



UM MODELO DE MAPAS AUTO-ORGANIZÁVEIS PARA ANÁLISE E ESTIMATIVA DA PRODUÇÃO DE SEDIMENTOS EM UMA MICROBACIA LOCALIZADA NO SEMIÁRIDO PARAIBANO

Camilo Allyson Simões de Farias¹, José Adalberto da Silva Filho² & Ulisses Alencar Bezerra³

RESUMO --- A definição de estratégias para o gerenciamento adequado de processos erosivos normalmente pressupõe o uso de modelos hidrossedimentológicos confiáveis. O manejo em regiões semiáridas, caracterizadas pela baixa pluviometria, altas taxas de evaporação e ocorrência de chuvas intensas, se torna mais difícil em função das grandes quantidades de sedimentos que tendem a ser produzidas apenas em períodos isolados. O objetivo desse estudo é desenvolver e verificar a aplicabilidade de um modelo de mapas auto-organizáveis para análise e estimativa da produção de sedimentos em uma microbacia localizada na Bacia Experimental de Sumé - PB. Para calibração e validação do modelo, utilizaram-se dados de produção de sedimentos, lâmina de escoamento, altura média da vegetação, e duração e intensidade da chuva correspondentes a 101 e 26 eventos, respectivamente, ocorridos entre 1985 e 1991. A partir dos mapas gerados, foi possível analisar e extrair diversas informações acerca das variáveis envolvidas na modelagem hidrossedimentológica. Os resultados do coeficiente de *Nash-Sutcliffe* entre dados calculados e observados para produção de sedimentos foram considerados eficazes, com valores iguais a 0,74 e 0,83 para os conjuntos de dados de calibração e validação, respectivamente.

ABSTRACT --- The definition of strategies for the appropriate management of erosive processes usually requires the use of reliable hydro-sedimentological models. The management in semiarid regions, characterized by low rainfalls, high evaporation rates and intense rainfalls, is more difficult due to the large amounts of sediments that tend to be produced only periodically. The aim of this study is to develop and verify the applicability of Self-Organizing Maps in order to analyze and estimate sediment yields in a watershed inside the Experimental Basin of *Sumé*, which is located in *Paraíba* State, Brazil. With the purpose of calibrating and validating the model, we used data from sediment yield, runoff, vegetation average height, and duration and intensity of rainfall corresponding to 101 and 26 events, respectively, which occurred between 1985 and 1991. From the generated maps, it was possible to analyze and extract information about several variables involved in the hydro-sedimentological modeling. The results for the Nash-Sutcliffe coefficient between calculated and observed data for sediment yields were considered to be effective with values equal to 0.74 and 0.83 for the calibration and test data sets.

Palavras-chave: redes neurais artificiais, mapas de Kohonen, hidrossedimentologia, modelagem.

¹ Prof. Adjunto III, Dr. Eng., Univ. Federal de Campina Grande / Câmpus Pombal - PB, Rua Jário Vieira Feitosa, 1.770, Pombal - PB. E-mail: camilo@ccta.ufcg.edu.br

² Graduando em Eng. Ambiental, Univ. Federal de Campina Grande / Câmpus Pombal - PB, Rua Jário Vieira Feitosa, 1.770, Pombal - PB. E-mail: ulisses_hand_13@hotmail.com

³ Graduando em Eng. Ambiental, Univ. Federal de Campina Grande / Câmpus Pombal - PB, Rua Jário Vieira Feitosa, 1.770, Pombal - PB. E-mail: jose_adalberto_silva@hotmail.com

INTRODUÇÃO

As severas condições naturais observadas no semiárido nordestino, caracterizado por escassos e, em geral, intensos eventos de chuva, propiciam a produção de grandes quantidades de sedimentos em períodos isolados, que podem, eventualmente, provocar assoreamento de corpos hídricos e prejudicar a qualidade ambiental e a produtividade agrícola (FARIAS & SANTOS, 2014; VANMAERCCKE *et al.*, 2010).

A modelagem hidrossedimentológica baseada em ferramentas de inteligência artificial, a exemplo das redes neurais artificiais, tem surgido como uma opção para conhecer e buscar alternativas para mitigar os efeitos adversos dos processos erosivos. Nesse campo de pesquisa, pode-se destacar os trabalhos realizados por Cobaner *et al.* (2009), Farias & Alves (2010), Farias & Santos (2014), Licznar & Nearing (2003) e Márquez & Guevara-Pérez (2010).

Recentemente, no estudo de Farias & Santos (2014), um modelo baseado em mapas auto-organizáveis (MAO) mostrou-se promissor na estimativa da produção de sedimentos em uma parcela experimental de erosão localizada no semiárido paraibano. Os modelos MAO são definidos como redes neurais artificiais cujo aprendizado é classificado como não supervisionado. Nesse tipo de modelagem, que é muito utilizada na classificação de padrões e *clustering* de dados, os elementos de entrada são agrupados em classes de acordo com suas similaridades por meio de métodos de treinamento competitivo (HAYKIN, 1999; KOHONEN, 1982).

Nesse estudo, buscar-se-á desenvolver e verificar a aplicabilidade de um modelo MAO para análise e estimativa da produção de sedimentos em uma microbacia localizada na Bacia Experimental de Sumé – PB.

MÉTODOS E MATERIAIS

Área de Estudo

A área de estudo selecionada é uma microbacia localizada na Bacia Experimental de Sumé, estado da Paraíba, na latitude 7° 40' S e longitude 37° 00' O. Essa bacia experimental está inserida na Bacia Hidrográfica do Rio Paraíba e suas instalações compreendem quatro microbacias com áreas entre 0,5 e 1 ha, nove parcelas experimentais de erosão de 100 m² e uma sub-bacia de 10 km². Essa região é caracterizada por um clima semiárido, com baixa pluviometria e altas taxas de evaporação. A cobertura vegetal predominante é a caatinga nativa (SRINIVASAN & GALVÃO, 2003).

Nas Figuras 1 e 2 encontram-se a localização da Bacia Experimental de Sumé e o levantamento topográfico da Microbacia 4, que foi escolhida como estudo de caso. As características físicas da Microbacia 4 estão mostradas na Tabela 1.

Os dados de lâmina de água escoada, altura média da vegetação, duração e intensidade de precipitações, e produção de sedimentos resultantes de eventos de chuva ocorridos entre 1985 e 1991 foram adquiridos a partir do trabalho de Srinivasan & Galvão (2003). Assim como os dados supracitados, a metodologia detalhada da sua coleta e processamento pode ser obtida em Srinivasan & Galvão (2003).

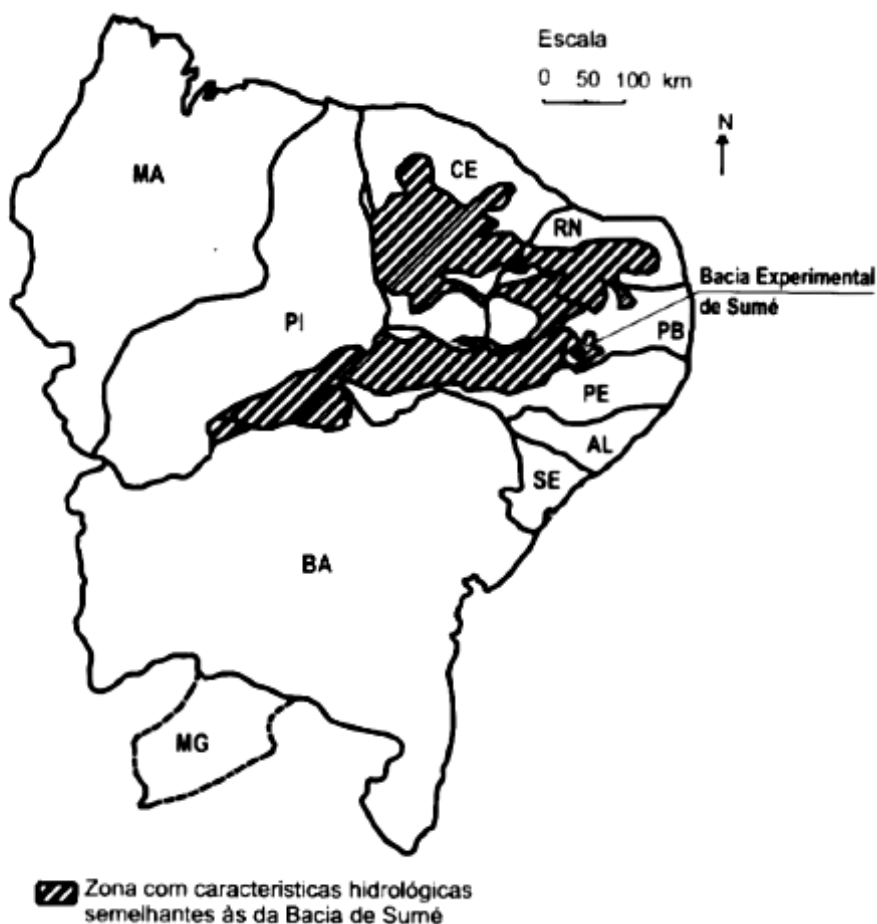


Figura 1 – Localização da Bacia Hidrográfica de Sumé - PB.
Fonte: Cadier *et al.*, 1983 *apud* Srinivasan & Galvão (2003).




Figura 2 – Levantamento topográfico da Microbacia 4.
 Fonte: Srinivasan & Galvão (2003).

Tabela 1 – Características físicas da Microbacia 4.

Área (ha)	Perímetro (m)	Declividade Média (%)	Cobertura Vegetal
0,48	270	6,8	Desmatada

Fonte: Cadier *et al.* (1983) *apud* Srinivasan & Galvão (2003).

Modelo de Mapas Auto-Organizáveis

Estrutura e Treinamento

A modelagem com mapas auto-organizáveis (MAO) consiste em representar vetores de entrada de um espaço multidimensional em espaços unidimensionais ou bidimensionais, mantendo-se a relação de vizinhança dos dados (SILVA *et al.*, 2010). A arquitetura da rede MAO desse estudo possui uma camada de entrada multidimensional e uma camada de saída bidimensional, também conhecida como camada competitiva. Na camada de saída, os neurônios concorrem entre si e

apenas um deles é considerado o vencedor, ou seja, a classe mais adequada para um determinado vetor de entrada. Nessas redes, cada elemento do vetor de entrada está conectado a todos os elementos da camada de saída. A força das conexões é medida por meio de pesos w_{ij} entre os vetores de entrada j e os neurônios da camada de saída i .

Nessa pesquisa, os vetores da camada de entrada possuem cinco componentes: lâmina escoada L , em [mm]; altura média da vegetação h , em [cm]; duração D do evento de chuva, em [min]; intensidade da chuva i , em mm min^{-1} ; e produção de sedimentos S , em kg ha^{-1} . Na camada de saída foram utilizados neurônios hexagonais, cujos pesos também possuem cinco componentes, correspondentes à dimensão dos vetores de entrada. Com base nas diretrizes sugeridas por García & González (2004), utilizou-se uma malha de 7×7 neurônios, fornecendo-se um mapa com 49 neurônios.

De forma básica, para treinar o modelo MAO, calcula-se as distâncias Euclidianas DI_i entre o vetor de entrada e os pesos ligados a cada um dos neurônios de saída i , conforme mostrado na Equação (1).

$$DI_i = \sqrt{\sum_{j=1}^5 (x_j - w_{ij})^2}; \text{ for } i = 1, 2, \dots, 49. \quad (1)$$

onde x_j é o j -ésimo componente do vetor de entrada \mathbf{x} .

O neurônio de saída i que possuir a menor distância Euclidiana ao vetor de entrada é considerado o neurônio vencedor. Os pesos conectados a este neurônio i^* e aos neurônios dentro de um certo raio de vizinhança Vi^* são então atualizados pela regra de Kohonen, conforme estabelecido em Beale *et al.* (2012). A vizinhança inicial foi estabelecida como a distância de três passos entre neurônios. Na Figura 3, visualiza-se a estrutura do modelo MAO desse estudo.

A apresentação dos vetores de entrada a rede é conduzida utilizando-se todo o conjunto de dados antes de qualquer atualização de pesos, numa forma de apresentação conhecida como modo de lote. Nesse modo, a seleção do neurônio vencedor é efetuada para cada vetor de entrada e então o vetor peso é movido para uma posição específica calculada pela média dos vetores de entrada para o qual o neurônio foi o vencedor ou vizinho do vencedor. Após várias apresentações do conjunto de dados de entrada, os pesos tendem a se estabilizar (BEALE *et al.*, 2012; FARIAS *et al.*, 2013; FARIAS & SANTOS, 2014).

O treinamento ocorreu em duas fases: (1) fase de ordenação e (2) fase de ajustes. Na fase de ordenação, o treinamento limitou-se a 100 apresentações do conjunto de dados de calibração, com o raio da vizinhança inicial igual a três passos e valor final igual a um. Para fase de ajustes, em que o raio da vizinhança fica abaixo da unidade e, portanto, há atualização somente no peso do neurônio vencedor, utilizou-se mais 100 apresentações. Mais detalhes sobre as fases de ordenação e ajustes podem ser vistos em Beale *et al.* (2012).

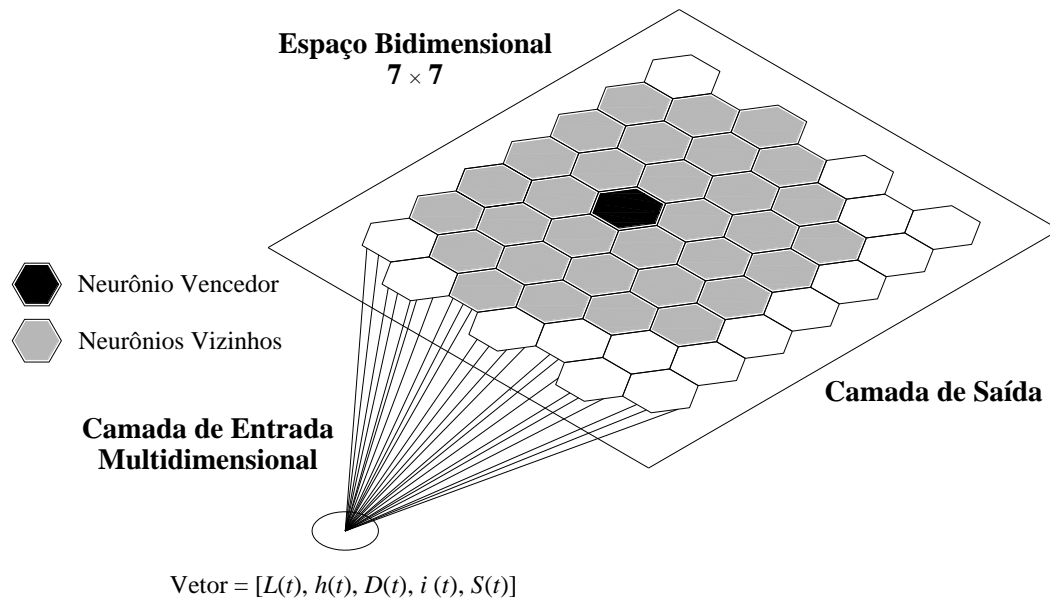


Figura 3 – Estrutura do modelo MAO.
Fonte: Adaptado de Farias & Santos (2014)

Antes do treinamento, os dados de entradas foram convenientemente escalonados para melhorar a eficiência na calibração do modelo MAO. O processo de escalonamento consistiu em normalizar os dados de forma que a média fosse igual a zero e o desvio padrão unitário (BEALE *et al.*, 2012).

O modelo MAO foi implementado em MATLAB R2012a utilizando o Neural Network Toolbox (BEALE *et al.*, 2012)

Previsão com o Modelo MAO

Depois de treinadas, as redes MAO foram utilizadas como ferramenta de previsão. Para tal, considerou-se o vetor de entrada com a ausência da variável (componente) a ser estimada,

adotando-se os seguintes passos: (1) calcular as distâncias Euclidianas entre o vetor de entrada e todos os neurônios do modelo MAO; (2) determinar o neurônio vencedor com base na menor distância Euclidiana; e (3) usar o peso do neurônio vencedor ligado ao elemento ausente do vetor de entrada como a estimativa.

Para calibração e validação do modelo, utilizaram-se dados de produção de sedimentos, lâmina escoada, altura média da vegetação, e duração e intensidade da chuva correspondentes a 101 e 26 eventos, respectivamente, ocorridos entre 1985 e 1991.

RESULTADOS E DISCUSSÃO

Durante o treinamento, com a utilização dos 101 eventos de calibração, observou-se uma alocação dos dados no mapa conforme mostrado na Figura 4. A partir dessa figura, identifica-se que a maior parte dos dados de entrada se localizou na parte superior direita do mapa.




Figura 4 – Distribuição dos dados de calibração no modelo MAO.

Na Figura 5 encontra-se os planos ou mapas de componentes do modelo MAO calibrado. A simulação dos valores das variáveis em estudo para os distintos neurônios ou classes é realizada por meio de uma escala de cores. As zonas amarelas correspondem aos maiores valores e as regiões em cor preta aos menores.

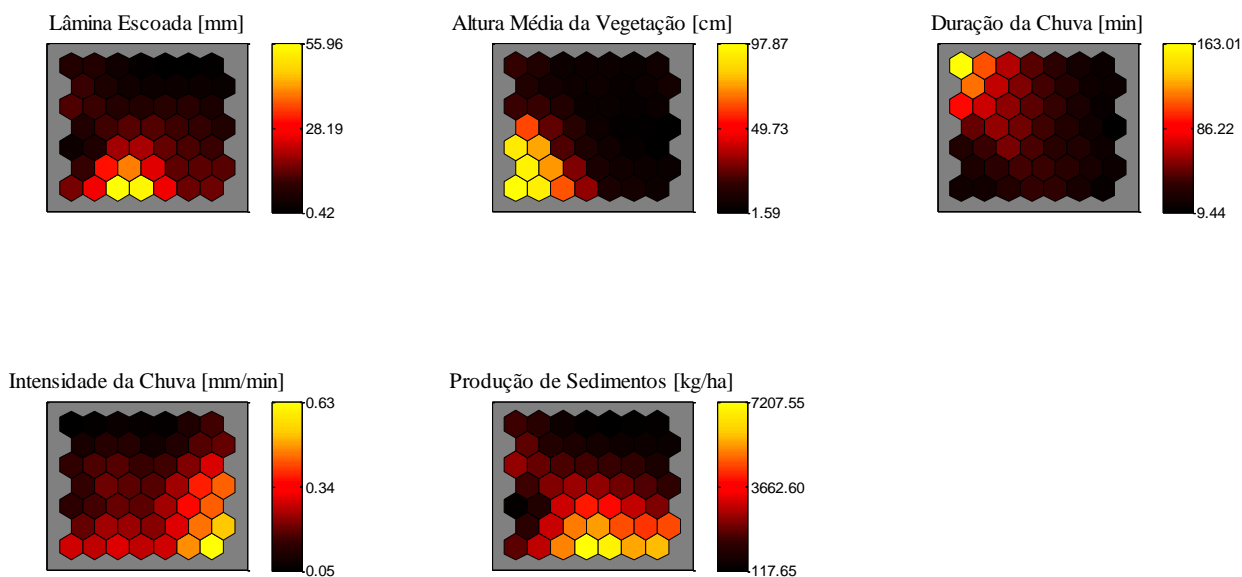


Figura 5 – Planos de componentes derivados da calibração do modelo MAO.

Ao comparar os mapas da lâmina escoada e de intensidade de chuva com o mapa de produção de sedimentos, averigua-se que as maiores quantidades de sedimentos são geradas nas classes em que se tem maiores vazões e/ou intensidades de chuva. Esse resultado é coerente com o observado no trabalho de Farias & Santos (2014), em que um modelo baseado em mapas auto-organizáveis foi utilizado na estimativa da produção de sedimentos em uma parcela experimental de erosão localizada no semiárido paraibano. Ao analisar os gradientes da duração da chuva com o de sua intensidade, constata-se que essas grandezas são inversamente proporcionais. Ao observar o mapa de altura média da vegetação, observa-se que quando os valores da altura média são altos, as produções de sedimentos tendem a ser médias ou baixas, mesmo quando há valores médios de lâmina de escoamento e intensidade de chuva.

O modelo MAO foi testado para estimativa da produção de sedimentos considerando 26 eventos de chuva totalmente independentes dos dados de calibração do modelo. Para isso, efetuou-se a medida da distância Euclidiana do vetor de entrada, sem a componente produção de sedimentos, para cada neurônio do mapa. Após identificado o neurônio com a menor distância Euclidiana, tomou-se o valor do seu peso correspondente a produção de sedimentos como a estimativa. A avaliação do desempenho do modelo MAO para estimativa da produção de sedimento baseou-se nos índices de correlação (R), viés relativo (VR) e eficiência $NASH$ (NASH & SUTCLIFFE, 1970). Na Tabela 2 mostra-se os resultados de desempenho considerando tanto o

conjunto de dados de calibração como o de testes. Nas Figuras 6 e 7 encontram-se os gráficos com valores de produção de sedimentos observados e calculados para os períodos de calibração e validação, respectivamente.

Tabela 2 – Desempenho do modelo MAO para estimativa da produção de sedimentos.

Conjunto de Dados	<i>NASH</i>	<i>R</i>	<i>VR</i>
Calibração	0,74	0,88	-8,07%
Teste	0,83	0,92	7,40%




Figura 6 – Valores observados e calculados de produção de sedimentos para os eventos do conjunto de dados de calibração.

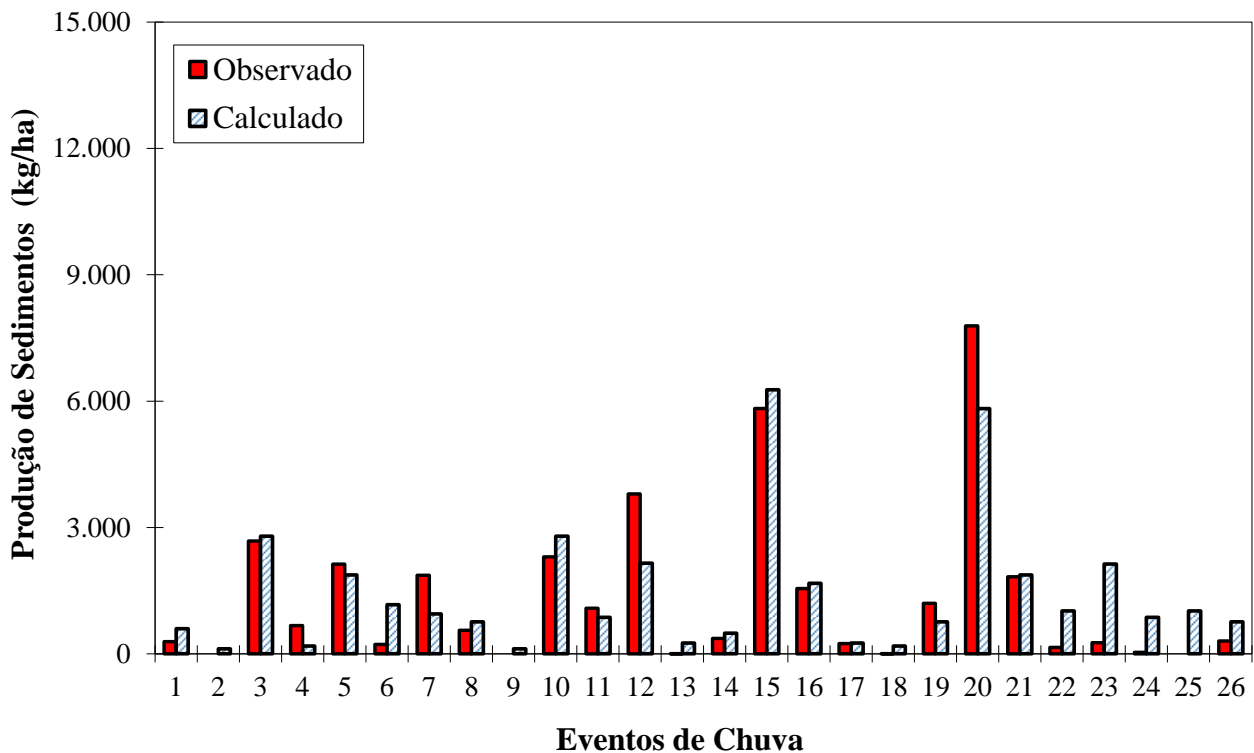


Figura 7 – Valores observados e calculados de produção de sedimentos para os eventos do conjunto de dados de validação.

Em termos de previsão, modelos hidrológicos que produzem valores de *NASH* iguais ou superiores a 0,75 são considerados eficazes (COLLISCHONN, 2001). Diante disso, pode-se considerar que os resultados produzidos pelo modelo MAO, tanto na calibração como na validação, são aceitáveis. Ao analisar as Figuras 6 e 7, é possível visualizar uma forte aderência entre as produções de sedimentos calculadas e observadas.

Os valores de correlação se apresentaram altos tanto para calibração ($R = 0,88$) como para validação ($R = 0,92$). Em análise aos resultados de viés relativo para a calibração e validação, percebe-se que houve subestimação e superestimação do modelo, respectivamente. Todavia, esses valores foram inferiores a 10%, indicando que o modelo MAO possui qualidade na previsão.

CONCLUSÕES

Nesse estudo, apresentou-se um modelo de mapas auto-organizáveis (MAO) para análise e estimativa da produção de sedimentos em uma microbacia hidrográfica localizada do semiárido paraibano, mais especificamente na Bacia Experimental de Sumé - PB.

Com o propósito de verificar a eficácia do modelo, um estudo comparativo entre dados calculados e observados da produção de sedimentos foi conduzido por meio de índices de desempenho. Com essa investigação, em que se utilizou um período de testes totalmente independente dos dados utilizados na calibração do modelo, averiguou-se que o modelo MAO apresentou qualidade na estimativa da produção de sedimentos.

Entendeu-se, também, que os mapas gerados pelo modelo mostraram-se viáveis como instrumentos de análise, principalmente por possibilitar a identificação visual, por meio do gradiente de cores em cada mapa, de correlações diretas e inversas entre as variáveis envolvidas na modelagem.

A partir dos resultados obtidos, sugere-se que este tipo de modelo seja testado para outras bacias hidrográficas, considerando diferentes escalas espaciais, com o objetivo de consolidar essa ferramenta de manejo na prevenção de riscos associados à produção de grandes quantidades de sedimentos.

AGRADECIMENTOS

Este trabalho foi realizado com apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (Processo n.º 477838/2013-8).

BIBLIOGRAFIA

BEALE, M.; HAGAN, M.; DEMUTH, H. **Neural Network Toolbox 7.0.3: User's Guide**. Natick: The MathWorks Inc., 2012. p. 404.

CADIER, E.; FREITAS, B. J. DE; LEPRUN, J. C. **Bacia Experimental de Sumé: Instalação e Primeiros Resultados**. Recife - PB: SUDENE, 1983. p. 87.

COBANER, M.; UNAL, B.; KISI, O. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. **Journal of Hydrology**, v. 367, n. 1-2, p. 52–61, mar 2009.

COLLISCHONN, W. **Simulação Hidrológica em Grandes Bacias**. [S.l.]: Universidade Federal do Rio Grande do Sul, 2001.

FARIAS, C. A. S. D. E.; ALVES, F. M. An ANN-based approach to modelling sediment yield : a case study in a semi-arid area of Brazil. v. 2, n. June, p. 14–18, 2010.

- FARIAS, C. A. S. DE; SANTOS, C. A. G. The use of Kohonen neural networks for runoff–erosion modeling. **Journal of Soils and Sediments**, v. 14, n. 7, p. 1242–1250, 21 jan 2014.
- FARIAS, C. A. S. DE; SANTOS, C. A. G.; LOURENÇO, A. M. G.; CARNEIRO, T. C. Kohonen neural networks for rainfall-runoff modeling: case study of Piancó River Basin. **Journal of Urban and Environmental Engineering**, v. 7, n. 1, p. 176–182, 30 jun 2013.
- GARCÍA, H. L.; GONZÁLEZ, I. M. Self-organizing map and clustering for wastewater treatment monitoring. **Engineering Applications of Artificial Intelligence**, v. 17, n. 3, p. 215–225, abr 2004.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd Ed. ed. Upper Saddle River: Prentice Hall, 1999.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, n. 1, p. 59–69, 1982.
- LICZNAR, P.; NEARING, M. . Artificial neural networks of soil erosion and runoff prediction at the plot scale. **CATENA**, v. 51, n. 2, p. 89–114, fev 2003.
- MÁRQUEZ, A.; GUEVARA-PÉREZ, E. Comparative analysis of erosion modeling techniques in a basin of Venezuela. **Journal of Urban and Environmental Engineering**, v. 4, n. 2, p. 81–104, 31 dez 2010.
- NASH, J. E.; SUTCLIFFE, J. V. River Flow Forecasting through Conceptual Models: Part I - A Discussion of Principles. **Journal of Hydrology**, v. 10, n. 3, p. 282–290, 1970.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINOLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo - SP: Artliber, 2010. p. 399.
- SRINIVASAN, V. S.; GALVÃO, C. DE O. **Bacia Experimental de Sumé: Descrição e Dados Coletados**. Campina Grande - PB: UFCG/CNPq, 2003. p. 129.
- VANMAERCKE, M.; ZENEBE, A.; POESEN, J.; *et al.* Sediment dynamics and the role of flash floods in sediment export from medium-sized catchments: a case study from the semi-arid tropical highlands in northern Ethiopia. **Journal of Soils and Sediments**, v. 10, n. 4, p. 611–627, 19 mar 2010.