

UNIVERSIDADE FEDERAL DO PARANÁ

TIAGO NORONHA DOS SANTOS

REDES NEURAIS ARTIFICIAIS E RELAÇÃO ZR APLICADAS À ESTIMATIVA
DE CHUVA

CURITIBA
2014

TIAGO NORONHA DOS SANTOS

REDES NEURAIS ARTIFICIAIS E RELAÇÃO ZR APLICADAS À ESTIMATIVA
DE CHUVA

Dissertação apresentada ao Curso de Pós-Graduação em Métodos Numéricos em Engenharia, área de concentração em Programação Matemática, do Departamento de Matemática, Setor de Ciências Exatas e do Departamento de Construção Civil, Setor de Tecnologia, da Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Ciências.

Orientador: Prof^o. Dr. Paulo Henrique Siqueira

Coorientador: Dr. Leonardo Calvetti

CURITIBA

2014

S237r

Santos, Tiago Noronha dos
Redes neurais artificiais e relação ZR aplicadas à estimativa de chuva /
Tiago Noronha dos Santos. – Curitiba, 2014.
82f. : il. color. ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de
Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em
Engenharia, 2014.

Orientador: Paulo Henrique Siqueira -- Coorientador: Leonardo Calvetti.
Bibliografia: p. 79-81.

1. Redes neurais (Computação). 2. Precipitação (Meteorologia). 3.
Meteorologia por radar I. Universidade Federal do Paraná. II. Siqueira, Paulo
Henrique III. Calvetti, Leonardo IV. Título.


CDD: 006.32

TERMO DE APROVAÇÃO

TIAGO NORONHA DOS SANTOS

REDES NEURAIS ARTIFICIAIS E RELAÇÃO ZR APLICADAS À ESTIMATIVA DE CHUVA.

Dissertação aprovada como requisito parcial para obtenção do grau de mestre no Programa de Pós-Graduação em Métodos Numéricos em Engenharia, da Universidade Federal do Paraná, pela seguinte banca examinadora:



Prof. Dr. Paulo Henrique Siqueira
Orientador - Membro do PPGMNE/UFPR



Prof.^a Dr.^a Deise Maria Bertholdi Costa
Membro do PPGMNE/UFPR



Prof. Dr. Cesar Augustus Assis Beneti
Membro do SIMEPAR/PR.

Curitiba, 10 de fevereiro 2014.

Dedico à,

minha família, amor e amigos.

AGRADECIMENTOS

Aos meus pais, Aroldo e Mara por todo o amor, carinho e apoio durante toda a minha vida.

Aos meus irmãos, Solange e Mateus por estarem comigo em todos os momentos.

Ao Rob, por todo o amor, carinho e puxões de orelha.

Aos amigos de uma vida, Ana, Gever, Luan, Pri e Rafa que estão comigo há tantos anos compartilhando alegrias e novas experiências.

Aos queridos amigos, Alana, Camila, Danilo, Jorge e Mari por horas de estudos juntos, discussões sobre nossos trabalhos e muita diversão.

Ao professor Paulo que me orientou durante esta fase, ajudando em momentos de dúvidas.

Ao Leonardo por todo o ensinamento na área meteorológica, além da paciência durante estes anos de estudo e à amizade.

Ao SIMEPAR pela oportunidade de desenvolver esta pesquisa.

À todos que me ajudaram e contribuíram para a conclusão deste trabalho, o meu sincero agradecimento.

“É preciso que eu suporte duas ou três larvas
se quiser conhecer as borboletas.”

O Pequeno Príncipe - Antoine de Saint-Exupéry

RESUMO

Por meio deste trabalho apresenta-se a utilização de redes neurais artificiais, em particular as rede neurais com funções de base radial e perceptron de múltiplas camadas, além de uma terceira técnica que busca por uma nova relação ZR. O objetivo deste trabalho é comparar o desempenho das técnicas ao converter dados de refletividade de radar em taxa precipitação de chuva. As metodologias propostas são comparadas com a relação ZR de Marshall-Palmer. Todos os dados meteorológicos utilizados são provenientes do SIMEPAR através do radar meteorológico e uma rede de pluviômetros. Os resultados apresentam-se satisfatórios após alguns índices de comparação serem testados, como a raiz do erro médio quadrático que enquanto para a relação de Marshall-Palmer fornece o valor 6.139 para os dados de treinamento, a rede RBF retorna 2.789, a rede MLP 3.289 e a nova relação ZR 2.895.

Palavras-chave: Redes Neurais Artificiais, Estimativa de Chuva, Relação ZR, Rede Neural RBF, Rede Neural MLP.

ABSTRACT

Through this work we present the use of artificial neural networks, in particular the neural network with radial basis functions and multilayer perceptron, and a third technique that searches for a new ZR relationship. All with the aim of comparing their ability to convert radar reflectivity data in rainfall. It also compares the proposed methodologies with the Marshall-Palmer ZR relationship. All meteorological data is provided by SIME-PAR through weather radar and rain gauge network. The results are found satisfactory after some comparison indices were tested, as the root mean square error for the relationship of Marshall-Palmer gives the value of 6.139 for the training data, the RBF network returns 2.789, the MLP network 3.289 and the new ZR relationship 2.895.

Key-words: Artificial Neural Networks, Rain Forecast, ZR Relationship, RBF Neural Network, MLP Neural Network.

LISTA DE FIGURAS

FIGURA 1 – MODELO NÃO-LINEAR DE UM NEURÔNIO	21
FIGURA 2 – TRANSFORMAÇÃO AFIM PRODUZIDA COM A PRESENÇA DE UM BIAS	22
FIGURA 3 – ARQUITETURA DE UMA REDE RBF	24
FIGURA 4 – ARQUITETURA DE UMA REDE MLP	32
FIGURA 5 – IMAGEM DE REFLETIVIDADE DO RADAR	40
FIGURA 6 – EXEMPLO DE DISTRIBUIÇÃO DE GOTAS	41
FIGURA 7 – ILUSTRAÇÃO PPI	43
FIGURA 8 – ELEVAÇÃO DO FEIXE	44
FIGURA 9 – ILUSTRAÇÃO CAPPI	44
FIGURA 10– DIÂMETRO DE GOTA DE CHUVA (<i>MM</i>)	48
FIGURA 11– VARREDURA DO RADAR	55
FIGURA 12– PLUVIÔMETRO <i>TIPPING BUCKET</i>	57
FIGURA 13– DISPOSIÇÃO DAS ESTAÇÕES METEOROLÓGICAS	60
FIGURA 14– NÚMERO DE NEURÔNIOS PARA A REDE RBF	62
FIGURA 15– NÚMERO DE NEURÔNIOS PARA A REDE MLP	63
FIGURA 16– PARÂMETROS DA RELAÇÃO ZR COM REM_Q	65
FIGURA 17– GRÁFICO DE DISPERSÃO PARA OS DADOS DE TREINAMENTO	72
FIGURA 18– GRÁFICO DE DISPERSÃO PARA OS DADOS DE VALIDAÇÃO ..	73
FIGURA 19– COMPARAÇÃO DA CHUVA ACUMULADA EM 1 HORA NO DIA 05/12/2013 ÀS 16:00HRS	74
FIGURA 20– COMPARAÇÃO DA CHUVA ACUMULADA EM 1 HORA NO DIA 20/06/2013 ÀS 13:00HRS	75
FIGURA 21– COMPARAÇÃO DA CHUVA ACUMULADA EM 1 HORA NO DIA	

21/09/2013 ÀS 19:00HRS	76
FIGURA 22– COMPARAÇÃO DA CHUVA ACUMULADA EM 24 HORAS NO DIA	
21/06/2013	77

LISTA DE TABELAS

TABELA 1	– ESTAÇÕES METEOROLÓGICAS: DADOS GEOGRÁFICOS	60
TABELA 2	– RANKING RELAÇÕES ZR	65
TABELA 3	– RELAÇÃO ZR E REDE RBF - TREINAMENTO	67
TABELA 4	– RELAÇÃO ZR E REDE RBF - VALIDAÇÃO	68
TABELA 5	– RELAÇÃO ZR E REDE MLP - TREINAMENTO	68
TABELA 6	– RELAÇÃO ZR E REDE MLP - VALIDAÇÃO	69
TABELA 7	– RELAÇÃO ZR E NOVA RELAÇÃO ZR - TREINAMENTO	69
TABELA 8	– RELAÇÃO ZR E NOVA RELAÇÃO ZR - VALIDAÇÃO	70
TABELA 9	– REDE RBF, REDE MLP E NOVA RELAÇÃO ZR - TREINAMENTO		70
TABELA 10	– REDE RBF, REDE MLP E NOVA RELAÇÃO ZR - VALIDAÇÃO	..	71
TABELA 11	– REMQ PARA O RANKING DE RELAÇÕES ZR EM DIFERENTES NÍVEIS DE <i>DBZ</i>	83

LISTA DE SIGLAS

ACP	Análise de Componentes Principais
CAPPI	Constant Altitude Plan Position Indicator
DSD	Raindrop Size Distribution
IPMet	Instituto de Pesquisas Meteorológicas
MLP	Multi-Layer Perceptron
NetCDF	Network Common Data Form
PPI	Plan Position Indicator
RBF	Radial Basis Function
RBFNN	Radial Basis Function Neural Network
REMQ	Raiz do Erro Médio Quadrático
RLM	Regressão Linear Múltipla
RNAs	Redes Neurais Artificiais
RNN	Recurrent Neural Network
SOFM	Self Organized Feature Map
WTA	Winner-Take-All Network

SUMÁRIO

1 INTRODUÇÃO	16
1.1 JUSTIFICATIVA	17
1.2 OBJETIVOS	17
1.2.1 Objetivo Geral	17
1.2.2 Objetivos Específicos	18
1.3 LIMITAÇÕES DO TRABALHO	18
1.4 DISPOSIÇÃO DO TRABALHO	18
2 TÉCNICAS	20
2.1 REDES NEURAIS ARTIFICIAIS	20
2.1.1 Neurônios	21
2.2 REDES NEURAIS COM FUNÇÕES DE BASE RADIAL	22
2.2.1 A construção de uma rede RBF	24
2.2.2 Arquitetura da rede RBF	24
2.2.3 O Teorema de Cover - Separabilidade de Padrões	24
2.2.4 Interpolação	25
2.2.5 Fases da Rede RBF	26
2.2.6 Funções de Base Radial	27
2.2.7 Centros da Rede RBF	28
2.2.8 Raio da Função de Base	29
2.2.9 Critério de Parada	30
2.3 PERCEPTRON DE MÚLTIPLAS CAMADAS	30
2.3.1 Características da rede MLP	32
2.3.2 O Algoritmo da Rede MLP	34

2.3.3 Função de Ativação	37
2.3.4 Critério de Parada	38
2.4 CONCEITOS METEOROLÓGICOS	38
2.4.1 Refletividade	39
2.4.2 Equação do Radar	40
2.4.3 PPI e CAPPI	43
2.4.4 Chuva	45
2.4.5 Distribuição do Tamanho das Gotas	45
2.4.6 Distribuição do Tamanho de Gotas de Nuvem	46
2.4.7 Distribuição do Tamanho de Gotas de Chuva	47
2.5 A RELAÇÃO ZR	49
2.6 MÉTODOS ALTERNATIVOS À RELAÇÃO ZR	52
2.7 ÍNDICES DE COMPARAÇÃO	53
3 INSTRUMENTOS	55
3.1 RADAR METEOROLÓGICO	55
3.1.1 Operação	56
3.2 PLUVIÔMETRO	56
3.2.1 Estrutura e Operação	56
4 APLICAÇÃO	58
4.1 BANCO DE DADOS	58
4.1.1 Dados de Radar	58
4.1.2 Dados de Pluviômetro	59
4.1.3 Filtro	60
4.2 APLICAÇÃO DA REDE RBF	61
4.2.1 Pré-processamento dos dados	61
4.3 APLICAÇÃO DA REDE MLP	62

4.3.1 Pré-processamento dos dados	62
4.4 APLICAÇÃO DA NOVA RELAÇÃO ZR	64
5 RESULTADOS	67
5.1 RESULTADOS DA REDE RBF	67
5.2 RESULTADOS DA REDE MLP	68
5.3 RESULTADOS DA NOVA RELAÇÃO ZR	69
5.4 COMPARAÇÃO ENTRE AS TRÊS NOVAS METODOLOGIAS	70
6 CONCLUSÃO	78
6.1 TRABALHOS FUTUROS	79
REFERÊNCIAS	80
ANEXO A – RANKING DAS RELAÇÕES ZR	83

1 INTRODUÇÃO

Classificar e caracterizar, de forma objetiva e acurada, um fenômeno meteorológico é um dos grandes desafios que meteorologistas enfrentam. Procurando vencer estes desafios utilizam-se diversos tipos de análises, conceitos, métodos estatísticos e modelos numéricos buscando uma definição com o mínimo erro dos padrões atmosféricos. Um desses desafios é calcular a estimativa de chuva em superfície terrestre no intuito de saber de fato a quantidade de chuva para determinada medida na atmosfera através do radar meteorológico do SIMEPAR, localizado na cidade de Teixeira Soares-PR.

São várias as informações medidas pelo radar, porém neste trabalho foca-se na principal variável para estimar a taxa de precipitação de chuva, conhecida como fator de refletividade do radar. As comparações são realizadas em pontos específicos onde estão instalados os pluviômetros. Estes instrumentos medem a quantidade de chuva que caiu em uma região específica.

Dessa forma, foram programadas as redes neurais de base radial (RBF), perceptron de múltiplas camadas (MLP) e a nova relação ZR com a finalidade de aproximar a conversão da refletividade do radar aos dados dos pluviômetros e podendo assim, comparar o resultado com a relação mais comumente utilizada no mundo, a relação ZR de Marshall-Palmer (MARSHALL; PALMER, 1948). Tal relação tem sido estudada ao longo dos últimos 40-50 anos e é descrita como uma função exponencial da refletividade do radar e a taxa de precipitação de chuva. Pode-se gerar novas relações ao se fazer uma variação de seus parâmetros.

1.1 JUSTIFICATIVA

Eventos meteorológicos severos podem ser responsáveis por danos irreparáveis à sociedade e aumentar a acurácia da estimativa de chuva é um dos fatores capazes de auxiliar no monitoramento destes eventos. Este é o motivo mais nobre deste trabalho. Por isso, busca-se a melhoria de métodos já existentes e também o desenvolvimento de novas metodologias.

A mediação de precipitação convencionalmente é realizada por meio de pluviômetros os quais são instalados em determinados pontos para representar a chuva da região. Porém, a ocorrência de chuva não é uniforme e varia muito de um ponto a outro. Por exemplo, uma tempestade pode atingir o centro de uma cidade como Curitiba com valores de até $30\text{mm}/h$ e a 3km de distância deste ponto de medição o volume pode ser de apenas $5\text{mm}/h$, pois esta área estaria na periferia da célula de tempestade.

As redes neurais utilizadas são consagradas na literatura como poderosos aproximadores de funções e classificadores de padrões, sabendo que dados meteorológicos são variáveis complexas. O desempenho das redes RBF e MLP são exaustivamente comparados em artigos, embora a fundamentação teórica de cada uma seja consideravelmente diferente. A técnica da nova relação ZR se dá pela necessidade de uma comparação mais próxima da tão conceituada relação de Marshall-Palmer.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é encontrar um ou mais métodos que façam a conversão de dados de refletividade em precipitação de chuva, e forneçam o menor erro possível quando comparados aos dados lidos pelas estações meteorológicas, podendo assim, estabelecer uma nova metodologia. Por isso, sensores remotos como radar meteorológico e satélites ambientais são utilizados para melhorar a identificação

da distribuição espacial da ocorrência da precipitação.

1.2.2 Objetivos Específicos

- Conhecer a teoria aprofundada de importantes redes neurais artificiais;
- Verificar qual técnica tem melhor performance: rede neural RBF, rede neural MLP ou a nova relação ZR;
- Encontrar relações ZR capazes de descrever com mais precisão determinadas classes de refletividade;
- Verificar se alguma técnica possui tendências de subestimar ou superestimar a precipitação de chuva.

1.3 LIMITAÇÕES DO TRABALHO

Este trabalho se atém à:

- Utilizar dados de PPI (*Plan Position Indicator*) do radar meteorológico com a primeira elevação;
- Utilizar dados de refletividade maiores ou iguais a $30dBZ$;
- Período dos dados de 01 de dezembro de 2008 a 04 de setembro de 2010.

1.4 DISPOSIÇÃO DO TRABALHO

O presente trabalho se inicia com a introdução, apresentação dos objetivos, justificativas e limitações no Capítulo 1. No Capítulo 2 tem-se a fundamentação teórica de cada metodologia proposta, seguida de uma revisão bibliográfica. Os instrumentos de medição são definidos no Capítulo 3. No Capítulo 4 apresenta-se a aplicação de cada técnica, cada uma com suas especificações. No Capítulo 5 têm-se os resultados e comparações entre as metodologias utilizando os índices definidos no Capítulo 2,

segue-se então para as conclusões do trabalho e as referências citadas ao longo do mesmo.

2 TÉCNICAS

2.1 REDES NEURAIS ARTIFICIAIS

Os trabalhos desenvolvidos com Redes Neurais Artificiais (RNAs), usualmente denominadas de “redes neurais”, têm sido motivados desde o início pelo reconhecimento de que o cérebro humano processa informações de forma diferente do computador convencional. O cérebro é um *computador* altamente *complexo, não-linear e paralelo* (HAYKIN, 2001). Ele tem a capacidade de organizar os seus neurônios, de forma a realizar certos processamentos de maneira muito mais veloz que o mais rápido e atual computador.

Para sermos mais específicos, o cérebro realiza diariamente tarefas de reconhecimento perceptivo em aproximadamente 100 – 200ms, enquanto tarefas menos complexas podem levar horas para serem executadas em um computador. Um cérebro tem a habilidade de desenvolver suas próprias regras através do que chamamos de “experiência”.

De forma mais geral, uma rede neural é projetada para modelar a maneira como o cérebro realiza uma atividade de interesse; a rede é normalmente simulada por programação em computadores. Para obterem desempenho satisfatório, as redes neurais empregam uma interligação de células computacionais simples denominadas “neurônios”. O meio utilizado para realizar a aprendizagem é chamado de *algoritmo de aprendizagem*, onde a função é alterar os valores dos pesos da rede de forma ordenada para alcançar o objetivo desejado.

2.1.1 Neurônios

Um neurônio é uma unidade de processamento de informação, fundamental para uma rede neural. A Figura 1 mostra o modelo de um neurônio, base para as redes neurais artificiais. Podemos identificar três elementos básicos (HAYKIN, 2001):




FIGURA 1: Modelo não-linear de um neurônio

FONTE: Adaptada de Haykin (2001)

1. Um conjunto de *elos de conexão*, cada um caracterizado por um peso. Particularmente, um sinal x_j na entrada j ligada ao neurônio k é multiplicado pelo peso w_{kj} . O primeiro índice é referente ao neurônio e o segundo à posição de entrada a qual o peso se refere. Diferente de uma sinapse do cérebro, o peso de um neurônio artificial pode estar em um intervalo com valores negativos e positivos.
2. Um *somador* Σ para os sinais de entrada, ponderados pelos respectivos pesos.
3. Uma *função de ativação* φ para delimitar a amplitude da saída de um neurônio.

O modelo da Figura 1 também inclui um bias, representado por b_k podendo aumentar ou diminuir a entrada da função de ativação.

Em termos matemáticos, podemos apresentar um neurônio k com as seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde x_1, x_2, \dots, x_m são as entradas; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos do neurônio k ; u_k é a saída da combinação linear devido aos valores de entrada; b_k é o bias; $\varphi(\cdot)$ é a função de ativação; e y_k é a saída do neurônio. Utilizar o bias tem o efeito de aplicar uma transformação afim à saída u_k , como a seguir:

$$v_k = u_k + b_k. \quad (3)$$

Em particular, considerando-se a dependência do bias b_k ser positivo ou negativo, a relação entre v_k do neurônio k e a saída u_k é modificada como na Figura 2.

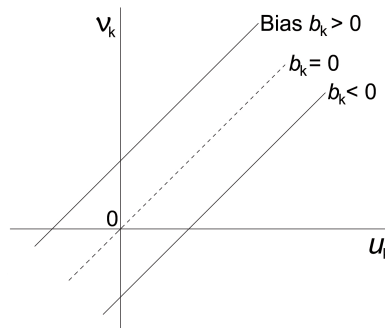


FIGURA 2: Transformação afim produzida com a presença de um bias

FONTE: Adaptada de Haykin (2001)

2.2 REDES NEURAIS COM FUNÇÕES DE BASE RADIAL

As redes neurais com funções de base radial (*Radial Basis Function Neural Network* - RBFNN) possuem aprendizado supervisionado e seguem um enfoque particular quando se fala em um problema de ajuste de curva ou aproximação em um espaço de dimensão alta. Dessa forma, consideramos que aprender é o mesmo que encontrar uma superfície em um espaço multidimensional que consiga ajustar melhor os dados de treinamento. Da mesma maneira, a generalização equivale ao uso da superfície multidimensional para interpolar os dados de teste. No cenário de uma rede neural, como em outras redes, a camada oculta fornece um conjunto de funções que formam uma base arbitrária para os padrões de entrada, então eles são expandidos sobre o espaço oculto (HAYKIN, 2001).

Na literatura, encontram-se trabalhos envolvendo as redes RBF aplicados à meteorologia, como em Santhanam e Subhajini (2011), onde a técnica foi utilizada juntamente com a rede neural de aprendizagem *back-propagation* para testar o desempenho na eficácia para a previsão. Como resultado, os autores concluíram que a rede RBF obteve a solução superior à rede de aprendizagem *back-propagation*, com valores de acurácia de 88,5% da rede RBF contra 82% da rede MLP.

No artigo de Wei (2011), a aplicação da rede RBF é combinada com a técnica de Análise de Componentes Principais (ACP) na previsão da precipitação de um reservatório de bacias hidrográficas em períodos de tufão. Os resultados mostraram que as previsões obtidas com a rede RBF e com a combinação RBF-ACP foram melhores do que as encontradas pelo método de Regressão Linear Múltipla (RLM) e pela combinação ACP-RLM. No entanto a junção RBF-ACP foi superior à rede RBF simples, na questão de velocidade de aprendizado, pois a técnica ACP reduz significativamente os parâmetros de entrada simplificando a arquitetura da rede.

No trabalho de Mutlu *et al.* (2008) é relatada uma avaliação de redes neurais artificiais para prever fluxos diários em estações hidrográficas situadas no Arkansas-EUA. Os modelos de redes neurais desenvolvidos foram: a rede MLP e a rede RBF. As duas redes foram testadas para prever o fluxo de corrente em quatro estações. Diferentes cenários foram utilizados, com várias combinações do conjunto de dados. Ao todo foram usados 739 padrões, divididos em 492 padrões de treinamento e os 247 restantes para testes. O melhor desempenho, baseado na raiz do erro médio quadrático, foi alcançado pelo modelo da MLP, considerando que o modelo da RBF também obteve desempenho satisfatório. O tempo de treinamento foi no intervalo de 1 – 2 minutos para o perceptron e 5 – 10 segundos para a RBF. Os autores concluíram que os modelos de RNAs são úteis para prever a resposta hidrológica em pontos diferentes de bacias hidrográficas.

2.2.1 A construção de uma rede RBF

A construção de uma rede neural RBF, se baseia em três camadas com características diferentes. A primeira camada é a de valores de entrada. A segunda e única camada intermediária, aplica a transformação não-linear nos valores de entrada para a camada oculta, que em geral é de alta dimensionalidade. A camada de saída possui a transformação linear, apresentando a resposta da rede ao padrão aplicado à entrada.

2.2.2 Arquitetura da rede RBF

Na Figura 3 é possível reconhecer as camadas da rede neural RBF, assim como os padrões de entrada, os centros das funções de base, as próprias funções de base como neurônios de ativação na camada oculta, os pesos calculados para a camada de saída e a influência do bias. Na Figura 3 a camada de entrada e de saída estão representadas com apenas um neurônio, simbolizando a forma como a rede RBF foi aplicada no trabalho.

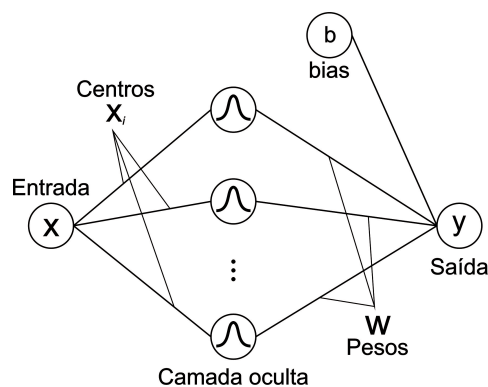


FIGURA 3: Arquitetura de uma rede neural RBF

FONTE: O autor (2014)

2.2.3 O Teorema de Cover - Separabilidade de Padrões

Quando uma rede (RBF) desempenha uma tarefa complexa para classificar padrões, a solução é encontrada pela sua transformação não-linear para um espaço de alta dimensão. O *Teorema de Cover sobre a separabilidade de padrões* justifica esse

processo e pode ser formulado como a seguir (HAYKIN, 2001):

Teorema 1 (Cover) . *Um problema complexo de classificação de padrões disposto não-linearmente em um espaço de alta dimensão tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade.*

O teorema de Cover sobre a separabilidade de padrões engloba dois itens básicos:

1. A formulação não-linear da função oculta.
2. A alta dimensionalidade do espaço oculto em relação ao espaço de entrada, esta dimensionalidade é determinada pelo número de unidades na camada oculta.

2.2.4 Interpolação

Ao resolver um problema de classificação não-linearmente separável, há um ganho pelo mapeamento do espaço de entrada em um novo espaço de dimensão alta. Usa-se então um mapeamento não-linear para transformar um problema de classificação não-linear difícil em um mais fácil que envolve filtragem linear (HAYKIN, 2001).

Considere uma rede alimentada adiante (*feedforward*) com uma camada de entrada, uma oculta e uma de saída com apenas uma unidade. Essa escolha de uma única saída é proposital e simplifica a exposição sem perda de generalidade. A rede realiza um mapeamento não-linear da entrada para o espaço oculto, seguido de um mapeamento linear do espaço oculto para a saída. Seja m_0 a dimensão do espaço de entrada, então, globalmente a rede representa um espaço de entrada de dimensão m_0 em um de saída unidimensional:

$$s : \mathbb{R}^{m_0} \rightarrow \mathbb{R}^1. \quad (4)$$

Pode-se considerar o mapa s como uma *hipersuperfície* $\Gamma \subset \mathbb{R}^{m_0+1}$, sendo Γ um gráfico multidimensional da saída como função de entrada.

- O treinamento constitui a otimização de um ajuste de Γ , baseado nos dados conhecidos apresentados à rede como padrões de entrada-saída.
- A generalização é a interpolação entre os pontos de dados, sendo formada ao longo da superfície gerada pelo procedimento de ajuste.

Assim, através da teoria da *interpolação multivariada* em um espaço de alta dimensionalidade, o problema de interpolação pode ser formulado como (HAYKIN, 2001):

Dado um conjunto de N pontos diferentes $\{\mathbf{x}_i \in \mathbb{R}^{m_0} | i = 1, 2, \dots, N\}$ e um conjunto correspondente de N números reais $\{d_i \in \mathbb{R}^1 | i = 1, 2, \dots, N\}$, encontre uma função $F : \mathbb{R}^N \rightarrow \mathbb{R}^1$ que satisfaça a condição de interpolação:

$$F(\mathbf{x}_i) = d_i, \quad i = 1, 2, \dots, N. \quad (5)$$

Para a interpolação aqui especificada, a função F é treinada com todos os pontos dos dados de treinamento.

2.2.5 Fases da Rede RBF

A técnica de funções de base radial (RBF) escolhe uma função F que tem a seguinte forma:

$$F(\mathbf{x}) = \sum_{i=1}^N \omega_i \varphi(\|\mathbf{x} - \mathbf{x}_i\|) \quad (6)$$

onde $\{\varphi(\|\mathbf{x} - \mathbf{x}_i\|) | i = 1, 2, \dots, N\}$ é um conjunto de funções arbitrárias, chamadas de *funções de base radial*. Os dados conhecidos $\mathbf{x}_i \in \mathbb{R}^{m_0}, i = 1, 2, \dots, N$ são os centros das funções de base.

Inserindo as condições de interpolação da Eq. (5) em (6), obtemos um conjunto de equações lineares para coeficientes ou pesos desconhecidos $\{\omega_i\}$:

$$\begin{bmatrix} \varphi_{11} & \varphi_{12} & \dots & \varphi_{1N} \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ \varphi_{N1} & \varphi_{N2} & \dots & \varphi_{NN} \end{bmatrix} \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_N \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_N \end{bmatrix} \quad (7)$$

onde

$$\varphi_{ji} = \varphi(\|\mathbf{x}_j - \mathbf{x}_i\|), \quad (j, i) = 1, 2, \dots, N. \quad (8)$$

Considere

$$\mathbf{d} = [d_1, d_2, \dots, d_N]^T$$

$$\mathbf{w} = [\omega_1, \omega_2, \dots, \omega_N]^T,$$

o vetor \mathbf{d} representa o vetor das respostas desejadas, o vetor \mathbf{w} o vetor dos pesos lineares e N é o tamanho da amostra para o treinamento. Agora considere a matriz $\Phi_{N \times N}$ com elementos φ_{ji} :

$$\Phi = \{\varphi_{ji} | (j, i) = 1, 2, \dots, N\}. \quad (9)$$

A matriz Φ recebe o nome de *matriz de interpolação*, que tem na Eq. (10) sua versão compacta

$$\Phi \mathbf{w} = \mathbf{x}. \quad (10)$$

Assume-se que a matriz de interpolação seja não-singular, existindo a inversa Φ^{-1} , resolve-se a Eq. (10) para \mathbf{w}

$$\mathbf{w} = \Phi^{-1} \mathbf{x}. \quad (11)$$

2.2.6 Funções de Base Radial

A pergunta crucial da seção anterior é: como garantir que a matriz de interpolação seja inversível? Verifica-se que para uma gama de funções de base radial e com certas condições, a resposta é dada pelo Teorema de Micchelli a seguir (HAYKIN, 2001).

Teorema 2 (Micchelli) *Considere que $\{\mathbf{x}_i\}_{i=1}^N$ seja um conjunto de pontos distintos em \mathbb{R}^{m_0} . Então, a matriz de interpolação $\Phi_{N \times N}$, cujo elemento ji é $\varphi_{ji} = \varphi(\|\mathbf{x}_j - \mathbf{x}_i\|)$, é não-singular.*

Existem várias funções de base radial que seguem o teorema de Micchelli, fala-se em especial sobre as funções gaussianas:

$$\varphi_j(t) = \exp\left(\frac{1}{2\sigma_j^2(t)}\|x_j(t) - c_j(t)\|^2\right) \text{ para um } \sigma_j > 0 \text{ e } \|x_j(t) - c_j(t)\| \in \mathbb{R} \quad (12)$$

onde, σ_j é o raio da função de base do neurônio j e $c_j(t)$ é o centro correspondente ao neurônio j . A saída da rede é uma combinação linear destas funções gaussianas.

As funções de base radial serão não-singulares se os pontos c_j forem todos distintos. Essa é a única exigência para garantir a existência da inversa da matriz de interpolação Φ .

2.2.7 Centros da Rede RBF

Uma forma comum e eficaz de se determinar os centros c das funções de base, é através de um algoritmo de formação de agrupamentos (*clusters*) (BARRETO, 2007), aqui utiliza-se um algoritmo conhecido como WTA (*Winner-take-all network*), descrito a seguir:

- **Passo 1:** Definir o número de funções de base radial (q) e a taxa de aprendizagem η , com $0 < \eta < 1$.
- **Passo 2:** Iniciar com valores aleatórios os centros $c_i, i = 1, \dots, q$.
- **Passo 3:** Fazer $t = 1$.
- **Passo 4:** Enquanto $t \leq N$,
 - **Passo 4.1:** Selecionar de forma aleatória e sem reposição o padrão de entrada $x(t)$.
 - **Passo 4.2:** Determinar o índice do centro mais próximo de $x(t)$

$$i^*(t) = \arg \min_{\forall i} \|x(i) - c(t)\|. \quad (13)$$

- **Passo 4.3:** Aplicar a regra de aprendizagem não supervisionada:

$$c_i(t+1) = \begin{cases} c_i(t) + \eta[x(t) - c_i(t)], & \text{se } i = i^*(t) \\ c_i(t), & \text{caso contrário} \end{cases} \quad (14)$$

- **Passo 4.4:** Fazer $t = t + 1$.
- **Passo 5:** Verificar se o critério de parada é atendido. Se sim, finalizar o treinamento, caso contrário, retornar ao Passo 3.

É importante notar que na regra de aprendizagem da rede WTA cada iteração só atualiza o centro mais próximo do padrão de entrada atual. Quanto ao critério de parada, existem duas possibilidades: (1) a variação do erro de quantização em função da iteração for pequena, ou (2) quando o número máximo de iterações for atingido. O erro de quantização é calculado como a seguir:

$$E_q = \frac{\sum_{t=1}^N \|x(t) - c_{i^*}(t)\|^2}{N}. \quad (15)$$

2.2.8 Raio da Função de Base

Com os centros das funções de base já determinados, o próximo passo é determinar os raios (σ_i) das funções. Se o raio for muito alto, acontece a suavidade da resposta da rede, porém, pode ocorrer excesso de generalização. Se o raio for muito pequeno, a precisão é elevada, mas apenas para os casos onde $x(t) \approx c_i$. Neste caso, a generalização da rede não é boa. Usa-se então uma técnica para determinar σ_i , que pode ser encontrada no trabalho de Barreto (2007).

Cada neurônio da camada oculta usa um raio próprio, que tem seu valor definido como metade da distância entre os centros do neurônio i e o centro mais próximo. ou seja,

$$\sigma_i = \frac{d_{\min}(c_i, c_j)}{2}, \quad \forall i \neq j \quad (16)$$

onde $d_{\min}(c_i, c_j) = \min_{\forall i \neq j} \{\|c_i - c_j\|\}$.

2.2.9 Critério de Parada

Segundo Lima e Guerreiro (2011) os pesos das conexões entre a camada oculta e a camada de saída podem ser determinados de duas formas. A primeira é através de um treinamento iterativo pela regra delta de correção de erro utilizada na rede MLP e descrita ao longo da Seção 2.3. Neste caso, o critério de parada utilizado pode ser o número máximo de iterações e a análise da variação do erro a cada iteração. A segunda forma, é o método utilizado neste trabalho para o treinamento da rede RBF, o da matriz pseudo-inversa já detalhado nesta Seção. Este método obtém diretamente os pesos, ou seja, não possui iterações ou critérios de parada.

2.3 PERCEPTRON DE MÚLTIPLAS CAMADAS

Os perceptrons de múltiplas camadas (*Multi-Layer Perceptron* - MLP) têm sido aplicados com sucesso em diversos problemas e áreas de pesquisa, através de um treinamento supervisionado e um algoritmo conhecido, o algoritmo de retropropagação (*back-propagation*) baseado na regra de aprendizagem pela correção do erro. Essa aprendizagem é basicamente composta por dois passos: um passo para frente, chamado de *propagação*, e um para trás, *retropropagação*. No primeiro passo, um padrão de entrada é aplicado aos nós da rede e seu efeito se propaga camada por camada. Por fim, a saída é produzida com a resposta real da rede. No decorrer do passo de propagação, os pesos permanecem fixos, e durante o passo para trás os pesos são todos ajustados de acordo com a regra de correção do erro. De forma específica, a resposta da rede é subtraída da resposta desejada para produzir um sinal de erro. Então, na retropropagação os pesos são ajustados fazendo com que a resposta real da rede se aproxime da resposta desejada (HAYKIN, 2001).

Na literatura trabalhos envolvendo dados meteorológicos e as redes MLP podem ser encontrados, e são motivadores quando se fala em desempenho e precisão das redes neurais artificiais aplicadas na área em questão. Na pesquisa descrita em Duncan *et al.* (2011) a rede MLP foi utilizada para prever enchentes em tempo real, baseada

em dados de radar meteorológico e pluviômetros. Os dados de entrada foram os de chuva medidos por esses dois equipamentos. A rede também foi utilizada para a previsão imediata de chuvas. Os resultados da pesquisa afirmaram que a rede neural pode proporcionar uma melhoria significativa com relação a velocidade sobre os simuladores hidráulicos convencionais, além de apresentar a oportunidade de gerar alarmes automatizados para inundações sem ser computacionalmente custoso.

No trabalho de Deshpande (2012) a rede MLP é proposta como uma ferramenta para prever chuvas de séries temporais tomando como base para comparação o erro médio quadrático e o erro médio quadrático normalizado. A rede MLP também foi comparada com outras redes, SOFM (*Self Organized Feature Map*) e RNN (*Recurrent neural network*), e os resultados foram favoráveis à rede MLP indicando os menores erros para cada índice.

Em outro trabalho, desenvolvido por Sousa e Sousa (2010) procurou-se minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos, fazendo a modelagem da relação não-linear entre chuva e vazão na bacia do rio Pi-ancó, na Paraíba. Para tal modelagem, utilizou-se a rede MLP, avaliando sua capacidade de modelar o processo de chuva-vazão e levando em consideração durante o treinamento a influência da arquitetura da rede e da inicialização dos pesos. No final do treinamento escolheu-se a melhor arquitetura com valores para o coeficiente de determinação, de eficiência e erro da estimativa de 92%, 77% e 8.29, respectivamente.

Na pesquisa desenvolvida por Oliveira *et al.* (2006) o objetivo foi estudar a variabilidade do nível do mar observado na Baía de Paranaguá-PR e também, fazer a predição dessas influências. Conhecendo a complexidade de formular modelos matemáticos que traduzam tal evento, os autores desenvolveram uma rede neural artificial do tipo MLP. Utilizaram-se séries horárias do nível do mar, direção e velocidade do vento e pressão atmosférica. A RNA foi projetada em função das correlações entre as variáveis de entrada (atmosféricas) e a variável de saída (maré meteorológica), apresentando um desempenho em torno de 99% para predições de 6h e 12h. As predi-

ções para 18h e 24h ficaram em torno de 91% e 80%, respectivamente. Os resultados sugerem a utilização do modelo como um complemento à previsão de marés.

2.3.1 Características da rede MLP

1. O modelo de cada neurônio inclui uma função de ativação não-linear, enfatizando que a função é diferenciável em qualquer ponto.
2. A rede possui uma ou mais camadas de neurônios ocultos, que não compõem a parte da entrada ou saída da rede.
3. Alto grau de conectividade, determinado pelas ligações da rede.

Combinando essas características com a habilidade de aprender através do treinamento, tem-se o poder computacional da rede MLP.

A Figura 4 apresenta a arquitetura de uma rede MLP com uma camada de saída e uma oculta. A rede exibida aqui é totalmente conectada, significando que um neurônio qualquer está ligado a todos os nós da camada anterior.

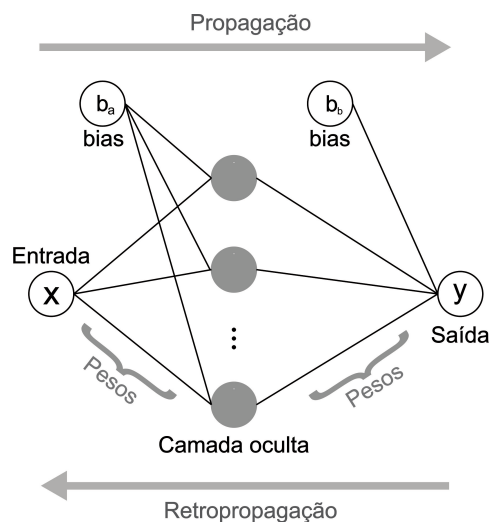


FIGURA 4: Arquitetura de uma rede neural MLP

FONTE: O autor (2014)

Cada nó de uma camada oculta ou de saída é desenvolvido para cumprir dois cálculos (HAYKIN, 2001):

1. O cálculo do sinal funcional que aparece na saída de um neurônio, que é uma função não linear do sinal de entrada e dos pesos relacionados com aquele neurônio.
2. O cálculo de uma estimativa do vetor gradiente, necessário para a retropropagação pela rede.

Antes de apresentar o algoritmo de retropropagação, verifica-se a seguinte notação:

- Os índices i, j , e k referenciam neurônios diferentes; o neurônio j se encontra uma camada à direita do neurônio i , e o neurônio k à direita do neurônio j , quando o neurônio j é de uma camada oculta.
- Na iteração n , o n -ésimo padrão é apresentado à rede.
- $\varepsilon(n)$ se refere à soma instantânea dos erros quadráticos na iteração n .
- $e_j(n)$ se refere ao sinal do erro na saída do neurônio j .
- $d_j(n)$ se refere à resposta desejada para o neurônio j .
- $y_j(n)$ se refere ao sinal funcional que aparece na saída do neurônio j .
- $\omega_{ji}(n)$ representa o peso conectando a saída do neurônio i à entrada do neurônio j , na iteração n . A correção aplicada a este peso é representada por $\Delta\omega_{ji}(n)$.
- $v_j(n)$ representa a soma ponderada de todas as entradas acrescida do bias do neurônio j .
- $\varphi_j(\cdot)$ representa a função de ativação que descreve a relação de entrada-saída na não-linearidade associada ao neurônio j .
- O bias aplicado ao neurônio j é representado por b_j ; seu efeito é representado por um peso $\omega_{j0} = b_j$ vinculado a uma entrada fixa “+1”.
- O i -ésimo termo do padrão de entrada é representado por $x_i(n)$.

- O k -ésimo termo do padrão de saída é representado por $o_k(n)$.
- A taxa de aprendizagem é representada por η .
- m_l representa o número de nós da camada l ; $l = 0, 1, \dots, L$, onde L é a profundidade da rede. Dessa forma, m_0 representa o tamanho da camada de entrada, m_L representa o tamanho da camada de saída e os outros representam as camadas intermediárias.

2.3.2 O Algoritmo da Rede MLP

O sinal de erro da saída do neurônio j , na iteração n , é

$$e_j(n) = d_j(n) - y_j(n). \quad (17)$$

Define-se o valor instantâneo do erro para o neurônio j como $\frac{1}{2}e_j^2(n)$. O valor instantâneo $\varepsilon(n)$ total do erro é encontrado somando-se os termos $\frac{1}{2}e_j^2(n)$ de todos os neurônios da camada de saída

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (18)$$

onde C inclui todos os neurônios da camada de saída. Seja N o número total de padrões do conjunto de treinamento. A média do erro quadrático pode ser obtida somando-se os $\varepsilon(n)$ e normalizando em relação a N , como a seguir

$$\varepsilon_{med} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n). \quad (19)$$

O erro $\varepsilon(n)$ e consequentemente a média ε_{med} , é uma função dos pesos e bias da rede. Para um certo conjunto de treinamento, ε_{med} é a função de custo medindo o desempenho na aprendizagem. A aprendizagem deve ajustar os parâmetros livres (pesos e bias) minimizando ε_{med} . Para tal minimização, considera-se um método no qual os pesos são atualizados de padrão em padrão até completar uma apresentação inteira do conjunto de treinamento. Os novos pesos são calculados conforme os erros de cada padrão. A média aritmética destes erros individuais sobre o conjunto de

treinamento é uma estimativa da alteração real dos pesos baseada na minimização da função ε_{med} sobre todo o conjunto de treinamento.

Considere um neurônio j sendo alimentado por um conjunto de neurônios de uma camada à sua esquerda. O campo local induzido $v_j(n)$ produzido na entrada da função de ativação é:

$$v_j(n) = \sum_{i=0}^m \omega_{ji}(n)y_i(n) \quad (20)$$

onde m é o total de entradas (com exceção do bias) no neurônio j . O peso ω_{j0} que corresponde à entrada $y_0 = +1$ é igual ao b_j aplicado ao neurônio j . Então, $y_j(n)$ aparente na saída do neurônio j na iteração n é:

$$y_j(n) = \varphi_j(v_j(n)). \quad (21)$$

O algoritmo de retropropagação aplica ao peso $\omega_{ji}(n)$, uma correção $\Delta\omega_{ji}(n)$ dada por:

$$\Delta\omega_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} \quad (22)$$

sendo η a taxa de aprendizagem do algoritmo. O sinal negativo na Eq. (22) indica a descida do gradiente em busca de uma mudança nos pesos que reduza $\varepsilon(n)$. A Eq. (22) pode ser escrita como:

$$\Delta\omega_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (23)$$

e $\delta_j(n)$ é o gradiente local, definido por:

$$\delta_j(n) = e_j(n) \varphi_j'(v_j(n)). \quad (24)$$

O gradiente local aponta as mudanças que devem ser feitas nos pesos.

Neste ambiente pode-se identificar dois casos, dependendo do local que o neurônio j está na rede. No primeiro caso, trata-se o neurônio j como sendo de saída. No segundo, o neurônio j é um neurônio oculto.

O neurônio j é de saída

Estando o neurônio j contido na camada de saída, ele é munido com uma resposta

desejada. Pode-se usar a Eq. (17) para calcular $e_j(n)$ referente a este neurônio. Determinando-se $e_j(n)$, calcula-se o gradiente local com a Eq. (24).

O neurônio j é oculto

Com o neurônio j sendo de uma camada oculta, não tem-se uma resposta desejada. Logo, o sinal de erro deve ser determinado recursivamente, utilizando os sinais de erro de todos os neurônios aos quais j está conectado. De acordo com a Eq. (24), o gradiente local pode ser redefinido como:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) \omega_{kj}(n) \quad (25)$$

onde k referencia um neurônio de saída.

O fator $\varphi'_j(v_j(n))$ no cálculo do $\delta_j(n)$ na Eq. (25) depende apenas da função de ativação relacionada ao neurônio oculto j . O somatório sobre k depende dos $\delta_k(n)$, requerendo conhecimento dos sinais de erro $e_k(n)$, para todos os neurônios da camada à direita do neurônio j , e dos termos ω_{kj} , que são os pesos associados às conexões.

Voltando as relações determinadas anteriormente para o algoritmo de retropropagação. Primeiramente, a correção $\Delta\omega_{ji}(n)$ sobre o peso conectando o neurônio i ao j é definida pela regra delta (HAYKIN, 2001):

$$\begin{pmatrix} \text{Correção} \\ \text{de peso} \\ \Delta\omega_{ji}(n) \end{pmatrix} = \begin{pmatrix} \text{Parâmetros da} \\ \text{taxa de aprendizagem} \\ \eta \end{pmatrix} \cdot \begin{pmatrix} \text{Gradiente} \\ \text{local} \\ \delta_j(n) \end{pmatrix} \cdot \begin{pmatrix} \text{Sinal de entrada} \\ \text{do neurônio } j \\ y_i(n) \end{pmatrix}. \quad (26)$$

Segundo, a dependência sobre o gradiente local $\delta_j(n)$ se o neurônio j é da camada de saída ou de alguma camada oculta:

1. Se o neurônio j é de saída, $\delta_j(n)$ é o produto de $\varphi'_j(v_j(n))$ pelo sinal do erro $e_j(n)$.
2. Se o neurônio j é oculto, $\delta_j(n)$ é o produto de $\varphi'_j(v_j(n))$ pela soma ponderada dos gradientes locais calculados para os neurônios na camada seguinte.

2.3.3 Função de Ativação

Para calcular o δ de cada nó da rede MLP, é necessário ter conhecimento da derivada da função $\varphi(\cdot)$ relacionada àquele neurônio. Então, precisa-se que $\varphi(\cdot)$ seja contínua. A função não-linear e continuamente diferenciável normalmente utilizada em redes MLPs é a sigmóide ou logística descrita a seguir (HAYKIN, 2001):

Função Logística. Definida por:

$$\varphi_j(v_j(n)) = \frac{1}{1 + \exp(-av_j(n))} \quad a > 0 \quad \text{e} \quad -\infty < v_j(n) < \infty. \quad (27)$$

De acordo com esta não-linearidade, a amplitude da saída se restringe ao intervalo $0 \leq y_j \leq 1$. Derivando a Eq. (27) em relação a $v_j(n)$, tem-se:

$$\varphi'_j(v_j(n)) = \frac{a \exp(-av_j(n))}{[1 + \exp(-av_j(n))]^2}. \quad (28)$$

Tendo $y_j(n) = \varphi_j(v_j(n))$, é possível eliminar o termo $\exp(-av_j(n))$ da Eq. (28) e escrever a derivada como:

$$\varphi'_j(v_j(n)) = ay_j(n)[1 - y_j(n)]. \quad (29)$$

No caso de um neurônio j na camada de saída, tem-se $y_j(n) = o_j(n)$, e pode-se expressar o gradiente local como:

$$\delta_j(n) = e_j(n) \varphi'_j(av_j(n)) = a[d_j(n) - o_j(n)]o_j(n)[1 - o_j(n)]. \quad (30)$$

Em outro caso, se o neurônio j for de alguma camada oculta, expressa-se o gradiente local como:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) \omega_{kj}(n) = ay_j(n)[1 - y_j(n)] \sum_k \delta_k(n) \omega_{kj}(n). \quad (31)$$

São algumas as funções de ativação utilizadas nas redes MLP, como: a função passo, a função linear, a logística e a tangente hiperbólica. Escolheu-se a logística por ser não-linear e retornar valores positivos, podendo assim, modelar melhor os

resultados como as relações ZR.

2.3.4 Critério de Parada

Para estabelecer um critério de parada, procura-se por um mínimo global ou local na superfície de erro. Dessa forma, suponha que \mathbf{w}^* seja um vetor de pesos e represente um mínimo, global ou local. A condição necessária para que \mathbf{w}^* de fato seja mínimo é que o gradiente $\mathbf{g}(\mathbf{w})$ da superfície em relação ao peso \mathbf{w} seja zero para $\mathbf{w}=\mathbf{w}^*$. Pode-se então, formular um critério de convergência para a aprendizagem por retropropagação, como a seguir (HAYKIN, 2001):

Considera-se que o algoritmo de retropropagação tenha convergido quando a norma euclidiana do vetor gradiente alcançar um limiar suficientemente pequeno.

Este critério pode causar problemas quando procura-se por tentativas bem-sucedidas, pois os tempos de aprendizagem podem ser longos. Além de precisar calcular o vetor gradiente.

Um critério diferente pode ser apresentado, visto que a função de medida de erro $\varepsilon_{med}(\mathbf{w})$ é estacionária em $\mathbf{w}=\mathbf{w}^*$, é o seguinte:

Considera-se que o algoritmo de retropropagação tenha convergido quando a taxa absoluta de variação do erro médio quadrático por iteração for suficientemente pequena.

Esta taxa do erro médio quadrático normalmente é considerada pequena se estiver no intervalo de 0.1 a 1 por cento. Neste trabalho utiliza-se o valor de 1 por cento, ou seja, 10^{-2} .

2.4 CONCEITOS METEOROLÓGICOS

No meio acadêmico e operacional de meteorologia distinguem-se estimativa e previsão da seguinte forma:

- **Estimativa:** é uma inferência de uma medição por meio de sensor remoto como radares, satélites, etc. Considera-se que o pluviômetro mede a chuva diretamente pelo armazenamento da água precipitada no recipiente do sensor. Quando a medição é indireta, por exemplo, pelo retorno do sinal eletromagnético de um radar ou pela emissividade da água da nuvem detectada por um satélite dizemos que é uma estimativa do valor de chuva em superfície. Além disso os sensores remotos detectam a água provável que chegaria à superfície enquanto os pluviômetros detectam o próprio volume atingido à 1.5m de altura do solo. Quando se fala em estimativa é algo que já ocorreu, ou seja, $P(t = 0)$.
- **Previsão:** usando estimativas podemos utilizar técnicas numéricas, estatísticas ou de extrapolação para prever a quantidade de chuva em um determinado lugar. Isto é, a chuva ainda não ocorreu, $P(t > 0)$.

2.4.1 Refletividade

No início da história das aplicações do radar meteorológico, a variável Refletividade do Radar foi definida em função do retroespalhamento total de uma área transversal de um alvo (nuvem). Segundo Rinehart (2004) a refletividade representada pelo símbolo η é definida como:

$$\eta = \sum_{Unid.Volume} \sigma_1 \quad (32)$$

onde o somatório é feito sobre todos os alvos individualmente em uma unidade de volume no espaço. Desde que o retroespalhamento da área transversal tenha unidade de área (por exemplo, cm^2) e o volume tenha unidades de volume, refletividade do radar η tipicamente tem unidade de cm^{-1} . Refletividade do radar é uma variável intensiva, em vez de uma variável extensiva. $\sum \sigma_1$ é o total de todos os alvos individuais do volume da amostra, mas η é normalizado para uma unidade de volume.

É comum a utilização de cores específicas para a visualização de uma imagem de refletividade, cores quentes representam valores elevados, enquanto cores frias simbolizam valores intermediários e baixos, conforme mostra a Figura 5.




FIGURA 5: Imagem de refletividade do radar (dia 20/06/2013 às 12:01hrs)

FONTE: O autor (2014)

2.4.2 Equação do Radar

RADAR é uma sigla que significa “RADio Detection And Ranging.” Esta é uma técnica de sensoriamento remoto ativo, pois envolve um transmissor enviando pulsos de radiação eletromagnética, e depois mede a quantidade de energia refletida ou espalhada que volta para a antena do radar. Segundo Muller (2013) este processo pode ser quantificado na equação do radar. A equação do radar é dada a seguir:

$$p_r = \frac{\pi^3 p_t g^2 \theta \phi h |K|^2 l z}{1024 \ln(2) \lambda^2 r^2} \quad (33)$$

onde,

p_t = energia transmitida pelo radar (watts).

p_r = energia recebida de volta pelo radar (watts).

g = razão entre a potência no eixo do feixe de energia a partir de uma antena isotrópica no mesmo ponto.

θ = largura do feixe horizontal (radianos).

φ = altura do feixe vertical (radianos).

h = comprimento de pulso (metros).

$|K|^2$ = constante dielétrica para hidrometeoros; normalmente com valor 0,93 para água líquida e 0,197 para gelo.

l = fator de perda para atenuação do feixe de radar, varia entre 0 e 1, geralmente perto de 1.

λ = comprimento de onda do pulso do radar (metros).

r = distância do alvo, ou seja, distância a um volume de precipitação que reflete o pulso originalmente transmitido de volta para o radar.

z = fator de refletividade do radar que pode ser expresso por $z = \sum_{vol} D^6$. Onde D é o diâmetro da gota e o somatório é feito sobre o total número de gotas de tamanhos variados dentro de uma unidade de volume no feixe, na equação é multiplicado pelo volume do radar (definido pela largura e altura do feixe, o comprimento do pulso e a distância do radar).

Para ilustrar, considere na Figura 6 uma seção de 1 metro cúbico do feixe de radar que contém uma distribuição de gotas de chuva de tamanhos diferentes, por exemplo, 19 gotas, cada uma identificada com um número de 1 a 19.




FIGURA 6: Exemplo de 1 metro cúbico de feixe de radar com uma distribuição de gotas de tamanhos diferentes.

FONTE: Muller (2013)

O somatório para o fator de refletividade do radar z , pode ser expandido da seguinte forma:

$$z = D_1^6 + D_2^6 + D_3^6 + \dots + D_{18}^6 + D_{19}^6. \quad (34)$$

Nota-se que z é uma propriedade inerente da distribuição do tamanho da gota e não é dependente do radar. Outro ponto importante é que z é proporcional à sexta potência dos tamanhos de gota, logo, gotas maiores causam grandes valores de refletividade quando comparadas com gotas pequenas.

A equação do radar pode ser escrita com uma pequena mudança:

$$p_r = \frac{\pi^3 p_t g^2 \theta \varphi c t |K|^2 l z}{1024 \ln(2) \lambda^2 r^2}, \quad (35)$$

onde h , o comprimento do pulso em unidades de distância, é substituído por c , a velocidade da radiação eletromagnética, e t , a duração do pulso.

Contudo, a distribuição do tamanho da gota no volume medido é desconhecida. Portanto, calcula-se o fator de refletividade do radar z , pela energia retornada, p_r , resolvendo a Eq. (35) para z :

$$z = \frac{p_r 1024 \ln(2) \lambda^2 r^2}{\pi^3 p_t g^2 \theta \varphi c t |K|^2 l}. \quad (36)$$

Pode-se combinar as variáveis conhecidas (específicas do radar), por exemplo, a largura do feixe, os valores numéricos e os valores já assumidos ($|K|^2$ assume o valor de água líquida, 0.93 já que não sabemos a priori que tipo de precipitação é, mesmo que possa realmente ser neve ou granizo, e l é geralmente assumido como 1) na equação acima em uma única constante c_1 , para chegar à expressão simplificada:

$$z = c_1 p_r r^2. \quad (37)$$

Dado um radar e sua configuração, as únicas variáveis independentes neste problema são: a quantidade de energia retornada p_r , e a distância r , para os ecos que não são medidos pelo radar. Assim, o fator de refletividade do radar z , pode ser calculado a partir desses itens conhecidos em c_1 combinados com p_r e r .

Como o fator de refletividade do radar abrange um grande intervalo de magnitudes de $0,0001mm^6/m^3$ para nevoeiro, até $36.000.000mm^6/m^3$ para granizo do tamanho de uma bola de tênis, é geralmente expresso em decibéis (dB) de refletividade ou em dBZ da seguinte forma:

$$Z = 10\log_{10} \left(\frac{z}{1mm^6/m^3} \right), \quad (38)$$

aqui é importante distinguir Z de z .

A transformação logarítmica aqui é usada para comprimir intervalos de grandes magnitudes em uma escala de valores mais compreensíveis.

2.4.3 PPI e CAPPI

PPI (*Plan Position Indicator*) é uma forma de visualizar as variáveis medidas pelo radar. Em geral, as variáveis são plotadas em um plano com centro na posição do radar. Cada ângulo de elevação possui um plano fixo. Assim, é importante observar que, quando a distância em relação ao radar aumenta, a altura do feixe em relação ao solo também aumenta (DAMIAN, 2011).

A Figura 7 apresenta a varredura do radar em um determinado ângulo com plano fixo. A Figura 8 ilustra como a altura do feixe aumenta conforme se distancia do radar.




FIGURA 7: Ilustração PPI

FONTE: MeteoPT (2013)




FIGURA 8: Elevação do feixe

FONTE: MeteoPT (2013)

CAPPI (*Constant Altitude Plan Position Indicator*) é o modo de visualizar uma variável a uma altura fixa. Diferentemente do PPI, em uma imagem de CAPPI, os pontos estão na mesma altitude independentemente da distância do radar. Na Figura 9 é fácil visualizar o CAPPI como um plano constante que corta os níveis de PPI.




FIGURA 9: Ilustração CAPPI

FONTE: MeteoPT (2013)

Como é necessária a presença de refletividade no ponto exato sobre os pluviômetros e a área com informações de refletividade do radar é maior em leituras PPI do que em elevadas altitudes de CAPPI, decidiu-se utilizar o método PPI na primeira elevação para a coleta dos dados. Também atentou-se para o fato de os dados desta elevação serem os mais próximos da superfície terrestre e por consequência, mais próximos dos pluviômetros.

2.4.4 Chuva

A precipitação pode ser medida pelo volume armazenado em um recipiente no tempo (Capítulo 3, Seção 3.2) ou pela detecção da distribuição de gotas num determinado volume, ou seja, um número de gotas N com um determinado diâmetro D . A refletividade (Capítulo 2, Seção 2.4.1) medida pelo radar meteorológico é proporcional à distribuição de gotas e por isso, pode-se estimar a chuva por radar fazendo a relação entre a refletividade e a distribuição de gotas. Como o volume de chuva é proporcional à distribuição de gotas, esse volume pode ser inferido diretamente a partir da refletividade medida pelo radar.

Chuva é facilmente detectada pela maioria dos radares e pode vir em uma grande variedade de intensidades, de leve garoa até ofuscamento causado por tempestades severas. A medição da chuva pelo radar é um dos usos quantitativos mais importantes do radar (RINEHART, 2004).

2.4.5 Distribuição do Tamanho das Gotas

A distribuição do tamanho de gotas é importante na determinação do fator de refletividade Z , o conteúdo de água M , e a taxa de precipitação R . O tamanho da distribuição é a densidade de volume por unidade do diâmetro (m^{-4}). A distribuição de alguns tipos de precipitações, como as gotas de chuva, gotas de nuvem e pedras de granizo foram medidas e teoricamente calculadas (DOVIÁK; ZRNIĆ, 1993). Gotículas de nuvem são normalmente formadas pela condensação de vapor de água. Super saturação (umidade $> 100\%$) é necessária para condensar o vapor de água no ar puro, mas a condensação é muito lenta para produzir gotas precipitantes (chuva) dentro do tempo de vida das nuvens. A coalescência (processo principal na formação de chuva) de gotas em colisão é necessária para o crescimento rápido das gotas de chuva.

Gotas com diâmetro $D < 0.35$ milímetros são essencialmente esféricas, e gotas até $1mm$ de diâmetro têm forma aproximada de uma esfera achatada. Gotas maiores ($D \geq 4mm$) têm uma elevada probabilidade de se romper em fragmentos menores.

2.4.6 Distribuição do Tamanho de Gotas de Nuvem

Considera-se uma gota de água em um ambiente de vapor a uma pressão tal que o equilíbrio é alcançado entre a taxa de evaporação das moléculas de água na gota e a taxa de condensação das moléculas que rodeiam a gota. A pressão de vapor necessária para atingir este equilíbrio depende exponencialmente do inverso do diâmetro (D^{-1}) da gota, gotas menores têm pressão de vapor muito mais elevada. Ar acima de uma superfície plana ($D \rightarrow \infty$) de água tem umidade $H = 100\%$ se o equilíbrio é estabelecido. Assim, uma gotícula introduzida em uma atmosfera quase saturada ($H = 100\%$) irá evaporar.

O diâmetro das gotas em que é atingido o equilíbrio é um valor crítico, pois gotas maiores continuam a crescer e gotas menores evaporam, enquanto a pressão do vapor é mantida. No ar puro, o vapor de água não irá condensar até que o ar torne-se supersaturado centenas de vezes mais. Neste estado altamente saturado, a condensação ocorre em íons produzidos pela passagem de partículas cósmicas.

Um ambiente puro raramente existe na atmosfera por causa de inúmeros aerossóis, naturais e manufaturados, que servem como centro de condensação (ou núcleos de condensação). Estes núcleos requerem uma pressão de vapor consideravelmente baixa para atingir o equilíbrio de gotas de água de mesmo diâmetro e, portanto, eles impedem que grandes supersaturações ocorram no ambiente natural.

Nem todos os núcleos de condensação são partículas sólidas. Alguns são líquidos higroscópicos, como ácido sulfúrico. Alguns têm a propriedade de condensar o vapor de água a uma pressão inferior a saturação (isto é, $H = 100\%$). Como a gota cresce em aerossóis, quer seja sólido ou líquido, o aumento do volume de gota protege da influência do núcleo, então a gota se parece mais com água pura. O vapor de pressão é necessário para um crescimento contínuo e o alcance das gotas à um tamanho de equilíbrio. Se $H < 100\%$, as gotas nunca atingem tamanhos necessários para formar nuvens (isto é, diâmetro da gota $\geq 5\mu m$), embora possam contribuir para a neblina, o que provoca uma diminuição moderada da visibilidade. Se gotas atingem o diâmetro

crítico e $H \geq 100\%$, em seguida, nuvens são formadas e gotas de nuvens podem continuar a crescer até o tamanho de precipitação. Contudo, muitas gotas competem no reservatório de vapor e diminui a saturação, então o crescimento de gotículas é restrito.

Agora considera-se uma parcela crescente de ar úmido. Gotas imediatamente começam a se formar em torno dos núcleos de condensação quando a parcela de ar, levantada por convecção, é levada abaixo de sua temperatura de ponto de orvalho (ou seja, a temperatura à qual o vapor de água começa a condensar). Núcleos mais eficientes permitem que gotas cresçam mais rapidamente, e quando a umidade é acessível pela corrente de ar a uma taxa igual a taxa à qual ele está a ser condensado sobre os núcleos, a concentração de gotas de nuvem é igual à concentração de núcleos ativados. O ar é supersaturado neste ponto, mas posteriormente a supersaturação diminui muito rapidamente para um estado quase estacionário, em que a taxa de condensação é muito próxima em relação a corrente de ar ascendente.

2.4.7 Distribuição do Tamanho de Gotas de Chuva

Gotas de água geralmente não se aderem em colisões, mas se rebatem. Mas, quando um pouco eletrificadas, passam a se unir em colisões. Assim, pequenas gotas são perdidas e grandes são criadas, fazendo a quantidade diminuir. O crescimento das grandes gotas e a perda das pequenas é equilibrado por gotas que se rompem quando atingem grandes dimensões. A probabilidade de ruptura aumenta exponencialmente com o diâmetro da gota (DOVIÁK; ZRNIĆ, 1993). Por exemplo, o tempo de vida de uma gota de $7.5mm$ verifica-se ser $10s$. Uma distribuição de tamanhos de gota de chuva exponencial foi observada por Marshall e Palmer (1948), que utilizou papel de filtro para medir diretamente a densidade de diâmetros de gota na superfície.

É interessante notar que, para os dados de Marshall-Palmer, a distribuição do tamanho de gota N_D tem a tendência de achatar gotas de diâmetro pequeno. Isto é consistente com as observações de Laws e Parsons (1943), cujo os dados (Figura 10)

mostram, além disso, um aumento rápido no N_D para gotas menores.

Os parâmetros para a distribuição de Marshall-Palmer são:

$$N_D = N_0 e^{-\lambda D}, \quad (39)$$

$$\lambda = 4.1 R^{-0.21} \text{ mm}^{-1}, \quad (40)$$

$$N_0 = 8 \times 10^3 \text{ m}^{-3} \text{ mm}^{-1}, \quad (41)$$

onde R é a taxa de precipitação em milímetros por hora.




FIGURA 10: Função de distribuição do tamanho de gotas de Marshall e Palmer (linhas contínuas) comparada com o resultado de Laws e Parsons (linhas pontilhadas).

FONTE: Rinehart (2004)

Esta distribuição é amplamente utilizada para calcular taxas de precipitação a partir de medições do fator de refletividade, embora o real tamanho da gota varie muito dependendo da localização geográfica, tipo de tempestade, estação, e região dentro da tempestade. Para melhor representar as distribuições de tamanho de gota, propõe-se a distribuição geral de λ (DOVIAK; ZRNIĆ, 1993):

$$N_D = N_0 D^\mu \exp(-\lambda D), \quad (42)$$

em que o parâmetro μ pode ter valores entre -3 e 8 .

2.5 A RELAÇÃO ZR

A partir da discussão acima, o fato de que existe uma relação entre a taxa de chuva e a refletividade do radar é inegável. Distribuições de tamanho de gotas medidas experimentalmente foram extensivamente utilizadas para calcular ambos, refletividade do radar e taxa de chuva. Traçando a taxa de chuva contra a refletividade ou correlacionando ambas estatisticamente, pode-se determinar a relação entre esses dois parâmetros. A relação matemática mais usada entre refletividade e taxa de chuva é a relação empírica exponencial:

$$Z = aR^b, \quad (43)$$

onde R é a taxa de precipitação (mm/h), Z é o fator de refletividade do radar (mm^6/m^3), e a e b são constantes empíricas. Na realidade, mede-se a refletividade e então pode-se usá-la para calcular a taxa de chuva. A Eq (43) pode ser escrita de uma maneira mais apropriada, como: $R = \alpha Z^\beta$, onde α e β são constantes empíricas.

A relação ZR mais comumente utilizada é também desenvolvida por Marshall e Palmer (MARSHALL; PALMER, 1948), $Z = 200R^{1.6}$. Esta relação formou a base para muitas pesquisas e foi amplamente utilizada para calcular os valores de precipitação a partir dos dados de radar.

Radares podem fornecer informações quantitativas sobre a chuva com ótima resolução. O fator de refletividade do radar para chuva varia em média de $20dBZ(100mm^6/m^3)$ para mais de $50dBZ(10000mm^6/m^3)$. Refletividades maiores que $75dBZ$ são medidas em tempestades, e refletividades a partir de $55dBZ$ são frequentemente associadas com granizo. Já valores menores que $20dBZ$ são associados a garoas e chuvas fracas.

Na literatura existem trabalhos que abordam a relação ZR de uma forma parecida com a que se utiliza nesta dissertação, por exemplo, o estudo feito por Jaiswal, Uma e Santhakumaran (2009) tem o objetivo de mostrar que a relação ZR varia em intervalos de taxa de precipitação diferentes. Os autores afirmam que é possível obter modelos

de previsão com taxas menores que $50\text{mm}/h$ e maiores que $10\text{mm}/h$, já para valores acima de $50\text{mm}/h$ e entre $4\text{mm}/h$ e $10\text{mm}/h$ nenhum modelo se apresentou adequado, com exceção de casos particulares.

No trabalho de Tenório, Moraes e Kwon (2010), os autores procuraram determinar uma relação ZR para o radar meteorológico situado na costa leste do nordeste brasileiro. A precipitação de chuva foi separada em duas classes, valores da taxa $R < 10\text{mm}/h$ para estratiforme e $R > 10\text{mm}/h$ para convectiva. Os dados de precipitação foram coletados através de um disdrômetro¹. Valores interessantes foram encontrados para as constantes da relação ZR, para a classe estratiforme a constante a varia entre 134 – 269 e b entre 1,22 – 1,38. Para convectiva encontram-se os valores entre 31 – 136 para a e entre 1,4 – 1,9 para b . Segundo os autores os valores encontrados para o caso estratiforme estavam de acordo com os citados na literatura, já para o caso convectivo não.

Em outro trabalho, desenvolvido por Calheiros e Gomes (2011), trata-se de curvas de probabilidades cumulativas derivadas de dados de refletividade provenientes dos radares das cidade de Bauru-SP e Presidente Prudente-SP, operados pelo Instituto de Pesquisas Meteorológicas IPMet-UNESP-Bauru, com um período de dados de aproximadamente 18 anos. As curvas são classificadas por intervalos diários, que segundo os autores esses intervalos têm um impacto substancial em aplicações hidrológicas. Os dados da área de precipitação foram calculados de duas formas: uma única relação ZR e um conjunto de relações representando diferentes intervalos diários. Como conclusão, os autores dizem que a evolução anual das curvas de probabilidades cumulativas sugerem uma estabilidade da estrutura de precipitação. A estratificação sazonal foi identificada em todos os intervalos, com exceção de 0 – 6h. A atividade convectiva de pico de verão foi bem caracterizada pelo elevado grau de estratificação no intervalo de 14 – 19h. No período de chuvas críticas (dezembro - março), a estrati-

¹Disdrômetro é um instrumento que mede o diâmetro, a quantidade e a velocidade de queda das gotas de um pequeno volume. É quase um pluviômetro avançado. Pode ser ótico, onde o sensor mede o tamanho, a quantidade e a velocidade das gotas por meio da variação da frequência do sinal eletromagnético, ou de impacto, onde a massa da gota é estimada pelo impacto desta na superfície do sensor.

ficação é nítida para o intervalo de 14 – 19h, e apresenta grau menor para o intervalo de 19 – 24h. Os intervalos de 0 – 6h e 6 – 14h não mostraram resultados significativos. Para o período de secas, a estratificação é consistentemente menor. Por fim, curvas para o mês de janeiro (chuvoso) e agosto (seco) indicam que janeiro é significativamente mais representativo para o período chuvoso do que agosto é para o período seco.

Na pesquisa desenvolvida por Tenório, Moraes e Sauvageot (2012) foram coletados dados sobre distribuição do tamanho de gota de chuva (DSD - *Raindrop Size Distribution*) em uma área litorânea do estado do Alagoas no nordeste brasileiro. Estes dados foram usados para analisar diferenças entre os parâmetros de precipitação continental e marítima. Os dados são separados em dois conjuntos, um com os sistemas de chuva que vêm do continente em movimento para o leste (no sentido do mar), o que representa o subconjunto continental, e outro com composto por sistemas de precipitação que se desenvolvem sobre o mar e estão se movendo para o oeste (perto da costa), representando o subconjunto marítimo. A taxa de chuva condicional média (ou seja, $R > 0$) é encontrada mais alta para o marítimo (4.6mm/h) do que para o continental (3.2mm/h). O coeficiente de variação do índice de chuva condicional é mais baixo para o marítimo (1.75) do que para o continental (2.25). As DSDs continentais e marítimas apresentaram diferenças significativas. Para o diâmetro D menor que 2mm, o número de gotas é maior para a chuva marítima do que para a continental. Isto reverte para $D > 2mm$, de tal forma que o fator de refletividade do radar Z para o subconjunto marítimo é menor do que o continental à mesma taxa de chuva. Os resultados mostraram que, para estimar a precipitação por radar na costa do nordeste brasileiro, os coeficientes da relação ZR precisam ser adaptados para a direção do movimento do sistema de chuva, na costa ou no mar.

No trabalho de Albrecht e Filho (2002) estudou-se a evolução temporal da relação ZR com cinco linhas de instabilidade ocorridas no estado de Rondônia durante o experimento WETAMC/LBA e TRMM/LBA. Linhas de instabilidade são sistemas convectivos muito comuns na Amazônia. Os dados foram coletados entre janeiro e fevereiro

de 1999 através de radares, disdrômetro e pluviômetros, todos instalados na região de estudo. O trabalho em geral, aproxima diferentes relações ZR para casos específicos de chuvas convectivas, de transição, ou estratiformes. Segundo os autores, foram encontrados grandes valores para os coeficientes a das relações ZR, devido às gotas grandes e conseqüentemente altos valores de refletividade e taxa de precipitação. Existe uma sensível diferença entre os coeficientes das relações ZR quando a precipitação é discriminada em convectiva, transição e estratiforme.

2.6 MÉTODOS ALTERNATIVOS À RELAÇÃO ZR

Buscando corrigir o viés de refletividade que depende da distância do radar, fato devido ao preenchimento parcial do feixe e aumento vertical do mesmo, Chumchean, Seed e Sharma (2004) verificaram que uma simples escala poderia ser aplicável, e uma função de transformação de escala foi proposta para assegurar a distribuição de probabilidade de refletividade tanto para perto quanto para longe. O estudo é feito primeiramente analisando as hipóteses desta simples escala para a refletividade do radar e então a primeira aplicação é realizada com dados horários de CAPPI em coordenadas cartesianas. Os dados são de 27 tempestades e medidos pelo radar meteorológico de Sydney, Austrália, no período de novembro/2000 até abril/2001, com CAPPI de $1.5km$, e através da rede de 254 pluviômetros instalados a menos de $100km$ do radar. Os dados horários do radar foram separados em anéis com os seguintes intervalos $0 - 20$, $20 - 40$, $40 - 60$, $60 - 80$, e $80 - 100km$, para verificar se de fato a precipitação média e a variância são independentes da distância do radar. A relação ZR com $Z = 200R^{1.6}$ de Marshall-Palmer foi utilizada para converter a refletividade em precipitação e também para analisar os resultados obtidos. Como conclusão, o autor afirma que a função de transformação de escala proposta é capaz de remover o viés que depende da distância do radar. A mesma ideia é aplicada para dados de PPI em coordenadas polares e conclusões satisfatórias também são obtidas.

Para Chumchean, Sharma e Seed (2006) o procedimento para estimar a precipi-

tação de chuva de radar em tempo real consiste em três passos: a medida da refletividade e a remoção de fontes de erros conhecidas; a conversão da refletividade em uma taxa de precipitação; e o ajuste do viés de campo médio, tal como avaliado usando uma rede de pluviômetros. Os autores propõem um procedimento para integração de estratégias para correção de erros do radar em estimativas de chuva em tempo real. As estratégias de correção adotadas no trabalho são: uma função de transformação de escala para remover viés que depende do intervalo na refletividade medida, e uma classificação dos tipos de tempestades para explicar a variação nas relações ZR para chuvas convectivas e estratiformes. Os resultados mostram uma diminuição na raiz do erro médio quadrático, verificando que os efeitos das duas estratégias são pequenos mas formam etapas importantes para a estimativa de chuva por radar.

2.7 ÍNDICES DE COMPARAÇÃO

Para fins de comparação dos resultados das técnicas apresentadas, utilizou-se a Raiz do Erro Médio Quadrático (REMQ), VIÉS e o Coeficiente de Correlação ρ , todos definidos em Ramírez (2003).

- VIÉS: é uma variável que indica a direção média dos desvios de um conjunto a partir de um conjunto de valores observados. Este valor indica a tendência, quando positivos indicam superestimativas, enquanto que valores negativos indicam subestimativas. A expressão é definida por:

$$\text{VIÉS} = \frac{1}{N} \sum_{i=1}^N (P_i - P_i^*) \quad (44)$$

onde, P_i são os valores de estimativa das técnicas, P_i^* são os valores observados através dos pluviômetros e N é o número de casos.

- Raiz do Erro Médio Quadrático (REMQ): é uma das medidas dos padrões de acurácia das estimativas que indica a magnitude média do erro. Esse índice será mais influenciado quando no conjunto de estimativas verificadas existirem erros de maior magnitude, mesmo que sejam poucos, do que quando ocorrem muitos erros

pequenos, já que ao calcular a potência dois os erros maiores serão realçados. A REMQ é definida como:

$$\text{REMQ} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - P_i^*)^2}. \quad (45)$$

- Coeficiente de Correlação (ρ): é uma medida da dependência linear entre dois conjuntos de dados, e pode ser expressa por:

$$\rho = \frac{N \sum_{i=1}^N P_i P_i^* - \sum_{i=1}^N P_i \sum_{i=1}^N P_i^*}{\sqrt{\left[N \sum_{i=1}^N P_i^2 - \left(\sum_{i=1}^N P_i \right)^2 \right] \left[N \sum_{i=1}^N (P_i^*)^2 - \left(\sum_{i=1}^N P_i^* \right)^2 \right]}}. \quad (46)$$

3 INSTRUMENTOS

3.1 RADAR METEOROLÓGICO

A tecnologia de radar meteorológico tem sido usada desde a Segunda Guerra Mundial, quando militares perceberam que a precipitação também aparecia nas telas de radar que rastreavam aviões e navios inimigos. Desde então cientistas passaram a usar radares para estudar e monitorar as características do tempo (*MetEd - Teaching and Training Resources for the Geoscience Community, 2013*).

Um radar meteorológico trabalha através da emissão de pulsos de energia eletromagnética em frequência de microondas para a atmosfera. Quando esses pulsos encontram algum objeto, parte da energia eletromagnética é espalhada e retorna para o radar. Esta energia é muitas vezes referida como sendo “refletida” de volta, e é onde aparece o termo “refletividade”.




FIGURA 11: Varredura do radar

FONTE: *MetEd - Teaching and Training Resources for the Geoscience Community (2013)*

3.1.1 Operação

O funcionamento do radar pode ser simplificado da seguinte maneira: a antena é apontada em um ângulo baixo e envia um pulso eletromagnético por uma fração de segundo, e depois recebe o retorno da energia, em seguida o radar gira a quantidade aproximada de 1° e repete o processo. Uma vez que o radar completa uma revolução o ângulo de elevação da antena é aumentado e repete-se o procedimento. Na Figura 11 pode-se perceber as elevações do radar e a região onde estão os alvos que refletem a energia emitida. O radar do SIMEPAR executa suas tarefas qualitativas com um raio de alcance de 480km a partir da sua posição na primeira elevação (PPI 0.5°), quando precipitações são percebidas nesta leitura, o radar passa a também executar varreduras quantitativas, com outros ângulos de elevação e produtos CAPPI, essa segunda leitura é feita com um raio de 240km a partir da posição do radar.

3.2 PLUVIÔMETRO

Pluviômetros são instrumentos usados para medir a precipitação de chuva (Japan Meteorological Agency, 2013). Existem vários modelos e formas de pluviômetros e dentre esses utilizaremos os chamados de *tipping bucket* (tipo balança ou caçamba) que são atualmente usados pelo SIMEPAR. Este tipo de pluviômetro geralmente envia um sinal elétrico (pulso) para cada unidade de precipitação coletada e permite uma observação remota ou automática com um gravador ou um contador. O único requerimento para o instrumento conectado ao pluviômetro é que seja capaz de contar pulsos. Assim, uma grande variedade de configurações e aplicações é possível para este sistema de medição. Precipitação sólida também pode ser medida se um aquecedor for fixado ao receptor.

3.2.1 Estrutura e Operação

Este tipo de pluviômetro consiste de um receptor e uma parte de medição, com o receptor servindo o recipiente (Figura 12). A parte da medição consiste de uma ca-

çamba basculante e de um pulso de geração com interruptor de lâminas (ou interruptor de mercúrio) montado dentro do receptor.



FIGURA 12: Pluviômetro *Tipping Bucket*
FONTE: Japan Meteorological Agency (2013)

Os *tipping buckets* consistem em duas caçambas triangulares ligadas à esquerda e à direita de um eixo de rotação, cada uma com a capacidade equivalente para uma determinada quantidade de precipitação. O interruptor é conectado a essas caçambas para gerar um sinal elétrico (pulso) a cada vez que a caçamba enche.

A água da chuva coletada no receptor é canalizada através do funil e é vertida para uma caçamba de tombamento. Quando atinge um valor predeterminado, a caçamba despeja a água em um cilindro de drenagem, fazendo com que o interruptor gere um pulso. Na sequência a água da chuva é derramada na outra caçamba. Enquanto a precipitação continua, esta operação é repetida e um pulso é gerado cada vez que uma caçamba é tombada.

Neste trabalho utiliza-se pluviômetros com precisão de $0,2\text{mm}$, ou seja, quando uma caçamba atinge a marca de $0,2\text{mm}$ ela tomba emitindo o sinal elétrico. Outras especificações do pluviômetro são: diâmetro da abertura de 20cm e acurácia de 0.5% até 12.7mm/h e de 2% até 50.8mm/h .

4 APLICAÇÃO

4.1 BANCO DE DADOS

O período de dados selecionado para o desenvolvimento das técnicas propostas é de 01 de dezembro de 2008 até 04 de setembro de 2010. São 22 meses coletados tanto para o treinamento quanto para a validação da metodologia.

Tanto as redes neurais quanto o projeto da nova relação ZR foram desenvolvidos em linguagem de programação Python na versão 2.7.3.

Antes de comparar as 3 metodologias desenvolvidas, faz-se a comparação de cada uma com a relação ZR de Marshall-Palmer, pois como já comentado no Capítulo 2 na Seção 2.5 essa é a relação mais utilizada no mundo,

$$Z = 200R^{1.6}. \quad (47)$$

4.1.1 Dados de Radar

Um novo dado do radar meteorológico do SIMEPAR fica disponível a cada 10 minutos aproximadamente, são arquivos em formato NetCDF (*Network Common Data Form*) contendo as variáveis medidas durante a varredura volumétrica. Têm-se informações como a própria refletividade, a velocidade e direção do vento, a refletividade máxima, as coordenadas geográficas de cada pixel, entre outras. Os dados utilizados são matrizes de PPI na primeira elevação, gerados através do software *geraprods* desenvolvido pelo SIMEPAR. Tendo a escolha de se obter dados em diferentes coordenadas e resoluções, decidiu-se buscar os dados em coordenadas cartesianas com resolução de $1km$, ou seja, cada pixel ou posição da matriz de dados equivale a $1km^2$. Como já informado no Capítulo 3, o raio de alcance do feixe de radar é de $200km$, significando que a matriz de dados utilizada possui 400 linhas e 400 colunas, totalizando

160000 posições. É importante citar que durante esta série de dados o radar de Teixeira Soares-PR operava com raio de alcance de $200km$, a partir de junho de 2013 o radar passou a operar com o raio de $240km$.

No início da pesquisa, trabalhou-se com uma média horária da refletividade dos dados de radar assim como com a refletividade máxima medida em cada hora. Após alguns testes e comparações com os dados de pluviômetro e com a relação ZR de Marshall-Palmer, decidiu-se utilizar em todos os métodos o valor máximo da refletividade medido em uma hora, pois os dados médios apresentaram discrepâncias razoáveis para serem eliminados do processo. Além disso, escolheu-se fazer uso de dados de refletividade iguais ou superiores a $30dBZ$, uma vez que valores abaixo desta medida representam de garoas à chuvas fracas além de representarem uma porcentagem expressiva no conjunto de padrões.

4.1.2 Dados de Pluviômetro

Os dados das estações meteorológicas (pluviômetros) são obtidos em um processo diferente dos dados de radar, mostrados no Capítulo 3. Faz-se uso dos dados de 18 estações meteorológicas acumulados ao longo de uma hora. Estas estações estão instaladas em um raio de $200km$ do radar para que seja possível a comparação dos dados. As estações do estado do Paraná estão nos municípios: Antonina; Cândido de Abreu; Cerro Azul; Curitiba; Entre Rios; Fernandes Pinheiro; Foz do Areia; Guarapuava; Guaratuba; Jaguariaiva; Lapa; Palmas; Palmital; Pinhais; Pinhão; Ponta Grossa; Telêmaco Borba e União da Vitória. Três destas estações foram escolhidas aleatoriamente para não fazer parte do treinamento, apenas da validação das técnicas, são elas: Cândido de Abreu, Palmas e Pinhais.

Com a eliminação dos dados de radar para valores de refletividade menores do que $30dBZ$, eliminam-se também os dados dos pluviômetros da hora correspondente.

Na Tabela 1 apresentam-se alguns dados importantes sobre os pluviômetros, como: o nome da estação, o município que ela se encontra, sua altitude(m) e as coordena-

das geográficas, latitude e longitude. Na Figura 13 é possível localizar as estações no mapa, a partir de seus respectivos índices presentes na primeira coluna da Tabela 1.

TABELA 1: Estações meteorológicas com seus dados de: altitude, latitude e longitude

Nome	Município	Altitude	Latitude	Longitude
Antonina (1)	Antonina	60	-25.22	-48.8
Cerro Azul (2)	Cerro Azul	366	-24.8166	-49.25
Curitiba (3)	Curitiba	935	-25.44817	-49.23033
Cândido de Abreu (4)	Cândido de Abreu	645	-24.6333	-51.25
Entre Rios (5)	Guarapuava	1095	-25.55	-51.4833
Fernandes Pinheiro (6)	Teixeira Soares	893	-25.45	-50.5833
Foz do Areia (7)	Pinhão	728.2	-26.0833	-51.65
Guarapuava (8)	Guarapuava	1070	-25.35	-51.5
Guaratuba (9)	Guaratuba	0	-25.8452	-48.5761
Jaguariaíva (10)	Jaguariaíva	900	-24.2269	-49.677
Lapa (11)	Lapa	909.8	-25.7833	-49.7666
Palmas (12)	Palmas	1100	-26.4667	-51.9667
Palmital (13)	Palmital	783	-24.8833	-52.2166
Pinhais (14)	Piraquara	930	-25.4167	-49.1333
Pinhão (15)	Pinhão	910	-25.64944	-51.9625
Ponta Grossa (16)	Ponta Grossa	885.59	-25.2166	-50.0166
Telêmaco Borba (17)	Telêmaco Borba	768	-24.3333	-50.6166
União da Vitória (18)	União da Vitória	756.53	-26.2333	-51.0666

FONTE: O autor (2014)




FIGURA 13: Disposição das 18 estações utilizadas no trabalho, com o círculo da área do radar

FONTE: O autor (2014)

4.1.3 Filtro

Com os pares de refletividade-precipitação já montados, aplicou-se um filtro procurando eliminar possíveis dados espúrios, por exemplo, a ocorrência de uma medida

alta de refletividade no radar e no horário correspondente não haver precipitação informada pelos pluviômetros, ou haver uma precipitação ínfima que poderia causar distúrbios no treinamento das RNAs. Dessa forma, o filtro consiste na eliminação de valores com duas vezes o desvio padrão da série.

4.2 APLICAÇÃO DA REDE RBF

Espera-se que com o treinamento da rede RBF para os pares criados, seja possível encontrar pesos que assimilem bem a conversão dos dados do radar em precipitação de chuva. Para tanto, foram adotados alguns procedimentos comuns antes do treinamento de fato.

4.2.1 Pré-processamento dos dados

Antes de apresentar os padrões à rede, é comum ou mesmo aconselhável, mudar a escala original das componentes dos vetores \mathbf{x} (padrões de entrada) e \mathbf{d} (valores desejados) para as escalas das funções de ativação (BARRETO, 2007), aqui apenas o vetor \mathbf{x} foi normalizado para que suas informações estejam na escala da função gaussiana $(0, 1)$, o vetor desejado não foi normalizado pois a função de ativação da camada de saída é linear e não deseja-se valores entre $(0, 1)$. Dessa forma, segue a normalização dos padrões:

$$x^* = \frac{\mathbf{x}}{x_{max}} \quad (48)$$

onde \mathbf{x} é o vetor de entrada da rede, x_{max} é valor máximo entre o conjunto de entrada e x^* o vetor normalizado. Tem-se então cada componente de entrada $\mathbf{x} \in (0, 1]$.

Para definir o número de neurônios na camada oculta, fez-se uma busca empírica dentro das possibilidades para este caso. Os valores dos padrões de entrada são dados de refletividade do radar acima de $30dBZ$, o valor máximo encontrado no período selecionado é de $53dBZ$, e estes valores variam de 0.5 em 0.5, obtendo dentro dos padrões 46 valores distintos de refletividade. Como no início da rede neural escolhe-se centros aleatórios dentro do conjunto de treinamento, e sabe-se que o critério é que

eles sejam distintos, então procurou-se dentre esses 46 possíveis valores qual retornaria a menor raiz do erro médio quadrático (REM_Q) com os dados de treinamento (Figura 14).




FIGURA 14: Número de neurônios para a rede RBF

FONTE: O autor (2014)

O mínimo valor encontrado da REM_Q para o número de neurônios na camada oculta foi 45.

4.3 APLICAÇÃO DA REDE MLP

Para a rede MLP também utilizam-se os pares refletividade-precipitação assim como na rede RBF. A principal diferença é que a rede RBF é treinada de forma direta através do método da matriz pseudo-inversa, já na rede MLP temos iterações buscando minimizar o erro com a regra delta.

4.3.1 Pré-processamento dos dados

A primeira etapa da rede MLP é definir a quantidade de camadas ocultas, o número de neurônios em cada camada, o critério de parada e também os valores iniciais dos pesos.

A arquitetura da rede MLP desenvolvida neste trabalho, segue a forma da camada de entrada, uma camada oculta e a camada de saída. A quantidade de neurônios na camada oculta foi definida através de testes, executando a rede 50 vezes para valores variáveis dos neurônios entre 1 e 50 e analisando a raiz do erro médio quadrático para cada caso. A maior parte dos casos teve a menor REMQ com o número de neurônios sendo 48, como pode ser visto na Figura 15:

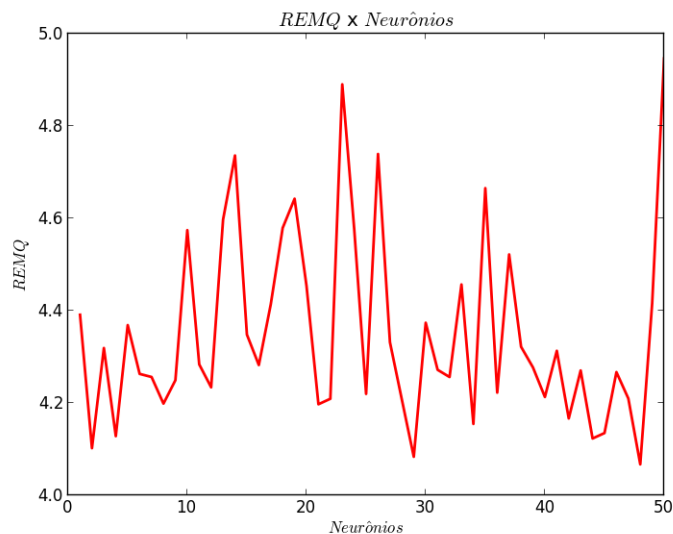


FIGURA 15: Número de neurônios para a rede MLP
 FONTE: O autor (2014)

Como critério de parada, utilizam-se duas condições:

- Quando o treinamento atinge o número máximo de iterações, neste caso a quantidade de iterações escolhida é 10000.
- Quando a taxa absoluta da variação do erro médio quadrático por iteração for suficientemente pequena, aqui esse valor é 10^{-2} .

Os pesos iniciais tanto para as conexões entre a entrada e a camada oculta quanto para as conexões entre a camada oculta e a saída, são definidos aleatoriamente no intervalo de -0.25 à 0.25 . O valor inicial do bias é 1. No decorrer do treinamento esses pesos e bias são atualizados conforme a regra delta de correção do

erro. A taxa de aprendizagem é iniciada com o valor 1, e a cada iteração é atualizada conforme a Eq. (49):

$$\eta = 0.95 \times \eta. \quad (49)$$

Os dados de entrada e os dados desejados são normalizados seguindo a Eq. (48). Para retornar à escala inicial, os dados resultantes da rede MLP são transformados conforme a Eq. (50):

$$x_s = x_{max} * y \quad (50)$$

onde x_s é o vetor à ser comparado com a saída desejada (dados dos pluviômetros), x_{max} é o valor máximo do vetor de entrada do treinamento e y é o vetor de saída processado pela rede.

4.4 APLICAÇÃO DA NOVA RELAÇÃO ZR

Durante a procura por uma nova relação ZR, novamente utiliza-se os pares de refletividade-precipitação. Dados estes pares do chamado conjunto de treinamento das redes neurais, utiliza-se a raiz do erro médio quadrático para analisar novos possíveis parâmetros para a relação. Para variar estes parâmetros escolheu-se intervalos que possuem os valores das relações mais conhecidas na literatura. Dessa forma, a constante empírica a varia no intervalo $[50, 300]$ e a constante b no intervalo $[1.0, 3.0]$. Faz-se então a relação para cada combinação de constantes a e b para os dados de refletividade e em seguida são comparados com os dados de precipitação através da REMQ (Figura 16).




FIGURA 16: Parâmetros da relação ZR com REMQ

FONTE: O autor (2014)

Nota-se que a faixa que apresenta os menores erros, entre 2.5 e 3.0 contém uma grande quantidade de combinações para a e b . Decidiu-se então, selecionar 5 relações conhecidas na literatura e outras 5 que apresentaram os melhores resultados a partir dos valores dos erros na Figura 16. A Tabela 2 mostra os parâmetros destas 10 relações. As 5 primeiras são conhecidas na literatura e as próximas 5 apresentaram os menores erros para os valores de dBZ .

TABELA 2: Ranking Relações ZR

Relação	Parâmetros	
	a	b
1	200	1.6
2	161	2.8
3	56	1.9
4	56	1.6
5	60	1.9
6	52	2.7
7	298	1.8
8	61	2.4
9	179	2.6
10	249	1.5

FONTE: O autor (2014)

As 5 primeiras relações encontram-se em Sauvageot (1992). Nota-se que a relação 1 é a relação ZR de Marshall-Palmer.

Após a criação deste “ranking” de relações, calcula-se novamente a REMQ para estes valores em todos os níveis de dBZ pertencentes ao conjunto. Na Tabela 11 no Anexo A é possível verificar todos os valores. Os 3 menores erros para cada nível de dBZ estão em destaque. Com o recurso da Tabela 11 verifica-se que a relação 6 obteve os menores erros em grande parte dos valores de dBZ , em muitos casos sendo de fato o menor erro. É importante notar que a relação 1 que é a de Marshall-Palmer obtém resultados satisfatórios para valores de refletividade abaixo de $42dBZ$, acima deste valor os erros são significativos devido a superestimativa já esperada dessa relação.

No início do trabalho esperava-se que fosse necessária a junção de duas ou mais relações para converter de forma mais precisa diferentes faixas de dBZ , porém, a relação 6 vista na Eq. (51) forneceu resultados bastante satisfatórios. Tem-se então a nova relação ZR:

$$Z = 52R^{2.7}. \quad (51)$$

5 RESULTADOS

Para facilitar a visualização nas tabelas, a relação ZR de Marshall-Palmer é denominada apenas por ZR.

5.1 RESULTADOS DA REDE RBF

Para todas as metodologias têm-se duas comparações a serem feitas: a dos dados de treinamento e a dos dados de validação. Então, fazendo uso dos índices já definidos, pode-se gerar a Tabela 3 para os dados de treinamento entre ZR e a rede RBF:

TABELA 3: Comparação entre a relação ZR e a rede RBF para os dados de treinamento de 15 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	2.630	6.139
RBF	0.004	2.789	0.750

FONTE: O autor (2014)

A rede RBF obteve resultados melhores que a ZR para os dados de treinamento em todos os índices.

A Tabela 4 mostra os resultados entre ZR e RBF para os dados de validação.

TABELA 4: Comparação entre a relação ZR e a rede RBF para os dados de validação de 3 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	3.075	8.395
RBF	-1.248	3.766	0.737

FONTE: O autor (2014)

Para os dados de validação a rede RBF manteve bons resultados quando comparados com a ZR, mostrando que durante o treinamento as características dos dados foram bem assimiladas.

5.2 RESULTADOS DA REDE MLP

Nesta Seção mostra-se os resultados da relação ZR comparados aos da rede MLP. A Tabela 5 mostra os resultados para os dados de treinamento entre ZR e rede MLP.

TABELA 5: Comparação entre a relação ZR e a rede MLP para os dados de treinamento de 15 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	2.630	6.139
MLP	1.288	3.289	0.739

FONTE: O autor (2014)

Para os dados de treinamento, a rede MLP apresenta resultados melhores que a relação ZR, para aproximadamente a metade da REMQ e do VIÉS.

A Tabela 6 mostra os resultados entre ZR e MLP para os dados de validação.

TABELA 6: Comparação entre a relação ZR e a rede MLP para os dados de validação de 3 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	3.075	8.395
MLP	0.636	3.708	0.745

FONTE: O autor (2014)

Para os dados de validação a MLP se comporta melhor em relação a ZR, e mantém a qualidade da conversão dos dados como no período de treinamento.

5.3 RESULTADOS DA NOVA RELAÇÃO ZR

Nesta Seção mostra-se os resultados da relação ZR comparados aos da nova relação ZR, para facilitar a leitura na Tabela 7 chama-se a nova relação ZR de nova ZR. A Tabela 7 mostra os resultados para os dados de treinamento entre ZR e nova ZR:

TABELA 7: Comparação entre a relação ZR e a nova relação ZR para os dados de treinamento de 15 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	2.630	6.139
nova ZR	-0.049	2.895	0.739

FONTE: O autor (2014)

Com os resultados da nova ZR, pode-se verificar que a nova relação apresenta uma pequena subestimativa com o valor do VIÉS negativo, que em valor absoluto é significativamente menor que o VIÉS para a relação ZR.

A Tabela 8 mostra os resultados entre ZR e nova ZR para os dados de validação.

TABELA 8: Comparação entre a relação ZR e a nova relação ZR para os dados de validação de 3 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	ZR	3.075	8.395
nova ZR	-0.051	3.359	0.734

FONTE: O autor (2014)

Com os dados de validação a nova ZR obteve resultados muito melhores que os da ZR de Marshall-Palmer.

5.4 COMPARAÇÃO ENTRE AS TRÊS NOVAS METODOLOGIAS

Nesta Seção compara-se as três novas metodologias desenvolvidas para a estimativa de chuva. A Tabela 9 mostra os valores dos índices para os dados de treinamento.

TABELA 9: Comparação entre a rede RBF, rede MLP e nova relação ZR para os dados de treinamento de 15 estações meteorológicas com acumulação horária

Técnicas \ Índices	VIÉS	REMQ	ρ
	RBF	0.004	2.789
MLP	1.288	3.289	0.739
nova ZR	-0.049	2.895	0.739

FONTE: O autor (2014)

Para os dados de treinamento pode-se concluir que as três metodologias obtiveram resultados satisfatórios, com a RBF apresentando uma pequena vantagem sobre as outras. Observa-se que a rede MLP apresenta o VIÉS muito maior que a rede RBF, devida a interpolação da rede RBF que obriga as funções de ativação passarem sobre os pontos dos padrões de entrada, por isso este pequeno VIÉS durante o

treinamento. É importante afirmar que as três foram superiores em todos os índices quando comparadas com a relação ZR de Marshall-Palmer.

A Tabela 10 exhibe os resultados para os dados de validação.

TABELA 10: Comparação entre a rede RBF, rede MLP e nova relação ZR para os dados de validação de 3 estações meteorológicas com acumulação horária

Técnicas	Índices	VIÉS	REMQ	ρ
	RBF		-1.248	3.766
MLP		0.636	3.708	0.745
nova ZR		-0.051	3.359	0.734

FONTE: O autor (2014)

Ao analisar os índices para os dados de validação, verifica-se que a nova ZR foi melhor com o VIÉS e REMQ. A RBF e MLP obtiveram valores bastante próximos. Destaca-se o pequeno VIÉS da nova relação ZR que mesmo com a REMQ similar ao das outras técnicas mostrou-se não possuir fortes tendências de sub ou superestimar a precipitação de chuva. E novamente o fato de todas as novas metodologias resultarem valores melhores que a relação ZR de Marshall-Palmer deve ser afirmado.

Com a análise do VIÉS sabe-se se o novo método tem tendências de subestimar ou superestimar a precipitação de chuva. Sobre a relação ZR de Marshall-Palmer ficou clara a superestimativa principalmente para valores acima de $42dBZ$ apresentados na Tabela 11 no Anexo A. Para os outros métodos alguns resultados foram próximos de zero, mostrando a proximidade com a precipitação coletada pelos pluviômetros.

Nas Figuras 17 e 18 apresentam-se os gráficos de dispersão para os dois períodos (treinamento e validação). O gráfico de dispersão permite visualizar o grau de associação entre as variáveis e a tendência de variação conjunta que apresentam (NAGHETTINI; PINTO, 2007).

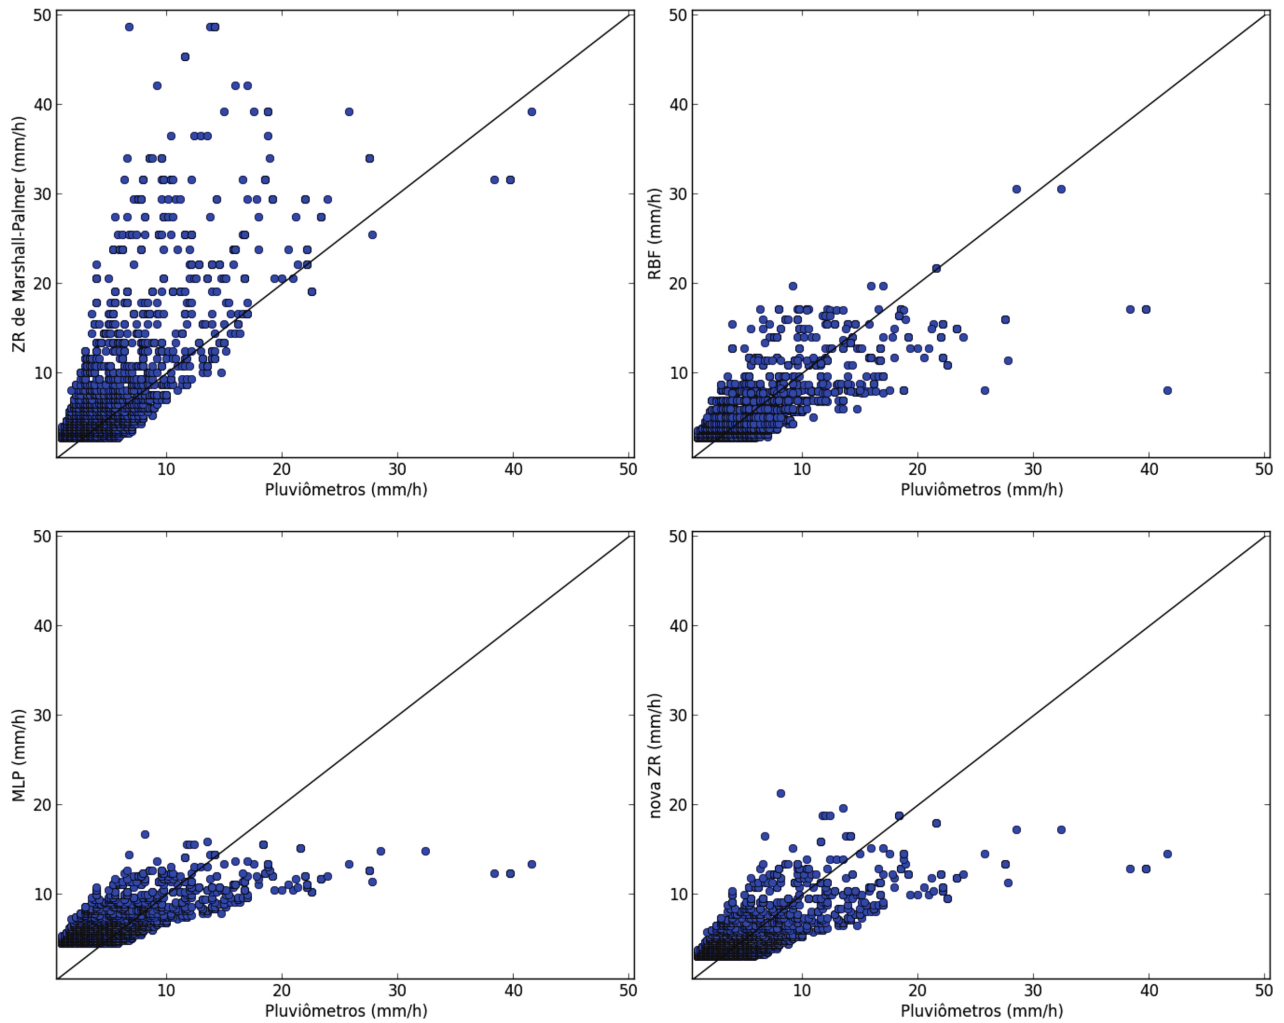


FIGURA 17: Gráfico de dispersão para os dados de treinamento

FONTE: O autor (2014)

Todas as técnicas (relação ZR de Marshall-Palmer, nova ZR, rede RBF e rede MLP) são comparadas com os dados dos pluviômetros através destes gráficos para os dados de treinamento. Em todos os casos têm-se a aglomeração dos pontos em torno da reta bissetriz devido ao grande volume de dados com valores abaixo de 20mm/h , então, destacam-se os resultados elevados e pontos dispersos. A rede MLP e a nova ZR mostram os comportamentos mais similares, enquanto a relação ZR de Marshall-Palmer exibe uma quantidade significativa de dados acima da bissetriz, representando as superestimativas.

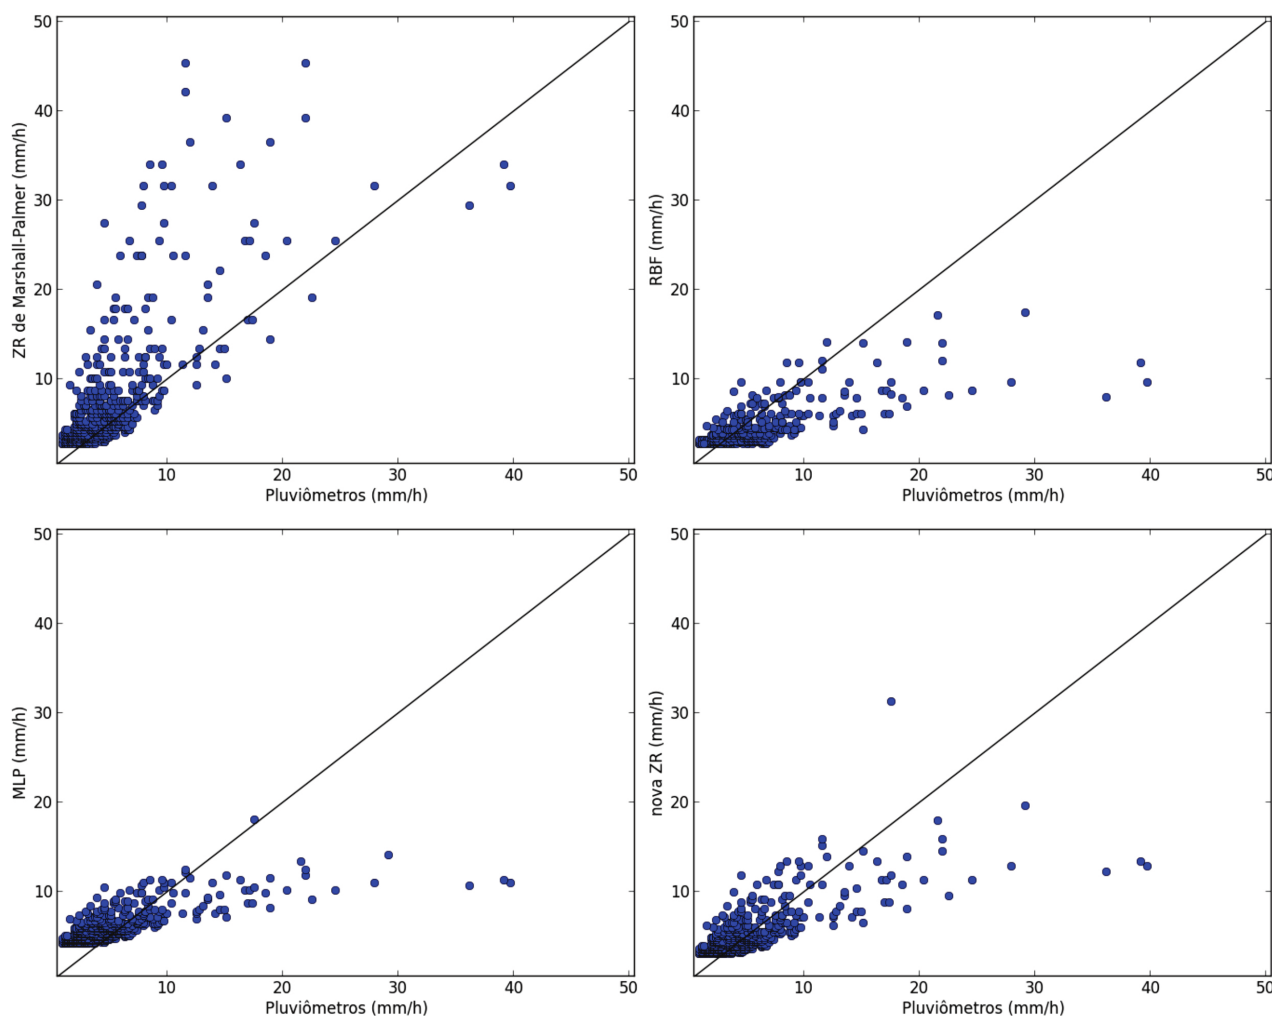


FIGURA 18: Gráfico de dispersão para os dados de validação

FONTE: O autor (2014)

Através dos gráficos de dispersão feitos com os dados de validação, observa-se as mesmas características que os dados de treinamento: a superestimativa da relação ZR de Marshall-Palmer e o comportamento similar das outras técnicas. É possível até verificar uma certa subestimativa da rede MLP, nova ZR e rede RBF, que pode ser confirmada com o valor do VIÉS, porém os resultados são melhores que os da relação ZR de Marshall-Palmer.

Agora apresentam-se algumas imagens da taxa de precipitação de chuva, convertendo os dados de refletividade. Foram selecionados alguns casos com chuvas expressivas na região de varredura do radar. Na Figura 19 tem-se o dia 05 de dezembro de 2013 às 16 horas, ou seja, os dados de refletividade são os máximos de

cada pixel coletado no intervalo de 16 : 00 – 16 : 59 horas. Na mesma figura também tem-se o valor referente dos pluviômetros para o mesmo dia e hora. Estão plotadas as estações utilizadas no estudo.

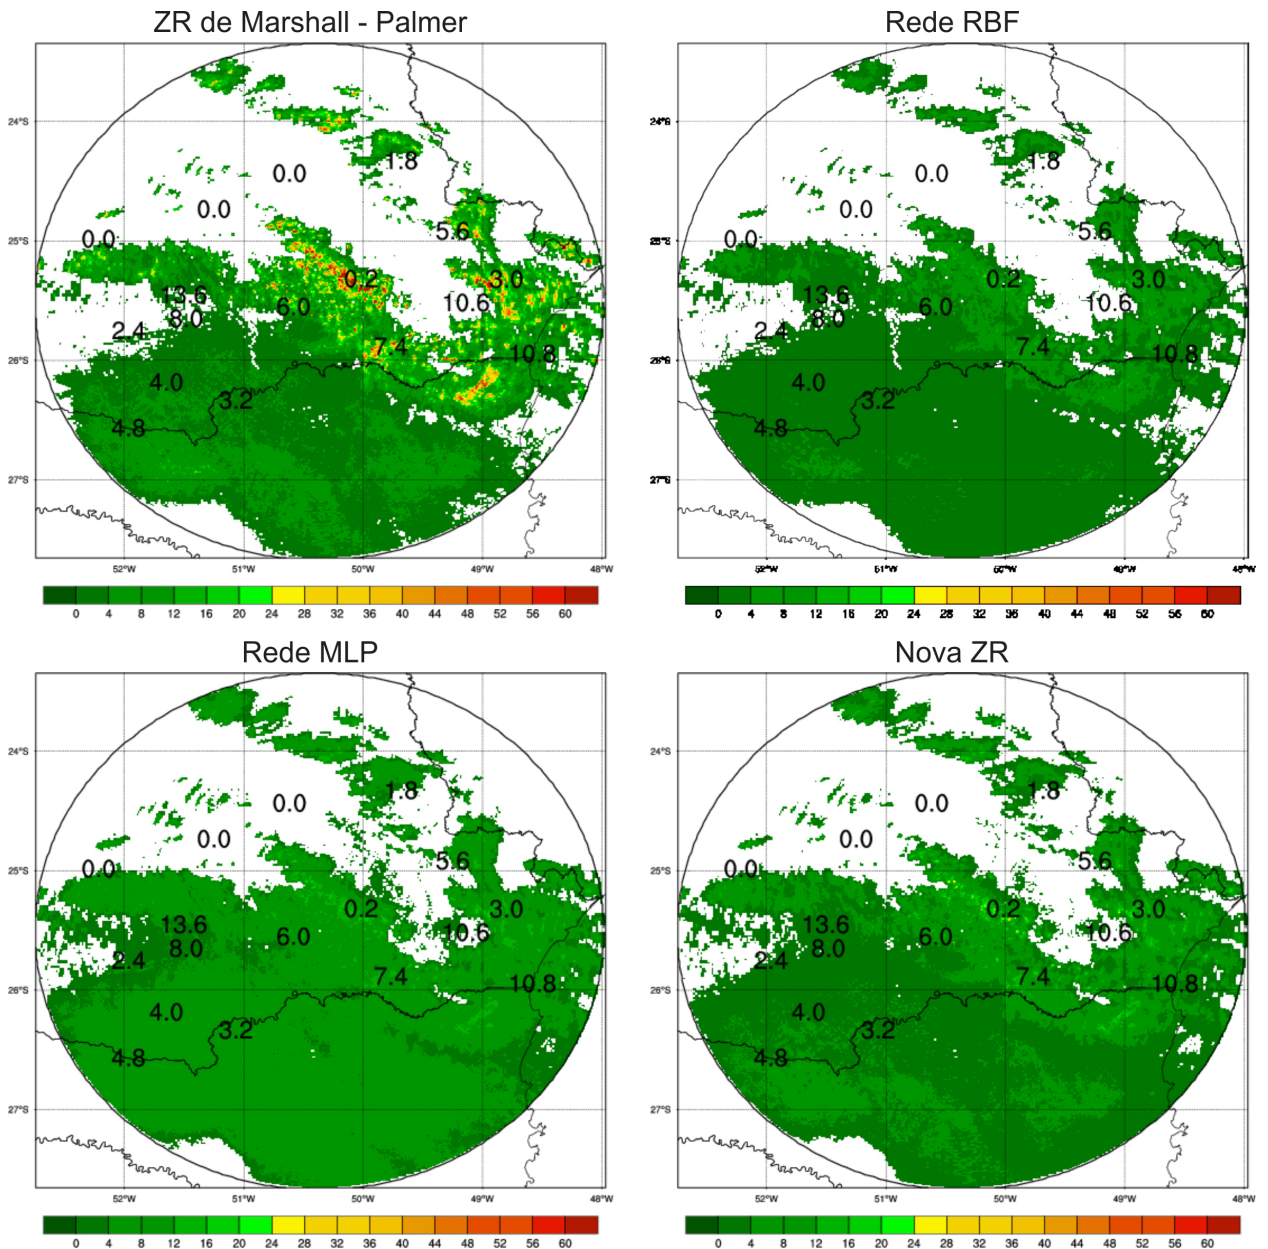


FIGURA 19: Comparação da chuva acumulada em 1 hora no dia 05/12/2013 às 16:00hrs

FONTE: O autor (2014)

Nota-se a princípio que o formato do evento meteorológico foi mantido em todas os casos, mesmo nas figuras posteriores. Observa-se a superestimativa da relação de Marshall-Palmer e mesmo que pequena, mas aparente, subestimativa da rede RBF.

A Figura 20 é do dia 20 de junho de 2013 às 13 horas, ou seja, dados no intervalo de 13 : 00 – 13 : 59 horas.

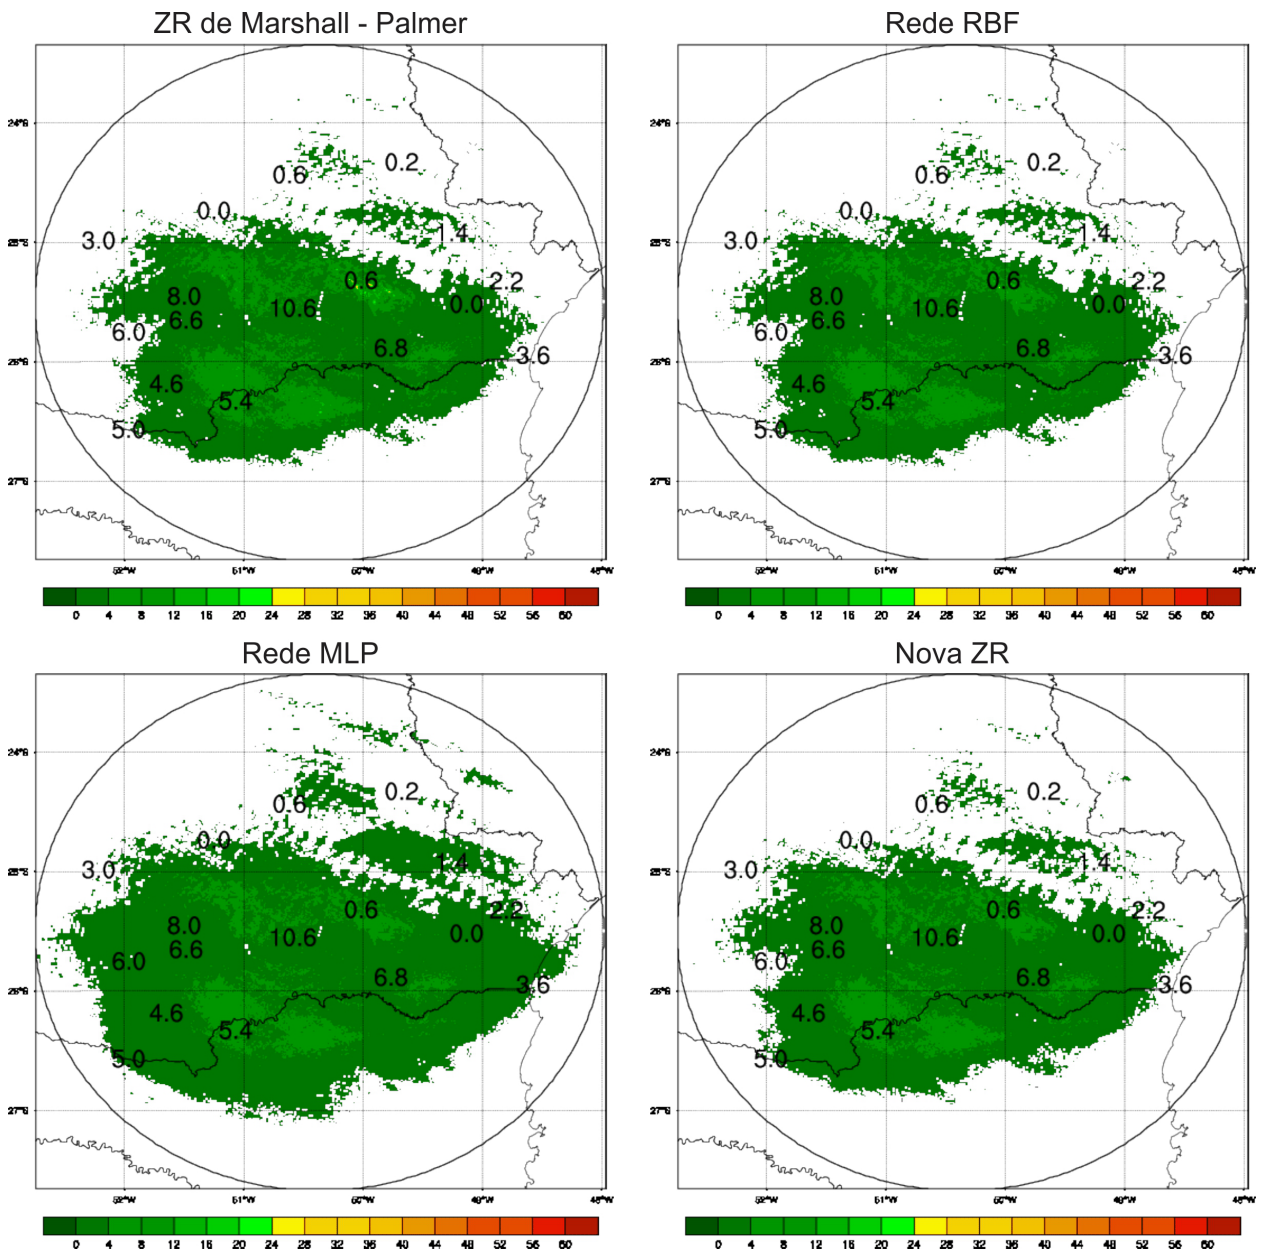


FIGURA 20: Comparação da chuva acumulada em 1 hora no dia 20/06/2013 às 13:00hrs

FONTE: O autor (2014)

Neste caso não observam-se grandes diferenças, devido ao baixo valor de refletividade horária. É importante lembrar que as redes neurais artificiais foram desenvolvidas com valores acima de $30dBZ$, podendo assim, não assimilar bem baixos valores de refletividade.

O caso mostrado na Figura 21, é do dia 21 de setembro de 2013 às 19 : 00 horas.

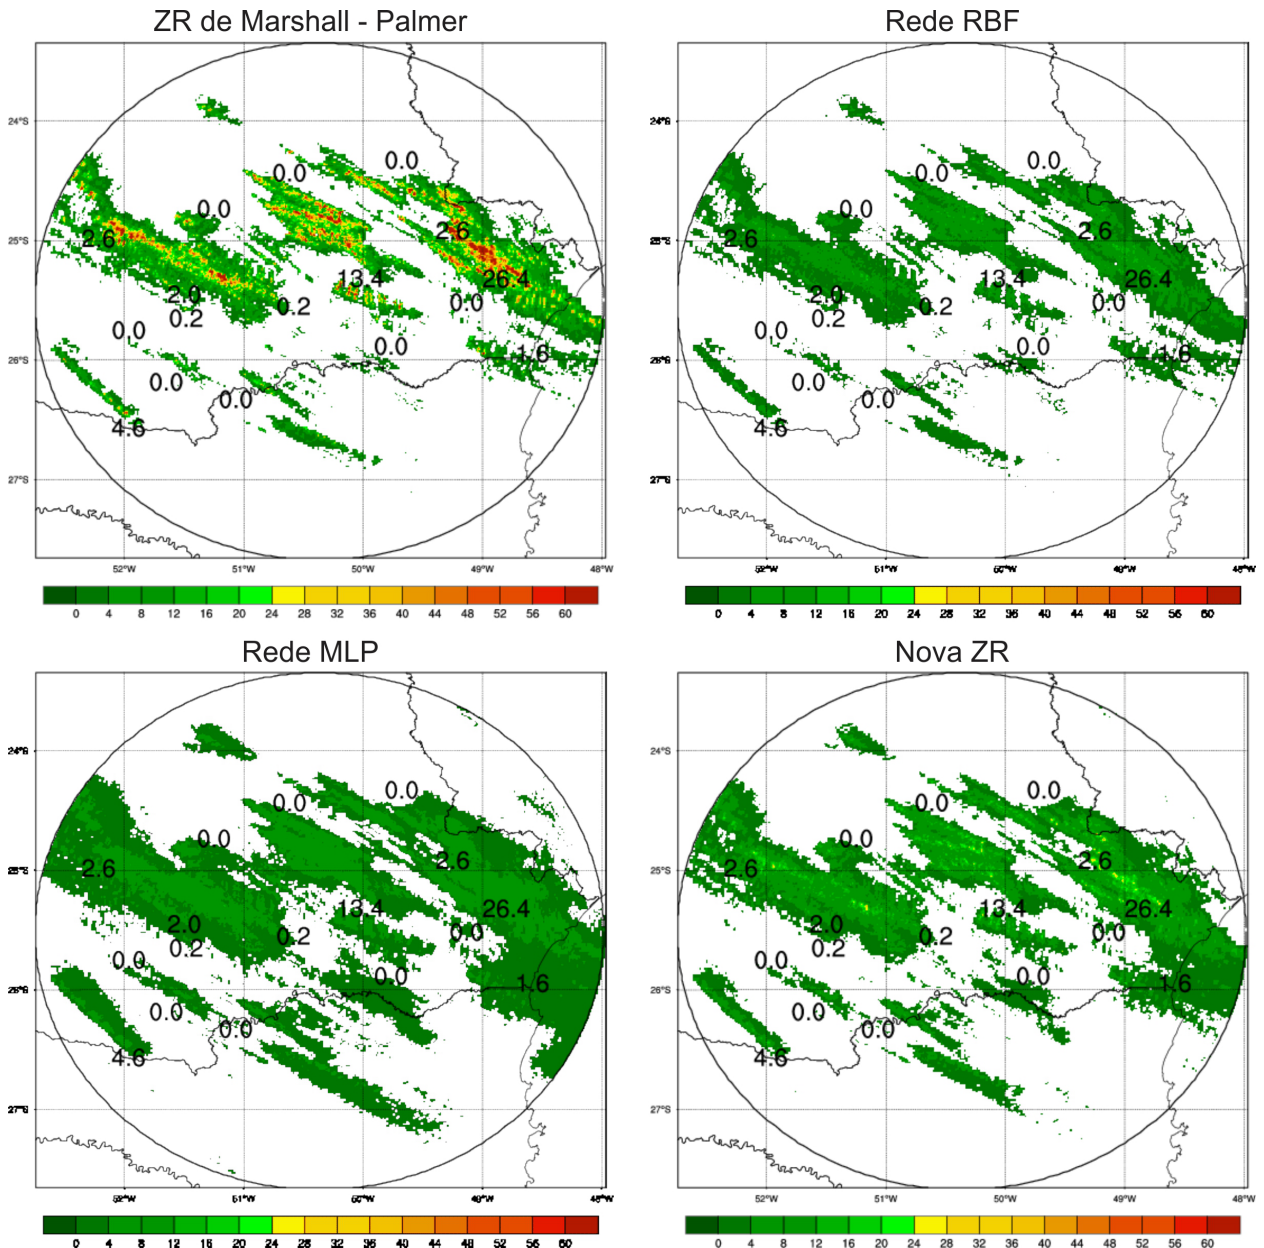


FIGURA 21: Comparação da chuva acumulada em 1 hora no dia 21/09/2013 às 19:00hrs

FONTE: O autor (2014)

Neste caso é bastante clara a superestimativa da ZR de Marshall-Palmer, com vários valores acima de $56\text{mm}/h$ (em cor vermelha) enquanto os pluviômetros indicam precipitações menos relevantes.

A Figura 22 mostra a precipitação de chuva acumulada durante as 24 horas do dia 21 de junho de 2013, tanto para os dados do radar, quanto para os dados dos

pluviômetros.

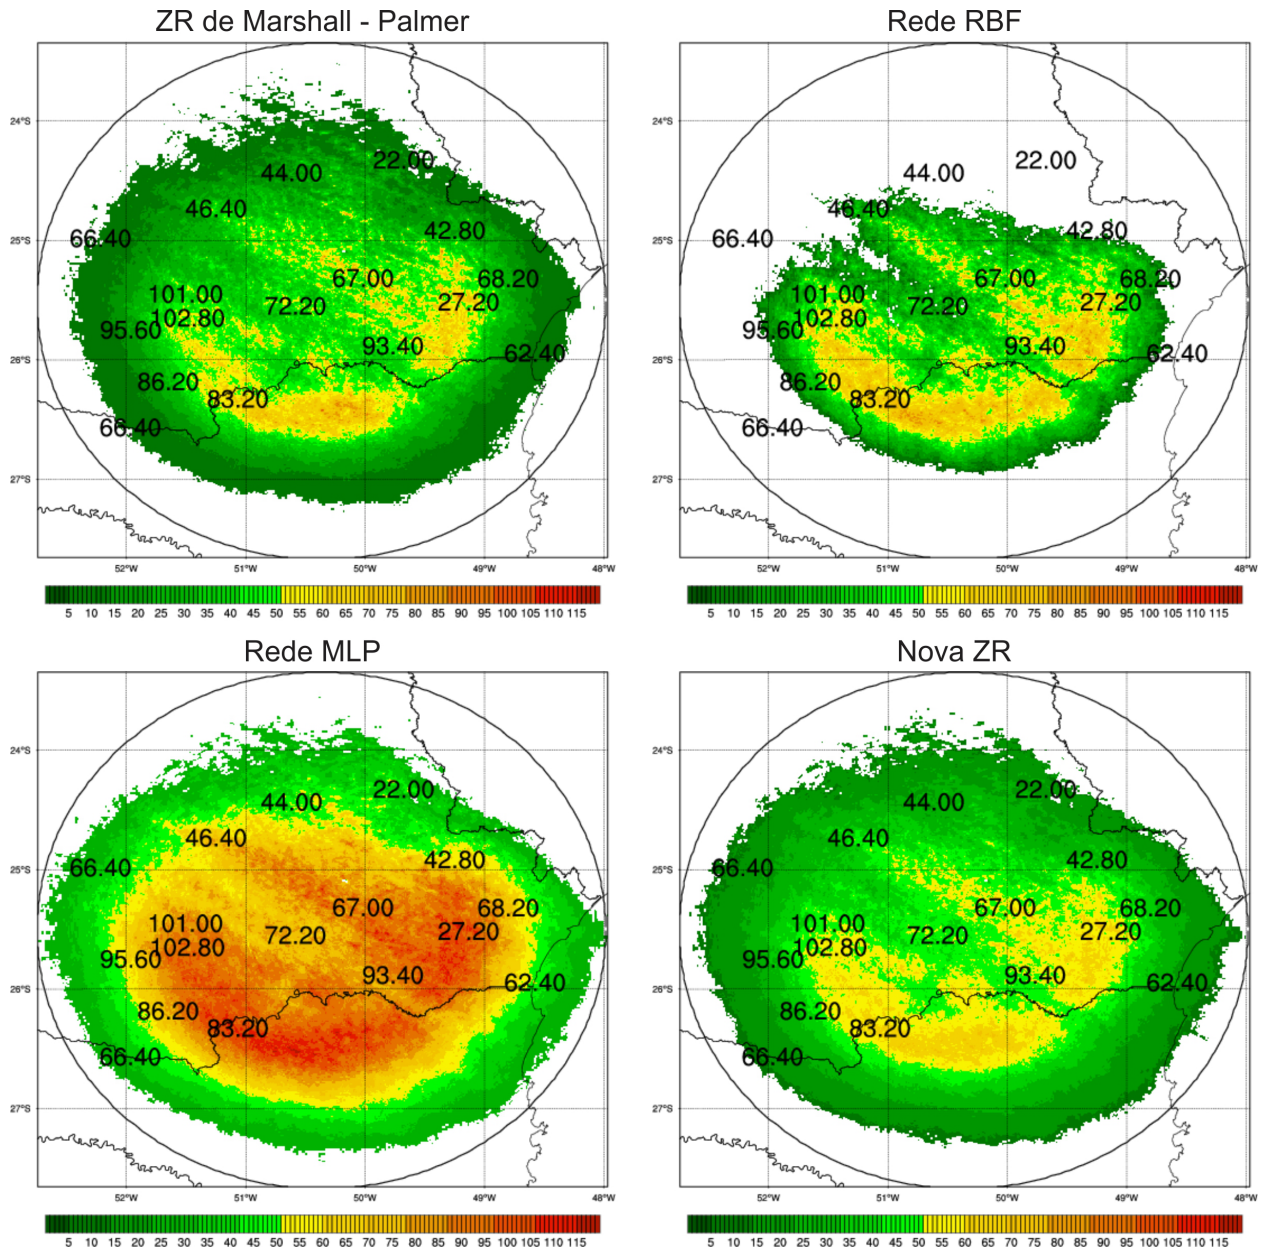


FIGURA 22: Comparação da chuva acumulada em 24 horas no dia 21/06/2013

FONTE: O autor (2014)

Com exceção da rede MLP, as outras técnicas obtiveram resultados muito próximos. A rede MLP apresentou valores muito bons para altas precipitações, próximos aos dos pluviômetros. Em todas as imagens é possível verificar o erro da leitura do radar que depende da distância em relação a ele.

6 CONCLUSÃO

A estimativa da precipitação de chuva com a melhor acurácia possível é fundamental para uma adequada e realística representação da distribuição espacial da precipitação, pois são estes dados que podem induzir, em casos extremos, a emissão de alertas de inundação e risco de escorregamento de terra e gerar uma série de medidas de amplo impacto sócio-econômico. O foco fundamental deste trabalho era justamente encontrar novas metodologias capazes de fazer tal estimativa através dos dados de refletividade de um radar meteorológico.

A relação ZR de Marshall-Palmer foi extensivamente utilizada nas comparações dos resultados por ser a maneira mais conhecida de se fazer a conversão dos dados de refletividade em precipitação. Três metodologias foram desenvolvidas: a rede neural RBF, a rede neural MLP e uma nova relação ZR com parâmetros bastante distintos da relação de Marshall-Palmer. Os resultados mostraram que todas as novas metodologias foram superiores à Marshall-Palmer, tanto com a REMQ, com o VIÉS e com o coeficiente de correlação ρ . A relação de Marshall-Palmer resultou em superestimativas tanto para os dados do período de treinamento quanto para os dados de validação.

Na comparação geral das três técnicas propostas, têm-se os melhores valores dos índices para a rede RBF com os dados de treinamento. No período de dados de validação, verifica-se que a nova relação ZR teve desempenho superior ao das redes neurais. Nenhuma das três metodologias obteve índices ruins quando comparadas as outras.

No início do trabalho acreditava-se que fossem necessárias duas ou mais relações ZR para melhorar a precisão da conversão, cada relação ZR seria responsável por algumas classes de *dBZ* pois, sabia-se que a relação de Marshall-Palmer obtinha

um excelente desempenho até um determinado valor de refletividade, após este valor as precipitações passavam a ser superestimadas. No trabalho verificou-se que esse limiar pode ser aproximadamente $42dBZ$. Surpreendentemente encontrou-se uma única relação capaz de fazer a conversão dos dados de refletividade com pequenos erros quando comparadas com as outras relações escolhidas.

Por fim, tem-se que a nova relação ZR obteve os melhores resultados, sendo escolhida como a melhor entre as três técnicas. Vimos que a rede RBF apresentou os melhores resultados para o período de treinamento, esta é uma consequência de redes supervisionadas, então dá-se mais crédito a técnica que se destaca no período de validação, ou seja, a nova relação ZR. Sugere-se que a rede RBF seja utilizada em paralelo com a nova relação ZR, já que apresentou bons resultados com erros pequenos. A rede MLP mesmo com bons valores não superou as outras.

6.1 TRABALHOS FUTUROS

Algumas sugestões para possíveis aprimoramentos deste trabalho:

- Treinar as redes neurais artificiais com dados de CAPPI em várias altitudes.
- Utilizar os dados dos radares das cidades de Bauru-SP, Presidente Prudente-SP, e o novo radar de Cascavel-PR, criando um mosaico.
- Separar em grupos as estações conforme a distância do radar, procurando corrigir o viés causado na região periférica da varredura.

REFERÊNCIAS

- ALBRECHT, R. I.; FILHO, A. J. P. Evolução temporal da relação z-r em sistemas precipitantes durante o experimento WETAMC/LBA e TRMM/LBA. In: **XII Congresso Brasileiro de Meteorologia**. Foz do Iguaçu, Parana, Brasil: [s.n.], 2002.
- BARRETO, G. de A. **Rede de Funções de Base Radial (RBF)**. Fortaleza, Ceará, Brasil, 2007.
- CALHEIROS, R. V.; GOMES, A. M. **Reflectivity Climatology for Central São Paulo**. 2011. Disponível em: <https://ams.confex.com/ams/35Radar/webprogram/Paper191620.html>, acesso em: Jan 2014.
- DUNCAN, A. P. *et al.* (Ed.). **Urban flood prediction in real-time from weather radar and rainfall data using artificial neural networks**, v. 351. Centre for Water Systems, University of Exeter, Harrison Building, North Park Road, Exeter EX4 4QF, UK: IAHS, 2011.
- CHUMCHEAN, S.; SEED, A.; SHARMA, A. Application of scaling in radar reflectivity for correcting range-dependent bias in climatological radar rainfall estimates. **Journal of Atmospheric and Oceanic Technology**, v. 21, p. 1545–1556, 2004.
- CHUMCHEAN, S.; SHARMA, A.; SEED, A. An integrated approach to error correction for real-time radar-rainfall estimation. **Journal of Atmospheric and Oceanic Technology**, v. 23, p. 67–79, 2006.
- DAMIAN, E. A. **Dois Metodologias Aplicadas à Classificação de Precipitação Convectiva e Estratiforme com Radar Meteorológico: SVM e K-MEANS**. Dissertação (Mestrado) — Universidade Federal do Paraná, 2011.
- DESHPANDE, R. R. On the rainfall time series prediction using multilayer perceptron artificial neural networks. **International Journal of Emerging Technology and Advanced Engineering**, v. 2, p. 148–153, 2012.
- DOVIK, R. J.; ZRNIĆ, D. S. **Doppler Radar and Weather Observations**. Minoela, New York: Dover Publications, INC, 1993.
- HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre: Bookman, 2001.
- JAISWAL, R. S.; UMA, S.; SANTHAKUMARAN, A. Study of z-r relationship over gandaki for different rainfall rates. **Indian Journal of Radio & Space Physics**, v. 38, p. 159–164, 2009.
- Japan Meteorological Agency. **Lecture Notes on WMO Training Workshop for Instrument Specialist of RAI (Japan, 1998)**. 2013. Disponível em: <http://www.jma.go.jp/jma/jma-eng/jma-center/ric/material.html>, acesso em: Fev 2013.

LAWS, J. O.; PARSONS, D. A. The relationship of raindrop size to intensity. **Transactions, American Geophysical Union**, v. 24, p. 452–460, 1943.

LIMA, A. G. de; GUERREIRO, A. M. G. Uso das redes neurais de função de base radial e growing neural gas na classificação de imagens de sensoriamento remoto. In: **XV Simpósio Brasileiro de Sensoriamento Remoto**. Curitiba, Parana, Brasil: [s.n.], 2011.

MARSHALL, J. S.; PALMER, W. M. The distribution of raindrops with size. **Journal of Meteorology**, v. 5, p. 165–166, 1948.

MetEd - Teaching and Training Resources for the Geoscience Community. **Weather Radar Fundamentals**. 2013. Disponível em: http://www.meted.ucar.edu/radar/basic_wxradar/, acesso em: Fev 2013.

METEOPT. **Fórum de Meteorologia**. 2013. Disponível em: <http://www.meteopt.com/>, acesso em: Dez 2013.

MULLER, B. **Radar Equation**. 2013. Disponível em: wx.db.erau.edu/faculty/mullerb/Wx365/Radar_equation/mp_rainrate_derivation.pdf, acesso em: Jan 2013.

MUTLU, E. *et al.* Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. **Hydrological Processes**, v. 22, p. 5097–5106, 2008.

NAGHETTINI, M.; PINTO, É. J. de A. **Hidrologia Estatística**. Belo Horizonte, Brasil: Serviço Geológico do Brasil, 2007.

OLIVEIRA, M. M. F. de *et al.* Modelagem da maré meteorológica utilizando redes neurais artificiais: Uma aplicação para a Baía de Paranaguá-PR, parte1: Dados meteorológicos da estação de superfície. **Revista Brasileira de Meteorologia**, v. 21, p. 220–231, 2006.

RAMÍREZ, M. C. V. **Previsão e Análise da Precipitação sobre as Regiões Sudeste e Sul do Brasil Utilizando Redes Neurais Artificiais**. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais - INPE, 2003.

RINEHART, R. E. **Radar for Meteorologists**. Nevada, Estados Unidos da América: Rinehart Publishing, 2004.

SANTHANAM, T.; SUBHAJINI, A. C. An efficient weather forecasting system using radial basis function neural network. **Journal of Computer Science**, v. 7, p. 962–966, 2011.

SAUVAGEOT, H. **Radar Meteorology**. [S.l.]: Artech House, 1992.

SOUSA, W. dos S.; SOUSA, F. de A. S. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, p. 173–180, 2010.

TENÓRIO, R. S.; MORAES, M. C. da S.; KWON, B. H. Raindrop distribution in the eastern coast of northeastern brazil using disdrometer data. **Revista Brasileira de Meteorologia**, v. 25, p. 415–426, 2010.

TENÓRIO, R. S.; MORAES, M. C. da S.; SAUVAGEOT, H. Raindrop size distribution and radar parameters in coastal tropical rain systems of northeastern Brazil. **Journal of Applied Meteorology and Climatology**, v. 51, p. 1960–1970, 2012.

WEI, C.-C. RBF neural network combined with principal component analysis applied to quantitative precipitation forecast for a reservoir watershed during typhoon periods. **Journal of Hydrometeorology**, v. 13, p. 722–734, 2011.

ANEXO A – RANKING DAS RELAÇÕES ZR

TABELA 11: REMQ para o ranking de relações ZR em diferentes níveis de *dBZ*

Relação	<i>a</i>	<i>b</i>	<i>dBZ</i>									
			30	31	32	33	34	35	36	37	38	39
1	200	1.6	1.35	1.54	1.63	1.83	2.05	2.33	2.61	3.07	3.48	4.97
2	161	2.8	1.49	1.67	1.88	2.02	2.48	2.51	2.61	2.94	4.11	3.79
3	56	1.9	2.47	2.83	3.10	3.55	3.84	4.54	5.14	5.81	6.17	8.16
4	56	1.6	3.89	4.59	5.31	6.29	7.13	8.66	10.13	11.77	13.22	16.83
5	60	1.9	2.33	2.67	2.92	3.34	3.60	4.26	4.82	5.45	5.78	7.70
6	52	2.7	1.41	1.55	1.60	1.70	1.91	1.94	1.94	2.12	2.88	3.02
7	298	1.8	1.47	1.61	1.73	1.80	2.13	2.06	2.02	2.21	3.02	3.00
8	61	2.4	1.49	1.65	1.70	1.83	1.98	2.08	2.13	2.30	2.78	3.31
9	179	2.6	1.48	1.66	1.85	1.98	2.42	2.43	2.50	2.80	3.94	3.62
10	249	1.5	1.34	1.50	1.59	1.75	1.99	2.25	2.52	3.02	3.48	5.05

Relação	<i>a</i>	<i>b</i>	<i>dBZ</i>									
			40	41	42	43	44	45	46	47	48	49
1	200	1.6	5.25	6.68	7.95	10.13	8.75	13.99	15.67	18.96	20.63	31.45
2	161	2.8	5.36	4.41	5.74	5.87	9.35	7.10	9.42	13.59	12.41	4.23
3	56	1.9	8.40	10.36	11.73	14.12	12.60	18.13	19.68	22.53	24.25	34.73
4	56	1.6	18.62	22.69	26.61	31.84	33.44	43.03	49.51	56.31	66.25	84.78
5	60	1.9	7.90	9.76	11.06	13.35	11.77	17.15	18.57	21.38	22.82	33.05
6	52	2.7	3.91	3.22	4.21	4.57	6.43	5.27	6.75	11.03	8.48	3.94
7	298	1.8	3.88	3.25	4.15	4.72	5.37	5.71	6.54	10.46	7.25	10.87
8	61	2.4	3.76	3.58	4.31	5.00	5.24	5.73	6.44	10.40	7.14	8.25
9	179	2.6	5.12	4.15	5.42	5.53	8.81	6.62	8.80	12.98	11.48	3.33
10	249	1.5	5.42	7.02	8.50	10.95	9.81	15.58	17.81	21.46	24.31	36.36

Relação	<i>a</i>	<i>b</i>	<i>dBZ</i>			
			50	51	52	53
1	200	1.6	33.21	41.44	51.24	66.68
2	161	2.8	9.76	7.73	1.88	4.53
3	56	1.9	35.94	42.95	51.98	65.82
4	56	1.6	92.77	113.15	130.08	157.71
5	60	1.9	34.12	40.80	49.64	63.18
6	52	2.7	7.02	3.79	5.92	13.05
7	298	1.8	11.17	12.84	19.08	28.94
8	61	2.4	8.74	7.96	12.87	20.94
9	179	2.6	8.79	6.28	0.00	6.66
10	249	1.5	39.04	49.34	60.39	78.07

FONTE: O autor (2014)