funções de transferência; a) sigmóide (logsig), b) tangente hiperbólica (tansig) e c) linear (purelin)

Para a interpolação foram adotados alguns cenários de entrada com diferentes configurações para o processo de treinamento das redes. Para a interpolação espacial os cenários adotados tiveram como variável de entrada: latitude, longitude, e/ou altitudes e/ou precipitação das estações dentro da região de dependência espacial, tendo como saída a tentativa de estimar a precipitação das estações A, B, C, D e E, Tabela 4.

TABELA 4: Cenários de utilizados para a interpolação espacial da precipitação

Cenários	Nº de estações de entrada	Entrada	Saída
1	63	Latitude e Longitude	Precipitação
2	63	Latitude, Longitude e Altitude	Precipitação
3	63	Latitude e Longitude e precipitação das estações dentro da área de dependência espacial	Precipitação
4	63	Latitude, Longitude, Altitude e precipitação das estações dentro da área de dependência espacial	Precipitação
5	245	Latitude, Longitude	Precipitação

Os cenários 1 ao 4 utilizaram as estações localizadas no estado de Alagoas, o cenário-1 teve como estrada para o treinamento das redes neurais as respectivas latitudes e longitudes das estações de Alagoas, para se estimar a precipitação. O cenário-2 utilizou como entrada a latitude, a longitude e a altitude das estações, tendo como saída a precipitação. O cenário-3 teve como entrada latitude, longitude e as precipitações das estações dentro da região de dependência espacial. O cenário-4 utilizou as mesmas entradas do cenário anterior mais os dados de altitudes. O cenário-5, além das estações localizadas no estado de Alagoas, tinha como entrada as estações localizadas no estado de Pernambuco. Sendo que para este cenário a rede utiliza como entrada apenas dados de latitude e longitude.

Para a interpolação temporal da precipitação, os cenários adotados levam em consideração a influência dos dias anteriores com precipitação, podendo ser definido, por esse método, quantos dias anteriores devem ser levados em consideração na tentativa de se preencher um dia em que não se disponha de registro de precipitação. Os cenários adotados estão disponíveis na Tabela 5. Posteriormente, esses dados foram utilizados para a interpolação temporal da precipitação na Fazenda Boa Fortuna.

A metodologia proposta consiste em admitir que o último valor de precipitação da estação Fazenda Boa Fortuna 1,30mm não foi medido, apresentando falha referente a erros instrumentais ou humanos. Na tentativa de se estimar esse dado “em falta”, foram estabelecidos alguns cenários, que através do histórico de precipitação existente na estação Boa Fortuna e em outras estações próximas tentaram preencher essa falha. Também foram utilizados dados passados (voltas) de precipitações e vazões, este último para apenas um cenário, na tentativa de se verificar quantos dias anteriores irão influenciar na precipitação do dia presente, uma vez que para muitas localidades existem vários dias sem precipitação, precipitação igual a zero.

Para todos os cenários foram estabelecidos 0, 5, 10, 15, 20 como dias passados com precipitação para estimativa temporal da precipitação. O cenário-1 tem como entrada a precipitação da Fazenda Boa Fortuna, para se estimar o dado em falta. Para o cenário-2 foram utilizados como entrada a precipitação da Fazenda Boa Fortuna e da estação mais a jusante Murici. O cenário-3 além dessas estações utilizou a precipitação de mais uma estação Santana do Mundaú. O cenário-4 talvez o mais atípicos de todos utilizou como entrada a precipitação e a vazão da estação Fazenda Boa Fortuna.

TABELA 5: Cenários de utilizados para a interpolação temporal da precipitação

Cenários	Dias anteriores	Entrada	Saída
1	0	Precipitação	Precipitação
	5	Precipitação	Precipitação
	10	Precipitação	Precipitação
	15	Precipitação	Precipitação
	20	Precipitação	Precipitação
2	0	Precipitação e Precipitação	Precipitação
	5	Precipitação e Precipitação	Precipitação
	10	Precipitação e Precipitação	Precipitação
	15	Precipitação e Precipitação	Precipitação
	20	Precipitação e Precipitação	Precipitação
3	0	Precipitação, Precipitação e Precipitação	Precipitação
	5	Precipitação, Precipitação e Precipitação	Precipitação
	10	Precipitação, Precipitação e Precipitação	Precipitação
	15	Precipitação, Precipitação e Precipitação	Precipitação
	20	Precipitação, Precipitação e Precipitação	Precipitação
4	0	Precipitação e Vazão	Precipitação
	5	Precipitação e Vazão	Precipitação
	10	Precipitação e Vazão	Precipitação
	15	Precipitação e Vazão	Precipitação
	20	Precipitação e Vazão	Precipitação

4. RESULTADOS E DISCUSSÕES

4.1. Distribuição mensal da Precipitação no Estado de Alagoas

A distribuição mensal da precipitação no estado de Alagoas é caracterizada por uma forte variabilidade. Apresentando dois períodos distintos na distribuição espacial da precipitação, um de máxima e outro de mínima, e alguns meses de transição. O período chuvoso está compreendido entre os meses de abril a julho, enquanto o período seco entre os meses de outubro a janeiro. Os meses de transição do período seco para o período chuvoso estão compreendidos entre os meses de fevereiro e março, enquanto os meses de agosto e setembro são os meses de transição do período chuvoso para o período seco, Figura 11.




Figura 11: Média mensal da precipitação no Estado de Alagoas de 1965 a 1980

Pode-se observar que após o mês de março, mês de transição do período seco para o chuvoso, são observadas precipitações sempre acima dos 140mm. Grande parte desses índices pluviométricos é devido à influência da umidade oriunda do oceano. Após o mês de julho a precipitação apresenta uma redução significativa em seus totais pluviométricos, onde para o mês de outubro esse valor é de aproximadamente 50mm, tendo início o período seco. Sá (2006) encontrou distribuição semelhante da precipitação para o estado de Alagoas.

Deste modo, optou-se em utilizar para os estudos de estimativa espacial da precipitação para Alagoas, os meses de máxima e mínima distribuição da precipitação para o

período seco e o chuvoso. Dessa forma, foram selecionados dois meses para a interpolação espacial e estudo da variabilidade espacial da precipitação para Alagoas: maio e novembro.

Na distribuição da precipitação mensal em Alagoas, o mês de maio demonstra os maiores valores de precipitação, com média de 200,56mm e mediana de 201,51mm; enquanto que o mês de novembro apresenta o menor índice pluviométrico, com média de 26,18mm e mediana de 23,53mm. O total anual apresenta valores médios de 1.234,27mm; com mediana de 1.238,01mm, Tabela 6.

TABELA 6: Resumo estatístico das precipitações pluviométricas para o estado de Alagoas, durante o período de 1965/1980 (DP = Desvio Padrão; CV = Coeficiente de Variação; PRP Mín = Precipitação Mínima; PRP Máx = Precipitação Máxima)

Meses	Média (mm)	Mediana (mm)	DP (%)	CV (%)	PRP Mín (mm)	PRP Máx (mm)
Jan	50,55	43,26	25,94	51,31	4,59	153,60
Fev	70,46	64,33	29,62	42,03	10,96	201,58
Mar	93,99	89,77	43,07	45,82	5,84	236,18
Abr	146,39	138,91	63,29	43,24	34,71	290,64
Mai	200,56	201,51	84,03	41,90	54,16	423,97
Jun	196,57	196,66	89,51	45,54	61,17	458,67
Jul	188,86	188,98	88,46	46,84	50,53	478,54
Ago	97,32	95,27	54,44	55,93	15,99	286,93
Set	82,85	79,81	47,88	57,78	8,84	247,00
Out	47,39	44,48	24,88	52,50	11,09	110,69
Nov	26,18	23,53	14,6	55,78	3,92	87,53
Dez	33,15	30,86	15,57	46,98	3,16	93,07
Σ Anual	1.234,27	1.238,01	517,73	41,95	293,16	2290,55

Diante disso, foi observado que os valores médios e medianos não possuem grande amplitude entre si, mostrando que a série não apresenta índices extremos, podendo-se então, trabalhar com os valores médios para o estudo dos métodos de interpolação. Bernardo (2002), estudando costa leste do NEB, onde está compreendido o estado de Alagoas, encontrou amplitudes máximas de 100 a 240mm, para os meses de abril e maio, estando condizentes com os índices encontrados neste estudo, não demonstrando erros significativos de medição.

O mês com o menor índice pluviométrico é o de novembro, com média de 26,18mm; e precipitação mínima no mês de dezembro, com apenas 3,16mm. Já, no período chuvoso, o

mês que apresentou o maior registro de precipitação foi o mês de julho, com 478,54mm, apesar de o mês mais chuvoso para o período estudado, ter sido maio, com uma média de 200,56mm.

O mês que mais oscilou em torno da média foi o mês de junho, com um desvio padrão de 89,51% e o que menos oscilou foi novembro, com um percentual de 14,6%. Tais oscilações no período chuvoso são comuns, devido ao regime dinâmico da precipitação estar associado a diversos fatores, destacando trimestres ou quadrimestres chuvosos, como atuação de alguns sistemas sinóticos, sendo a ZCAS, um dos principais sistemas atuantes no leste do nordeste (ENE) durante esse período, quando alimentadas pelas perturbações ondulatórias dos Alísios (Molion e Bernardo, 2002). Cohen et al. (1989) descreveram as perturbações costeiras que atingem a Amazônia e o NEB, associadas à brisa marítima, e sugeriram que essas perturbações sejam o fator principal para o máximo pluviométrico junto à costa, em maio-junho.

Os meses mais secos apresentaram um subtotal na precipitação média, de 310,58mm; correspondendo a 25,16% do total anual, enquanto que os meses mais chuvosos apresentaram um subtotal de 923,69mm; que corresponde a 74,84% do total anual de precipitação na região.

Apesar dessa diferença de 49,68% entre os subtotais do período seco e do período chuvoso, o coeficiente de variação (CV) para todos os meses oscilou mensalmente entre 41,9 e 57,78%, mostrando assim, que a margem de oscilação entre os meses, em escala sazonal, não foi distante. No cálculo do CV em escala espacial, os valores oscilaram entre um mínimo de 34,56% e um máximo de 91,99% para o estado de Alagoas. Isso mostra que, no Estado ocorre uma maior variação da precipitação espacialmente do que sazonalmente, podendo ser devido a fatores topográficos e climáticos.

Avalos (2003) encontrou coeficientes de variação da precipitação para a região de Galícia/Espanha, flutuando entre 20% e 146%. Segundo o autor, isso põe em evidência uma heterogeneidade espacial deste parâmetro no clima desta região, que em geral apresentou uma maior variabilidade durante a estação seca.

4.2. Dependência Espacial da Precipitação

O ajuste dos variogramas testados para se determinar a região de dependência da precipitação para este estudo pode ser observada através de seus parâmetros (Patamar ($C + C_0$) - ponto o qual a função se estabiliza no variograma; Efeito Pepita (C_0) - ponto onde o variograma toca o eixo das ordenadas e Alcance (a) - zona de dependência espacial), permitem verificar se ocorre dependência espacial, ou não. Havendo dependência espacial, é possível se estimar valores da propriedade em estudo para os locais não amostrados dentro do campo de análise através da técnica de Krigagem.

Entre os variogramas testados (esférico, exponencial e gaussiano) o modelo esférico obteve melhor ajuste para o mês de maio. Esse modelo descreve uma curva mais suave de sua função apresentado resultados satisfatório para meses com índices pluviométricos elevados como nos trabalhos de Kuhn et al. (2007) e Garrigues et al. (2006). Os parâmetros variográficos decorrente da utilização do modelo esférico pode ser observados na Tabela 7. O efeito pepita encontrado mostra valor muito baixo em relação ao patamar, demonstrando que na série utilizada de dados não há erros significativos de medições. O alcance encontrado para o mês de maio determina uma região de dependência espacial de 72Km, distância a partir da qual as amostras tornam-se independentes, não existindo mais a dependência espacial entre as amostras.

TABELA 7: Parâmetros dos modelos teóricos ajustados ao variograma experimental para a precipitação média em Alagoas. (C_0 =Efeito Pepita, $C+C_0$ =Patamar, a =Alcance)

Meses	Modelo de variograma	C_0	$C + C_0$	A (Km)
Maio	Esférico	1.2881e-010	1.2769	72
Novembro	Exponencial	0.1105	2.4472	80

Para o mês de novembro o modelo exponencial de variograma demonstrou melhor ajuste aos dados de precipitação o referido mês. Esse modelo atinge o patamar assintoticamente, enquanto que o modelo esférico o atinge no valor do alcance. Para este tipo de variograma a literatura recomenda se utilizar apenas 95% do valor do patamar, como comenta Shao et al. (2007). O efeito pepita deste modelo, semelhante o mês de maio, demonstrou resultado satisfatório, mostrando a não existência de falhas que pudessem comprometer a utilização desses dados.

A região de dependência espacial obtida por esses modelos determina um alcance de 80Km de raio. Como a literatura não recomenda a utilização de 100% desse alcance, a região de dependência espacial para esse mês será cerca de 76Km. Resultado muito próximo do encontrado para o mês de maio. É bom ressaltar que, em vários estudos que envolvem atributos naturais, os modelos esférico e exponencial são os que melhor expressam os resultados, destacando-se entre esses atributos a precipitação pluviométrica, como o estudo de Lee et al. (2006).

Os modelos de variogramas apresentaram resultado satisfatório no ajuste de seus parâmetros. Cambardella et al. (1994) consideram que a dependência espacial é elevada quando o efeito pepita é inferior a 25% do valor do patamar. Isso demonstra no presente estudo pequenos percentuais nos modelos ajustados, representando forte dependência espacial entre os dados de precipitação.

O alcance encontrado pelos modelos de variogramas variaram entre 72 e 76Km, para maio e novembro respectivamente. Essa região mostra a distância dentro da qual as amostras apresentam-se correlacionadas espacialmente, indicando a distância a partir da qual as amostras passam a não possuir correlação espacial e a relação entre elas torna-se aleatória.

Mello et al. (2003) trabalhando com dados de precipitação máxima, encontraram alcance próximos uns dos outros, na faixa de 90 a 100km para o estado São Paulo. Wanderley et al. (2009a) encontraram alcance de dados de precipitação variaram entre 82 e 90Km para o estado de Alagoas. Essa distância expressa a área máxima de influência da variável em estudo, após essa distância, as amostras tornam-se independente, não sendo mais caracterizada a dependência espacial.

Haberlandt (2007) estudando dados de precipitação encontrou alcance que variaram de 80 a 140Km. O efeito pepita encontrado variaram de 0,10 a 0,40 e o patamar de 0,60 a 0,80. Teegavarapu (2007) encontrou efeito pepita de 0,10 a 0,20 e patamar de 0,10 a 1,20 para o estado de Kentucky, EUA. Estes estudos validam a qualidade dos resultados encontrados.

Desta forma, neste estudo optou-se em determinar uma distância padrão para todos os meses em estudo de 70Km de raio. Desta forma, toda amostra cuja distância for menor ou igual a essa amplitude fornece informações sobre esse ponto, podendo ser utilizada para a estimação da precipitação em uma estação base (no centro da região de dependência espacial). As demais estações que não estão dentro desta região de dependência espacial, não serão usadas.

A distância de 70Km foi adotada para facilitar e agilizar o processo de agrupamento dos dados em planilha. Uma vez que, esta distância está dentro do raio mínimo de

dependência obtido pelo mês de maio de 72Km. A Figura 12 mostra como exemplo, a região de dependência espacial para a estação de Limueiro de Anadia, no centro do círculo, localizada no município de mesmo nome, com Latitude $-9^{\circ}75'$, Longitude $-36^{\circ}5'$ e altitude de 150m. Onde as estações localizadas dentro deste raio, foram utilizadas para a interpolação da precipitação nesta estação. O processo foi repetido para todas as demais estações.




Figura 12: Região de dependência espacial para a estação de Limueiro de Anadia

4.3. Análise da Estimativa Espacial da Precipitação para o Mês de Maio

A precipitação média para o mês de maio no estado de Alagoas apresenta grande variabilidade espacial. A Figura 13 mostra a distribuição da precipitação para o mês de maio, na qual pode ser observada que os maiores valores da precipitação estão localizados nas regiões da grande Maceió e litoral norte, apresentando valores de 250 a 320mm. A pluviometria sofreu uma significativa redução ao adentrar no continente com uma variação, que pode até chegar a 200mm, no sertão e sertão do São Francisco. A região do agreste torne-se o divisor de águas, com índices de precipitação variando de 150 a 250mm. Após essa região, os totais pluviométricos são inferiores a 100mm em boa parte do sertão e sertão do São Francisco.




Figura 13: Interpolação espacial da precipitação no estado de Alagoas para o mês de maio com 63 estações

Amorim et al. (2008) utilizaram os métodos interpoladores Inversos da Distância e função Spline e Wanderley et al. (2009b) o método de Krigagem para estudarem a variabilidade espacial da precipitação para Alagoas encontraram totais pluviométricos variando de 8 a 332mm e 10 a 335mm, respectivamente. Bernardo (2002) mostrou que os

grandes totais de precipitação que ocorreram, durante o inverno, com picos no mês de maio, estão associados à penetração de massas de ar de origem polar.

De acordo com Molion de Bernardo (2002), o mês de maio está inserido na quadra chuvosa do nordeste, que compreende os meses de abril, maio, junho e julho, sendo o período mais úmido, onde em anos chuvosos, cerca de 60 a 70% das chuvas que caem são devidas ao deslocamento da Zona de Convergência do Atlântico Sul (ZCAS) alimentada pela corrente de umidade dos Alísios, intensificando os sistemas de brisa (em que sua circulação pode chegar a 300km adentro do continente), formando células convectivas, que penetram mais ao continente. Os meses que estão inseridos na quadra chuvosa do estado de Alagoas mostram grande potencialidade para o cultivo agrícola.

Os resultados obtidos na estimação da precipitação para as estações A, B, C, D e E, para o mês de maio no estado de Alagoas, não mostraram uma variação significativa entre os totais observados e os estimados pelo método de krigagem ordinária. A exceção estar nos resultados obtidos para a estação C e E, que devido à grande variabilidade da precipitação na região, mostrou uma diferença maior entre os dados observados e estimados, Figura 14.




Figura 14: Interpolação espacial da precipitação no estado de Alagoas para o mês de maio com 58 estações

4.3.1. Análise da Estimativa Espacial da Precipitação para o Mês de Novembro

A distribuição espacial da precipitação para o mês de novembro em Alagoas mostra que o estado, em quase toda sua totalidade, apresenta índice pluviométrico que oscilam em torno de 10 a 40mm, Figura 15. Esses totais abrangem uma área que incluem o Sertão, Sertão do São Francisco, Agreste e parte do Litoral e Zona da Mata. Os maiores índices de precipitação, para este mês, são observados no nordeste do estado, chegando a valores acima de 70mm.




Figura 15: Interpolação espacial da precipitação no estado de Alagoas para o mês de novembro com 63 estações

O mês de novembro está compreendido entre os meses do período seco que se estendem entre os meses de outubro, novembro, dezembro e janeiro. Esses meses são marcados por apresentar déficit de precipitação, o que pode ocasionar perdas agrárias expressivas para o estado, prejudicando no plantio da cana-de-açúcar. .

Amorim et al. (2008) utilizaram os métodos interpoladores Inversos da Distância e função Spline e Wanderley et al. (2009b) o método de Krigagem para estudarem a variabilidade espacial da precipitação para Alagoas encontraram totais pluviométricos

variando para o mês de novembro de 8 a 116mm e 7 a 76mm. A configuração da distribuição da precipitação pode estar caracterizada pela atuação de sistemas de brisa e de eventuais sistemas frontais, além da hipótese da presença de vórtices ciclônicos associados a sistemas frontais.

No estudo de Comrie e Broyles (2002) os autores comentaram que, em geral, a variabilidade da precipitação no verão e inverno está ligada a trocas de calor em direções zonais e meridionais, e movimentos no sentido leste-oeste do anticiclone, ou cavado, sobre a região. Os autores observaram também que processos convectivos localizados conduzem as anomalias no verão, sendo espacialmente mais complexas que no inverno, quando há presença de sistemas sinóticos de grande escala, como os sistemas frontais, que causam precipitação.

Devida a variabilidade da precipitação ser menos proeminente no mês de novembro do que o mês de maio, a estimativa da precipitação para as estações A, B, C, D e E foi satisfatória, Figura 16. Sendo observado a maior diferença entre o valor observado e o estimado na estação E, de aproximadamente 7mm.




Figura 16: Interpolação espacial da precipitação no estado de Alagoas para o mês de novembro com 58 estações

4.4. Interpolação Espacial da Precipitação com Redes Neurais Artificiais

4.4.1. Interpolação Espacial da Precipitação para o Cenário-1

A estimativa de dados de precipitação para o cenário-1 consiste na utilização da latitude e da longitude, das estações de medição utilizadas para a interpolação localizadas no estado de Alagoas, como dados de entrada. A saída das redes neurais é referente à precipitação das estações A, B, C, D e E, na tentativa de ser estimar os valores observados de precipitação das respectivas estações.

O coeficiente de correlação obtido no treinamento das redes neurais para a interpolação da precipitação, para os meses de maio e novembro foram de $R=0,902$ e $R=0,825$ respectivamente, Figuras 17 e 18. Segundo Ferreira (2005), os coeficientes de correlação baixos e pouco significativos poderão influenciar no ajuste estatístico dos modelos, reduzindo sua dependência espacial.




Figura 17: Coeficiente de correlação para o mês de maio obtido pelo cenário-1




Figura 18: Coeficiente de correlação para o mês de novembro obtido pelo cenário-1

As figuras mostram distribuição das estações utilizadas para o processo de validação, teste e treinamento das redes, bem como o melhor ajuste linear da reta. As equações demonstradas nas figuras $A=(0.82)T + (34.70)$ e $A=(0.68)T + (8.63)$ respectivamente para os meses de maio e novembro, mostram um melhor ajuste para o mês de maio do que o mês de novembro, com coeficiente de correlação mais próximo de 1. Pellegatti (2007) ressaltou que no contexto da precipitação, a latitude e a altitude proporcionaram coeficientes elevados e significativos, mostrando que é possível modelar adequadamente os totais precipitados em função das coordenadas geográficas e altitude.

Os dados interpolados de precipitação para as estações A, B, C, D, e E para os meses em estudo podem ser observados na Tabela 8 para o mês de maio e Tabela 9 para o mês de novembro. As tabelas mostram os valores observados e estimados de precipitação para as estações A, B, C, D e E, e o Erro Absoluto Médio (EAM) e o Erro Percentual Médio Absoluto (EPMA). O EAM mostra a diferença existente entre os dados estimados e observados na estação, já o EPMA exprime essa diferença em porcentagem.

TABELA 8: Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-1, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Maio		EAM (mm)	EPMA (%)
	Precipitação (mm)			
	Observada	Estimada		
A	168,60	191,36	22,76	13,49
B	204,85	143,00	61,85	30,19
C	104,05	103,49	0,56	0,53
D	104,04	119,80	15,76	15,14
E	264,55	259,72	4,83	1,82

A interpolação realizada para o mês de maio com o cenário-1 demonstrou menores valores para a estação C com EAM=0,56mm entre o valor observado na estação e estimado pela rede neural e EPMA=0,53%. Os valores observados na estação B, com EAM=61,85 e EPMA=30,19, mostram que para a estação B apesar de um erro absoluto médio de 61,85mm, a metodologia utilizada foi capaz de estimar 69,81% da precipitação observada nessa estação.

TABELA 9: Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-1, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Novembro		EAM (mm)	EPMA (%)
	Precipitação (mm)			
	Observada	Estimada		
A	18,79	18,72	0,07	0,37
B	18,89	13,1	5,79	30,65
C	3,92	3,48	0,44	11,22
D	15,72	15,49	0,23	1,46
E	35,76	32,34	3,42	9,56

O cenário-1 para o mês de novembro teve como resultado mais expressivo os valores estimado para a estação A. Entre o valor observado 18,79 e o estimado 18,72 conseguiu um EAM=0,07mm e um EPMA=0,37%. Feng e Hong (2008) em simulação hidrológica utilizando redes neurais para a interpolação de dados de precipitação na China, encontrou erro médio na estimação de 0.44% e 0.58%.

Os resultados mostrados na Tabela X denotam que a interpolação realizada para o mês de novembro obteve resultados mais expressivos do que os obtidos para o mês de maio. Esta evidencia pode está relacionada ao fato de que o mês de novembro apresenta uma menor variabilidade espacial da precipitação. Segundo Chiang et al. (2007) a variabilidade espacial pode ser a causadora de grande incerteza.

4.4.2. Interpolação Espacial da Precipitação para o Cenário-2

Para o cenário-2, além dos valores da latitude e longitude foi utilizados também as respectivas altitude das estações de medições. Uma vez que, a altitude, a latitude e a longitude influenciam nas condições climáticas de uma região (MELLO e SILVA, 2009). A caracterização das chuvas em função da altitude surge como uma alternativa para minimizar erros na estimativa, onde qualquer melhoria na estimativa de precipitação pode ser considerada significativa, uma vez que, a precipitação é um insumo fundamental que governa a resposta dos sistemas hidrológicos.

Para o período de validação, teste e treinamento podem ser observados nos resultados obtidos neste cenário, que a utilização dos dados de altitude, além dos de latitude e longitude, proporcionaram uma melhora significativo no treinamento da rede, em comparação ao cenário anterior, com coeficiente de correlação de $R=0,914$ e $R=0,912$, para maio e novembro, Figuras 19 e 20.




Figura 19: Coeficiente de correlação para o mês de maio obtido pelo cenário-2




Figura 20: Coeficiente de correlação para o mês de novembro obtido pelo cenário-2

A utilização de dados de altitude das estações pode nos dá informações adjacentes da influência da topografia local na distribuição da precipitação, onde se pode modelar valores mais expressivos de precipitação do que sem o uso desta variável de entrada.

Resultado observado também por Sá (2006), que na tentativa de estimar dados de precipitação utilizando latitude e longitude, constatou uma melhora significativa nos resultados quando além da latitude e da longitude utilizou também dados de altitude. Fenille e Cardim (2007) analisaram a variabilidade espacial da altitude e das precipitações pluviométricas e constaram que essas variáveis apresentam forte dependência espacial e estão diretamente correlacionadas.

Os resultados obtidos da estimativa de dados de precipitação para mês de maio utilizando-se do cenário-2 são mostrados na Tabela 10. Para a estação B, que demonstrou melhor resultado para o mês de maio, o valor estimados mostra um EAM=4,38mm e um EPMA=2,13% entre o valor observado e estimado.

TABELA 10: Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-2, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Maio			
	Precipitação (mm)		EAM (mm)	EPMA (%)
	Observada	Estimada		
A	168,6	208,19	39,59	23,48
B	204,85	209,23	4,38	2,13
C	104,05	72,30	31,75	30,51
D	104,04	100,90	3,14	3,01
E	264,55	214,32	50,23	18,98

Observando-se a Tabela 10 nota-se que a estação D mostrar um EAM menor que o observado na estação B. Esse fato não pode ser confundido pelo leitor levando-o a acreditar que o valor estimado para a estação D é melhor do que o estimado para a estação B. A estação D obteve EPMA=3,01% que em comparação ao demonstrado na estação B de EPMA=2,13%, percebe-se que o EPMA maior nesta estação D do que na B. Onde para a estação D eu tenho um menor valor entre o observado e o estimado, que corresponde a uma diferença maior em porcentagem em comparação com a estação B.

Para o mês de novembro a interpolação da precipitação que demonstrou melhor resultado foi obtido para a estação C com EAM=0,04 e EPMA=1,02. Para este cenário os valores do EPMA não variaram muito entre os dados observados e estimados pela as redes neurais. O EAM máximo encontrado para o cenário-2 foi de 2,50mm para a estação A, este cenário demonstrou também EPMA variando de 0,04 a 12,08mm, evidenciando o menor EPMA dos máximos observados para os outros cenários, Tabela 11.

TABELA 11: Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-2, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Novembro			
	Precipitação (mm)		EAM (mm)	EPMA (%)
	Observada	Estimada		
A	18,79	21,06	2,27	12,08
B	18,89	19,49	0,60	3,71
C	3,92	3,88	0,04	1,02
D	15,72	16,41	0,69	4,38
E	35,76	38,26	2,50	6,99

4.4.3. Interpolação espacial da precipitação para o cenário-3

A interpolação realizada no cenário-3 consiste em utilizar a precipitação observada em estação próximas, a estação base, juntamente com a latitude e a longitude das estações. Para este cenário foram utilizadas a precipitação de 6 estações próximas a estação base, dentre do raio de dependência espacial obtido pela análise variográfica.

O número de estações próximas que são utilizadas para se estimar a precipitação na estação base pode ser significativa devido à variabilidade espacial da precipitação, onde estações não muito próximas aumentar o erro de estimativa dos dados. A utilização da precipitação das estações próximas a estação base proporcionaram um melhor treinamento da rede com coeficiente de correlação de $R=0,948$ e $R=0,91$ para o mês de novembro e maio, Figura 21 e 22. Teegavarapu e Chandramouli (2005) em seu estudo encontraram coeficiente de correlação de $R=0,751$ utilizando 6 e 12 estações na tentativa de estimar dados de precipitação.




Figura 21: Coeficiente de correlação para o mês de maio obtido pelo cenário-3




Figura 22: Coeficiente de correlação para o mês de novembro obtido pelo cenário-3

Teegavarapu et al. (2009) constataram que houve uma queda significativa do erro absoluto quando o número de estações utilizadas, para estimar a precipitação, no período de treinamento e testes passou de 14 para 6 estações. Os autores mostraram também que os coeficientes de correlação, entre as estações, demonstram variação de 0,75 e 0,82 para 0,95 e 0,97 para treinamento e teste, respectivamente, quando comparado com uma estação não tão próxima, com uma mais próxima da estação base.

A estimativa dos dados de precipitação também foi considerada satisfatória juntamente com os coeficientes de correlação, EAM e EPMA obtidos para os meses de maio e novembro. Alguns resultados mostraram uma pequena variação entre os dados observados nas estações de medição e os estimados, obtendo-se 99,96% de acerto na estimativa da precipitação do mês de maio para a estação C, Tabela 12.

Para a estação C o valor de precipitação medido na estação foi de 104,05mm e o estimado de 104,01mm. Dentre todos os cenários utilizados para a interpolação da precipitação, o cenário-3 para a estação C obteve o melhor resultado para o mês de maio, com EAM=0,04mm e EPMA=0,03%.

TABELA 12: Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-3, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Maio		EAM (mm)	EPMA (%)
	Precipitação (mm) Observada	Estimada		
A	168,6	118,2	50,40	29,89
B	204,85	195,16	9,69	4,73
C	104,05	104,01	0,04	0,03
D	104,04	89,74	14,30	13,74
E	264,55	185,1	79,45	30,03

Para o mês de novembro a maior amplitude entre o valor medido na estação e o estimado através das redes neurais foi para a estação A com EAM=6,09mm, Tabela 13. A estação C mostra um EAM menor que 1mm entre a precipitação observada e estimada na estação, só que o EPMA dessa estação é maior que 25% do índice observado de precipitação. Isso é decorrente da quantidade de precipitação medida nessa estação ter um valor inferior a 4mm, onde qualquer variação, por pequena que ela seja, dá um EPMA grande.

TABELA 13: Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-3, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Novembro		EAM (mm)	EPMA (%)
	Precipitação (mm) Observada	Estimada		
A	18,79	12,7	6,09	32,41
B	18,89	21,00	2,11	11,16
C	3,92	2,93	0,99	25,25
D	15,72	14,79	0,93	5,91
E	35,76	28,19	7,57	21,16

O resultado mais expressivo obtido para o cenário-3 para o mês de novembro foi estimado para a estação D. A precipitação observada nesta estação tem pouco mais de 15mm, é verdade que para todo mês de novembro a quantidade de chuva não alcança índices elevados.

O erro absoluto médio e o erro percentual médio absoluto mostrados na Tabela X para a estação D foi de 0,93mm e 5,91%. Esse valor não chega a ser um resultado tão expressivo como o conseguido para o mês de maio, pois para outros cenários apresentaram resultados melhores.

4.4.4. Interpolação Espacial da Precipitação para o Cenário-4

O cenário-4 não se diferencia muito do cenário anterior, sendo neste cenário além da latitude e da longitude, a altitude também foi usada para interpolação da precipitação juntamente com a precipitação das estações próximas, onde neste cenário foram utilizadas o mesmo numero que no cenário anterior, 6 estação.

O método de escolha das estações mais próximas foi o mesmo método geoestatístico adotado no cenário anterior. Em estudo semelhante, Teegavarapu e Chandramouli (2005) definiram através do método de Thiessen, utilizarem quatro estações mais próximas para a estimativa da precipitação na estação base, a qual foi definida no centro dos polígonos.

O método de interpolação de valores em uma estação com dados que apresentam falhas, pode ser preenchidos como uma combinação ponderada dos valores de todas as estações próximas. Deste modo, a estimativa apresenta dados significativos, se as correlações entre os pesos da estação base e de todas as outras estações forem mantidos constantes.

Um fator importante também que não se pode passar despercebido é as características dos dados espaciais, que podem proporcionam melhoria nos valores estimados pelos modelos. Se a distribuição da precipitação para uma região apresenta-se de forma homogênea a probabilidade dos dados estimados apresentarem essa mesma distribuição é maior.

A correlação obtida neste cenário fio muito próxima dos melhores valores obtidos neste estudo, $R=0,909$ e $R=0,937$ respectivamente para os meses de maio e novembro, Figuras 23 e 24. As equações de melhor ajuste mostradas nas figuras $A=(0,933)T + (13,1)$ e $A=(0,995)T + (0,871)$ são muito próximas do ideal, uma vez que para o melhor ajuste o valar que acompanha o termo T, tem que ter seu valor igual a 1 e o outro valor igual a 0 (zero).

A equação obtida no treinamento para o mês de novembro mostra um ajuste melhor do que a equação para o mês de maio, com o valor que multiplica o termo T estando mais próximo de 1, bem como o outro valor que mostra-se próximo de 0 (zero). Ambas as estimações foram consideradas satisfatórias, onde a precipitação estimada para esse cenário obteve índices muito próximos dos valores observados nas estações, mostrando erros pequenos.




Figura 23: Coeficiente de correlação para o mês de maio obtido pelo cenário-4




Figura 24: Coeficiente de correlação para o mês de novembro obtido pelo cenário-4

A precipitação estimada para as estações A, B, C, D e E para o mês de maio pode ser observada na Tabela 14. O melhor valor interpolado foi obtido para a estação B, com EAM=3,215 e EPMA=1,56mm. O cenário-4 apresentou EAM variando entre 3,21 e 44,87mm, este cenário é marcado por apresentar o menor valor para os valores máximos de EPMA=27,39.

TABELA 14: Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-4, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Maio		EAM (mm)	EPMA (%)
	Precipitação (mm) Observada	Precipitação (mm) Estimada		
A	168,6	213,47	44,87	26,61
B	204,85	208,06	3,21	1,56
C	104,05	75,55	28,50	27,39
D	104,04	87,38	16,66	16,01
E	264,55	243,01	21,54	8,14

Para o mês de novembro a melhor estimativa foi obtida para estação A com 18,79mm observado e 18,42mm estimado. Essa estação apresentou EAM=0,37mm e EPMA=1,96%. Para a estação C é observado o maior EPMA, correspondendo a 39,03%, esse valor é o maior EPMA encontrado na interpolação da precipitação para o mês de novembro entre todos os cenários testados, mas corresponde a um desvio de 1,53mm entre o valor observado e estimado, Tabela 15.

TABELA 15: Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-4, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Novembro		EAM (mm)	EPMA (%)
	Precipitação (mm) Observada	Precipitação (mm) Estimada		
A	18,79	18,42	0,37	1,96
B	18,89	21,01	2,12	11,22
C	3,92	5,45	1,53	39,03
D	15,72	13,47	2,25	14,31
E	35,76	30,70	5,06	14,14

4.4.5. Interpolação Espacial da Precipitação para o Cenário-5

O cenário-5 de interpolação da precipitação é semelhante ao cenário-1, tendo dados de latitude e longitude como entrada, só diferenciando-se do mesmo pelo número de estação que foram utilizadas. Nos demais cenários foram utilizados dados de 63 estações localizadas no estado de Alagoas. Neste cenário, além destas estações foram usadas mais 182 estações localizadas no estado de Pernambuco, em um total de 245.

O uso de longas séries de dados assegura a generalização temporal e espacial reduzindo o risco de excesso na construção de funções não-linear para avaliar a estrutura da correlação espacial das observações melhorando a precisão do método de estimativa. Deste modo, o aumentando o número de estação ou de dados, aumenta também a capacidade de aprendizagem da rede, existindo uma maior quantidade de dados para o período de validação, teste e treinamento.

A correlação obtida para este cenário foi de $R=0,904$ e $R=0,779$ respectivamente para maio e novembro, Figuras 25 e 26. As equações de melhor ajuste para os meses em estudo são: $A = (0,82)T + (18,7)$ e $A = (0,613)T + (9,81)$ respectivamente para maio e novembro.




Figura 25: Coeficiente de correlação para o mês de maio obtido pelo cenário-5




Figura 26: Coeficiente de correlação para o mês de novembro obtido pelo cenário-5

A precipitação interpolada para o mês de maio pode ser vistas na Tabela 16. Para a estação B o valor estimado difere 0,39% do valor registrado na estação para o mês de maio com EAM=0,80 e EPMA=0,39. Para a estação D o valor de precipitação estimado corresponde a 0,05%, com EAM=0,05 e EPMA=0,04.

TABELA 16: Precipitação observada e estimada para o mês de maio nas estações A, B, C, D e E para o cenário-5, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Maio		EAM (mm)	EPMA (%)
	Precipitação (mm)	Precipitação (mm)		
	Observada	Estimada		
A	168,6	117,20	51,40	30,48
B	204,85	205,65	0,80	0,39
C	104,05	101,25	2,80	2,69
D	104,04	104,09	0,05	0,04
E	264,55	183,80	80,75	30,52

Para o cenário-5 os valores de EAM=0,05 e EPMA=0,04 são muito próximos do melhor valor encontrado no estudo, com 104,04mm observados e 104,09mm estimados para o cenário-3. Marzano et al. (2006) estimaram dados com falhas de precipitação com redes neurais e encontraram EAM que variaram entre 4,4 a 4,9mm. Teegavarapu e Chandramouli

(2005) interpolando dados de precipitação utilizando seis estações encontraram AME=0,10 e EPMA=2,54, aumentando o número de estações para doze encontrou EAM=0,09 e EPMA=1,91.

Para o mês de novembro, resultados da estimativa da precipitação também foram satisfatórios, principalmente para a estação C, onde o valor estimado corresponde a 100% do valor observado na estação de medição com EAM=0 e EPMA=0, Tabela 17. A estação A também obteve resultados satisfatórios na interpolação, os valores estimados diferem 0,76mm do valor observado na estação e estimada pela a rede neural.

O EPMA dessa estação foi de 4,04%. A estação D foi outra que apresentou bom resultado com EAM=0,48mm de amplitude entre a precipitação observada e estimada na estação. Os demais valores de precipitação estimados para as outras estações não mostraram erros significativos.

TABELA 17: Precipitação observada e estimada para o mês de novembro nas estações A, B, C, D e E para o cenário-5, e seu respectivo Erro Absoluto Médio (EAM) e Erro Percentual Absoluto Médio

Estações	Mês de Novembro		EAM (mm)	EPMA (%)
	Precipitação (mm) Observada	Estimada		
A	18,79	19,55	0,76	4,04
B	18,89	21,63	2,74	14,50
C	3,92	3,92	0,00	0,00
D	15,72	15,24	0,48	3,05
E	35,76	33,05	2,71	7,57

O cenário-5 obteve os melhores resultados do EAM e de EPMA para ambos os meses em estudo. A interpolação da precipitação da estação C obteve 100% de acerto, demonstrando EAM e EPMA igual a 0 (zero), assim como resultados expressivos para as outras estações. Nourani et al. (2009) estimaram dados de precipitação com redes neurais encontraram erro médio absoluto entre 0,88 a 0,96mm.

4.5. Interpolação Temporal da Precipitação com Redes Neurais Artificiais

A interpolação temporal de dados de precipitação surge como uma alternativa para o preenchimento de falhas existentes em banco de dados de estações de medições, uma vez que essas lacunas comprometem longas séries, afetando o desenvolvimento de estudos climatológicos e hidrológicos nas estações.

Deste modo pode-se afirmar que o valor de um dado dia ou mês, de uma variável, depende de dias ou meses anteriores. Deste modo pode-se assumir que a precipitação (p) em uma estação, para um dado dia ou mês (t) é função da precipitação ($p(t-n)$) de dias ou meses anteriores ($t-1, t-2, \dots, t-n$). Assim, a combinação do número de voltas (dados passados) na camada de entrada pode ser composta por diversas combinações, de modo a verificar a influência de cada uma dessas voltas no preenchimento de falha de precipitação através das redes neurais.

A distribuição diária da precipitação na Fazenda Boa Fortuna, a qual foi utilizada para se estimar o dado de precipitação em falta pode ser vista na Figura 27. A distribuição temporal da série mostra uma forte sazonalidade existente entre os dados, não sendo observado na série tendência.




Figura 27: Precipitação diária observada na Fazenda Boa Fortuna entre os anos de 1993 a 2002

A interpolação pode ser uma alternativa promissora para a reconstrução de dados de precipitação, apresentando-se como solução de múltiplos problemas, especialmente quando os dados de entrada de um modelo apresentam falhas.

Os resultados obtidos com a interpolação para os cenários adotados, assim como o número de voltas utilizadas são mostradas na Tabela 18. Os respectivos X encontrados na tabela são referentes a valores que não foram possíveis se estimar devido ao grande número de dados utilizados. Os dois primeiros cenários utilizados na interpolação da precipitação demonstraram que a utilização de dados passados, melhoraram os resultados encontrados. Jacquin e Shamseldin (2006) mostraram que a utilização de tempos passados como variável de entrada tem um efeito benéfico em termos de eficiência nos valores obtidos.

TABELA 18: Cenários utilizados para a interpolação temporal da precipitação com seus respectivos número de voltas e dados observados e estimados

Número de Voltas	Cenários				
	1		2	3	4
	Observado	Estimado	Estimado	Estimado	Estimado
0	1,30	1,20	2,25	3,00	2,04
5	1,30	1,36	2,11	3,10	4,98
10	1,30	2,20	3,40	4,02	4,62
15	1,30	3,84	2,55	X	3,36
20	1,30	3,76	X	X	X

O primeiro cenário utilizou apenas dados de precipitação da estação Fazenda Boa Fortuna, localizada no município de Rio Largo-AL. Este cenário obteve melhor resultado na interpolação com a utilização de cinco dados passados ($t-5$), com EAM=0,0673 e EPMA=5,1769. O coeficiente de correlação $R=0,819$ e a equação de melhor ajuste $A=(0,564)T + (1,44)$ encontrada para o período de treinamento utilizando cinco voltas pode ser observado na Figura 28.




Figura 28: Coeficiente de correlação para o cenário-1 com a utilização de cinco voltas

O erro médio absoluto e o erro percentual médio absoluto encontrado para os cenários utilizados na interpolação temporal da precipitação para a fazenda Boa Fortuna, com suas respectivas voltas, estão descritos na Tabela 19. Os resultados encontrados mostraram, para alguns casos que, com o aumento do número de tempos passados (voltas), aumentaram também o EAM e o RPMA.

TABELA 19: Erro Médio Absoluto e Erro Percentual Médio Absoluto dos cenários utilizados para a interpolação temporal da precipitação com RNA

Número de Voltas	Cenários							
	1		2		3		4	
	EAM (mm)	EPMA (%)	EAM (mm)	EPMA (%)	EAM (mm)	EPMA (%)	EAM (mm)	EPMA (%)
0	0,0917	7,0538	0,9537	7,3438	1,7050	8,0085	0,7401	20,8086
5	0,0673	5,1769	0,8134	6,4010	1,8097	7,4385	3,6851	25,9906
10	0,9039	6,2765	2,1068	8,4479	2,7264	9,0330	3,3239	23,9223
15	2,5495	7,8706	2,2515	8,7224	X	X	2,0637	23,0634
20	2,5202	7,2133	X	X	X	X	X	X

O EAM encontrado para o cenário-1 variou de 0,0673 a 2,5495mm, para cinco e quinze voltas respectivamente. Este cenário demonstrou, para cinco volta, o melhor resultado entre os dados estimados para o preenchimento de falhas existente na fazenda Boa Fortuna. O EPMA para esse cenário variaram de 5,1769 a 7,8706.

O cenário dois utilizou para o preenchimento de falhas usou dados de precipitação oriundos da estação Fazenda Boa Fortuna e da estação Murici. O resultado encontrado no cenário-2 foi análogo ao cenário anterior, demonstrando resultado satisfatório com a utilização de cinco dados passados. Este cenário para cinco voltas demonstrou EAM=0,8134, EPMA=6,4010 e coeficiente de correlação $R=0,693$, Figura 29.




Figura 29: Coeficiente de correlação para o cenário-2 com a utilização de cinco voltas

Partal e Kisi (2007) mostraram que a interpolação de dados de precipitação com apenas um dia de precipitação anterior, melhorou o desempenho de três estações das cinco utilizadas em seu estudo. Os autores utilizaram dados de precipitação com 1 a 5 dias anteriores, concluindo que com quatro dias anteriores dados o EPMA é menor e o coeficientes de determinação passou de 6,85 para 8,39.

A interpolação realizada com o auxílio do cenário-3 utilizou as precipitações das estações Fazenda Boa Fortuna, Murici e Santana do Mundaú. Esse cenário não demonstrou melhoras com a utilização de dados passados, isso pode ser atribuído ao fato de que, neste

cenário, foram utilizadas estações mais distantes da estação Boa Fortuna. Este cenário mostrou que a utilização de estações, não tão próximas, assim como a adição de dados passados, para essa situação, não trouxeram melhoras significativas nos resultados.

O resultado obtido para o cenário-3 teve o melhor ajuste com a utilização de dados sem voltas correspondendo a 3,00mm. A tabela também mostra que para alguns cenários não foi possível se estimar nenhum valor, decorrente a falta de memória do computador utilizado. A utilização de dados passados aumenta o tempo de processamento e a demanda computacional. O cenário-3 obteve EAM=1,70mm, EPMA=8,00% e R=0,55, Figura 30.




Figura 30: Coeficiente de correlação para o cenário-3, sem voltas

Bodria e Cermák (2000) concluíram através de seu estudo que a precipitação de um determinado mês foi dependente dos dois últimos meses do ano em curso (dois tempos passados), e da precipitação desse mesmo mês de dois anos anteriores. O uso de três ou mais tempos passados não melhorou significativamente o desempenho da rede.

O cenário-4, talvez a mais atípico dos cenários, utilizou dados de precipitação e de vazão para se estimar dados de precipitação. O método se mostrou uma ferramenta promissora, obtendo o terceiro melhor resultado para a interpolação da precipitação, sendo inferior ao cenário-1 sem e com cinco voltas. Remesan et al. (2009) mostraram que o EPME variou em função do número de dados de entrada, variando de 1,67 para 0,61 quando o número de dados de entrada foi aumentado de 250 para 2000.

Este fato foi verificado para esse cenário quando o número de dados passados mudou de 10 para 15 voltas, com a diminuição do EPMA de 23,9223 para 23,0634%. Devido à falta de memória do computador utilizado, não se pode observar com quantas voltas o valor estimado seria satisfatório.

A utilização de dados de vazão e de precipitação mostrou boa correlação para a interpolação temporal com $R=0,811$, Figura 31. O EAM e o EPMA, para a interpolação realizada sem volta foi de 0,74mm e 20,80% respectivamente. Chang e Chen (2001) utilizaram tempos passados e futuros para a previsão de precipitação e de vazão, com atrasos $t-2$, $t-1$, t e $t+1$, encontraram EAM entre 1,38 a 7,09 e EPMA de 0,03 a 0,06.




Figura 31: Coeficiente de correlação para o cenário-4, sem voltas

Coulibaly e Evora (2007) na reconstrução de dados diárias de precipitação para três estações usando rede neurais do tipo MLP encontraram EAM de 1,21, 1,22 e 1,96 e r 0,843, 0,843 e 0,669 respectivamente para cada estação.

5. CONCLUSÕES

Esta dissertação abordou a utilização de Sistemas Inteligentes para o estudo da variabilidade espacial e temporal da precipitação, visando o preenchimento de falhas decorrentes da falta de estações de medições, bem como, de erros instrumentais e humanos de séries temporais de dados de precipitação; podemos concluir que:

- O estado de Alagoas apresentou uma grande variabilidade quanto à distribuição espacial e temporal da precipitação, observando-se que o mês de maio com maior variabilidade obteve EPMA mais elevado;
- A utilização de técnicas geoestatísticas proporcionou definir a região de dependência espacial da precipitação através da utilização do variograma;
- A utilização do método de interpolação espacial Krigagem Ordinária condicionou compreender como se dá a distribuição espacial da precipitação para os meses de maio e novembro, obtendo resultados satisfatórios na estimativa da precipitação para as estações A, B, C, D e E, para ambos os meses estudados;
- A utilização de Redes Neurais Artificiais com múltiplas camadas (MLP) para a interpolação espacial foi satisfatória. A interpolação espacial para o mês de maio obteve o melhor resultado na estimativa da precipitação para a estação C no cenário-3, com $EAM=0,04$ e $EPMA=0,03$. O cenário-4 demonstrou os menores valores para o EPMA.
- Os resultados da interpolação espacial para o mês de novembro demonstraram EAM e EPMA melhores do que o mês de maio, fato que pode ser atribuído a menor variabilidade verificada neste mês. Para este mês, o cenário-2 obteve os melhores EPMA e o cenário-5 obteve o melhor resultado da interpolação para a estação C, com EAM e EPMA igual a zero;
- A interpolação temporal mostrou resultado satisfatório para os dois primeiros cenários com a utilização de cinco dados passados. Para os cenários 3 e 4, os melhores resultados foram obtidos sem a utilização de dados sem voltas. Observou-se que com o aumento do número de voltas o EAM e o EPMA também aumentaram para alguns cenários.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALSAMAMRA, H.; RUIZ-ARIAS, J. A.; POZO-VÁZQUEZ, D.; TOVAR-PESCADOR, J. A comparative study of ordinary and residual kriging techniques for mapping global solar radiation over southern Spain. **Agricultural and Forest Meteorology**, Volume 149, Issue 8, 3 August, Pages 1343-1357, 2009.

ALMEIDA; C. das N. **Consistência de Dados Pluviométricos**. Universidade Federal da Paraíba/Departamento de Engenharia Civil/Laboratório de Recursos Hídricos e Engenharia. Março de 2007.

ALVES, M. C.; BOTELHO, S. A.; PINTO, L. V. A.; POZZA, E. A.; OLIVEIRA, M. S.; FERREIRA, E.; ANDRADE, H. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.12, n.5, p.527–535, 2008.

AMORIM, R. C. F.; RIBEIRO, A.; LEITE, C. C., LEAL, B. G.; SILVA, J. B. G. Avaliação do desempenho de dois métodos de espacialização da precipitação pluvial para o estado de Alagoas. **Acta Sci. Technol.** Maringá. v. 30, n. 1 p. 87-91, 2008.

ASSIS, J. S.; ALVES, A. L.; NASCIMENTO, M. C. **Atlas Alagoano: Espaço Geo-Histórico e Cultural**. Ed. Grafset. 2007.

AVALOS, J. M. M. **Estimacion y Simulacion de la precipitacion en Galicia a Escala Mensual**. Tese de Doutorado. Universidade da Coruña, España. 2003.

AYOADE, J. O. **Introdução à climatologia para os trópicos**. 12 ed. - Rio de Janeiro: Bertrand Brasil. p 1-319, 2007.

BAÚ, A. L.; GOMES, B. M.; QUEIROZ, M. M. F.; OPAZO, M. A. U.; SAMPAIO, S. C. Comportamento Espacial Da Precipitação Pluvial Mensal Provável Da Mesoregião Oeste Do Estado Do Paraná. **Irriga**, Botucatu, v. 11, n. 2, p 150-168, abril-junho, 2006.

BARGAOUI, K. K.; CHEBBI, A. Comparison of two kriging interpolation methods applied to spatiotemporal rainfall. **Journal of Hydrology**, Volume 365, Issues 1-2, 15 February, Pages 56-73, 2009.

BODRIA, L. e V. CERMÁK, V. Prediction of extreme precipitation using a neural network: application to summer flood occurrence in Moravia. **Advances in Engineering Software**. V. 31, 311–321p, 2000.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Editora JC. 262p, 2000.

BRAGA, A. P., CARVALHO, A. P. L., LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ªed., Rio de Janeiro: LTC, 2007.

BRITO, J. I. B.; BRAGA, C. C. Chuva no Estado da Paraíba em 2004. **Boletim da Sociedade Brasileira de Meteorologia (BSBMET)**. Vol. 29, nº 1 – março, p27-32, 2005.

BUCENE, L. C.; ZIMBACK, C. R. L. Comparação de Métodos de Interpolação e Análise Espacial em Dados de pH, em Botucatu-SP. **Irriga**, Botucatu, v. 8, n. 1, p 21-28. Jan-abr, 2003.

CAMBARDELLA, C.A., MOORMAN, T.B., NOVAK, J.M., PARKIN, T.B., KARLEN, D. L., TURCO, R.F., KONOPKA, A.E. Field-scale variability of soil properties in Central Iowa soils. **Soil Sci. Soc. Am. J.** v.58, p.1501-11, 1994.

CAMARGO, E. C. G. **Geoestatística: Fundamentos e Aplicações**. Geoprocessamento em Projetos Ambientais, 36p. 2004.

CARVALHO, F. O. **Estratégias numéricas para solução de modelos de não-equilíbrio para absorção gasosa com reações químicas complexas (regime estacionário e dinâmico)**. Tese (doutorado em Engenharia Química: Sistemas de Processos Químicos e Informática). Universidade Estadual de Campinas - Faculdade de Engenharia Química. Campinas – SP. Agosto de 2000.

CARVALHO, J. R. P.; ASSAD, E. D. Análise Espacial Da Precipitação Pluviométrica No Estado De São Paulo: Comparação de Métodos de Interpolação. **Rev. Eng. Agrícola**, Jaboticabal, v.25, n.2, p.377-384, maio/ago. 2005.

CHANG, F. J.; CHEN Y. C. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction. **Journal of Hydrology**, Volume 245, Pages 153-164. 2001.

CHIANG, Y. M.; CHANG, F. J.; JOU, B. J. D.; LIN, P. F. Dynamic ANN for precipitation estimation and forecasting from radar observations. **Journal of Hydrology**. 334, 250– 261. 2007.

CELIKOGU, H. B. Application of radial basis function and generalized regression neural networks in non-linear utility function specification for travel mode choice modelling. **Mathematical and Computer Modelling**, Volume 44, Issues 7-8, October, Pages 640-658. 2006.

COELHO, G. B. **Análise e Simulação do Processo de Transformação de Chuva em Vazão com Suporte de Sistema de Informações Geográficas (SIGs)**. Dissertação de Mestrado Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, Recife-Pe, 93p. 2006.

COHEN, J. C. P.; SILVA DIAS, M. A. F. da, NOBRE C. A. **Aspectos climatológicos das linhas de instabilidade da Amazônia**. Cachoeira Paulista-SP, Climamálise, v.4, n 11, p34-39, 1989.

COMRIE, A. C. e BROYLES, B. Variability and spatial modeling of fine-scale precipitation data for the Sonoran Desert of southwest Arizona. University of Arizona, Tucson, U.S.A. **Journal of Arid Environments**, v. 50, 573–592p. 2002.

COULIBALY; P., EVORA; N. D. Comparison of neural network methods for infilling missing daily weather records. **Journal of Hydrology**, Volume 341, Issues 1-2, 20 July, Pages 27-41. 2007.

DJURABEKOVA; F.G., DOMINGOS; R., CERCHIARA G., CASTIN; N., VINCENT; E., MALERBA; L. Artificial intelligence applied to atomistic kinetic Monte Carlo simulations in Fe–Cu alloys. **Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms**, Volume 255, Issue 1, February, Pages 8-12. 2007.

FENG, L.; HONG, W. On hydrologic calculation using artificial neural networks. **Applied Mathematics Letters**. V. 21, 453–458p. 2008.

FENILLE, M. C.; CARDIM, M. Correlação espacial entre a altitude e as precipitações pluviométricas no Estado de São Paulo. São Paulo, UNESP, **Geociências**, v. 26, n. 2, p. 135-141, 2007.

FERREIRA, D. F. **Estatística básica**. Lavras: UFLA, 760p. 2005.

FERREIRA, N. S.; REPELLI, C. A.; ALVES, J. M. B.; SOUZA, E. B. LOCZCIT – Um Procedimento Numérico para a localização do Eixo Central da Zona de Convergência Intertropical no Atlântico Tropical. **Revista Brasileira de Meteorologia**. V.20, nº 2, 159-164p, 2005.

FILHO, T. K.; ASSAD, E. D.; LIMA, P. R. S. Regiões Pluviométricas Homogêneas no Brasil. **Revista Agropecuária Brasileira**. V.40, nº4. 311-322p. 2005.

GARRIGUES, S.; ALLARD, D.; BARET, F.; WEISS, M. Quantifying spatial heterogeneity at the landscape scale using variogram models. **Remote Sensing of Environment**, Volume 103, Issue 1, 15 July, Pages 81-96. 2006.

GOMES, B. M., CRUZ, R. L. Comportamento Espacial dos Percentis 75 da Precipitação Decenal para o Estado de São Paulo, na Primavera. **Irriga**, Botucatu, v. 7, n. 2, 2002.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**, 228. p 113–129. 2000.

HABERLANDT, U. Geostatistical interpolation of hourly precipitation from rain gauges and radar for a large-scale extreme rainfall event. **Journal of Hydrology**. 332, 144–157p. 2007.

HINGRAY, B.; HAHA, M. B. Statistical performances of various deterministic and stochastic models for rainfall series disaggregation. **Atmospheric Research**, Volume 77, Issues 1-4, September-October, Pages 152-175. 2005.

IMAI, N. N.; VICENTE, J.; LIMA, D. L.; TACHIBANA, V. M.; SILVA, E. A.; VOLL, E.; OLIVEIRA, H. E. S. **Análise Comparativa da Interpolação por Krigagem Ordinária e Krigagem por Indicação no Caso de Ervas Daninhas em Cultura de Soja**. Unesp – Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia – Departamento de Cartografia. Presidente Prudente - Sp – Brasil. 2007.

JACQUIN, A. P.; SHAMSELDIN, A. Y. Development of rainfall–runoff models using Takagi–Sugeno fuzzy inference systems. **Journal of Hydrology**. V. 329, 154– 173p. 2006.

JAKOB, A. A. E.; YOUNG, A. F. O uso de métodos de interpolação espacial de dados nas análises sociodemográficas. XV ENCONTRO NACIONAL DE ESTUDOS POPULACIONAIS, ABEP, **Anais**. Caxambu –MG – Brasil, de 18 a 22 de setembro de 2006.

KYRIAKIDIS, P. C.; MILLER, N. L.; KIM, J. A spatial time series framework for simulating daily precipitation at regional scales. **Journal of Hydrology**, Volume 297, Issues 1-4, 1 September, Pages 236-255. 2004.

KUHN, G.; KHAN, S.; GANGULY, A. R.; BRANSTETTER, M. L. Geospatial-temporal dependence among weekly precipitation extremes with applications to observations and climate model simulations in South America. **Advances in Water Resources**, Volume 30, Issue 12, December, Pages 2401-2423. 2007.

KUO, J. T.; WANG, Y. Y.; LUNG, W. S. A hybrid neural-genetic algorithm for reservoir water quality management. **Water Research**, Volume 40, Issue 7, April, Pages 1367-1376. 2006.

LEE, W. K.; BIGING, G. S.; SON, Y.; BYUN, W. H.; LEE, K. H.; SON, Y.M.; SEO, J. H. Geostatistical analysis of regional differences in stem taper form of *Pinus densiflora* in central Korea. **Journal of Ecological Research. Publisher Springer Japan**. ISSN 0912-3814 (Print) 1440-1703. Volume 21, Number 4 / July, 2006.

LIN, G. F.; CHEN, L. H. A non-linear rainfall-runoff model using radial basis function network. **Journal of Hydrology**, Volume 289, Issues 1-4, 20 April, Pages 1-8. 2004.

LI, Y. P.; HUANG, G. H.; HUANG, Y. F.; ZHOU, H. D. A multistage fuzzy-stochastic programming model for supporting sustainable water-resources allocation and management. **Environmental Modelling & Software**, Volume 24, Issue 7, July, Pages 786-797. 2009.

LOBBRECHT, A. H.; SOLOMATINE, D. P. Machine learning in real-time control of water systems. **Urban Water**, Volume 4, Issue 3, September, Pages 283-289. 2002.

LOURENÇO, R.W. **Comparação entre métodos de interpolação para Sistemas de Informações Geográficas**. Dissertação de mestrado elaborada junto ao curso de Pós-Graduação em Geociências – área de concentração em Geociências e Meio Ambiente do Instituto de Geociências e Ciências Exatas da Universidade Estadual Paulista, Campus de Rio Claro. Rio Claro, SP, 1998.

LUO; B., MAQSOOD; I., HUANG; G.H., YIN; Y.Y., HAN; D.J. An inexact fuzzy two-stage stochastic model for quantifying the efficiency of nonpoint source effluent trading under uncertainty. **Science of The Total Environment**, Volume 347, Issues 1-3, 15 July, Pages 21-34. 2005.

MACKEY, B. P. A non-linear fuzzy set technique for combining precipitation forecasts. Conference on Weather Analysis and Forecasting, 20. Conference on Numerical Weather Prediction, 16. **American Meteorological Society**, 11-15 January, Seattle, Washington. 2004.

MARCEDO, S. R.; LIMA, W. F.; MACHADO, L. A. T.; JUNIOR, O. P. Monitoramento e Evolução de Descargas Elétrica Atmosférica a Sistemas Convectivos de Mesoescala. **Boletim da Sociedade Brasileira de Meteorologia**, A Meteorologia e a Sociedade. Vol. 29, nº3, 67p, 2005.

MARZANO, F. S.; FIONDA, E.; CIOTTI, P. Neural-network approach to ground-based passive microwave estimation of precipitation intensity and extinction. **Journal of Hydrology**. V. 328, 121–131p. 2006.

MELLO, C. R.; SILVA, A. M. **Rev. bras. eng. agríc. ambient.** v.13, n.1, p.68–74, 2009.

MELLO, C. R.; LIMA, J. M.; SILVA, A. M.; MELLO, J. M.; OLIVEIRA, M. S. Krigagem e Inverso do Quadrado da Distância para a Interpolação dos Parâmetros da Equação de Chuva Intensas. **Rev. Bras. Ci. Solo**, 27:925-933, 2003.

MOLION, L. C. B.; BERNADO, S. O. Uma revisão dinâmica das chuvas no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 17, n.1, p 1-10. 2002.

MÜLLER, M.; FILL, H. D. Redes Neurais Aplicadas na Propagação de Vazões. In. XV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. **Anais**. Instituto de Tecnologia para o Desenvolvimento – LACTEC. Centro de Hidráulica e Hidrologia Prof. Parigot de Souza – CEHPAR. Universidade Federal do Paraná –UFPR. 2003.

NIMER, E. **Pluviometria da Região Hídrica de Pernambuco e Paraíba**. Série Recursos Naturais e Meio Ambiente; 03. Rio de Janeiro: IBGE, 18p, 1979.

NOURANI, V.; ALAMI, M. T.; AMINFAR, M. H. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. **Engineering Applications of Artificial Intelligence**. V. 22, 466–472p. 2009.

OZGUR, N. B.; KOYUNCU, M.; YAZICI, A. An intelligent fuzzy object-oriented database framework for video database applications. **Fuzzy Sets and Systems**, Volume 160, Issue 15, 1 August, Pages 2253-2274. 2009.

PARTAL; T., KIŞI; Ö. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. **Journal of Hydrology**, Volume 342, Issues 1-2, 15 August, Pages 199-212. 2007.

PELLEGATTI, C. H. G. **Avaliação espaço-temporal da precipitação no perfil Baixada Santista – Vertentes Oceânicas – Robordo Interiorano da escarpa da Serra do Mar-SP**. Dissertação de Mestrado. Faculdade de Filosofia, Letras e Ciências Humanas. São Paulo, São Paulo, 128p. 2007.

PERES, P. L. D.; IVANIL S. BONATTI, I. S.; WALTER C. BORELLI, W. C. The Linear Interpolation Method: A Sampling Theorem Approach. **Revista Controle & Automação**, Vol.14 no.4/Outubro, Novembro e Dezembro, 439p. 2003.

PINHEIRO; K. S. F., SOUSA; C. J. S., MENEZES; R. H. N. Caracterização espaço-temporal da precipitação efetiva e do índice de aridez na bacia hidrográfica do Riacho da Boa Hora, Urbano Santos-MA. In: XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, **Anais**. Goiânia, Brasil, 16-21 abril, INPE, p. 2535-2542. 2005.

POKROVSKY, O.M., European rain rate modulation enhanced by changes in the NAO and atmospheric circulation regimes. **Computers and Geosciences**, doi:10.1016/j.cageo.2007.12.005. 2008.

PRUSKI; F. F., PEREIRA; S. B., NOVAES; L. F. SILVA; D. D., RAMOS; M. M. Precipitação Média Anual e Vazão Específica Média de Longa Duração, na Bacia do São Francisco. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, p.247-253, 2004.

REMESAN, R.; SHAMIM, M.A.; HAN, D.; MATHEW, J. Runoff Prediction Using an Integrated Hybrid Modelling Scheme, **Journal of Hydrology**. V. 541, 322-336p. 2009.

RENTERIA; A. R. **Estimação de probabilidade fuzzy a partir de dados imprecisos**. Rio de Janeiro. 94p. Tese de Doutorado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro. 2006.

SÁ, M. O. **Variabilidade Espacial da Precipitação para o Estado de Alagoas: Uma aplicação de Geoestatística e Redes Neurais Artificiais**. Dissertação (Mestrado em Meteorologia/) – Universidade Federal de Alagoas, UFAL – Maceió, Alagoas, 2006.

SHAO, X.; STEIN, M.; CHING, J. Statistical comparisons of methods for interpolating the output of a numerical air quality model. **Journal of Statistical Planning and Inference**, Volume 137, Issue 7, 1 July, Pages 2277-2293. 2007.

SHEN, J.; SHEN, W.; SUN, H. J.; YANG, J. Y. Fuzzy neural nets with non-symmetric π membership functions and applications in signal processing and image analysis. **Signal Processing**, Volume 80, Issue 6, June, Pages 965-983. 2000.

SIROIS, A. The effects of missing data on the calculation of precipitation-weighted-mean concentrations in wet deposition. **Atmospheric Environment**. Part A. General Topics, Volume 24, Issue 9, Pages 2277-2288. 1990.

SUGIMOTO, S.; NAKAKITA, E.; IKEBUCHI, S. A stochastic approach to short-term rainfall prediction using a physically based conceptual rainfall model. **Journal of Hydrology**, Volume 242, Issues 1-2, 15 February, Pages 137-155. 2001.

TEEGAVARAPU, R. S. V. e CHANDRAMOULI V. Improved weighting methods, deterministic and stochastic data-driven models for estimation of missing precipitation records. **Journal of Hydrology**, Volume 312, June, Pages 191–206. 2005.

TEEGAVARAPU; R. S. V. Use of universal function approximation in variance-dependent surface interpolation method: An application in hydrology. **Journal of Hydrology**, Volume 332, Issues 1-2, 1 January, Pages 16-29. 2007.

TEEGAVARAPU, R. S. V; TUFAIL, M.; ORMSBEE, L. Optimal functional forms for estimation of missing precipitation data. **Journal of Hydrology**, Volume 374, Issues 1-, 30 July, Pages 106-115. 2009.

TERCEDEIRO, L. V. **Hidrologia**. ISEL-Instituto Superior de Engenharia de Lisboa. DEC-Secção de Hidráulica e Obras Hidráulicas. 2006.

TRIPLET, J. P.; ROCHE, G. **Météorologie Générale**. Ecole Nationale de la Météorologie. Seconde Édition. p. 67-80. 1977.

TUBELIS, A.; NASCIMENTO, F.J.L. **Meteorologia Descritiva: Fundamentos e Aplicações**. São Paulo: Nobel – 2ª reimpressão, p 01-374. 1983.

TUCCI, C. E. M. **Hidrológicos: Ciência e Aplicação**. 2. Ed.; 2.reimpr. - Porto Alegre. Ed. Universidade/UFRGS/ Associação Brasileira de recursos Hídrico, p-183-186, 2001.

TUCCI, C. E. M. **Modelos Hidrológicos**. Porto Alegre: Ed. Universidade/UFRGS/ associação Brasileira de Recursos Hídricos, 1998.

VAREJÃO, M. A. **Meteorologia e Climatologia**. Versão digital 2 – Recife, 2006.

VALENÇA, M. **Aplicando Redes neurais: um guia completo**. Olinda, PE: Ed. do Autor, 284p. 2005.

VENDRUSCULO, L. G.; CARVALHO, J. R. P.; VIEIRA, S. R. Uso Do Software Geost Para Análise Espacial Da Precipitação Pluvial Anual No Estado De São Paulo. In: IV CONGRESSO BRASILEIRO DA SOCIEDADE BRASILEIRA DE INFORMÁTICA APLICADA À AGROPECUÁRIA E À AGROINDÚSTRIA. **Anais**, 2003.

VERMA; P., SINGH; P., GEORGE; K.V., SINGH; H.V., DEVOTTA; S., SINGH; R.N. Uncertainty analysis of transport of water and pesticide in an unsaturated layered soil profile using fuzzy set theory. **Applied Mathematical Modelling**, In Press, Corrected Proof, Available online 15 December 2007.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Ed. UFV, p 15-446. 2006.

VILLELA, S. M.; MATOS, A. **Hidrologia Aplicada**. São Paulo, Ed. McGraw-Hill do Brasil. p 5-315. 1975.

WANDERLEY, H.S.; CARVALHO, F. de O.; AMORIM; R. F. C. Análise espacial da precipitação para o Estado de Pernambuco. In: IX SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE. Livro de Resumo. **Anais**. Salvador-BA. Novembro, página 148. 2008.

WANDERLEY, H. S.; CARVALHO, F. O.; RICARDO CARLOS FERREIRA DE AMORIM, R. C. F. Análise geoestatística da precipitação para o estado de Alagoas. In: XVIII CONGRESSO BRASILEIRO DE RECURSOS HÍDRICOS. Livro de Resumo. **Anais**. Campo Grande-MT. Novembro, página 236. 2009^a.

WANDERLEY, H. S.; CARVALHO, F. O.; RICARDO CARLOS FERREIRA DE AMORIM, R. C. F.; CARVALHO, A. L. Estudo dos meses de máxima e mínima distribuição da precipitação no estado de alagoas. In: XVI Congresso Brasileiro de Agrometeorologia. **Anais**. Setembro, Belo Horizonte, MG. de 2009b.

XAVIER, T. de M. B. S., Chuvas intensas em janeiro/fevereiro 2004 no Ceará e a previsão em anos de neutralidade no Pacífico. **Boletim da Sociedade Brasileira de Meteorologia (BSBMET)**. Vol. 29, nº 1 – março, p 17-26. 2005.

YURDUSEV, M. A.; FIRAT, M. Adaptive neuro fuzzy inference system approach for municipal water consumption modeling: An application to Izmir, Turkey. **Journal of Hydrology**, Volume 365, Issues 3-4, 25 February, Pages 225-234. 2009.

ZAMBOTI, J. L. **Mapas pluviométricos médios mensais no verão para o Estado do Paraná, utilizando métodos geoestatísticos**. Tese (Doutorado em Agronomia/Energia na Agricultura) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista. Botucatu, 134p. 2001.

ZAMBOTI, J. L.; MELEM, V. M. **Precipitação Pluviométrica do Litoral e do Interior Do Estado do Paraná, Mapeada Por Métodos Geoestatísticos**. Botucatu-SP, 2002.

7. ANEXO

TABELA 20 : Codificação, nome e localização das 63 estações pluviométricas selecionadas do banco de dados da ANA, distribuídas no estado de Alagoas

Código	Nome	Latitude (°)	Longitude (°)	Altitude (m)
835072	Colônia Leopoldina	-8.91	-35.71	166
835073	Ibateguara (Piquete)	-8.98	-35.93	505
935001	Flecheiras	-9.28	-35.71	70
935005	Maceió	-9.56	-35.78	5
935010	Maragogi	-9.01	-35.23	5
935011	Matriz de Camaragibe	-9.16	-35.51	16
935012	Murici	-9.31	-35.94	82
935013	Passo de Camaragibe	-9.23	-35.48	90
935016	Porto Calvo	-9.06	-35.4	54
935019	Porto de Pedras (DNOS)	-9.16	-35.3	22
935021	Rio Largo	-9.48	-35.83	62
935023	Satura	-9.58	-35.81	10
935024	Saúde	-9.53	-35.63	10
935025	São Luiz do Quitunde	-9.33	-35.55	4
935028	Tatuamunha	-9.23	-35.35	12
935054	Pilar (3898211)	-9.63	-35.96	8
936010	Atalaia	-9.51	-36.01	54
936014	Capela (Conceição do Paraíba)	-9.43	-36.08	34
936015	Craíba (Caraíbas)	-9.61	-36.78	230
936016	Fazenda Varrela	-9.7	-36.05	100
936019	Igaci (Olhos d'água do Acioli)	-9.55	-36.63	240
936020	Junqueiro	-9.93	-36.48	120
936022	Lagoa da Canoa	-9.83	-36.73	235
936026	Limoeiro de Anadia	-9.75	-36.5	150
936028	Major Isidoro (Sertãozinho)	-9.53	-36.98	217

Código	Nome	Latitude (°)	Longitude (°)	Altitude (m)
936031	Mar Vermelho	-9.45	-36.38	620
936032	Minador do Negrão	-9.31	-36.86	393
936033	Munguba	-9.06	-36.2	404
936034	Palmeira dos Índios	-9.4	-36.65	342
936041	Quebrângulo	-9.33	-36.48	411
936044	Rocha Cavalcanti	-9.1	-36.06	156
936045	Santana do Mundaú	-9.16	-36.21	221
936046	Sebastião Ferreira	-9.8	-36.06	0
936047	São Jose da Laje	-9.01	-36.05	250
936048	São Miguel dos Campos	-9.78	-36.1	12
936049	Santa Efigênia	-9.3	-36.13	170
936050	Traipu	-9.96	-36.98	40
936051	Traipu	-9.96	-36.98	40
936052	Tanque D'arca	-9.53	-36.43	280
936053	União dos Palmares	-9.16	-36.05	155
936056	Usina Cansanção do Sinimbu	-9.86	-36.15	20
936057	Viçosa	-9.38	-36.25	300
936066	Arapiraca (DNOS)	-9.75	-36.65	264
936070	Anadia	-9.63	-36.33	100
937004	Poço das Trincheiras	-9.21	-37.28	255
937005	Riacho Grande	-9.46	-37.46	210
937006	Santana do IpanEAM	-9.36	-37.25	250
937007	Água Branca	-9.28	-37.93	510
937010	Batalha	-9.66	-37.13	120
937011	Cacimbinhas	-9.4	-37	300
937012	Capia da Igrejinha	-9.18	-37.43	280
937013	Delmiro Gouveia (Pedra)	-9.39	-37.99	256
937014	Mata Grande	-9.13	-37.73	633

Código	Nome	Latitude (°)	Longitude (°)	Altitude (m)
937016	Olho D'água das Flores	-9.53	-37.28	286
937019	Pão de Açúcar	-9.73	-37.43	45
937022	Piranhas (Marechal Floriano)	-9.61	-37.76	110
1036003	Igreja Nova	-10.11	-36.65	17
1036004	Penedo	-10.28	-36.58	28
1036005	Penedo	-10.28	-36.55	28
1036008	Piacabucu	-10.41	-36.41	10
1036009	Porto Real do Colégio	-10.18	-36.83	30
1036011	Colônia Pindorama	-10.11	-36.4	110
1036013	Coruripe	-10.11	-36.16	10