

NOTA TÉCNICA

REDES NEURAIS ARTIFICIAIS PARA ESTIMATIVA MENSAL DA EROSIVIDADE DA CHUVA NO ESTADO DE MINAS GERAIS

Michel Castro Moreira¹, Fernando Falco Pruski², Thiago Emanuel Cunha de Oliveira³, Francisco de Assis de Carvalho Pinto⁴, Demetrius David da Silva⁴

RESUMO

Dada à necessidade de se conhecer os valores da erosividade da chuva para qualquer localidade, tendo em vista o planejamento de uso de práticas para controle da erosão, e considerando a escassez dessas informações, no presente trabalho teve-se por objetivo desenvolver redes neurais artificiais (RNAs) para a estimativa mensal da erosividade da chuva no Estado de Minas Gerais. Utilizaram-se dados de erosividade da chuva, latitude, longitude e altitude de 268 estações pluviométricas situadas no Estado de Minas Gerais e em seu entorno. Foram treinadas 48 RNAs, considerando-se os índices de erosividade EI_{30} e $KE>25$ e duas metodologias de obtenção da energia cinética da precipitação. Na avaliação dos resultados obtidos com as RNAs desenvolvidas, utilizaram-se o coeficiente de determinação e o índice de confiança. A análise dos resultados possibilitou que se verificasse que as RNAs desenvolvidas são eficientes para estimativa mensal da erosividade da chuva, constituindo alternativa viável para a obtenção desses valores, para qualquer localidade do Estado de Minas Gerais.

Palavras-chave: inteligência artificial, conservação do solo, equação universal de perda de solo.

ABSTRACT

Artificial Neural Networks for Monthly Estimates of Rainfall Erosivity in the Minas Gerais State

Considering the importance rainfall erosivity for a location to plan erosion control practices, and due to lack of such information, the present work was done to develop an Artificial Neural Networks (ANN) for monthly rainfall erosivity estimation of the State of Minas Gerais. Erosivity rainfall data, latitude, longitude and altitude from 268 stations located in the state of Minas Gerais and vicinity were used in the study. Forty-eight ANN were trained to estimate rainfall erosivity using the EI_{30} and $KE>25$ indices and two methods for kinetic energy estimation. The ANN performance was evaluated by the coefficient of determination and the confidence index. The developed ANN were efficient to estimate rainfall erosivity, yielding a viable alternative for erosivity value interpolation in the State of Minas Gerais.

Keywords: artificial intelligence, soil conservation, universal soil loss equation.

Recebido para publicação em 23.04.2007 Aprovado em 27.10.2008

¹ Graduação em Ciência da Computação, Doutorando em Eng. Agrícola, DEA, UFV, Viçosa (MG), 36570-000. Bolsista do CNPq. mmoreira@gprh.ufv.br

² Engenheiro Agrícola, Professor Titular, DEA, UFV, Viçosa (MG), 36570-000. Bolsista do CNPq.

³ Graduando em Ciência da Computação, DPI, UFV, Viçosa (MG), 36570-000. Bolsista da FAPEMIG.

⁴ Agrônomo, Professor Adjunto, DEA, UFV, Viçosa (MG), 36570-000. Bolsista do CNPq.

INTRODUÇÃO

Nos últimos anos, o uso de redes neurais artificiais (RNAs) se tornou popular para predição e estimativa de variáveis em um grande número de áreas, tais como finanças, geração de energia, medicina, recursos hídricos e ciências ambientais (MAIER & DANDY 2000).

O desenvolvimento de uma RNA consiste em determinar sua arquitetura, isto é, os números de camadas e de neurônios em cada camada, bem como ajustar os seus parâmetros livres w 's e b 's, fase esta conhecida como treinamento. A arquitetura varia de acordo com a complexidade do problema e não pode ser definida antes do treinamento, constituindo uma procura baseada em tentativas e erros (HAGAN et al., 1996).

Diversos autores têm aplicado as RNAs para a estimativa de variáveis climáticas, em substituição aos métodos tradicionais de interpolação espacial (SÁRKÖZY, 1999; LI, 2002; MAS et al., 2004; TIMM et al., 2006). MOREIRA et al. (2006) analisaram a acurácia de uma RNA, em relação ao método de interpolação, "Inverso de uma Potência da Distância" (ID), para a estimativa da erosividade da chuva. Estes autores evidenciaram que a RNA obteve

melhor desempenho, apresentando-se como alternativa viável para a interpolação dos valores da erosividade.

A erosividade da chuva (R) expressa a capacidade da chuva em provocar erosão, sendo um dos fatores da Equação Universal de Perda de Solo (USLE). A USLE é um modelo empírico que permite estimar as perdas de solo, sendo utilizada para o planejamento de uso de práticas de controle da erosão.

Tendo em vista a importância que o conhecimento da erosividade da chuva apresenta para o planejamento de uso de práticas de controle da erosão hídrica e a dificuldade que os técnicos que atuam na área de conservação de solo e água têm para a sua obtenção, no presente trabalho teve-se por objetivo desenvolver redes neurais artificiais para a estimativa mensal da erosividade da chuva em qualquer localidade do Estado de Minas Gerais.

MATERIAL E MÉTODOS

Utilizaram-se dados de erosividade da chuva, latitude, longitude e altitude de 254 estações pluviométricas situadas no Estado de Minas Gerais (Figura 1) e de mais 14 estações localizadas em seu entorno.

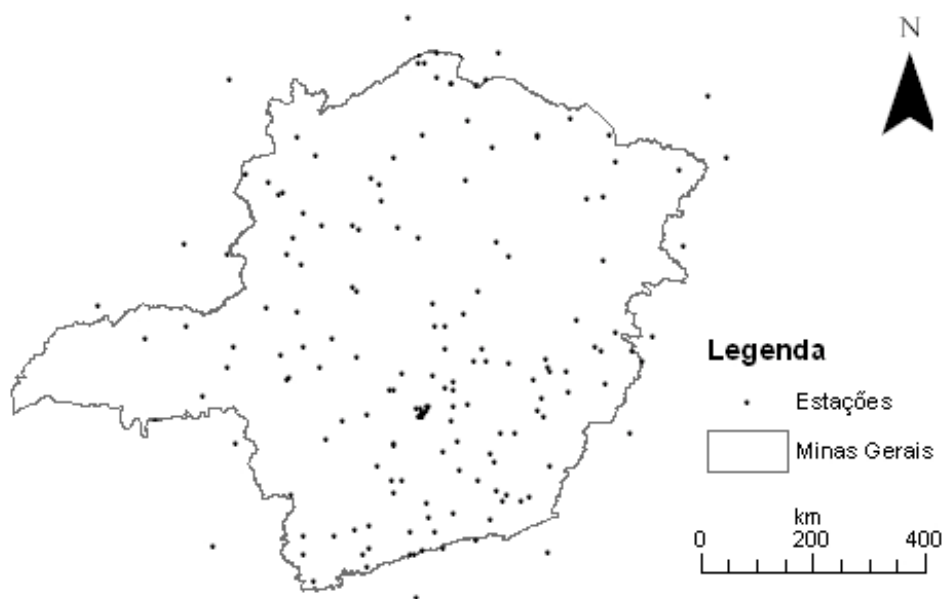


Figura 1. Estações pluviométricas utilizadas no presente estudo.

Os valores de erosividade foram obtidos segundo a metodologia proposta por Pruski et al. (2007), em que se estima o valor da erosividade da chuva a partir de séries sintéticas de precipitação geradas utilizando-se o programa computacional ClimaBR 2.0.

Como o valor mensal da erosividade da chuva é obtido pelo somatório dos valores mensais dos índices de erosividade EI_{30} ou $KE > 25$ e que, para o cálculo desses índices, existem duas metodologias de obtenção da energia cinética da precipitação (FOSTER et al., 1981; WAGNER & MASSAMBANI, 1988), gera-se, para cada estação utilizada no estudo, quatro valores mensais de erosividade da chuva.

Para o treinamento das RNAs, foram escolhidas, aleatoriamente, 240 estações, enquanto as 28 restantes foram utilizadas para teste. Utilizaram-se RNAs retroalimentadas com arquitetura do tipo 3-n1-n2-1, sendo: um vetor de entrada com três variáveis, duas camadas intermediárias com n1 e n2 neurônios artificiais e um neurônio na camada de saída. O vetor de entrada foi composto pelos valores da latitude e da longitude de cada estação, em graus decimais, bem como pelo valor de sua altitude, em metros. No neurônio da camada de saída, empregou-se uma função de ativação linear para fornecer o valor da erosividade da chuva da localidade representada pelo vetor de entrada, em $MJ\ mm\ h^{-1}\ ha^{-1}\ ano^{-1}$, para estimativa considerando o EI_{30} ou $MJ\ ha^{-1}\ ano^{-1}$ e para estimativa considerando o $KE > 25$.

Visando garantir que cada parâmetro de entrada recebesse igual atenção durante o treinamento, aumentando assim sua

eficiência, tanto os dados de entrada quanto os de saída foram padronizados para o intervalo entre -1 e 1 (MAIER & DANDY, 2000).

As RNAs foram treinadas utilizando o algoritmo de aprendizado de Retropropagação do Erro. Em cada iteração deste algoritmo, os parâmetros w 's e b 's são atualizados por uma regra de treinamento, tendo sido adotada a Levenberg-Marquardt. No desenvolvimento das RNAs, testaram-se diferentes combinações de números de neurônios, funções de ativação nas camadas intermediárias e números de iterações (Quadro 1). O número de neurônios testados foi limitado pelo número de amostras utilizadas para treinamento, conforme proposto por Hagan et al. (1996).

Considerando que, no início do treinamento, os parâmetros livres são gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, a RNA que representava cada combinação dos parâmetros do Quadro 1 foi treinada 20 vezes. Dentre essas 20 RNAs treinadas, se armazenou a que apresentou o maior valor do coeficiente de determinação (r^2), o qual foi calculado a partir dos dados de erosividade das 28 estações da amostra de teste e os estimados pela RNA.

Na avaliação dos resultados obtidos com as RNAs desenvolvidas, utilizou-se, além do r^2 , o índice de confiança (c), proposto por Camargo & Sentelhas (1997), o qual é calculado pelo produto do coeficiente de correlação (r) e do índice de concordância (d), proposto por Willmott (1981). No Quadro 2, estão apresentados os critérios de avaliação do desempenho da RNA quanto ao seu índice de confiança.

Quadro 1. Parâmetros testados durante o processo de desenvolvimento das RNAs para estimativa da erosividade da chuva no Estado de Minas Gerais

Parâmetro	Valores
Número de neurônios nas camadas intermediárias	1 a 12; 1 a 12
Funções de ativação nas camadas intermediárias	Logística Sigmóide; Tangente Hiperbólica Sigmóide
Número de ciclos	50; 100; 200; 500

Quadro 2. Análise do desempenho do modelo com base no índice de confiança

Valor de c	Desempenho
> 0,85	Ótimo
0,76 a 0,85	Muito bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sufrível
0,41 a 0,50	Mau
≤ 0,40	Péssimo

Fonte: Camargo & Sentelhas (1997).

RESULTADOS E DISCUSSÃO

No Quadro 3, estão apresentados o número de neurônios das camadas intermediárias e ciclos de treinamento das redes neurais artificiais desenvolvidas para estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com o índice de erosividade EI_{30} e as metodologias de obtenção da energia cinética da precipitação propostas por Foster et al. (1981) e Wagner & Massambani (1988).

Verifica-se que, de maneira geral, o número de neurônios na primeira camada foi superior ao da segunda camada. Considerando que as redes desenvolvidas poderiam ter número máximo de 24 neurônios, observa-se que as arquiteturas das redes desenvolvidas apresentaram baixos números de neurônios, tendo as redes para o mês de setembro, considerando a metodologia de Foster et al. (1981) e Wagner & Massambani (1988), apresentado o maior número de neurônios (16 no total). Apesar do número de neurônio da primeira e segunda camada ter variado de um a doze, observa-se que apenas quatro, das 24 RNAs desenvolvidas, apresentaram o número máximo de neurônios em suas camadas.

Segundo Lippmann (1987), menores arquiteturas possuem maior capacidade de generalização, enquanto maiores arquiteturas têm a capacidade de aprender mais rapidamente, ou seja, necessitam de menor número de ciclos de treinamento em seu desenvolvimento. Uma arquitetura com

erro mínimo se atinge com o aumento do número de neurônios ou com o aumento do número de ciclos de treinamento até um limite que não apresente problemas de “memorização” (PENG & WEN, 1999), que se caracteriza por apresentar um baixo erro na amostra de treinamento, mas com tendência de aumento do erro na amostra de teste.

Observa-se que as redes treinadas com a regra de treinamento Levenberg-Marquardt atingiram melhores desempenhos com números menores de ciclos de treinamento. Este comportamento é atribuído ao fato de que, acima de 200 ciclos, as redes, na maioria dos meses, apresentaram problemas de “memorização”.

Pelo fato da regra de treinamento utilizada constituir a mais eficiente quanto à convergência para o erro mínimo em função do número de ciclos de treinamento (HAGAN et al., 1996), verifica-se baixos valores de número de ciclos obtidos, sendo observados em apenas três RNAs a ocorrência do número máximo de ciclos de treinamento.

No Quadro 4, estão apresentados o número de neurônios das camadas intermediárias e ciclos de treinamento das redes neurais artificiais desenvolvidas para estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com o índice de erosividade $KE > 25$ e as metodologias de obtenção da energia cinética da precipitação propostas por Foster et al. (1981) e Wagner & Massambani (1988).

Quadro 3. Número de neurônios das camadas intermediárias e ciclos de treinamento das redes neurais artificiais desenvolvidas para estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com o índice de erosividade EI_{30} e as metodologias de obtenção da energia cinética da precipitação propostas por Foster et al. (1981) e Wagner & Massambani (1988)

Mês	EI_{30}					
	F			WM		
	n1	n2	ciclos	n1	n2	ciclos
Jan	3	5	50	3	5	200
Fev	6	1	500	3	6	100
Mar	11	1	200	3	9	50
Abr	11	1	200	11	1	200
Mai	3	9	50	3	9	50
Jun	12	1	50	12	1	50
Jul	7	1	500	7	1	500
Ago	5	3	50	5	3	50
Set	12	4	50	12	4	50
Out	10	1	50	10	1	50
Nov	3	2	100	3	2	100
Dez	5	2	200	5	2	200

F: Energia cinética calculada pelo método proposto por Foster et al. (1981).

WM: Energia cinética calculada pelo método proposto por Wagner & Massambani (1988).

n1 e n2: Número de neurônios na primeira e segunda camada intermediária, respectivamente.

Quadro 4. Número de neurônios das camadas intermediárias e ciclos de treinamento das redes neurais artificiais desenvolvidas para estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com o índice de erosividade $KE > 25$ e as metodologias de obtenção da energia cinética da precipitação propostas por Foster et al. (1981) e Wagner & Massambani (1988)

Mês	$KE > 25$					
	F			WM		
	n1	n2	ciclos	n1	n2	ciclos
Jan	4	3	200	4	1	200
Fev	12	2	500	6	1	500
Mar	5	3	50	5	2	500
Abr	11	1	500	3	3	200
Mai	2	2	500	3	1	100
Jun	6	1	200	8	1	200
Jul	8	1	50	12	1	50
Ago	6	1	50	2	2	200
Set	11	4	50	2	4	500
Out	3	8	50	3	1	50
Nov	3	4	100	5	3	200
Dez	5	2	500	2	2	500

F: Energia cinética calculada pelo método proposto por Foster et al. (1981).

WM: Energia cinética calculada pelo método proposto por Wagner & Massambani (1988).

n1 e n2: Número de neurônios na primeira e segunda camada intermediária, respectivamente.

Pela análise do número de neurônios das camadas intermediárias, apresentado no Quadro 4, verifica-se um comportamento similar ao observado para as RNAs desenvolvidas para estimativa da erosividade da chuva de acordo com o índice de erosividade EI_{30} , em que o número de neurônios da primeira camada foi superior ao da segunda. Da mesma forma, as arquiteturas das RNAs apresentaram baixos valores de número de neurônios, tendo, novamente, a rede do mês de setembro, considerando a metodologia proposta por Foster et al. (1981), apresentado o maior número de neurônios (15 no total).

Em relação ao número de ciclos de treinamento, observa-se que apenas seis RNAs foram treinadas com o número mínimo de ciclos, evidenciando-se, dessa forma, comportamento contrário ao observado para as RNAs desenvolvidas, considerando o índice de erosividade EI_{30} . Tal comportamento está associado à maior complexidade no ajuste das RNAs para estimativa da erosividade, considerando-se o índice de erosividade $KE > 25$ em relação ao índice EI_{30} .

No Quadro 5, estão apresentados os valores do coeficiente de determinação,

índice de confiança e desempenho calculados a partir dos dados obtidos nas 28 estações utilizadas para teste, utilizando-se as redes neurais artificiais desenvolvidas para a estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com os índices de erosividade EI_{30} e $KE > 25$ e as metodologias de obtenção da energia cinética propostas por Foster et al. (1981) e Wagner & Massambani (1988).

Dos valores apresentados no Quadro 5, verifica-se que das 24 RNAs desenvolvidas, correspondentes aos 12 meses do ano e às duas metodologias de estimativa da energia cinética, 11 obtiveram a classificação “Ótimo”, 11 a classificação “Muito Bom” e apenas duas a classificação “Bom”.

Em relação ao r^2 , observa-se que este variou entre 0,73 a 0,92, tendo, para as RNAs classificadas como “Ótimo”, uma variação entre 0,85 a 0,92 e, para as classificadas como “Muito Bom”, variação entre 0,73 a 0,92, sendo que as duas RNAs classificadas como “Bom”, apresentaram os valores 0,73 e 0,83. Assim, verifica-se que os valores de r^2 corroboraram a classificação de desempenho proposta por Camargo & Sentelhas (1997).

Quadro 5. Valores do coeficiente de determinação (r^2), índice de confiança (c) e classificação de desempenho (D) das RNAs desenvolvidas para estimativa mensal da erosividade da chuva, de acordo com o índice de erosividade EI_{30} e as metodologias de obtenção da energia cinética da precipitação

Mês	EI_{30} (MJ mm h ⁻¹ ha ⁻¹ ano ⁻¹)					
	F			WM		
	r^2	c	D	r^2	c	D
Jan	0,89	0,91	Ótimo	0,87	0,89	Ótimo
Fev	0,85	0,87	Ótimo	0,85	0,86	Ótimo
Mar	0,75	0,79	M. bom	0,92	0,89	Ótimo
Abr	0,83	0,84	M. bom	0,83	0,71	Bom
Mai	0,92	0,92	Ótimo	0,92	0,91	Ótimo
Jun	0,92	0,90	Ótimo	0,92	0,90	Ótimo
Jul	0,73	0,73	Bom	0,92	0,85	M. bom
Ago	0,73	0,81	M. bom	0,80	0,84	M. bom
Set	0,83	0,77	M. bom	0,83	0,83	M. bom
Out	0,90	0,92	Ótimo	0,90	0,92	Ótimo
Nov	0,80	0,85	M. bom	0,80	0,85	M. bom
Dez	0,80	0,84	M. bom	0,80	0,85	M. bom

F: Energia cinética calculada pelo método proposto por Foster et al. (1981).

WM: Energia cinética calculada pelo método proposto por Wagner & Massambani (1988).

Verifica-se, de maneira geral, em relação às RNAs desenvolvidas, considerando as metodologias de obtenção da energia cinética propostas por Foster et al. (1981) e Wagner & Massambani (1988), que não houve distinção, em termos de desempenho, entre as RNAs para estimativa da erosividade, considerando-se os dois métodos.

No Quadro 6, estão apresentados os valores de r^2 e c , e a classificação de desempenho das RNAs desenvolvidas para estimativa mensal da erosividade da chuva no Estado de Minas Gerais, de acordo com o índice de erosividade $KE > 25$ e as metodologias de obtenção da energia cinética propostas por Foster et al. (1981) e Wagner & Massambani (1988).

De acordo com os resultados de desempenho, observam-se, nos valores apresentados no Quadro 6, que dentre as 24 RNAs desenvolvidas, 12 obtiveram a classificação “Ótimo”, nove a classificação “Muito Bom”, uma obteve a classificação “Mau” e duas obtiveram a classificação “Péssimo”.

Os piores desempenhos ocorreram no mês de julho, para a energia cinética

calculada utilizando-se o método proposto por Wagner & Massambani (1988) e de agosto, quando foram utilizados os dois métodos de obtenção da energia cinética, mesmo tendo-se obtido, para estes meses, valores de coeficiente de determinação de 1,00, 0,82 e 0,80, respectivamente.

A discordância entre critérios de eficiência de um modelo e os valores de r^2 também foi verificada por Legates & McCabe Jr. (1999), tendo estes autores salientado que altas correlações podem ser obtidas por modelos inapropriados, sugerindo que outros índices devam ser utilizados para avaliação de desempenho de modelos.

O fato dos valores de erosividade da chuva serem reduzidos nos meses em que se verificou os piores desempenhos, acaba por acarretar em maiores erros relativos. Assim, apesar dos baixos desempenhos dessas três RNAs, os mesmos não comprometem o planejamento de uso de práticas para o controle de erosão, já que esses meses são caracterizados pela baixa pluviosidade.

Quadro 6. Valores do coeficiente de determinação (r^2), índice de confiança (c) e classificação de desempenho (D) das RNAs desenvolvidas para estimativa mensal da erosividade da chuva de acordo com o índice de erosividade $KE > 25$ e as metodologias de obtenção da energia cinética da precipitação.

Mês	KE > 25 (MJ ha ⁻¹ ano ⁻¹)					
	F			WM		
	r^2	c	D	r^2	c	D
Jan	0,89	0,91	Ótimo	0,91	0,93	Ótimo
Fev	0,87	0,87	Ótimo	0,87	0,89	Ótimo
Mar	0,83	0,81	M. bom	0,83	0,86	Ótimo
Abr	0,86	0,82	M. bom	0,88	0,85	M. bom
Mai	0,80	0,81	M. bom	0,80	0,80	M. bom
Jun	1,00	0,79	M. bom	1,00	0,87	Ótimo
Jul	0,99	0,80	M. bom	1,00	0,46	Mau
Ago	0,82	0,16	Péssimo	0,80	0,28	Péssimo
Set	0,85	0,77	M. bom	0,83	0,76	M. bom
Out	0,91	0,92	Ótimo	0,90	0,92	Ótimo
Nov	0,92	0,94	Ótimo	0,88	0,91	Ótimo
Dez	0,89	0,91	Ótimo	0,90	0,93	Ótimo

F: Energia cinética calculada pelo método proposto por Foster et al. (1981).

WM: Energia cinética calculada pelo método proposto por Wagner & Massambani (1988).

Da mesma forma, como verificado para as RNAs para estimativa da erosividade de acordo com o índice EI_{30} , não se verificou diferença, em termos de desempenho, entre as RNAs para estimativa da erosividade considerando-se os dois métodos de obtenção da energia cinética.

De acordo com os valores de r^2 e as classificações de desempenho, as RNAs são eficientes para estimativa da erosividade da chuva, pois, dentre as 48 RNAs desenvolvidas, 23 obtiveram a classificação “Ótimo”, 20 obtiveram classificação “Muito Bom”, duas obtiveram classificação “Bom”, uma obteve classificação “Mau” e duas obtiveram a classificação “Péssimo”. Verifica-se, dessa maneira, a ocorrência de 43 RNAs com classificações de desempenho “Ótimo” ou “Muito Bom”. Os piores desempenhos ocorreram nos meses de julho, para o $KE > 25$ (WM), e agosto, para o $KE > 25$ (WM e F), sendo recomendada maior análise, quando da utilização dos valores estimados pelas RNAs, para esses meses.

CONCLUSÕES

- Com base nos resultados obtidos neste trabalho, pode-se concluir que as RNAs desenvolvidas possibilitam a estimativa da erosividade mensal da chuva, constituindo alternativa viável para a obtenção desses valores para qualquer localidade do Estado de Minas Gerais.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais – FAPEMIG e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pelo apoio financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

CAMARGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo. **Revista**

Brasileira de Agrometeorologia, v.5, p.89-97, 1997.

FOSTER, G.R.; McCOOL, D.K.; RENARD, K.G.; MOLDENHAUER, W.C. Conversion of the universal soil loss equation to SI units. **Journal of Soil and Water Conservation**, v.36, p.355-359, 1981.

HAGAN, M.T. DEMUTH, H.B.; BEALE, M. **Neural network design**. Boston: PWS, 1996. n.p.

LEGATES, D. R.; MCCABE JR., G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. **Water resources research**, v. 35, p.233-241, 1999.

LI, B. **Spatial interpolation of weather variables using artificial neural networks**. Athens: University of Georgia, 2002. 89p. (Dissertação de Mestrado)

LIPPMANN, R.P. An introduction to computing with neural nets. **IEEE Acoustics, Speech and Signal Processing Magazine**. v.4, p.4–22, 1987.

MAS, J.F.; PUIG, H., PALACIO, J.L., SOSA-LOPEZ, A. Modelling deforestation using GIS and artificial neural networks. **Environmental Modelling & Software**. v.19, p.461-471, 2004.

MAIER, H.R.; DANDY, G.C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environmental Modelling & Software**, v.15, p.101-123, 2000.

MOREIRA, M.C.; CECÍLIO, R.A.; PINTO, F.A.C.; PRUSKI, F.F. Desenvolvimento e análise de uma rede neural artificial para estimativa da erosividade da chuva para o Estado de São Paulo. **Revista Brasileira de Ciência do Solo**, v. 30, n.6, p.1069-1074, 2006.

PENG, C. & WEN, X. Recent applications of artificial neural networks in forest resource management: an overview. In: CORTÉ, U. & SÁNCHEZ-MARRÉ, M., eds. **Environmental Decision Support Systems and Artificial Intelligence**. AAAI Press, Menlo Park, CA, 1999. p.15-22.

PRUSKI, F.F.; MOREIRA, M.C.; GONÇALVES, F.A.; OLIVEIRA, T.E.C. de; PINTO, F.A.C.; SILVA, D.D. da. Erosividade da chuva a partir de séries sintéticas de precipitação. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 36, 2007, Bonito, **Resumos...** Bonito: SBEA, 2007. CD-ROM

SÁRKÖZY, F. Gis functions – Interpolation. **Periodica polytechnica Ser. Civ. Eng.**, v.43, p.63-86, 1999.

TIMM, L.C.; GOMES, D.T.; BARBOSA, E.P.; REICHARDT, K.; SOUZA, M.D.; DYNIA, J.F. Neural network and state-space models for studying relationships among soil properties. **Scientia Agrícola**, v.63, p.386-395, 2006.

WAGNER, C.S.; MASSAMBANI, O. Análise da relação intensidade de chuva: energia de Wischmeier & Smith e sua aplicabilidade à região de São Paulo. **Revista Brasileira de Ciência do Solo**, v.12, p.197-203. 1988.

WILLMOTT, C.J. On the validation of models. **Phys. Geogr.**, v.2, p.184-194, 1981.