

PREVISÃO SAZONAL DE PRECIPITAÇÃO NO CEARÁ: COMPARAÇÃO ENTRE MODELAGEM DINÂMICA E UM MODELO COM REDE NEURAL

THIAGO N. DE CASTRO¹, JOSÉ M. BRABO ALVES² & MOSEFRAN B. M. FIRMINO³

¹Bolsista, Mestrando em Engenharia Elétrica, Fundação Cearense de Meteorologia e Recursos Hídricos – FUNCEME – Av. Rui Barbosa, 1246, 60.115 – 221 – Aldeota – Fortaleza – Ce – tnc@funceme.br

²Meteorologista, Dr. em Engenharia Civil – Recursos Hídricos – Fundação Cearense de Meteorologia e Recursos Hídricos – FUNCEME – Av. Rui Barbosa, 1246, 60.115 – 221 – Aldeota – Fortaleza – Ce – brabo@funceme.br

³Engenheiro Civil, Ms. em Engenharia Civil e Ambiental – Companhia de Gestão de Recursos Hídricos – COGERH – Rua Adualdo Batista, 1550, 60.824 – 140 – Parque Iracema – Fortaleza – Ce – mosefran@gmail.br

Apresentado no XVII Congresso Brasileiro de Agrometeorologia – 18 a 21 de Julho de 2011 - SESC - Centro de Turismo de Guarapari, Guarapari - ES.

RESUMO: Água é um dos recursos naturais mais preciosos no mundo, especialmente em regiões como o Nordeste Brasileiro, que devido ao seu clima, faz-se necessário a otimização de seu uso. Atualmente existem diferentes técnicas utilizadas em previsão de chuvas. Neste artigo apresenta-se um modelo de previsão sazonal que utiliza Rede Neural Artificial (RNA) baseada em *Neo-Fuzzy Neuron* (NFN) e compara seus resultados com os obtidos por downscaling dinâmico com uso do Modelo Regional Espectral (*Regional Spectral Model* – RSM). Os resultados mostraram que a RNA-NFN tem potencial de previsão trimestral (nos primeiros seis meses do ano) de precipitação em várias regiões homogêneas do Estado do Ceará, com correlação mais expressiva e menor erro quadrático médio do que obtidos pela previsão dinâmica.

PALAVRAS-CHAVE: previsão sazonal, redes neurais, NFN

SEASONAL PRECIPITATION FORECAST IN CEARÁ: COMPARISON BETWEEN DYNAMIC MODELING AND A NEURAL NETWORK MODEL

ABSTRACT: Water is one of the most precious natural resource of the world, especially in regions like the Northeast of Brazil, due to its weather, requires the management of this resource. In nowadays there are many different techniques used in rainfall forecast. This work presents a seasonal forecast model that uses a Neo-Fuzzy Neuron (NFN) based Artificial Neural Network (ANN) and compare it results with the results of a dynamic downscaling model using the Regional Spectral Model (RSM). The results shows that the ANN-NFN had a great potential on the seasonal forecast (for the first six months of the year) of precipitation in many homogeneous regions of Ceará, with a more expressive correlation and a lower root mean square error compared to dynamic prediction.

KEY-WORDS: seasonal forecast, neural network, NFN

1 – INTRODUÇÃO

Água é um bem escasso e no Nordeste do Brasil (NEB) é dependente da variabilidade interanual de precipitação na Região. Na região semi-árida do NEB sua escassez é observada em particular nos últimos seis meses do ano. A fim de melhor gerenciar este recurso, diversos estudos vêm sendo feitos utilizando diferentes métodos para efetuar previsão de chuvas e assim melhorar a distribuição da água disponível na região (ALVES, COSTA, et al., 2007).

Técnicas estático-estocásticas vêm apresentando melhores resultados que os advindos da modelagem dinâmica. Downscaling dinâmico tem sido usado em várias áreas do globo mostrando resultados mais realísticos de várias variáveis atmosféricas (regime de ventos – monções, precipitação, etc), comparados a resultados de modelos globais atmosféricos com resolução horizontal acima de 250 km. No downscaling dinâmico modelos regionais com grades de dezenas de quilômetros ou menores são inicializados com dados vindos dos modelos globais (ALVES, COSTA, et al., 2007).

O uso de RNAs como modelos de previsão meteorológicas foram usadas em vários estudos, entre os quais citam-se (SRIVASTAVA, PANDA, et al., 2010); (TALEI, CHUA e QUEK, 2010) e (WU, CHAU e FAN, 2010) mostrando seu potencial nesta área de estudo.

Este trabalho apresenta um modelo de RNA baseado em NFN voltado à previsão sazonal de precipitação sobre as oito Regiões Homogêneas do estado do Ceará. Ao final é comparado com a previsão feita por downscaling dinâmico usando o RSM que é a versão do Modelo Regional (MR) de 1997 desenvolvido no Centro de Modelagem de Meio Ambiente do National Centers for Atmospheric Prediction (NCEP) (ALVES, COSTA, et al., 2007).

2 – MATERIAL E MÉTODOS

2.1 – Dados

Os dados utilizados para alimentar a RNA foram dados de reanálise do NECP das seguintes variáveis: divergência, movimento vertical, temperatura do ar, umidade específica, vorticidade, componente meridional e zonal do vento. Foram também utilizados dados de anomalias das regiões de Niño 3+4 e do dipolo de Temperatura da Superfície do Mar (TSM) no oceano Atlântico. Para os dados de reanálise foi feita uma média entre os níveis de 925 hPa e 850 hPa para uma grade de coordenadas entre 3°S-8°S e 41°W-37,5°W que contém o estado do Ceará como um todo. Os valores observados de precipitação mensal de observações diárias em postos pluviométricos no Estado do Ceará obtidas na Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) serviram de base para o cálculo da precipitação mensal por polígono de Thiessen para as oito regiões homogêneas do Estado (Figura 1). Calculou-se a precipitação acumulada para cada trimestre subsequente (exemplo: janeiro a março, fevereiro a abril, etc até o mês de junho).

Para os dados de precipitação prevista pelo RSM foi usada uma média dos 10 membros previstos, tendo como condição de contorno a TSM prevista. Foi feita uma interpolação da grade do RSM de 60 km dos valores de precipitação prevista pelo RSM e interpolada para uma grade de 10 km na área de cada sub-região homogênea e calculou-se a precipitação

trimestral na região usando a técnica de polígono de Thiessen. O RSM foi aninhado ao modelo global ECHAM4.5, cujas variáveis atmosféricas, de seus 10 membros, serviram para alimentá-lo de 6 em 6 horas no seu processo de previsão, maiores detalhes deste aninhamento-downscaling podem ser encontrados em ALVES, COSTA et al., (2007).



Figura 1 - Oito regiões homogêneas. Fonte: (FUNCEME)

2.2 – Neo-Fuzzy Neuron

Devido ao aumento do uso de Sistemas de Inferência Fuzzy (SIF) associados a RNA era esperado o surgimento de sistemas híbridos da sinergia entre eles. Inserido neste contexto encontram-se as RNA baseadas em NFN. A arquitetura de uma rede NFN é próxima da de uma RNA com n-entradas, porém ao invés de usar os pesos sinápticos contém sinapses não-lineares (BODYANSKIY, KOKSHENEV e KOLODYAZHNIY, 2003).

Este tipo de rede possui tantos neurônios quanto à dimensão do vetor de entrada, porém cada neurônio “n” possui “NSn” partições. Cada partição apresenta uma função de pertinência e um peso associado. Sendo assim, a entrada “ x_i ” passa por um processo de fuzzificação ponderado por um peso e então é feita a defuzzificação desta:

$$y = \sum_{i=1}^n f(x_i) = \sum_{i=1}^n (u_{ji}(x_i) \cdot w_{ji})$$

Onde u_{ji} é a função de pertinência da partição “ j ” da entrada “ x_i ”, w_{ji} é o peso da partição “ j ” da entrada “ x_i ” e “ y ” a saída do modelo.

Foi utilizado o algoritmo sugerido por BODYANSKIY, KOKSHENEV e KOLODYAZHNIY (2003) para atualização dos pesos. O modelo de RNA-NFN utilizou os dados dos meses de outubro, novembro e dezembro das variáveis de reanálises entre 925 hPa e 850 hpa, anomalia do Niño 3+4 e dipolo do Atlântico para estimar a precipitação acumulada dos próximos quatro trimestres (janeiro a março, fevereiro a abril, março a maio e maio a junho). O período

de treinamento escolhido foi entre os anos de 1961 a 2000, enquanto que para a validação utilizou-se o período de 2001 a 2010.

3 – RESULTADOS E DISCUSSÕES

Uma síntese dos resultados para as oito regiões podem ser visto na Tabela 1. Foram utilizadas como parâmetros de avaliação: a raiz do erro médio quadrático (do inglês Root Mean Square Error - RMSE) e a correlação entre valor previsto e observado para cada modelo.

Tabela 1 - Dados de análise estatística no período de validação do modelo

	Neural		RSM	
	RSME	Correlação	RSME	Correlação
Cariri	184,99	0,62	149,20	0,72
Ibiapaba	167,11	0,67	170,15	0,59
Jaguaribana	155,70	0,68	139,72	0,59
Macico de Baturite	147,39	0,76	171,18	0,47
Litoral Fortaleza	218,93	0,59	229,44	0,47
Litoral Norte	192,73	0,72	194,19	0,64
Litoral Pecem	177,02	0,65	182,43	0,54
Sertao Central Inhamuns	130,05	0,65	124,04	0,55

Verifica-se que a região do Cariri foi à única região que apresentou tanto RSME maior quanto correlação mais baixa para o modelo RNA em comparação ao apresentado pelo modelo RSM. Apenas as regiões do Sertão Central e Inhamuns e Jaguaribana apresentaram um RSME maior para o modelo neural, porém com maior correlação do que o modelo dinâmico. Na região do Maciço de Baturité foram obtidos os melhores resultados, cuja figura 2 mostra a variabilidade interanual entre as observações as duas técnicas de modelagem, para RNA pode-se observar uma previsão para os trimestres de 2011.

4 – CONCLUSÕES

Com base nos resultados obtidos pode-se afirmar que o modelo RNA apresenta um potencial elevado uma vez que apresentou resultados, em sua maioria, com erro menor e correlação maior que o modelo dinâmico. O treinamento da rede para cada região foi relativamente rápido, cerca de um minuto em um computador com processador Intel® Core™ 2 Duo de 2.00GHz, pois o modelo convergiu em poucas épocas. Modelo mostrou-se eficiente no que foi requisitado, uma vez que, apenas uma região apresentou piores resultados e as regiões do Sertão Central e Inhamuns e Jaguaribana apresentaram apenas um RSME maior que pode ter sido causado por extremos de precipitação ao longo dos anos de análise, visto que este parâmetro de avaliação tem grande influência das diferenças entre a precipitação observada e a prevista elevada ao quadrado.

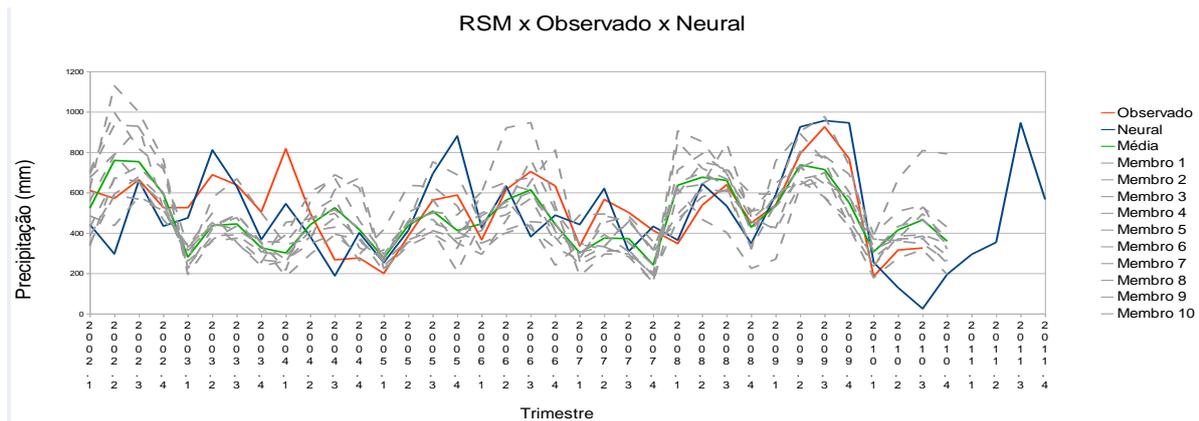


Figura 2 – Precipitação trimestral do Maciço de Baturité com a previsão do modelo Neural e dinâmica. A nomenclatura ANO.NÚMERO é utilizada para representar os trimestres de 1 = janeiro a março, 2 = fevereiro a abril, 3 = março a maio, 4 = abril a junho. As linhas em cinza representam as previsões dos 10 membros do modelo dinâmico e a linha em verde a sua média. A linha em azul representa a previsão do modelo Neural e a linha em vermelho representa os valores observados de precipitação para a região.

5 – REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, J. M. B. et al. Um Estudo Inter-Comparativo de Previsão Sazonal Estatística-Dinâmica de Precipitação no Nordeste Brasileiro. **Revista Brasileira de Meteorologia**, v. 22, n. 3, p. 354-372, 2007.

BODYANSKIY, Y.; KOKSHENEV, I.; KOLODYAZHNIY, V. An Adaptive Learning Algorithm for a Neo Fuzzy Neuron. **3rd Conference of the European Society for Fuzzy Logic and Technology**, 2003. 375-379.

FUNCEME. **FUNCEME**. Disponível em: <<http://www.funceme.br/index.php/areas/acudes-e-rios/precipitacao-media>>. Acesso em: Outubro 2010.

HAYKIN, S. **Neural Networks - A Comprehensive Foundation**. [S.l.]: Pearson, 1998.

SRIVASTAVA, G. et al. Forecasting of rainfall using ocean-atmospheric indices with a fuzzy neural technique. **Journal of Hydrology**, 20 Outubro 2010. 190-198.

TALEI, A.; CHUA, L. H. C.; QUEK, C. A Novel Application of a Neuro-Fuzzy Computational Technique in Event-Based Rainfall-Runoff Modeling. **Expert Systems with Applications**, 2010. 7456-7468.

WU, C. L.; CHAU, K. W.; FAN, C. Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data-Preprocessing Techniques. **Journal of Hydrology**, 25 Maio 2010. 146-167.