

## APLICAÇÃO DAS REDES NEURAIS DE BASE RADIAL NA METEOROLOGIA

Emerson Yoshio Maeda (IC, FUNDAÇÃO ARAUCÁRIA), (UNESPAR/FECILCAM),  
math.maeda@gmail.com

Juliano Fabiano da Mota (OR), (UNESPAR/FECILCAM), jfmota@fecilcam.br

Adriano Vitor (CO-OR), IFSC, profadrianovitor@hotmail.com

**RESUMO:** As Redes Neurais Artificiais são um grupo de modelos matemáticos que simulam o funcionamento do sistema neurológico humano. Esta técnica tem sido utilizada em diversas áreas do conhecimento, nos mais diversos tipos de problemas, tais como: o reconhecimento de padrões, a aproximação de funções e a previsão de séries temporais, sendo que, na maioria dos casos, com uma eficácia igual ou superior a outras técnicas. Nesta pesquisa, o principal objetivo foi ajustar os parâmetros de uma Rede Neural para realizar a previsão do nível de precipitação pluviométrica na região de Campo Mourão, por meio de dados históricos coletados na estação climatológica, mantida pelo departamento de Geografia da UNESPAR – Universidade Estadual do Paraná (Campus de Campo Mourão). Nesta pesquisa foi utilizado um algoritmo de aprendizagem Rede Neural de Base Radial e também foi realizada a comparação com outro algoritmo de aprendizagem conhecido como *Back-Propagation*. Nota-se que a aplicação das Redes Neurais de Base Radial apresentou um ganho considerável em relação à outra rede testada.

**PALAVRAS-CHAVE:** *Redes Neurais Artificiais; Rede Neural de Base Radial; Meteorologia.*

### INTRODUÇÃO

A previsão de precipitação pluviométrica tem um alto grau de não linearidade dos eventos, logo pode ser considerada uma tarefa complexa, dificultando a previsão.

Para auxiliar na pesquisa foram considerados modelos matemáticos que tem como base o método de aprendizagem do cérebro, conhecido como Redes Neurais Artificiais (RNA), utilizado, nas mais diversas aplicações, para a resolução de problemas complexos.

Mais especificamente, nesta pesquisa foi utilizado um algoritmo de aprendizagem chamada Rede Neural de Base Radial (RBFNN), uma rede alimentada adiante (*feed-forward*) e supervisionada.

### DESCRIÇÃO DO PROBLEMA

A cidade de Campo Mourão, selecionada para o desenvolvimento da pesquisa, situa-se na região Noroeste do Estado do Paraná. Segundo Mota (2007), Campo Mourão agrega 25 municípios com economia baseada inicialmente no setor primário e hoje realiza investimentos na área industrial, já em avançado estágio de implementação do setor secundário e desenvolvimento do setor terciário.

Com o auxílio do Departamento de Geografia da FECILCAM – Faculdade Estadual de Ciências e Letras de Campo Mourão<sup>1</sup> foram coletados dados históricos na estação climatológica da FECILCAM, sobre as variáveis que influenciam na precipitação pluviométrica totalizando 365 exemplos observados (dias) e 15 variáveis, as quais estão descritas na Tabela 1. Essas informações históricas são fundamentais para o treinamento da Rede Neural.

Tabela1 - Variáveis Meteorológicas

VARIÁVEL	TIPO	DESCRIÇÃO
Pressão Média	Real	Fornecida em milímetros de coluna de mercúrio (mmHg)
Temperatura Média (Ar)	Real	Temperatura medida ao ar livre
Temperatura Média (Bulbo Úmido)	Real	Temperatura medida no bulbo úmido, que fica mergulhada em um recipiente em água destilada
Temperatura Média (Extrema)	Real	Tem como função mostrar a temperatura mínima e máxima no período de 24 horas
Umidade Relativa	Real	É a relação entre a pressão de vapor do ar e saturação sobre uma superfície de água
Velocidade do Vento	Real	Valores fornecidos nas horas 12h, 18h e 24h
Direção do Vento	1 Norte 2 Sul 3 Leste 4 Oeste 5 Noroeste 6 Nordeste 7 Sudoeste 8 Sudeste 9 Sem Direção	Direção fornecida sendo mostrada utilizando os pontos cardeais e colaterais
Precipitação	Real	A precipitação mensurada em milímetros de chuva num período de 24 horas
Evaporação	Real	Processo de evaporação da umidade presente na superfície terrestre
Insolação Média	Real	Total de horas de sol das 5 horas até as 19 horas
Nebulosidade Média	Real	Valor atribuído entre 0 a 10 nos horários de 12, 18 e 24 horas
Nuvens	Inteiro	Quantidade de nuvens visíveis a olho nu

<sup>1</sup> A FECILCAM é um Campus da UNESPAR – Universidade Estadual do Paraná, que está em fase de consolidação.

## REVISÃO DE LITERATURA

Nesta seção iremos abordar uma revisão literária sobre as redes neurais e suas principais características, a fim de fundamentar os experimentos realizados.

### Redes Neurais Artificiais

Segundo Haykin, (2001), estima-se que no cérebro humano haja aproximadamente 10 milhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões, e suas características são:

- É uma rede altamente interconectada;
- Apresenta paralelismo maciço, ou seja, muitos neurônios operando ao mesmo tempo;
- O processamento é distribuído de modo que a informação é não localizada, significando que um fato pode corresponder à atividade de certo número de neurônios;
- Admite tolerância à falhas, assim o prejuízo a poucos neurônios não afeta a operação do cérebro significativamente;
- A aprendizagem é exibida pelo ajustamento do efeito de acoplamento de dois neurônios.

Com base nessas premissas, Haykin (2001) define uma rede neural como uma máquina de processamento paralelo que pode transformar conhecimento experimental em informações úteis.

### Redes Neurais De Base Radial

As Redes Neurais de Base Radial é uma rede alimentada adiante e possui uma camada de entrada, uma intermediária e uma de saída. Neste capítulo será definido os principais tópicos utilizados nesta pesquisa.

### Funções de Base Radial

Segundo Haykin, (2001), uma Rede Neural é definida como Rede Neural de Base Radial quando a função de ativação dos neurônios de sua camada intermediária são de base radial. Uma função é dita como de base radial quando seu valor funcional é igual ao valor funcional da norma de seus argumentos, ou seja,

$$f(x) = f(|x|) \quad (3.1)$$

### O Problema da Interpolação

De acordo com Powell *apud* Mota (2011), Powell usou uma abordagem para aproximar funções por meio de combinações lineares de funções de base radial, que introduz um conjunto de  $N$

funções base, uma para cada observação amostral, tornando a forma  $\varphi(|x - x^n|)$  onde  $\varphi(\cdot)$  é uma Rede Neural de Base Radial. Logo, cada função base depende somente da sua distancia ( $|x - x^n|$ ) e a aproximação toma forma definida em:

$$h(x) = \sum_{n=1}^N w_n \varphi(|x - x^n|) \quad (3.2)$$

No problema da interpolação exata na equação 3.3 temos que  $t(x^n)$  são os valores alvos e  $h(x^n)$  são os resultados do modelo de interpolação,

$$h(x^n) = t(x^n) \quad (3.3)$$

combinando as duas equações, temos

$$\sum_{n=1}^N w_n \varphi(|x - x^n|) = t \quad (3.4)$$

podendo ser representado matricialmente por,

$$\varphi \cdot w = t \quad (3.5)$$

em que  $t = (t^1, t^2, \dots, t^n)$ ,  $w = (w_1, w_2, \dots, w_n)$  e  $\varphi$  é uma matriz quadrada. A solução formal da equação (3.5) é dada na equação (3.6) e segundo o Haykin, (2001), pelo teorema de Michelli a matriz é invertível.

$$w = \varphi^{-1} \cdot t \quad (3.6)$$

### O Problema do XOR

Com o intuito de exemplificar o funcionamento de uma Rede Neural de Base Radial, apresentamos a seguir um problema clássico na classificação de padrões conhecido como XOR, também chamado de problema do "ou" exclusivo.

Para Haykin, (2001), o problema do XOR (ou exclusivo) tem como objetivo construir um classificador de padrões que produza a saída binária 0 ou 1 dependendo do padrão de entrada, nesse problema do XOR existem quatro pontos (padrões): (1,1), (0,1), (0,0) e (1,0) em um espaço bidimensional. Desta forma os pontos mais próximos no espaço de entrada, em termos da distancia de

Hamming, são mapeados para regiões que estão mais afastadas no espaço de saída. As funções de ativação são as gaussianas:

$$\varphi_1(x) = e^{-\|x-t_1\|^2} \quad (3.3)$$

$$\varphi_2(x) = e^{-\|x-t_2\|^2} \quad (3.4)$$

Assim podemos mapear os padrões de entrada para o plano por meio de  $\varphi_1 - \varphi_2$  como será mostrada na figura a seguir.




Figura 1 – Diagrama de tomada de decisão.

### Trabalhos Correlatos

Coelho (2000), utiliza a Rede Neural de Base Radial para previsão de series temporais, seus resultados são encorajadores e mostrou vantagens devido a capacidade de aproximação de funções não lineares, com rapidez e eficiência do aprendizado.

Altran (2005) fez um estudo das Funções de Base Radial e Sigmoidal aplicada à previsão de cargas elétricas via Redes Neurais Artificiais utilizando dados históricos de um período pré-estabelecido. Os resultados dos testes com a função de Base Radial foram mais precisos quando comparados com a função Sigmoidal.

Mota (2011), utilizou as Redes Neurais de Base Radial com o Algoritmo Genético para determinar os pesos da Camada de Saída de uma Rede Neural de Base Radial e comparou com o

modelo exato da pseudo-inversão, e os testes mostraram que é capaz de gerar resultados bons se comparado com o modelo exato.

## EXPERIMENTOS E ANÁLISE DOS RESULTADOS

Nesta pesquisa foram coletados dados históricos na estação climatológica mantida pelo Departamento de Geografia da FECILCAM, totalizando 365 observações contendo os valores observados das variáveis meteorológicas.

Foram observadas 15 variáveis meteorológicas, foi elaborado um algoritmo para discretização das saídas separando-as em três classes, com o auxílio do MATLAB2010a®, com algoritmos existentes em suas bibliotecas de funções e algumas rotinas criadas buscando automatizar tarefas. Na Tabela 2 é possível observar como foi realizada a discretização das classes: “Não chove”, “Chove até 50mm” e “Chove mais de 50mm”.

Tabela 2 – Discretização das Classes

Classe Discretizada	Classe
$(1 \ -1 \ -1)$	Não Chove
$(-1 \ 1 \ -1)$	Chove até 50mm
$(-1 \ -1 \ 1)$	Chove mais de 50mm

O experimento consistiu em modelar uma Rede Neural de Base Radial testando de dois a 30 neurônios na camada escondida, com incremento de dois neurônios a cada rodada. A função de base radial utilizada foi a Gaussiana. Como os pesos iniciais são aleatórios, o experimento foi realizado 10 vezes com cada quantidade de neurônios na camada escondida e os melhores resultados obtidos com cada configuração foram codificados na Tabela 3 da seguinte forma:

- *ptr*: percentual de classificações corretas no conjunto de treinamento;
- *pvl*: percentual de classificações corretas no conjunto de validação;
- *pts*: percentual de classificações corretas no conjunto de teste;
- *nneuro*: é a quantidade de neurônios na camada intermediária.

Como é possível observar na Tabela 3, no experimento realizado o melhor resultado foi 82% no conjunto de teste utilizando 24 neurônios na camada escondida. É possível também notar que, embora nenhum resultado do conjunto de treinamento tenha ultrapassado os 70% de capacidade preditiva, vários resultados do conjunto de testes, em 13 das 15 arquiteturas testadas, ultrapassaram esse patamar.

Tabela 3 – Resultados Obtidos com a Rede Neural de Base Radial

<i>Ptr</i>	<i>Pvl</i>	<i>pts</i>	<i>nneuro</i>
61	76	69	2
65	31	69	4
63	64	75	6
65	57	76	8
67	57	71	10
62	67	76	12
63	65	73	14
64	63	75	16
62	67	76	18
62	65	78	20
63	67	73	22
<b>64</b>	<b>56</b>	<b>82</b>	<b>24</b>
65	63	72	26
65	60	75	28
65	58	76	30

Na Tabela 4 estão apresentados os resultados obtidos em Maeda, Mota e Vitor (2011), codificados da seguinte forma:

*ptr*: percentual de classificações corretas no conjunto de treinamento,

- *pvl*: percentual de classificações corretas no conjunto de validação,
- *pts*: percentual de classificações corretas no conjunto de teste,
- *nneuro*: é a quantidade de neurônios na camada intermediária,
- *fci*: função de ativação na camada intermediária podendo ser:
  - *Lin* – função linear,
  - *Tanh* – tangente hiperbólica e,
  - *Log* – logística,
- *ta*: taxa de aprendizagem com melhor desempenho naquela configuração,
- *algr*: variação do algoritmo utilizada, podendo ser:
  - *Original*: versão original do algoritmo,
  - *Momentum*: adição da taxa de momento,
  - *Momentum* e *taa*: adição da taxa de momento e taxa de aprendizagem adaptativa,
  - *Levmarg*: Variação de *Levenberg-Marquardt*.

Vale ressaltar que o trabalho de Maeda, Mota e Vitor (2011), utilizou o *Perceptron* de Múltiplas Camadas como algoritmo de aprendizagem para o treinamento da Rede Neural.

Tabela 4 – Resultados Obtidos com o *Perceptron* de Múltiplas Camadas

<i>Algr</i>	<i>ptr</i>	<i>pvl</i>	<i>pts</i>	<i>nneuro</i>	<i>fci</i>	<i>t.a</i>
Original	64	68	57	20	Lin	0,01
<i>Momentum</i>	62	72	71	28	Log	0,5

<i>Momentum e taa</i>	52	75	62	30	Tanh	0,5
<i>Levmarq</i>	62	64	47	6	Log	0,5

O resultado obtido com maior percentual de acerto utilizando o *Perceptron* de Múltiplas Camadas foi 71% no conjunto de testes, com a inserção da taxa de *Momentum*. Analisando com a Tabela 3 pode-se perceber que a Rede Neural de Base Radial teve uma melhoria significativa se comparada com a outro modelo matemático testado, que somente em dois casos a Rede Neural de Base Radial apresentou resultados inferiores, se comparado com o melhor caso do *Perceptron* de Múltiplas Camadas.

### CONSIDERAÇÕES FINAIS

O modelo matemático Rede Neural de Base Radial mostrou uma eficiência superior ao *Perceptron* de Múltiplas Camadas. De acordo com os testes realizados a capacidade preditiva foi superior a 82% no conjunto de testes, com a utilização de 24 neurônios na camada escondida, com função de ativação do tipo Gaussiana, contra 71% no melhor caso apresentado no *Perceptron* de Múltiplas Camadas. Está técnica mostrou superior também no tempo computacional referente a outra técnica citada.

Em suma, o modelo desenvolvido mostrou a sua superioridade se comparado com o *Back-Propagation* e com acerto de 82% no conjunto de teste. Para uma futura implementação num programa de computador com essa capacidade de acerto, seria viável à implementação do algoritmo.

### AGRADECIMENTOS

À Fundação Araucária pelo apoio financeiro por meio do Programa de Bolsas de Iniciação Científica em convênio com a UNESPAR/FECILCAM.

### REFERÊNCIAS

ALTRAN, A. B. **Um estudo das funções de base radial aplicadas a previsão de cargas elétricas via Redes Neurais Artificiais.** Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, São Paulo, 2005.

COELHO, L. dos S. **Rede Neural de Base Radial em previsão de series temporais: algoritmo e aplicação.** Pontifícia Universidade Católica do Paraná, Paraná, 2000.

HAYKIN, S. **Redes neurais: princípios e práticas.** 2. Ed. Porto Alegre: Bookman, 2001.



MAEDA, E. Y. **Aplicação de redes neurais artificiais na previsão de precipitação pluviométrica na região de campo mourão com base em variáveis meteorológicas.** VI Encontro de produção científica e tecnológica, Campo Mourão, Paraná, 2011.

MOTA, J. F. **Uma Rede Neural de Base Radial em computação evolucionária,** XXXII Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia, Ouro Preto, Minas Gerais, 2011.

MOTA, J. F. **Um estudo de caso para a determinação do preço de venda de imóveis urbanos via redes neurais artificiais e métodos estatísticos multivariados.** 74 f. Dissertação (Mestrado em – Métodos Numéricos em Engenharia) – Setor de Ciências Exatas e Tecnológicas, Universidade Federal do Paraná, Curitiba, Paraná, 2007.