

PREVISÃO DE CHUVA PARA O PADRÃO DE VERÃO ZCAS -VCAN ATRAVÉS DE UM *DOWNSCALING* ESTATÍSTICO

María Cleofé Valverde Ramírez¹, Nelson Jesus Ferreira¹ e Haroldo Fraga do Campos Velho²

RESUMO

Este trabalho realiza previsão de chuva diária para o padrão de verão ZCAS–VCAN sobre 12 localidades do estado de São Paulo, através de um *downscaling* estatístico das saídas do modelo Eta/CPTEC. Uma rede neural artificial (RNA) é utilizada para construir dois modelos de transferência de escalas para o *downscaling*. No primeiro, selecionaram-se casos de ocorrência do padrão ZCAS-VCAN para gerar o modelo de previsão, e no segundo se considerou toda a série do período de verão. O resultado da previsão através do *downscaling* mostrou que as previsões são melhores quando se especifica o fenômeno ao qual a chuva está associada. Quando as previsões são comparadas com a chuva gerada pelo modelo Eta, os erros diminuem em até 70%. Este é um aspecto esperado, uma vez que o *downscaling* visa refinar a previsão do modelo.

ABSTRACT

This work performs forecast of daily rain for the ZCAS-VCAN summer pattern over 12 places in the São Paulo state using a statistical downscaling of the Eta/CPTEC model. An artificial neural network is used to build two models for scaling transfer. For the first case, patterns of ZCAS-VCAN were selected to generate the forecast model, and for the second one, it was considered all series of the summer period. The result of the forecast using the downscaling has shown that the rain forecast is better when the weather pattern is specified. The errors with respect to ETA model are reduced up 70%. This feature is expected, since the downscaling process is applied to improve the model forecasting.

Palavras-Chave: *Downscaling* Estatístico, Previsão de Chuva, Redes Neurais Artificiais.

INTRODUÇÃO

Técnicas de *downscaling* estatístico para aprimorar as previsões dos modelos numéricos são utilizadas nos maiores centros de previsão de tempo do mundo. O principal objetivo destas técnicas é poder transferir a previsão espacial de um modelo numérico para uma previsão pontual, ajustando as previsões do modelo para localidades específicas (Hewitson e Crane, 1996). Para o

¹ Centro de Previsão do Tempo e Estudos Climáticos (CPTEC), Instituto Nacional de Pesquisas Espaciais (INPE). C.P. 515, CEP: 12201-970. São José dos Campos – SP Brasil.. E-mails: valverde@cptec.inpe.br, nelson@cptec.inpe.br.

²Laboratório Associado de Computação e Matemática Aplicada (LAC) – INPE. E-mails:, haroldo@lac.inpe.br

desenvolvimento de modelos de *downscaling* estatísticos usualmente utilizam séries contínuas que caracterizam períodos de verão, inverno, secos ou chuvosos, períodos frios ou quentes. Porém, nestes períodos encontram-se incluídos diferentes sistemas de tempo que podem não ter um mesmo desenvolvimento dinâmico. Neste contexto, utilizou-se uma versão simplificada do método de *downscaling* “*weather pattern methods*” (Wilby e Wigley, 1997). Este método inicialmente classifica subjetivamente ou objetivamente padrões de tempo para depois relacioná-los com a chuva local. Neste trabalho selecionaram-se casos do padrão ZCAS-VCAN para gerar um modelo neural de previsão de precipitação sobre a região de São Paulo, associado a este padrão de tempo.

As RNAs já tem sido utilizadas satisfatoriamente para *downscaling* estatístico sobre o Sudeste do Brasil (Valverde Ramírez et al, 2005 e 2006) utilizando as saídas do modelo regional Eta. Com este novo enfoque de *downscaling* espera-se melhorar as previsões, uma vez que esta nova ferramenta é alimentada por variáveis que caracterizam um comportamento dinâmico específico, relacionado com a chuva local.

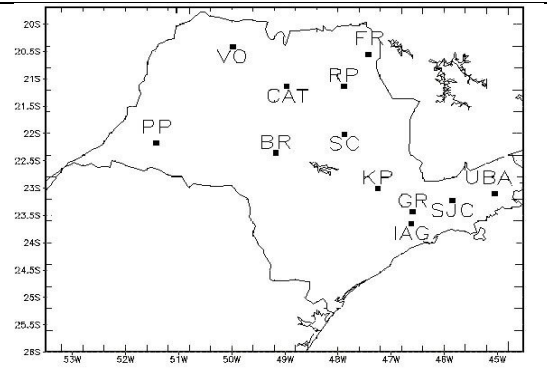
2. DADOS E METODOLOGIA

Dados

Dados de precipitação diária de 12 estações meteorológicas do estado de São Paulo (Tabela 1), fornecidos pela INFRAERO de Guarulhos, Instituto Nacional de Meteorologia (INMET) e Instituto de Astronomia, Geofísico e Ciências Atmosféricas (IAG/USP). Além disso, foram utilizadas saídas do modelo regional Eta (Mesinger, 1990) e imagens do satélite GOES-8 do CPTEC para o período de verão (dezembro 1999 a fevereiro 2002 e fevereiro de 2006).

TABELA 1- Características Geográficas das estações do estado de São Paulo

Nome da Estação	Cód	Lat/Lon	Alt (m)
Guarulhos	GR	23° 26' S/46° 28' W	803
IAG	IAG	23° 39' S/46° 37' W	598
Campinas	KP	23° 00' S/47° 08' W	661
Bauru	BR	22° 21' S/49° 03' W	590
Presidente Prudente	PP	22° 10' S/51° 25' W	435
Ribeirão Preto	RP	21° 08' S/47° 46' W	621
Franca	FR	20°33' S/47°24' W	1026
Catanduva	CAT	21°8'S/48°58' W	536
São Carlos	SC	22°6'S/47°53' W	856
São José dos Campos	SJC	23°13'S/45°51' W	660
Ubatuba	UBA	23°6'S/45°3' W	8
Votuporanga	VO	20°25'S/49°59' W	503



Metodologia

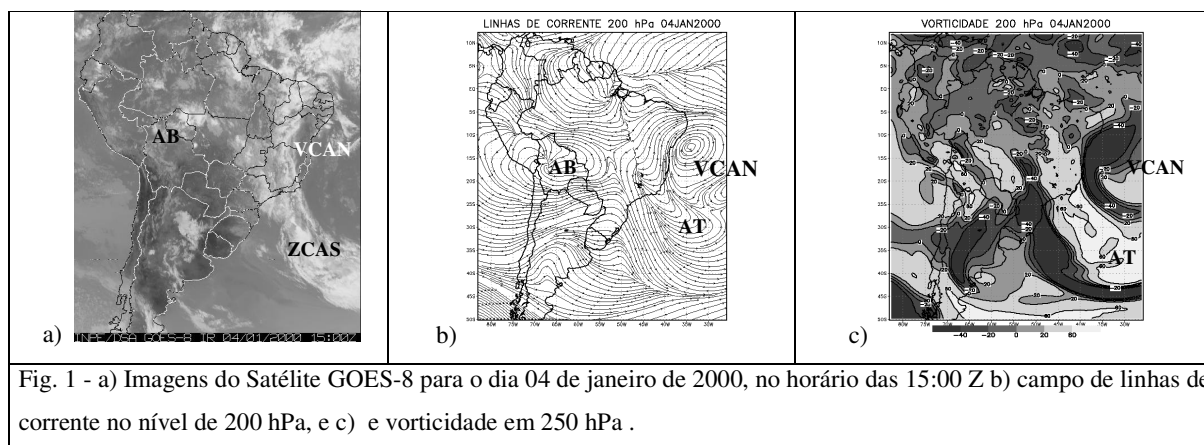
A RNA é uma técnica matemática que permite mapear conjuntos de dados de entrada e de saída através de uma função de transferência não linear. A formulação matemática de redes neurais artificiais é detalhada em Haykin (1994). Neste trabalho utilizou-se uma rede neural *feed-forward*

(*perceptron* de multicamadas), com uma função de transferência sigmoïdal e com o algoritmo de treinamento *resiliente propagation* (RPROP) (Riedmiller and Braun, 1993).

Para a construção do modelo neural de *downscaling*, utilizou-se como conjunto de entrada as variáveis em nove pontos de grade do modelo Eta mais próximos de cada estação meteorológica e correspondente aos horários: 06:00, 12:00, 18:00 UTC do dia anterior à previsão e 00 UTC do dia da previsão. O conjunto de saída foi a precipitação diária, na estação correspondente. A seleção dos preditores (variáveis de entrada da rede neural) baseada no estudo sinótico de identificação do padrão ZCAS-VCAN (Valverde Ramírez et al. 2004) são: umidade específica, convergência de umidade, divergência, temperatura potencial equivalente, água precipitável e velocidade vertical. Do conjunto total de dados foram selecionados 12 casos de ZCAS-VCAN. Destes casos, 10 serviram para treinamento e 2 para testar a RNA (Fevereiro de 2002 e 2006). Também foi criado um modelo neural para o período de verão completo, onde outros sistemas de tempo ocorreram, além do padrão ZCAS-VCAN. As estatísticas para quantificar o desempenho da previsão foram: o coeficiente de correlação (ρ) e o *Skill Score* (SS) (Mao et al 1999). Um SS positivo indica melhorias em valor de porcentagem da previsão do modelo neural sobre a previsão do Eta.

RESULTADOS

O padrão de verão ZCAS-VCAN forma-se pela atuação simultânea da ZCAS e do VCAN sobre o sudeste e nordeste do Brasil respectivamente, interagindo ambos os sistemas e reforçando a nebulosidade sobre a região Sudeste (Valverde Ramírez et al., 2004). A Fig. 1 exemplifica o caso ocorrido em 1-9/01/2000. A imagem de satélite mostra a banda de nebulosidade associada à ZCAS se misturando com a nebulosidade do VCAN. O campo de linhas de corrente mostra o VCAN próximo à costa, e no seu setor sul uma crista bem pronunciada associada à alta do Atlântico sul em altos níveis (AT) (Valverde Ramírez et al 1999, Ferreira et al, 2001). A Alta da Bolívia (AB) está presente, porém, pouco definida. O campo de vorticidade confirma a intensidade dos sistemas: VCAN (ciclônica) e ZCAS (anticiclônica). A Fig. 2 exemplifica dois casos ZCAS-VCAN: de 16-29/02/2002 e 9-13/02/2006 que foram utilizados para testar o modelo neural de *downscaling*.



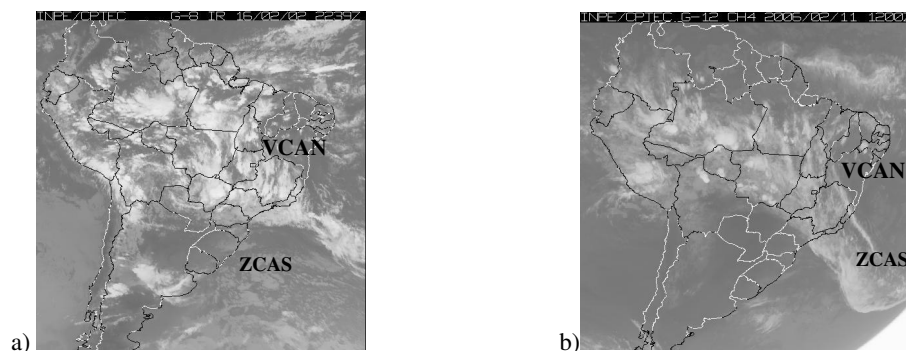


Fig. 2 - Imagens do Satélite GOES-8 a) dia 16/02/2002 às 22:39 Z, b) dia 11/02/2006 às 12:00Z

Resultados da Previsão

O modelo neural treinado foi testado para dois eventos; para o caso ocorrido em Fevereiro de 2002, os cálculos estatísticos (Tabela 1), mostraram que as previsões com o modelo neural (RNA e RNA- P) foram aprimoradas quando comparadas com o Eta em 10 (BR, CAT, GR, IAG, KP, SC, SJC, RP, UBA e VO) das 12 estações de estudo, sendo que sete delas (BR, GR, KP, IAG, SJC, RP e UBA) pertencem ao experimento que incluiu somente o padrão ZCAS-VCAN (**RNA-P**). Os coeficientes de correlação (ρ) para o experimento RNA-P estiveram acima de 0,8 com exceção da estação de UBA. Os coeficientes de correlação (ρ) para o experimento RNA alcançaram valores acima de 0,7.

Para o caso de Fevereiro de 2006, somente tivemos disponibilizadas informações de sete estações (CAT, FR, PP, SC, SJC, UBA e VO) e foi testado apenas o modelo RNA-P. Este caso de ZCAS-VCAN causou tempestades severas e acúmulos significativos de chuva sobre São Paulo, Rio de Janeiro e Minas Gerais (http://www.cptec.inpe.br/tempo/casos_significativos.shtml). Especificamente sobre o Vale do Paraíba, em SJC e no dia 13 se reportaram fortes temporais com presença de granizo. As estatísticas (Tabela 2) mostram que a **RNA-P** teve um bom desempenho com coeficientes de correlação de até 0,94 para UBA. Somente para Franca e São Carlos, estações com topografia acentuada, a rede não conseguiu superar a previsão do Eta.

Os SSs mostraram para ambos os casos testados, reduções significativas do erro em relação às previsões do Eta, de até 71,97 % para a estação de KP para o evento de Fevereiro de 2002 e de até 64,36 % na estação de PP para o evento de Fevereiro de 2006.

Por outro lado, o Eta previu melhor em FR e PP, especificamente em FR a RNA teve mais dificuldade e isto pode estar associado a fatores topográficos (Tabela 1), variável esta que o modelo neural não incluiu, mas que o Eta inclui nas suas parametrizações topográficas.

Na Figura 3 apresentam-se os gráficos de barras para algumas das estações de estudo comparando a precipitação observada com as previsões obtidas pelos experimentos RNA-P, RNA e o modelo ETA (valor da previsão do ponto mais próximo às estações de estudo), o que confirma e verifica os cálculos estatísticos obtidos na Tabela 2 depois do *downscaling* estatístico.

TABELA -2 - Índices Estatísticos: ρ e SS para os casos de ZCAS-VCAN de Fevereiro de 2002 e 2006

	Fevereiro 2002 (16-29)					Fevereiro 2006 (8-14)		
	ρ			SS(%)		P		SS(%)
	RNA	RNA-P	Eta	RNA	RNA-P	RNA-P	ETA	RNA-P
BR	0,32	0,91	0,51	40,02	43,81	-	-	-
CAT	0,79	0,57	0,19	31,38	10,35	0,72	0,46	0,67
FR	0,03	0,05	0,11	-48,90	-23,32	-0,20	-0,32	-157,67
GR	0,56	0,89	0,50	-3,40	38,60	-	-	-
IAG	0,70	0,81	-0,03	-0,76	6,08	-	-	-
KP	0,35	0,88	0,39	18,88	71,97	-	-	-
PP	-0,09	0,82	0,95	-105,29	-63,13	0,54	0,44	64,36
RP	-0,12	0,44	0,44	-40,0	5,29	-	-	-
SC	0,7	0,3	0,6	30,46	-54,59	0,61	0,61	-16,34
SJC	0,7	0,8	0,5	-9,33	49,75	0,54	0,18	15,56
UBA	0,3	0,3	-0,2	15,40	23,22	0,94	0,79	50,12
VO	0,7	0,5	0,2	28,44	31,06	0,86	0,75	7,11

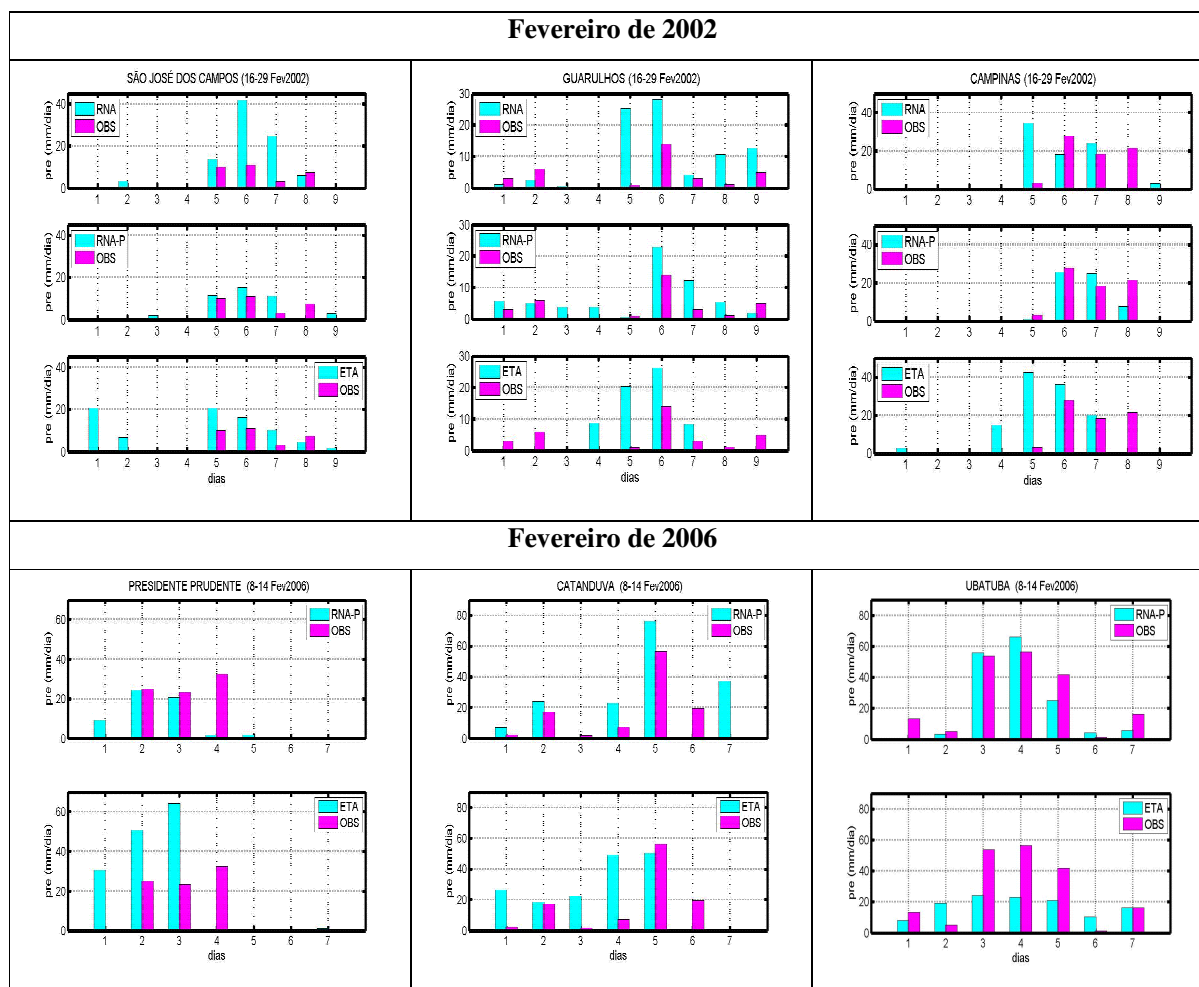


Fig.3 – Previsão de precipitação para 6 localidades do estado de SP feita pelo Downscaling Estatístico para os modelos do RNA, RNA-P e para o modelo regional Eta.

CONSIDERAÇÕES FINAIS

Este trabalho testou uma versão simplificada de um tipo de *downscaling* estatístico conhecido como “*weather pattern methods*” (Wilby e Wigley, 1997) para prever chuva diária associada ao padrão de verão ZCAS-VCAN sobre a região de São Paulo. Esta versão foi simplificada, pois a seleção do padrão de estudo foi subjetiva e não considerou um método de previsão probabilística. No entanto, com a metodologia das RNAs aplicada para o *downscaling* os resultados mostraram um bom desempenho. Especificamente para o experimento RNA-P a maioria das localidades onde foram feitas as previsões tiveram melhor desempenho quando comparado com a previsão do experimento que incluiu outros tipos de padrões de tempo. Este resultado era de se esperar, pois no modelo de previsão neural (RNA-P) são especificadas apenas as características dinâmicas que estão exclusivamente associadas ao padrão de tempo ao qual a chuva está associada. Por outro lado, nas estações onde a topografia é mais acentuada, como foi o caso da cidade de Franca a RNA não conseguiu um bom resultado, e inclusive o Eta também não. Características locais e de microclima devem ser mais predominantes que as características sinóticas sobre esta estação.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ferreira, N.J.; A. Correia e Valverde Ramírez, M.C. Synoptic scale features of the tropospheric circulation over tropical South America during the WETAMC TRMM/LBA experiment. **Atmosfera**, p. 13-30, 2004.
- Haykin, S. **Neural Networks: A Comprehensive Foundation**. Mc Master University, Prentice Hall International Inc, 1994.
- Hewitson B.C.; Crane, R.G. Climate downscaling: techniques and application. **Climate Research**, v. 7, n. 29, p. 85-95, Nov. 1996.
- Mao, Q.; McNider, T.; Mueller, S. An Optimal Model Output Calibration Algorithm Suitable for Objective Temperature Forecasting. **Weather Forecasting**, v. 14, n. 2, p. 190 – 202, April 1999.
- Mesinger, F.; Thomas, L.; Ward, J. ETA Model precipitation forecast for a period including tropical storm Alison. **Weather and Forecasting**, v. 5, p. 483-493. 1990.
- Riedmiller, M., Braun, H. A direct adaptive method for faster backpropagation learning: The RPRO algorithm. **In proceeding of the IEEE International Conference on Neural Networks**, 1993.
- Valverde Ramírez M.C., Kayano, M. T., Ferreira, N. J. Statistical analysis of upper tropospheric vortices in the vicinity of northeast Brazil during the 1980-1989. **Atmosfera**, 12 (2), 75-88. 1999.
- Valverde Ramírez M.C., N. J. Ferreira and H. F. Campos Velho. **Padrão de verão: ZCAS-VCAN atuando sobre a região sudeste do Brasil**. In: XIII Congresso de Brasileiro de Meteorologia. Fortaleza - Ceará. Brazil. 2004.
- Valverde Ramírez M.C., H. Campos Velho and N. J. Ferreira. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. **Journal of Hydrology**, **30** (1-4), 146-162. 2005
- Valverde Ramírez M.C. N. J. Ferreira and H. F. Campos Velho. Linear and nonlinear statistical downscaling for rainfall forecasting over southeastern Brazil. **Weather and Forecasting** (In Press). 2006
- Wilby, R.L.; Wigley T.M.L. Downscaling general circulation model output: a review of methods and limitations. **Progress in Physical Geography**, v. 21, n. 4, p. 530 – 548. 1997.