

DESENVOLVIMENTO E ANÁLISE DE UMA REDE NEURAL ARTIFICIAL PARA ESTIMATIVA DA EROSIVIDADE DA CHUVA PARA O ESTADO DE SÃO PAULO⁽¹⁾

Michel Castro Moreira⁽²⁾, Roberto Avelino Cecílio⁽³⁾, Francisco de Assis de Carvalho Pinto⁽⁴⁾ & Fernando Falco Pruski⁽⁵⁾

RESUMO

O conhecimento do valor da erosividade da chuva (R) de determinada localidade é fundamental para a estimativa das perdas de solo feitas a partir da Equação Universal de Perdas de Solo, sendo, portanto, de grande importância no planejamento conservacionista. A fim de obter estimativas do valor de R para localidades onde este é desconhecido, desenvolveu-se uma rede neural artificial (RNA) e analisou-se a acurácia desta com o método de interpolação “Inverso de uma Potência da Distância” (ID). Comparando a RNA desenvolvida com o método de interpolação ID, verificou-se que a primeira apresentou menor erro relativo médio na estimativa de R e melhor índice de confiança, classificado como “Ótimo”, podendo, portanto, ser utilizada no planejamento de uso, manejo e conservação do solo no Estado de São Paulo.

Termos de indexação: conservação do solo, erosão hídrica, equação universal de perdas de solo

SUMMARY: *ESTIMATES OF RAINFALL EROSIIVITY IN SÃO PAULO STATE BY AN ARTIFICIAL NEURAL NETWORK*

Knowledge on rainfall erosivity (R) of particular sites is fundamental for soil loss estimation by the Universal Soil Loss Equation (USLE) and therefore highly important in

⁽¹⁾ Recebido para publicação em abril de 2005 e aprovado em outubro de 2006.

⁽²⁾ Mestrando em Engenharia Agrícola, Departamento de Engenharia Agrícola, Universidade Federal de Viçosa – UFV. CEP 36570-000 Viçosa (MG). Bolsista do CNPq. E-mail: mmoreira@dpi.ufv.br

⁽³⁾ Doutorando em Engenharia Agrícola, Departamento de Engenharia Agrícola, UFV. Bolsista da CAPES. E-mail: racecilio@yahoo.com.br

⁽⁴⁾ Professor Adjunto, Departamento de Engenharia Agrícola, UFV. Bolsista do CNPq. E-mail: facpinto@ufv.br

⁽⁵⁾ Professor Titular do Departamento de Engenharia Agrícola, UFV. Bolsista do CNPq. E-mail: ffpuski@ufv.br

conservation planning. In order to obtain the R value estimates for places where it is unknown, an artificial neural network (ANN) was developed for the state of São Paulo, and its accuracy compared with the Inverse Distance Weighted (IDW) interpolation method. The developed ANN presented a smaller mean relative error in the R estimation and a confidence index classified as "excellent", better than the IDW. ANN can therefore be used to estimate R values for soil use planning, management and conservation in São Paulo state.

Index terms: soil conservation, water erosion, universal soil loss equation.

INTRODUÇÃO

A chuva é o principal elemento climático que intervém no processo de erosão hídrica do solo, pois dela, dentre outros fatores, dependem o volume e a velocidade do escoamento superficial. Segundo Hernani et al. (2002), as perdas anuais de solo e água em áreas agrícolas brasileiras ocasionadas pela erosão hídrica são da ordem de 822,7 milhões de toneladas e 171 bilhões de m³, respectivamente, estando associada a estes valores uma perda de US\$ 4,2 bilhões por ano, referente aos custos relativos à reposição de corretivos e fertilizantes, à menor produtividade, aos maiores custos de produção, ao tratamento de água, à manutenção de estradas e ao maior consumo de energia, dentre outros. A utilização de modelos capazes de estimar as perdas ocasionadas por erosão hídrica é de fundamental importância para a escolha de práticas de conservação da água e do solo que possam minimizar estes impactos.

Wischmeier & Smith (1958) desenvolveram a Equação Universal de Perda de Solo (USLE), por meio da qual se podem estimar as perdas de solo e identificar os fatores que exercem os maiores efeitos sobre estas. Dentre os componentes da USLE, o que expressa a capacidade erosiva da chuva é conhecido como fator erosividade da chuva (R).

Para o cálculo do fator R, são necessários registros pluviográficos, que são de difícil obtenção no Brasil. Além disso, o processamento e análise destes dados é bastante lento e trabalhoso (Bertoni & Lombardi Neto, 1990), fazendo com que informações relativas à erosividade estejam disponíveis apenas para pequeno número de localidades no Brasil.

Visando superar esta limitação, alguns autores propõem a utilização de equações empíricas, baseadas nas precipitações mensais e anuais, para estimar o valor de R (Val et al., 1986; Morais et al., 1991; Lombardi Neto & Moldenhauer, 1992; Rufino et al., 1993). Entretanto, mesmo com estas equações, a obtenção da erosividade da chuva fica restrita a localidades em que exista uma base de dados pluviométricos satisfatória. Nas localidades onde nem mesmo registros pluviométricos estão disponíveis, autores como Bertoni & Lombardi Neto (1990), Rufino et al. (1993), Erosividade (1999) e Silva (2004) utilizaram técnicas de interpolação dos valores de R.

De acordo com Sárközy (1999), as Redes Neurais Artificiais (RNA) podem ser usadas como ferramentas de interpolação, e sua capacidade de aprendizado para diferentes parâmetros de entrada torna-as capazes de resolver problemas muito complexos em diversas áreas do conhecimento. Li (2002) salienta que a utilização das RNA constitui alternativa potencial para a estimativa de variáveis climáticas, em substituição aos métodos tradicionais de interpolação.

Uma RNA é composta por um conjunto de elementos computacionais, denominados neurônios artificiais, que relacionam os valores de saída e entrada pela equação:

$$y^{ij} = f\left(\sum_{i'}^n y^{i'(j-1)} w_{i'}^{ij} + b^{ij}\right) \quad (1)$$

em que y^{ij} = valor de saída do neurônio i da camada j ; n = número de neurônios da camada anterior; $y^{i'(j-1)}$ = valor de saída do neurônio i' da camada anterior; $w_{i'}^{ij}$ = valor do peso sináptico do neurônio i da camada j , ativado pelo neurônio i' da camada anterior; b^{ij} = valor de compensação do neurônio i da camada j ; f = função de ativação do neurônio i .

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).

O presente trabalho teve por objetivo desenvolver uma rede neural artificial, para o Estado de São Paulo, e analisar a acurácia desta com o método de interpolação "Inverso de uma Potência da Distância".

MATERIAL E MÉTODOS

Utilizaram-se dados de erosividade da chuva, latitude, longitude e altitude de 138 estações pluviométricas situadas no Estado de São Paulo. Os valores de R para cada estação foram obtidos pela equação 2, proposta por Lombardi Neto & Moldenhauer (1992), a partir de dados de precipitação média anual do período de 1961 a 1990. A soma dos

valores de EI_{mensal} para os 12 meses do ano representou o valor da erosividade da chuva.

$$EI_{mensal} = 89,823 \left(\frac{r^2}{P} \right)^{0,759} \quad (2)$$

em que EI_{mensal} = erosividade média mensal do mês k , MJ mm h⁻¹ ha⁻¹; r = precipitação média mensal do mês k , mm; e P = precipitação média anual, mm.

Para o treinamento da RNA, foram escolhidas aleatoriamente 100 estações, enquanto as 38 estações restantes foram utilizadas para teste. A figura 1 ilustra o mapa de elevação do Estado de São Paulo com as 138 estações pluviométricas, sendo identificadas tanto as estações para treinamento como para teste.

Utilizou-se uma RNA retroalimentada do tipo 3-n₁-n₂-1: 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




Figura 1. Mapa de elevação do Estado de São Paulo com a identificação das estações utilizadas tanto para treinamento como para teste.

da chuva, em MJ mm h⁻¹ ha⁻¹ ano⁻¹, da localidade representada pelo vetor de entrada.

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 pela equação 3 (MatLab, 2000; Maier & Dandy, 2000).

$$p_n = \frac{2 * (p - \min p)}{(\max p - \min p)} - 1 \quad (3)$$

em que p_n = valor normalizado, adimensional; p = valor observado; $\min p$ = valor mínimo da amostra, e $\max p$ = valor máximo da amostra.

A RNA foi treinada utilizando o algoritmo de Retropropagação do Erro, que é um algoritmo iterativo para minimizar o erro quadrático médio entre o valor simulado e o valor esperado da erosividade da chuva na amostra de treinamento. Em cada iteração, os parâmetros w 's e b 's da RNA são atualizados por uma regra de treinamento.

No desenvolvimento da RNA, foram testadas diferentes combinações de números de neurônios, funções de ativação nas camadas intermediárias, números de iterações e regras de treinamento (Quadro 1).

Tendo em vista 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 RNA treinadas, armazenou-se a que apresentou o menor erro relativo médio (ERM), o qual foi calculado pela equação 4 (Schaeffer, 1980).

$$ERM = \frac{1}{N} \left[\sum_{i=1}^N \left| \frac{Ro_i - Ri_i}{Ro_i} \right| \right] \quad (4)$$

em que ERM = erro relativo médio, ou adimensional; Ro_i = valor calculado da erosividade da chuva da estação i , MJ mm ha⁻¹ h⁻¹ ano⁻¹; Ri_i = valor estimado da erosividade da chuva para a estação i , MJ mm ha⁻¹ h⁻¹ ano⁻¹, N = número de estações da amostra de teste.

Quadro 1. Parâmetros submetidos a variações de valores durante o processo de desenvolvimento da RNA para estimar a erosividade da chuva de localidades do Estado de São Paulo

Parâmetro	Valor
Número de neurônios nas camadas intermediárias	1 a 7; 1 a 7
Funções de ativação nas camadas intermediárias	Logística Sigmóide; Tangente Hiperbólica Sigmóide
Número de ciclos	50; 100; 500; 1.000; 3.000; 5.000; 8.000
Regra de treinamento	Gradiente Descendente com <i>Momentum</i> ; Levenberg-Marquardt

Na avaliação dos resultados obtidos com a RNA desenvolvida, utilizou-se, além do ERM, o índice de confiança (c), proposto por Camargo & Sentelhas (1997) e que, segundo Baena (2004), permite analisar conjuntamente a precisão e a exatidão dos resultados obtidos, sendo calculado pelo produto do coeficiente de correlação (r) e do índice de concordância (d), proposto por Willmott (1981). No quadro 2, são apresentados os critérios de avaliação do desempenho da RNA quanto ao seu índice de confiança.

Com vistas em verificar a acurácia da RNA desenvolvida, compararam-se, para as 38 estações de teste, os resultados estimados com a RNA com aqueles obtidos pelo método de interpolação “Inverso de uma Potência da Distância” (ID), tendo-se também utilizado para este fim os índices ERM e “c”. No método de interpolação ID, o valor atribuído à estação interpolada foi obtido pela média ponderada que utiliza o peso das estações pluviométricas mais próximas (no caso, utilizaram-se as 10 estações da amostra de treinamento mais próximas) ponderados pelo inverso de uma potência da distância, conforme a equação 5. Na interpolação dos parâmetros, utilizaram-se seis diferentes expoentes da distância: 1 (ID1), 2 (ID2), 3 (ID3), 4 (ID4) e 5 (ID5).

$$Ri_i = \frac{\sum_{i=1}^j \left(\frac{Ro_i}{x_i^m} \right)}{\sum_{i=1}^j \left(\frac{1}{x_i^m} \right)} \quad (5)$$

em que x_i = distância euclidiana entre o i -ésimo posto de controle e a estação i , m ; m = expoente da distância euclidiana, adimensional, e j número de estações de controle, adimensional.

Com a RNA desenvolvida e utilizando informações de altitude, latitude e longitude, obteve-se o mapa de erosividade da chuva para o Estado de São Paulo. As informações de altimetria foram obtidas do Projeto GTOPO30⁽⁶⁾, no qual se encontram disponíveis informações de altitude em células com resolução horizontal de 1 km.

Quadro 2. Análise do desempenho do modelo com base no índice de confiança (Camargo & Sentelhas, 1997)

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	Sofrível
0,41 a 0,50	Mau
≤ 0,40	Péssimo

⁽⁶⁾ <http://edcdaac.usgs.gov/gtopo30/gtopo30.asp>

RESULTADOS E DISCUSSÃO

No quadro 3, estão apresentados o número de neurônios das camadas intermediárias, o erro quadrático médio (EQM) da amostra de treinamento e o erro relativo médio (ERM) da amostra de teste da melhor RNA, para cada número de ciclos testados, utilizando a regra de treinamento Gradiente Descendente com *Momentum* (GDM).

As redes treinadas com GDM tenderam a diminuir o ERM com o aumento do número de ciclos de treinamento, observa-se, porém, que não se atingiu uma arquitetura ótima, pelo fato de o ERM não ter convergido para um valor mínimo. 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 baixo EQM na amostra de treinamento, mas com tendência de aumento do ERM na amostra de teste. O número de neurônios testados foi limitado pelo número de amostras utilizadas para treinamento, conforme proposto por Hagan et al. (1996).

No quadro 4, estão apresentados o número de neurônios das camadas intermediárias, o erro quadrático médio (EQM) da amostra de treinamento e o erro relativo médio (ERM) da amostra de teste da melhor RNA, para cada número de ciclos testados, utilizando a regra de treinamento Levenberg-Marquardt (LM).

As redes treinadas com LM atingiram os melhores desempenhos com os números menores de ciclos, sendo este comportamento atribuído ao fato de que, acima de 100 ciclos de treinamento, as redes apresentaram problemas de “memorização”. Os valores de EQM e ERM obtidos para um número de ciclos igual a 100 caracteriza a melhor capacidade desta arquitetura em simular a erosividade da chuva em relação às demais.

Comparando os métodos de treinamento, verifica-se que o LM apresentou menores valores de EQM e de ERM. Este resultado confirma a afirmação de Hagan et al. (1996) de que o LM constitui a mais eficiente regra de treinamento quanto à convergência para o erro mínimo, considerando o número de ciclos de treinamento.

A configuração da melhor RNA consiste de quatro neurônios na primeira camada e dois na segunda com funções de ativação nas camadas intermediárias do tipo tangente hiperbólica sigmóide. O número de ciclos utilizados foi de 100 e a regra de treinamento a de Levenberg-Marquardt.

No quadro 5, encontram-se os valores de erosividade da chuva calculados pela equação 2 e estimados tanto pela RNA quanto pelo método de interpolação ID, utilizando diferentes potências, para as 38 estações da amostra de teste.

Quadro 3. Número de neurônios das camadas intermediárias, erro quadrático médio (EQM) da amostra de treinamento e erro relativo médio (ERM) da amostra de teste da melhor RNA para cada número de ciclos testados, utilizando a regra de treinamento Gradiente Descendente com *Momentum*

Número de ciclo	Neurônio na camada 1	Neurônio na camada 2	EQM	ERM
50	4	5	0,0462	0,0548
100	2	4	0,0663	0,0572
500	7	7	0,0542	0,0480
1.000	6	7	0,0446	0,0421
3.000	5	7	0,0392	0,0418
5.000	7	7	0,0328	0,0415
8.000	6	6	0,0366	0,0403

Quadro 4. Número de neurônios das camadas intermediárias, erro quadrático médio (EQM) da amostra de treinamento e erro relativo médio (ERM) da amostra de teste da melhor RNA para cada número de ciclos testados, utilizando a regra de treinamento Levenberg-Marquardt

Número de ciclo	Neurônio na camada 1	Neurônio na camada 2	EQM	ERM
50	5	4	0,0085	0,0334
100	4	2	0,0253	0,0322
500	3	5	0,0067	0,0348
1.000	3	5	0,0063	0,0364
3.000	5	2	0,0075	0,0340
5.000	3	4	0,0070	0,0348
8.000	3	5	0,0065	0,0362

Considerando os valores estimados pela RNA com os obtidos pelo método de interpolação ID, verificou-se que os erros foram iguais ou reduzidos quando da utilização da RNA em 25 das 38 estações da amostra de teste, considerando o método ID1; e, 20, 26, 28 e 29 estações, quando considerados os métodos de interpolação ID2, ID3, ID4 e ID5, respectivamente. Sabendo que a altitude influencia o valor de erosividade da chuva, por interferir nas características da precipitação, o melhor desempenho da RNA se explica, em parte, pelo uso da altitude das estações na interpolação, fato que não ocorre quando da utilização do método ID, que considera apenas a distância euclidiana entre as estações de controle e a localidade onde se deseja estimar a erosividade.

Na localidade de Tietê, onde o valor de R foi o menor da amostra de teste, verificou-se que todos os métodos de interpolação tenderam a superestimar o valor de R, tendo a RNA apresentado o maior erro relativo percentual (ER), comportamento que pode ser explicado pela grande variabilidade dos valores de altitude e de R na região onde esta se localiza.

Na localidade de Juquitiba, a RNA apresentou maior subestimativa do valor de R, enquanto os

métodos ID superestimaram esse valor. A superestimativa feita pelos métodos ID decorre do fato de que as estações mais próximas de Juquitiba se localizam no litoral do Estado, apresentando altos valores de R. Já a subestimativa apresentada pela RNA decorre da incorporação da altitude da localidade na estimativa de R, sendo esta, para Juquitiba, superior à altitude das estações litorâneas próximas.

Em Iguape, localidade com maior valor de R, os métodos ID apresentaram os maiores valores absolutos de ER, enquanto a RNA estimou o valor de R para esta localidade com baixo ER (-1 %). Nesta localidade, que se situa no litoral Sul do Estado e a 3 m acima do nível do mar, a RNA foi o método que levou ao menor ER pelo fato de ter o ajuste da RNA permitido tanto a consideração do efeito da altitude quanto da continentalidade do local, o que não foi possível quando do uso do método de interpolação ID.

Em termos gerais, a RNA apresentou tendência de superestimar a erosividade da chuva, o que leva à superestimativa dos valores de perda de solo e, conseqüentemente à adoção de práticas de uso e manejo do solo capazes de manter as perdas abaixo dos limites toleráveis.

Os erros relativos percentuais, tanto utilizando a RNA quanto os métodos de interpolação ID, foram, em menos de 6 % dos casos, superiores a 10 %, valor considerado baixo para a estimativa da erosividade da chuva. Tal comportamento caracteriza, portanto, que tanto o uso da RNA quanto dos métodos de interpolação ID acarretam pequenos erros relativos percentuais na estimativa do valor de R. O uso da RNA acarreta, entretanto, menor ER, sendo o máximo valor de ER obtido quando do uso a RNA de 13 %, enquanto para o método de interpolação ID ocorreram erros superiores a 20 %. Além da menor amplitude do ER com o uso da RNA, obteve-se menor ER em relação ao método de interpolação ID em mais de 50 % dos casos. Estes fatos permitem afirmar que o uso da RNA permitiu melhor desempenho na estimativa do valor de R que o método de interpolação ID.

No quadro 6, encontram-se os valores dos índices ERM e c, calculados para a amostra de teste, considerando a RNA desenvolvida e as cinco interpolações realizadas pelo método ID. Verificou-se, pela análise, que a RNA apresentou o menor ERM e o melhor desempenho na interpolação dos valores de R, de acordo com o índice c. Em relação ao método de interpolação ID, observa-se a tendência de piora do desempenho com o aumento da potência da distância.

Portanto, considerando ter a RNA acarretado menor ERM, além de maior índice de confiança, pode-se afirmar que tal método permitiu melhor interpolação dos valores de erosividade da chuva para o Estado de São Paulo. Desta forma, a RNA desenvolvida pode ser utilizada com satisfatório grau de precisão na estimativa da erosividade da chuva para o planejamento de uso, manejo e conservação do solo,

Quadro 5. Valores calculados de erosividade da chuva e estimados pela RNA e pelo interpolador ID para as estações da amostra de teste

Estação	Ro	RNA		ID1		ID2		ID3		ID4		ID5	
		Ri	ER	Ri	ER	Ri	ER	Ri	ER	Ri	ER	Ri	ER
Altinópolis	8.029	7.934	-1	7.892	-2	7.862	-2	7.818	-3	7.771	-3	7.729	-4
Araraquara	7.188	6.515	-9	7.098	-1	7.024	-2	6.972	-3	6.941	-3	6.926	-4
Bebedouro	7.090	7.231	2	7.239	2	7.146	1	7.056	0	6.981	-2	6.924	-2
Borborema	6.418	6.497	1	6.818	6	6.705	4	6.597	3	6.523	2	6.482	1
Botucatu	7.076	7.148	1	6.545	-8	6.524	-8	6.501	-8	6.476	-8	6.449	-9
Braúna	6.451	6.535	1	6.627	3	6.603	2	6.583	2	6.569	2	6.560	2
Campos do Jordão	8.421	8.321	-1	8.258	-2	8.541	1	8.568	2	8.569	2	8.569	2
Capão Bonito	6.130	6.171	1	6.746	10	6.568	7	6.434	5	6.350	4	6.302	3
Cosmorama	7.382	7.121	-4	6.920	-6	7.000	-5	7.066	-4	7.115	-4	7.148	-3
Cravinhos	7.224	7.764	7	7.659	6	7.693	6	7.725	7	7.749	7	7.768	8
Dracena	6.423	7.017	9	6.282	-2	6.214	-3	6.159	-4	6.116	-5	6.084	-5
Eldorado	7.083	7.064	0	7.419	5	7.380	4	7.360	4	7.356	4	7.358	4
Guaimbé	6.533	6.501	0	6.751	3	6.788	4	6.811	4	6.819	4	6.817	4
Guaratinguetá	7.296	6.863	-6	7.441	2	6.992	-4	6.671	-9	6.505	-11	6.427	-12
Iguape	10.153	10.022	-1	7.946	-22	7.802	-23	7.649	-25	7.508	-26	7.392	-27
Itapetininga	6.545	6.370	-3	6.539	0	6.422	-2	6.333	-3	6.273	-4	6.238	-5
Itapeva	5.939	6.179	4	5.958	0	5.914	0	5.882	-1	5.863	-1	5.853	-1
Jundiá	6.754	6.848	1	6.841	1	6.741	0	6.693	-1	6.677	-1	6.672	-1
Juquiá	8.089	7.836	-3	7.737	-4	7.968	-1	7.956	-2	7.855	-3	7.746	-4
Juquitiba	7.104	6.187	-13	7.638	8	7.848	10	8.026	13	8.166	15	8.272	16
Monte Alegre do Sul	7.355	7.337	0	7.413	1	7.630	4	7.715	5	7.734	5	7.737	5
Monte Alto	7.664	7.767	1	7.142	-7	7.155	-7	7.166	-6	7.171	-6	7.173	-6
Olímpia	6.930	7.298	5	7.132	3	7.155	3	7.178	4	7.194	4	7.202	4
Pedregulho	7.928	8.082	2	7.984	1	8.133	3	8.228	4	8.279	4	8.307	5
Pereira Barreto	6.217	6.496	4	6.424	3	6.426	3	6.437	4	6.453	4	6.467	4
Rancharia	6.409	6.665	4	6.545	2	6.579	3	6.606	3	6.624	3	6.636	4
Riversul	6.063	6.255	3	6.231	3	6.215	3	6.201	2	6.192	2	6.186	2
Sta. Cruz da Conceição	7.039	7.239	3	7.261	3	7.109	1	6.944	-1	6.816	-3	6.738	-4
Sta. Cruz do Rio Pardo	6.839	6.625	-3	6.692	-2	6.811	0	6.890	1	6.923	1	6.934	1
S. Joaquim da Barra	8.253	7.815	-5	7.853	-5	7.913	-4	7.958	-4	7.984	-3	7.995	-3
S. José do Rio Pardo	7.544	7.548	0	7.672	2	7.649	1	7.617	1	7.590	1	7.571	0
S. José do Rio Preto	6.857	6.627	-3	7.045	3	7.087	3	7.123	4	7.150	4	7.166	5
S. Miguel Arcanjo	6.163	6.210	1	6.894	12	6.690	9	6.577	7	6.543	6	6.544	6
S. Pedro	6.904	6.899	0	6.694	-3	6.717	-3	6.741	-2	6.765	-2	6.785	-2
Tabapuã	6.819	7.082	4	7.114	4	7.115	4	7.115	4	7.113	4	7.109	4
Tejupa	6.677	6.700	0	6.494	-3	6.511	-2	6.521	-2	6.527	-2	6.530	-2
Tietê	5.873	6.517	11	6.274	7	6.128	4	6.042	3	5.999	2	5.976	2
Urânia	6.556	6.605	1	6.488	-1	6.379	-3	6.301	-4	6.253	-5	6.225	-5

Ro: valor calculado da erosividade da chuva da estação, MJ mm ha⁻¹ h⁻¹ ano⁻¹; Ri: valor estimado da erosividade da chuva da estação MJ mm ha⁻¹ h⁻¹ ano⁻¹; ER: erro relativo percentual entre os valores de erosividade Ri e Ro, %.

Quadro 6. Valores dos índices ERM e c e desempenho da RNA desenvolvida e das interpolações

	RNA	ID1	ID2	ID3	ID4	ID5
ERM	0,0322	0,0414	0,0403	0,0429	0,0457	0,0479
c	0,89	0,73	0,71	0,68	0,63	0,60
Desempenho	Ótimo	Bom	Bom	Bom	Mediano	Sofrível

ERM: Erro relativo médio; c: Índice de confiança; Desempenho: Critérios de Classificação de Camargo & Sentelhas (1997); RNA: Rede neural artificial; ID m : Interpolação pelo método do inverso de uma potência da distância com expoente m .

motivo pelo qual se apresenta, na figura 2, o mapa de erosividade da chuva do Estado de São Paulo obtido com o uso da RNA.

Comparando as figuras 1 e 2, pode-se observar a influência tanto da altitude quanto da continentalidade na erosividade da chuva obtida pela RNA, verificando-se que os maiores valores de R são encontrados na região nordeste, nas Serras do Mar e Mantiqueira e no litoral do Estado, com uma tendência de declínio do valor de R com a redução da altitude e o afastamento do litoral.

Os resultados obtidos pela RNA para a geração do mapa de erosividade média anual da chuva do Estado de São Paulo mostram semelhança com os resultados obtidos por Bertoni & Lombardi Neto (1999).

No endereço eletrônico <http://www.ufv.br/dea/gprh/neterosividade>, encontra-se disponível o programa computacional “netErosividade SP”, que viabiliza a aplicação da RNA desenvolvida neste trabalho, além do mapa de erosividade média anual do Estado de São Paulo, em formato que permite sua manipulação em ferramentas de sistemas de informações geográficas.




Figura 2. Erosividade média anual da chuva para o Estado de São Paulo obtida pela RNA desenvolvida.

CONCLUSÕES

1. A utilização de redes neurais artificiais mostrou-se viável para a interpolação dos valores da erosividade da chuva no Estado de São Paulo.

2. A RNA desenvolvida apresentou melhor desempenho na estimativa da erosividade da chuva que o método de interpolação “Inverso de uma Potência da Distância”.

LITERATURA CITADA

- BAENA, L.G.N. Modelo para geração de séries sintéticas de dados climáticos. Viçosa, Universidade Federal de Viçosa, 2004. 154p. (Tese de Doutorado)
- BERTONI, J. & LOMBARDI NETO, F. Conservação do solo. 2.ed. São Paulo, Ícone, 1990. 355p.
- CAMARGO, A.P. & SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo. R. Bras. Agrometeorol., 5:89-97, 1997.
- CASTELLANO, G.; FANELLI, A.M. & PELILLO, M. An iterative pruning algorithm for feedforward neural networks. IEEE T Neural Networ, 8:519-531, 1997.
- EROSIVIDADE software. Versão 1.0, GPRH / IAC, Viçosa, MG, 1999.
- HAGAN, M.T.; DEMUTH, H.B. & BEALE, M. Neural network design. Boston, PWS Publishing Company, 1996. Não paginado.
- HERNANI, L.C.; FREITAS, P.L.; PRUSKI, F.F.; De MARIA, I.C.; CASTRO FILHO, C. & LANDERS, J.C. A erosão e seu impacto. In: MANZATTO, C.V.; FREITAS JÚNIOR, E. & PERES, J.R.R., eds. Uso agrícola dos solos brasileiros. Rio de Janeiro, Embrapa, 2002, p.47-60.
- KHOURY JÚNIOR, J.K. Desenvolvimento e avaliação de um sistema de visão artificial para classificação de madeira serrada de eucalipto. Viçosa, MG, Universidade Federal de Viçosa, 2004. 101p. (Tese de Doutorado)
- LI, B. Spatial interpolation of weather variables using artificial neural networks. Athens, University of Georgia, 2002. 89p. (Tese de Mestrado)

- LOMBARDI NETO, F. & MOLDENHAUER, W.C. Erosividade da chuva: sua distribuição e relação com perdas de solo em Campinas, SP. *Bragantia*, 51:189-196, 1992.
- MAIER, H.R. & DANDY, G.C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environ. Modell. Softw.*, 15:101-123, 2000.
- MATLAB software. Version 6.0. Natick, The MathWorks, Inc., 2000.
- MORAIS, L.F.B.; SILVA, V.; NASCHENVENG, T.M.C.; HARDOIN, P.C.; ALMEIDA, J.E.L.; WEBER, O.L.S.; BOEL, E. & DURIGON, V. Índice EI30 de chuva e sua relação com o coeficiente de chuva do sudoeste de Mato Grosso. *R. Bras. Ci. Solo*, 15:339-444, 1991.
- PENG, C. & WEN, X. Recent applications of artificial neural networks in forest resource management: an overview. In CORTÉ, U. & SÁNCHEZ-MARRÈ, M., eds. *Environmental Decision Support Systems and Artificial Intelligence*. Menlo Park, AAAI Press, 1999. p.15-22.
- RUFINO, R.L.; BISCAIA, R.C.M. & MERTEN, G.H. Determinação do potencial erosivo da chuva do Estado do Paraná, através de pluviometria: terceira aproximação. *R. Bras. Ci. Solo*, 17:439-444, 1993.
- SÁRKÖZY, F. Gis functions - Interpolation. *Periodica Polytechnica Ser. Civ. Eng.*, 43:63-86, 1999.
- SCHAEFFER, D.L. A model evaluation methodology applicable to environmental assessment models. *Ecol. Model.*, 8:275-295, 1980.
- SILVA, A.M. Rainfall erosivity map for Brazil. *Catena*, 57:251-259, 2004.
- VAL, L.A.; BAHIA, V.G.; FREIRE, J.C. & DIAS JÚNIOR, M.S. Erosividade das chuvas em Lavras, MG. *Ci. Prática*, 10:199-209, 1986.
- WILLMOTT, C.J. On the validation of models. *Phys. Geogr.*, 2:184-194, 1981.
- WISCHMEIER, W.H. & SMITH, D.D. Rainfall energy and its relationship to soil loss. *Trans. Am. Geophys Union*, 39:285-291, 1958.