



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA PREVISÃO DE PRECIPITAÇÃO PLUVIOMÉTRICA NA REGIÃO DE CAMPO MOURÃO COM BASE EM VARIÁVEIS METEOROLÓGICAS

MAEDA, Emerson Yoshio (PIBIC/FA), FECILCAM, math.maeda@gmail.com
MOTA, Juliano Fabiano da (OR), FECILCAM, jfmota@fecilcam.br
VITOR, Adriano (CO-OR), FECILCAM, profadrianovitor@hotmail.com

Resumo: As Redes Neurais Artificiais são um grupo de modelos matemáticos que simulam o 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, buscou-se 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). Foram comparadas quatro variações do algoritmo de aprendizagem *Back-propagation*, aplicado num *Perceptron* de múltiplas camadas: original, com adição da taxa de momento, com taxa de aprendizagem adaptativa e taxa de momento e por fim a variação de *Levenberg-Marquardt*. Os testes mostraram uma capacidade preditiva que varia 42% a 71% no conjunto de testes, o melhor resultado foi obtido com a adição da taxa de *momentum* (momento).

Palavras-chave: Redes Neurais Artificiais. Meteorologia. Previsão Pluviométrica.

1. INTRODUÇÃO

Segundo Mota (2007), o cérebro humano tem a capacidade de interpretar técnicas com auxílio de livros e/ou de professores, os quais ensinam a diferenciar objetos, animais, plantas, enfim tudo que se encontra no ambiente, tal como identificar o que é considerado correto.

A previsão de precipitação pluviométrica pode ser considerada uma tarefa complexa, pois as variáveis geralmente consideradas no problema possuem um alto grau de não linearidade, dificultando a previsão.

As RNA - Redes Neurais Artificiais, modelos matemáticos que têm como base utilizar o mesmo método de aprendizagem do cérebro humano, têm como um de seus objetivos auxiliar na resolução de problemas complexos nas mais diversas aplicações.

VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

Nesta pesquisa foi utilizado o algoritmo de aprendizagem *Back-propagation* que é num *Perceptron* de múltiplas camadas, uma rede alimentada adiante (*feed-forward*) e supervisionada, ou seja, uma rede em que o aprendizado é obtido por correção de erro. Nos experimentos realizados, foram consideradas quatro variações do algoritmo de aprendizagem *Back-propagation*: original, uma variação com taxa de momento, outra com taxa de aprendizagem adaptativa e taxa de momento e por fim a variação de *Levenberg-Marquardt*.

2. DESCRIÇÃO DO PROBLEMA

A cidade de Campo Mourão está situada na região Noroeste do estado do Paraná esta cidade foi selecionada para o desenvolvimento da pesquisa. A sede da COAMO Agroindustrial Cooperativa encontra-se nesta cidade e a economia predominante gira em torno da agricultura e do pólo alimentício.

Tabela1 - Variáveis Meteorológicas

continua

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	Direção fornecida sendo mostrada utilizando os pontos cardeais e colaterais



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

	6 Nordeste 7 Sudoeste 8 Sudeste 9 Sem Direção	
--	-----------------------------------------------------------	--

		conclusão
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

Com o auxílio do Departamento de Geografia da FECILCAM – Faculdade Estadual de Ciências e Letras de Campo Mourão¹, no qual 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.

3. REVISÃO DE LITERATURA

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

3.1. REDES NEURAIAS ARTIFICIAIS

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



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

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.

O cérebro tem seu funcionamento extremamente complexo, contudo poderia ser mais eficiente pela quantidade de conexões sinápticas e 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 para utilização.

3.2. BREVE HISTÓRICO DAS REDES NEURAIS ARTIFICIAIS

Existem trabalhos publicados sobre RNA há mais de 60 anos, mas somente a partir da década de 1990 houve a sistematização do desenvolvimento desta área de pesquisa.

Fausett (1994) apresenta um breve histórico sobre as Redes Neurais:

- 1943 – *Mc Culloch e Pitts* deram suas contribuições no estudo das RNAs. A proposta foi criar um modelo matemático para uma célula nervosa, denominado neurônio artificial. Com esse modelo poderiam calcular algumas funções lógicas particulares;
- 1949 – neste período foi criada a “regra de Hebb” que descobriu conexões entre os neurônios, por meio das sinapses, durante o processo de aprendizagem. Hebb propôs que as mudanças fossem proporcionais às ativações dos mesmos;



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

- 1959 – o *Perceptron* descrito por Rosenblatt foi o primeiro modelo de Rede Neural, que usando os valores das conexões entre as sinapses, poderia aprender certas funções lógicas;
- 1962 - a proposta de Widrow foi baseado no algoritmo da regra delta, conhecida como *Adaline*;
- 1969 – Minsky e Papert mostraram que o *Perceptron* possuía limitações. Neste período a pesquisa das RNAs foi abandonada quase que completamente;
- 1974 – Werbos lançou as ideias iniciais do algoritmo *Back-propagation*, o qual possibilitou que o *Perceptron* de múltiplas camadas tivesse capacidade de aprendizado;
- 1986 e 1987 – foram apresentados novos resultados com a técnica de retro-propagação e isto culminou num grande desenvolvimento para as RNAs.

3.3. CARACTERÍSTICAS DAS REDES *FEED-FORWARD*

3.3.1. Função de Ativação

O treinamento de Redes Neurais ou treinamento dos neurônios, pode ser escrito na forma de um modelo matemático:

$$v_k = \sum_{j=1}^n w_{kj} x_j + b_k \quad (3.1)$$

$$y_k = \varphi(v_k) \quad (3.2)$$

A equação (3.1) é um sinal de entrada na rede; a equação (3.2) a função φ é denominada função de ativação do neurônio. Segundo a Fausett (1994), existem três tipos de função de ativação que são os mais utilizados, é necessário que tal função seja contínua e diferenciável, pois há necessidade da utilização de sua derivada:

i. Função Degrau (*Threshold*):

$$\varphi(v_k) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.3)$$



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

ii. Função Linear:

$$\varphi(v) = v \text{ com } 0 < v < \infty \quad (3.4)$$

iii. Função Sigmoidal:

a) Função Logística:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.5)$$

b) Função Tangente Hiperbólica:

$$\varphi(v) = \tanh(v) \quad (3.6)$$

3.3.2. Arquiteturas

Para Haykin (2001) existem três tipos de arquiteturas diferentes que são fundamentais para o funcionamento da rede:

- Redes alimentadas adiante (*feed-forward*) com camada única: não se considera a camada de entrada, pois não é feito cálculo algum;
- Redes alimentadas adiante (*feed-forward*) com múltiplas camadas: também não é considerada a camada de entrada, o cálculo é feito somente nas camadas intermediárias e na camada de saída;
- Redes alimentadas adiante com laços de realimentação (redes recorrentes): neste caso a rede deve possuir pelo menos um laço de realimentação.

3.3.3. Aprendizagem

As Redes Neurais com a utilização de modelos matemáticos aprendem com a inserção de dados históricos, contanto que as variáveis sejam válidas para usar no algoritmo. O aprendizado da rede consiste basicamente em ajustar os pesos de forma que a rede consiga realizar uma determinada tarefa. Segundo Haykin (2001):

- Aprendizagem Supervisionado – também pode ser denominado “aprendizado com um professor”, quando o conjunto de valores de entrada tem seu próprio valor de saída. Quando o valor de saída é diferente da saída desejada, são ajustados os pesos para reduzir o erro;



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

- Aprendizado não-supervisionado – conhecido como rede Auto-Organizada, ou Mapa Auto-Organizado. Este tipo de rede classifica os dados sem a utilização de informações históricas, utilizando somente a semelhança entre os padrões como critério de classificação.

3.4. PERCEPTRON MULTICAMADAS E ALGORITMO *BACK-PROPAGATION*

O *Perceptron* de múltiplas camadas consiste em uma rede *feed-forward* na qual há, pelo menos, duas camadas, sendo uma intermediária e uma de saída, além dos nós de entrada. O algoritmo baseado em correção de erro mais utilizado para o treinamento deste tipo de rede é o *Back-propagation* que se baseia na descida do gradiente e aprendizagem por correção de erro para ajustar os pesos da rede. Em suma, este método consiste basicamente em melhorar, ajustar, os pesos da rede baseado em informações sobre a retropropagação do erro.

3.4.1. O Algoritmo *Back-propagation*

No algoritmo *Back-propagation* os pesos sinápticos são ajustados por meio de retropropagação do erro, a Figura 1 mostra o funcionamento do algoritmo num *Perceptron* de múltiplas camadas.

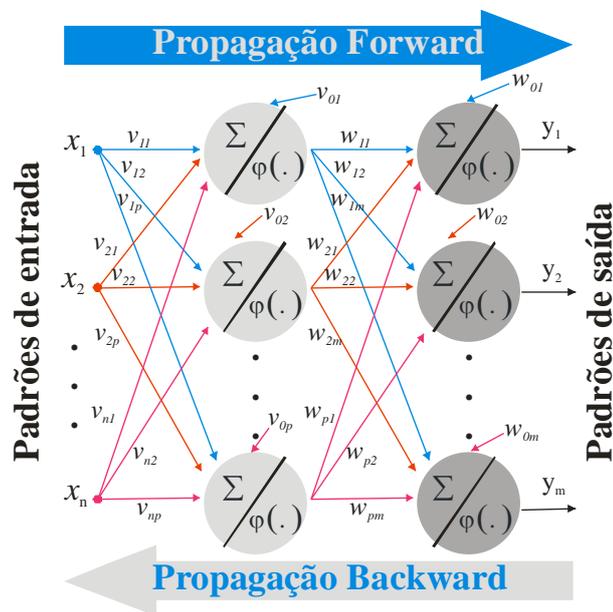


Figura 1 - Esquema do Algoritmo *Back-propagation*

O algoritmo *Back-propagation* tem seu aprendizado extremamente limitado quando aplicado num *Perceptron* de camada única, porém, se o número de camadas for aumentado para dois pode-se resolver uma quantidade significativamente maior de problemas. São raros os casos em que se fazem necessárias mais do que duas camadas.

3.4.2. Variações do Algoritmo *Back-propagation*

O algoritmo *Back-propagation* por anos tem sido foco de estudo para desenvolver variações do algoritmo. Para Silva *et al.* (2010) algumas das principais variações são:

- Taxa de *Momentum*: com a inserção do termo *momentum* obtém-se a garantia de que o “passo” será na direção de minimização da função de erro;
- Taxa de aprendizagem adaptativa: esta variação busca ajustar o tamanho do passo que se dá em direção ao mínimo da função em questão a cada iteração. Consiste em aumentar o passo, caso a rede neural sofra uma queda de desempenho e aumentar o passo, caso contrário.
- Método de *Levenberg-Marquardt*: A utilização desse algoritmo tende a exigir um esforço computacional elevado. Este é um método de gradiente de segunda ordem, baseado no método de mínimos quadrados para modelos



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

não lineares, que incorporado ao algoritmo *Back-propagation* pode reduzir a quantidade de iterações.

3.5. TRABALHOS CORRELATOS

Kaur *et al.* (2011) utilizaram o *Perceptron* de múltiplas camadas na previsão dos valores máximos e mínimos da umidade relativa do ar. Os resultados mostraram que a Rede Neural testada obteve uma boa acurácia, sendo possível visualizar graficamente o desempenho alcançado pelo modelo criado.

Mlakar e Buznar (2011) utilizaram o *Perceptron* de múltiplas camadas e redes de Kohonen para previsão de curto prazo da concentração de SO₂ (dióxido de enxofre) num ambiente semi-urbano. Os resultados mostraram superioridade das redes de Kohonen nas previsões de curto prazo.

Santhanam e Subhajini (2011) compararam uma Rede de Base Radial com o *Perceptron* de múltiplas camadas na previsão do clima baseadas em variáveis meteorológicas fornecidas por especialistas. Os resultados apontaram uma acurácia de 88,5% da Rede de Base Radial contra 82% do *Perceptron* de múltiplas camadas.

Cintra e Velho (2010) aplicaram uma RNA para substituir o cálculo da inversão de matrizes de erros constante do algoritmo de assimilação baseado em filtro de Kalman. Os resultados mostram uma melhora no desempenho do filtro em questão, entretanto a complexidade algorítmica aumentou consideravelmente.

Sousa e Sousa (2010) aplicaram o *Perceptron* de múltiplas camadas na previsão de vazão de um rio. Várias configurações da Rede Neural foram testadas e o melhor resultado obtido alcançou uma eficiência de 77% no conjunto de testes.

Tsukahara *et al.* (2010) utilizaram o *Perceptron* de múltiplas camadas na recuperação de valores em séries meteorológicas horárias, mais especificamente de falhas em tais séries. Os resultados mostraram que as Redes Neurais têm uma tendência a subestimar os dados reais, como se tentasse suavizar o modelo.

Moreira *et al.* (2008) utilizou umas das técnicas de RNA para estimar temperaturas mínima, média e máxima do ar, na região Nordeste do Brasil. Com o auxílio do Instituto Nacional de Meteorologia que forneceram dados suficientes para a aplicação do *Back-propagation*.



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

Oliveira *et al.* (2006) também aplicaram o *Perceptron* de múltiplas camadas na correção de valores em séries meteorológicas. Os resultados mostraram um bom desempenho do modelo desenvolvido, chegando a um coeficiente de correlação de $r = 0,99$ entre a série predita e a série real. Vale salientar que correlações acima de 0,7 são consideradas fortes.

Soares *et al.* (2000) aplicaram o *Perceptron* de múltiplas camadas de três camadas (entrada, intermediária e saída), e utilizou o algoritmo *Back-propagation error corrector algorithm* que aplica o padrão de entrada e se propaga para camada de saída e compara os resultados. A metodologia proposta foi para aplicar a previsão da precipitação pluviométrica mensal para o Nordeste do Brasil.

4. EXPERIMENTOS E ANÁLISE DOS RESULTADOS

Na fase inicial do projeto foi realizada uma vasta revisão bibliográfica sobre as RNA e o *Perceptron* de camada única e de múltiplas camadas para melhor compreensão do tema proposto.

Em seguida 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, na próxima etapa foi elaborado um algoritmo para discretização das classes que foram separadas 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



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

Os experimentos consistiram em modelar um *Perceptron* de múltiplas camadas, testando de dois a 20 neurônios na camada escondida, com cada uma das quatro variações do algoritmo *Back-propagation*, registrando o melhor resultado dentre as configurações de arquitetura testadas.

Como os pesos iniciais são aleatórios, o experimento foi realizado 10 vezes com cada variação do algoritmo. A Tabela 3 contém os melhores resultados obtidos com cada configuração e, apenas buscando uma melhor sistematização na apresentação dos resultados, a Tabela 3 está codificada 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;
- *algtr*: 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;
 - *Levmarq*: Variação de *Levenberg-Marquardt*.

Tabela 3 – Resultados Obtidos

<i>algtr</i>	<i>ptr</i>	<i>pvl</i>	<i>pts</i>	<i>Nneuro</i>	<i>fci</i>	<i>t.a</i>
<i>Original</i>	64	68	57	20	<i>Lin</i>	0,01
<i>Momentum</i>	62	72	71	28	<i>Log</i>	0,5
<i>Momentum e taa</i>	52	75	62	30	<i>Tanh</i>	0,5
<i>Levmarq</i>	62	64	47	6	<i>Log</i>	0,5

VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

Como é possível observar na Tabela 3, nos experimentos realizados, o melhor resultado foi a variação que leva em consideração a taxa de momento, chegando a classificar corretamente 71% dos exemplos do conjunto de testes.

Certamente, apesar da inserção de uma taxa de momento buscar evitar ótimos locais, a variação que apresentou melhores resultados encontrou um ótimo local com menor erro em relação às outras variações testadas.

5. CONSIDERAÇÕES FINAIS

Apesar de o algoritmo ter mostrado uma capacidade preditiva de 71% no conjunto de testes no melhor caso, o ideal é que este percentual seja superior a 80%. Em virtude disso, algumas considerações se fazem necessárias.

Primeiramente com relação às variações do algoritmo *Back-propagation*, é importante observar que:

- as diferenças entre as variações testadas foram bastante significativas, sendo que a melhor delas atingiu 71% de classificações corretas no conjunto de testes, ou seja, numa eventual implementação do modelo, a probabilidade de acerto na previsão estaria em torno dessa porcentagem, para novos exemplos não apresentados à rede;
- nenhuma das variações testadas apresentou desempenhos superiores a 60% no conjunto de treinamento. Isso mostra que a rede ficou com uma característica generalista e não houve, de forma alguma, o clássico problema de *overfitting* – rede que classifica corretamente mais de 90% dos exemplos do conjunto de treinamento e apresenta um desempenho muito inferior no conjunto de testes;
- A inserção da taxa de momento possibilitou ao modelo a fuga de um ótimo local que classificou corretamente apenas 57% do conjunto de testes e acabou por conseguir o melhor resultado de todos, pois as outras variações apresentaram desempenho inferior.

Com relação ao desempenho da técnica como método de previsão da precipitação pluviométrica, observamos:



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

- o problema de prever a precipitação pluviométrica não é uma tarefa simples de se modelar matematicamente, pois as variáveis que causam o fenômeno são altamente não lineares e as variações meteorológicas têm uma leve tendência caótica;
- os modelos matemáticos e estatísticos trabalham com uma simplificação da realidade e seus resultados exprimem apenas a parte sistemática da realidade, deixando a parte aleatória; um bom modelo é o que consegue minimizar esta parte aleatória;
- um sistema com apenas 71% de probabilidade de acerto na previsão seria pouco confiável e, mais ainda, não recomendável.

Em suma, o modelo desenvolvido deixou a desejar em vários aspectos, principalmente na probabilidade de acerto na previsão. Para uma eventual implementação num programa de computador que faça a predição do volume de chuvas, na região de Campo Mourão, o modelo deverá ser revisto e melhorado.

Como sugestões para trabalhos futuros, traçamos as seguintes observações:

Por constatar a insuficiência dos resultados apresentados, estão listadas a seguir algumas sugestões para trabalhos que busquem continuar a linha de pensamento apresentada aqui:

- testar outros modelos de Redes Neurais, tais como: as de base radial, as máquinas de vetor-suporte, entre outras;
- utilizar a Análise de Componentes Principais como ferramenta no tratamento dos dados, afim de evitar o problema da multicolinearidade dos dados;
- comparar a abordagem via Redes Neurais com a abordagem via Estatística;

AGRADECIMENTOS

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

REFERÊNCIAS

CINTRA, R.S, VELHO; H.F. de Campos; TODLING, R. **Redes Neurais Artificiais na Melhoria de Desempenho de Métodos de Assimilação de Dados: Filtro de Kalman.** Sociedade brasileira de Matemática Aplicada e Computacional p 29-39, 2010.



VI EPCT

Encontro de Produção Científica e Tecnológica

24 A 28 DE OUTUBRO DE 2011

FAUSETT, Laurene. **Fundamentals of neural networks: architectures, algorithms, and applications**. New Jersey: Prentice-Hall, 1994.

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

KAUR, Amanpreet; SHARMA, J K; AGRAWAL, Sunil. **Artificial neural networks in forecasting maximum and minimum relative humidity**. International Journal of Computer Science and Network Security, 2011

MLAKAR, Primož; BOŽNAR Marija Zlata. **Artificial Neural Networks - a Useful Tool in Air Pollution and Meteorological Modelling**. Advanced Air Pollution, p 495-508, 2011.

MOREIRA, Michel Castro; CECÍLIO, Roberto Avelino. **Estimativa das temperaturas do ar utilizando redes neurais artificiais, para a região Nordeste do Brasil**. Revista Brasileira de Agrometeorologia. p. 181-188, 2008

MOTA, Juliano Fabiano. **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.
MOTA, Juliano Fabiano; STEINER, Maria Teresinha Arns. **Estudando um caso de determinação do preço de venda de imóveis urbanos utilizando redes neurais artificiais e métodos estatísticos multivariados**. X Encontro de Modelagem Computacional, Nova Friburgo – RJ, 2007.

OLIVEIRA, Amauri; SOARES, Jacyra; ESCOBEDO, João. **An Application Of Neural Network Technique To Improve Quality Of Meteorological Measurements**. Congresso Brasileiro de Meteorologia; p. 1-5, 2006.

SANTHANAM, Tiruvenkadam; SUBHAJINI, A.C.; **An Efficient Weather Forecasting System using Radial Basis Function Neural Network**. Journal of Computer Science; p. 962-966, 2011.

SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SOARES, Alexandre Pinhel; LACERDA, Francis; MOURA, Geber Barbosa de Albuquerque. **Estimativa de precipitação pluviométrica mensal através das redes neurais**. Congresso Brasileiro de Meteorologia. p. 1357-1361. 2000.

SOUSA, Wanderson dos S.; SOUSA, Francisco de A. S. de; **Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó**. Revista Brasileira de Engenharia Agrícola e Ambiental. p. 173-180, 2010.

TSUKAHARA, Rodrigo Yoiti; JENSEN, Thomas; CARAMORI, Paulo Henrique. **Utilização de Redes Neurais Artificiais para Preenchimento de Falhas em Séries Horárias de Dados Meteorológicos**. Congresso Brasileiro de Meteorologia. 2010.