

Aplicação de Redes Neurais Artificiais e Transformada de Ondeletas para Estimativas de Precipitação usando imagens do satélite GOES-8 : Resultados Preliminares

Maria Cleofé Valverde Ramírez¹

Li Weigang²

Nelson Jesus Ferreira¹

¹Instituto Nacional de Pesquisas Espaciais – INPE

C.P. 515, CEP: 12201-970, São José dos Campos - SP, Brasil.

²Universidade de Brasília – CIC/UnB, C.P. 4466, CEP: 70919-970, Brasília –DF, Brasil

E-mails: valverde@met.inpe.br, nelson@met.inpe.br, weigang@cic.unb.br

Abstract

Artificial Neural Networks and Multiresolution Wavelet transform technique is applied to construct the nonlinear relationship between meteorological satellite and radar images. With the trained networks, the developed system gives the estimated next time precipitation image. The paper shows the method of network structure construction, input/output image pattern preparing and the sequence of the training. The statistic analysis results show the premise precipitation estimation for the São Paulo region. With the further modification, the system can be also used to estimate rainfall rate near radar cover region through the on-line update training process.

1. Introdução

O uso de Redes Neurais Artificiais (RNA) aplicada a situações meteorológicas para previsão ou reconhecimento de padrões ainda constitui um desafio para os pesquisadores. Embora esta técnica nos facilite estabelecer uma relação não linear, que é característica na dinâmica de quase todos os fenômenos meteorológicos não podemos explicar com precisão a física envolvida nesta. Para o caso específico de precipitação, as estimativas usando modelos de previsão numérica ou imagens de satélite meteorológico ainda não conseguem através de suas parametrizações estimar satisfatoriamente o campo de chuva. Por isso, com o intuito de alcançar um melhor desempenho nas estimativas de precipitação propõe-se o uso de RNA. O objetivo do trabalho é estimar precipitação treinando uma RNA supervisionada usando imagens de satélite meteorológico e tendo

como verdade terrestre os dados de Radar. As pesquisas até agora feitas tem sido orientadas a trabalhar com séries temporais num determinado ponto [2], [5], [6], [8], [10] e [11]. No estudo proposto trabalhou-se com dados bidimensionais, espaço e tempo, especificamente para processamento de imagens.

Tendo em vista a elevada carga computacional envolvida devido a grande quantidade de dados brutos das imagens de satélite utilizou-se a técnica das transformadas de ondeletas multiresolução (TOM), mediante esta técnica podemos decompor nosso sinal em diferentes escalas reduzindo a dimensão original dos dados. Os coeficientes obtidos pela decomposição são treinados separadamente na RNA, diminuindo o tempo de treinamento e reduzindo os problemas de generalização derivados deste. Note-se que sendo a TOM invisível, podemos levar o resultado da saída da RNA a sua dimensão original, através da TOM inversa.

2. Dados

Os dados utilizados foram as imagens do satélite meteorológico GOES8 no canal infravermelho (4x4 km), e dados de precipitação do radar meteorológico de Bauru (1x1 km). Estas imagens foram fornecidas pelo Centro de Previsão de Tempo e Clima (CPTEC) do INPE, e pelo Instituto de Pesquisas Meteorológicas (IPMet) respectivamente. A área de alcance do radar é a região central do Estado de São Paulo e o nordeste do Paraná (Fig. 1a). As imagens usadas foram do dia 2 de março de 1998 de três horários diferentes, com um intervalo de meia hora.

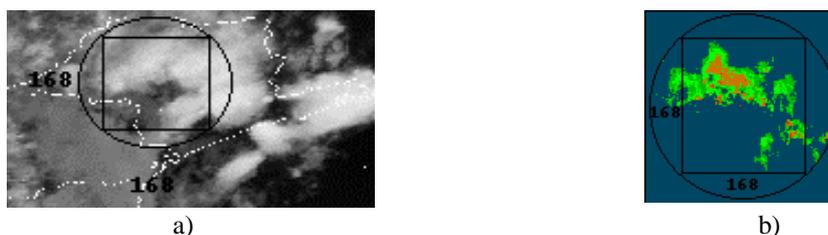


Fig. 1 - Imagem no canal infravermelho do satélite GOES8 (a) e imagem de Radar (b).

3. Metodologia

Redes Neurais Artificiais (RNA)

Para a aplicação da técnica de RNA utiliza-se o simulador SNNSv4.1 [12] desenvolvido pelo Institute for Parallel and Distributed High Performance System (IPVR) da Universidade de Stuttgart. O processamento da informação dentro das unidades é modelado no simulador com a função de ativação e a função de saída. A função de ativação primeiro computa a somatória ponderada dos valores de saída da camada de entrada. Logo a função de saída toma este resultado para gerar as saídas da camada de saída. A função de ativação default do SNNS é a Act-Logistic ou Logística, definida como:

$$a_j(t+1) = \frac{1}{1 + e^{-\left(\sum_i w_{ij} o_i(t) - \theta_j\right)}}$$

onde: $a_j(t+1)$ é ativação da camada j (camada interna) no passo $(t+1)$, w_{ij} é o peso da conexão entre os neurônios da camada de entrada i e os neurônios da camada interna j , o_i é a saída da camada i no passo t , θ_j é o limiar (bias) da camada j , i é o índice da camada de entrada, j é o índice da camada intermediária, k é o índice da camada de saída. A função de saída é a função identidade (Out_identity).

$$o_j(t) = f_{out}(a_j(t))$$

Onde: $a_j(t)$ é a função de ativação da camada j no passo t , e $o_j(t)$ é a saída da unidade j no passo t .

Transformada de Ondeletas Multiresolução (TOM).

A TOM é uma técnica de análise de sinal que decompõe dados ou funções em diferentes componentes de frequência e então estuda cada componente com uma resolução adequada a sua escala [4].

Num análise de TOM nos freqüentemente falamos de aproximação e detalhes. As aproximações são as escalas altas, componentes de baixa freqüência do sinal. Os detalhes são de escala baixa, componentes de alta freqüência. Mallat (1989) desenvolveu um eficiente algoritmo para implementar um método de decomposição usando o filtro Quadrature Mirror Filters (QMF) para processamento de sinais. Este filtro segue uma decomposição hierárquica de sinais para canais de frequência independentes [3]. Para este caso específico de pre-processamento de imagens de radar e de satélite, este critério tem como objetivo através da

decomposição reduzir a dimensão dos dados facilitando o treinamento da RNA e evitando problemas de sobregeneralização.

Para a decomposição usou-se a TOM biortogonal, esta ondeleta exibe a propriedade de fase linear a qual é necessária para sinais e reconstrução de imagens. A biortogonal é uma generalização da noção de bases ondeletas ortonormais, chamada biortogonais de ondeletas. Isto é, no lugar de uma base ortonormal da forma $2^{j/2} \psi(2^j x - k)$, $j, k \in \mathbb{Z}$, são usadas duas bases cada uma dual de outra, denotada por $\psi_{j,k}$ e $\tilde{\psi}_{j,k}$ [9].

Para efeito de comparação também usou-se esta TOM em sua versão periódica, supondo que nosso sinal é periódico, embora esta afirmação esteja longe da realidade a principal vantagem é que não apresenta coeficientes extras que geralmente são gerados no processo de filtragem. Desde que as TOM são um filtro de passa-banda com uma função resposta conhecida (a função ondeleta) é possível reconstruir a imagem original usando de modo idêntico deconvolução ou o filtro inverso.

3.1 Aplicação

3.1.1. Preparação dos dados

Primeiro se navegou ponto a ponto na imagem de satélite para localizar a área circular coberta pelo radar (Fig. 1a). Posteriormente a imagem de radar teve que ser degradada de 1x1 km para 4x4 km, para isto, usou-se o método de interpolação bicúbica. Para facilitar o tratamento da informação da área circular foi selecionado o quadrado máximo que apresentou uma dimensão de 168x168 pixels (Fig. 1(a)(b)).

Para a construção da arquitetura da rede tiveram que redimensionar-se as imagens. Para isto usou-se dois diferentes vias: a TOM e um método simples de interpolação bicúbica. A decomposição através das TOM foi feita para o nível 1 e para duas famílias das biortogonais (bior 4.1 e bior 4.2), por tanto nossos dados reduziram sua dimensão a 84x84 pixels para cada coeficientes de TOM (aproximação e detalhes). Estes coeficientes foram treinados separadamente pela RNA.

As etapas para o desenvolvimento do modelo de RNA são descritas:

- a) Construção da base de dados. Aqui definem-se dois conjuntos de dados:
 - Dados de entrada/saída conhecido na literatura como "training set". Usam-se para o treinamento dois padrões de entrada/saída: TEM1/RA1 e TEM2/RA2 (Ver Tabela 1)
 - Um conjunto para testar o treinamento da rede. Utilizou-se TEM3 para testar a arquitetura da rede

treinada e RA3 para comparar o resultado desse teste (precipitação estimada a partir de TEM3:

ERA3). Definem-se as imagens na Tabela 1.

Tabela 1 – Definição das imagens de radar e de satélite

Horário(GMT)	Nome da Imagem	Nome da imagem
	Imagem IR (temperatura de brilho °K)	Imagem de Radar (precipitação mm/hora)
20:08	TEM1	RA1
20:38	TEM2	RA2
21:08	TEM3	RA3

b) Configuração da estrutura da RNA e treinamento.

A rede utilizada foi a Rede Feed Forward de três camadas. Uma importante focalização das RNA é a questão de como ajustar os pesos das conexões para conseguir o comportamento desejado. Para o treinamento usou-se a lei de aprendizado Resilient Propagation (Rprop) [12]. Foram feitos vários testes com diferentes arquiteturas, sendo que a que proporcionou melhor resultado foi a de 84x84 neurônios nas camadas de entrada e saída e 28x28 na camada interna. A escolha de número de neurônios na camada interna foi feita tendo como critério que deles depende a não linearidade da rede e por conseguinte uma melhor generalização. A rede treinou com 2000 ciclos, e usando um parâmetro de aprendizado de 0.0001 garantiu uma boa convergência.

4 Análises dos Resultados

As imagens selecionadas apresentavam considerável nebulosidade associada a um sistema frontal que se deslocava pela região Sudeste do Brasil atingindo especificamente a região central de São Paulo (Ver Fig. 1(a)). As imagens de radar no mesmo horário confirmaram a existência de precipitação.

O treinamento do grupo de imagens entrada/saída TEM1/RA1 e TEM2/RA2 gerou uma arquitetura que foi testada com TEM3, o resultado

obtido foi a imagem de radar estimada (ERA3). Com esta arquitetura de rede também tentamos reconstruir RA1 (RRA1).

Os resultados obtidos pela RNA usando as diferentes formas de redução da dimensão (interpolação, TOM e TOM periódica) não mostraram diferenças notáveis espacialmente. A estimação (ERA3) mostrou uma boa distribuição espacial semelhante a chamada verdade terrestre (Fig. 2). Mas em termos quantitativos ela apresentou máximos e mínimos não coincidentes com a verdade terrestre os quais foram diferentes tanto nos dados que foram tratados com a simples interpolação e os que se aplicaram as TOM. A maior diferença foi na máxima precipitação observada. No entanto a reconstrução RRA1 foi quase idêntica quantitativa e espacialmente. A Fig. 2 mostra apenas as imagens de reconstrução de RA1 (RRA1) e de estimação de RA3 (ERA3) geradas pela RNA usando o método de redução bior3.7.

Foi feita uma avaliação estatística para observar as diferenças quantitativas nas diversas formas de redução. Calculou-se o desvio padrão (σ) e o erro quadrático médio (eqm). Utilizou-se o seguinte critério para poder afirmar que nossa estimação possa ser considerada boa [2]: $\sigma_r \cong \sigma_v$ e $MSE < \sigma_v$ onde r representa a estimação feita pela RNA e v a verdade terrestre (imagem de radar). A tabela 2 mostra os resultados.

Tabela 2

	Interpolação Cubica		Bior3.7				Bior4.4			
	ERA3	RA3	Periódica		Não - periódica		Periódica		Não - periódica	
	ERA3	RA3	ERA3	RA3	ERA3	RA3	ERA3	RA3	ERA3	RA3
σ	1.06434	1.406	1.11816	1.406	1.1612	1.406	1.17781	1.406	1.19967	1.406
Eqm	0.01242		0.998967		0.9510		0.99997		0.99669	
Vmax (mm)	18.87	23.7	16.87	23.7	15.80	23.7	23.37	23.7	22.48	23.37

Na tabela 2 podemos observar que os resultados gerados pela rede tanto com a simples interpolação como a de TOM apresentam uma estimação razoável desde que cumprem o critério estabelecido por Bitencourt ($eqm < \sigma_v$). De todos os

resultado aquele que usou-se a interpolação apresentou um valor de eqm menor. No entanto o que foi usado a TOM bior4.4 na sua forma periódica foi maior. Isto pode ser explicado devido à introdução de amostras extras no momento da decomposição. Se compararmos

a forma simples de TOM (sem ser periódica) e a periódica observaremos que o eqm é ligeiramente maior devido a sua propriedade de não apresentar coeficientes extras no processo de filtragem. A maior vantagem observada na aplicação das TOM é que na reconstrução dos coeficientes treinados obteve-se

valores de precipitação mais próximos à verdade terrestre se compararmos com a simples interpolação. Das duas famílias biortogonais, a bior4.4 na sua forma periódica apresentou o valor mais próximo a verdade terrestre (Tabela 2).

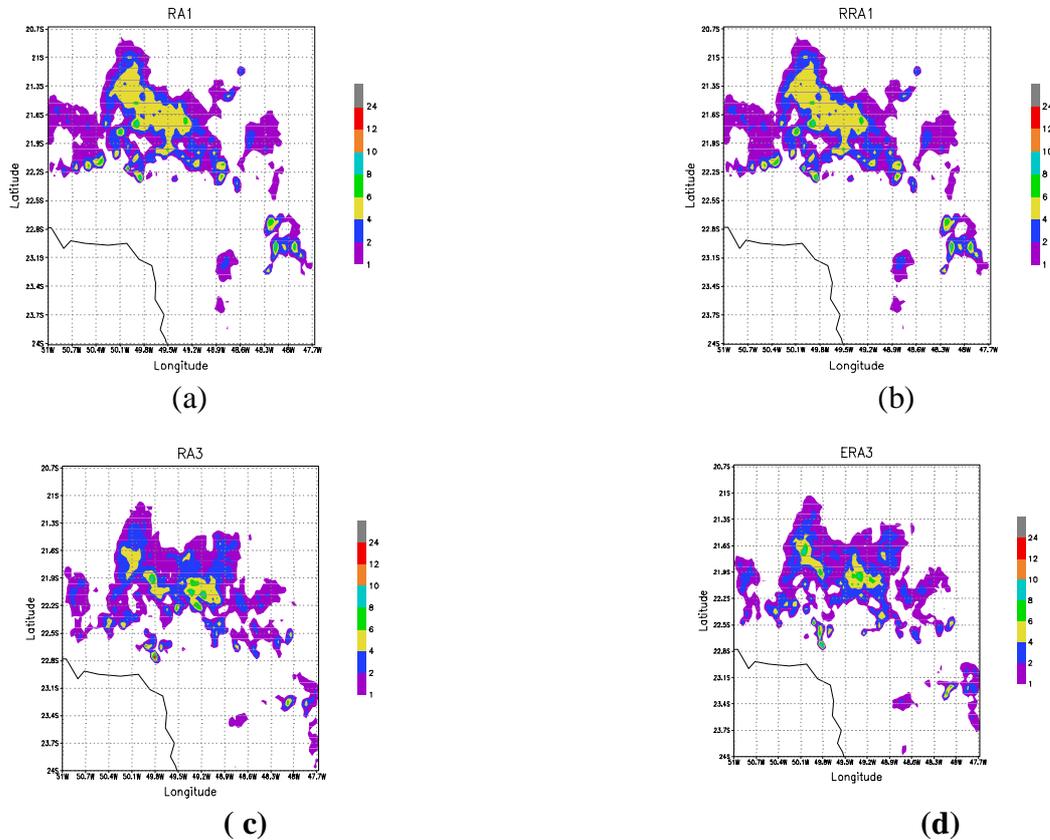


Fig. 2 Imagens de: (a) radar RA1, (b) reconstrução RRA1, (c) radar RA3, (d) estimacão ERA3.

5 Conclusões

O uso de RNA para o processamento de imagens de satélite, especificamente para a estimativa de precipitação constitui-se numa nova e útil ferramenta na área de Meteorologia. Os resultados preliminares indicam que a arquitetura da rede treinada localiza áreas de máxima e mínima precipitação utilizando a informação de temperatura de brilho numa imagem infravermelha. A técnica complementar usada (TOM) para reduzir a dimensão dos dados ajudou a diminuir o tempo de processamento da Rede. Assim, também observou-se que em sua versão periódica (bior 4.4) foi mais efetiva em nível quantitativo. Ela apresentou valores máximos de precipitação próximos a verdade terrestre. Embora tenhamos trabalhado com um número pequeno de imagem de dados (satélite e radar) e tenham surgido muitas questões que ainda precisam ser exploradas acreditamos que estes resultados apresentados são importantes já que estão servindo de

base para outros que estamos desenvolvendo atualmente.

6 Bibliografia

- [1] Bitencourt, P.D. (1996), Desempenho das previsões de variáveis simples e derivadas obtidas pelo modelo global do CPTEC/COLA para alguns casos significativos ocorridos sobre o centro-sul do Brasil. Tese de Mestrado. INPE, São José dos Campos.
- [2] Cavazos, T (1997) “Downscaling Large-Scale Circulation to Local winter rainfall in North-Eastern Mexico”. International Journal of Climatology, Vol 17, 1069-1082.
- [3] Cohen, A. Froment, J. (1989), Imagem compression and multiescale approximation. Wavelets and applications. Proceedings of the

- international conference. Editor, Y. Meyer. Pp. 181-206. Marseille, France, May.
- [4] Daubechies, I. (1992). *Tem Lectures on Wavelets*. Philadelphia, SIAM.
- [5] Hsu, K., Gao, X., Soroshian, S., e Gupta, H., (1997), Precipitation estimation from remotely sensed information using artificial neural networks. *Journal of Applied Meteorology* 36, 1176-1190.
- [6] Key, J. R. (1994). Classification of arctic cloud and sea ice features in multi-espectral satellite data. *Neural Nets: Applications in Geography*. Hewitson, B. C., Crane, R. G. (1994). Kluwer Academic Publishers. *Printer in the Netherlands*, pp 145-179.
- [7] Mallat, S., (1989): Multifrequency channel decomposition of images and wavelets models. *IEEE Trans. Acoust. Speech Signal Proc.*, vol 37, pp 2091-2110.
- [8] Marzbam, C., e G. Stumpf, (1996). Neural Network for Tornado prediction based on Doppler radar derived attributes. *Journal of Applied Meteorology*, 35:p.617-626.
- [9] Meyer, Y., (1993). *Wavelets Algorithms e Applications*. Society for Industrial and Applied Mathematics. Philadelphia. Pp. 59-60.
- [10] Sorooshian, S., (1997). Precipitation estimation from remotely sensed information using artificial neural network models (PERSIANN). *Global Energy and Water Cycle Experiment.*, 2: 1-7.
- [11] Weigang, L.; Sá, L.D.; Bevilaqua, R.M.; Nordenman, D.J. R. Prediction of Sea Surface Temperature in Tropical Atlantic Ocean Time Series using Neural Networks. *Brazilian Academy of Sciences Annals*, 68 (Supl. 1), pp. 23-33, 1996.
- [12] Zell, A., (1995). Stuttgart Neural Network Simulator –SNNS, Manual version 4.01, University of Stuttgart, Report N° 6/95.