

# UMA ABORDAGEM *NEURO-FUZZY* PARA PREVISÃO DE CHUVA

*María Cleofé Valverde Ramírez*<sup>1</sup>, *Ernesto Araujo*<sup>2</sup>

## RESUMO

Um modelo *neuro-fuzzy* (NF) para previsão de chuva é apresentado neste trabalho. O modelo NF combina as técnicas das redes neurais artificiais (RNA) e a lógica *fuzzy* (LF) a fim de otimizar o método de aprendizado e treinamento da RNA ao mesmo tempo que se permite lidar com a incerteza e imprecisão em dados medidos. Os resultados mostram que o modelo NF produz previsões mais próximas ao observado quando comparado com a abordagem RNA convencional, apresentando-se como uma ferramenta promissora para previsão de sinais meteorológicos.

## ABSTRACT

A neuro-fuzzy (NF) model for rainfall forecasting is presented in this work. The NF model intertwines artificial neural networks (ANN) with fuzzy logic (FL) techniques in order to optimize the approach of learning and training of the ANN meanwhile to allow to deal with uncertainty and imprecision in measured data. Results show that the use of NF model produces better performance when compared to conventional ANN approach and so, this approach presents to be a promising tool for forecasting meteorological variables.

**Palavras Chaves:** Lógica *Fuzzy*, Redes Neurais Artificiais e Previsão de chuva.

## INTRODUÇÃO

A chuva é uma variável difícil de modelar devido à complexidade não-linear dos processos que a originam e a alta variabilidade no espaço/tempo (Olson, 1995). Técnicas não lineares de inteligência artificial têm surgido como ferramentas alternativas para auxiliar na simulação e previsão de chuva, assim como pré-processar as saídas dos modelos de previsão numérica do tempo. Destaca-se entre estas técnicas a RNA (Kuligowsky e Barros e 1998; Cavazos, 1997), que vem sendo utilizada na previsão de chuva (ASCE, 2000 e Valverde et al., 2005). Para fins de previsão uma RNA tem como base o aprendizado do comportamento de uma variável meteorológica a partir do comportamento passado ou presente de outras variáveis ou da mesma variável meteorológica. Para a RNA aprender, esta é submetida a um processo de treinamento, o qual está relacionado com a quantidade de neurônios (unidades de processamento da informação)

---

<sup>1</sup> Centro de Previsão de Tempo e Clima - CPTEC. Instituto Nacional de Pesquisas Espaciais – INPE.  
E-mail:valverde@cptec.inpe.br.

<sup>2</sup> Laboratório de Integração e Testes. Instituto Nacional de Pesquisas Espaciais - INPE  
C.P. 515, CEP: 12201-970, São José dos Campos – SP Brasil. E-mail:ernesto@lit.inpe.br

da camada interna que deve se fornecer a RNA para obter um bom desempenho (Haykin, 1994). A dificuldade da RNA é encontrar o número de neurônios adequados que evidenciem um bom resultado. Por este motivo, e dependendo da complexidade do parâmetro que se deseja prever a tarefa de treinamento pode se tornar trabalhosa. A fim de superar esta desvantagem da RNA, este trabalho explora a combinação do uso das RNA com a LF para previsão de sinais meteorológicos. O sistema NF tem como vantagens o aprendizado através de dados de treinamento (característica das redes neurais) e a fácil interpretação da funcionalidade (característica dos sistemas *fuzzy*) (Nauk, 1997).

O objetivo deste trabalho é avaliar o desempenho desta abordagem para previsão de chuva diária e mensal quando comparada ao mensurado e a resultados de previsão empregando uma RNA convencional.

## **DADOS E METODOLOGIA**

### **Dados**

Utilizaram-se as saídas do modelo regional ETA/CPTEC (Messinger, 1999) (1999-2002) fornecidos pelo CPTEC. Dados de precipitação mensal do modelo MPI-ECHAM (<https://esg.llnl.gov:8443/metadata/browse>) (1981-2100) e dados de precipitação diária para as estações de Campinas (KP), Ribeirão Preto (RP) e IAG/USP, fornecidos pelo Instituto Nacional de Meteorologia (INMET) e Instituto de Astronomia, Geofísico e Ciências Atmosféricas.

### **Metodologia**

Neste trabalho utilizou-se o modelo *neuro-fuzzy* do tipo Takagi-Sugeno (Sugeno, 1985) para previsão de chuva. A combinação das técnicas RNA e LF é chamada de sistema *Neuro-Fuzzy* e é utilizada para lidar com as dificuldades e limitações apresentadas para cada uma das técnicas isoladas (Sandri e Correa, 1999). Um sistema *neuro-fuzzy* é um sistema *fuzzy* que usa um algoritmo de estratégias de aprendizado derivado do comportamento de redes neurais para encontrar os parâmetros determinados pelos conjuntos *fuzzy* e regras *fuzzy* através do processamento de dados de treinamento (entrada e saída) (Nauk, 1997).

Sistemas *fuzzy* foram desenvolvidos por Zadeh (1965), tais sistemas são descritos por um conjunto de regras *fuzzy* do tipo: *SE* <premissa> *ENTÃO* <conseqüência> utilizando variáveis lingüísticas com termos simbólicos, que definem ações de controle em função das diversas faixas de valores que as variáveis de estado do problema podem assumir (Bothe, 1997). Considere, por exemplo, uma regra fornecida por meteorologista: *SE* <a temperatura do ar é 15 °C> *E* <a umidade relativa é 98 %> *E* <está completamente nublado> *ENTÃO* <a probabilidade de ocorrência de chuva é 70 %>. Regras como estas podem ser estipuladas pelo especialista que até certo ponto são subjetivas (experiência do previsor), mas que podem ser processadas matematicamente através da

lógica *fuzzy*. Se uma das principais vantagens desta abordagem é a capacidade de representar incertezas inerentes ao conhecimento humano; uma das desvantagens destes sistemas é não ter a capacidade de generalizar (Sandri e Correa 1999). A RNA, por outro lado, gera uma resposta (predição) a partir de um ou mais dados de entradas previamente conhecidos. Através de sucessivas apresentações dos dados de entrada e saída, a RNA aprende a relação entre elas e através de um algoritmo de minimização de erros, procura reduzir o erro quadrático médio em cada iteração do treinamento. Assim, esta relação pode ser aplicada para novos valores de entrada, a qual produzirá um valor de saída associado a uma nova previsão. Uma característica muito vantajosa das RNAs é a sua capacidade de generalizar, mesmo quando submetidas a uma situação não contemplada durante o treinamento (Haykin, 1994).

O modelo Takagi-Sugeno que é utilizado neste trabalho pode ser descrito por um conjunto de regras SE-ENTÃO que representam relações lineares locais de entrada e saída de sistemas não-lineares: Ri: SE <entrada\_1=x> E <entrada\_2=y>, ENTÃO saída <z<sub>i</sub> =ax+by+c>, sendo que a saída z<sub>i</sub> é ponderada para cada regra estabelecida por um peso, por exemplo para a regra “AND” o peso será: w<sub>i</sub> =AND(F<sub>1</sub>(x),F<sub>2</sub>(y)), onde F<sub>1,2(c)</sub> são funções de pertinências para a entrada 1 e 2. A eleição das funções de pertinência dependerá do comportamento da série que cada partição presente, usualmente pode ser representado por uma função sigmóide ou gaussiana. As regras nebulosas do tipo “AND” podem ser ilustradas da seguinte forma: SE a temperatura do ar é 32°C “AND” a nebulosidade predominante é cumulonimbus ENTÃO a probabilidade de chuva é de 90%. Logo a saída final do sistema é uma média ponderada de todas as regras de saída como segue:

$$saida\_final = \frac{\sum_{i=1}^N w_i x_i}{\sum_{i=1}^N w_i} .$$

Posteriormente ao estabelecimento da formulação *fuzzy* é aplicado um algoritmo de treinamento (retropropagação) (Haykin, 1994) para treinar os parâmetros das funções de pertinência e emular o comportamento desejado. Maiores detalhes ver Sandri e Correa (1999). A vantagem desta aproximação em relação a RNA é que a priori são estabelecidas às regras SE-ENTÃO com suas respectivas funções de pertinência, ao contrario da RNA que é preciso testar vários conjuntos de neurônios na sua camada interna até achar o melhor resultado. Para a geração dos resultados utilizou-se o *toolbox* de lógica *fuzzy* implementado no pacote *Matlab* v.7.0 (Misiti et al.,1997).

Para o estudo específico, inicialmente se determinaram as variáveis de entrada e saída para gerar o sistema de inferência *fuzzy* que modele o comportamento dos dados. Na previsão de precipitação diária se utilizaram como variáveis de entrada, a umidade específica, convergência de umidade, divergência e temperatura do ar derivadas do modelo ETA/CPTEC para prever a chuva local em cada estação de estudo. Para a previsão mensal se utilizou a série histórica passada e presente de chuva gerada pelo modelo MPI/ECHAM pertencente ao *Intergovernmental Panel on*

*Climate Changes* (IPCC), para prever o comportamento futuro sobre a região do Nordeste. Para a quantificação do desempenho nas previsões se utilizaram a raiz do erro quadrático médio e o coeficiente de correlação.

## RESULTADOS

### Previsão da Precipitação diária

O período de validação para os modelos NF e RNA compreendeu 16-29 (9 dias) de fevereiro de 2002, pois houve chuvas fortes sobre a região associadas à Zona de Convergência do Atlântico Sul (ZCAS). As previsões de chuva através das técnicas NF, RNA e do modelo ETA comparadas com a observação são mostradas nas Figuras 1, 2 e 3 para as estações de São Paulo: IAG/USP, Campinas e Ribeirão Preto. A previsão do ETA é determinada para o ponto de grade mais próximo a cada estação. Pode se observar nas figuras que as previsões da NF e a RNA conseguem capturar os períodos de chuva. Na estação do IAG a NF (Fig. 1a) aproxima melhor os valores previstos ao observado quando comparado com a RNA (Fig. 1b), embora gere chuvas muito fracas (<5 mm/dia) em dias em que não ocorreram de fato. Por outro lado, em Campinas (Fig. 2a), a previsão da RNA se aproxima melhor ao valor observado, enquanto que a previsão da NF superestima a chuva nos dias 5 e 6 (Fig. 2b). Na estação de Ribeirão Preto, a NF (Fig. 3a) conseguiu um melhor desempenho quando comparada com a RNA (Fig. 3b), pois, se aproximou mais aos valores observados, embora tenha superestimado a chuva no dia 5. Todavia, o modelo ETA teve dificuldade de capturar os períodos de chuva sobre tudo nas estações de Campinas e IAG. O resumo dos dados estatísticos que avaliam o desempenho dos modelos é mostrado na Tabela 1.

TABELA 1 – Raiz do erro quadrático médio dos diferentes modelos de previsão

	$\rho$			REQM		
	NF	RNA	ETA	NF	RNA	ETA
<b>IAG</b>	<b>0,94</b>	0,81	-0,035	<b>3,78</b>	10,13	<b>10,77</b>
<b>KP</b>	0,83	<b>0,88</b>	0,39	8,55	<b>5,25</b>	<b>16,03</b>
RP	0,82	<b>0,67</b>	<b>0,44</b>	9,3	<b>18,92</b>	<b>15,95</b>




Figura 1 – Previsão para os modelos para a estação do IAG: a) *Neuro-Fuzzy*, b) RNA, c) ETA. Os 9 dias equivalem ao período de 16-29 de fevereiro de 2002.




Figura 2 – Previsão para os modelos *Neuro-Fuzzy*, RNA e modelo Eta para a estação de Campinas.




Figura 3 – Previsão para os modelos *Neuro-Fuzzy*, RNA e modelo Eta para a estação de Ribeirão Preto

### *Previsão de precipitação mensal para a região do Nordeste*

Para a aplicação da abordagem NF na previsão mensal sobre o Nordeste foi selecionada uma área compreendida entre 43.60°W e 34.72°W, posteriormente se calculou a média da chuva na área a fim de se obter uma série temporal representativa do período chuvoso. Para o treinamento foi utilizado o intervalo de 1981 a 2006 enquanto que para a validação das abordagens foi empregado o período 2006-2100. As curvas obtidas pela previsão da NF assim como a do modelo MPI/ECHAM são muito próximas (4a), sendo a diferença obtida de  $10^{-5}$  mm/dia entre o previsto pela NF e pelo modelo MPI-ECHAM dada na Figura 4b. O comportamento da chuva (4a) é muito variável e se observa uma ligeira tendência de aumento da precipitação ao longo dos 100 próximos anos sobre o Nordeste.

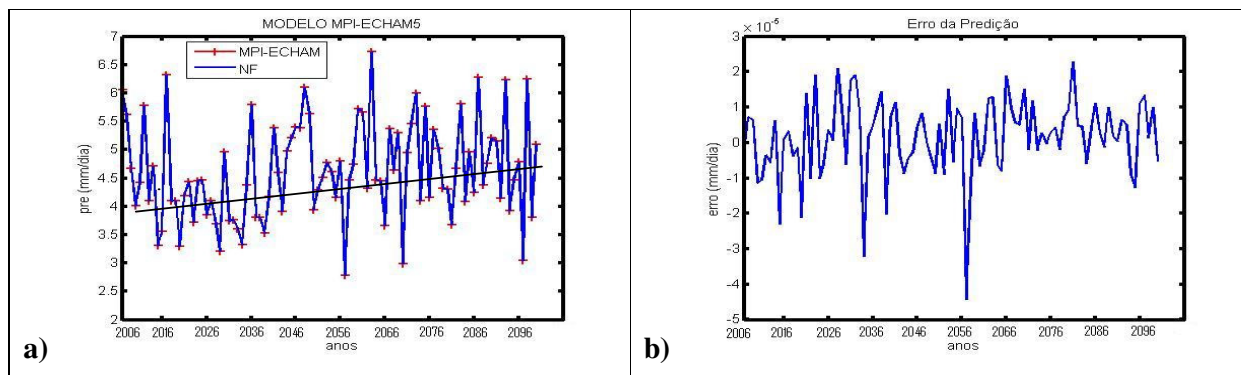


Fig. 4 Previsão de chuva do modelo MPI/ECHAM (a) e erro da previsão vs dado gerado pelo modelo (b).

## CONSIDERAÇÕES FINAIS

Os resultados da abordagem *Neuro-Fuzzy* na previsão de chuva apresentam-se promissores e mostraram a alta aplicabilidade da NF para previsão de tempo e clima da variável chuva. Na previsão diária o seu desempenho foi melhor quando comparado ao das RNA em duas das estações (KP e IAG). Embora não se possa fazer uma comparação direta com a previsão do ETA por ela apresentar um valor espacial (equivalente a sua resolução) e não pontual como é o caso da previsão da RNA e NF, nos dá uma idéia do erro do modelo e da necessidade de fazer procedimentos de *downscaling* estatístico para aprimorar a previsão do ETA. Por outro lado, para a previsão mensal os resultados foram ótimos. O modelo NF conseguiu reproduzir o comportamento pluviométrico que o modelo MPI-ECHAM simulou para os próximos 100 anos sobre o Nordeste. Vale ressaltar que a NF mostrou melhor desempenho para a previsão mensal que para a diária. Isto se deve a uma menor variabilidade temporal numa informação de chuva mensal que numa informação diária.

Os resultados da previsão da NF sugerem que pode ser utilizada com igual ou melhor desempenho na previsão de outras variáveis de menor complexidade dinâmica como é o caso da temperatura.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ASCE Task Committee on application of artificial neural networks in hydrology, 2000: Artificial neural networks in hydrology. II: Hydrologic application. *Journal of Hydrologic Engineering, ASCE*, 5, 124-137.
- Bothe, H. (1997). *Fuzzy neural network*. Seventh International Fuzzy System Association World Congress/ Tutorials – IFSA97, p. 01-387, Jun 1997.
- Cavazos, T. *Downscaling Large-Scale Circulation to Local winter rainfall in North-Eastern Mexico*. *International Journal of Climatology*, v. 17, n. 10, p. 1069-1082, Aug. 1997.
- Haykin, S. *Neural networks: a comprehensive foundation*. Ontario, Canada. Mc Master University, Prentice Hall International Inc, 1994.
- Kuligowski, R.; Barros A. Localized Precipitation Forecast from a Numerical Weather Prediction Model using Artificial Neural Networks. *Weather and Forecasting*, v. 13, n. 4, p. 1194 – 1204, Dec. 1998.
- Olson, D. A.; Junker, N.; Korty, B. (1995) Evaluation of 33 years of quantitative precipitation forecasting at the NMC. *Weather and Forecasting*, v. 10, n. 3, p. 498-511, Sep. 1995.
- Mesinger, F., 1984: A blocking technique for representation of mountains in atmospheric models, *Riv. Meteorol. Aeronaut.*, 44, 195-202.
- Misiti, M.; Misiti, Y.; Oppenheim, G.; Poggi, J. *MATLAB, wavelet toolbox: user's guide*. Natick, MA . The Math Works, Inc. 24 Prime Park Way, 01760-1500, USA. 1997.
- Nauck, D. *Neuro-Fuzzy Systems: Review and Prospects*. Proceedings of the Fifth European Congress on Intelligent Techniques and Soft Computing (EUFIT'97), Aachen, 1997.
- Sandri, S.; Correa C.; *Lógica Nebulosa*. In: *V escola de Redes Neurais*, IV Congresso Brasileiro de Redes Neurais. [CD ROM], São José dos Campos: ITA, p. c073 – c090, Jul, 1999.
- Sugeno, M., *Industrial applications of fuzzy control*, Elsevier Science Pub. Co., 1985.
- Valverde Ramírez M.C., H. Campos Velho and N. J. Ferreira, 2005: Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *Journal of Hydrology*, 30 (1-4), 146-162.
- Zadeh, L. Fuzzy sets. *Fuzzy Sets, Information and Control*, n. 8, p. 338-353, 1965.